XI ХАЛЫҚАРАЛЫҚ ҒЫЛЫМИ-ТӘЖІРИБЕЛІК КОНФЕРЕНЦИЯ

**«ИНФОРМАТИКА ЖӘНЕ ҚОЛДАНБАЛЫ МАТЕМАТИКА»**

XI МЕЖДУНАРОДНАЯ НАУЧНО-ПРАКТИЧЕСКАЯ КОНФЕРЕНЦИЯ

**«ИНФОРМАТИКА И ПРИКЛАДНАЯ МАТЕМАТИКА»**

XI INTERNATIONAL SCIENTIFIC AND PRACTICAL CONFERENCE

**«COMPUTER SCIENCE AND APPLIED MATHEMATICS»**

**CSAM 2026**

# МАТЕРИАЛЫ

## КОНФЕРЕНЦИИ

*Конференция материалдары • Conference Proceedings*

**ТОМ 1**

Казахский национальный университет имени аль-Фараби
Институт информационных и вычислительных технологий КН МНВО РК
Люблинский технический университет (г. Люблин, Польша)
Университет «Туран»

**7–11 октября 2026 г.**

Алматы, 2026

УДК 004.4:519.6 (063)
ББК 32.973.202
И 74

**Главный редактор:**
академик НАН РК, доктор физико-математических наук, профессор
**Калимолдаев М.Н.**

**Ответственные редакторы:**
декан механико-математического факультета КазНУ имени аль-Фараби, к.ф.-м.н., профессор **Мансурова М.Е.**
ученый секретарь ИИВТ КН МНВО РК, PhD, ассоц. профессор **Усатова О.А.**
старший научный сотрудник ИИВТ КН МНВО РК, PhD, ассоц. профессор **Зиятбекова Г.З.**
старший научный сотрудник ИИВТ КН МНВО РК, PhD **Аршидинова М.Т.**
заведующая кафедрой «Искусственный интеллект и Big Data» КазНУ имени аль-Фараби, PhD **Сарсембаева Т.С.**
секретарь конференции, КазНУ имени аль-Фараби **Айдарова Л.Н.**

**И 74 Информатика и прикладная математика**: Материалы XI Междунар. науч.-практ. конф. (07.10 – 11.10.2026 г.). В 2-х т. Т. 1. – Алматы, 2026. – 422 с.

ISBN 978-601-228-615-1 (т. 1)
ISBN 978-601-228-614-4 (общ.)

В сборнике опубликованы доклады, представленные учеными Республики Казахстан, Российской Федерации, Республики Узбекистан, Азербайджанской Республики, Кыргызской Республики, Турецкой Республики, Республики Польша, Венгрии, Индии, Греции, Китайской Народной Республики и других стран.

Рассмотрены актуальные вопросы математического моделирования, оптимизации и вычислительного анализа, искусственного интеллекта, больших данных и интеллектуальных систем, инноваций в области управления компьютерными науками и инженерии, кибербезопасности, конфиденциальности и цифрового доверия.

Материалы сборника предназначены для научных работников, докторантов, магистрантов, а также студентов старших курсов.

УДК 004.4:519.6 (063)
ББК 32.973.202

ISBN 978-601-228-615-1 (т. 1)
ISBN 978-601-228-614-4 (общ.)

© Институт информационных и вычислительных технологий КН МНВО РК, 2026
© Казахский национальный университет имени аль-Фараби, 2026

# КРАТКАЯ ПРОГРАММА
## XI Международной научно-практической конференции
## «Информатика и прикладная математика»
## «Computer Science and Applied Mathematics»

**Дата проведения:** **7–11 октября 2026 г.**

**Время:** **09:00–18:00**

**Место проведения:** **Библиотека КазНУ имени аль-Фараби,**
**зал Абая (ауд. № 308), ауд. № 408**
**г. Алматы, проспект аль-Фараби, 71/27**

| | |
|---|---|
| **Среда, 7 октября** | |
| **09:00–18:00** | Встреча и прибытие зарубежных участников |
| **Четверг, 8 октября** | |
| **09:30–10:00** | Официальная регистрация участников конференции и встреча гостей |
| **10:00–11:00** | **Приветственное слово** |
| **11:00–13:10** | **Пленарное заседание** |
| **13:10–14:30** | Перерыв на обед |
| **14:30–16:00** | Секционные заседания |
| **16:00–18:00** | Круглый стол «Искусственный интеллект и языковые технологии: от научных основ к технологиям будущего» |
| **Пятница, 9 октября** | |
| **10:00–12:10** | **Пленарное заседание** |
| **12:10–14:30** | Перерыв на обед |
| **14:30–17:10** | Секционные заседания |
| **Суббота, 10 октября** | |
| **09:00–18:00** | День культурной и социальной программы |
| **Воскресенье, 11 октября** | |
| **Завершение работы конференции, отъезд участников** | |

**ОРГАНИЗАТОРЫ И КОМИТЕТЫ КОНФЕРЕНЦИИ**
**XI Международной научно-практической конференции**
**«Информатика и прикладная математика»**
**«Computer Science and Applied Mathematics»**

**Организаторы:**

- Казахский национальный университет имени аль-Фараби (г. Алматы, Республика Казахстан)
- Институт информационных и вычислительных технологий КН МНВО РК (г. Алматы, Республика Казахстан)
- Люблинский технический университет (г. Люблин, Польша)
- Университет «Туран» (г. Алматы, Республика Казахстан)

## Программный комитет

**Председатель Международного программного комитета:**

- Калимолдаев Максат Нурадилович, академик НАН РК, д.ф.-м.н., профессор, Республика Казахстан

**Сопредседатели Международного программного комитета:**

- Бекманова Гульмира Тылеубердиевна, к.т.н., доктор PhD, доцент, Республика Казахстан
- Ибраимов Маргулан Касенович, PhD, доцент, Республика Казахстан
- Разакова Дина Ибрагимовна, PhD, доцент, Республика Казахстан

**Заместители Председателя Международного программного комитета:**

- Мансурова Мадина Есимхановна, к.ф.-м.н., профессор, Республика Казахстан
- Усатова Ольга Александровна, PhD, ассоц. профессор, Республика Казахстан
- Зиятбекова Гулзат Зиятбековна, PhD, ассоц. профессор, Республика Казахстан

**Члены Международного программного комитета:**

- Abdul Razaque, PhD, USA
- Abdullayev Fahreddin, professor, Turkey
- Aijaz Shaikh, professor, Finland
- Andrzej Smolarz, professor, Poland
- Dietmar Beyer, PhD, Germany
- Dmitrishin Roman, professor, Ukraine
- Hazar Elman, professor, Turkey

- Karimov Adalat, professor, Azerbaijan
- Keylan Alimhan, professor, Japan
- Maksim Iavich, PhD, professor, Georgia
- Michele Pagano, professor, Italy
- Mohamed Othman, professor, Malaysia
- Mosavi Amir, professor, Hungary
- Müslüm Arici, professor, Turkey
- Ravil Muhamediev, professor, Latvia
- Айда-заде Камиль Раджабович, д.ф.-м.н., профессор, член-корреспондент НАН Азербайджана
- Мальцева Светлана Валентиновна, д.т.н., профессор, Россия
- Марченко Михаил Александрович, д.т.н., профессор, Россия
- Матерухин Андрей Викторович, д.т.н., профессор, Россия
- Медведев Сергей Борисович, д.ф.-м.н., профессор, Россия
- Посыпкин Михаил Анатольевич, член-корреспондент РАН, Россия
- Родионов Алексей Сергеевич, д.т.н., профессор, Россия
- Тузиков Александр Васильевич, д.т.н., профессор, член-корреспондент НАН Беларуси
- Алгазы Кунболат Тилеуханулы, PhD, Республика Казахстан
- Аманжолова Сауле Токсановна, к.т.н., ассоц. профессор, Республика Казахстан
- Амиргалиева Салтанат Нурадиловна, д.ф.-м.н., профессор, Республика Казахстан
- Амирханова Гульшат Аманжоловна, доктор PhD, Республика Казахстан
- Ахметжанов Максат Аканович, PhD, Республика Казахстан
- Ахметов Искандер Рафаилович, PhD, Республика Казахстан
- Бабенко Татьяна Васильевна, д.т.н., профессор, Республика Казахстан
- Боймуродов Фаррух Фарход угли, PhD, Республика Узбекистан
- Байтенова Лаура Маратовна, к.э.н., профессор, Республика Казахстан
- Барахнин Владимир Борисович, д.т.н., профессор, Россия
- Бегимбаева Енлик Ериковна, PhD, Республика Казахстан
- Бектемесов Мактагали Абдимажитович, д.ф.-м.н., профессор, Республика Казахстан
- Бектемысова Гульнара Умиткуловна, к.т.н., ассоц. профессор, Республика Казахстан
- Бельгибаев Бауржан Абдрахимович, д.т.н., доцент, Республика Казахстан

- Галбаев Жалалидин Токтобаевич, д.т.н., профессор, Кыргызская Республика
- Дарибаев Беимбет Серикович, PhD, ассоц. профессор, Республика Казахстан
- Жартыбаева Макпал Галымбековна, PhD, Республика Казахстан
- Жукабаева Тамара Кукеновна, PhD, Республика Казахстан
- Иманкулов Тимур Сакенович, PhD, ассоц. профессор, Республика Казахстан
- Искаков Казизат Такуадинович, д.ф.-м.н., профессор, Республика Казахстан
- Исмаилов Бактыбек Искакович, д.т.н., профессор, Кыргызская Республика
- Ишанходжаев Гайрат, д.т.н., профессор, Республика Узбекистан
- Калинин Алексей Анатольевич, PhD, доцент, Республика Казахстан
- Калижанова Алия Уалиевна, к.ф.-м.н., профессор, Республика Казахстан
- Капалова Нурсулу Алдажаровна, к.т.н., ассоц. профессор, Республика Казахстан
- Карюкин Владислав Игоревич, PhD, Республика Казахстан
- Киселева Ольга Владимировна, к.т.н., ассоц. профессор, Республика Казахстан
- Козбакова Айнур Холдасовна, PhD, ассоц. профессор, Республика Казахстан
- Кошеков Кайрат Темирбаевич, д.т.н., профессор, академик НАН РК, Республика Казахстан
- Касымбек Нурислам, PhD, Республика Казахстан
- Лисневский Ростислав Валерьевич, PhD, ассоц. профессор, Республика Казахстан
- Мазаков Талгат Жакупович, д.ф.-м.н., профессор, Республика Казахстан
- Мусабаев Рустам Рафикович, к.т.н., ассоц. профессор, Республика Казахстан
- Мусиралиева Шынар Женисбековна, к.ф.-м.н., доцент, Республика Казахстан
- Найзабаева Ляззат Кадыралиевна, д.т.н., профессор, Республика Казахстан
- Назирова Эльмира Шодмоновна, д.т.н., профессор, Республика Узбекистан
- Нуралиев Фахриддин Муродиллаевич, д.т.н., профессор, Республика Узбекистан
- Омаров Батырхан, PhD, Республика Казахстан
- Пак Александр Александрович, к.т.н., профессор, Республика Казахстан
- Пак Иван Тимофеевич, д.т.н., профессор, Республика Казахстан
- Рахимова Диана Рамазановна, PhD, Республика Казахстан

- Равшанов Нормахмад, д.т.н., профессор, Республика Узбекистан
- Сакан Кайрат, PhD, Республика Казахстан
- Сатыбалдина Дина Жагипаровна, к.ф.-м.н., ассоц. профессор, Республика Казахстан
- Сеилова Нургуль Абадуллаевна, к.т.н., ассоц. профессор, Республика Казахстан
- Сеилов Шахмаран Журсинбекович, д.э.н., профессор, Республика Казахстан
- Сейткулов Ержан Нураханович, к.ф.-м.н., ассоц. профессор, Республика Казахстан
- Сембиев Ордабай Зайтаевич, д.т.н., профессор, Республика Казахстан
- Тастанова Саида Алдияровна, д.т.н., PhD, доцент, Республика Узбекистан
- Ташатов Нурлан Наркенович, к.ф.-м.н., PhD, ассоц. профессор, Республика Казахстан
- Тиреуов Канат Маратович, академик НАН РК, д.э.н., Республика Казахстан
- Торобеков Бекжан Торобекович, д.т.н., профессор, Кыргызская Республика
- Тукеев Уалшер Ануарбекович, д.т.н., профессор, Республика Казахстан
- Турарбек Асем, PhD, Республика Казахстан
- Тусупова Сауле Амангельдиевна, д.т.н., профессор, Республика Казахстан
- Утегенова Анара Урантаевна, PhD, ассоц. профессор, Республика Казахстан
- Хомпыш Ардабек, PhD, Республика Казахстан
- Шормакова Асем Ноябревна, PhD, Республика Казахстан
- Эшкараева Нархол Гузаровна, к.т.н., профессор, Республика Узбекистан

**Ученые секретари конференции:**

- Аршидинова Мукаддас Тургановна, PhD, Республика Казахстан
- Сарсембаева Талшын Сагдатбековна, PhD, Республика Казахстан

## Организационный комитет

**Председатели:**

- Усатова Ольга Александровна, PhD, ассоц. профессор, Республика Казахстан
- Мансурова Мадина Есимхановна, к.ф.-м.н., профессор, Республика Казахстан

**Члены Организационного комитета:**

- Айдарова Л.Н., Республика Казахстан
- Абдуали Б.А., PhD, Республика Казахстан
- Аспантаев А.Б., Республика Казахстан
- Варенников А.В., Республика Казахстан
- Лизунов О.А., Республика Казахстан
- Меркебаев А.Г., Республика Казахстан
- Мухитова А.А., Республика Казахстан
- Ткачев К.В., Россия
- Толеу А., Республика Казахстан
- Шахмаев Р.А., Республика Казахстан

## Соорганизаторы конференции

**Дорогие друзья, уважаемые коллеги, организаторы и участники XI Международной научно-практической конференции «Информатика и прикладная математика»!**

От имени Международного программного комитета и организаторов сердечно приветствую всех участников **XI Международной научно-практической конференции «Информатика и прикладная математика»**! Наша конференция, которая в этом году проводится уже в одиннадцатый раз, стала признанной научной площадкой для обмена идеями и результатами исследований в области математического моделирования, искусственного интеллекта, анализа данных, информационной безопасности и цифровых технологий. Выражаю искреннюю благодарность Казахскому национальному университету имени аль-Фараби, Институту информационных и вычислительных технологий КН МНВО РК, Люблинскому техническому университету и Университету «Туран» за совместную работу по подготовке и проведению конференции.

Мы живем в период, когда информационные технологии и прикладная математика определяют темпы развития экономики, науки и общества. Искусственный интеллект переходит из лабораторий в повседневную практику – в медицину, сельское хозяйство, промышленность, энергетику, образование и государственное управление. Вместе с новыми возможностями возникают и новые вызовы: надежность и объяснимость интеллектуальных систем, защита персональных данных, кибербезопасность критической инфраструктуры, сохранение языкового и культурного многообразия в эпоху больших языковых моделей. Ответы на эти вопросы невозможны без фундаментальной математической подготовки, междисциплинарного сотрудничества и открытого научного диалога.

Развитие искусственного интеллекта и цифровизация экономики определены в числе стратегических приоритетов Республики Казахстан. Наращивание потенциала отечественной науки, подготовка высококвалифицированных кадров и ускоренное внедрение результатов исследований в практику – важнейшие задачи, решению которых призвана служить и наша конференция.

В этом году в работе конференции принимают участие ученые и специалисты из Казахстана, России, Узбекистана, Азербайджана, Кыргызстана, Турции, Польши, Венгрии, Индии, Греции, Китая и других стран. Программа включает пленарные доклады ведущих ученых, работу четырех секций – «Математическое моделирование, оптимизация и вычислительный анализ», «Искусственный интеллект, Big Data, наука о данных и интеллектуальные системы», «Инновации в области управления компьютерными науками и инженерии», «Кибербезопасность, конфиденциальность и цифровое доверие», а

также круглый стол «Искусственный интеллект и языковые технологии: от научных основ к технологиям будущего». Особенно радует, что значительную часть докладов представляют молодые ученые, докторанты и магистранты – именно им предстоит определять будущее казахстанской и мировой науки.

Проведение наших ежегодных встреч стало доброй традицией. С каждым годом растет число участников, повышается качество выступлений и публикаций, расширяется география научного сотрудничества. Уверен, что и нынешняя конференция станет местом плодотворных дискуссий, новых научных контактов и совместных проектов, а идеи, высказанные здесь, найдут воплощение в исследованиях и практических разработках.

Уважаемые участники и организаторы конференции! Позвольте выразить Вам глубокую благодарность за участие, поддержку и развитие нашей конференции. Желаю всем плодотворной работы, интересных докладов, творческих успехов и новых научных достижений!

Председатель Международного
программного комитета,
академик НАН РК, д.ф.-м.н., профессор **Калимолдаев М.Н.**

# СОДЕРЖАНИЕ

стр.

## Секция 1. Математическое моделирование, оптимизация и вычислительный анализ


1. **Родионов А.С.** 17
Проблемы эффективной реализации алгоритмов анализа связности случайных графов и методы их решения

2. **Айда-заде К.Р., Рагимов А.Б.** 23
О решении одного класса коэффициентно обратных задач относительно параболических уравнений с переопределенными нелокальными условиями

3. **Нуралиев Ф.М., Сафаров Ш.Ш., Салаев А.К.** 28
Математическое моделирование деформации тонкой пластины сложной геометрии под действием собственного веса методом PINN

4. **Байтуленов Ж.Б., Тапеева С.К.** 39
Модификация метода фиктивных областей для нелинейной модели неньютоновской жидкости

5. **Жакебаев Д.Б., Мусират С.** 41
Численное моделирование эффекта Магнуса на вращающемся цилиндре методом решёточных уравнений Больцмана

6. **Bessonova G., Tursynzhanova A., Ataniyazova A., Omarova P., Mustafin S., Amirgaliyeva S.** 47
CFD-based assessment of urban morphology effects on ventilation efficiency and NO2 dispersion in residential areas of Almaty

7. **Sagimbayeva L.A., Kassenov S.E., Tugenbayeva Zh.S.** 56
Analysis of the analytical and PINN-based solution of a pharmacokinetics problem

8. **Yuldashov Sh.N., Nazirova E.Sh.** 60
A model and numerical solution algorithm for groundwater filtration problem in a three-layer porous medium interconnected with a low-permeability layer

9. **Boymurodov F.F., Nazirova E.Sh., Eshkaraeva N.G., Xujamurotova M.G.** 63
Linguistic and mathematical models for identifying and correcting punctuation errors in Uzbek interrogative sentences

10. **Накибаева М.Т., Мукимбеков М.Ж., Маткерим Б.** 66
Моделирование актуальных задач в освоении залежей нефти

11. **Ташев А.А., Аршидинова М.Т.** 72
Численное исследование влияния температуры окружающей среды на термо-напряженно-деформированное состояние стержня с криволинейной образующей

12. **Shukurova M.E.** 79
Mathematical modeling of non-stationary non-linear filtration processes in multi-layered porous media

13. **Kenzhebayeva M., Serovajsky S.** 87
Solving the inverse gravimetric problem for an oil and gas deposit with two anomalies

14. **Асубай А.О., Рысбайулы Б.** 96
Обратные задачи для уравнения теплопроводности в двумерной анизотропной среде

15. **Алдабеков А.Т., Торобеков Б.Т.** 97
Математическая модель поддержки принятия решений при управлении газодымозащитной службой

16. **Duran V., Yusubov Ç.** 105
Optimal AI use in education: a multi-objective mathematical optimization model balancing learning performance and cognitive independence

17. **Худайберген Б.Б., Темирбеков А.Н., Темирбеков Н.М.** 109
Численное моделирование несжимаемого вязкого течения в L-образном канале с различными углами изгиба

18. **Мәдібайұлы Ж.** 111
Көпірдің орнықтылығын математикалық жолмен жасанды интеллектіні қолданып есептеу

19. **Амирханов Б., Амирханова Г., Тюлепбердинова Г., Мазаков Т., Ахметов Д., Раева А.** 112
Математическая модель робастного контроля недолива закрытых упаковок для цифрового двойника производственной линии

20. **Назирова Э.Ш., Абидова Ш.Б., Мадетбаева Н.Б.** 119
Математические модели дистрибутивной семантики с онтологическим априорным распределением для выявления фразеологизмов узбекского языка

21. **Назирова Э.Ш., Абидова Ш.Б., Узакова М.А., Усманова К.А., Медетбаева Н.Ш.** 126
Применение метода Гаусса для разрешения лексической многозначности в задачах многоязычного электронного перевода

22. **Nuraliev F., Sultanov B., Artikbayev M., Orazbayev A.** 132
Solving the deformation problem of a mesh plate with a complex shape under external forces

23. **Ravinder J., Bernick Raj A., Nandakumar C.D.** 140
A new framework for generating fuzzy metrics by t-norms and indistinguishability operators

24. **Sakhuadinov D.S., Baisholanova K.S.** 154
Development of an intelligent GIS for search and visualization of urban infrastructure

25. **Zhuzbayev S.S., Mukasheva T.D.** 163
The method of bicharacteristics and the Tarabrin splitting scheme in hybrid prediction of effective properties of composite materials

26. **Howeidi H.S., Hassan Z.A.H.** 169
Enhancing reliability and reducing costs in bipartite networks: a comparative study of allocation techniques

## Секция 2. Искусственный интеллект, Big Data, Наука о данных и Интеллектуальные системы


27. **Kalimoldayev M.N., Mansurova M.E.** 178
Artificial intelligence development in Kazakhstan over the past decade: a comprehensive review

28. **Mosavi A., Aidarova L., Baipakbayeva S., Ospan A., Sarsembayeva T., Mansurova M., Kalimoldayev M.** 192
Toward holistic and trustworthy AI

29. **Tukeyev U.** 205
Neuro-symbolic NLP for Turkic languages

30. **Berikov V.B., Kutnenko O.A.** 211
Feature selection and sample self-correction in multiple instance learning with weak labeling

31. **Есимов А.С., Кусаинова А.Т.** 218
Экспериментальный датасет георадарных данных археологических объектов для решения обратных задач и автоматизации интерпретации

32. **Тастанов М.С.** 223
Интеграция сквозных технологий искусственного интеллекта в задачи социальной инклюзии: опыт разработки национальной системы Surdo AI в Узбекистане

33. **Тастанова С.А.** 227
Динамическая причинно-семантическая модель прогрессирования цирроза печени

34. **Сегизбаева Ж.Е., Рахманберді Н.А.** 235
Әзірбайжан–қазақ тілдік жұбы үшін синтетикалық деректер генерациясы мен морфологиялық постпроцессинг негізіндегі нейрондық машиналық аударма жүйесі

35. **Тукеев У.А., Рысбек Б.С.** 241
Қазақ тіліндегі бағдарламалау сұрақ-жауап жүйесі үшін морфологияға бейімделген көпміндетті оқыту

36. **Шормакова А.Н., Күмісбек М.Н.** 246
Қазақ тілді мәтіндік трафиктегі әлеуметтік-инженерлік қауіптерді жіктеудегі классикалық алгоритмдердің шешім шекараларының деградациясы

37. **Омархалиева Н.Г., Тукеев У.А.** 249
Түрік тілін автоматты тану нәтижелерін MAPP арқылы кейінгі өңдеу: үш ASR жүйесін салыстыру

38. **Аубакирова Р.** 254
Хватит ли 64 примеров на класс? Распознавание токсичных текстов на казахском языке при малом объёме разметки

39. **Матанов Н.Б., Рахимова Д.Р.** 259
Использование сторонних больших языковых моделей как фактор риска утраты культурного кода казахского общества

40. **Дюсебаев Р.Е., Балгабаева Л.Ш.** 269
Влияние искусственного интеллекта и онлайн-платформ на новый формат журналистики

41. **Токоева Б.Ж., Охотников В.И., Торобеков Б.Т.** 274
Алгоритмы и программные средства для регулирования светофоров с использованием технологий машинного обучения

42. **Nazirova E.Sh., Alimova F.M.** 283
Integrating heterogeneous data in the higher education system based on an ontological approach

43. **Maatov K.M., Mambetov Zh.I., Toktorbaev A.M., Kholiknazarov R.Kh., Ergashev O.M., Mamadaliev N.A.** 289
Agricultural production planning and problem solving using MS Excel

44. **Ergashev O.M., Mamadaliev N.A., Kholiknazarov R.Kh., Mambetov Zh.I., Toktorbaev A.M., Maatov K.M.** 296
AI-assisted real-time student performance prediction using web technologies

45. **Иманбекова А.Н., Тажиева Р.Н.** 305
Жүректің эхокардиографиялық бейнелерін CNN және XAI әдістері негізінде талдауға арналған интеллектуалды сараптама жүйесін әзірлеу

46. **Сакыпбекова М.Ж., Камбаров Д.Б.** 315
Құс ауруларының клиникалық белгілерін ерте анықтаудағы зерттеу үрдістерінің дамуы

47. **Amirkhanov A., Adilzhanova S., Amirkhanov B., Fu Y., Faruzkyzy Y.** 328
What imbalance machinery is worth on cardiotocography data: a seven-way benchmark with fixed seeds

48. **Aida-zade K.R., Azimov R., Faraslis I., Providas E.** 335
A computer vision system that processes aerial images for identifying the vegetative health states of crop fields

49. **Aida-zade K.R., Mustafayev E., Azimov R.** 340
Analysis of some text features in the example of recognizing the authors of literary fictions

50. **Ortikova F.S., Tastanova S.A.** 345
Geometric modeling and feature fusion techniques for advanced facial image recognition in biometric systems

51. **Белик Г.А.** 349
Методика оценки устойчивости MobileNetV2 к искажениям изображений листьев томата

52. **Дәруіш С.З., Утегенова А.У., Жумабекова Ж.Ж.** 355
Интеллектуальные слои ГИС экологического паспорта района падения для оценки риска загрязнения почв нефтепродуктами

53. **Ataniyazova A., Kaiyrbekova A., Baekova G., Amirgaliyeva S., Kozbakova A., Mustafin S.** 362
Development of a comprehensive methodology for assessing water quality using satellite data and machine learning

54. **Құдайбергенова А.Қ.** 374
Машиналық оқыту алгоритмдері негізінде су тасқынына байланысты төтенше жағдайларды болжауды модельдеу

55. **Темирбеков Н.М., Худайберген Б.Б., Темирбеков А.Н., Касенов С.Е.** 375
Картирование перспективности месторождений полезных ископаемых на основе глубокого обучения с использованием многоисточниковых геопространственных данных и GIS-предикторов

56. **Шәріпбек Б., Әбірбек Н., Жуманова Л.** 377
Қазақстанның өңірлері бойынша зерттеу

57. **Abdulla I.T., Akhmed G.Zh., Alimzhanova Zh.M.** 378
Machine learning-based classification of block ciphers using ciphertext-derived features

58. **Кәрібаева А.С., Карюкин В.И., Әмірова Д.Т., Абдуали Б.А.** 384
Генерация экспрессивной казахской речи в современных нейросетевых TTS-системах

59. **Куанышбекова Д.Е.** 390
Ағзаның физиологиялық күйін болжаудағы интеллектуалды цифрлық егіз технологиясы

60. **Васильева Л.А.** 395
Искусственный интеллект в современной веб-разработке

61. **Калкабек А.М., Маматалиев М.А., Торобеков Б.Т.** 400
Интеллектуальная система координации БПЛА и мобильного робототехнического комплекса при ликвидации чрезвычайных ситуаций

62. **Айдарова Л.Н., Калимолдаев М.Н.** 411
Интеллектуальная система управления агророботом на основе методов компьютерного зрения и анализа данных для точечной обработки посевов

63. **Бажибаева А.Б.** 415
Компьютерное зрение для определения вовлеченности обучающихся

64. **Алдунин Д.А., Мальцева С.В.** 420
Синтетические данные: применение в образовательных сервисах

# Секция 1. Математикалық модельдеу, оңтайландыру және есептеу анализі

# Секция 1. Математическое моделирование, оптимизация и вычислительный анализ

# Section 1. Mathematical Modeling, Optimization, and Computational Analysis

# ПРОБЛЕМЫ ЭФФЕКТИВНОЙ РЕАЛИЗАЦИИ АЛГОРИТМОВ АНАЛИЗА СВЯЗНОСТИ СЛУЧАЙНЫХ ГРАФОВ И МЕТОДЫ ИХ РЕШЕНИЯ[1]

Родионов А.С.
e-mail: alrod@sscc.ru
*Институт вычислительной математики и математической геофизики СО РАН, Россия*

***Аннотация.*** *В докладе рассматриваются различные аспекты компьютерной реализации алгоритмов расчёта показателей связности случайных графов с надёжными вершинами и независимо отказывающими рёбрами. Предлагаются быстрые методы реализации некоторых базовых процедур, пути избегания повторных расчётов и быстрый способ организации полного перебора возможных состояний графа.*

**Введение**

Значение произвольной функции (показателя) $\mu$ случайного графа $G$ определяется как её математическое ожидание:

$$E[\mu(G)] = \sum_{H \in \Gamma} P(H)\mu(H), \quad (1)$$

где Г – множество всех возможных реализаций графа. Для краткости знак математического ожидания обычно опускается и используется просто $\mu(G)$. Вероятность конкретной реализации $H$ вычисляется тривиально:

$$P(H) = \prod_{e \in H} p_e \prod_{e \in G \setminus H} (1 - p_e). \quad (2)$$

Поскольку общее количество реализаций есть $2^m$, где m есть число рёбер графа, точное вычисление значения показателя для графов хоть сколько ни будь большой размерности прямым перебором практически невозможно (для графа со ста рёбрами число вариантов равно 1 267 650 600 228 229 401 496 703 205 376), применяются различные методы редукции, декомпозиции и приближений. Эти методы используют ряд стандартных операций перенумерации и/или удаления вершин и рёбер, приводящих к изменению матриц либо списков, используемых для представления графа, чаще всего матрицы смежности или списка рёбер. В докладе кратко описываются методы редукции и декомпозиции, вопросы эффективной реализации стандартных операций и построения приближений значений показателей. В качестве примера показателей в докладе рассматриваются вероятность связности случайного графа (All-Terminal reliability, ATR, обозначается как $R(G)$) и математическое ожидание числа несвязных пар вершин (Expected number of Disconnected Pairs of nodes, EDP, обозначается как $N(G)$). Последний показатель взаимно однозначен с вероятностью произвольного парного соединения.

**Основные операции при использовании методов редукции и декомпозиции**

К основным методам редукции размерности графа относятся удаление висячих вершин и замена простых цепей рёбрами [1–4]. Эти операции сводятся к удалению вершин: соответственно висячей либо внутренних вершин цепи с последующим соединением её оконечных вершин новым ребром.

Напомним, что удаление висячей вершины $v$, присоединённой к остальному графу ребром e с надёжностью $p_e$, приводит к выражениям [1]:

[1] Исследования выполнены в рамках проекта FWNM-2025-0005 ИВМиМГ СО РАН

$$R(G) = p_e R(G \setminus v);$$
$$N(G) = N(H) + (1 - p_e) w_v (W(G) - w_v),$$

где граф $H$ есть граф $G\setminus v$ с новым весом вершины $s$, с которой имела связь вершина $v$: $w_s^* = w_s + p_e w_v$.

Что до цепей, то справедливы следующие теоремы.

1. Для ATR [4]:

**Теорема 1**. Пусть граф $G(n,m)$ содержит простую цепь из $k$ ребер $e_1,e_2,\ldots, e_k$ с вероятностями присутствия $p_1,p_2,\ldots,p_k$. Тогда надежность графа $G(n,m)$ равна

$$R(G(n,m)) = \prod_{i=1}^{k} p_i \left( \sum_{i=1}^{k} p_i^{-1} - k + 1 \right) R(H(n - k + 1, m - k + 1)),$$

где граф H(n-k+1,m-k+1) получен из G(n,m) заменой этой цепи ребром с вероятностью присутствия

$$p = \left( \sum_{i=1}^{k} p_i^{-1} - k + 1 \right)^{-1}.$$

2. EDP [5]:

**Теорема 2**. Пусть в связном графе $G$ присутствует цепь $Ch=\{e_1=(v_1,v_2),\ldots, e_k=(v_k,v_{k+1})\}$, соединяющая вершины $v_1$ и $v_{k+1}$, то

$$N(G) = A \times N(G^o) + B \times N(G^*) + C \times [1 - R_{1,k+1}(G^o)] + D,$$

где $G^o$ имеет те же структуру и матрицу надёжности рёбер $P$, как $G\setminus e_{1,k+1}\setminus Ch$ и следующие веса вершин $v_1$ и $v_{k+1}$:

$$WT_1(G^o) = w_1 + \frac{\sum_{i=2}^{k} w_i \prod_{j=1}^{i-1} p_j \left(1 - \prod_{j=i}^{k} p_j\right)}{1 - \prod_{i=1}^{k} p_i},$$

$$WT_{k+1}(G^o) = w_{k+1} + \frac{\sum_{i=2}^{k} w_i \prod_{j=i}^{k} p_j \left(1 - \prod_{j=1}^{i-1} p_j\right)}{1 - \prod_{i=1}^{k} p_i},$$

где $G^*$ имеет те же структуру и $P$ как $G\setminus e_{1k}/Ch$ и вес объединённой вершины $v_{<1,k+1>}$

$$WT_1(G^*) = w_1 + w_{k+1} + \sum_{i=2}^{k} w_i \left[ \prod_{j=1}^{k} p_j (1 - 2p_{1,k+1}) + p_{1,k+1} \left( \prod_{j=1}^{i-1} p_j + \prod_{j=i}^{k} p_j \right) \right].$$

Коэффициенты $A,B,C$ и $D$ являются конечными выражениями от весов вершин и надёжности рёбер:

$$A = p_{1,k+1} + q_{1,k+1} \prod_{j=1}^{k} p_j,$$

$$B = q_{1,k+1}\left(1 - \prod_{j=1}^{k} p_j\right),$$

$$C = -\,q_{1,k+1}\prod_{i=1}^{k} p_i\left\{\sum_{i=2}^{k-1}\sum_{j=i+1}^{k} w_i w_j\left(1 - \prod_{s=1}^{i-1} p_s\right)\left(1 - \prod_{s=j}^{k} p_s - \prod_{s=i}^{k} p_s + \prod_{s=i}^{j-1} p_s\right),\right.$$

$$\left. + \sum_{i=2}^{k} w_i^2\left(1 - \prod_{j=i}^{k} p_j\right)\left(1 - \prod_{j=1}^{i-1} p_j\right)\right\} / \left(1 - \prod_{i=1}^{k} p_i\right),$$

$$D = W(G \setminus Ch)\sum_{i=2}^{k} w_i\left(1 - \prod_{j=1}^{i-1} p_j\right)\left(1 - \prod_{j=i}^{k} p_j\right) + \sum_{i=2}^{k-1}\sum_{j=i+1}^{k} w_i w_j\left(1 - \prod_{s=i}^{j-1} p_s\right)\left(1 - \prod_{s=j}^{k} p_s \prod_{s=1}^{i-1} p_s\right).$$

Нетрудно видеть, что в обоих случаях присутствуют операции удаления цепи, в случае ATR с подставлением нового ребра, соединяющего её оконечные вершины. В случае EDP, после удаления цепи, требуется также получить граф с объединением этих вершин. Поскольку для вычисления этих показателей абсолютно неважна нумерация вершин, требуется лишь сохранение верного соединения рёбер безотносительно к этой нумерации. Так, для графа на Рис.1 удаление цепи 8-7-1-2-4 проще всего провести последовательным удалением внутренних вершин цепи в обратном порядке их номеров, как показано на Рис. 2.

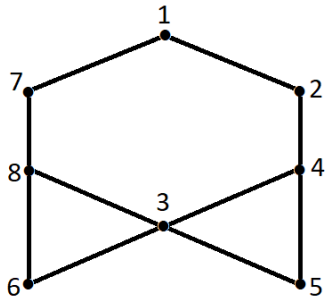



Рис. 1 Пример графа с цепью

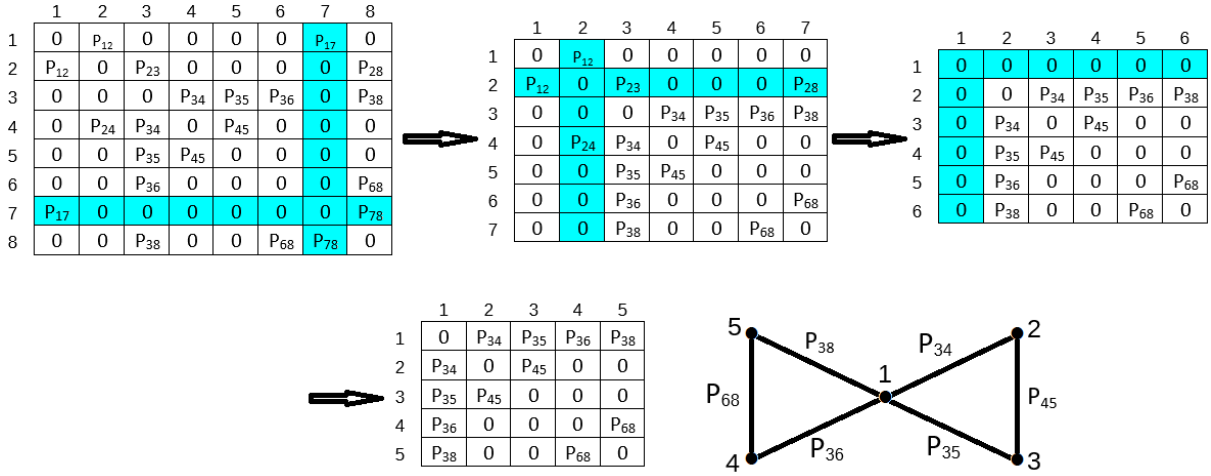



Рис. 2 Последовательное удаление вершин цепи и его результат.

Декомпозиция графа предполагает приведение матрицы смежности к блочному виду, где блок соответствует компоненту связности графа.

Подобные манипуляции с матрицами, представляющими исследуемый граф и его компоненты, наиболее эффективно выполнять с помощью параллельных пересылок данных.

**Эффективная реализация полного перебора**

После проведения декомпозиции могут быть получены подграфы относительно малой размерности, допускающие полный перебор вариантов разрушения. Этот вопрос рассматривался в [6]. Предлагается использовать маску состояний рёбер, представляющую собой бинарную строку, в которой 1 соответствует присутствию ребра, 0 – его отсутствию. Для этого необходим нумерованный список рёбер, по которому всегда можно восстановить соответствующее состояние матрицы смежности. Строку длиной m можно преобразовать в целое число в двоичном представлении. Тогда возможные маски соответствуют числам от 0 до $2^m$-1, и можно передавать подмножества этих чисел, в частном случае диапазоны, вычислительным ядрам для обработки. Для ATR это означает просто проверку связности соответствующих графов, а для EDP – нахождение количества несвязных пар вершин. Вероятность осуществления реализации подсчитывается по формуле (2) одновременно с восстановлением маски по номеру реализации. Отметим, что все числа до $2^{n-1}$-2 соответствуют маскам несвязных графов, достаточно предварительно посчитать суммарную вероятность этих реализаций и в дальнейшем не рассматривать.

**Избавление от повторных расчётов при декомпозиции графа по рёберному сечению**

Для дальнейшего изложения введём обозначение $G^{ij...k}$ для графа, полученного из графа $G$ стягиванием вершин с номерами $i,j,\ldots,k$.

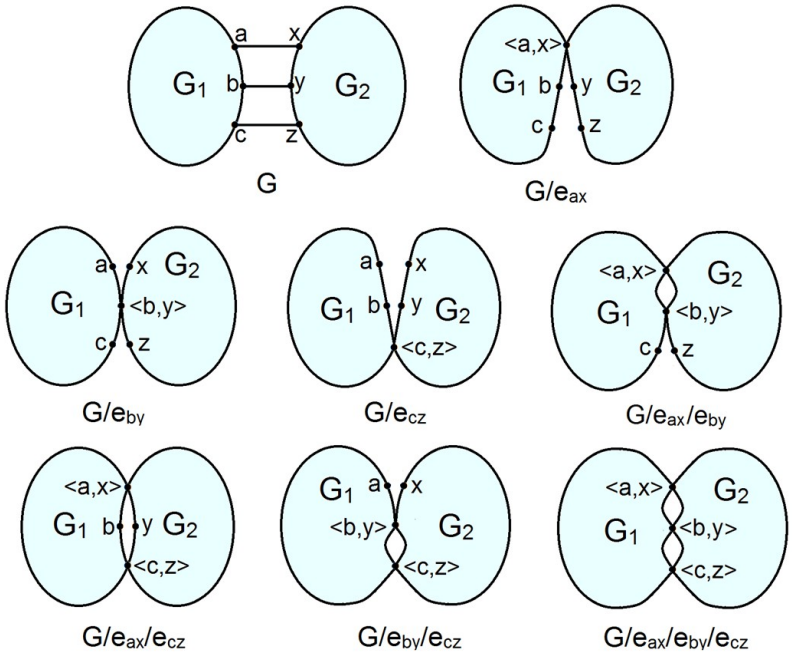



Рис. 3 Варианты стягивания компонент графа по надёжным рёбрам разреза.

В работе {7] предложены формулы декомпозиции по 1-, 2- и 3-х вершинному разрезу при вычислении $R(G)$. Первый случай тривиален, достаточно перемножить значения этого показателя для каждого из компонент. Во втором случае, кроме этого, требуется получить значения ATR для графов, получаемых из компонент стягиванием вершин сечения (пусть они имеют номера $x$ и $y$.):

$$R(G) = R(G_1)R(G_2) + R(G_1)[R(G^{xy}{}_2) - R(G_2)] + R(G_2)[R(G^{xy}{}_1) - R(G_1)].$$

Для 3-вершинного сечения имеем формулу, в которой рассматриваются как варианты стягивания пар вершин (третью вершину сечения обозначим как $z$), так и стягивание всех трёх вершин:

$$R(G) = \frac{1}{2}\{R(G_1^{yz})[R(G_2^{xy}) + R(G_2^{xz}) - R(G_2^{yz})] + R(G_1^{xy})[R(G_2^{yz}) + R(G_2^{xz}) - R(G_2^{xy})] +$$

$$R(G_1^{xz})[R(G_2^{xy}) + R(G_2^{yz}) - R(G_2^{xz})] - R(G_1)[R(G_2^{xy}) + R(G_2^{xz}) + R(G_2^{yz})] -$$

$$R(G_2)[R(G_1^{xy}) + R(G_1^{yz}) + R(G_1^{xz})] + R(G_1)R(C_2)\} + R(G_1)R(C_2^{xyz}) + R(G_1^{xyz})R(C_2).$$

Пусть теперь мы имеем 3-рёберное сечение. Имеем 8 вариантов состояния его рёбер, один из которых (все рёбра отказали) даёт заведомо несвязный граф. На Рис.3 показаны результаты стягивания по не отказавшим рёбрам, вероятности реализаций очевидны. Если применять вышеприведённые формулы по очереди к каждому варианту, то, например, для последнего, где получен 3-вершинный разрез, нужны значения ATR для вариантов стягивания пар вершин, которые также используются при стягивании по паре надёжных рёбер. Приведение подобных при суммировании позволяет не повторять соответствующие расчёты:

$$R(G) = R(G_1)R(G_2)(p_{ax}q_{by}q_{cz} + q_{ax}p_{by}q_{cz} + q_{ax}q_{by}p_{cz} - p_{ax}p_{by}q_{cz} + p_{ax}p_{by}p_{cz} - q_{ax}p_{by}p_{cz}) +$$

$$R(G_1)[\frac{p_1p_2(2q_3 - p_3)}{2}R(G_2^{xy}) + \frac{p_1p_3(2q_2 - p_2)}{2}R(G_2^{xz}) + \frac{p_2p_3(2q_1 - p_1)}{2}R(G_2^{yz}) + p_1p_2p_3R(G_2^{xyz})] +$$

$$R(G_2)[\frac{p_1p_2(2q_3 - p_3)}{2}R(G_1^{ab}) + \frac{p_1p_3(2q_2 - p_2)}{2}R(G_1^{ac}) + \frac{p_2p_3(2q_1 - p_1)}{2}R(G_1^{bc}) + p_1p_2p_3R(G_1^{abc})] +$$

$$\frac{p_1p_2p_3}{2}\{R(G_1^{ab})[R(G_2^{xz}) + R(G_2^{yz}) - R(G_2^{xy})] + R(G_1^{ac})[R(G_2^{xy}) + R(G_2^{yz}) - R(G_2^{xz})] +$$

$$R(G_1^{bc})[R(G_2^{xy}) + R(G_2^{xz}) - R(G_2^{yz})]\}.$$

Этот подход распространяется на произвольное количество рёбер в разрезе. При количестве рёбер разреза более 3 просто получаем новые варианты стянутых графов и известными вероятностями реализации, которые обрабатываются самостоятельно.

**Заключение**

Рассмотрены некоторые приёмы повышения эффективности расчётов характеристик связности случайных графов. Основные пути решения заключаются в использовании параллельных вычислений и исключения повторных вычислений. Дальнейшие исследования касаются улучшения методов декомпозиции и ускорения вычисления приближенных оценок различных показателей надёжности сетей.

**Литература**

1. Colbourn, C. J. The Combinatorics of Network Reliability / Oxford University Press: N.Y., 1987. – 160 p.

2. Jereb, L. Network reliability: models, measure and analysis / 2. Jereb, L.// Proceedings of the 6th IFIP Workshop on Performance Modeling and Evaluation of ATM Networks, 1998, pp. T02/1– T02/10.

3. Shooman, A. M. Algorithms for network reliability and connection availability analysis // Electro/95 International. Professional Program Proceedings, – 1995, pp. 309 –333.

4. Rodionov, A. S., Migov, D. A. and Rodionova O. K., Improvements in the efficiency of cumulative updating of all-terminal network reliability / IEEE Trans. Reliab., vol. 61, no. 2, pp. 460–465, 2012.

5. Rodionov, A.S., Rodionova, O.K., Choo, H., On the Expected Value of a Number of Disconnected Pairs of Nodes in Unreliable Network. / 5. Rodionov, A. S. //Gervasi, O., Gavrilova, M.L. (eds) Computational Science and Its Applications – ICCSA 2007. ICCSA 2007. Lecture Notes in Computer Science, vol 4707. Springer, Berlin, Heidelberg. – P.534-543.

6. Родионов А .С., Сакерин А. В., Мигов Д. А. Некоторые вопросы параллельной реализации полного перебора / Родионов А.С. // Вестник СибГУТИ. № 4 (28), 2014, с. 79-84.

7. Мигов, Д. А., Декомпозиция сети по сечениям при расчёте её надёжности // Прикладная дискретная математика, 2020, № 47, С. 62–86.

# О РЕШЕНИИ ОДНОГО КЛАССА КОЭФФИЦИЕНТНО ОБРАТНЫХ ЗАДАЧ ОТНОСИТЕЛЬНО ПАРАБОЛИЧЕСКИХ УРАВНЕНИЙ С ПЕРЕОПРЕДЕЛЕННЫМИ НЕЛОКАЛЬНЫМИ УСЛОВИЯМИ

[1]Айда-заде К.Р., [1,2]Рагимов А.Б.
e-mail: kamil_aydazade@rambler.ru, anar_r@yahoo.com
*[1]Институт Математики Министерство Науки и Образования Азербайджанской Республики, Азербайджан*
*[2]Бакинский Государственный Университет, Азербайджан*

***Аннотация.*** *В работе рассматривается обратно коэффициентная задача для линейного параболического уравнения с неизвестными коэффициентами в правой части. Специфика рассматриваемой обратной задачи заключается в том, что восстанавливаемые коэффициенты находятся при свободном члене и они зависят только от пространственной переменной, кроме того, для восстановления коэффициентов ведутся наблюдения в заданные моменты времени, число которых должно быть не меньше числа восстанавливаемых коэффициентов. Предложен подход к численному решению задачи, основанный на методе прямых и специальном виде представления для решения. Метод не требует построения каких-либо итерационных процедур.*

## Введение

В последние годы возросло внимание исследователей к коэффициентно-обратным задачам относительно процессов, описываемых уравнениями с частными производными, в частности, параболическими уравнениями [1-7]. К исследуемым обратным задачам, в частности, приводит важный класс краевых задач с нелокальными (интегральными) краевыми и начальными условиями. Нелокальность условий обусловлена невозможностью на практике проводить замеры измеряемых параметров состояния объекта (процесса) мгновенно или в его отдельно взятых точках.

В данной работе исследуется численное решение обратных задач, в которых идентифицируемые коэффициенты зависят лишь от одной переменной: пространственной переменной. Специфика рассматриваемой обратной задачи заключается, в том, что, во-первых, восстанавливаемые коэффициенты находятся при свободном члене, во-вторых, они зависят только от пространственной переменной. В третьих, в отличие от ранее рассмотренных задач здесь для восстановления коэффициентов ведутся наблюдения в заданные моменты времени, число которых может превышать число восстанавливаемых коэффициентов. Известно, что результаты проводимых наблюдений могут иметь погрешности и превышение числа наблюдений позволяет с практической точки зрения повысить точность восстановления коэффициентов.

В работе с использованием метода прямых исходная задача сводится к решению коэффициентно обратной задаче относительно системы обыкновенных дифференциальных уравнений с переопределенным числом нелокальных краевых условий. Относительно решения полученной системы дифференциальных уравнений предлагается специальное представление, в котором учавствуют решения вспомогательных задач Коши. Далее, используя все имеющиеся нелокальные краевые условия, формируется переопределенная система линейных алгебраических уравнений [8, 9]. Таким образом, в предлагаемом подходе не используются какие-либо итерационные процедуры. Предлагаемый подход опробирован на решении тестовых задач, проведен анализ полученных результатов.

## Постановка задачи

Рассмотрим коэффициентно-обратную задачу относительно параболического уравнения:

$$\frac{\partial v(x,t)}{\partial t} = a(x,t)\frac{\partial^2 v(x,t)}{\partial x^2} + a_1(x,t)\frac{\partial v(x,t)}{\partial x} + a_2(x,t)v(x,t) + f(x,t) + F(x,t),$$
$$(x,t) \in \Omega = \{(x,t): 0 < x < 1,\ 0 < t \le T\}, \tag{1}$$

где

$$F(x,t) = \sum_{s=1}^{L} B_s(x,t)C_s(x), \tag{2}$$

при следующих начально-краевых условиях:

$$v(x,0) = \varphi_0(x), \quad x \in [0,1], \tag{3}$$

$$v(0,t) = \psi_0(t),\ v(l,t) = \psi_1(t), \quad t \in [0,T], \tag{4}$$

Здесь $L > 0$ – заданное целое число; заданные функции $a(x,t) > 0$, $a_1(x,t)$, $a_2(x,t)$, $f(x,t), B_s(x,t)$, $\varphi_0(x)$, $\psi_0(t), \psi_1(t)$ непрерывны по $x$ и $t$; $B_s(x,t)$ – линейно-независимые функции, дифференцируемые по $t$, причем $a_2(x,t) \le 0, B_s(x,t) \ge 0$, $\frac{\partial B_s(x,t)}{\partial t} \ge 0$.

Для восстановления вектор-функции $C(x) = (C_1(x),...,C_L(x))^T$ за счет результатов проводимых наблюдений имеются следующие дополнительные условия:

$$v(x,\bar{t}_s) = \varphi_{1s}(x), \quad x \in [0,1],\ \bar{t}_s \in (0,T], \quad s = 1,...,l, \tag{5}$$

где $l$ – заданное целое число, причем $l \ge L$; $\bar{t}_s \in (0,T],\ s = 1,...,l$ – заданные моменты времени; заданные функции $\varphi_{1s}(x),\ s = 1,...,l$ непрерывны по $x$ и $t$. Функции $\varphi_0(x), \varphi_{1s}(x), \psi_0(t), \psi_1(t)$ удовлетворяют условиям согласования:

$$\varphi_0(0) = \psi_0(0),\ \varphi_0(l) = \psi_1(0),\ \varphi_{1s}(0) = \psi_0(\bar{t}_s),\ \varphi_{1s}(l) = \psi_1(\bar{t}_s),\ s = 1,...,l.$$

Наблюдаемые значения функции $\varphi_{1s}(x),\ s = 1,...,l$ в заданные моменты времени $\bar{t}_s$ при $x \in (0,1)$ могут иметь погрешности различной природы. Поэтому в таких случаях желательно, чтоб число наблюдений превышало число восстанавливаемых коэффициентов.

Задача (1)-(5) заключается в определении неизвестной непрерывной $L$-мерной вектор-функции $C(x) = (C_1(x),...,C_L(x))^T$ и соответствующего решения краевой задачи $v(x,t)$ – дважды непрерывно дифференцируемой по $x$ и один раз непрерывно дифференцируемой по $t$ при $(x,t) \in \Omega$, с учетом условий (1)-(5).

## Численное решение задачи

Предлагаемый подход к численному решению задачи (1)-(5), основан на использовании метода прямых [10, 11]. Задача (1)-(5) сводится к системе обыкновенных

дифференциальных уравнений с неизвестными параметрами. Для определения этих параметров предлагается метод, основанный на результатах работ авторов [8, 9].

В области $\Omega$ проведем прямые $x_i = ih_x,\ i = 0,1,...,N,\ h_x = 1/N$. На этих прямых определим функции:

$$v_i(t) = v(x_i, t),\ t \in [0,T],\ i = 0,1,...,N,$$

для которых, согласно (3)-(5), справедливы следующие условия:

$$v_i(0) = \varphi_0(x_i) = \varphi_{0i},\ i = 0,...,N, \tag{6}$$

$$v_0(t) = \psi_0(t),\ v_N(t) = \psi_1(t),\quad t \in [0,T], \tag{7}$$

$$v_i(\bar{t}_s) = \varphi_{1s}(x_i) = \varphi_{1s,i},\quad \bar{t}_s \in (0,T],\ s = 1,...,l,\ i = 0,...,N. \tag{8}$$

На прямых $x = x_i$ аппроксимируем производные $\partial v/\partial x$, $\partial^2 v/\partial x^2$ с использованием центральных разностных соотношений:

$$\left.\frac{\partial v(x,t)}{\partial x}\right|_{x=x_i} = \frac{v_{i+1}(t) - v_{i-1}(t)}{2h_x} + O(h_x^2),\ i = 1,...,N-1, \tag{9}$$

$$\left.\frac{\partial^2 v(x,t)}{\partial x^2}\right|_{x=x_i} = \frac{v_{i+1}(t) - 2v_i(t) + v_{i-1}(t)}{h_x^2} + O(h_x^2),\ i = 1,...,N-1. \tag{10}$$

Далее используем обозначения:

$$a_i(t) = a(x_i,t),\ \overline{f}_i(t) = f(x_i,t),\ a_{1i}(t) = a_1(x_i,t),\ a_{2i}(t) = a_2(x_i,t),$$
$$B_{si}(t) = B_s(x_i,t),\ C_{si} = C_s(x_i),\ s = 1,...,L,\ i = 1,...,N-1.$$

Подставляя (9), (10) в (1), получаем систему обыкновенных дифференциальных уравнений $(N-1)$-го порядка с неизвестным (идентифицируемым) вектором параметров $C_s = (C_{s1},...,C_{s,N-1})^T$:

$$\dot{v}(t) = A(t)v(t) + f(t) + \sum_{s=1}^{L} E_{B(t),s} C_s,\ t \in (0,T], \tag{11}$$

$$v(0) = \varphi_0, \tag{12}$$

$$v(\bar{t}_s) = \varphi_{1s},\ s = 1,...,l, \tag{13}$$

$$v(t) = (v_1(t),...,v_{N-1}(t))^T,\ B_s(t) = (B_{s1}(t),...,B_{s,N-1}(t))^T,\ \varphi_0 = (\varphi_{01},...,\varphi_{0,N-1})^T,$$

где $\varphi_{1s} = (\varphi_{1s,1},...,\varphi_{1s,N-1})^T$, $E_{B(t),s}$ – $(N-1)$-мерная квадратная матрица, в которой $i$-й элемент главной диагонали равен $i$-й компоненте вектора $B_s(t)$, т. е. $B_{si}(t)$, все остальные элементы равны нулю. Ненулевые элементы квадратной $(N-1)$-мерной трехдиагональной матрицы $A$ имеют вид

$$\tilde{a}_{ii}(t)=\frac{1}{h_x^2}\left[-2a_i(t)+h_x^2 a_{2i}(t)\right],\ i=1,...,N-1,$$

$$\tilde{a}_{i,i+1}(t)=\frac{1}{h_x^2}\left[a_i(t)+\frac{h_x}{2}a_{1i}(t)\right],\ i=1,...,N-2,$$

$$\tilde{a}_{i,i-1}(t)=\frac{1}{h_x^2}\left[a_i(t)-\frac{h_x}{2}a_{1i}(t)\right],\ i=2,...,N-1.$$

Вектор $f(t)$ определяется следующим образом:

$$f(t)=\left(\overline{f}_1(t)+\left(\frac{a_1(t)}{h_x^2}-\frac{a_{11}(t)}{2h_x}\right)\psi_0(t),\ \overline{f}_2(t),...,\overline{f}_{N-2}(t),\ \overline{f}_{N-1}(t)+\left(\frac{a_{N-1}(t)}{h_x^2}+\frac{a_{1,N-1}(t)}{2h_x}\right)\psi_1(t)\right)^T.$$

Задача (11)-(13) при налагаемых условиях на коэффициенты уравнения (1) и функции, участвующие в начально-краевых условиях, аппроксимирует задачу (1)-(5) с точностью $O(h_x^2)$ (вопросы сходимости решения задачи (11)-(13) к решению задачи (1)-(5) и оценки погрешности рассмотрены в работе [11]). Отметим, что погрешность $O(h_x^2)$ можно улучшить за счет использования схем аппроксимации производных по $x$ более высокого порядка [12, 13].

Обозначим через $0_{N\times N}$ нулевую $N$-мерную квадратную матрицу.

**Теорема.** Пусть $\alpha_s(t)$, $s=1,...,L$ – квадратная матричная, а $y(t)$ – векторная функции размерности $(N-1)$ являются решением задач Коши:

$$\dot{\alpha}_s(t)=A(t)\alpha_s(t)+E_{B(t),s},\ s=1,...,L, \tag{14}$$

$$\alpha_s(0)=0_{(N-1)\times(N-1)},\ s=1,...,L, \tag{15}$$

$$\dot{y}(t)=A(t)y(t)+f(t), \tag{16}$$

$$y(0)=\varphi_0. \tag{17}$$

Тогда для произвольного постоянного $(N-1)$-мерного вектора $C_s$ решением задачи Коши (11), (12) будет следующая вектор-функция

$$v(t)=\sum_{s=1}^{L}\alpha_s(t)C_s+y(t). \tag{18}$$

Решив раздельно матричные задачи Коши (14), (15) для определения $\alpha_s(t), s=1,...,L$ и задачу Коши (16), (17) относительно векторной функции $y(t)$.

Использовав условие (13) и представление (18), получим систему $l$ линейных алгебраических уравнений относительно вектора $C$, которую в общем случае запишем так

$$QC=G. \tag{19}$$

Здесь матрица $Q = ((q_{is})),\ i = 1,...,l,\ \ s = 1,...,L$, вектор $G = (g_1, g_2,..., g_l)^T$ определяются с использыванием $\alpha_s(t)$, $\gamma(t)$ и $\varphi_{1s}$.В случае, если $l = L$, то решение определяется непосредственно из (19): $C = Q^{-1}G$. В случае, если $l > L$ под решением переопределенный системы (19) будем понимать вектор:

$$C = (Q^T Q)^{-1} Q^T G, \tag{20}$$

называемый нормальным решением переопределенной системы ([7]).

В докладе будут приведены результаты проведенных многочисленных компьюторных экспериментов на примере решения тестовых задач и анализ полученных результатов.

## Литература


1. Prilepko, A.I., Orlovsky, D.G., Vasin, I.A. Methods for Solving Inverse Problems in Mathematical Physics / – M. Dekker: New York, 2000. – 709 p.
2. Ivanchov, M.I. Inverse Problems for Equations of Parabolic Type / Lviv: VNTL Publications, 2003. – 238 p.
3. Hasanov, A. Identification of spacewise and time dependent source terms in 1D heat conduction equation from temperature measurement at a final time / International Journal of Heat and Mass Transfer, 2012. – Vol. 55, P. 2069-2080.
4. Yang, L., Deng, Z.-C., Yu, J.-N., Luo, G.-W. Optimization method for the inverse problem of reconstructing the source term in a parabolic equation / Mathematics and Computers in Simulation, 2009. – Vol. 80, P. 314-326.
5. Yan, L., Fu, C.L., Yang, F.L. The method of fundamental solutions for the inverse heat source problem / Engineering Analysis with Boundary Elements, 2008. – Vol. 32, P. 216-222.
6. Ismailov, M.I., Kanca, F., Lesnic, D. Determination of a time-dependent heat source under nonlocal boundary and integral overdetermination conditions / Applied Mathematics and Computation, 2011. – Vol. 218, P. 4138-4146.
7. Сергиенко, И. В., Дейнека, В. С., Решение некоторых обратных задач теплопроводности для составной пластины с использованием псевдообратных матриц / Доклады НАН Украины, 2011. N 12. С. 28–34.
8. Aida-zade, K.R., Rahimov, A.B. An approach to numerical solution of some inverse problems for parabolic equations / Inverse Problems in Science and Engineering, 2014. – Vol. 22, N 1, P. 96-111.
9. Aida-zade, K.R., Rahimov, A.B. On recovering space or time-dependent source functions for a parabolic equation with nonlocal conditions / Applied Mathematics and Computation, 2022. –Vol. 419, 126849 (17 pages)
10. Rothe, E. Zweidimensionale parabolische Randwertaufgaben als Grenzfall eindimensionaler Randwertaufgaben / Math. Ann. 1930. –Vol. 102, N 1, P. 650–670.
11. Будак, Б.М. О методе прямых для некоторых квазилинейных краевых задач параболического типа / Ж. вычисл. матем. и матем. физ. 1961. – Т. 1. N 6. С. 1105-1112.
12. Самусенко, А.В., Фролова, С.В. Многоточечные схемы продольного варианта метода прямых повышенной точности для решения некоторых задач математической физики / Весці НАН Беларусі. Сер. фіз.-мат. навук. 2009. N 3. С. 31-39.
13. Лисковец, О.А. Метод прямых // Дифференц. урав. 1965. – Т. 1. N 12. С. 1662-1678.

# Математическое моделирование деформации тонкой пластины сложной геометрии под действием собственного веса методом PINN

Нуралиев Ф.М.[1], Сафаров Ш.Ш.[2], Салаев А.К.[1]
e-mail: f.m.nuraliev@gmail.com, sh.safarov@afu.uz, salayevalisher@gmail.com
[1]*Ташкентский университет информационных технологий имени Мухаммада аль-Хорезми, Узбекистан*
[2]*Государственный университет «Cyber University», Ташкент, Узбекистан*

***Аннотация.*** *Задача изгиба квадратной стальной пластины (сторона $a = 20$ см) с центральным круговым отверстием ($R = 5$ см) под действием собственного веса решена с помощью физически информированной нейронной сети (PINN) для двух вариантов граничных условий: жёсткого защемления ($w = 0$, $\partial w/\partial n = 0$) и шарнирного опирания ($w = 0$, $M_n = 0$). Область сложной формы описана аналитически единой R-функцией Рвачёва; главные граничные условия выполняются точно за счёт соответствующего множителя в структуре решения ($\omega^2$ для защемления и гладкая функция $\omega$ в первой степени для шарнирного опирания), тогда как естественное условие $M_n = 0$ автоматически следует из минимизации полной энергии изгиба. Симметрия задачи по группе $D_4$ гарантируется симметрично-инвариантными входами сети; обучение выполняется вариационно (метод Deep Ritz) на ~18 000 коллокационных точках со сгущением у границ и несмещённой оценкой интеграла энергии с весами важности. Методика верифицирована на двух задачах с аналитическими решениями: шарнирно опёртый диск (погрешность 0,005 %) и шарнирно опёртый квадрат (совпадение со значением Навье в шести значащих цифрах). Сравнение с независимым эталонным решением по методу Рэлея–Ритца даёт $|w|_{\max} = 2,631 \cdot 10^{-5}$ мм (отклонение 0,73 %) для защемлённой пластины и $|w|_{\max} = 9,583 \cdot 10^{-5}$ мм (отклонение 0,35 %) для шарнирно опёртой; в обоих случаях максимум прогиба расположен на диагоналях на расстоянии $\pm 6$ см от центра, а энергия, достигнутая PINN, ниже энергии эталона ($J / |J_{ref}| \leq -1$), что доказывает точность решения на уровне эталона в энергетической норме. Показано также, что традиционная функция потерь PINN на основе поточечной невязки систематически занижает амплитуду прогиба примерно на 25 % для данной задачи четвёртого порядка, и объяснён механизм этого эффекта.*

***Ключевые слова:*** *физически информированная нейронная сеть (PINN); уравнение Софи Жермен–Лагранжа; бигармоническое уравнение; R-функция; вариационный метод; Deep Ritz; метод Рэлея–Ритца; защемлённая пластина; шарнирно опёртая пластина; изгиб пластин.*

## 1. Введение

В рамках теории Кирхгофа–Лява изгиб тонких упругих пластин описывается уравнением Софи Жермен–Лагранжа (бигармоническим уравнением) четвёртого порядка. Это уравнение служит базовой моделью при расчёте многочисленных элементов конструкций в машиностроении, строительстве и приборостроении. Для областей сложной формы (например, пластин с отверстиями) аналитические решения отсутствуют, а традиционные сеточные методы требуют построения качественной сетки и специальных элементов для оператора четвёртого порядка. На практике встречаются два основных типа закрепления: жёсткое защемление (запрещены и прогиб, и поворот) и шарнирное опирание (прогиб запрещён, поворот свободен) — в последнем случае на границе должен обращаться в нуль нормальный изгибающий момент.

В последние годы физически информированные нейронные сети (PINN) интенсивно исследуются как перспективный бессеточный подход к решению дифференциальных уравнений [1, 2]. Однако уравнения четвёртого порядка представляют для PINN особую трудность: вычисление производных высокого порядка

методом автоматического дифференцирования затратно, а невязка вблизи границы оказывается чрезвычайно жёсткой, что дестабилизирует обучение. Для таких задач эффективной альтернативой является метод Deep Ritz, основанный на эквивалентной вариационной формулировке уравнения [3]; для шарнирного опирания вариационный подход обладает ещё одним принципиальным преимуществом — условие на момент является естественным граничным условием, которое следует из самого функционала и не требует навязывания аппроксимации.

Мощным инструментом аналитического описания сложных областей и точного выполнения граничных условий является теория R-функций Рвачёва [4, 5]: с помощью функции $\omega(x, y)$, обращающейся в нуль на границе области, строятся структуры решения, тождественно удовлетворяющие граничным условиям при любой аппроксимации. В последнее время эта идея получила развитие в литературе по PINN в форме точного наложения граничных условий с помощью функций расстояния [6].

Целью настоящей работы является построение единой методики PINN, решающей уравнение Софи Жермен–Лагранжа для квадратной пластины с центральным круговым отверстием как в случае защемления, так и в случае шарнирного опирания, с результатами, строго подтверждёнными независимым методом. Основные результаты работы: (i) структуры решения на основе R-функций, точно выполняющие главные граничные условия ($\omega^2$ для защемления и гладкая функция $\omega$ в первой степени, согласованная с угловой асимптотикой, для шарнирного опирания); (ii) симметрично-инвариантные входы и фурье-признаки [7], гарантирующие симметрию решения; (iii) веса важности, обеспечивающие несмещённую оценку интеграла энергии на коллокационном множестве со сгущением у границ; (iv) корректный учёт естественного граничного условия на криволинейной границе отверстия через полную энергию изгиба, подтверждённый на аналитических решениях; (v) эмпирическое выявление систематического занижения амплитуды при использовании функции потерь на основе поточечной невязки и его устранение вариационным обучением; (vi) проверка качества решения по математически обоснованному критерию, опирающемуся на свойство минимальности энергетического функционала.

## 2. Материалы и методы

### *2.1. Постановка задачи и обезразмеривание*

Рассмотрим квадратную стальную пластину со стороной $a = 20$ см, из центра которой удалён круг радиуса $R = 5$ см. Прогиб $w(x, y)$ удовлетворяет уравнению Софи Жермен–Лагранжа:

$$D\left(\frac{\partial^4 w}{\partial x^4} + 2\frac{\partial^4 w}{\partial x^2 \partial y^2} + \frac{\partial^4 w}{\partial y^4}\right) = q(x, y),\ (x, y) \in \Omega, \quad (1)$$

$$\Omega = \left[-\frac{a}{2};\ \frac{a}{2}\right] \times \left[-\frac{a}{2};\ \frac{a}{2}\right] \setminus \left\{x^2 + y^2 \le R^2\right\},$$

где $D = \frac{Eh^3}{12(1-\nu^2)}$ — цилиндрическая жёсткость, $q = \rho g h$ — распределённая нагрузка от собственного веса пластины. Рассматриваются два условия закрепления. Жёсткое защемление:

$$w|_\Gamma = 0,\ \frac{\partial w}{\partial x}|_\Gamma = 0,\ \frac{\partial w}{\partial y}|_\Gamma = 0 \quad (2а)$$

и шарнирное опирание:

$$w|_\Gamma = 0,\ M_n|_\Gamma = 0, \quad (2б)$$

где $M_n$ — изгибающий момент, нормальный к границе. Важно отметить, что на криволинейной границе (окружности отверстия) условие $M_n = 0$ содержит, помимо $\partial^2 w/\partial n^2$, слагаемое с кривизной границы и коэффициентом $\nu$; поэтому его упрощение до $w = 0$, $\nabla^2 w = 0$ было бы некорректным — ниже это условие учитывается точно

вариационным путём. Принятые физические и геометрические параметры приведены в таблице 1; им соответствуют $D = 494,5$ Н·м и $q = 231,0$ Н/м².

Таблица 1. Физические и геометрические параметры задачи

| **Величина** | **Обозначение** | **Значение** |
|---|---|---|
| Сторона квадрата | $a$ | 0,20 м |
| Радиус отверстия | $R$ | 0,05 м |
| Толщина | $h$ | 0,003 м |
| Модуль Юнга (сталь) | $E$ | 200 ГПа |
| Коэффициент Пуассона | $\nu$ | 0,30 |
| Плотность | $\rho$ | 7850 кг/м³ |
| Цилиндрическая жёсткость | $D$ | 494,5 Н·м |
| Нагрузка от собственного веса | $q = \rho g h$ | 231,0 Н/м² |

Для численной устойчивости задача обезразмеривается: $\xi = x/a$, $\eta = y/a$, $W = wD/(qa^4)$. Уравнение принимает вид $\nabla^4 W = 1$, область переходит в $[-1/2;\ 1/2]^2 \setminus \{r \le r_0\}$, $r_0 = R/a = 0,25$, а физический прогиб восстанавливается по формуле $w = W \cdot qa^4/D$ ($qa^4/D = 7,475 \cdot 10^{-4}$ м). В случае защемления безразмерное решение не зависит от $\nu$; в случае шарнирного опирания $\nu$ входит в решение через естественное условие и энергию.

***2.2. Область, граничные функции и точное выполнение главных условий***

Область описывается единой аналитической функцией с помощью $R_0$-конъюнкции Рвачёва:

$$f_1 \wedge f_2 = f_1 + f_2 - \sqrt{f_1^2 + f_2^2}, \quad (3)$$

$$\omega(\xi,\eta) = (f_1 \wedge f_2) \wedge f_c,\ f_1 = \frac{1}{4} - \xi^2,\ f_2 = \frac{1}{4} - \eta^2,\ f_c = \frac{\xi^2 + \eta^2 - r_0^2}{2r_0}. \quad (4)$$

Функция $\omega$ положительна внутри области, обращается в нуль на её границе и нормирована вблизи границы подобно функции расстояния; она используется как маска области и для сортировки коллокационных точек. Для случая защемления структура решения принимается в виде [4, 5, 14 - 16]

$$W(\xi,\eta) = \left(\frac{\omega}{\omega_{\max}}\right)^2 \cdot e^{\lambda} \cdot N_\theta(s_1, s_2), \quad (5)$$

где $N_\theta$ — нейронная сеть, $\lambda$ — обучаемая логарифмическая амплитуда. Благодаря множителю $\omega^2$ на границе тождественно выполняются как $W = 0$, так и $\nabla W = 0$, т. е. оба условия (2а) удовлетворяются точно при любой $N_\theta$ [4, 6].

В случае шарнирного опирания главным является только условие $w = 0$, тогда как поворот должен оставаться свободным, поэтому множитель берётся в первой степени. Здесь удобна гладкая мультипликативная форма граничной функции:

$$\varphi(\xi,\eta) = f_1 \cdot f_2 \cdot f_c,\ \ W = \frac{\varphi}{\varphi_{\max}} \cdot e^{\lambda} \cdot N_\theta(s_1, s_2). \quad (6)$$

Функция $\varphi$ аналитична во всей плоскости, точно обращается в нуль на границе и положительна внутри области; в углах квадрата $\varphi \sim u \cdot v$ ($u$, $v$ — расстояния до сторон), что соответствует истинной угловой асимптотике решения при шарнирном опирании и сохраняет конечность интеграла энергии в углах. Таким образом, в обоих случаях главные граничные условия выполняются тождественно, без штрафных слагаемых; условие $M_n = 0$ для шарнирного опирания реализуется как естественное условие, что показано в следующем подразделе.

***2.3. Архитектура сети: гарантия симметрии и фурье-признаки***

Задача (область, нагрузка и граничные условия) инвариантна относительно группы симметрии квадрата $D_4$, следовательно, точное решение обладает той же симметрией.

Чтобы гарантировать это свойство, на вход сети вместо координат подаются $D_4$-инварианты:

$$s_1 = 2\left(\xi^2 + \eta^2\right),\ s_2 = 16\xi^2\eta^2,\ s_1, s_2 \in [0;\ 1]. \quad (7)$$

Известно, что кольцо инвариантов группы $D_4$ на плоскости порождается именно полиномами $\xi^2 + \eta^2$ и $\xi^2\eta^2$, поэтому любая гладкая функция входов (7) автоматически обладает симметрией четвёртого порядка. Для эффективного обучения производных высокого порядка входы дополняются фурье-признаками [7]: $\sin(k\pi s_1)$, $\cos(k\pi s_1)$, $\sin(k\pi s_2)$, $\cos(k\pi s_2)$, $k = 1, \ldots, 8$. В соответствии с постановкой задания скрытая часть сети состоит из 6 слоёв по 80 нейронов с функцией активации SiLU [8]; общее число обучаемых параметров составляет $\approx 35,3$ тыс. Архитектура одинакова для обоих случаев закрепления.

***2.4. Коллокационные точки и веса важности***

Обучающее множество содержит в общей сложности 17 985 точек: 9 000 внутренних точек, равномерно распределённых по области, ~4 500 точек в полосах (безразмерной) ширины 0,06 вдоль сторон квадрата и ~4 500 точек в кольце той же ширины вокруг отверстия (рис. 1). В соответствии с заданием такое распределение сгущено вблизи границ и лучше покрывает зоны наибольших градиентов решения.




Рис. 1. Распределение коллокационных точек со сгущением у границ (стороны квадрата и окружность отверстия); всего 17 985 точек

Простое усреднение по неравномерно распределённым точкам не является несмещённой оценкой интеграла: приграничные полосы получили бы искусственно завышенный в 3–4 раза вес. Поэтому каждой точке приписывается вес важности — величина, обратная локальной плотности выборки, $\kappa_i = 1/p(x_i)$; $p(x)$ вычисляется аналитически как плотность трёхкомпонентной смеси (равномерная внутренняя компонента, приграничные полосы и кольцо). Взвешенное среднее тогда в точности оценивает $(1/|\Omega|)\int(\cdot)\,d\Omega$. Корректность весов проверена на эталонном решении: взвешенная оценка эталонной энергии отличается от точного квадратурного значения на ~1 %, тогда как невзвешенная оценка ошибочна даже по знаку.

***2.5. Вариационное обучение (Deep Ritz) и естественное граничное условие***

В общем случае вариационная задача на основе полной энергии изгиба пластины имеет вид (в безразмерной форме):

$$J[W] = \int_\Omega \left[\frac{1}{2}\left(\nabla^2 W\right)^2 - (1-\nu)\left(W_{\xi\xi}W_{\eta\eta} - W_{\xi\eta}^2\right) - W\right] d\Omega \to min. \quad (8)$$

Уравнение Эйлера–Лагранжа для (8) внутри области есть в точности $\nabla^4 W = 1$ (слагаемое с гауссовой кривизной имеет дивергентную форму и не даёт вклада во внутреннее уравнение). В случае защемления при условиях (2а) интеграл от гауссова слагаемого по области обращается в нуль [9], и функционал сводится к $J = \int\left[\frac{1}{2}\left(\nabla^2 W\right)^2 - W\right] d\Omega$. В случае шарнирного опирания это слагаемое необходимо

сохранить: минимизация (8) в классе функций $w = 0$ даёт в качестве естественного условия именно $M_n = 0$ — в его корректной форме на криволинейной границе, с учётом кривизны и $\nu$. Тем самым «трудное» условие шарнирного опирания следует из самого функционала без каких-либо штрафных слагаемых, а известные парадоксы, возникающие при некорректном упрощении криволинейной шарнирно опёртой границы [10], исключаются по построению.

Существенно, что (8) содержит лишь производные второго порядка: это делает вычисления в несколько раз дешевле по сравнению с поточечной невязкой четвёртого порядка, сохраняет устойчивость в формате float32 и позволяет обойти жёсткость у границы и в углах, присущую четвёртой производной структуры решения. Дискретная функция потерь принимается в виде взвешенного среднего:

$$\widehat{J}(\theta, \lambda) = \frac{\sum_i \kappa_i e_i}{\sum_i \kappa_i}, \;\; e_i = \frac{1}{2}\left(\nabla^2 W_i\right)^2 - (1-\nu)\left(W_{\xi\xi} W_{\eta\eta} - W_{\xi\eta}^2\right)_i - W_i. \quad (9)$$

Обучение проводится в три этапа. (A) Тёплый старт: на короткой стадии обучения с учителем (Adam, ≤1000 эпох) сеть подгоняется к значениям эталонного решения Рэлея–Ритца. (B) Основной этап: функционал $\widehat{J}$ минимизируется оптимизатором Adam [11] в течение 2 500 эпох (начальный шаг $10^{-3}$, экспоненциальное затухание, ограничение нормы градиента значением 1,0, случайный батч из 5 000 точек на итерацию); каждые 200 эпох сохраняется наилучшее по $J$ на полном множестве состояние, и именно оно принимается по завершении. (C) Финальная доводка: на полном множестве применяется метод L-BFGS [12]; если он ухудшает функционал, автоматически восстанавливается предыдущее состояние. На протяжении всего процесса отслеживаются два показателя: отношение диагонального пика к эталону и отношение энергий $J/\left|J_{ref}\right|$.

### *2.6. Независимый эталон для верификации: решение по методу Рэлея–Ритца*

Для каждого случая закрепления та же задача была решена также классическим методом Рэлея–Ритца: соответствующий функционал минимизировался на 40 базисных функциях, построенных с помощью соответствующей граничной функции (полиномы Чебышёва; $(\omega/\omega_{\max})^2 \cdot T_a \cdot T_b$ для защемления и $(\varphi/\varphi_{\max}) \cdot T_a \cdot T_b$ для шарнирного опирания); интегралы вычислялись на равномерной сетке 700×700. Надёжность эталонов проверена обогащением базиса с 15 до 60–84 функций: диагональный пик монотонно сходился от $W_{\max} = 3,4788 \cdot 10^{-5}$ к $3,4946 \cdot 10^{-5}$ в случае защемления и от $1,2691 \cdot 10^{-4}$ к $1,2776 \cdot 10^{-4}$ в случае шарнирного опирания, стабилизируясь соответственно до четырёх значащих цифр и до 0,03 %; энергия в обоих случаях монотонно убывала. В силу фундаментального свойства аппроксимаций Галёркина $J_{RR} \geq J_{exact}$, поэтому при выполнении неравенства $J_{PINN} \leq J_{RR}$ нейросетевое решение гарантированно не менее близко к точному в энергетической норме, чем эталон, — это неравенство принято в настоящей работе в качестве основного критерия качества.

### *2.7. Аналитическая верификация методики*

Новые элементы, введённые для случая шарнирного опирания, — полная энергия изгиба, гладкий множитель первой степени и естественное условие на криволинейной границе — были до применения проверены на двух задачах с аналитическими решениями. Первая — шарнирно опёртая круглая пластина (решающий тест для криволинейной границы): вычисленный прогиб в центре отличался от классической аналитической формулы лишь на 0,005 %, а радиальный профиль совпал в пяти значащих цифрах; это непосредственно доказывает, что естественное условие $M_n = 0$ на криволинейной границе корректно следует из энергии. Вторая — шарнирно опёртая квадратная пластина: прогиб в центре совпал с известным значением Навье $W_{\max} = 0,00406235$ в шести значащих цифрах, что подтверждает корректность мультипликативной формы $\varphi$ и угловой асимптотики. Лишь после прохождения обоих тестов методика была применена к основной области.

**3. Результаты**

Вычисления выполнены в среде Google Colab (GPU NVIDIA T4, float32); для каждого случая построение эталона, тёплый старт и полное обучение в совокупности заняли ~15 минут.

***3.1. Случай жёсткого защемления***

Эталон Рэлея–Ритца даёт $W_{\max} = 3,4945 \cdot 10^{-5}$ (безразмерный), $|w|_{\max} = 2,612 \cdot 10^{-5}$ мм в точках $(\pm 6,0;\ \pm 6,0)$ см от центра, лежащих на диагоналях. На рис. 2 показана эволюция энергетического функционала в ходе обучения: начиная с $J/\left|J_{ref}\right| \approx -0,83$ после тёплого старта, функционал за 200 эпох достиг эталонного уровня $-1,000$ и к концу обучения установился на уровне $\approx -1,005$ — основной критерий качества $J_{PINN} \leq J_{RR}$ выполнен.

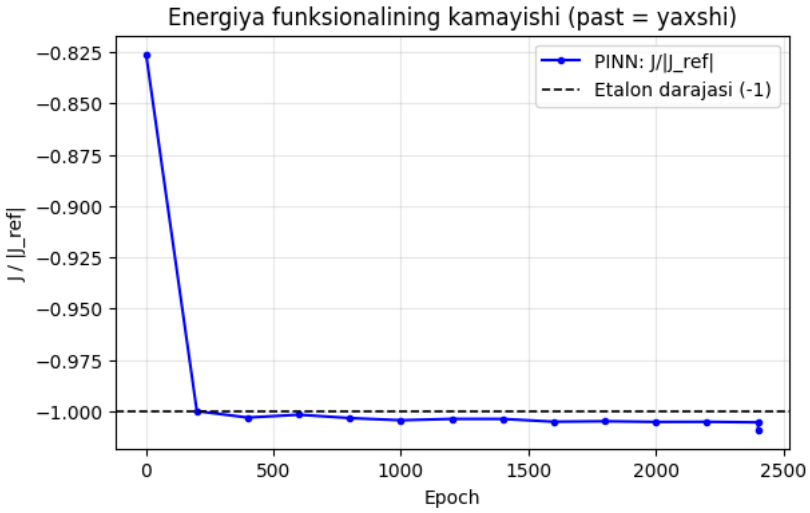



Рис. 2. Случай защемления: убывание энергетического функционала в ходе обучения. Штриховая линия — эталонный уровень ($-1$); итоговое значение $J/\left|J_{ref}\right| \approx -1,005$

Полученная поверхность прогиба показана на рис. 3 с двух ракурсов. Благодаря инвариантным входам решение обладает строгой симметрией четвёртого порядка: прогиб образует четыре одинаковых лепестка в четырёх широких зонах между отверстием и углами квадрата, а вдоль всего контура и значение, и нормальная производная плавно обращаются в нуль. Максимальный прогиб $|w|_{\max} = 2,631 \cdot 10^{-5}$ мм отличается от эталонного значения лишь на 0,73 %.

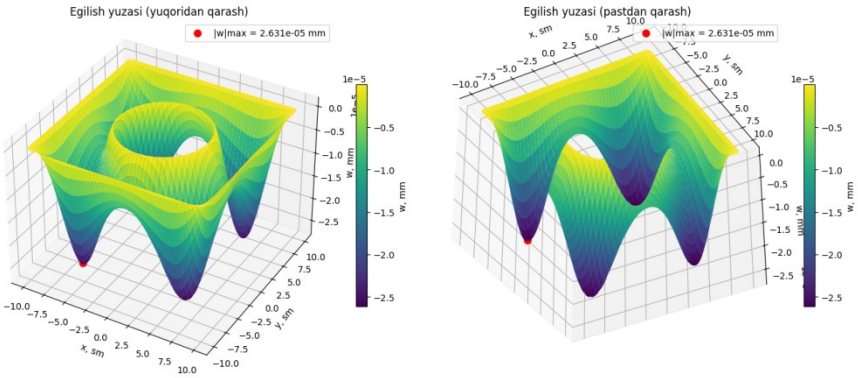



Рис. 3. Случай защемления: поверхность прогиба $w(x,y)$ (слева — вид сверху, справа — вид снизу). Красной точкой отмечено положение максимального прогиба $|w|_{\max} = 2,631 \cdot 10^{-5}$ мм (на диагонали)

В сечениях на рис. 4 кривые PINN практически совпадают с эталоном: в центральном сечении пик $\approx 8,9 \cdot 10^{-6}$ мм достигается при $x \approx \pm 7,5$ см, а в диагональном сечении два симметричных лепестка достигают глубины $2,63 \cdot 10^{-5}$ мм.

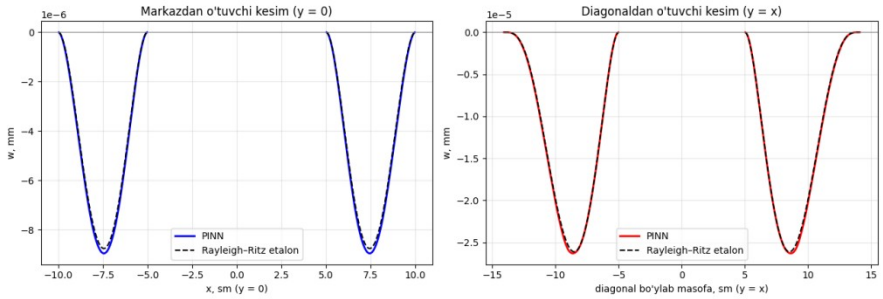



Рис. 4. Случай защемления: сечения через центр ($y = 0$, слева) и вдоль диагонали ($y = x$, справа) — PINN (сплошная линия) и эталон (штриховая)

В качестве сравнительного эксперимента та же архитектура была обучена с традиционной функцией потерь — средним квадратом поточечной невязки. В двух независимых запусках модель сошлась к одному и тому же решению с диагональным пиком, равным 71–75 % эталона (итоговое $|w|_{\max} = 1,957 \cdot 10^{-5}$ мм, т. е. 74,9 % эталона). Таким образом, обучение по поточечной невязке систематически занижает амплитуду прогиба примерно на 25 % для данной задачи четвёртого порядка, тогда как вариационное обучение той же самой сети обеспечило точность 0,73 %.

***3.2. Случай шарнирного опирания***

Эталон для случая шарнирного опирания: $W_{\max} = 1,2776 \cdot 10^{-4}$ (безразмерный), $|w|_{\max} = 9,550 \cdot 10^{-5}$ мм, снова на диагоналях в точках $(\pm 6,0;\ \pm 6,0)$ см — положение максимума естественно сохраняется, поскольку геометрия не изменилась. На рис. 5 показана сходимость по энергии: $J/\,|J_{ref}|$ достигло $-1,000$ за 200 эпох и установилось на уровне $\approx -1,003$ — основной критерий выполнен и в этом случае.

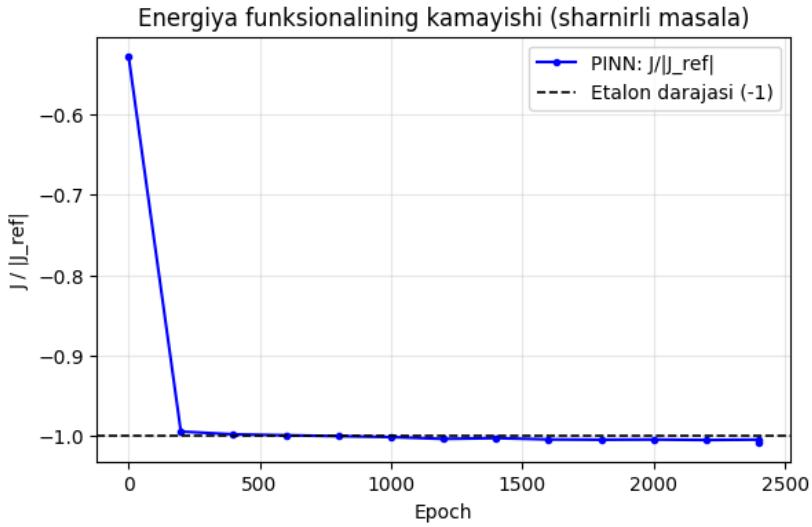



Рис. 5. Случай шарнирного опирания: убывание энергетического функционала; итоговое значение $J/\,|J_{ref}| \approx -1,003$ (ниже эталонного уровня)

Поверхность прогиба (рис. 6) четырёхлепестковая и полностью симметричная, как и в случае защемления, однако амплитуда заметно больше: $|w|_{\max} = 9,583 \cdot 10^{-5}$ мм, что лишь на 0,35 % отличается от эталона. Отчётливо виден ненулевой наклон поверхности вблизи границ — свобода поворота — характерный признак шарнирного опирания.

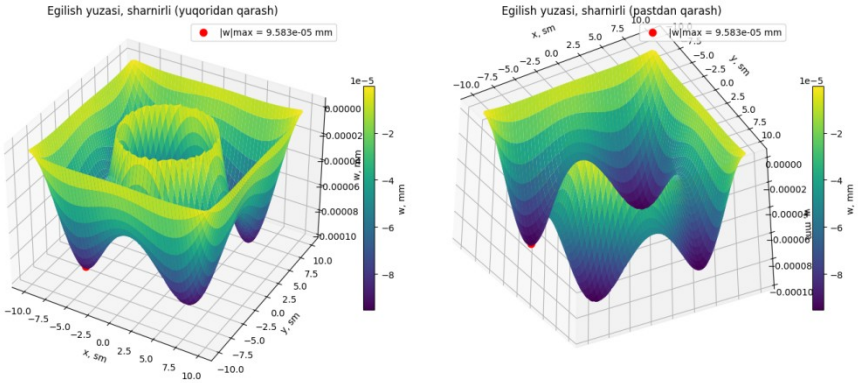



Рис. 6. Случай шарнирного опирания: поверхность прогиба $w(x, y)$ (слева — вид сверху, справа — вид снизу). Красной точкой отмечено $|w|_{\max} = 9,583 \cdot 10^{-5}$ мм (на диагонали)

В сечениях (рис. 7) кривые PINN и эталона неразличимы: пик в центральном сечении составляет $\approx 5,2 \cdot 10^{-5}$ мм при $x \approx \pm 7,5$ см ($5,15 \cdot 10^{-5}$ мм в эталоне), а глубина диагонального сечения — $9,6 \cdot 10^{-5}$ мм. Крутой, некасательный подход кривых к нулю вблизи границы также согласуется с условием шарнирного опирания.

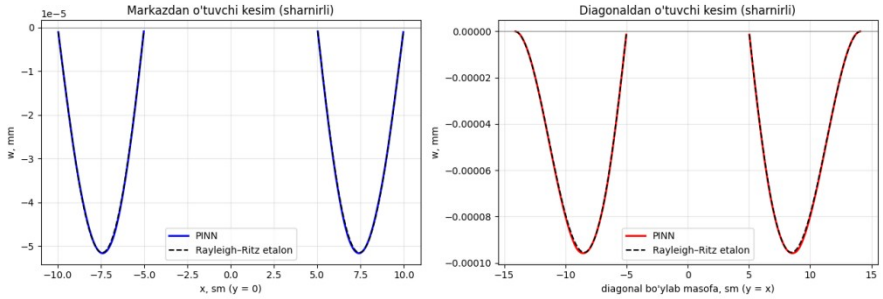



Рис. 7. Случай шарнирного опирания: сечения через центр ($y = 0$, слева) и вдоль диагонали ($y = x$, справа) — PINN (сплошная линия) и эталон (штриховая)

### *3.3. Сравнение двух случаев и физическая согласованность*

Основные численные показатели сведены в таблицу 2. При шарнирном опирании максимальный прогиб в $9,55/2,61 \approx 3,7$ раза больше, чем при защемлении, — что полностью согласуется с более податливым закреплением, обусловленным свободой поворота (для сравнения: для сплошной квадратной пластины отношение прогибов при шарнирном опирании и защемлении $\approx 3,2$). В обоих случаях прогиб имеет порядок $10^{-5}$–$10^{-4}$ мм (десятки–сотни нанометров), что соответствует высокой жёсткости стальной пластины; условие $w \ll h$ выполняется с огромным запасом, что оправдывает применение линейной теории Кирхгофа.

Таблица 2. Сравнение результатов PINN с эталонами Рэлея–Ритца

| **Показатель** | **Защемление: PINN** | **Защемление: эталон** | **Шарнир: PINN** | **Шарнир: эталон** |
|---|---|---|---|---|
| Безразмерный $W_{\max}$ | 3,52·10⁻⁵ | 3,4945·10⁻⁵ | 1,282·10⁻⁴ | 1,2776·10⁻⁴ |
| $\|w\|_{\max}$, мм | 2,631·10⁻⁵ | 2,612·10⁻⁵ | 9,583·10⁻⁵ | 9,550·10⁻⁵ |
| Положение, см | (±6; ±6) | (±6,0; ±6,0) | (±6; ±6) | (±6,0; ±6,0) |
| Отклонение от эталона | 0,73 % | — | 0,35 % | — |
| $J / \lvert J_{ref} \rvert$ | ≈ −1,005 | −1,000 | ≈ −1,003 | −1,000 |

## 4. Обсуждение

Механизм выявленного в случае защемления недостатка подхода на основе поточечной невязки состоит в следующем. Четвёртая производная структуры решения $\omega^2 N_\theta$ принимает очень большие значения в приграничных и особенно в угловых зонах, причём эти слагаемые пропорциональны амплитуде решения. Оптимизатор,

минимизирующий квадрат невязки, ищет баланс между этими жёсткими граничными слагаемыми и внутренним источником и уменьшает суммарную невязку ценой снижения амплитуды. Характерно, что средний квадрат поточечной невязки смещённого решения оказался даже меньше, чем у эталона, — т. е. поточечная метрика не является надёжной мерой качества решения для данной задачи. Наблюдаемое явление согласуется с общими выводами о патологиях градиентного потока в PINN [13] и даёт их наглядное количественное проявление для уравнений четвёртого порядка. Вариационный функционал устраняет проблему в корне: $J$ содержит лишь ограниченные вторые производные, а снижение амплитуды увеличивает энергию, поэтому дрейф амплитуды энергетически невозможен.

Случай шарнирного опирания выявил ещё одно принципиальное преимущество вариационного подхода: поскольку условие на момент $M_n = 0$ является естественным, его вообще не потребовалось навязывать аппроксимации — минимизация полной энергии изгиба в классе $w = 0$ обеспечила его самостоятельно, в корректной форме на криволинейной границе отверстия с учётом слагаемых с кривизной и $\nu$. Его корректность обоснована в два этапа: сначала на тестах с аналитическими решениями (шарнирно опёртый диск — погрешность 0,005 %; шарнирно опёртый квадрат — совпадение со значением Навье в шести цифрах), а затем на основной задаче через энергетический критерий и совпадение с эталоном с точностью 0,35 %. Известно, что подходы, основанные на упрощении криволинейной шарнирно опёртой границы до $w = 0$, $\nabla^2 w = 0$, приводят к парадоксам теории пластин [10]; предложенная вариационная схема исключает этот риск по построению. Кроме того, гладкая мультипликативная граничная функция с угловой асимптотикой $\omega \sim u \cdot v$ точно воспроизводит поведение шарнирно опёртого решения в углах и гарантирует регулярность интеграла энергии.

Практически важными оказались ещё два элемента методики. Во-первых, тёплый старт запускал обучение в окрестности правильной амплитуды и резко ускорял сходимость — в обоих случаях энергия достигала эталонного уровня за 200 эпох, тогда как итоговое решение полностью определяется энергетическим функционалом и превосходит эталон. Во-вторых, веса важности позволили статистически корректно использовать требуемую заданием коллокацию со сгущением у границ. Следует подчеркнуть, что оба случая закрепления решены с абсолютно одинаковыми архитектурой, гиперпараметрами и расписанием обучения, без какой-либо перенастройки, — свидетельство робастности и универсальности предложенной методики.

Работа выполнена в рамках линейной теории Кирхгофа, что полностью оправдано для рассматриваемого нагружения. Естественными направлениями развития подхода являются смешанные граничные условия (часть контура защемлена, часть шарнирно опёрта), другие виды нагрузок, области с несколькими отверстиями, переход к модели Рейсснера–Миндлина и параметрические PINN по геометрическим параметрам.

**Заключение**

Задача изгиба квадратной стальной пластины с центральным круговым отверстием под действием собственного веса решена для случаев защемления и шарнирного опирания единой методикой PINN, основанной на R-функциях и вариационном обучении. Главные граничные условия выполнены точно посредством соответствующих структур решения ($\omega^2$ для защемления; гладкая функция $\omega$ в первой степени, согласованная с угловой асимптотикой, для шарнирного опирания); условие $M_n = 0$ для шарнирного опирания естественным образом следовало из минимизации полной энергии изгиба, и этот механизм подтверждён на тестах с аналитическими решениями (диск — 0,005 %; квадрат — совпадение в шести цифрах). Сеть требуемой архитектуры 6×80 (SiLU) обучена на ~18 000 коллокационных точках со сгущением у границ с использованием взвешенного функционала Deep Ritz.

Оба решения всесторонне подтверждены независимыми эталонами Рэлея–Ритца: $|w|_{\max} = 2,631 \cdot 10^{-5}$ мм для защемления (отклонение 0,73 %) и $|w|_{\max} = 9,583 \cdot 10^{-5}$ мм для шарнирного опирания (отклонение 0,35 %); в обоих случаях максимум лежит на диагоналях на расстоянии $\pm 6$ см от центра, сечения практически совпадают с эталонными, а достигнутая PINN энергия ниже энергии эталонов ($J / \left|J_{ref}\right| \leq -1$), что доказывает высокую точность решений в энергетической норме. Прогиб при шарнирном опирании в $\approx 3,7$ раза больше, чем при защемлении, что согласуется с физическими представлениями о жёсткости закрепления. Установлено также, что традиционная PINN на основе поточечной невязки систематически занижает амплитуду примерно на 25 % для данной задачи четвёртого порядка, и объяснён механизм этого эффекта — наблюдение, дающее важный практический аргумент в пользу выбора вариационного подхода PINN для уравнений высокого порядка и задач с естественными граничными условиями.

**Литература**

1. Raissi, M. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations / M. Raissi, P. Perdikaris, G.E. Karniadakis // Journal of Computational Physics. – 2019. – Vol. 378. – P. 686–707.

2. Lagaris, I.E. Artificial neural networks for solving ordinary and partial differential equations / I.E. Lagaris, A. Likas, D.I. Fotiadis // IEEE Transactions on Neural Networks. – 1998. – Vol. 9, N. 5. – P. 987–1000.

3. E, W. The Deep Ritz method: A deep learning-based numerical algorithm for solving variational problems / W. E, B. Yu // Communications in Mathematics and Statistics. – 2018. – Vol. 6, N. 1. – P. 1–12.

4. Рвачёв, В.Л. Теория R-функций и некоторые её приложения / В.Л. Рвачёв. – Киев: Наукова думка, 1982. – 552 с.

5. Rvachev, V.L. R-functions in boundary value problems in mechanics / V.L. Rvachev, T.I. Sheiko // Applied Mechanics Reviews. – 1995. – Vol. 48, N. 4. – P. 151–188.

6. Sukumar, N. Exact imposition of boundary conditions with distance functions in physics-informed deep neural networks / N. Sukumar, A. Srivastava // Computer Methods in Applied Mechanics and Engineering. – 2022. – Vol. 389. – Art. 114333.

7. Tancik, M. Fourier features let networks learn high frequency functions in low dimensional domains / M. Tancik, P. Srinivasan, B. Mildenhall et al. // Advances in Neural Information Processing Systems (NeurIPS). – 2020. – Vol. 33. – P. 7537–7547.

8. Ramachandran, P. Searching for activation functions / P. Ramachandran, B. Zoph, Q.V. Le // arXiv preprint arXiv:1710.05941. – 2017.

9. Timoshenko, S.P. Theory of Plates and Shells / S.P. Timoshenko, S. Woinowsky-Krieger. – 2nd ed. – New York: McGraw-Hill, 1959. – 580 p.

10. Babuška, I. The plate paradox for hard and soft simple support / I. Babuška, J. Pitkäranta // SIAM Journal on Mathematical Analysis. – 1990. – Vol. 21, N. 3. – P. 551–576.

11. Kingma, D.P. Adam: A method for stochastic optimization / D.P. Kingma, J. Ba // Proc. of the 3rd International Conference on Learning Representations (ICLR). – 2015.

12. Liu, D.C. On the limited memory BFGS method for large scale optimization / D.C. Liu, J. Nocedal // Mathematical Programming. – 1989. – Vol. 45. – P. 503–528.

13. Wang, S. Understanding and mitigating gradient flow pathologies in physics-informed neural networks / S. Wang, Y. Teng, P. Perdikaris // SIAM Journal on Scientific Computing. – 2021. – Vol. 43, N. 5. – P. A3055–A3081.

14. F. Nuraliev, S. Safarov, and M. Artikbayev, “Solving the problem of geometrical nonlinear deformation of electro-magnetic thin plate with complex configuration and analysis of results,” in Proc. 2021 International Conference on Information Science and

Communications Technologies (ICISCT), Tashkent, Uzbekistan, 2021, pp. 1-5, DOI: 10.1109/ICISCT52966.2021.9670282.

15. F. Nuraliev, Sh. Safarov, M. Artikbayev, and O. Sh. Abdirozikov, “Calculation Results of the Task of Geometric Nonlinear Deformation of Electro-magneto-elastic Thin Plates in a Complex Configuration,” in Proc. 2022 International Conference on Information Science and Communications Technologies (ICISCT), Tashkent, Uzbekistan, 2022, pp. 1-5, DOI: 10.1109/ICISCT55600.2022.10146920.

16. S. Safarov and M. Bahramov, “Computational modeling of nonlinear processes in thin elastic plates subjected to electromagnetic fields,” CEUR Workshop Proceedings, vol. 4213, pp. 276-284, 2026.

# МОДИФИКАЦИЯ МЕТОДА ФИКТИВНЫХ ОБЛАСТЕЙ ДЛЯ НЕЛИНЕЙНОЙ МОДЕЛИ НЕНЬЮТОНОВСКОЙ ЖИДКОСТИ

Байтуленов Ж.Б., Тапеева С.К.
E-mail: janibekbb47@gmail.com
*Казахский национальный университет имени аль-Фараби, Алматы, Казахстан*

*В данной работе исследуется одна модификация метода фиктивных областей для стационарной модели неньютоновской жидкости. Доказывается существование и сходимость слабого решения вспомогательной задачи. Выводится оценка сходимости сильного решения приближенной задачи.*

В ограниченной области $\Omega \subset R^3$ рассмотрим стационарную математическую модель неньютоновской жидкости [1]:

$$\mathrm{Re}(\mathrm{v}\cdot\nabla)\mathrm{v} + \nabla P = (1-\alpha)\Delta \mathrm{v} + \nabla\cdot S + f, \tag{1}$$

$$S + We(\mathrm{v}\cdot\nabla)S = 2\alpha D, \quad div\mathrm{v} = 0, \tag{2}$$

с краевым условием

$$\mathrm{v}\big|_G = 0, \tag{3}$$

где: $x = (x_1, x_2, x_3) \in \Omega$, $\mathrm{v} = (\mathrm{v}_1(x), \mathrm{v}_2(x), \mathrm{v}_3(x))$ – вектор скорости жидкости, $P = P(x)$ - давление, $S = S(x)$ - упругая часть тензора напряжений, тензорная функция $D = (\nabla \mathrm{v} + (\nabla \mathrm{v})^T)/2$ – тензор скоростей деформации, $D, S$ - тензоры второго ранга с компонентами $\frac{1}{2}\left(\frac{\partial \mathrm{v}_i}{\partial x_j} + \frac{\partial \mathrm{v}_j}{\partial x_i}\right)$, $S_{ij}$; $\mathrm{Re} = uL/\mu$ и $We = \lambda_1 u / L$ - соответственно число Рейнольдса и число Вейсенберга, $\alpha = 1 - \lambda_2/\lambda_1$ - числовой параметр, $\lambda_1$ - время релаксации, $\lambda_2$ - время запаздывания, $0 < \lambda_2 < \lambda_1$. $u, L$ - характерные скорость и размер модели, $f = (f_1(x), f_2(x), f_3(x))$ - вектор массовых сил, $G$ - граница области $\Omega$.

Далее, в области $D_0 \supset \Omega$ исследуется следующая модификация метода фиктивных областей с продолжением по старшим коэффициентам:

$$\mathrm{Re}(\mathrm{v}^\varepsilon\cdot\nabla)\mathrm{v}^\varepsilon + \nabla P^\varepsilon = div(K(\mathrm{v}^\varepsilon)\nabla \mathrm{v}^\varepsilon) + \nabla\cdot S^\varepsilon + f^\varepsilon, \tag{5}$$

$$S^\varepsilon + We(\mathrm{v}^\varepsilon\cdot\nabla)S^\varepsilon = 2\alpha D^\varepsilon, \tag{6}$$

$$div\mathrm{v}^\varepsilon = 0, \tag{7}$$

$$\mathrm{v}^\varepsilon\big|_{G_1} = 0, \tag{8}$$

с условием согласования

$$\left[\mathrm{v}^\varepsilon\right]_G = 0, \ \left[K(\mathrm{v}^\varepsilon)\frac{\partial \mathrm{v}^\varepsilon}{\partial n} - P^\varepsilon n + S^\varepsilon\cdot n\right]\Big|_G = 0, \ \left[S^\varepsilon\right]_G = 0, \tag{9}$$

: $0 < \beta < 1$, $G_1$ - граница области $D_0$, $G_1 \cap G = \emptyset$, $\varepsilon > 0$, n – вектор нормали к

где

$$\xi(x) = \begin{cases} 0, & \text{в } \Omega \\ 1, & \text{в } D_1 = D_0 \setminus \Omega. \end{cases} \quad f^{\varepsilon}(x) = \begin{cases} f(x), & \text{в } \Omega \\ 0, & \text{в } D_1 \end{cases}$$

границе $G_1$,

$$K^{\varepsilon}(\mathrm{v}^{\varepsilon}) = \begin{cases} 1 - \alpha, \quad при \quad x \in \Omega, \\ \dfrac{1 - \alpha}{\varepsilon \left\| \nabla \mathrm{v}^{\varepsilon} \right\|^{\beta}_{L_2(D_1)}}, 0 \le \beta < 1, x \in D_1 = D_0 / \Omega, \end{cases}$$

$f \in L_{6/5}(\Omega)$

**Теорема 1.** Пусть . Тогда существует хотя бы одно обобщенное решение задачи (5)-(9) и для решения имеет место оценка

$$\left\| \mathrm{v}^{\varepsilon}_x \right\|^2_{L_2(\Omega)} + \left\| S^{\varepsilon} \right\|^2_{L_2(D_0)} + \frac{1}{\varepsilon} \left\| \mathrm{v}^{\varepsilon}_x \right\|^{2-\beta}_{L_2(D_1)} \le C < \infty$$

.

**Теорема 2.** Для решений задач (1)-(3) и (5)-(9) справедлива оценка

$$\left\| \mathrm{v}^{\varepsilon} - \mathrm{v} \right\|^2_{L_2(\Omega)} + \left\| S^{\varepsilon} - S \right\|^2_{L_2(\Omega)} \le C \varepsilon^{\frac{1}{1-\beta}}, \quad 0 < \beta < 1.$$

**Литература.**

1. Турганбаев М.Е. Фильтрация вязкоупругой жидкости типа Олдройда // Динамика сплошной среды. Вып. 108, 1994, с.80-97.

# ЧИСЛЕННОЕ МОДЕЛИРОВАНИЕ ЭФФЕКТА МАГНУСА НА ВРАЩАЮЩЕМСЯ ЦИЛИНДРЕ МЕТОДОМ РЕШЁТОЧНЫХ УРАВНЕНИЙ БОЛЬЦМАНА

Жакебаев Д.Б., Мусират С.
e-mail: Zhakebayev@kaznu.kz sayamusirat@gmail.com

Казахский национальный университет имени аль-Фараби, Алматы, Казахстан

Аннотация. Методом решёточных уравнений Больцмана (модель D2Q9, BGK-приближение), ранее апробированным на классической задаче обтекания неподвижного цилиндра, выполнено численное моделирование эффекта Магнуса на вращающемся цилиндре. Алгоритм расширен путём введения коррекции Ладда для подвижной стенки. При $Re$=100 проведено испытание коэффициента вращения $\alpha=U_{sp}/U_0$ в диапазоне 0–3,0: показано, что подъёмная сила растёт по модулю монотонно, а вихревые узлы дорожки Кармана отклоняются в направлении вращения. Результаты сопоставлены с литературными данными [3, 5]: критерий полного подавления колебаний, использованный в [3] для определения критического коэффициента вращения $\alpha_L$, в исследованном диапазоне $\alpha\leq3{,}0$ не достигнут — колебания $C_l(t)$ остаются ненулевыми при всех рассмотренных $\alpha$.

**Ключевые слова:** метод решёточных уравнений Больцмана, D2Q9, эффект Магнуса, вращающийся цилиндр, ротор Флеттнера, дорожка Кармана, коррекция Ладда.

## Введение

Обтекание вращающегося цилиндра лежит в основе эффекта Магнуса — возникновения силы, перпендикулярной направлению набегающего потока. Физически данный эффект обусловлен суперпозицией циркуляционного течения, порождаемого вращением цилиндра, и набегающего потока: на стороне, где окружная скорость поверхности совпадает по направлению с набегающим потоком, локальная скорость возрастает, а точка отрыва пограничного слоя смещается вниз по потоку, тогда как на противоположной стороне — против потока; возникающая асимметрия распределения давления и порождает результирующую поперечную силу [1]. Классические эксперименты Прандтля (1925) впервые показали, что при достаточно высокой скорости вращения дорожка Кармана за цилиндром подавляется [1]. Практическим приложением эффекта Магнуса служит ротор Флеттнера, использование которого в морских перевозках может обеспечивать экономию топлива до 20% согласно оценкам, приведённым в [2].

Задача о вращающемся цилиндре к настоящему времени хорошо изучена: показано, что вращение подавляет срыв вихрей, причём критический коэффициент $\alpha_L$ слабо зависит от числа Рейнольдса [3], построена параметрическая карта режимов течения для $0\leq\alpha\leq6$ [4], а в области высоких коэффициентов вращения (приблизительно $\alpha$=4,3–4,6) описан второй периодический режим, отличный от классической дорожки Кармана [5]. Метод решёточных уравнений Больцмана (РУБ) [7–9], основанный на эволюции мезоскопической функции распределения частиц, представляет собой вычислительно эффективную и естественно распараллеливаемую альтернативу классическим методам вычислительной гидродинамики [6]. Цель настоящей работы состоит в том, чтобы расширить ранее апробированный алгоритм РУБ на задачу о вращающемся цилиндре, установить зависимость подъёмной силы от коэффициента вращения и верифицировать полученные результаты сопоставлением с независимыми литературными данными.

## 1. Постановка задачи

Расчётная область представляет собой прямоугольный канал размером $N_x \times N_y$ узлов решётки с цилиндром радиуса $R$, центр которого расположен по вертикали посередине канала, а по горизонтали — на расстоянии $0{,}2N_x$ от входной границы (рисунок 1).

**Начальные условия.** Во всей расчётной области при $t = 0$ задаются:

$$\begin{aligned} &\rho(x,\, y,\, 0) \;=\; \rho_0 \;=\; 1, \\ &u_x(x,\, y,\, 0) \;=\; U_0, \quad u_y(x,\, y,\, 0) \;=\; 0, \\ &f_i(x,\, y,\, 0) \;=\; f_i^{eq}(\rho_0,\, u_0), \end{aligned} \tag{1}$$

где $\mathbf{u}_0 = (U_0,\, 0)$, а равновесная функция распределения $f_i^{eq}$ определяется формулой (6) (раздел 2).

**Граничные условия.** В методе РУБ граничные условия задаются через функции распределения $f_i$; используется нумерация направлений модели D2Q9: $\mathbf{e}_0 = (0,\, 0)$, $\mathbf{e}_1 = (1,\, 0)$, $\mathbf{e}_2 = (0,\, 1)$, $\mathbf{e}_3 = (-1,\, 0)$, $\mathbf{e}_4 = (0,\, -1)$, $\mathbf{e}_5 = (1,\, 1)$, $\mathbf{e}_6 = (-1,\, 1)$, $\mathbf{e}_7 = (-1,\, -1)$, $\mathbf{e}_8 = (1,\, -1)$. Знаком * отмечены значения после этапа столкновения.

Вход ($x = 0$), условие Зоу–Хе [13]: $u_x = U_0$, $u_y = 0$,

$$\begin{aligned} &\rho \;=\; \frac{f_0 \,+\, f_2 \,+\, f_4 \,+\, 2(f_3 \,+\, f_6 \,+\, f_7)}{1 \,-\, U_0}, \quad f_1 \;=\; f_3 \,+\, \frac{2}{3}\rho U_0, \\ &f_5 \;=\; f_7 \,-\, \frac{1}{2}(f_2 \,-\, f_4) \,+\, \frac{1}{6}\rho U_0, \quad f_8 \;=\; f_6 \,+\, \frac{1}{2}(f_2 \,-\, f_4) \,+\, \frac{1}{6}\rho U_0. \end{aligned} \tag{2}$$

Выход ($x = N_x - 1$), экстраполяция нулевого порядка (условие свободного вытекания):

$$f_i(N_x \,-\, 1,\, y) \;=\; f_i(N_x \,-\, 2,\, y), \quad i \;=\; 3,\, 6,\, 7. \tag{3}$$

Стенки канала (условие прилипания), отражение (bounce-back) $f_{\bar{i}} = f_i^*$:

$$\begin{aligned} &y \;=\; 0: \quad f_2 \;=\; f_4^*, \quad f_5 \;=\; f_7^*, \quad f_6 \;=\; f_8^*; \\ &y \;=\; N_y \,-\, 1: \quad f_4 \;=\; f_2^*, \quad f_7 \;=\; f_5^*, \quad f_8 \;=\; f_6^*. \end{aligned} \tag{4}$$

Поверхность цилиндра ($(x - x_c)^2 + (y - y_c)^2 = R^2$, где $(x_c,\, y_c) = (0{,}2N_x,\, N_y/2)$): отражение с коррекцией Ладда для подвижной стенки, учитывающей скорость вращения $\mathbf{u}_w = \Omega \times \mathbf{r}$ с угловой скоростью $\Omega = \alpha U_0/R$ (формула (7), раздел 2); $\Omega > 0$ соответствует вращению против часовой стрелки.

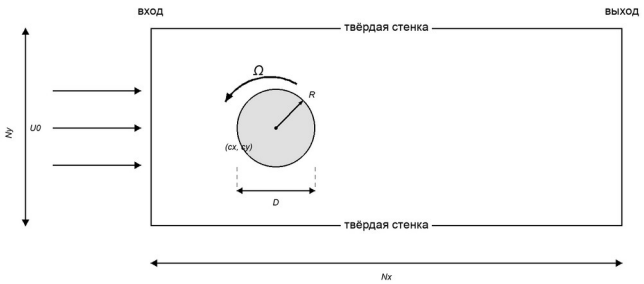



**Рисунок 1 –** Схема расчётной области: прямоугольный канал с вращающимся цилиндром

Все расчёты проведены при $Re = U_0 D/\nu = 100$ ($U_0 = 0{,}04$, $D = 44$ узла решётки, $\tau = 0{,}553$) на сетке $N_x \times N_y = 500 \times 400$ ($D/N_y = 0{,}11$) для $\alpha = 0$–$3{,}0$ с шагом 0,5. Расчёт проводился 6000 шагов, коэффициенты $C_d$, $C_l$ осреднялись по последним 2000 шагам.

Для визуализации структуры следа (рисунок 2) дополнительно вычисляется поле завихрённости (центральные разности):

$$\omega \;=\; \frac{\partial u_y}{\partial x} \,-\, \frac{\partial u_x}{\partial y}$$

## 2. Метод

Расчёты выполнены с использованием алгоритма РУБ, ранее апробированного на классической задаче обтекания неподвижного цилиндра [10]. В методе РУБ эволюция функции распределения частиц $f_i(\boldsymbol{x},t)$ вдоль $i$-го дискретного направления решётки D2Q9 [12] описывается уравнением в приближении BGK [11]:

$$f_i(x + e_i\Delta t,\, t + \Delta t) = f_i(x,t) - \frac{1}{\tau}\left(f_i(x,t) - f_i^{eq}(x,t)\right) \tag{5}$$

$$f_i^{eq}(x,t) = w_i\rho\left(1 + \frac{(e_i\cdot u)}{c_s^2} + \frac{(e_i\cdot u)^2}{2c_s^4} - \frac{(u\cdot u)}{2c_s^2}\right) \tag{6}$$

где $\tau$ — время релаксации, связанное с кинематической вязкостью соотношением $\nu=c_s^2(\tau-1/2)$ (в решёточных единицах, $\Delta x=\Delta t=1$); $w_i$ — весовые коэффициенты модели D2Q9 ($w_0=4/9$ для нулевого направления, $w_i=1/9$ для четырёх основных направлений, $w_i=1/36$ для четырёх диагональных направлений); $\boldsymbol{e}_i$ — соответствующие дискретные скорости решётки [12]; $c_s = 1/\sqrt{3}$ — решёточная скорость звука. Дискретная эволюция разделяется на этапы столкновения и стриминга, а макроскопические плотность и скорость восстанавливаются как моменты функции распределения: $\rho=\Sigma_i f_i$, $\rho\boldsymbol{u}=\Sigma_i \boldsymbol{e}_i f_i$ (суммирование по всем $i$=0,…,8). На твёрдой стенке (включая поверхность цилиндра) применяется простая схема отражения (bounce-back) без субрешёточной интерполяции положения границы; на входной границе задаётся однородная скорость $U_0$ методом Зоу–Хе [13]; на выходной границе недостающие компоненты функции распределения копируются со значений соседнего (предпоследнего) столбца узлов решётки (экстраполяция нулевого порядка).

Для вращающегося цилиндра стандартное условие отражения дополняется коррекцией Ладда [14], учитывающей тангенциальную скорость движущейся границы $\boldsymbol{u}_w=\Omega\times\boldsymbol{r}$ ($\boldsymbol{r}$ — радиус-вектор от центра цилиндра до узла границы):

$$f_{\bar{i}}(x_b,t+\Delta t) = f_i^{*}(x_b,t) - 2w_i\rho\,\frac{e_i\cdot u_w}{c_s^2} \tag{7}$$

Здесь $\bar{i}$ обозначает направление, противоположное $i$ ($e_{\bar{i}}=-\boldsymbol{e}_i$), а $f_i^{*}$ — значение функции распределения после этапа столкновения (постколлизионное, до применения коррекции), а $f_{\bar{i}}(\boldsymbol{x}_b,t+\Delta t)$ — уже отражённое значение (для вращающегося цилиндра — с учётом коррекции (7)), используемое на следующем шаге стриминга.

Коэффициент вращения $\alpha=U_{sp}/U_0$, где $U_{sp}=\Omega R$ — окружная скорость поверхности цилиндра. Гидродинамическая сила на цилиндре вычисляется методом обмена импульсом: для каждого граничного узла xb суммированием по всем 9 направлениям решётки D2Q9 (i=0,…,8):

$$F_x = \sum_{i=0}^{8} 2e_{i,x}f_{\bar{i}}(x_b,t+\Delta t), \qquad F_y = \sum_{i=0}^{8} 2e_{i,y}f_{\bar{i}}(x_b,t+\Delta t) \tag{8}$$

где $f_{\bar{i}}$ — отражённое значение функции распределения по формуле (7) (при $\Omega$=0 совпадает с $f_i^{*}$); коэффициенты сопротивления и подъёмной силы вычисляются как:

$$C_d = \frac{F_x}{\frac{1}{2}\rho_0 U_0^2 D}, \qquad C_l = \frac{F_y}{\frac{1}{2}\rho_0 U_0^2 D}$$

## 3. Результаты

### 3.1. Испытание коэффициента вращения

Зависимости $C_l(\alpha)$, $C_d(\alpha)$ и амплитуды колебаний $C_l$(t) определены для $\alpha$=0–3,0 с шагом 0,5 (рисунок 3); значения при $\alpha$=0,1,2,3, соответствующие полям завихрённости на рисунке 2, приведены в таблице 1.

**Таблица 1 –** Испытание коэффициента вращения ($Re$=100, $D/N_y$=0,11, осреднено по t>4000)

| $\alpha$ | $C_d$ | $C_l$ | Амплитуда колебаний $C_l$ |
|---|---|---|---|
| 0,0 | 1,776 | −0,000 | 0,020 |
| 1,0 | 1,803 | −3,018 | 0,773 |
| 2,0 | 2,240 | −7,214 | 0,728 |
| 3,0 | 4,650 | −12,262 | 0,635 |

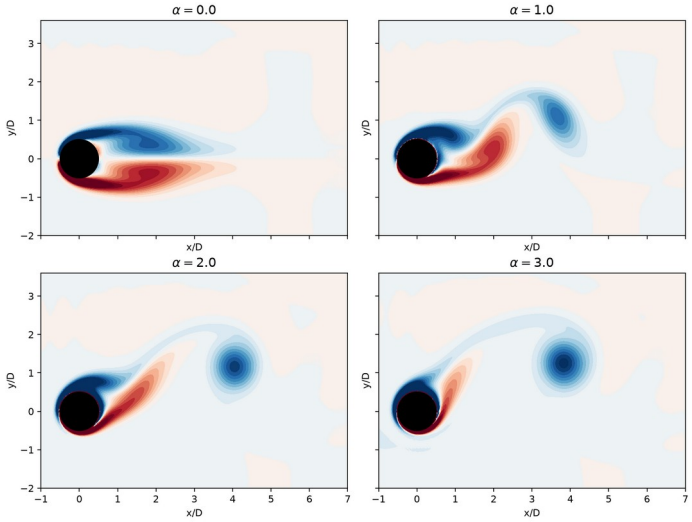



**Рисунок 2 –** Поле завихрённости ($D/N_y$=0,11), $\alpha$=0,1,2,3: вихревой узел чётко отделён от следа в виде обособленного пятна, расположенного на высоте $y/D$≈1,2–1,4

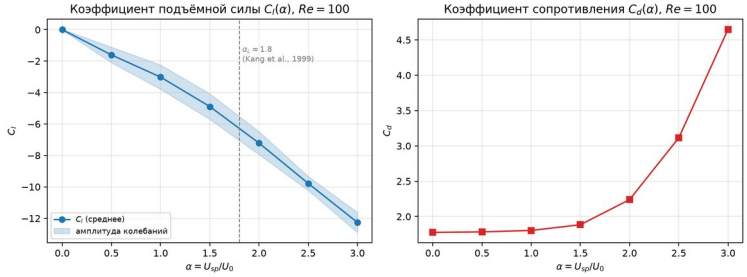



**Рисунок 3 –** $C_l(\alpha)$ и $C_d(\alpha)$; вертикальная линия — критическое значение $\alpha_L$≈1,8 [3] (значение получено в иной постановке — неограниченный поток; приведено как ориентир)

Подъёмная сила растёт по модулю практически монотонно с увеличением $\alpha$ (таблица 1). Амплитуда колебаний $C_l$(t) резко возрастает от $\alpha$=0 до $\alpha$=1, а при дальнейшем увеличении $\alpha$ до 3,0 слабо убывает, оставаясь существенно ненулевой; критерий полного подавления колебаний, использованный в [3] для определения $\alpha_L$, в рамках выполненных расчётов не достигнут. При $\alpha \gtrsim 2$ коэффициент сопротивления $C_d$ растёт заметно резче; возможными факторами являются ускорение потока в зазоре между цилиндром и стенкой и переход вихревой структуры к режиму обособленного пятна (рисунок 2); разделение вкладов этих факторов остаётся предметом дальнейшей работы.

## 3.2. Сравнение с независимыми литературными данными

Согласно [3], критический коэффициент вращения, полностью подавляющий срыв вихрей в неограниченном потоке, для $Re$=60,100,160 составляет $\alpha_L$≈1,4, 1,8 и 1,9 соответственно; для $Re$=200 в работе [5] приводится $\alpha_L$=1,9 и установившиеся значения $C_l$≈−6 и −10,3 при $\alpha$=2,0 и 3,0, что близко по величине к полученным здесь для $Re$=100 значениям (−7,21, −12,26; таблица 1). Отметим, что данное сопоставление носит

ориентировочный характер: в [5] приведённые значения $C_l$ относятся к иному числу Рейнольдса ($Re$=200 против $Re$=100 в настоящей работе) и к установившемуся (бесколебательному) режиму течения, тогда как в настоящей работе при тех же $\alpha$ колебания $C_l$(t) сохраняются; в [3] критическое $\alpha_L$ получено в постановке с неограниченным потоком, в отличие от канала конечной высоты ($D/N_y$=0,11), рассматриваемого в данной работе.

## Заключение

В настоящей работе алгоритм РУБ (модель D2Q9) расширен на случай вращающегося цилиндра путём введения коррекции Ладда для подвижной границы. Численно показано, что подъёмная сила монотонно растёт по модулю от 0 до −12,26 при $\alpha$=0–3,0 ($Re$=100, $D/N_y$=0,11), а вихревые узлы дорожки Кармана отклоняются в направлении вращения. Амплитуда колебаний $C_l$(t) остаётся существенно ненулевой во всём исследованном диапазоне $\alpha \leq 3{,}0$: критерий полного подавления колебаний, использованный в [3] для определения $\alpha_L$, в рамках выполненных расчётов не достигнут.

Полученные результаты могут служить качественным ориентиром для предварительной оценки эффекта Магнуса — в частности, применительно к судовым роторам Флеттнера, для которых отношение окружной скорости ротора к скорости ветра является ключевым параметром, определяющим генерируемую движущую силу. Разработанный алгоритм РУБ представляет собой существенно более простой и вычислительно дешёвый инструмент по сравнению с полномасштабными трёхмерными турбулентными DNS-расчётами [2] и воспроизводит основную качественную закономерность — рост подъёмной силы с увеличением коэффициента вращения и отклонение вихревой дорожки в направлении вращения. Вместе с тем настоящие расчёты выполнены в двумерной ламинарной постановке при $Re$=100, тогда как в реальных условиях эксплуатации роторы Флеттнера работают в трёхмерном турбулентном режиме при существенно более высоких числах Рейнольдса [2]; прямой количественный перенос приведённых здесь значений $C_d$, $C_l$ на натурные условия в данной работе не проводился и требует перехода к трёхмерной турбулентной модели.

Дальнейшее развитие работы связано с переходом к трёхмерной модели для учёта концевых эффектов ротора, применением схемы с многократной релаксацией (MRT) для расширения диапазона устойчивости по $\alpha$, использованием интерполяционной (субрешёточной) схемы отражения для более точного представления криволинейной границы цилиндра, а также со снижением загромождения расчётного канала и удлинением статистического окна осреднения для количественного сопоставления с эталонным $\alpha_L$.

## ЛИТЕРАТУРА

[1] Prandtl, L. (1926). Application of the “Magnus effect” to the wind propulsion of ships. *NACA Technical Memorandum* 367.

[2] Massaro, D., M. Karp, N. Jansson, S. Markidis, and P. Schlatter (2024). Direct numerical simulation of the turbulent flow around a Flettner rotor. *Scientific Reports* 14, Art. 3004.

[3] Kang, S., H. Choi, and S. Lee (1999). Laminar flow past a rotating circular cylinder. *Physics of Fluids* 11(11), 3312–3321.

[4] Stojković, D., M. Breuer, and F. Durst (2002). Effect of high rotation rates on the laminar flow around a circular cylinder. *Physics of Fluids* 14(9), 3160–3178.

[5] Kalinin, E.I. and A.B. Mazo (2013). Steady and periodic regimes of laminar flow around the rotating cylinder. *arXiv:1312.2787*.

[6] Anderson, J.D. (1995). *Computational Fluid Dynamics: The Basics with Applications*. McGraw-Hill, New York, 547 p.

[7] Krüger, T., H. Kusumaatmaja, A. Kuzmin, O. Shardt, G. Silva, and E.M. Viggen (2017). *The Lattice Boltzmann Method: Principles and Practice*. Springer, Cham, 694 p.

[8] Succi, S. (2001). *The Lattice Boltzmann Equation for Fluid Dynamics and Beyond*. Clarendon Press, Oxford, 288 p.

[9] Chen, S. and G.D. Doolen (1998). Lattice Boltzmann method for fluid flows. *Annual Review of Fluid Mechanics* 30, 329–364.

[10] Schäfer, M., S. Turek, F. Durst, E. Krause, and R. Rannacher (1996). Benchmark computations of laminar flow around a cylinder. In: *Flow Simulation with High-Performance Computers II*, Notes on Numerical Fluid Mechanics, Vol. 48. Vieweg, Braunschweig, 547–566.

[11] Bhatnagar, P.L., E.P. Gross, and M. Krook (1954). A model for collision processes in gases. I. Small amplitude processes in charged and neutral one-component systems. *Physical Review* 94(3), 511–525.

[12] Qian, Y.H., D. d'Humières, and P. Lallemand (1992). Lattice BGK models for Navier-Stokes equation. *Europhysics Letters* 17(6), 479–484.

[13] Zou, Q. and X. He (1997). On pressure and velocity boundary conditions for the lattice Boltzmann BGK model. *Physics of Fluids* 9(6), 1591–1598.

[14] Ladd, A.J.C. (1994). Numerical simulations of particulate suspensions via a discretized Boltzmann equation. Part 1. Theoretical foundation. *Journal of Fluid Mechanics* 271, 285–310.

# CFD-Based Assessment of Urban Morphology Effects on Ventilation Efficiency and $NO_2$ Dispersion in Residential Areas of Almaty

**Galina Bessonova[1], Aliya Tursynzhanova[1,2] Aisulu Ataniyazova[2], Perizat Omarova[2,3], Salim Mustafin[2] , Saltanat Amirgaliyeva**

ga_bessonova@kbtu.kz, ilee021199@gmail.com, aissulu.12@mail.ru, omarova.peryzat2@gmail.com, mustafinsal@mail.ru

[1]*School of Information Technology and Engineering, Kazakh-British Technical University*

[2]*Laboratory of Artificial Intelligence and Robotics named after academician Amirgaliyev Y.N*

*Institute of Information and Computational Technologies, Almaty, Kazakhstan*

[3]*Department of Software Engineering, Satbayev University (KazNRTU), Almaty, Kazakhstan*

***Abstract:*** *In densely built cities, traffic emissions combine with complex urban morphology and unfavourable climatic conditions, and urban air pollution remains a critical issue. In Almaty, high nitrogen dioxide ( $\mathbf{NO_2}$) concentrations are strongly influenced not only by emission intensity but also by airflow patterns within residential areas.*

*This study investigates the effect of urban morphological characteristics on air flow behaviour and $\mathbf{NO_2}$ dispersion using three real residential configurations located at major traffic intersections in Almaty. Three-dimensional Computational Fluid Dynamics (CFD) simulations were performed in ANSYS Fluent in the same inflow and emission conditions, to isolate the effect of building layout. Airflow was modeled using the $\mathbf{k-\omega}$ SST turbulence model, while pollutant transport was simulated using the Species Transport approach.*

*The results show significant differences in ventilation efficiency and pollutant spread depending on urban layout. The most effective design can reduce average pollutant levels by as much as 49% compared to the least efficient ones. Generally, layouts with greater spatial permeability and better airflow continuity tend to have fewer stagnation zones and support more efficient removal of pollutants.*

*The findings provide quantitative proof that urban morphology plays a key role in shaping neighborhood air quality. The study also presents a practical framework for assessing how building configurations impact ventilation efficiency and the spread of pollutants in real urban environments.*

***Keywords:*** *Urban morphology; Air pollution dispersion; Computational fluid dynamics (CFD); Urban ventilation; Nitrogen dioxide ($NO_2$); ANSYS Fluent.*

## Introduction

As of January 14, 2025, Swiss firm IQAir identified Almaty as the city with the highest air pollution levels [1]. Besides primary sources like traffic and industry, urban layout also plays a crucial role in shaping airflow and pollutant spread, impacting local air quality [2-5].

Urban air pollution has been extensively studied using both numerical and data-driven approaches, with particular attention to the role of urban morphology in influencing airflow and pollutant dispersion.

Several review papers summarize the current research status, emphasizing the strengths and limitations of computational fluid dynamics (CFD) in modeling urban airflow and pollutant transport [6-8]. These studies confirm CFD's role as a dependable and commonly used method for assessing urban air quality.

A large body of research focuses on CFD-based simulations of airflow and pollutant dispersion in urban environments. Previous studies demonstrate that building morphology significantly influences ventilation efficiency and pollutant accumulation [2, 3, 9]. High-density

layouts tend to generate recirculation zones and pollutant trapping, while more open and permeable configurations enhance airflow and pollutant removal [4], [9-11].

Most studies on modeling prefer Reynolds-Averaged Navier–Stokes (RANS) approaches because they are computationally efficient and offer reasonable accuracy for engineering purposes [12, 13]. Comparisons between RANS and Large Eddy Simulation (LES) reveal that although LES is more precise, its higher computational cost restricts its practical use [7, 12]. The k-ω SST turbulence model is commonly employed for predicting near-wall flows and flow separation around buildings [14, 15].

Recent research further explores how particular urban layouts impact airflow. Findings show that street canyon shape, building density, and orientation significantly influence ventilation efficiency and how pollutants disperse [16-20]. These results highlight the vital role of urban form in determining local aerodynamic conditions.

In addition to CFD-based strategies, data-driven methods use meteorological and traffic data to predict air pollution. Machine learning models like LSTM and gradient boosting effectively capture the temporal variations of pollutants [21]. However, since these approaches do not explicitly model physical airflow dynamics, their capacity to provide detailed spatial information on pollutant dispersion remains limited.

Environmental and health studies further underscore the need to lower traffic emissions and enhance urban airflow [22-25]. They emphasize the significant connection between $NO_2$ exposure and negative health effects.

Although significant progress has been made in this field, several challenges remain. Many studies rely on simplified or idealized urban layouts, limiting their applicability to real-world settings. Furthermore, research specifically on Central Asian cities such as Almaty is scarce. There are also few comparative studies evaluating different residential configurations under identical boundary conditions.

Therefore, this study aims to address these gaps by providing a controlled CFD-based analysis of airflow and $NO_2$ dispersion in residential areas of Almaty, focusing on the influence of building configuration under identical simulation conditions.

In this study, three residential configurations located at major traffic intersections in Almaty are selected as case studies. Three-dimensional geometries are reconstructed based on real urban layouts, and numerical simulations are performed using ANSYS Fluent.

The simulations are conducted under consistent inflow and emission conditions to focus on the impact of urban morphology. Airflow is modeled with the k--$ extomega$ SST turbulence model, and pollutant dispersion is simulated using the Species Transport method.

For each configuration, airflow patterns and $NO_2$ concentration fields are analyzed. A comparative assessment is performed based on velocity distribution, extent of low-velocity zones, and vertical profiles of pollutant concentration.

The obtained results are further used to evaluate the relationship between urban layout characteristics and ventilation efficiency, as well as their impact on pollutant dispersion within the urban canopy layer.

## Methods and Materials

The numerical analysis was conducted using the ANSYS CFD software, specifically with the ANSYS Fluent module. All results were analyzed after the flow achieved a quasi-steady state.

### *A. Numerical Setup*

Main simulation parameters, including inflow turbulence properties and pollutant emission settings, were adopted from [26], where they were validated against experimental and numerical data and subsequently used in additional urban dispersion research [27]. The

reliability and physical accuracy of the current simulations are ensured by employing these validated parameters.

Three residential building configurations located in close proximity at the intersection of two major traffic corridors in Almaty were selected and recreated as three-dimensional geometries for comparative purposes.

The primary goal was to simulate how pollution forms at street level and how it disperses in the urban environment. At the start, the computational domain was filled with still air without any pollutants (initial $NO_2$ mass fraction set to zero). These initial conditions were consistent across all simulation cases. The shared parameters used for these simulations are summarized below.

Table 1. Ansys Fluent general parameters

| | |
|---|---|
| Time marching | SIMPLE |
| Time discretization | Euler-Implicit |
| Space discretization | 2nd-order central difference |
| Inflow B.C. | Velocity: uniform velocity and random fluctuations of 4% (x) and 2% (y, z) of streamwise velocity; Concentration: constant (= 0.0) |
| Outflow B.C. | Gradient zero |
| Wall B.C. | Velocity: Spalding's law; Concentration: gradient-zero |
| Line source | Velocity: constant (= 1.923 × 10−2 m/s); Concentration: constant (= 1.0) |

To facilitate a fair and controlled comparison across configurations, the same computational settings were used for all simulations. The summary below covers the computational domain, mesh details, numerical schemes, and boundary conditions.

Table 2. Geometry parameters

| | |
|---|---|
| Domain type | 3D urban street canyon |
| Grid step size | $\Delta x_{\max} = 5\ m$<br>$\Delta x_{\min} = 1\ m$ |
| Mesh type | Unstructured |

The computational domain (Figure 1) was defined based on the characteristic building height H to ensure scalability and consistency across all cases. These dimensions were chosen to reduce boundary effects on the simulated flow field.

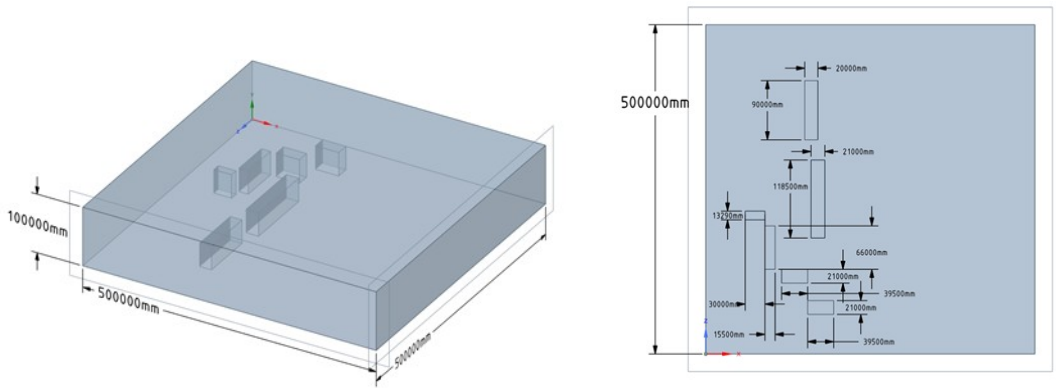



Figure 1. Computational domain

*B. Model equations*

For each residential setup, two numerical cases were considered: one featuring a nitrogen dioxide (NO2) emission source and one without any pollutant emissions. The scenario including emissions aimed to study pollutant dispersion patterns, while the emission-free scenario focused on airflow behavior within the residential space, particularly identifying air stagnation zones and enabling qualitative comparisons with earlier two-dimensional Python simulations.

The turbulence was simulated with the k-ω model, which uses two equations to solve for turbulent kinetic energy (k) and specific dissipation rate (ω). This approach is ideal for both free-stream turbulent flows and viscous-dominated flows, providing an accurate depiction of near-wall behavior.

The basic equations of the model are given by (1) and (2).

The equation for turbulence kinetic energy (k):

$$\frac{\partial k}{\partial t} + U_j \frac{\partial k}{\partial x_j} = P_k - \beta k\omega + \frac{\partial}{\partial x_j}\left[(v + \sigma_k^* v_t)\frac{\partial k}{\partial x_j}\right] \quad (1)$$

The equation for:

$$\frac{\partial \omega}{\partial t} + U_j \frac{\partial \omega}{\partial x_j} = \alpha \frac{\omega}{k} P_{\ k} - \beta\omega^2 + \frac{\partial}{\partial x_j}\left[(v + \sigma_\omega^* v_t)\frac{\partial \omega}{\partial x_j}\right] \quad (2)$$

where: $P_k$- generation of turbulent energy, $v_t$ - turbulent viscosity, $\alpha, \beta, \sigma_k^*, \sigma_\omega^*$ - empirical constants of the model.

The k–ω SST formulation was used to model the turbulence effects since it provides better accuracy in the near-wall region and reliable prediction of flow separation in the confined urban environment [19, 20]. This model is particularly suitable for simulating air flow around buildings with complex geometries.

The Species Transport model was employed in the simulation cases involving pollutant emissions to model NO2 dispersion within the airflow [21, 22]. This approach allows for accounting the transport and spatial distribution of pollutants in urban flow scenarios.

The basic transfer equation for the i-th chemical component in (3) is:

$$\frac{\partial}{\partial t}(\rho Y_i) + \nabla \bullet \left(\rho \vec{v} Y_i\right) = -\nabla \vec{J_1} + \ R_i S_i \quad (3)$$

where: $Y_i$- mass fraction of the ith component, $\vec{v}$- flow velocity vector, $\vec{J_1}$ - the diffusion flow of the component, $R_i$- chemical reaction rate (if reactions are enabled), $S_i$ - external source (if specified)

**Results and Discussion**

To evaluate the influence of urban morphology on airflow and pollutant dispersion, a comparative analysis of three residential configurations (RC-1, RC-2, and RC-3) was performed based on velocity fields and $NO_2$concentration distribution.

The 180-second mark was chosen for analysis because the flow is near a quasi-steady state by then. This state is marked by stabilized velocity fields and concentration distributions, with only slight changes occurring afterward.

The airflow structure within each configuration was first analyzed using velocity contours, as shown in Figure 2.

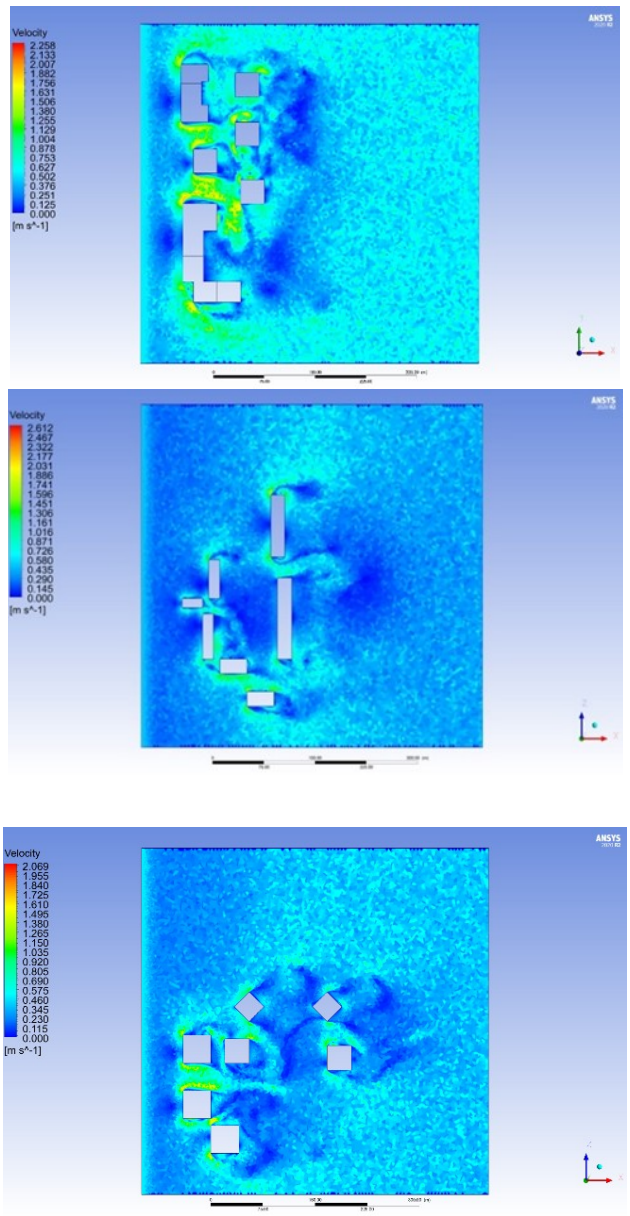
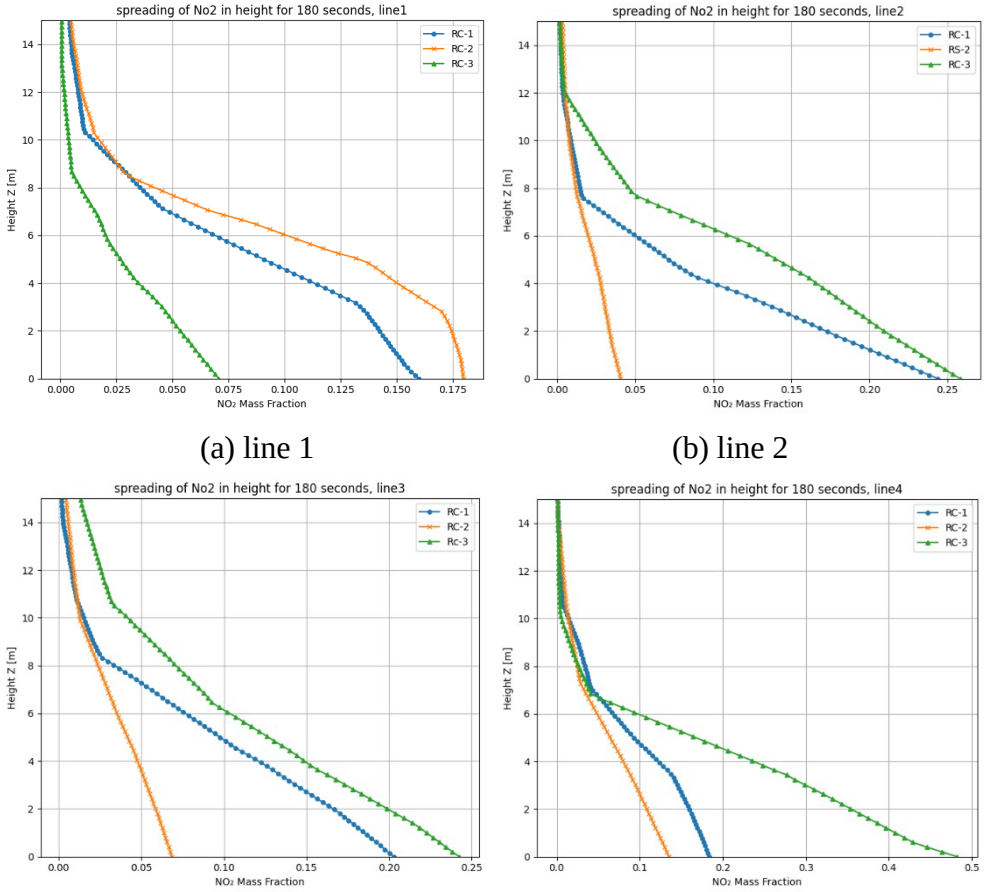



Figure 2. Velocity contours: a - RC-1, b - RC-2, c - RC-3

The results show that RC-2 offers a more even airflow distribution and better wind penetration within the urban layout. Conversely, RC-1 and RC-3 display significant low-velocity areas and recirculation zones around building clusters, which hinder air exchange and lead to pollutant buildup.

The smaller stagnation zones in RC-2 enhance ventilation, which in turn improves how pollutants disperse.

The vertical distribution of $NO_2$concentration along sampling lines is presented in Figure 3.




(a) line 1 (b) line 2

(c) line 3 (d) line 4

Figure 3. The vertical distribution of $NO_2$concentration: a – line 1, b – line 2, c – line 3, d – line 4

The profiles show that RC-2 generally has lower concentration levels across most of the vertical domain compared to RC-1 and RC-3. This suggests better pollutant removal and more efficient mixing of air within the urban canopy.

While sampling line positions may differ slightly because of geometric constraints, the general trends stay consistent, enabling dependable comparison between different configurations.

To give a more complete evaluation of ventilation effectiveness, two quantitative measures were examined: the average concentration at 180 seconds and the pollutant accumulation behavior from 60 to 180 seconds.

The average concentration was determined by calculating the mean of all sampling-line profiles at the chosen quasi-steady state. Additionally, the concentration increase over the simulation period was measured as follows:

$$\Delta C = C_{180} - C_{60} \quad (4)$$

where $C_{180}\ and\ C_{60}$denote the average $NO_2$concentration at 180 s and 60 s, respectively.

To characterize the rate of pollutant accumulation, the following metric was introduced:

$$R = \frac{C_{180} - C_{60}}{180-60} \quad (5)$$

where R represents the average accumulation rate of NO2 during the analyzed time interval. The results are summarized in Table 3.

Table 3. $NO_2$ concentration results

| **Residential Complex** | **Average $NO_2$ Concentration** | **Concentration Increase (ΔC)** | **Accumulation Rate ($s^{-1}$)** |
|---|---|---|---|
| RC-1 (Metropole) | 0.062 | 0.051 | $4.23 \times 10^{-4}$ |
| RC-2 (Central Avenue) | 0.032 | 0.033 | $2.76 \times 10^{-4}$ |
| RC-3 (Al Farabi) | 0.064 | 0.058 | $4.84 \times 10^{-4}$ |

The analysis shows notable differences in both concentration levels and how pollutants accumulate. RC-2 has the lowest average concentration and the smallest increase over time. Its accumulation rate is about 43% lower than in RC-1 and 57% lower than in RC-3.

These results show that RC-2 enhances pollutant removal and improves air exchange in the urban canopy layer. Meanwhile, RC-1 and RC-3 have higher accumulation rates, indicating less effective ventilation and a greater tendency for pollutants to be retained.

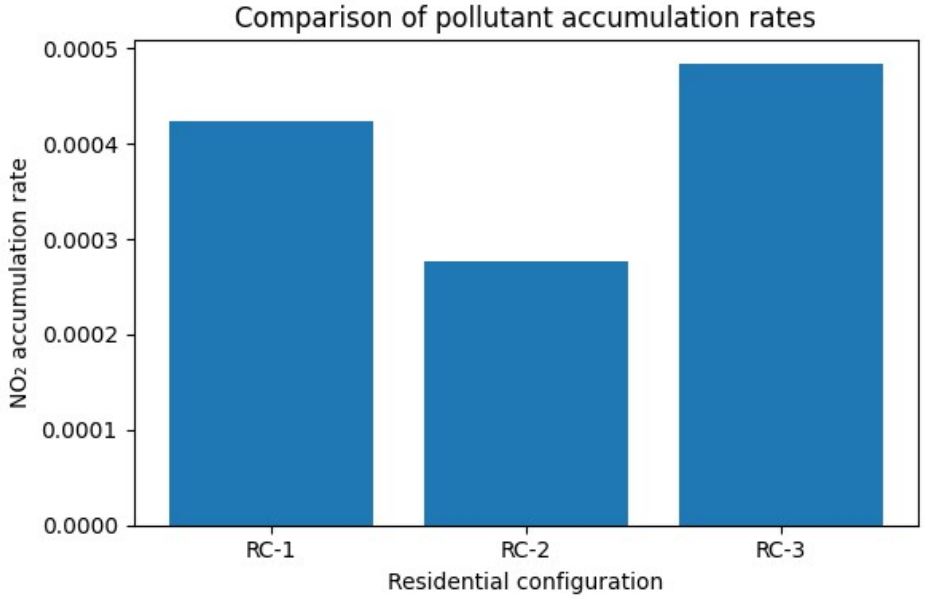



Figure 4. Comparison of $NO_2$accumulation rates for different residential configurations

The results support the hypothesis that urban layouts featuring greater spatial permeability and better building orientation concerning the prevailing wind lead to enhanced ventilation and lower pollutant buildup.

In particular, the RC-2 configuration, known for improved airflow continuity and fewer stagnation zones, shows the lowest concentrations. This reinforces the idea that increased permeability results in more effective pollutant removal.

The results also show that building orientation alone cannot guarantee optimal ventilation, as seen in RC-3, where local flow acceleration is insufficient to offset recirculation zones.

Overall, the results emphasize that the interaction between spatial permeability and urban design is crucial in shaping airflow patterns and air quality within neighborhoods.

## Conclusion

This study examined how urban morphology impacts airflow and dispersion in Almaty's residential zones, using three real residential setups under consistent boundary and emission conditions.

The findings show that urban layout greatly influences ventilation effectiveness and pollutant spread at the neighborhood level. Out of all the cases studied, the RC-2 setup performed

best, reducing average concentration by as much as 49% compared to the least effective, RC-3. The agreement between the concentration and accumulation analyses confirms that RC-2 offers the best ventilation among the configurations examined.

The results show that designs with higher spatial permeability and better airflow continuity decrease stagnation zones and improve pollutant removal. Conversely, compact layouts or those with ongoing recirculation areas often lead to pollutant buildup and less effective ventilation.

Simultaneously, the findings indicate that individual geometric factors like building orientation alone do not ensure optimal ventilation, emphasizing the need to account for the combined influence of urban layout features.

Overall, the study offers quantitative proof of how urban morphology influences air quality, showing that even in comparable city environments, variations in building layouts can significantly affect pollutant dispersion.

The results can aid in developing urban planning and design strategies to enhance natural ventilation and lower air pollution in densely built cities like Almaty. Future efforts will include integrating real traffic data, considering more pollutant types, and validating results with field measurements to improve the reliability of the findings.

Despite these findings, the study has notable limitations. The simulations rely on idealized boundary conditions and simplified emission models, without direct validation from field data. Additionally, the analysis focuses on only one pollutant ($NO_2$) and a specific urban setup. These factors could affect the applicability of the results to other contexts.

**Acknowledgment**

This research has been funded by the Committee of Science of the Ministry of Science and Higher Education of the Republic of Kazakhstan (Grant No.BR24992852 "Intelligent models and methods of Smart City digital ecosystem for sustainable development and the citizens' quality of life improvement")

## References

[1] IQAir. (2025). World air quality ranking. Retrieved March 4, 2026, from https://www.iqair.com/world-air-quality-ranking

[2] Zhang, Y., Kwok, K. C. S., Liu, X., & Niu, J. (2020). Impact of building morphology on urban ventilation and pollutant dispersion. Building and Environment, 181, 107120.

[3] Hang, J., Luo, Z., Sandberg, M., & Gong, J. (2020). Natural ventilation assessment in high-density urban areas. Building and Environment, 171, 106651.

[4] Zhou, X., Li, Y., & Wang, Z. (2022). Influence of urban geometry on airflow and pollutant dispersion. Building and Environment, 207, 108415.

[5] Li, X., & Britter, R. (2022). Urban ventilation and air quality in complex terrain cities. Atmospheric Environment, 268, 118785.

[6] Blocken, B. (2021). Computational fluid dynamics for urban physics: Achievements and challenges. Journal of Wind Engineering and Industrial Aerodynamics, 214, 104658.

[7] Tominaga, Y., & Stathopoulos, T. (2020). CFD simulation of near-field pollutant dispersion in urban environments: A review. Atmospheric Environment, 225, 117356.

[8] Oke, T. R., Mills, G., Christen, A., & Voogt, J. A. (2021). Urban climates. Cambridge University Press.

[9] Liu, H., Zhang, Y., & Li, X. (2021). Effects of building arrangement on pollutant dispersion. Building and Environment, 196, 107789.

[10] Gu, Z., Liu, X., & Wang, Y. (2022). Impact of building density on ventilation efficiency. Building and Environment, 210, 108700.

[11] Peng, Z., Wang, Y., & Li, H. (2022). Urban ventilation performance under different building configurations. Urban Climate, 41, 101056.

[12] Salim, S. M., Buccolieri, R., Chan, A., & Di Sabatino, S. (2020). Numerical simulation of atmospheric pollutant dispersion in urban street canyon. Building and Environment, 174, 106777.

[13] Jiang, Y., Wang, X., & Li, Z. (2022). Urban airflow simulation using RANS models. Journal of Wind Engineering, 220, 104846.

[14] Menter, F. R. (1994). Two-equation eddy-viscosity turbulence models for engineering applications. AIAA Journal, 32(8), 1598–1605.

[15] Gimenez, J. M., & Bre, F. (2023). Enhanced k-omega SST model for airflow around buildings. Building and Environment, 237, 110321.

[16] He, L., Zhang, X., Wang, Y., & Li, Z. (2021). CFD simulation of pollutant dispersion in urban street canyons. Atmospheric Environment, 253, 118371.

[17] Wang, Y., Liu, H., & Chen, X. (2023). Urban airflow and pollutant dispersion modeling using CFD. Sustainable Cities and Society, 89, 104332.

[18] Ren, C., Zhang, X., & Li, Y. (2023). Urban morphology and air pollution dispersion: CFD study. Atmospheric Environment, 295, 119527.

[19] Sun, J., Zhang, X., & Liu, Y. (2023). CFD analysis of urban air pollution under different layouts. Science of the Total Environment, 857, 159419.

[20] Zhao, B., Li, X., & Wang, Y. (2021). Numerical study of airflow and pollutant transport in urban areas. Environmental Pollution, 268, 115911.

[21] Yedilkhan, M., Nurpeiisov, A., & Tolegenova, A. (2025). Air quality prediction using LSTM with attention in Almaty. Journal of Problems in Computer Science, 3(1), 3–12.

[22] Xing, Y., & Brimblecombe, P. (2021). Role of traffic emissions in urban air pollution. Atmospheric Environment, 246, 118126.

[23] Chen, J., & Hoek, G. (2020). Long-term exposure to nitrogen dioxide and mortality. Environmental Health Perspectives, 128(4), 047003.

[24] Khomenko, S., Cirach, M., Pereira-Barboza, E., Mueller, N., Barrera-Gomez, J., Rojas-Rueda, D., de Hoogh, K., Hoek, G., & Nieuwenhuijsen, M. (2021). Premature mortality due to air pollution in European cities. The Lancet Planetary Health, 5(3), e121–e134.

[25] Abhijith, K. V., Kumar, P., Gallagher, J., McNabola, A., Baldauf, R., Pilla, F., Broderick, B., Di Sabatino, S., & Pulvirenti, B. (2017). Air pollution abatement performances of green infrastructure in open road and built-up street canyon environments. Atmospheric Environment, 162, 71–86.

[26] Kikumoto, H., & Ooka, R. (2012). Large-eddy simulation of pollutant dispersion in urban environments. Journal of Wind Engineering and Industrial Aerodynamics, 104, 273–284.

# ANALYSIS OF THE ANALYTICAL AND PINN-BASED SOLUTION OF A PHARMACOKINETICS PROBLEM

**Sagimbayeva L.A., Kassenov S.E., Tugenbayeva Zh.S.**
e-mail: Sagymbaeva.lida@gmail.com
*Faculty of Mechanics and Mathematics*
*Al-Farabi Kazakh National University, Almaty, Kazakhstan*

***Abstract***

*This article examines a three-compartment linear pharmacokinetic model that describes the distribution of a drug in an organism divided into three components. The mathematical model is represented by a system of ordinary differential equations, where each equation characterizes the change in the amount of the drug in the corresponding compartment, as well as its adsorption and elimination processes. The use of the Laplace transform method allows for an analytical solution of this system, obtaining explicit expressions for the time dependence of concentrations and studying the influence of various model parameters. In addition, the analytical solution is compared with a modern machine-learning approach based on neural networks - physics-informed neural networks (PINN).*

***Keywords:*** *computational mathematics, pharmacokinetics, ordinary differential equations (ODE), Laplace transform, neural networks.*

Pharmacokinetics is a branch of pharmacology that studies the dynamics of a drug's absorption, distribution, metabolism, and elimination in an organism. Pharmacology, in turn, studies drugs, their chemical structure, mechanism of action, and effect on the body. Studying pharmacokinetic processes allows a deeper understanding of how drugs interact with the body and helps optimize dosing regimens for maximum therapeutic effect. The goal of this article is to give a detailed analysis of a three-compartment pharmacokinetic model: to describe the system of differential equations underlying the model and justify the three-compartment approach; to obtain an analytical solution using the Laplace transform; to analyze how the adsorption, distribution and elimination coefficients affect the concentration dynamics; and to apply a neural-network-based approach (PINN) and compare it with the analytical result.

The differential equations describing the dynamics of drug amounts in the three-compartment linear model are as follows:

$$\frac{dm_a}{dt} = -k_a m_a \tag{1}$$

$$\frac{dm_1}{dt} = k_a m_a - (k_{12} + k_{13} + k_{el})\, m_1 + k_{21} m_2 + k_{31} m_3 \tag{2}$$

$$\frac{dm_2}{dt} = k_{12} m_1 - k_{21} m_2 \tag{3}$$

$$\frac{dm_3}{dt} = k_{13} m_1 - k_{31} m_3 \tag{4}$$

$$\frac{dm_{el}}{dt} = k_{el} m_1 \tag{5}$$

Initial conditions:

$$m_a(0) = m_0, m_1(0) = m_2(0) = m_3(0) = m_{el}(0) = 0 \tag{6}$$

Problem (1)-(6) describes the process of drug distribution in the organism, which is divided into three compartments. The central compartment (V1) includes the heart and circulatory system, where the drug concentration is considered uniform. The second compartment represents organs with high blood supply (liver, kidneys, lungs). The third compartment covers tissues with low blood supply (fatty tissue, bones, muscles, etc.). Let m0 be the amount of drug at the injection site, and $m_1$, $m_2$, $m_3$, $m_{el}$ its amounts in compartments 1, 2, 3, and “eliminated”, respectively. Then the concentrations are computed as $C_a(t) = \frac{m_a(t)}{V_1}$, $\frac{C_1(t)=m_1(t)}{V_1}$, $C_2(t) = \frac{m_2(t)}{V_1}$, $C_3(t) = \frac{m_3(t)}{V_1}$, $C_{el}(t) = \frac{m_{el}(t)}{V_1}$.

Here ka is the rate constant of drug adsorption at the injection site; $k_{12}$ and $k_{21}$ are the rate constants of drug transfer from compartment 1 to compartment 2 and back, respectively; $k_{13}$and $k_{31}$ are the rate constants of drug transfer from compartment 1 to compartment 3 and back, respectively; kel is the rate constant of drug elimination from compartment 1.

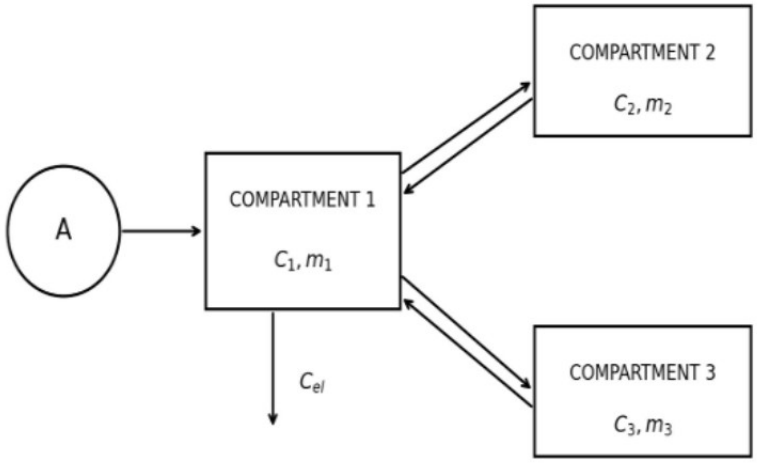



*Figure 1. Diagram of the three-compartment model with extravascular drug administration*

Dividing the equations of system (1)-(6) and the initial data by the corresponding volumes yields the system of differential equations for concentrations:

$$\frac{dC_a}{dt} = -k_a C_a \tag{7}$$

$$\frac{dC_1}{dt} = k_a C_a - (k_{12} + k_{13} + k_{el}) C_1 + k_{21} C_2 + k_{31} C_3 \tag{8}$$

$$\frac{dC_2}{dt} = k_{12} C_1 - k_{21} C_2 \tag{9}$$

$$\frac{dC_3}{dt} = k_{13} C_1 - k_{31} C_3 \tag{10}$$

$$\frac{dC_{el}}{dt} = k_{el} C_1 \tag{11}$$

Initial conditions:

$$C_a(0) = C_0, C_1(0) = C_2(0) = C_3(0) = C_{el}(0) = 0 \tag{12}$$

The Laplace transform is used to solve system (7)-(11) with initial conditions (12). Denoting the Laplace image of a function $C(t)$ by $\overline{C}(p)$, and using $C_a'(t) \doteq p \bullet \overline{C_a}(p) - C_0$, substitution into (7)-(11) and elimination of the intermediate images gives:

$$\overline{C_1}(p) = \frac{C_0 \cdot k_a \cdot (p+k_{21}) \cdot (p+k_{31})}{(p+k_a)(p+\alpha)(p+\beta)(p+\gamma)} = \frac{A_1}{p+\alpha} + \frac{A_2}{p+\beta} + \frac{A_3}{p+\gamma} + \frac{A_4}{p+k_a} \tag{13}$$

where $\alpha$, $\beta$, $\gamma$ satisfy $\alpha + \beta + \gamma = k_{12} + k_{13} + k_{21} + k_{31} + k_{el}$, $\alpha\beta + \alpha\gamma + \beta\gamma = k_{12}k_{31} + k_{13}k_{21} + k_{21}k_{31} + k_{21}k_{el} + k_{31}k_{el}$, and $\alpha\beta\gamma = k_{21}k_{31}k_{el}$; and the coefficients are:

$$A_1 = \frac{C_0 \cdot k_a \cdot (k_{21} - \alpha)(k_{31} - \alpha)}{(k_a - \alpha)(\beta - \alpha)(\gamma - \alpha)}$$

$$A_2 = \frac{C_0 \cdot k_a \cdot (k_{21} - \beta)(k_{31} - \beta)}{(k_a - \beta)(\alpha - \beta)(\gamma - \beta)}$$

$$A_3 = \frac{C_0 \cdot k_a \cdot (k_{21} - \gamma)(k_{31} - \gamma)}{(k_a - \gamma)(\alpha - \gamma)(\beta - \gamma)}$$

$$A_4 = -(A_1 + A_2 + A_3)$$

Transforming back to the time domain gives the final analytical solution:

$$C_a(t) = C_0 \cdot e^{-k_a t} \tag{14}$$

$$C_1(t) = A_1 e^{-\alpha t} + A_2 e^{-\beta t} + A_3 e^{-\gamma t} - (A_1 + A_2 + A_3)\, e^{-k_a t} \tag{15}$$

The functions $C_2(t)$, $C_3(t)$ and $C_{el}(t)$ are then obtained from the earlier relations using $C_1(t)$. While this analytical solution is exact, it requires deep domain knowledge to interpret and becomes difficult to apply to more complex problems because of its high computational cost.

To address this, a physics-informed neural network (PINN) is applied. The neural network approximates the solution of the ODE system for the concentrations in the central and peripheral compartments: $\hat{y} = [\widehat{C_1}(t;\theta),\ \widehat{C_2}(t;\theta), \widehat{C_3}(t;\theta), \widehat{C_{el}}(t;\theta)]$, where $\theta$ denotes the network's parameters (weights and biases), the input is time t, and the activation function is tanh. The architecture is a fully connected network (FNN) with 1 input, 3 hidden layers of 40 neurons each, and 4 outputs, corresponding to $C_1(t)$, $C_2(t)$, $C_3(t)$, $C_{el}(t)$. DeepXDE is used for automatic differentiation to compute the derivatives of the network's outputs with respect to t, which is needed to verify that the approximated solution satisfies the ODE system.

To ensure the network satisfies both the ODE system and the initial conditions, the loss function is composed of two terms. The first is the ODE loss, defined as the mean squared residual of the governing equations evaluated at collocation points in the time domain:

$$L_{ODE}(\theta) = \frac{1}{N_r} \sum_{i=1}^{N_r} \|N(t_i;\theta)\|^2 \tag{16}$$

where N(ti;θ) is the vector of residuals of the equations governing $C_1(t)$, $C_2(t)$, $C_3(t)$, $C_{el}(t)$. The second term is the initial-condition loss:

$$L_{IC}(\theta) = \frac{1}{N_{IC}} \sum_{i=1}^{N_{IC}} \|y\hat{}(0;\theta)\ -\ y(0)\|^2 \tag{17}$$

The neural network approximates the pharmacokinetic model's solution: given input time t, it outputs approximate drug concentrations in the central and peripheral compartments. Automatic differentiation computes the derivatives of these approximations, used to form the ODE residuals. The combined loss (ODE + initial conditions) is minimized by an optimizer, training the network to produce a smooth solution consistent with the model's physical laws.

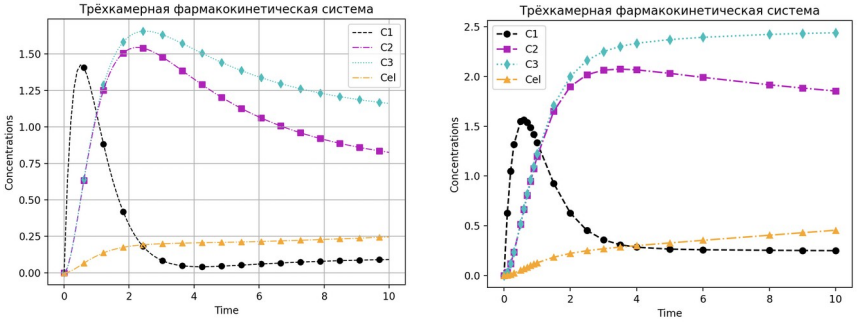



*Figure 2. Plots of $C_1(t)$, $C_2(t)$, $C_3(t)$, $C_{el}(t)$ for the analytical solution and the PINN solution*

The comparison between the neural-network result and the analytical solution shows a high degree of agreement. The analytical solution provides exact values, but its application to more complex problems is significantly hindered by high computational complexity and time cost. In contrast, using neural networks substantially accelerates computation and improves modeling efficiency; the neural-network approach therefore represents a more optimal strategy for pharmacokinetic analysis, balancing accuracy and computational efficiency. A difference is nevertheless observed between the neural-network result and the analytical solution, indicating a need for further analysis and refinement of the computational methods. The observed deviations in the neural-network method may be due to insufficient input data; alternative approaches based on solving inverse problems will therefore be considered in future work to reduce these errors and improve the reliability of the results.

## REFERENCES

1. Urmashev, B.A., Tursynbay, A.T., Temirbekov, A.N., Amantayeva, A.B. Solving the reverse problems of pharmacokinetics for a linear two-compartment model with absorption // The IEEE 12th International Conference Application of Information and Communication Technologies. – Almaty, Kazakhstan, 2018, 17-19 October. – P. 33-39.

2. Bektemessov, Z., Cherfils, L., Allery, C., Berger, J., Serafini, E., Dondossola, E., Casarin, S. On a data-driven mathematical model for prostate cancer bone metastasis // AIMS Mathematics. – 2024. – Vol. 9, N 12. – P. 34785-34805.

3. Kasenov, S.E., Urmashev, B.A., Tursynbay, A.T., Temirbekov, A.N., Amantayeva, A.B., Sagimbayeva, L.A. Solving the inverse problem of pharmacokinetics for a three-compartment model // Vestnik KazNITU. – 2020. – N 2(138). – P. 708-715.

4. Kabanikhin, S.I. Inverse and ill-posed problems. – Novosibirsk: Siberian Scientific Publishing House, 2008. – 460 p.

5. Kabanikhin, S.I., Bektemesov, M.A., Nurseitova, A.T. Iterative methods for solving inverse and ill-posed problems with data on part of the boundary. – Almaty-Novosibirsk: International Foundation of Inverse Problems, 2006. – 394 p.

6. Kozlov, V.A., Mazya, V.G., Fomin, A.V. On one iterative method for solving the Cauchy problem for elliptic equations // Journal of Computational Mathematics and Mathematical Physics. – 1991. – Vol. 31, N 1. – P. 64-73.

7. Kabanikhin, S.I., Karchevsky, A.L. Optimizational method for solving the Cauchy problem for an elliptic equation // Journal of Inverse and Ill-posed Problems. – 1995. – Vol. 3, N 1. – P. 21-46. https://doi.org/10.1515/jiip.1995.3.1.21

8. Marchuk, G.I. Mathematical modeling in environmental problems. – Moscow: Nauka, 1982. – 320 p.

# A MODEL AND NUMERICAL SOLUTION ALGORITHM FOR GROUNDWATER FILTRATION PROBLEM IN A THREE-LAYER POROUS MEDIUM INTERCONNECTED WITH A LOW-PERMEABILITY LAYER

**Yuldashov Sh.N.[1], Nazirova.E.Sh.[2]**
e-mail: shavkatbek28.12@gmail.com
[1]*The National Pedagogical University of Uzbekistan named after Nizami, Uzbekistan*
[2]*Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan*

***Abstract.*** *This article presents a mathematical model and a numerical solution algorithm for solving problems of unsteady groundwater and pressure water filtration in a three-layer porous medium. During the research, a specific mathematical model was developed for a three-layer medium comprising a well-conductive artesian aquifer, a watertight artesian layer, and a phreatic aquifer. It is expressed as a quasi-linear system of parabolic partial differential equations and was implemented through numerical calculation algorithms and computer programming. The results of the computational experiments show that the proposed numerical model and algorithm allow for the high-accuracy prediction of groundwater and artesian water flow in a three-layer porous medium.*

***Keywords:*** *unsteady groundwater flow, unconfined aquifer, confined aquifers, three-layer aquifer system, interlayer leakage, Thomas algorithm.*

We consider the unsteady movement of groundwater in a three-layer, heterogeneous formation. This layer comprises a well-permeable confined aquifer, an impermeable confined layer beneath it, and a poorly permeable upper layer containing groundwater.

The filtration process under consideration is described by the following quasilinear system of parabolic partial differential equations:

$$\begin{cases} \dfrac{\partial H}{\partial t} = \dfrac{\mu}{\mu_b T_x}\dfrac{\partial}{\partial x}\left[K_b H \dfrac{\partial H}{\partial x}\right] - \dfrac{\mu}{\mu_b}K_b\left(1 - \dfrac{h_1}{H}\right) + \dfrac{\mu}{\mu_b}(f - w) \\ \dfrac{\partial h_1}{\partial t} = \dfrac{\partial}{\partial x}\left[T_1 \dfrac{\partial h_1}{\partial x}\right] + K_b\left(1 - \dfrac{h_1}{H}\right) - \dfrac{K_\Pi}{m_\Pi}(h_2 - h_1) - Q \\ \dfrac{\partial h_2}{\partial t} = \dfrac{\partial}{\partial x}\left[T_2 \dfrac{\partial h_2}{\partial x}\right] + \dfrac{K_\Pi}{m_\Pi}(h_2 - h_1), \quad 0 < x < L, \quad t > 0. \end{cases} \tag{1}$$

with boundary conditions

$$H(x,t_0) = F_1(x); \quad h_1(x,t_0) = F_2(x); \qquad h_2(x,t_0) = F_3(x); \tag{2}$$

$$-k\frac{\partial H}{\partial x} = \eta\alpha(H_A - H), \; x = 0; \quad k\frac{\partial H}{\partial x} = \eta\alpha(H_A - H), \; x = L \tag{3}$$

$$-k\frac{\partial h_1}{\partial x} = \eta\alpha(h_A - h_1), \; x = 0; \qquad k\frac{\partial h_1}{\partial x} = \eta\alpha(h_A - h_1), \quad x = L \tag{4}$$

$$-k\frac{\partial h_2}{\partial x} = \eta\alpha(h_A - h_2), \; x = 0; \qquad k\frac{\partial h_2}{\partial x} = \eta\alpha(h_A - h_2), \quad x = L \tag{5}$$

Here $H = (x,t)$ – the depth from the main aquifer to the free surface of the groundwater; $h_1 = (x,t), \; h_2 = (x,t)$ – pressures of the main layer; $K_b(x)$ – filtration coefficient of the cover

layer; $T_1 = k_1 m_1,\ T_2 = k_2 m_2$ – transmissivity coefficients of the pressure layer; $m(x)$, $K(x)$, $\mu$ – the capacity of the main horizon, filtration coefficients and elastic water yield coefficients; $\mu_b$ – water permeability coefficient of the cover layer; $f(x,t)$ – infiltration function; $w(x,t)$ – evaporation.

We transform the variables in (1) and in the boundary conditions (2)–(5) into dimensionless form.

$$H^* = \frac{H}{H_x};\ \ h_1^* = \frac{h_1}{h_x};\ \ h_2^* = \frac{h_2}{h_x};\ \ h_\Pi^* = \frac{h_\Pi}{h_x};\ K_b^* = \frac{K_b}{K_x};\ K_\Pi^* = \frac{K_\Pi}{K_x};$$

$$k_1 m_1^* = \frac{km}{k_x m_x};\ \ k_2 m_2^* = \frac{km}{k_x m_x};\ \ \tau = \frac{T_x t}{\mu L^2};\ \ x^* = \frac{x}{L};\ \ \eta^* = \frac{K_x h_x}{L}\eta.$$

Here $K_x, H_x, T_x$ – Some characteristic values corresponding to the function.

For simplicity, by dropping the asterisks on the dimensionless variables, we obtain the following system of dimensionless differential equations:

$$\begin{cases} \dfrac{\partial H}{\partial \tau} = \dfrac{K_x \mu H_x}{\mu T_x}\dfrac{\partial}{\partial x}\left[K_b H \dfrac{\partial H}{\partial x}\right] - \dfrac{K_x \mu L^2}{\mu_b T_x H_x} K_b\left(1 - \dfrac{h_1}{H}\right) + \dfrac{\mu L^2}{\mu_b T_x H_x}(f - w) \\ \dfrac{\partial h_1}{\partial \tau} = \dfrac{\partial}{\partial x}\left[T_1 \dfrac{\partial h_1}{\partial x}\right] + \dfrac{K_x L^2}{T_x H_x} K_b\left(1 - \dfrac{h_1}{H}\right) - \dfrac{K_x L^2}{T_x H_x}\dfrac{K_\Pi}{h_\Pi}(h_2 - h_1) - \dfrac{K_x L^2}{T_x H_x} Q \\ \dfrac{\partial h_2}{\partial \tau} = \dfrac{\partial}{\partial x}\left[T_2 \dfrac{\partial h_2}{\partial x}\right] + \dfrac{K_x L^2}{T_x H_x}\dfrac{K_\Pi}{h_\Pi}(h_2 - h_1) \end{cases} \tag{6}$$

The dimensionless problem (6) is solved by the finite-difference method with the boundary conditions (2) – (5).

The movement of groundwater in a porous medium is, in general, a three-dimensional process, with the pressure field varying in all directions through space. However, the geometric characteristics of real strata – their vertical thickness being significantly smaller than their horizontal extent – allow the flow to be regarded as nearly horizontal [6; pp. 25-26].

Numerical solution algorithm. The machine algorithm consists of the following steps:

1. The values of the parameters in the system of equations and the initial groundwater level $H_i^0$ and $h_{1i}^0, h_{2i}^0\ \ (i = 1,2,...,N)$ input the head of the pressurised waters.
2. Determine the initial values of the friction coefficients $\alpha_0, \beta_0,\ \ \alpha_0', \beta_0',\ \ \alpha_0'', \beta_0''$ from the boundary conditions.
3. Calculating the values of the parameters and solving the three diagonal finite-difference equations for $A_i, B_i, C_i, F_i,\ A_i', B_i', C_i', F_i',\ A_i'', B_i'', C_i'', F_i''$.
4. Calculating the values of the Thomas method coefficients. $\alpha_i, \beta_i,\ \alpha_i', \beta_i',\ \alpha_i'', \beta_i''\ \ (i = 1,2,...,N-1)$
5. Calculating the function value on the left boundary: $H_{1n}, h_{1n}, h_{2n}.$
6. Calculating the function value: $H_i, h_{1i}, h_{2i}.\ \ (i = 0,1,2,...,N)$

7. Output function values in tabular and graphical form: $H_i, h_{1i}, h_{2i}.$ $(i = 0,1,2,...,N)$
8. Moving to the next time layer. At the same time, the solution obtained is used as the initial value for the next time step.
9. Steps 2 to 8 of the algorithm are repeated at each time step.
10. Finish solving the problem.

## CONCLUSION

Using a software package based on a mathematical model and a computational algorithm, various hydrogeological and land reclamation forecasting problems are solved for two- and three-layer models of aquifers, taking into account all natural and artificial factors that influence the filtration process of groundwater and artesian water.

## REFERENCES

1. *Abutaliev, F.B.* Solving Problems of Transient Filtration: Numerical and Analytical Methods. Fan Publishing House, Tashkent, 1972. p.
2. *Abutaliev, F.B.* et al. Effective Approximate-Analytical Methods for Solving Problems in Filtration Theory. Published by Fan, Tashkent, 1978.
3. *Abutaliev, F.B., Khadzhibayev, N.N., Izmaylov, I.I., Umarov, U.* The application of numerical methods and computers in hydrogeology. – Tashkent: Fan, 1976. – 160 pp.
4. *Abutaliev, F. B., Abutaliev, E. B., Baklushin, M. B.* 'On the operation of vertical drainage wells in layered soils of limited extent', in the collection *Application of Mathematical Methods in Hydrogeological and Engineering-Geological Investigations*, Issue 34, Moscow, VSEGINGEO Publishing House, 1970.
5. *Abutaliev, F. B.* Some analytical and numerical methods for solving problems of unsteady flow in single-layer and multi-layer formations// PhD thesis, 1969, pp. 2–20.
6. *Bear, J.* Hydraulics of Groundwater / *J. Bear.* – New York: McGraw-Hill, 1979. – 567 p.

# LINGUISTIC AND MATHEMATICAL MODELS FOR IDENTIFYING AND CORRECTING PUNCTUATION ERRORS IN UZBEK INTERROGATIVE SENTENCES

Boymurodov F.F.[1], Nazirova.E.Sh.[2], Eshkaraeva N.G.[3], Xujamurotova M.G.[4]
e-mail: farruxboymurodov96@gmail.com
[2]*Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan*
[1,3,4]*Karshi State University, Uzbekistan*

***Аннотация.*** *This article presents the development of linguo-mathematical models aimed at identifying and correcting punctuation errors in Uzbek interrogative sentences. The analysis primarily focuses on instances of the incorrect use of the question mark (?), either at the end of a sentence or within the context. During the research, specialized linguo-mathematical models were created for both simple and complex interrogative sentences. These models were implemented through algorithms based on morphological analysis, rule-based checks, and punctuation norms, utilizing the UZMORF software suite. The software determines the necessity of a question mark by considering the intonational and grammatical features of the sentence. Experimental results demonstrate that the developed model enables the high-precision detection and correction of punctuation errors in Uzbek interrogative sentences.*

***Keywords:*** *linguistic-mathematical model, punctuation, spelling errors, UZMORF, morphological analysis, syntactic analysis.*

Currently, issues of natural language processing (NLP) are developing rapidly in the field of linguistics and information technology. Automatic analysis of the morphological, syntactic, and semantic aspects of the text serves to qualitatively improve human-computer interaction. Specifically, research by Fatma Howedi and Souad Alharm examined n-gram models of punctuation marks in determining authorship for short Arabic texts [1].

The first scientific research on computer linguistics in Uzbekistan dates back to the 1990s. A.K.Pulatov developed software tools for analyzing and synthesizing verb forms in the Uzbek language, comparing them with their equivalents in Russian and English, based on parts of speech, and these works became the foundation for automatic analysis and correction research in the subsequent language [2; 48-52).

Also, in the works of M.Kh.Khakimov, work was carried out on the formalization of natural languages, modeling syntactic and semantic connections, and creating linguistic and logical models for multilingual machine translation systems. These approaches serve as a theoretical basis for contextual analysis and integration of language models in identifying punctuation errors in the Uzbek language [3; P. 180-190].

This article highlights the issue of identifying and correcting punctuation errors in Uzbek interrogative sentences based on the above-mentioned relevance and analysis.

In the Uzbek language, simple and complex sentences are formed from sequences involving subject, predicate, attribute, object, case, punctuation marks, and suffixes. To identify and edit punctuation errors in sentences, we introduce the following designations as a set of the above cases [4; pp. 63-66]:

$$\lambda_i = (\lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5, \lambda_6, \lambda_7, \lambda_8, \lambda_9, \lambda_{10}, \lambda_{11}, \lambda_{12}, \lambda_{13}).$$

where $\lambda_{\lambda(i)}$ - respectively the following existing punctuation punctuation marks in the Uzbek language:

$$\lambda_i = (.,\ ,,\ ?,\ !,\ \_,\ ’,\ ‘,\ "",\ -,\ (),\ :,\ ;,\ ...).$$

Below, based on the above designations, a linguistic-mathematical model has been developed for interrogative sentences that determine punctuation from a given text in the Uzbek language.

Linguistic-mathematical model of a simple interrogative sentence

$$G_{w_s} = \oplus\downarrow \sum_{s=1}^{N} S_s \vee \sum_{t=1}^{y} T(t_t) \vee \sum_{i=1}^{n} E(e_i) \oplus\downarrow \lambda_2 \oplus \lambda_5 \oplus\downarrow \sum_{k=1}^{o} K(k_k) \oplus\downarrow \tilde{p}_t \oplus \lambda_3.$$

Linguistic-mathematical model of a complex interrogative sentence

$$G^{?}_{mur} = \oplus\downarrow \sum_{s=1}^{z} S_s + \lambda_{\lambda(5)} \oplus\downarrow \sum_{s=1}^{z} S_s \vee \sum_{i=1}^{n} E(e_i) * (\oplus\downarrow \lambda_{\lambda(2)}) + \lambda_{\lambda(5)} \oplus\downarrow \sum_{s=1}^{z} S_s \vee \sum_{t=1}^{y} T(t_t) * (\oplus\downarrow \lambda_{\lambda(2)}) +$$

$$+ \lambda_{\lambda(5)} \oplus\downarrow \sum_{s=1}^{z} S_s \vee \sum_{h=1}^{r} H(h_h) * (\oplus\downarrow \lambda_{\lambda(2)}) + \lambda_{\lambda(5)} \oplus\downarrow \sum_{s=1}^{z} S_s \vee \sum_{i=1}^{s} A(a_i) * (\oplus\downarrow \lambda_{\lambda(2)}) + \lambda_{\lambda(5)} \oplus\downarrow \sum_{k=1}^{o} K(k_k) \oplus\downarrow$$

$$\oplus\downarrow \tilde{p} + \lambda_{\lambda(3)}.$$

Here $\lambda_1$ – period (.) punctuation mark; $\lambda_2$ – comma (,) punctuation mark; $\lambda_3$ – interrogative (?) punctuation mark; $\lambda_4$ – exclamation (!) punctuation mark; $\lambda_5$ – interval (_) punctuation mark; $a_j$ – word-forming affixes; $f_k$ – form-forming affixes; $p_r$ – word-changing affixes; interrogative particles; $S_s$ – interrogative pronouns; $U_u$ - key words of interjection; $B_b$ - connecting words; $B_z$ – exclusive connecting words; $\oplus$ – conjunction; $\downarrow$ – connection; $\vee$ – logical disjunction (or).

Interrogative sentences: If a sentence contains the interrogative pronouns particuli $\tilde{p}$ or $S_{s(i)}$, and it can be said in an interrogative tone according to the content of the sentence, it is necessary to check whether the sentence ends with an interrogative sign (?).

$$S_s = \{ S_1, S_2, S_3, S_4, S_5, S_6, S_7, ...., S_s \}.$$

Based on these vectors, 12 cases in a simple interrogative sentence and 76 cases in a simple expanded interrogative sentence were modeled in the structural cases of Uzbek interrogative sentences.

## CONCLUSION

The study developed a linguistic and mathematical model aimed at identifying and editing punctuation errors found in Uzbek interrogative sentences. The model determines the correct use of the question mark, taking into account morphological, grammatical, and intonational features. As a result of experiments conducted using the UZMORF software package, it was confirmed that the approach developed is effective in automating punctuation processes in interrogative sentences.

## REFERENCES

1. Howedi F., Alharm S. Punctuation Marks Effect on Arabic Authorship Attribution Using a Variable Length of Character N-grams //African Journal of Advanced Pure and Applied Sciences (AJAPAS). – 2023. – С. 352-359.

2. Pulatov A.K., Alixodjayev B., Djurayeva N. Razrabotka programmi kompyuternogo analiza i sinteza glagolov uzbekskogo yazika // O‘zMU xabarlari. – Tashkent, 2002. – № 2. – S. 17-19.

3. Xakimov M.X. Matematicheskiye modeli angliyskogo yazika dlya sistemi mnogoyazichnix situatsiy mashinnogo perevoda. // V Mejdunarodnaya konferensiya po kompyuternoy obrabotke tyurkskix yazikov «TurkLang 2017». Trudi konferensii. Tom 1. – Kazan, 2017. S. 222-232.

4. Abidova Sh.B. Turkiy tillar uchun elektron tarjimaning modellari va algoritmlari (o‘zbek tilidan qoraqalpoq tiliga tarjima misolida). Texnika fanlari bo‘yicha falsafa doktori (PhD) – diss – Toshkent – 2021.

5. Nazirova, E. S., Abidova, S. B., Xolmuminov, Y. X., Boymurodov, F. F., Medetbayeva, N. B., & Usmonova, K. A. Mathematical Model and Algorithm for Grammatical Editing of Given Words in Uzbek Language //International Seminar on Mathematics in Industry. – Cham : Springer Nature Switzerland, 2024. – С. 175-182.

6. Boymurodov F. Microsoft word uchun o ‘zbek tili so ‘zlarni imloviy tahrirlash plaginini yaratish algoritmlari va dasturi //DIGITAL TRANSFORMATION AND ARTIFICIAL INTELLIGENCE. – 2025. – Т. 3. – №. 1. – С. 39-44.

# МОДЕЛИРОВАНИЕ АКТУАЛЬНЫХ ЗАДАЧ В ОСВОЕНИИ ЗАЛЕЖЕЙ НЕФТИ

**Накибаева М.Т., Мукимбеков М.Ж., Маткерим Б.**
e-mail: m.mukim@gmail.com
*Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан*

***Аннотация***
*В данной работе рассматриваются актуальные задачи течения пластовой жидкости в пористой среде с учетом интерференции скважин для моделирования процесса разработки залежей нефти вторичными методами в системе нагнетательных и добывающих скважин. Строятся вычислительные алгоритмы для решения данных задач. Для уменьшения вычислительного времени вычислительный алгоритм распараллеливается. Производится анализ расчетов.*

На сегодняшний день, когда происходит быстрое развитие нефтяной промышленности в Казахстане, встают вопросы об эффективности разработки залежей нефти и нефтяных объектов с использованием современных математических методов и современных технологии по компьютерному моделированию пластовых процессов с применением высокопроизводительных вычислений. Для увеличения коэффициента извлечения нефти применяют вторичные методы, которые позволяют улучшить физические, фильтрационно-емкостные характеристики нефтяного пласта [1-3].

В данной работе рассматривается задача по восстановлению динамических параметров нефтяного пласта с учетом произвольной геометрии пласта. Задача осложняется тем, что контур месторождения может иметь произвольную форму. Для решения подобной задачи в работе предлагаются эффективные разностные сетки.

Математическая модель имеет следующий вид:

$$m\frac{\partial p}{\partial t} = div(k\nabla p) + \sum_{i=1}^{N} Q_i\,\delta(x - x_i, y - y_i), \quad (x,y)\in\Omega, \quad 0 < t \le T. \tag{1}$$

Здесь $\Omega$ - область месторождения; $T$ - период разработки месторождения; $p$ - давление нефти в пласте; $k$ - абсолютная проницаемость пласта; $m$ - пористость пласта; $Q_i$ - приведенные дебиты пластовой жидкости на скважинах; $(x_i, y_i)$ - координаты $i$-ой скважины; $N$ - количество скважин на месторождении.

В качестве начального условия берется начальное распределение давления нефти в пласте:

$$p(x,y,0) = \mu(x,y). \tag{2}$$

На границах области течения задается следующее условие:

$$\left.\frac{\partial p}{\partial n}\right|_{\Gamma} = 0. \tag{3}$$

В работе строится параллельный, вычислительный алгоритм для решения данной задачи на вычислительном кластере и производится анализ результатов.

Вычислительный алгоритм для решения задачи (1)-(3) строится следующим образом.

В области $\Omega$ введем следующую разностную сетку $\omega_{ij}$, где $x_{i+1} = x_i + hx_i$, $y_{j+1} = y_j + hy_j$, $t^0 = 0$, $t^{n+1} = t^n + \Delta t$, $(i, j)$ -индексы внутренних узловых точек области $\Omega$, $n = 0...M$.

Уравнение (1) будем решать неявной схемой расщепления по пространственным переменным [4].

Неявная схема расщепления для уравнения давления по направлению $x$ будет иметь следующий вид:

$$hx_i hy_j m_{ij} \frac{p_{ij}^{n+1/2} - p_{ij}^n}{\tau/2} =$$

$$= hy_j (k_{i+1/2\,j}^n \frac{p_{i+1\,j}^{n+1/2} - p_{ij}^{n+1/2}}{hx_i} - k_{i-1/2\,j}^n \frac{p_{ij}^{n+1/2} - p_{i-1\,j}^{n+1/2}}{hx_{i-1}}) +$$

$$+ hx_i (k_{ij+1/2}^n \frac{p_{ij+1}^n - p_{ij}^n}{hy_j} - k_{ij-1/2}^n \frac{p_{ij}^n - p_{ij-1}^n}{hy_{j-1}}) + \sum_{l=1}^{N} (Q_l)^n \vartheta_{ij}^{скв},$$

А по направлению $y$ неявная схема будет имет следующий вид:

$$hx_i hy_j m_{ij} \frac{p_{ij}^{n+1} - p_{ij}^{n+1/2}}{\tau/2} =$$

$$= hx_i (k_{ij+1/2}^n \frac{p_{ij+1}^{n+1} - p_{ij}^{n+1}}{hy_j} - k_{ij-1/2}^n \frac{p_{ij}^{n+1} - p_{ij-1}^{n+1}}{hy_{j-1}}) +$$

$$+ hy_j (k_{i+1/2\,j}^n \frac{p_{i+1\,j}^{n+1/2} - p_{ij}^{n+1/2}}{hx_i} - k_{i-1/2\,j}^n \frac{p_{ijk}^{n+1/2} - p_{i-1\,jk}^{n+1/2}}{hx_{i-1}}) + \sum_{l=1}^{N} (Q_l)^n \vartheta_{ij}^{скв}.$$

В работе для уменьшения вычислительного времени вычислительный алгоритм распараллеливается, в последующем, задача решается на вычислительном кластере, производится анализ расчетов.

Дополнительно к вышеуказанной задаче рассматривается задача по восстановлению геолого-промысловых показателей разработки месторождений вторичными методами. Математическая модель в области $(0 < x < l, 0 < t \le T)$ имеет следующий вид:

$$\frac{\partial s}{\partial t} = r \frac{\partial}{\partial x}(kG(s)\frac{\partial s}{\partial x})) + r \frac{\partial}{\partial x}(kI(s)\frac{\partial p}{\partial x})), \quad (4)$$

$$- \frac{\partial}{\partial x}(kF(s)\frac{\partial p}{\partial x}) = \frac{\partial}{\partial x}(kG(s)\frac{\partial s}{\partial x})) \quad . \tag{5}$$

Здесь $s$ - насыщенность воды в пласте; $p$ - давление нефти в пласте; $k$ - функция проницаемости пласта; $m$ - функция пористости пласта.

Начальное условие для насыщенности воды имеет следующий вид:

$$s|_{t=0} = s^0(x), \qquad 0 < x < l \quad . \tag{6}$$

На левой границе ставятся условия для насыщенности воды и давления нефти соответственно:

$$kG(s)\frac{\partial s}{\partial x}\Big|_{x=0} = \alpha_1(t) \quad kI(s)\frac{\partial p}{\partial x}\Big|_{x=0} = \beta_1(t), \qquad 0 < t \le T \quad . \tag{7}$$

На правой границе ставятся аналогичные условия:

$$kG(s)\frac{\partial s}{\partial x}\Big|_{x=l} = \alpha_1(t) \quad kF(s)\frac{\partial p}{\partial x}\Big|_{x=0} = \beta_2(t), \qquad 0 < t \le T \quad . \tag{8}$$

Дополнительно ставятся условия для давления пласта и насыщенности воды:

$$p|_{x=l} = f_1(t), \quad s|_{x=0} = f_2(t), \qquad 0 < t \le T \quad . \tag{9}$$

Целевой функционал имеет следующий вид:

$$J(r,k) = \int_0^T [p(l,t,r,k) - f_1(t)]^2 dt + \int_0^T [s(0,t,r,k) - f_2(t)]^2 dt \quad . \tag{10}$$

Неизвестными считаются функция проницаемости $k(x)$ и функция от коэффициента пористости $r(x)$, которые нужно определить.

Сопряженная система имеет следующий вид:

$$- \frac{\partial \varphi}{\partial t} + nq(G'(s)\frac{\partial s}{\partial x} + I'(s)\frac{\partial p}{\partial x})\frac{\partial \varphi}{\partial x} =$$
$$= n\frac{\partial}{\partial x}(qG(s)\frac{\partial \varphi}{\partial x}) + \frac{\partial}{\partial x}(qG(s)\frac{\partial \theta}{\partial x}) - q(F'(s)\frac{\partial p}{\partial x} + G'(s)\frac{\partial s}{\partial x})\frac{\partial \theta}{\partial x}, \tag{11}$$

$$\frac{\partial}{\partial x}(qF(s)\frac{\partial\theta}{\partial x})] = -n\frac{\partial}{\partial x}(qI(s)\frac{\partial\varphi}{\partial x}) \quad . \tag{12}$$

Начальное условие имеет следующий вид:

$$\varphi\big|_{t=T} = 0 \quad . \tag{13}$$

Граничные условия имеют следующий вид:

$$\theta\big|_{x=0} = 0 \quad , \quad (q(F(s) - I(s))\frac{\partial\theta}{\partial x})_{x=l} = -2[p(l,t,n,q) - f_1(t)] \quad ,$$

$$(nqG(s)(1 - \frac{I(s)}{F(s)})\frac{\partial\varphi}{\partial x})_{x=0} = 2[s(0,t,n,q) - f_2(t)] \quad , \quad \varphi\big|_{x=l} = 0 \quad . \tag{14}$$

Градиент функционала равен следующему:

$$\nabla J_q = \int_0^T [nG(s)\frac{\partial s}{\partial x}\frac{\partial\varphi}{\partial x} + nI(s)\frac{\partial p}{\partial x}\frac{\partial\varphi}{\partial x} + F(s)\frac{\partial p}{\partial x}\frac{\partial\theta}{\partial x} + G(s)\frac{\partial s}{\partial x}\frac{\partial\theta}{\partial x}]dt \quad , \tag{15}$$

$$\nabla J_n = -\int_0^T [\frac{\partial}{\partial x}(qG(s)\frac{\partial s}{\partial x}) + \frac{\partial}{\partial x}(qI(s)\frac{\partial p}{\partial x})\varphi]dt \quad . \tag{16}$$

Вычислительный алгоритм для решения задачи (4)-(16) строится следующим образом.

Для расчетной области $0 \le x \le l$, $0 \le t \le T$ вводятся следующие неравномерные разностные сетки как по пространственной переменной так и по временной переменной: $x_{i+1} = x_i + h_i$, $i = 0...N$, $t^0 = 0$, $t^{n+1} = t^n + \Delta t^n$, $n = 0...M$, $\Delta t^0 = \text{const}$ ($\Delta t^0$ - задаваемый начальный шаг).

Уравнения (4), (5) аппроксимируются следующими разностными уравнениями:

$$\frac{s_i^{n+1} - s_i^n}{\Delta t^n} = \frac{1}{\hbar_i} n_i (a_{i+1/2}^{n+1}(\frac{s_{i+1}^{n+1} - s_i^{n+1}}{h_i}) - a_{i-1/2}^{n+1}(\frac{s_i^{n+1} - s_{i-1}^{n+1}}{h_{i-1}})) \quad , \tag{17}$$

$$-\frac{1}{\hbar_i}(b_{i+1/2}^{n+1}(\frac{p_{i+1}^{n+1} - p_i^{n+1}}{h_i}) - b_{i-1/2}^{n+1}(\frac{p_i^{n+1} - p_{i-1}^{n+1}}{h_{i-1}}) = \frac{1}{\hbar_i}(a_{i+1/2}^{n+1}(\frac{s_{i+1}^{n+1} - s_i^{n+1}}{h_i}) - a_{i-1/2}^{n+1}(\frac{s_i^{n+1} - s_{i-1}^{n+1}}{h_{i-1}})) \quad . \tag{18}$$

Здесь $a_{i+1/2}^{n+1} = \frac{1}{2}((q_{i+1}G(s_{i+1}^{n+1}) + q_i G(s_i^{n+1}))$, $a_{i-1/2}^{n+1} = \frac{1}{2}((q_{i-1}G(s_{i-1}^{n+1}) + q_i G(s_i^{n+1}))$,

$$b_{i+1/2}^{n+1} = \frac{1}{2}((q_{i+1}F(s_{i+1}^{n+1}) + q_iF(s_i^{n+1})) \quad b_{i-1/2}^{n+1} = \frac{1}{2}((q_{i-1}F(s_{i-1}^{n+1}) + q_iF(s_i^{n+1}))$$

,  .

Сопряженную систему (11), (12) будем аппроксимировать следующим образом:

$$-\frac{(\varphi_i^{n+1} - \varphi_i^n)}{\Delta t^n} + \frac{1}{2}(g_i^n - |g_i^n|)(\frac{\varphi_{i+1}^n - \varphi_i^n}{h_i}) + \frac{1}{2}(g_i^n + |g_i^n|)(\frac{\varphi_i^n - \varphi_{i-1}^n}{h_{i-1}}) =$$

$$= \frac{1}{\hbar_i} r_i(a_{i+1/2}^n(\frac{\varphi_{i+1}^n - \varphi_i^n}{h_i}) - a_{i-1/2}^n(\frac{\varphi_i^n - \varphi_{i-1}^n}{h_{i-1}})) + \frac{1}{\hbar_i}(a_{i+1/2}^n(\frac{\theta_{i+1}^n - \theta_i^n}{h_i}) - a_{i-1/2}^n(\frac{\theta_i^n - \theta_{i-1}^n}{h_{i-1}})) -$$

$$-\frac{1}{2}(e_i^n - |e_i^n|)(\frac{\theta_{i+1}^n - \theta_i^n}{h_i}) - \frac{1}{2}(e_i^n + |e_i^n|)(\frac{\theta_i^n - \theta_{i-1}^n}{h_{i-1}})$$

, (19)

$$\frac{1}{\hbar_i}(b_{i+1/2}^n(\frac{\theta_{i+1}^n - \theta_i^n}{h_i}) - b_{i-1/2}^n(\frac{\theta_i^n - \theta_{i-1}^n}{h_{i-1}})) = -\frac{n_i}{\hbar_i}(c_{i+1/2}^n(\frac{\varphi_{i+1}^n - \varphi_i^n}{h_i}) - c_{i-1/2}^n(\frac{\varphi_i^n - \varphi_{i-1}^n}{h_{i-1}}))$$

. (20)

Здесь $c_{i+1/2}^n = \frac{1}{2}((q_{i+1}I(s_{i+1}^n) + q_iI(s_i^n)) \quad c_{i-1/2}^n = \frac{1}{2}((q_{i-1}I(s_{i-1}^n) + q_iI(s_i^n))$

, ,

$$g_i^n = (nq(G'(s)\frac{\partial s}{\partial x} + I'(s)\frac{\partial p}{\partial x}))_i^n \quad e_i^n = (q(F'(s)\frac{\partial p}{\partial x} + G'(s)\frac{\partial s}{\partial x}))_i^n$$

, .

Системы уравнений (17)-(18) и (19)-(20) являются нелинейными, будем их решать одним из итерационных методов, предварительно линеаризуя нелинейные члены [5]. Минимизирующие последовательности строятся следующим образом:

$$k^{(p+1)}(x) = k^{(p)}(x) - \alpha^n \nabla J_k^{(p)}$$

, (21)

$$r^{(p+1)}(x) = r^{(p)}(x) - \beta^n \nabla J_r^{(p)}$$

,

где

$$\nabla J_k^{(p)} = \int_0^T [r(G(s)\frac{\partial s}{\partial x} + I(s)\frac{\partial p}{\partial x})\frac{\partial \varphi}{\partial x} + (F(s)\frac{\partial p}{\partial x} + G(s)\frac{\partial s}{\partial x})\frac{\partial \theta}{\partial x}]dt$$

, (22)

$$\nabla J_r^{(p)} = -\int_0^T [\frac{\partial}{\partial x}(kG(s)\frac{\partial s}{\partial x}) + \frac{\partial}{\partial x}(kI(s)\frac{\partial p}{\partial x})\varphi]dt$$

.

Здесь $p$ - номер итерации, $p = 0,1,2,...$. Коэффициенты $\alpha^n$, $\beta^n$ для построения минимизирующихся последовательностей находятся одним из методов, приведенных в [5].

В работе строится вычислительный алгоритм для решения данной задачи на вычислительном кластере и производится анализ результатов.

**Список литературы**

1 Азиз Х., Сеттари Э. Математическое моделирование пластовых систем. - М.: Недра, 1982. - 407 с.
2 Кричлоу Г. Современная разработка нефтяных месторождений. Проблемы моделирования. - М.: Недра, 1979. - 303 с.
3 Мукимбеков М.Ж. Об одной двумерной задаче в процессе добычи углеводородов // Исследования по интегро-дифференциальным уравнениям. 2008. Выпуск 39. - С. 217-226.
4 Андерсон Д., Таннехил Дж. Вычислительная гидромеханика и теплообмен. М.: Мир, 1990.-384 с.
5 Самарский А.А. Теория разностных схем. - М.: Наука, 1977. - 656 с.

# ЧИСЛЕННОЕ ИССЛЕДОВАНИЕ ВЛИЯНИЯ ТЕМПЕРАТУРЫ ОКРУЖАЮЩЕЙ СРЕДЫ НА ТЕРМО-НАПРЯЖЕННО-ДЕФОРМИРОВАННОЕ СОСТОЯНИЕ СТЕРЖНЯ С КРИВОЛИНЕЙНОЙ ОБРАЗУЮЩЕЙ

**А.А. Ташев[1], М.Т. Аршидинова[2]**

*[1]Институт механики и машиноведения им. академика У.А.Джолдасбекова КН МНиВО РК, Алматы*

*[2]Казахский национальный исследовательский технический университет имени К.И.Сатпаева, Алматы*

e-mail: azattash@mail.ru, mukaddas_arshidi@mail.ru

***Abstract.*** *В работе рассматривается горизонтальный стержень ограниченной длины переменного сечения. Радиус сечения стержня по ее длине меняется нелинейно. В связи с этим образующий стержня будет криволинейной. Боковая поверхность этого стержня теплоизолированное. Радиус поперечного сечения левого конца стержня меньше чем правый. На площадь поперечного сечения левого конца стержня подведен тепловой поток постоянной интенсивности. Численно исследуется влияние температуры окружающей среды на термо-напряженно-деформированное состояние исследуемого стержня. При этом основные разрешающие уравнения выводится из условия сохранения тепловой энергии. Разработаны алгоритм и программа, позволяющие провести серии вычислительных экспериментов по исследованию термо-напряженно-деформированного состояния стержня с криволинейными образующими под воздействием температуры окружающей среды. Исследование проводилось с применением вычислительного метода основанной на законе сохранения тепловой энергии.*

***Ключевые слова:*** *нелинейное сечение, тепловой поток, теплообмен, температура окружающей среды, удлинение, осевая сила, деформация, напряжение, перемещение.*

## Введение

В настоящее время к решению задач термо-напряженно-деформированного состояния стержня с криволинейной образующей уделяется мало внимания.

Исследование закона распределения температуры в телах различных формах (стержень, конус и т.д) с использованием вариационного подхода рассмотрены в [1-2]. В этих работах были применены вариационные принципы для исследования закона распределения температуры и напряжения одномерных и двумерных тел, имеющих простую конфигурацию.

В [3-4] исследован ограниченный длиной стержень переменным поперечным сечением. При этом, боковая поверхность стержня изолирована. Тепловой поток подается на левый торец стержня. На правом конце происходит теплообмен с окружающей средой. В работе с использованием вариационного подхода определяется поле распределения температуры, смещения, три составляющие деформации и напряжений. Здесь же показаны методы получения термомеханических характеристик стержня: удлинение, осевое усилие, законы распределения деформации, напряжения и перемещения.

В [5] предлагается использование разностных схем для уравнения теплопроводности на криволинейных сетках в терминах тепловых потоков, основанные на вариационном принципе. Исследуются свойства разностных операторов и вопросы устойчивости и аппроксимации.

## 1. Постановка задачи

Рассматривается горизонтальный стержень ограниченной длины L[M]. Ось *OX* направлен слева на право и совпадает с осью стержня. Радиус стержня меняется

нелинейно по закону $r(x)=ax^2+bx+c, 0 \le x \le L$, где a, b, c – постоянные величины, такие, что $r(x=0) < r(x=L)$. На площадь поперечного сечения левого торца стержня подается тепловой поток с постоянной интенсивностью. Площадь поперечного сечения правого торца стержня равна $\pi r^2(x=L) = (aL^2+bL+c)^2$, а площадь поперечного сечения левого конца стержня - $\pi r^2(x=0) = \pi \cdot c^2$. На правом конце стержня происходит теплообмен с окружающей средой, с температурой $T_{oc}[^\circ C]$. Коэффициент теплообмена $h = \left[\frac{Bm}{M^{2\circ}C}\right]$.

Боковая поверхность стержня теплоизолирована. В случае защемления только одного конца стержня определяется величина удлинения стержня вследствие наличия теплового потока и теплообмена. В случае зещемления обеих концов стержня определяются:

1) возникающее осевое температурное усилие;
2) законы распределения термоупругих, температурных и упругих составляющих деформаций и напряжений по длине рассматриваемого стержня;
3) поле перемещения.

## 2. **Вычислительный метод и алгоритм, основанный на законе сохранения тепловой энергии**

Стержень делим на n-дискретных элементов одинаковой длины. Боковая поверхность всех элементов теплоизолирована. В пределах длины каждого дискретного элемента аппроксимируем поле температуры и перемещения полиномом второго порядка [1].

В нашем случае, рассматриваемый стержень с криволинейной образующей состоит из n=4 элементов одинаковой длины $l = \frac{L}{4}[\text{м}]$. Далее, для каждого дискретного элемента формируется функционал полной тепловой энергии:

$$\left.\begin{aligned} I_1 = \int_{F(x=0)} \frac{h}{2}(T-T_{oc})\,ds + \int_{V_1} \frac{K_{xx}}{2}\left(\frac{dT}{dx}\right)^2 dv \\ I_2 = \int_{V_2} \frac{K_{xx}}{2}\left(\frac{d\partial T}{dx}\right)^2 dv \\ I_3 = \int_{V_3} \frac{K_{xx}}{2}\left(\frac{dT}{dx}\right)^2 dv \\ I_4 = \int_{V_4} \frac{K_{xx}}{2}\left(\frac{dT}{dx}\right)^2 dv + \int_{F(x=L)} qT\,ds \end{aligned}\right\} \quad (1)$$

Тогда выражение функционала полной тепловой энергии для исследуемого стержня в целом имеет вид:

$$I = \sum_{i=1}^{4} I_i \quad (2)$$

Минимизируя этот функционал по узловым значениям температуры $T_1, T_2, \ldots T_9$ строится разрешающая система линейных алгебраических уравнений с учетом естественных граничных условий:

$$\frac{\partial I}{\partial T_r} = 0, \quad r = 1 \div 9. \quad (3)$$

Решая эту систему, определяются узловые значения $T_r$, $r = 1 \div 9$.

Далее, в пределах длины каждого дискретного элемента определяется поле температуры:

$$T_r(x) = \frac{2x^2-3lx+l^2}{l^2}T_{2r-1} + \frac{4lx+4x^2}{l^2}T_{2r} + \frac{2x^2-lx}{l^2}T_{2r+1}, \quad 0 \le x \le l, \quad r = 1 \div 4. \quad (4)$$

Если один конец исследуемого стержня жестко защемлен, а другой свободен, то из-за наличия поле температуры он удлиняется. Величину термического удлинения определяется следующим образом:

$$\Delta L = \int_0^L \alpha T(x)dx \text{ [м].} \tag{5}$$

где $\alpha \left[\frac{1}{\bullet^{\circ}\text{C}}\right]$ – коэффициент теплового расширения материала.

Если оба конца исследуемого стержня жестко защемлены, то в нем возникает термическое осевое усилие R[N]:

$$R = \frac{E \bullet \Delta l_T}{\int_0^L \frac{dx}{F(x)}} [\text{Н}] \tag{6}$$

В этом случае, законы распределения термоупругих, температурных и упругих составляющих деформаций, и напряжений определяются следующим образом:

$$\left.\begin{aligned} \varepsilon(x) &= \tfrac{R}{E \cdot F(x)} \\ \sigma(x) &= \tfrac{R}{F(x)} \\ \varepsilon_T(x) &= -\alpha \cdot T(x) \\ \sigma_T(x) &= E \cdot \varepsilon_T(x) \\ \varepsilon_x(x) &= \varepsilon(x) - \varepsilon_T(x) \\ \sigma_x(x) &= E \cdot \varepsilon_x(x) \end{aligned}\right\}, \quad 0 \le x \le L \tag{7}$$

Потенциальная энергия упругих деформации с учетом наличия поле температур, имеет следующий вид:

$$\prod = \int_V \tfrac{\sigma_x(x)}{2} dv - \int_V \alpha E \cdot T(x)\varepsilon_x(x) = = \tfrac{E}{2} \int_V \tfrac{dU}{dx} dv - \alpha \cdot E \int_V T(x) \tfrac{dU}{dx} dv \tag{8}$$

Минимизируя этот функционал по узловым значениям перемещения строится система линейных алгебраических уравнений для определения перемещения узлов:

$$\frac{\partial \Pi}{\partial U_r} = 0, \quad r = 2 \div 8. \tag{9}$$

Из-за защемления обеих концов стержня имеет место, это $U_1 = U_2 = 0$.

После определения узловых перемещений $U_r$, строится поле перемещения в пределах длины каждого дискретного элемента:

$$U_r(x) = \frac{2x^2 - 3lx + l^2}{l^2} U_{2r-1} + \frac{4lx - 4x^2}{l^2} U_{2r} + \frac{2x^2 - lx}{l^2} T_{2r+1}, \quad r = 1 \div 4; \; 0 \le x \le l. \tag{10}$$

В целях исследования влияния температуры окружающей среды на термо-напряженно-деформированное состояние исследуемого стержня с криволинейной образующей были использованы следующие исходные данные:

*L=0.2*[м]; *n=4;* $l = \frac{L}{n} = 0.05$[м]; $K_{xx} = 75 \frac{Bm}{\text{м} \bullet^{\circ}\text{C}}$; $h = 10 \frac{Bm}{M^{2\circ}\text{C}}$;

*r(x)=ax²+bx+c=0,25x²-0,025x+0,005; a=0,25; b=0,025; c=0,005;*

$$\alpha = 0,0000125 \left[\frac{1}{^{\circ}\text{C}}\right];$$

$$E = 2 \cdot 10^{11}[\tfrac{H}{\text{м}^2}];\quad q = -500\ [\tfrac{Bm}{M^2}]\ ;$$
$$T_{oc} \in [50^{\circ}\text{C};\ 40^{\circ}\text{C};\ 30^{\circ}\text{C};\ 20^{\circ}\text{C};\ 10^{\circ}\text{C}\ ].$$

Полученные численные результаты показывают, что узловые значения температуры при $T_{oc} = 40^{\circ}\text{C}$,будут в среднем в 1.23 раза меньше чем в случае $T_{oc} = 50^{\circ}\text{C}$. Величина удлинения исследуемого стержня при $T_{oc} = 40^{\circ}\text{C}$ будет в среднем в 1.1818 раза меньше по сравнению с $T_{oc} = 50^{\circ}\text{C}$. Но величина возникающего термического осевого усилия при $T_{oc} = 40^{\circ}\text{C}$ примерно 1.23 раза меньше чем в случае с $T_{oc} = 50^{\circ}\text{C}$.

Далее, узловые значения всех составляющих деформаций и напряжений, а так же перемещения в случае $T_{oc} = 40^{\circ}\text{C}$ примерно в 1.23 раза меньше чем в случае $T_{oc} = 50^{\circ}\text{C}$. Отсюда видно, что при уменьшения температуры окружающей среды на 20% (от 50[°C] до 40[°C]) приводит к уменьшению примерно 1.23 раза искомых параметров, кроме величины термического удлинения стержня. Оно уменьшается примерно в 1.18 раза. Теперь анализируем отношения искомых величин при $T_{oc} = 50[^{\circ}\text{C}]$ и $T_{oc} = 30[^{\circ}\text{C}]$. Они в среднем составляют 1.6. Проведенные вычислительные эксперименты также показывает, что уменьшения температуры окружающей среды на 60% приводит к уменьшению значение термического удлинения на 2,16 раза, а остальных параметров примерно 2.28 раза по сравнению с результатами при $T_{oc} = 50[^{\circ}\text{C}]$. Если уменьшить эту температуру окружающей среды на 80% то при $T_{oc} = 10[^{\circ}\text{C}]$ полученные отношенияв среднем в 4 раза меньше по сравнению с результатами при $T_{oc} = 50[^{\circ}\text{C}]$. При этом значения термического удлинения стержня будет примерно в 4.33 раза меньше чем при $T_{oc} = 50[^{\circ}\text{C}]$.

Полученные результаты приводятся на рисунках 1-5. На рисунке-1 приводится закон распределения температуры по длине исследемого стержня при различных значениях температуры окружающей среды.

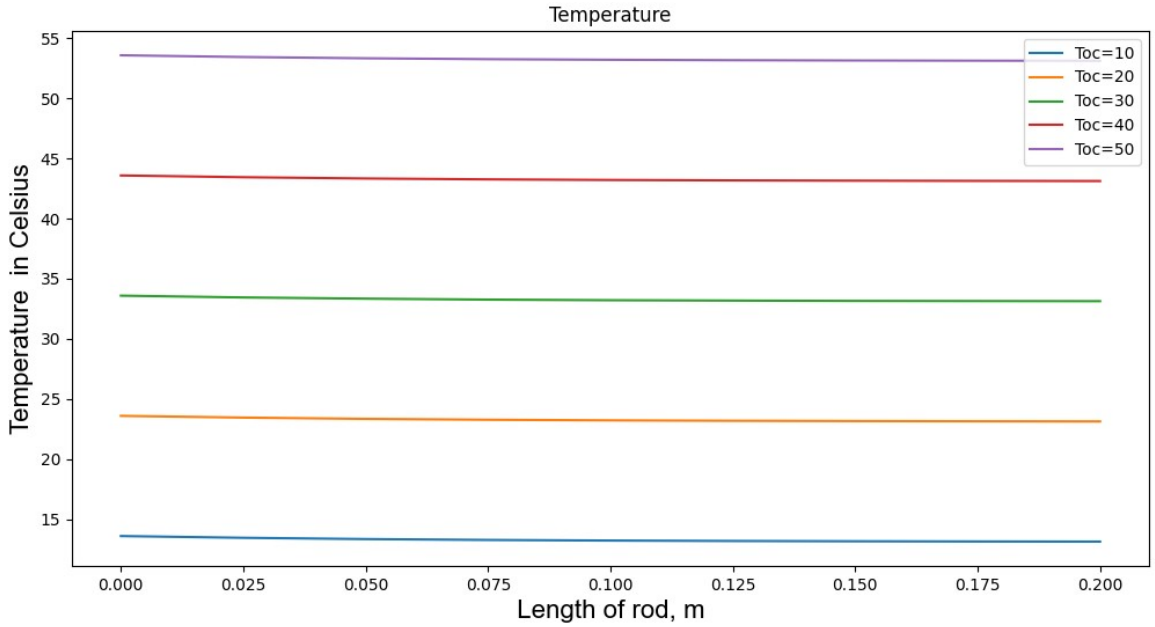



Рисунок 1. График зависимости температуры от температуры окружающей среды по длине стержня

В таблице-1 приводятся значения термического удлинения стержня при защемлении с одного конца и термического усилия, когда оба конца -– защемлены при различных значениях температуры окружающей среды.

Таблица -1.

| $T_{oc}[^{\circ}\text{C}]$ | 50 | 40 | 30 | 20 | 10 |
|---|---|---|---|---|---|

| $\Delta l_T$[м] | 0,00013 | 0,00011 | 0,00008 | 0,00006 | 0,00003 |
|---|---|---|---|---|---|
| R[H] | -30058,616 | -24414,764 | -18770,915 | -13127,065 | -7483,215 |

На рисунках 2-4 приводится законы распределения термоупругих, температурных и упругих составляющих деформаций по длине исследуемого стержня в зависимости от температуры окружающей среды.

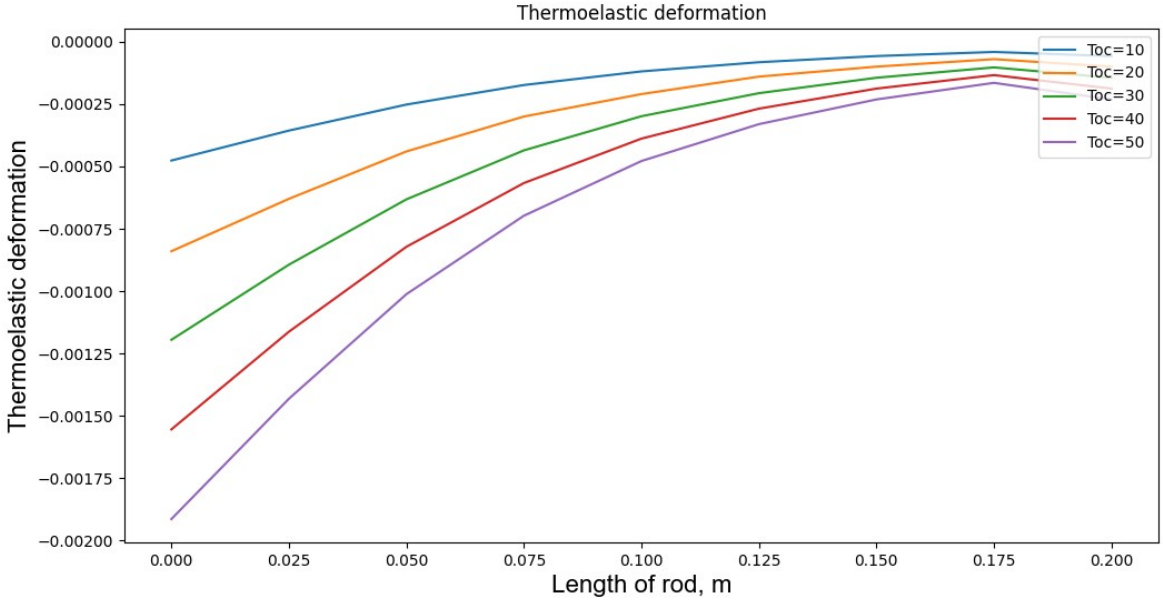



Рисунок 2. График зависимости термоупругой деформации от температуры окружающей среды по длине стержня

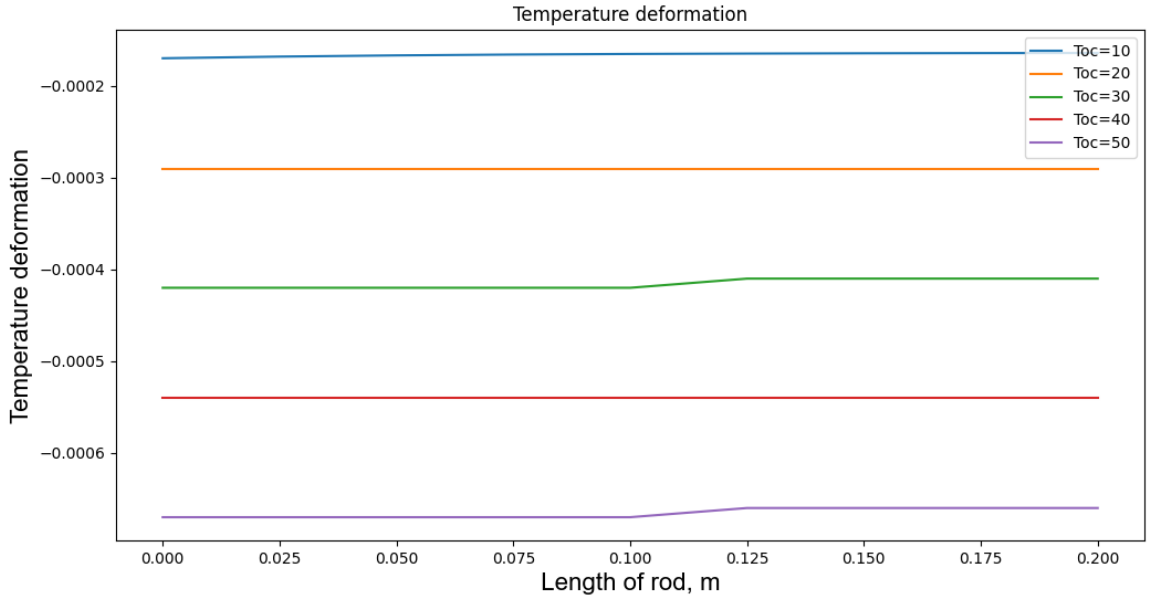



Рисунок 3. График зависимости температурной деформации от температуры окружающей среды по длине стержня

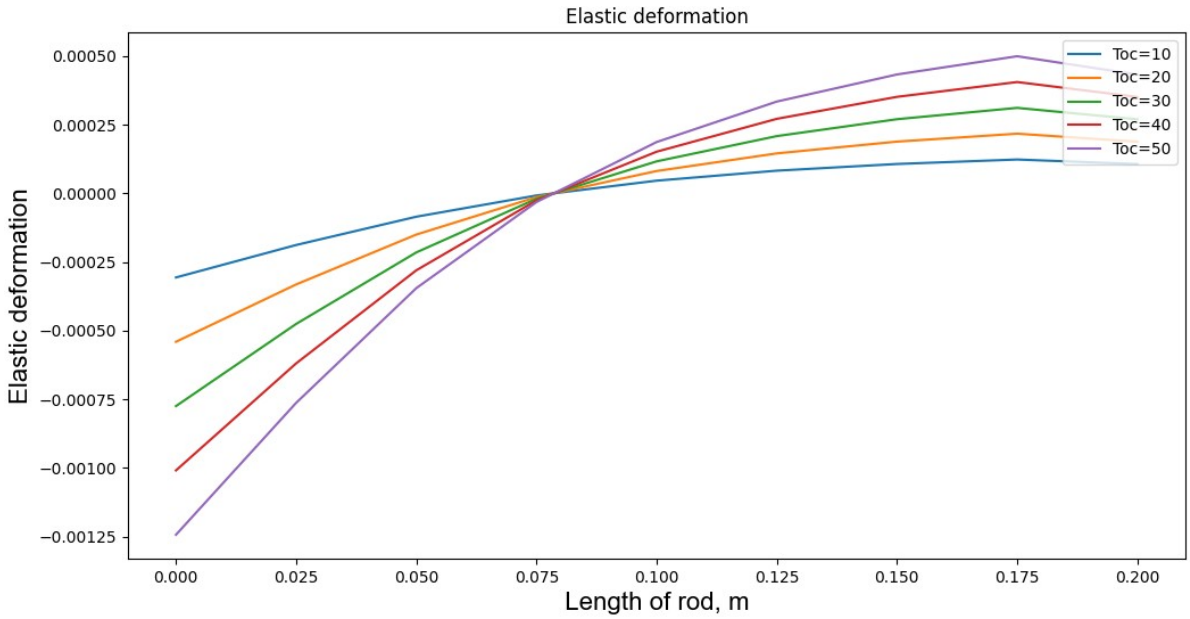



Рисунок 4. График зависимости упругой деформации от температуры окружающей среды по длине стержня

Из этих кривых видно, что термоуругая и температурная составляющие по всей длине исследуемого стержня имеют сжимающий характер, упругая составляющая деформация на первой половине длины стержня имеет сжимающий, а на второй - растягивающий характер.

Характеры составляющих напряжений соответствует к характерам аналогичных составляющих деформаций. Так же узловые значение осотавляющих напряжений будут пропорциональны к значением соответствующих составляющих деформаций.

Закон распределения перемещения по длине стержня для различных значений температуры окружающей среды приводится на рисунке 5.

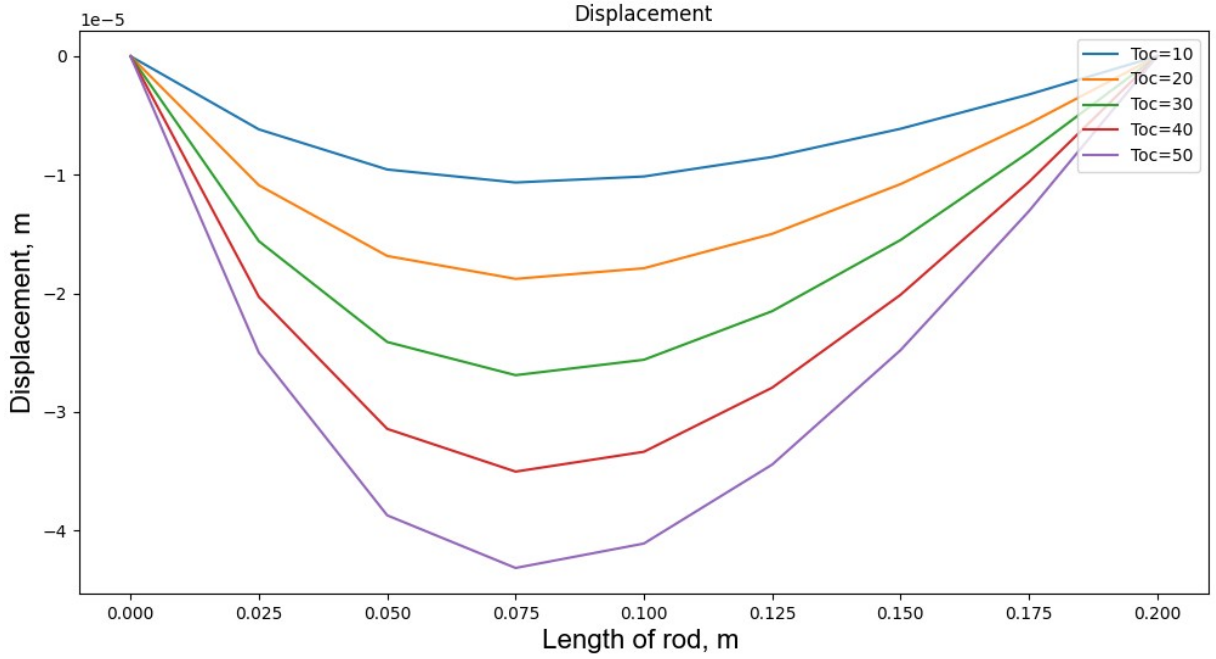



Рисунок 5. График зависимости перемещения от температуры окружающей среды по длине стержня

Из рисунка видно, что с увеличением температуры окружающей среды увеличивается значения перемещений сечения стержня.

**Заключение**

1. На основе баланса количества тепла разработаны вычислительный метод и алгоритм, а также программное обеспечение для исследования термо-напряженно-деформированное состояние стержня с криволинейной образующей при различных значениях окружающей среды.

2. При рассмотрении задачи влияния величины температуры окружающей среды на термо-напряженно-деформированное состояние стержня с криволинейной образующей были выявлены ряд закономерностей.

3. Исследовано изменения величины удлинения стержня в зависимости от величины температуры окружающей среды. Выявлено, что при увеличении значения температуры окружающей среды наблюдается увеличение значение всех искомых параметров.

Данная работа выполнена благодаря финансированию фундаментальных научных исследований комитетом науки Министерства науки и высшего образования Республики Казахстан Института механики и машиноведения им. академика У.А. Джолдасбекова.

**References**

1. *J. L. Segerlind*, “Applied finite element analysis”, New York-London-Sydney-Toronto, Jonh Wiley and Song, 1976.

2. *Зенкович О, Морган К*. Конечные элементы и аппроксимация: Пер. с англ. –М.: Мир, 1986,-318с.

3. *M. T Arshidinova, A. Kudaykulov, A.A.Tashev, K.B. Begaliyeva,* «Numerical Modeling Of Nonlinear Thermomechanical Processes In a Rod Of Variable Cross Section In The Presence Of Heat Flow», 5th International Conference on Information Science and Control Engineering, 2018.

4. *A. Kudaykulov, A. A. Tashev, A. Askarova*. «Computational algorithm and the method of determining the temperature field along the length of the rod of variable cross section», Journal Open Engineering.

5. *Т. К. Коршия, В. Ф. Тишкин, А. П. Фаворский, М. Ю. Шашков.* Вариационный подход к построению разностных схем для уравнения теплопроводности на криволинейных сетках. Журнал вычислительной математики и математической физики, 1980, том 20, номер 2, страницы 401–421.

# MATHEMATICAL MODELING OF NON-STATIONARY NON-LINEAR FILTRATION PROCESSES IN MULTI-LAYERED POROUS MEDIA

**Shukurova M.E.**

*Karshi State Technical University, Uzbekistan*

***Abstract:*** *This paper considers the mathematical modeling of unsteady filtration of oil and gas phases and interlayer flow (over-flow) processes in multilayer porous media. For a two-layer system, a system of multiphase nonlinear partial differential equations is formulated based on capillary pressure relationships and third-type (Robin) boundary conditions. To address the strong nonlinearities arising in the modeling process, an implicit finite-difference scheme combined with the Newton–Raphson and tridiagonal matrix (Thomas) algorithm methods is proposed.*

***Keywords:*** *mathematical modeling, unsteady filtration, multilayer porous medium, capillary pressure, variable nonlinear processes, implicit finite-difference scheme, tridiagonal matrix algorithm.*

## INTRODUCTION

Predicting hydrodynamic processes within porous media plays a pivotal scientific and practical role in the efficient development of petroleum reservoirs featuring complex geological architectures. In heterogeneous multilayer collectors, the simultaneous movement of oil and gas is governed by intricate physical mechanisms, including interlayer gas cross-flow (over-flow) driven by spatial pressure differentials across boundary zones, alongside strong capillary forces. These intertwined physical interactions convert the governing mathematical system into a highly non-linear regime, requiring advanced computational frameworks to accurately capture phase distribution dynamics.

The core objective of this study is to formulate a robust mathematical model describing the coupled non-stationary filtration of oil and gas phases across two interacting porous layers, as well as to derive an effective numerical solution algorithm. The governing model incorporates phase permeability functions, capillary pressure relations, and pressure-dependent fluid densities to ensure physical fidelity. To overcome non-linearity and guarantee computational stability, an implicit finite-difference scheme combined with an iterative block-tridiagonal matrix technique is implemented for spatial and temporal discretization.

By establishing rigorous third-type boundary conditions at domain extremities, the developed algorithmic framework successfully resolves phase pressure and saturation fields under transient operational scenarios. The numerical scheme effectively accounts for cross-layer mass transfer, enabling accurate forecasting of pressure redistribution and fluid saturation trends across both reservoir zones. Consequently, this computational model serves as a reliable decision-support tool for optimizing resource recovery strategies and analyzing hydrodynamic performance in complex multilayer reservoir systems.

## LITERATURE REVIEW

Mathematical modeling of non-linear non-stationary filtration processes of two-phase (oil and gas) fluids in multilayer porous media represents one of the most critical challenges in petroleum reservoir dynamics. Analysis of recent international scientific publications indicates that modeling filtration mechanisms in multilayer reservoirs with complex geological structures relies not only on classic Darcy equations, but also on complex physical phenomena including phase interactions, capillary forces, and cross-layer fluid interflow (over-flow).

Specifically, computational algorithm solutions for multiphase flows in heterogeneous porous media developed by Z. Chen, G. Huan, and Y. Ma [9], demonstrate the high efficiency of implicit finite-difference schemes and upwind methodologies in handling non-linear formulations of Darcy's law. These computational foundations directly support the discretization and linearization of our non-stationary governing equations for gas and oil

transport across First and Second porous layers, ensuring numerical stability throughout time-stepping procedures.

Furthermore, K.A. Lie [10], comprehensively details numerical frameworks for incorporating saturation-dependent relative phase permeability $K(S)$ and capillary pressures $P_{cog}$ within reservoir simulation models. This approach provides the exact mathematical structure required to maintain the phase balance constraints $S_{1o} + S_{1g} = 1$ and $S_{2o} + S_{2g} = 1$ and execute iterative updates of pressure and saturation distributions at each temporal iteration.

Thermodynamic and hydrodynamic mechanisms governing inter-layer leakage and dissolved gas release $R_s$ in multilayer petroleum reservoirs are rigorously established by T. Ertekin, J.H. Abou-Kassem, and G.R. King [11]. The cross-flow exchange term $\pm\frac{\rho_{2g} k_{\text{П}}}{h_2 h_{\text{П}} \mu_g}(P_{2g} - P_{1g})$ representing gas redistribution between the first and second layers, alongside pressure-dependent fluid density variations, directly adopts the constitutive physical relations developed in their work.

Regarding finite-difference approximations and stability analysis, A.A. Samarskiy and P.N. Vabishchevich [8], provide the theoretical foundation for solving systems of non-linear partial differential equations under Robin boundary conditions. This enables the exact transformation of third-type boundary conditions $\left(-\frac{k\partial P}{\mu\partial x} = \alpha(P_A - P)\right)$ at spatial domain boundaries $x = 0$ and $x = L$ into algebraic systems solved via block and tridiagonal matrix algorithms.

Finally, M.J. Blunt [12] examines microscopic and macroscopic flow dynamics and capillary pressure phenomena in multiphase porous media. His findings provide the physical-mathematical justification for coupling phase pressures through capillary pressure relations $P_{1o} + P_{1g} = P_{1cog}$ and $P_{2o} + P_{2g} = P_{2cog}$ within our system.

## MATHEMATICAL FORMULATION

The mathematical formulation of non-stationary, non-linear filtration processes in multi-layered porous media provides the theoretical foundation for describing complex fluid and gas transport mechanisms in heterogeneous petroleum reservoirs. In a multi-layered domain consisting of *N* distinct geological strata, the pressure distribution within the *i*-th layer *i = 1, 2, …,N* is governed by the space-time variable field $\rho_i(x,y,z,t)$, where non-linearity arises primarily from pressure-dependent fluid properties, stress-sensitive permeability, and non-Darcy flow behavior.

The mass conservation principle applied to an elemental volume of the *i*-th porous layer yields the generalized continuity equation $\frac{\partial(\phi_i \rho_i)}{\partial t} + \nabla \cdot (\rho_i v_i) = q_i$, where $\phi_i$ represents the effective porosity, $\rho_i$ denotes the fluid density, $v_i$ is the superficial velocity vector, and $q_i$ accounts for internal sources or sinks such as production and injection wells.

To incorporate non-linear transport dynamics, the filtration velocity $v_i$ is expressed using the generalized non-linear Darcy-Forchheimer law, $v_i = -\frac{k_i(\rho_i)}{\mu_i(\rho_i)(1+\beta_i\rho_i|v_i|)}\nabla\rho_i$, which accounts for inertial resistance effects during high-velocity flow regimes near wellbores, alongside pressure-dependent absolute permeability tensor $k_i(\rho_i)$ and dynamic fluid viscosity $\mu_i(\rho_i)$.

Substituting the non-linear velocity relationship into the mass conservation equation leads to the non-stationary, three-dimensional non-linear partial differential equation (PDE) governing the pressure field $\rho_i(x,y,z,t)$ in the *i*-th layer:

$$\frac{\partial}{\partial t}(\phi_i(p_i)\rho_i(p_i)) - \nabla\cdot\left(\frac{\rho_i(p_i)k_i(p_i)}{\mu_i(p_i)}\nabla p_i\right) = q_i(x,y,z,t)$$

Expanding the time-derivative term via the chain rule introduces the total isothermal compressibility coefficient of the saturated porous medium, $c_t^{(i)} = c_f^{(i)} + c_r^{(i)}$, where $c_f^{(i)} = \frac{1}{\rho_i}\frac{\partial\rho_i}{\partial p_i}$ is the fluid compressibility and $c_r^{(i)} = \frac{1}{\phi_i}\frac{\partial\phi_i}{\partial p_i}$ is the rock matrix compressibility, transforming the accumulation term into $\phi_i\rho_i c_t^{(i)}\frac{\partial p_i}{\partial t}$.

By defining the generalized non-linear piezoconductivity parameter $k_i(p_i) = \frac{k_i(p_i)}{\phi_i(p_i)\mu_i(p_i)c_t^{(i)}(p_i)}$, the governing PDE can be rewritten in canonical parabolic form, highlighting the strong pressure dependence of the diffusivity coefficient across variable pressure regimes:

$$\frac{\partial p_i}{\partial t} = \nabla\cdot(k_i(p_i)\nabla p_i) + \frac{1}{\phi_i c_t^{(i)}\rho_i}(k_i(p_i)\nabla\rho_i\cdot\nabla p_i + q_i)$$

For multi-layer systems separated by thin semi-impermeable clay or mudstone interbeds (aquitards), hydraulic interaction between adjacent layers *i* and *i+1* occurs through cross-flow mechanisms driven by vertical piezoconductivity and pressure gradients across the interface $z = z_{i,i+1.}$.

The interlayer cross-flow flux $W_{i,i+1}(x,y,t)$ per unit horizontal area is mathematically modeled using the generalized semi-permeable boundary condition based on hydraulic resistance, $W_{i,i+1} = \sigma_{i,i+1}(p_{i+1} - p_i)\big|_{z=z_{i,i+1.}}$, where defines the specific vertical hydraulic conductivity of the separating interbed of thickness $d_{inter.}$

The complete boundary value problem requires specifying appropriate initial and boundary conditions across the external domain boundaries $\Gamma$. Initial pressure distributions are defined as $p_i(x,y,z,0) = P_{0,i}(x,y,z)$, while boundary conditions enforce either specified

pressure (Dirichlet), $pi\big|_{\Gamma_1} = P_b(t)$, or specified flux (Neumann) condition, $-\frac{k_i}{\mu_i}\frac{\partial p_i}{\partial n}\Big|_{\Gamma_2} = d(t)$, including no-flow outer boundaries where $d(t) = 0$.

This rigorous system of coupled, non-linear PDEs, complemented by non-linear piezoconductivity coefficients and hydraulic coupling at layer interfaces, forms the robust mathematical basis required for discrete numerical approximations-such as finite difference or finite element schemes-enabling precise simulation of non-stationary filtration dynamics in complex layered petroleum reservoirs.

## NUMERICAL METHODS

To capture the non-linear dynamics of multi-layer filtration without analytical intractability, the continuous boundary-value problem formulated previously must be projected onto a discrete spatio-temporal computational grid. The choice between spatial discretizations hinges on domain topology: structured, orthogonal grid networks suit standard finite difference formulations, whereas irregular geometrical interfaces and anisotropic pinch-outs favor finite element method formulations via weak variational formulations.

To construct the discrete system, the continuous continuous non-linear differential operator is transformed using a fully implicit time-stepping scheme to maintain unconditional numerical stability across stiff pressure transitions:

$$L\left(p_i^{n+1}\right) = \nabla \cdot \left[k_i\left(p_i^{n+1}\right)\nabla p_i^{n+1}\right] + Q_i\left(p_i^{n+1}\right) - \phi_i c_t^{(i)} \frac{p_i^{n+1} - p_i^n}{\Delta t} = 0$$

- A 7-point cell-centered spatial stencil in three dimensions approximates diffusion flux terms across control volume faces using harmonic-mean transmissibility weighting between adjacent grid nodes $(j,k,l)$ and $(j+1,k,l)$.
- Weak-form integration over a domain $\Omega_e$ utilizes piecewise polynomial continuous Lagrange shape functions $N_\alpha(x)$, converting local element residual integrals $\int_{\Omega_e} N_\alpha L(p)\, d\Omega = 0$ into global stiffness and mass matrices via galerkin projection.

*Iterative and non-linear solution algorithms*

Because coefficients such as piezoconductivity $k_i(p_i)$ and interbed cross-flow fluxes $W_{i,i+1}(p)$ depend strongly on the local pressure field \$p_i\$, direct matrix inversions are inapplicable. The discretized non-linear system must be linearized at each time step $t^{n+1}$.

- The non-linear residual vector $R\left(p^{n+1}\right)$ is solved iteratively using the primary variable derivatives to form the system Jacobian matrix $J\left(p^{(m)}\right) = \frac{\partial R}{\partial p}\Big|^{(m)}$. The update step follows $J^{(m)}\delta p^{(m+1)} = -R^{(m)}$ until the residual norm satisfies $\left\|R^{(m)}\right\|_2 < \varepsilon_{tol}$.
- For moderately non-linear regimes or preconditioning stages inside iterative solvers, point-wise Gauss-Seidel iterations update pressure values sequentially using the most recently calculated neighbor values, accelerating convergence over classical Jacobi parallel updates:

$$p_j^{(m+1)} = \frac{1}{a_{jj}} \left( b_j \sum_{k<j} a_{jk} p_k^{(m+1)} - \sum_{k>j} a_{jk} p_k^{(m)} \right)$$

This discrete formulation ensures conservative flux approximation at layer interfaces, permitting robust numerical simulation of non-stationary pressure propagation across complex multi-layered media.

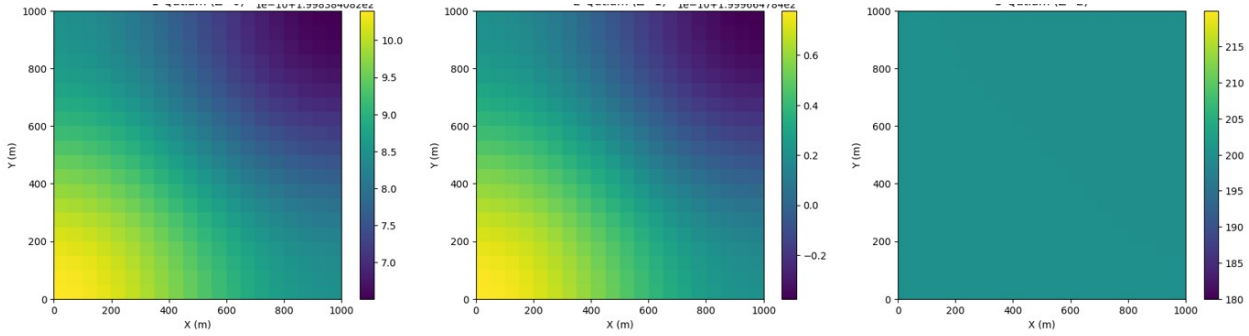



**Figure 1. Spatial pressure distribution in a multi-layered porous medium during non-local non-stationary filtration (t = 5)**

This figure illustrates the three-dimensional $1000\,m \times 1000\,m \times 30\,m$ spatial pressure field distribution generated by the mathematical model at $T = 5$. The numerical solution captures the hydrodynamic influence of a single production well situated at the domain center $X = 500\,m, Y = 500\,m$ operating under a constant bottom-hole pressure condition of $P_w = 120\,Bar$.

- Layer 1 $Z = 0$, high-permeability layer, $k_1 = 100\,mD$ - direct completion of the production well within this layer forms a pronounced isotropic radial cone of depression. The fluid pressure transitions smoothly from *120 Bar* at the wellbore node to the initial reservoir pressure of *200 Bar* toward the outer boundary domains.
- Layer 2 $Z = 1$, Low-permeability interbed, $k_2 = 30\ mD$ - Governed by vertical hydraulic resistance and cross-flow flux $W_{1,2}$, pressure depletion is transmitted into this layer. Due to lower piezoconductivity, the drawdown cone remains localized, maintaining a minimum central pressure near *192.4 Bar*.
- Layer 3 $Z = 2$, Medium-permeability layer, $k_3 = 80\ mD$ - Interbed hydraulic coupling induces a vertical pressure gradient, driving dynamic cross-flow fluid movement from *Layer 3* through *Layer 2* toward *Layer 1*, resulting in a gradual, spatially extended pressure reduction across the stratum.

This visualization demonstrates how non-linear piezoconductivity and interlayer hydraulic interaction collectively dictate pressure wave propagation velocity and overall reservoir drainage dynamics.

## RESULTS AND DISCUSSION

To validate the proposed spatio-temporal hydrodynamic solver and assess the influence of pressure-dependent non-linear piezoconductivity $k_i(p)$, numerical experiments were performed using geological and field data from the Gazli oil and gas field (Bukhara region, Uzbekistan). The simulated domain models a three-layered heterogeneous reservoir section $1000\,m \times 1000\,m \times 30\,m$ under non-stationary filtration regimes.

The spatial evolution of the pressure field $p(x,y,z,t)$ was evaluated over a $T=5days$ production interval under a constant bottom-hole pressure condition $P_w = 120\,Bar$ at the central production well $X = 500\,m, Y = 500\,m$.

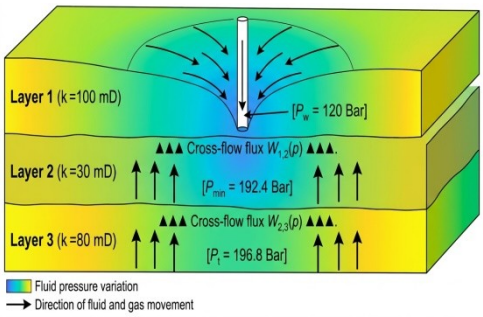



**Figure 2. Conceptual model of multi-layer non-linear filtration and cross-flow**

The total volumetric production rate $Q_{total}(t)$ is obtained by integrating radial fluxes around the wellbore control volume across all participating strata:

$$Q_{total}(t) = \sum_{k=1}^{Nz} \int_{\Gamma_w} \frac{k_k(p)}{\mu(p)} (\nabla p_k \cdot n) d\Gamma$$

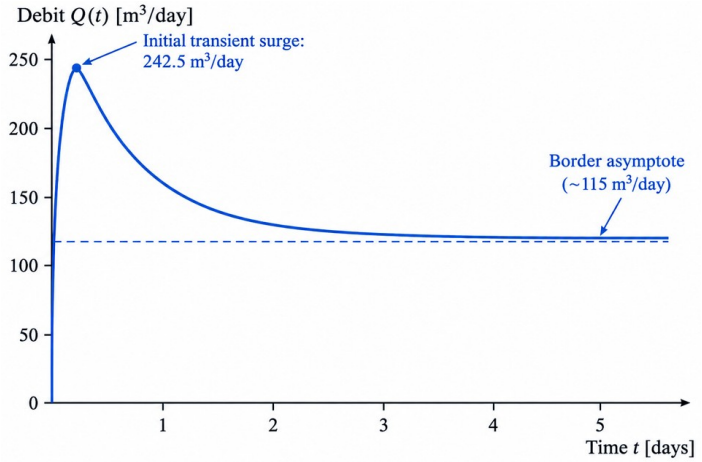



**Figure 2. Temporal dynamics of the total production flow rate Q(t) during non-stationary filtration.**

During early-time filtration $t < 15$, high initial pressure gradients drive a transient surge in production $Q \approx 242.5\,m^3/day$. As depletion expands radially and cross-flow stabilizes between strata, production asymptotes toward quasi-steady filtration $\approx 115.0 m^3/day$.

The numerical model results were compared against historical bottom-hole pressure buildup and drawdown test data collected from monitoring wells in the Gazli extraction department.

*Model validation and error evaluation against Gazli field historical data. Table 1.*

| Parameter / Metric | Historical Field Data (Gazli) | Model (Non-Linear κ(p)) | Model (Linear Constant κ) | Absolute Error (%) |
|---|---|---|---|---|
| **Wellbore** | 121.8 Bar | 120.0 Bar | 134.2 Bar | 1.47\% |

| | | | | |
|---|---|---|---|---|
| **Pressure $P_w$ (t=5d)** | | | | |
| **Interlayer Cross-flow $W_{1,2}$** | 14.2m$^3$ day | 13.8 m$^3$day | 8.5m$^3$day | 2.81\% |
| **Stabilized Well Debit $Q_{stab}$** | 118.5m$^3$day | 115.0 m$^3$day | 92.0m$^3$day | 2.95\% |

Neglecting the pressure dependence of piezoconductivity $k = const$ underestimates total reservoir drainage by over *20\%*, as constant-property assumptions fail to account for permeability degradation near depressurized wellbore zones.

## CONCLUSION

This study presents a robust mathematical framework and numerical solution methodology for simulating non-stationary, non-linear filtration processes in complex multi-layered porous media with cross-flow interaction. By integrating pressure-dependent piezoconductivity $\kappa(p)$ and non-linear hydraulic boundary coupling across adjacent strata, the developed formulation accurately captures the transient hydrodynamic behavior of heterogeneous petroleum reservoirs.

The principal scientific and practical outcomes of this research are summarized as follows:

- A three-dimensional coupled system of parabolic non-linear partial differential equations was formulated to model variable pressure propagation $p_i(x, y, z, t)$ and interlayer fluid exchange driven by vertical hydraulic gradients $W_{i,i+1}$.
- A fully implicit Finite Difference discretization integrated with a Newton-Raphson iterative solver was implemented in Python (NumPy, SciPy). This configuration ensured numerical stability across steep spatial pressure gradients and rapid transient phases near wellbore zones.
- Computational results revealed an initial high-magnitude production surge *242.5 $m^3$ day* attributable to instantaneous near-wellbore localized pressure depletion, which progressively relaxed into a stabilized quasi-steady production rate $\approx 115.0 m^3 / day$ due to continuous interbed cross-flow support.
- Comparative evaluation using historical production metrics from the Gazli oil and gas field demonstrated high predictive fidelity, reducing model error to under *3.0%, 1.47%* for bottom-hole pressure $P_w$ *and 2.95\%* for stabilized flow rate $Q_{stab}$. Conversely, conventional linear assumptions $k = const$ underestimated total reservoir drainage efficiency by more than *20%*.

The developed algorithmic modules provide a reliable quantitative tool for optimizing field development strategies, predicting interlayer fluid migration, and maximizing total recovery efficiency in multi-layered stress-sensitive reservoirs.

## REFERENCES

1. Abutaliev, F. B. *Primenenie chislennykh metodov s ispol'zovaniem EVM v gidrogeologii [Application of Numerical Methods Using Computers in Hydrogeology]*. Fan, 1976.
2. Abutaliev, F. B., Baklushin, M. B., Erbekov, Ya. S., Izmailov, N. N., Umarov, U., & Khodjibaev, N. N. *Analiz dinamiki gruntovykh vod analiticheskimi i chislennymi metodami [Analysis of Groundwater Dynamics by Analytical and Numerical Methods]*. Fan, 1975.

3. Bereslavskii, E. N. Effect of evaporation or infiltration on the free surface of groundwater in certain problems of underground hydromechanics. *Doklady Physics*, 61(6), 279–284, 2016.
4. Karimov, M. M., & Karshiyev, D. A. Modelirovanie nelineynogo protsessa filtratsii podzemnykh vod v poristoy srede [Modeling the Nonlinear Groundwater Filtration Process in a Porous Medium]. *Problems of Computational and Applied Mathematics*, (6)62, 2025.
5. Kuskovskiy, V. S., Kashevarov, A. A., & Rybakova, S. T. *Otsenka zapasov podzemnykh vod infil'tratsionnykh vodozabornykh sooruzheniy metodami matematicheskogo modelirovaniya [Assessment of Groundwater Reserves of Infiltration Water Intakes through Mathematical Modeling]*. SB RAS Publishing, 2004.
6. Musin, R. Kh., & Khramchenkov, M. G. *Vvedenie v chislennoye modelirovanie geofil'tratsii: uchebno-metodicheskoe posobie [Introduction to Numerical Modeling of Geofiltration: Educational and Methodological Guide]*. Kazan University Press, 2019.
7. Polubarinova-Kochina, P. Ya. *Teoriya dvizheniya gruntovykh vod [Theory of Groundwater Movement]* (2nd ed.). Nauka, 1977.
8. Samarskii, A. A., & Vabishchevich, P. N. *Computational Heat Transfer*. Wiley, 1995.
9. Chen, Z., Huan, G., & Ma, Y. *Computational Methods for Multiphase Flows in Porous Media*. Society for Industrial and Applied Mathematics (SIAM), 2006. https://doi.org/10.1137/1.9780898718942
10. Lie, K.-A. *An Introduction to Reservoir Simulation Using MATLAB/GNU Octave: User Guide for the MATLAB Reservoir Simulation Toolbox (MRST)*. Cambridge University Press, 2019. https://doi.org/10.1017/9781108591416
11. Ertekin, T., Abou-Kassem, J. H., & King, G. R. *Basic Applied Reservoir Simulation*. Society of Petroleum Engineers (SPE), 2001.
12. Blunt, M. J. *Multiphase Flow in Permeable Media: A Pore-Scale Perspective*. Cambridge University Press, 2017. https://doi.org/10.1017/9781316145401
13. Nazirova, E., Nematov, A., Shukurova, M. E., Artikbaeva, G., Ismailov, S., Nematov, A. R., & Matyakubov, M. Mathematical modeling of pressure-dependent variation in the hydrodynamic parameters of gas fields. *Modelling*, 7(1), 30, 2026. https://doi.org/10.3390/modelling7010030
14. Shukurova, M. E., Talipov, M., Ruziev, K., & Jurayeva, K. Advanced geospatial monitoring of oil and gas infrastructure via satellite data. *Mathematical Models in Engineering*, 12(2), 1–12, 2026.
15. Shukurova, M. E. Mathematical model of filtration process for two-phase "oil-gas" system in two-layer dynamic connection. *2023 3rd International Conference on Technological Advancements in Computational Sciences (ICTACS)*, 1–6, 2023. https://doi.org/10.1109/ICTACS59847.2023.10390246

# SOLVING THE INVERSE GRAVIMETRIC PROBLEM FOR AN OIL AND GAS DEPOSIT WITH TWO ANOMALIES

***Merey Kenzhebayeva, Simon Serovajsky**
merey-mex-2017@mail.ru
*Al-Farabi Kazakh National University, Almaty, Kazakhstan*

***ABSTRACT***

*During the exploration and operation of oil and gas fields, knowledge of their internal structure is highly desirable. Solving the inverse gravimetric problem for an oil and gas field makes it possible to accurately reconstruct the density structure given the location of an anomaly, which would considerably simplify the extraction process and the decision-making regarding well operation methods. This paper addresses the solution of the inverse gravimetric problem for an oil and gas field containing two anomalies. The mathematical model is based on the Poisson equation for the gravitational field potential, with homogeneous boundary conditions on an artificially extended domain and an additional condition specifying the vertical derivative of the potential on the surface segment where gravimeter measurements are taken. The inverse problem is reformulated as an optimization problem, in which the density values of the two anomalies are found by minimizing a quadratic functional that measures the discrepancy between the computed and measured gravitational field gradients. Since differentiating the functional leads to an adjoint problem whose right-hand side contains the derivative of a delta function — a quantity difficult to compute numerically — the derivative-free Nelder–Mead method is employed instead. Numerical experiments, implemented in Python using NumPy, OpenCV, and Matplotlib, demonstrate that the method recovers the densities of both anomalies with very high accuracy (relative errors on the order of $10^{-6}$) regardless of the initial approximation. The proposed approach enables reliable identification of subsurface anomaly densities from surface gravimetric monitoring data and offers a way to improve the accuracy of mineral resource exploration at minimal financial cost.*

*Keywords: inverse gravimetric problem, oil and gas field, density anomaly, Nelder–Mead method, Poisson equation, geodynamic monitoring*

## 1. Introduction

The oil recovery factor is generally regarded as the main criterion for evaluating the effectiveness of a field's development system. In the fields of Western Kazakhstan, the recovery factor barely reaches 35%, whereas in many countries it exceeds 50–60% [1]. This is explained by the fact that the share of hard-to-recover reserves in the mineral resource base is steadily growing, and according to some estimates [1], it already accounts for more than 40% of all discovered oil reserves.

About 160 fields are currently under development, with total oil production amounting to 90.4 million tons and gas production to 55.5 billion cubic meters, provided mainly by three fields — Tengiz, Karachaganak, and Kashagan. These account for 60% of the country's total production. The remaining 40% is produced from fields that have mostly reached a mature stage of development and are in the late stages of their operational life. As a rule, the output from these fields is heavily watered, and most of the residual reserves fall into the category of hard-to-recover reserves.

During the operation of oil and gas fields, problems arise with oil extraction. Oil can "migrate" from one location to another, and during operation its exact location becomes difficult to determine. Since exploration of a field is carried out at the initial design stage, no further analysis of location changes is performed during the subsequent production process, even as the situation evolves. Repeated exploration is not undertaken because of the high financial costs involved.

Inverse gravimetric problems involve reconstructing the structure of a given domain from measurements of gravitational field characteristics [2]. Such studies are necessary for gravimetrically based assessment of geodynamic events occurring at oil and gas fields.

By solving the inverse gravimetric problem for an oil and gas field, it is possible to detect oil and gas with sufficient accuracy without major financial expenditure, which would considerably simplify the extraction process and decision-making regarding well operation methods. The fundamentals of inverse problems in geophysics are well described in [3, 4]. Reference [2, 5] provides a detailed account of the basics of most applied inverse problems, presenting the fundamental concepts of the physical formulation of the gravimetric problem, the principles for solving forward and inverse problems in gravity exploration, and analytical methods for solving inverse problems for simple anomaly shapes.

The relevance of inverse gravimetric problems for oil and gas fields stems from the fact that significant, often undesirable, changes occur during the long-term operation of a field [6, 7, 8]. For this reason, existing fields are regularly monitored. Here we are specifically interested in gravimetric monitoring (geodynamic monitoring of oil and gas fields). Gravimeters are used to measure the acceleration of free fall, which corresponds to the gradient of the gravitational field potential [9, 10]. This experimental information can serve as the basis for formulating inverse gravimetric problems. It is well known that inverse problems are, in principle, ill-posed [11]. In particular, the values of free-fall acceleration obtained through measurement may be associated with various gravity anomalies. Thus, the solution of the inverse gravimetric problem in its full formulation is not unique. Naturally, when such a problem is solved numerically, the algorithm produces only one of these possible solutions — a result that may not correspond to reality. It may be mathematically correct yet have no practical value. For this reason, in practice only particular (restricted) inverse gravimetric problems are actually solved [12–22]. These studies differ, first, in the amount of measured information, second, in the amount of information to be identified, and third, in the research methods employed.

Reference [23] considers an anomaly in a two-layer medium and gives a brief overview of approaches to constructing Newtonian- and gradient-type iterative processes. The author and his students primarily consider integral equations for formulating inverse gravimetric problems.

References [17, 22] describe in more detail the mathematical model for formulating the forward problem, and analyze the behavior of the gravitational field potential and its gradient near the boundary condition when solving the forward gravimetric problem.

One of the most important methods for exploring and analyzing mineral deposits is associated with the detection and identification of gravitational anomalies [2, 17]. Thus, gravimetric methods are used to determine various deviations of the gravitational potential that indicate the presence of any inhomogeneities within the considered thickness of the Earth's crust. Interpreting the results obtained requires solving some form of inverse gravimetric problem [22, 19]. As is well known, inverse gravimetric problems are fundamentally ill-posed: not only is the stability of the solution with respect to input data lacking, but uniqueness of the solution is often absent as well [25]. One of the best-known optimization methods for solving inverse problems is the assembly (fitting) method proposed by Strakhov [24, 18]; more recently, this method has been modified from its original statistical form into a combined statistical–deterministic approach [20]. In this paper, a gradient-type method is used to solve the problem under consideration, which can be regularized, i.e., it is conditionally stable. Numerous studies on Newton-type methods for reconstructing the boundary of a medium in inverse gravimetric problems have been carried out in [18, 21].

The distinguishing features of the present problem are as follows: 1) since the structure of the reservoir is complex, we consider not one but two distinct inhomogeneities; 2) because we extend the domain, the gravitational field measurements end up located on an interior

surface; 3) during the analysis of the problem, it becomes clear that algorithms requiring computation of the functional's derivative are inefficient, and therefore we applied the Nelder–Mead method. The use of this method provides a sufficiently good solution to the inverse gravimetric problem with two anomalies.

**2. Problem Statement**

The mathematical formulation of the problem is based on the potential of the gravitational field generated by an anomaly. Oil and gas fields generally have a complex structure, and it is necessary to identify this structure under conditions where only a limited amount of measured information is available. We consider the reconstruction of the densities of two anomalies.

Consider a domain of certain dimensions, containing two inhomogeneities, whose locations are assumed to be known. Relying on the property that the gravitational field decreases with increasing distance from the object, we extend the domain under study in all four directions so that the gravitational field of the anomaly vanishes on the boundaries. In this way we obtain extended artificial boundaries on which the potential equals zero. For simplicity, we assume that the domain is extended by the same distance P in every direction. We take the origin of the coordinate system to be the upper-left corner of the domain under study, as shown in Figure 1. Then, along the Ox axis, we have the range from 0 to 2P + L (twice the extension P in the two directions, plus the length of the domain under study). Along the Oy axis, we have the range from –M–P to P. These will subsequently serve as the limits of integration over the domain (see Figure 1).

The mathematical model reduces to the Poisson equation

$$\Delta\, \eta(x, \mathrm{y}) = -4\pi G \psi(x, \mathrm{y})$$

with homogeneous boundary conditions

$$\eta(x, \mathrm{y})|_{\partial\Omega'} = 0$$

and an additional condition on the segment

$$\left.\frac{\partial \eta(x, y)}{\partial \mathrm{y}}\right|_{NK} = \eta_2(x)$$

located in the interior of the domain under study (the values of the gravitational field gradient recorded by gravimeters on the segment NK). The anomaly density is given by the following formula

$$\psi(x, \mathrm{y}) = \begin{cases} 0, & \text{вне } \Omega_1 \text{ и } \Omega_2 \\ \psi_1, & \text{в } \Omega_1 \\ \psi_2, & \text{в } \Omega_2 \end{cases}$$

where $\psi_1\ and\ \psi_2$are the differences between the density of the anomaly and the density of the surrounding soil.

Gravimeters measure gradients of the gravitational field annually or once every two years along a segment (on the surface of an oil field) as part of geodynamic monitoring of oil fields. After the forced expansion of the domain, the gravimeter measurements in the mathematical model formulation turn out to be specified on the interior part of the domain.

This circumstance, arising from physical considerations, makes our problem far from trivial and predetermines the methodology for its investigation.

The formulation of the inverse problem is as follows: it is necessary to determine the value of the density of inhomogeneities (4) in the extended domain under study (1–2), given known values of the vertical derivative of the field potential on the segment (3) (Fig. 1).

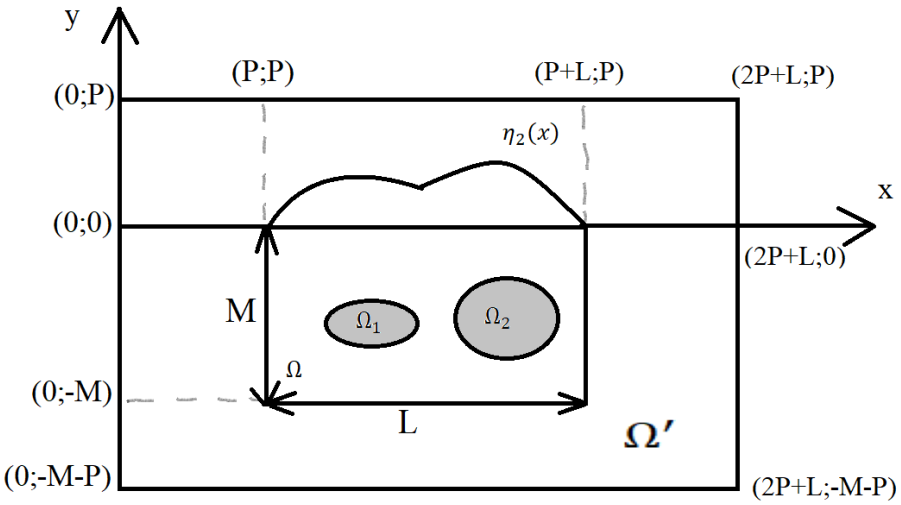



Figure 1. The domain under study.

$$\Delta\,\eta(x,\mathrm{y}) = -4\pi G\psi(x,\mathrm{y}) \tag{1}$$

$$\eta(x,\mathrm{y})|_{\partial\Omega'} = 0 \tag{2}$$

$$\frac{\partial\eta(x,y)}{\partial \mathrm{y}}\Big|_{NK} = \eta_2(x) \tag{3}$$

$$\psi(x,\mathrm{y}) = \begin{cases} 0, & \text{вне } \Omega_1 \text{ и } \Omega_2 \\ \psi_1, & \text{в } \Omega_1 \\ \psi_2, & \text{в } \Omega_2 \end{cases} \tag{4}$$

To solve the inverse problem, it is necessary to reformulate it as an optimization problem. For this purpose, we introduce a functional of the form (5) — the quadratic deviation of the values of the vertical components of the gravitational field gradient from the measured gravimeter readings.

$$I\,(\psi_1,\psi_2\,) = \int_N^K \left( \frac{\partial\eta(x,y)}{\partial \mathrm{y}}\Big|_{NK} - \eta_2(x)\right)^2 dx \to \min \tag{5}$$

Consequently, the optimization problem is formulated as follows: it is required to find the value of $\psi\,(\psi_1,\psi_2\,)$ from the condition of minimizing the functional (5).

**3. Method**

To solve the inverse problem, the forward problem must be solved repeatedly. Solving the forward problem means calculating the gravitational field gradient on the surface of the domain under study, given a known density of the anomaly and its location. An arbitrary value of the density ρ is taken as the initial approximation for the solution of the forward problem. Then, using the forward-problem solutions to search for the exact value of ρ, the functional to be minimized is constructed. That is, the quadratic difference is calculated

between the forward-problem solution (using the initial density approximation) and the forward-problem solution for the exact value.

At the first stage, we attempted to solve the formulated optimization problem using the classical gradient method. For this, the functional must be differentiated. We derived the derivative of the functional and the adjoint problem. As a result, we obtained

**Theorem 1:** The derivative of the functional I at the point $\psi\,(\psi_1, \psi_2\,)$ is equal to:

$$I_*^{'}\,(\psi_1, \psi_2) = \begin{cases} 0, & \text{вне } \Omega_1 \text{ и } \Omega_2 \\ 4\pi G \iint_{\Omega_1} p(x,y)dxdy, & \text{в } \Omega_1 \\ 4\pi G \iint_{\Omega_2} p(x,y)dxdy, & \text{в } \Omega_2 \end{cases} \tag{6}$$

where $p(x, y)$ is the solution of the adjoint system, which has the following form:

$$\begin{gathered} \triangle p(x,y) = \alpha(x)\frac{\partial}{\partial y}\left(2\left(\frac{\partial \eta(x,0)}{\partial y} - \eta_2(x)\right)\delta(y)\right) \\ p(0;y) = 0 \\ p(2P+L;y) = 0 \\ p(x;-M-P) = 0 \\ p(x;P) = 0 \end{gathered} \tag{7}$$

The complexity of this problem formulation lies in the state equation of the adjoint problem. Specifically, the right-hand side of equation (7) contains the derivative of the delta function. The derivative of the delta function is difficult to compute using numerical methods. For this reason, we decided to use a different solution method that does not require computing the gradient of the functional. The problem was solved using the Nelder–Mead method.

The Python object-oriented programming language was used to write the program. The NumPy, OpenCV, and Matplotlib libraries were actively used. Working with pixels, we studied and applied the OpenCV library. We also studied the BGR and RGB formats and the correct use of the appropriate format when working with the geological-lithological profiles of the field. The implementation of this program is based on image segmentation and finding the dominant colors in a Python environment using the OpenCV library. Image segmentation is a preliminary stage of image processing. The obtained values make it possible to determine the density distribution over the area under consideration. To convert the geological-lithological profile of the field into digital format, the "Converter" software is used [24]. The "Converter" program provides good graphical representation of the results obtained using the Matplotlib library. The program writes the final converted result as a two-dimensional array to a text file. Thus, the density matrix can be easily read for further use together with other programs.

To solve the inverse problem, the forward problem must be solved repeatedly. Recall that solving the forward problem means calculating the gravitational field gradient on the surface of the domain under study, given known densities of the anomaly and their locations. We then set aside the exact density values $(\psi_1,\ \psi_2)$ and take an arbitrary density value $\psi$ (a two-dimensional vector) as the initial approximation. Next, using the forward-problem solutions for the exact $(\psi_1,\ \psi_2)$, we construct the functional to be minimized. That is, we compute the quadratic difference between the forward-problem solution (using the initial density approximation) and the forward-problem solution for the exact $(\psi_1,\ \psi_2)$. The functional is then minimized using the Nelder–Mead method.

**4. Results**

The calculation results are shown in Table 1. Figure 2 shows the location of the anomaly. Psi_resh = (−4.999978; −5.0000053) is the result of the program's calculation (this is the found value of the density ρ). Recall that the exact solution is ρ_exact. The absolute error is Δ, and the relative error is δ. This amounts to an error of (0.000004%; 0.000001%). The value of the functional (6) is close to zero, meaning it is nearly zero. That is, we obtained a very good solution to the problem.

Since we are solving the inverse gravimetric problem for an oil and gas field with two anomalies based on exploratory geological-lithological profiles, we already have an approximate location of the anomaly. And based on the gravimetric readings on the Earth's surface, we can determine the density of the underground anomaly quite accurately.

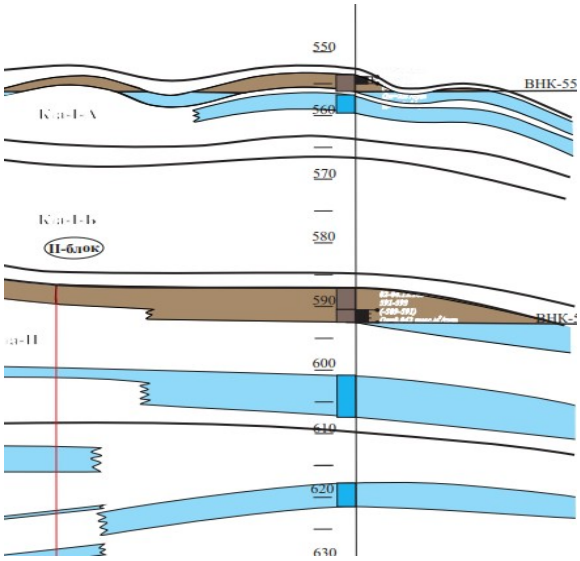



Figure 2. Location of the anomaly in the domain under study.

*Table 1. Results of calculations for the inverse gravimetric problem using the Nelder–Mead method.*

| name | value |
|---|---|
| Exact density values of the anomaly | (-5; -5) |
| Result of the inverse problem solution | (-4.999978; -5.0000053) |
| Absolute error | $(2.17\times10^{-5}; 5.32\times10^{-6})$ |
| Relative error. | $(4.34\times10^{-6}; 1.065\times10^{-6})$ |
| Value of the functional | $3.87\times10^{-12}$ |

Calculations were carried out with different parameter values: 1) changing the location of the two anomalies, 2) changing the sizes of the two anomalies, 3) changing the density values of the two anomalies themselves, 4) changing the value of epsilon for minimizing the functional, 5) changing the initial approximation of the density values. In all cases, the accuracy of the reconstructed information was approximately the same. The densities of the two anomalies are recovered very well. The error in reconstructing the densities of the inhomogeneities is (0.000004%; 0.000001%). The reconstruction occurs quickly and accurately. Consequently, the Nelder–Mead method reconstructs the densities of the two anomalies very well.

The calculations showed that the initial approximation has little influence on the final result. Any initial approximation can be used (except zero). The amount of computation does not change significantly depending on the initial approximation, since the iteration step of the Nelder–Mead method is fairly large at the initial stage, which allows the exact solution to be reached quickly with a minimal number of iterations.

## 5. Discussion

The results obtained demonstrate that the inverse gravimetric problem for oil and gas fields can be effectively solved by reformulating it as an optimization problem and applying a derivative-free numerical method. The initial attempt to use the classical gradient method revealed a fundamental difficulty: the adjoint equation contains the derivative of the delta function on its right-hand side, which is extremely difficult to compute numerically with acceptable accuracy. This obstacle motivated the shift to the Nelder–Mead method, which does not require gradient information and instead relies on direct comparison of functional values.

The numerical experiments confirm that this approach yields highly accurate results. For the two-anomaly case considered, the relative error in the reconstructed density values did not exceed 0.000004%, and the value of the minimized functional approached zero (on the order of $10^{-12}$), indicating that the recovered solution is very close to the exact one.

A series of additional computations, in which the location, size, density, minimization tolerance (epsilon), and initial approximation of the anomalies were varied, showed that the reconstruction accuracy remained consistently high across all these scenarios. This robustness suggests that the method is not sensitive to the particular configuration of the anomalies or to the choice of initial approximation — any nonzero starting value produced comparably accurate results within a similar number of iterations. This is an important practical advantage, since in real geophysical applications the true density distribution is unknown, and a method whose performance does not critically depend on a good initial guess is considerably more reliable.

The relatively large step size of the Nelder–Mead method at the early iterations appears to be the main reason for the fast convergence, allowing the algorithm to approach the exact solution within a small number of steps regardless of the starting point. This behavior is particularly valuable in the context of geodynamic monitoring of oil fields, where computational efficiency is important given the need for repeated solution of the forward problem.

It should be noted that the practical applicability of the method benefits from the fact that, for real fields, an approximate location of subsurface anomalies is typically already known from exploratory geological-lithological profiles. Combined with surface gravimetric measurements, this a priori information allows the density of underground anomalies to be determined with high precision, as demonstrated by the numerical results.

## 7. Conclusion

In this work, an inverse problem of gravimetry for determining the density of subsurface inhomogeneities in oil and gas fields was formulated and solved. The problem was reduced to a minimization problem for a quadratic functional representing the deviation between computed and measured values of the vertical component of the gravitational field gradient.

An attempt to solve the problem using the classical gradient method showed that the corresponding adjoint problem involves the derivative of the delta function, which is not amenable to accurate numerical computation. To overcome this difficulty, the Nelder–Mead method was employed, which does not require computation of the functional's gradient.

A program was developed in Python using the NumPy, OpenCV, and Matplotlib libraries, incorporating image segmentation techniques to extract density information from geological-lithological profiles converted into digital format using the "Converter" software.

Numerical experiments for a model with two anomalies demonstrated excellent agreement between the reconstructed and exact density values, with relative errors on the order of $10^{-6}$–$10^{-5}$ % and functional values approaching zero. Variation of the anomalies' location, size, density, minimization tolerance, and initial approximation confirmed the stability and reliability of the method: the quality of reconstruction remained consistently

high, and the choice of initial approximation had little effect on the final result or the computational cost.

These results indicate that the proposed approach combining a derivative-free optimization method with a priori geological information provides an effective and computationally efficient tool for solving the inverse gravimetric problem in the context of geodynamic monitoring of oil and gas fields. Future work may extend this methodology to more complex anomaly configurations and three-dimensional density distributions, as well as explore its performance under noisy or incomplete gravimetric data typical of real field measurements.

## References

1. Kursiv.kz. Problemy dobychi na zrelykh neftyanykh mestorozhdeniyakh obsudili vkursiv.kz, 2019.

2. Serovajsky S.Ya., Azimov A.A., Kenzhebayeva M.O., Nurseitov D.B., Nurseitova A.T., Sigalovskiy M.A. Mathematical Problems of Gravimetry and its Applications. International Journal of Mathematics and Physics, 2019.

3. Romanov V.G., Kabanikhin S.I. Obratnye zadachi geoelektriki. Nauka, 1991.

4. Kabanikhin S.I. Obratnye i nekorrektnye zadachi. Sibirskoe nauchnoe izdatelstvo, 2009.

5. Kabanikhin S.I., Iskakov K.T., Bektemesov M.A., Shishlenin M.A. Algoritmy i chislennye metody resheniya obratnykh i nekorrektnykh zadach. Izdatelstvo ENU im. Gumileva, 2011.

6. Nesterenko Yu.M., Nesterenko M.Yu., Dnistryanski V.I., Glyantsev A.V. Influence of the Development of Hydrocarbon Deposits on Geodynamics and Water Systems of the Southern Urals Region. Bulletin of the Orenburg Scientific Center, Ural Branch of the Russian Academy of Sciences, 2010.

7. Kuz'min Yu.O. Modern Geodynamics and Geodynamic Risk Assessment for Subsoil Use. AEN, 1999.

8. Chernykh V.A. Hydro-Mechanics of Oil and Gas Production. VNIIGAZ, 2001.

9. Virtanen H. Studies of Earth Dynamics with Superconducting Gravimeter. University of Helsinki, Geodetiska Institutet, 2006.

10. Vinogradov V.B., Bolotnova L.A. Gravimeters. UGGU Publ., 2010.

11. Kabanikhin S. Inverse and Ill-posed Problems: Theory and Applications. Walter de Gruyter, 2012.

12. Strakhov V.N., Lapina M.I. The Assembly Method for Solving the Inverse Problem of Gravimetry. Reports of the USSR Academy of Sciences, 1976.

13. Misici L., Zirilli F. The Inverse Gravimetry Problem: An Application to the Northern San Francisco Craton Granite. Journal of Optimization Theory and Applications, 1989.

14. Barzaghi R., Sansò F. The Integrated Inverse Gravimetric-Tomographic Problem: A Continuous Approach. Inverse Problems, 1998.

15. Michel V. Regularized Wavelet-Based Multiresolution Recovery of the Harmonic Mass Density Distribution from Data of the Earth's Gravitational Field at Satellite Height. Inverse Problems, 2005.

16. Jacoby W., Smilde P. Gravity Interpretation: Fundamentals and Application of Gravity Inversion and Geological Interpretation. Springer Science & Business Media, 2009.

17. Prutkin I., Saleh A. Gravity and Magnetic Data Inversion for 3D Topography of the Moho Discontinuity in the Northern Red Sea Area. Journal of Geodynamics, 2009.

18. Balk P.I., Yeske A. Fitting Approach of V.N. Strakhov to Solving Inverse Problems of Gravity Exploration: Up-to-Date Status and Real Abilities. Geophysical Journal, 2013.

19. Vasin V.V., Akimova E.N., Miniakhmetova A.F. Iterative Newton Type Algorithms and Its Applications to Inverse Gravimetry Problem. Vestnik of the South Ural State University. Series: Mathematical Modelling and Programming, 2013.

20. Akimova E.N., Vasin V.V., Misilov V.E. Algorithms for Solving Inverse Gravimetry Problems of Finding the Interface Between Media on Multiprocessing Computer Systems. Vestnik of Ufa State Aviation Technical University, 2014.

21. Balk P., Dolgal A., Balk T., Khristenko L. Joint Use of Inverse Gravity Problem Methods to Increase Interpretation Informativity. Geofizicheskiy Zhurnal, 2017.

22. Toyganbayeva N.A., Nurseitov D.B., Kenzhebayeva M.O. Converter — programma-preobrazovatel, perevodyashchee geologo-litologicheskiy profil mestorozhdeniya v tsifrovoy format. Author's Certificate of the Republic of Kazakhstan No. 9556, 2020.

# ОБРАТНЫЕ ЗАДАЧИ ДЛЯ УРАВНЕНИЯ ТЕПЛОПРОВОДНОСТИ В ДВУМЕРНОЙ АНИЗОТРОПНОЙ СРЕДЕ.

А.О. Асубай, Б. Рысбайулы
e-mail: azo31@mail.ru
*Казахский национальный университет им.Аль-Фараби,*

***Аннотация.*** *Нахождение коэффициентов теплопроводности в анизотропной среде.*

Анализ современного состояния исследования явлений конвективного переноса теплоты в анизотропных пористых средах.

Интенфикация конветивного переноса теплоты в технических и технологических системах является еще не разрешенный до конца проблемой [1-3], от которой зависит уменьшение габаритно – массовых характеристик теплопередающих аппаратов и увеличение их тепловой производительности. Классические способы интенсификации конвективный теплопередачи таковы [4]: снижение термического сопротивления; увеличение скорости теплоносителей; применение развитых поверхностей; турбулизация потока. При этом обязательно возникают дополнительные расходы энергии на увеличение импульса теплоносителя. То есть сравнение интенсивности теплопередачи корректно лишь при одинаковой расходной мощности на движение теплоносителей [5].

Интегральное термическое сопротивление определяется толщиной пограничного слоя, который нужно либо уменьшить, а еще лучше разрушить [6]. Поэтому все перечисленные методы интенсификации теплопередачи, по существу, направлены на решение этой проблемы , однако их возможности практически уже исчерпаны.

В связи с этим сформировался тренд использования для идентификаций теплопередачи пористых материалов, обладающих существенно развитой поверхностью в единицу объема. Теоретическое и экспериментальное изучение теплообменных элементов с пористыи накопителями подтвердило их эффективность. Наличие природных пористых сред с отсутствием геометрической симметрии инициировало исследование влияния анизотропности на физические свойств, лавные из которых проницаемость и теплопроводность.

Решая прямую задачу можно увидеть распределения тепла на двумерной анизотропной среде. После минимизировав функционал, и составления вычислительной программы решая обратную задачу можно найти необходимые коэффициенты.

**Литература:**

1. А. А. Жухаускас. Конвективный перенос в теплообменниках М.: Наука, 1982. - 472 с.
2. В. С. Авдуевский. Основы теплопередачи в авиационной и ракетно-космической технике - Машиностроение, 1992.-528с.
3. A. Bejan. Concrection heat transfer - NY: John Wiley&Sons, Inc., 2004.- 673p.
4. А. С. Горшенин. Методы интенсификации теплообмена. Самарский государственный университет, 2009.- 82с.
5. Д. Д. Калафати , В. В. Попалов. Оптимизация теплообменников по эффективности теплообмена. Энергоатомиздат, 1986.-152с.
6. Г. А. Кардашев. Физические методы интенсификации процессов химической технологий. Химия, 1980.- 208с.

# МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПРИ УПРАВЛЕНИИ ГАЗОДЫМОЗАЩИТНОЙ СЛУЖБОЙ

**А. Т. Алдабеков[1], Торобеков Б.Т.[2]**

[1]Академия гражданской защиты им. М. Габдуллина МЧС РК, Казахстан, e-mail: tushila_010@mail.ru

[2] Кыргызский государственный технический университет им. И. Раззакова, Кыргызская Республика, e-mail: bekjan2003@mail.ru

***Аннотация.***

*В статье рассматривается математическая модель поддержки принятия решений при управлении газодымозащитной службой (ГДЗС) в условиях применения средств автоматизации и технических средств для передачи данных (датчики телеметрий). Исследование направлено на повышение эффективности организационной структуры управления звеньями ГДЗС, снижение информационной нагрузки на должностных лиц и вероятности ошибок при выполнении расчётно-контрольных операций. Методологическую основу составили методы теории управления, теории вероятностей и математической статистики, теории множеств, концептуального и имитационного моделирования. Для описания вероятностных состояний технической системы применён аппарат уравнений Эрланга как частный случай системы уравнений Колмогорова. Предложен подход к оценке организационной структуры с учётом резервирования управленческих функций. Разработаны алгоритмы выбора структуры управления и распределения функций между должностными лицами. Экспериментальная проверка с участием 105 человек показала устойчивое снижение количества расчётных ошибок при переходе от ручных вычислений к техническим и программным средствам.*

***Ключевые слова:*** *газодымозащитная служба, принятие решений, математическая модель, организационная структура, резервирование функций, телеметрия, автоматизация, человеческий фактор.*

**Введение.**

Деятельность ГДЗС при тушении пожаров характеризуется выполнением работ в условиях ограниченной видимости, воздействия опасных факторов пожара, дефицита времени и неполноты оперативной информации. Эффективность применения звеньев ГДЗС определяется не только техническими характеристиками средств индивидуальной защиты органов дыхания (СИЗОД), но и качеством организации управления, своевременностью получения информации и обоснованностью принимаемых решений[5].

Анализ функционирования ГДЗС Республики Казахстан показывает необходимость совершенствования механизмов управления на основе математического моделирования, автоматизированной обработки информации и телеметрического контроля. Ранее выполненное математическое моделирование применения звеньев ГДЗС подтвердило возможность применения методов системного анализа для прогнозирования параметров функционирования службы [1].

Цель настоящей работы заключается в развитии математического и алгоритмического обеспечения поддержки принятия решений при управлении ГДЗС с учётом состояния технических средств, организационной структуры, резервирования управленческих функций и влияния человеческого фактора.

**Постановка проблемы.**

Система управления ГДЗС на пожаре представляет собой организационно-техническую систему, включающую руководителя тушения пожара, контрольно-пропускной пункт ГДЗС, посты безопасности, командиров звеньев и газодымозащитников. При увеличении количества одновременно работающих звеньев возрастает объём информации о состоянии личного состава и СИЗОД, а также количество расчётных, контрольных и управленческих операций [6].

Использование подхода с применением телеметрии позволяет сформировать информационный контур, при котором параметры работы звена автоматически передаются в информационно-аналитическую систему (ИАС), обрабатываются и представляются руководителю тушения пожара (РТП) лицу, принимающему решение. Обобщённая схема предлагаемого взаимодействия представлена на рис.1.




Рисунок 1. Общая схема системы поддержки принятия решений при управлении ГДЗС

В рамках такого подхода телеметрические средства обеспечивают получение исходных данных, ИАС выполняет их обработку и расчёт параметров, а РТП осуществляет оценку оперативной обстановки и принимает окончательное управленческое решение.

**Обзор литературы.**

Математические методы поддержки управления пожарно-спасательными подразделениями развиваются в направлении применения вероятностных, имитационных, информационных и многокритериальных моделей. В исследованиях Д. В. Тараканова получили развитие многокритериальные модели и методы поддержки управления пожарными подразделениями на основе мониторинга динамики пожара [2].

В ранее выполненном исследовании А. Т. Алдабекова математическое моделирование применено для анализа и прогнозирования количества пожаров с привлечением ГДЗС в Республике Казахстан [1]. Вместе с тем для развития системы поддержки принятия решений требуется учитывать не только параметры отдельных звеньев, но и распределение функций между должностными лицами, возможность их передачи и резервирования.

**Материалы и методы.**

Методологическую основу исследования составили методы теории управления, элементы теории вероятностей и математической статистики, теория множеств, концептуальное и имитационное моделирование [3].

**Моделирование технической составляющей.**

Программно-аппаратный комплекс системы телеметрии (ПАКСТ) рассматривается как совокупность измерительных средств, каналов передачи информации и программно-аппаратных средств обработки данных. Для математического описания вероятностных состояний технической системы использована система уравнений Эрланга как частный случай системы уравнений Колмогорова [3].

$$P(t) = \{P_0(t), P_1(t), \ldots, P_i(t)\}, \quad (1)$$

где, $P_0(t)$ характеризует исправное состояние рассматриваемых элементов; $P_1(t)$ — состояние при отказе одного элемента; $P_i(t)$ — состояние при отказе i элементов. Упрощённое графическое представление переходов между состояниями показано на рис.2.

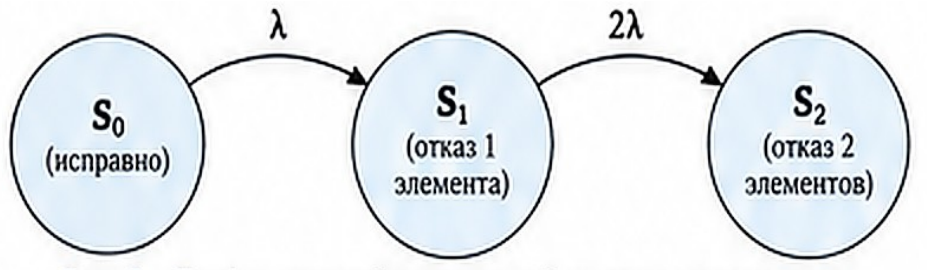



Рисунок 2. Граф состояний технической системы телеметрии

Такое представление позволяет связать техническую надёжность телеметрического комплекса со временем его функционирования и количеством контролируемых элементов.

**Модель резервирования функций управления.**

$$S = \{s_1, s_2, \ldots, s_n\} \quad (2)$$

$$F = \{f_1, f_2, \ldots, f_m\} \quad (3)$$

Распределение функций между элементами структуры описывается матрицей специализации $Q = ||q_{ij}||$, где $q_{ij}$ характеризует закрепление соответствующей функции за определённым элементом организационной структуры.

$$f_j: s_i \rightarrow s_{i+r_1} \rightarrow s_{i+r_2} \quad (4)$$

Для критически значимых функций предусматриваются основной исполнитель, первый резерв и второй резерв. Принцип резервирования представлен на рис.3.

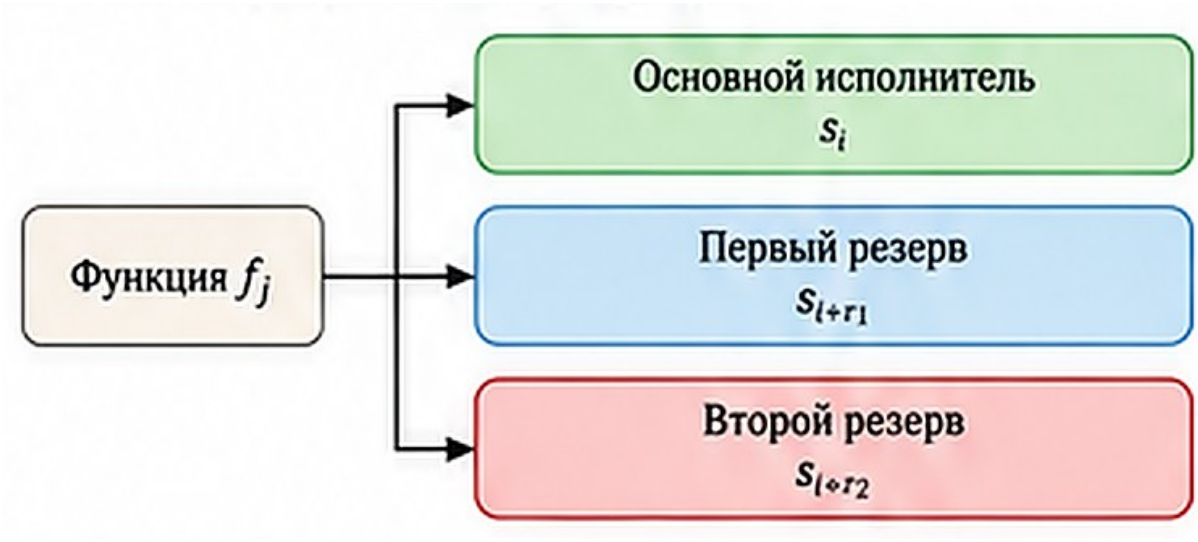



Рисунок 3. Схема резервирования управленческой функции

Такой подход позволяет исследовать устойчивость непосредственно организационной структуры: при невозможности выполнения функции основным элементом предусматривается её передача резервному исполнителю.

**Алгоритм поддержки принятия решений.**

На основе предложенного подхода разработан комплекс алгоритмов, включающий выбор типа структуры системы управления, принятие решения о создании КПП ГДЗС, распределение функций КПП, передачу управленческих функций РТП и распределение функций между должностными лицами на пожаре [3]. Обобщённая логика выбора структуры представлена на рис.4.




Рисунок 4. Блок-схема алгоритма выбора структуры управления ГДЗС

$$D(t) \rightarrow X(t) \rightarrow M(t) \rightarrow S^* \rightarrow F^* \rightarrow \text{IPTП} \rightarrow U(t), \quad (5)$$

где, D(t) — исходные данные; X(t) — оцененное состояние звеньев; M(t) — результат математической обработки; S* — выбранная организационная структура; F* — распределение функций; IPTП — информация для лица, принимающего решение; U(t) — управляющее воздействие.

**Имитационное и экспериментальное исследование.**

Для апробации математического аппарата использовалось имитационное моделирование случайных процессов. При моделировании динамики падения давления в баллонах дыхательных аппаратов использовался показательный закон распределения, а при моделировании информации о предпочтениях лица, принимающего решение, — нормальный закон распределения [3].

Для экспериментальной оценки влияния способа выполнения расчётов на вероятность возникновения ошибок проведено исследование с участием 105 человек. Сравнивались четыре способа: ЭК1 — арифметический расчёт без вспомогательных средств; ЭК2 — калькулятор и бумага; ЭК3 — специальная таблица; ЭК4 — мобильное приложение «Калькулятор ГДЗС» [3].

**Результаты и обсуждение**.

**Результаты оценки технической надёжности.**

Для оценки безотказности телеметрической системы рассмотрены варианты подключения к ПАКСТ одного и двух звеньев ГДЗС. Аналитическое решение для варианта двойного резервирования получено с использованием преобразования Лапласа, матричного представления системы и формул Крамера [3].

$$\alpha = 0{,}5; \quad \lambda = 0{,}01 \text{ мин}^{-1}; \quad t = 30 \text{ мин} \quad (6)$$

В расчётном примере при втором варианте работы вероятность безотказного функционирования оказалась ниже на 10 % по сравнению с вариантом подключения одного звена [3]. Характер изменения вероятности безотказной работы во времени представлен на рис.5.

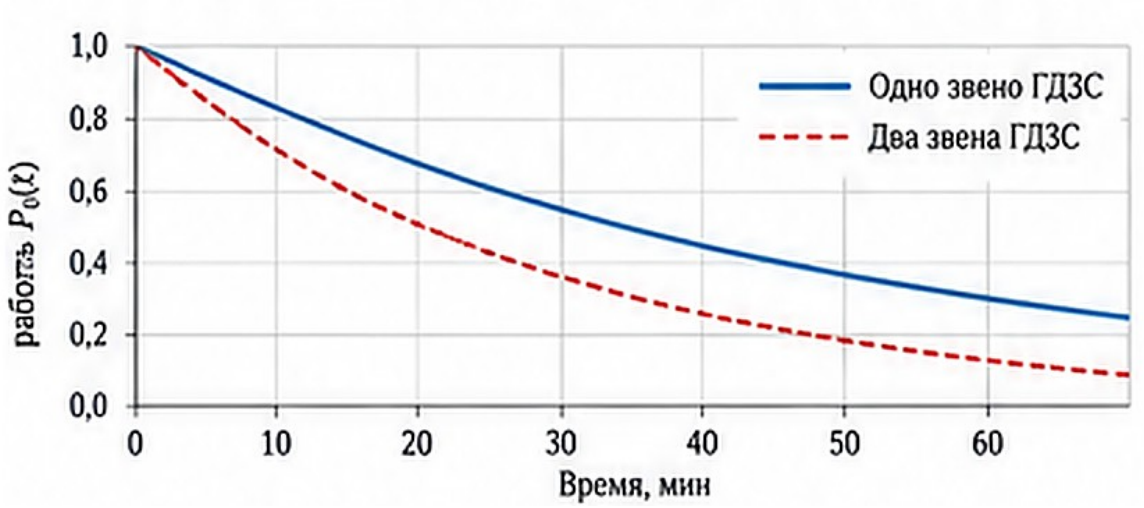



Рисунок 5 – Изменение вероятности безотказной работы технической системы во времени

Результат показывает необходимость учитывать изменение нагрузки на программно-аппаратную часть системы при увеличении количества одновременно контролируемых звеньев.

**Результаты совершенствования организационной структуры.**

Для оценки организационного эффекта рассмотрены два сценария: традиционная структура и структура с использованием телеметрического контроля. Исходные расчётные результаты представлены в таблице 1 [3].

*Таблица 1. Сравнение организационных сценариев управления*

| **Количество работающих звеньев** | **Традиционная структура, чел.** | **Телеметрический сценарий, чел.** | **Разница, чел.** |
|---|---|---|---|
| 1 | 7 | 7 | 0 |
| 2 | 11 | 10 | 1 |
| 3 | 18 | 13 | 5 |
| 4 | 22 | 16 | 6 |
| 5 | 29 | 22 | 7 |
| 10 | 52 | 40 | 12 |

Наиболее выраженный относительный результат получен при одновременной работе трёх звеньев: расчётная численность элементов структуры изменяется с 18 до 13 человек. Разница составляет 5 человек, или 27,8 % [3]. Графическая интерпретация результатов представлена на рис.6.

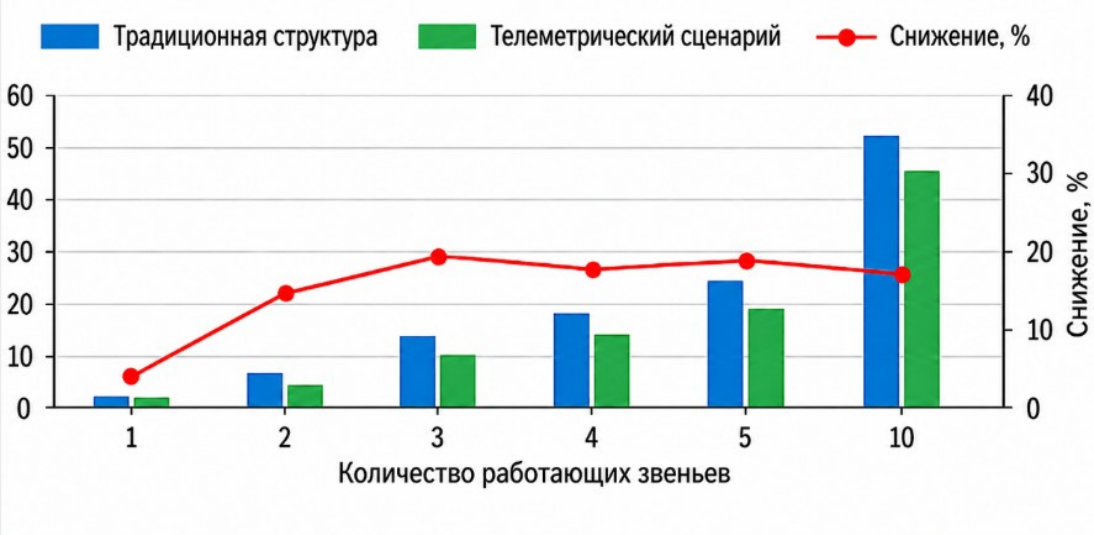



Рисунок 6 – Сравнение организационных сценариев в зависимости от количества работающих звеньев ГДЗС

Полученный результат следует интерпретировать не как непосредственное сокращение штатной численности ГДЗС, а как возможность перераспределения персонала между информационно-контрольными и оперативными функциями.

**Результаты экспериментальной оценки человеческого фактора.**

Экспериментальная часть позволила оценить влияние способа выполнения расчётных операций на количество допускаемых ошибок. Для всех пяти групп установлена общая тенденция: наибольшее количество ошибок наблюдалось при ЭК1; применение калькулятора, специальной таблицы и программного средства последовательно улучшало результаты [3]. Сравнительная визуализация представлена на рис.7.

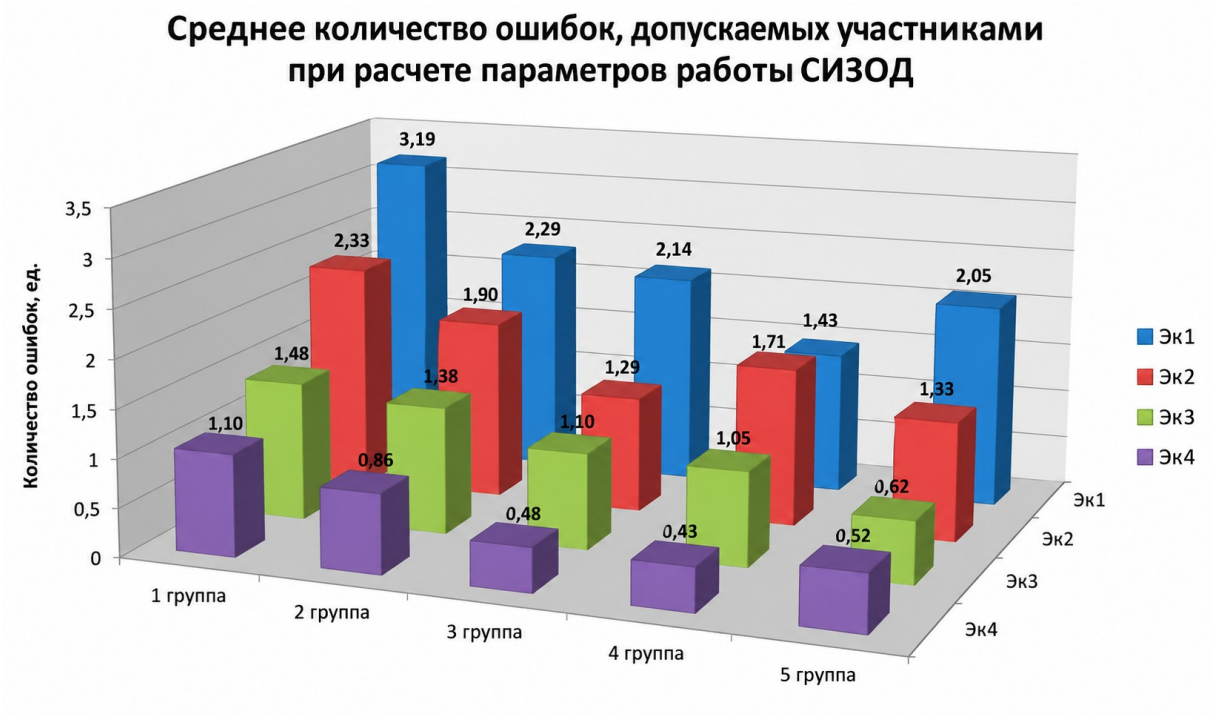



Рисунок 7. Результаты экспериментальной оценки влияния способа расчёта на количество ошибок

Полученные данные подтверждают целесообразность автоматизации повторяющихся информационно-расчётных операций. При этом автоматизация не исключает человека из системы управления, а обеспечивает лицо, принимающее решение, своевременной и формализованной информацией.

**Заключение**.

В результате исследования сформирован математический подход к поддержке принятия решений при управлении газодымозащитной службой, объединяющий техническую надёжность, организационную структуру, резервирование функций и влияние человеческого фактора.

Разработана модель оценки организационной структуры управления, предусматривающая основное выполнение, резервирование и двойное резервирование функций. На её основе сформирован комплекс алгоритмов выбора структуры и перераспределения функций между элементами системы управления.

Сравнительный анализ организационных сценариев показал возможность перераспределения личного состава, занятого информационно-контрольными операциями. Для сценария с тремя работающими звеньями расчётная разница составила 5 человек, или 27,8 %. Экспериментальное исследование с участием 105 человек подтвердило тенденцию снижения количества ошибок по мере перехода от ручного расчёта к техническим и программным средствам.

Предлагаемый подход создаёт основу для построения информационно-аналитической системы, в которой телеметрические средства обеспечивают получение исходных данных, математические модели — их обработку и оценку, алгоритмы — выбор структуры и распределение функций, а окончательное решение принимается ответственным должностным лицом.

**Литература.**

1. Алдабеков А. Т. Математическое моделирование применения звеньев газодымозащитной службы в Республике Казахстан // Сибирский пожарно-спасательный вестник. 2024. № 4. С. 44–49. DOI: 10.34987/vestnik.sibpsa.2024.45.94.005.

2. Тараканов Д. В. Многокритериальные модели и методы поддержки управления пожарными подразделениями на основе мониторинга динамики пожара в здании: дис. ... д-ра техн. наук. Москва, 2018. 340 с.

3. Алдабеков А.Т. Разработка математической моделей для оценки качества внедрение системы телеметрии в управление организационной структуры газодымозащитной службы / А. Т. Алдабеков , В.В.Теребнев, А.С.Зюкова// Вестник Дагестанского государственного технического университета. Технические науки, принято для издания в №4 (52), декабрь 2025 г.

4. Об утверждение наставления по организации газодымозащитной службы органов государственной противопожарной службы Министерства по чрезвычайным ситуациям Республики Казахстан: приказ КПС МЧС РК от 08.09.2022 г. №2. – URL: https://www.gov.kz/memleket/entities/kps/documents/details/381668?lang=ru&ysclid=lw8rxudf9h454466110

5. Коршунов И. В., Смагин А. В., Теребнев В. В., Муратов Ю. В. Методика оценки оперативно-тактических возможностей звеньев ГДЗС при проведении спасательной операции людей //Материалы 8-й Международной научно-практической конференции «Пожаротушение: проблемы, технологии, инновации». Академия ГПС МЧС России, Москва, 2022. С. 93-97.

6. Коршунов И. В., Смагин А. В., Теребнев В. В., Массерова И. В. Оценка тактических возможностей звеньев газодымозащитной службы // Пожары и чрезвычайные ситуации: предупреждение, ликвидация. 2024. № 1. С. 39–46. DOI:10.25257/ FE.2024.1.39-46

7. Гринченко Б. Б. Структура информационной системы поддержки управления безопасностью газодымозащитников // Технологии техносферной безопасности. 2019. № 3(85). С. 77–85. DOI:10.25257/TTS.2019.3.85.77-85

8. Алехин Е.М., Брушлинский Н.Н., Коломи-ец Ю.И., Соколов С.В., Вагнер П. Проблемно-ориентированные имитационные системы для автоматизированного проектирования и стратегического управления экстренными и аварийно-спасательными службами городов // Вестник РАЕН. 2012. Т. 12. № 3. С. 27-34. URL: https:// elibrary.ru/item.asp?id=23640414

9. Михайлов К. А. Модель для информационной поддержки управления пожарными подразделениями при тушении пожаров в зданиях / К. А. Михайлов // Технологии техносферной безопасности. – 2022. – № 2(96). – С. 141-150. – DOI 10.25257/TTS.2022.2.96.141-150. – EDN MXDXGK.

**Сведения об авторе**

Алдабеков Аслан Такенович, старший преподаватель кафедры ПС и ФП Академия гражданской защиты имени Малика Габдуллина Министерства по чрезвычайным ситуациям Республики Казахстан, e-mail: tushila_010@mail.ru

Торобеков Бекжан Торобекович, доктор технических наук, профессор кафедры ОПУТ Кыргызского государственного технического университета им. И. Раззакова, г. Бишкек, ORCID: https://orcid.org/0000-0003-3330-3799 , e-mail: bekjan2003@mail.ru

# OPTIMAL AI USE IN EDUCATION: A MULTI-OBJECTIVE MATHEMATICAL OPTIMIZATION MODEL BALANCING LEARNING PERFORMANCE AND COGNITIVE INDEPENDENCE

**Duran V., Yusubov Ç.**
e-mail: volkan.duran8@gmail.com; Çərkəz.yusubov@aztu.edu.az
*Iğdır University, Türkiye; Azerbaijan Technical University, Azerbaijan*

*Annotation. Generative artificial intelligence (GenAI) can improve immediate task performance, yet unrestricted assistance may reduce the cognitive effort that supports retention, transfer, and independent reasoning. This paper formulates educational AI use as a nonlinear bi-objective optimization problem in which assisted learning performance and cognitive independence are treated as distinct objectives. Concave quadratic response functions are used to derive the single-objective maxima, the Pareto-efficient set, a weighted-sum decision rule, and an independence-constrained solution. The mathematical analysis corrects a common oversimplification: increasing the weight on performance does not necessarily increase the optimal AI-use level unless a specific parameter condition is satisfied. An illustrative numerical example is used only to demonstrate model behavior; no empirical threshold is claimed. The framework is intended as a transparent basis for future experimental parameter estimation, sensitivity analysis, and context-specific educational policy.*

## 1. INTRODUCTION

Large language models can support explanation, feedback, drafting, problem solving, and personalized learning, but the educational value of such support cannot be represented adequately by a single outcome such as the quality of an AI-assisted product. Reviews of large language models in education identify substantial opportunities alongside practical, ethical, transparency, and human-oversight challenges [1, 2]. Recent meta-analytic evidence also indicates that GenAI can improve several learning outcomes on average, while effects vary substantially across learner, task, and design conditions [3].

A central difficulty is that assisted performance and independent learning are not identical constructs. Fan et al. [4] reported that ChatGPT support improved essay scores relative to comparison conditions without equivalent gains in knowledge-related outcomes, and raised concerns about metacognitive laziness. Cognitive offloading theory explains why external tools can reduce internal processing demands [5]. In a randomized controlled trial, unrestricted ChatGPT-assisted study was associated with lower delayed retention than traditional study [6]. At the same time, recent work shows that AI-supported offloading should not be treated as uniformly harmful: dependent offloading and autonomous, scaffolded offloading have different associations with perceived cognitive outcomes [7].

These findings motivate a multi-objective formulation. Educational decision makers may wish to increase assisted learning performance while preserving the learner's ability to retrieve, reason, transfer, evaluate, and solve problems without continuous AI support. Multi-objective optimization is designed precisely for problems in which no single feasible decision simultaneously maximizes all objectives [8, 9]. The research question is therefore: How should AI-assistance intensity be selected when assisted performance and cognitive independence are simultaneous and potentially conflicting objectives?

## 2. MATHEMATICAL FORMULATION

Let $x \in [0,1]$ denote normalized AI-assistance intensity, where $x = 0$ means no permitted AI assistance and $x = 1$ means the maximum assistance allowed by the learning environment. In an empirical application, x should be operationalized by a reproducible assistance protocol (for example, allowed functions, number of prompts, degree of answer generation, or an experimentally assigned assistance dose), not merely by self-reported usage frequency. Let $P(x)$ denote a normalized assisted-performance outcome and $C(x)$ a

normalized measure of cognitive independence. Both should be placed on comparable or explicitly standardized scales before a weighted aggregation is interpreted.

A parsimonious concave response is assumed for assisted performance: initial AI support can yield sizable gains, but marginal gains diminish.

$$P(x) = P_0 + ax - bx^2, \quad a > 0,\ b > 0 \tag{1}$$

Cognitive independence is allowed to receive a small initial scaffolding benefit while declining under excessive substitution of learner thinking:

$$C(x) = C_0 + gx - dx^2, \quad g \geq 0,\ d > 0 \tag{2}$$

The parameter g captures autonomy-supportive scaffolding at low intensity, whereas d captures the curvature of the independence cost at higher intensity. The quadratic form is not asserted as a psychological law; it is a transparent response-surface approximation that can later be replaced by empirically estimated nonlinear functions.

Because both functions are strictly concave, their unconstrained interior maximizers are a/(2b) and g/(2d). After respecting x ∈ [0,1], define

$$x_P = clip[a/(2b),\ 0,\ 1], \quad x_C = clip[g/(2d),\ 0,\ 1] \tag{3}$$

where clip[z,0,1] = min(1,max(0,z)). The bi-objective problem is

$$maximize\ \{P(x),\ C(x)\} \quad subject\ to\ 0 \leq x \leq 1 \tag{4}$$

For the one-dimensional, strictly concave case used here, if $x_C < x_P$, every x ∈ [$x_C$, $x_P$] is Pareto efficient: moving left improves C but lowers P, whereas moving right improves P but lowers C. If $x_P < x_C$, the efficient interval is [$x_P$, $x_C$]; if $x_P = x_C$, the efficient set collapses to a singleton. Thus, the model yields an efficient set rather than a universal scalar optimum. The image of this set in objective space is the Pareto frontier.

### 3. SCALARIZATION, SENSITIVITY, AND CONSTRAINTS

When a single operational decision is required, one possible scalarization is a weighted utility:

$$U(x) = \lambda P(x) + (1 - \lambda)C(x), \quad 0 \leq \lambda \leq 1 \tag{5}$$

For an interior solution, differentiation gives the stationary point below; the clip operator enforces feasibility:

$$x^*(\lambda) = clip\{[\lambda a + (1 - \lambda)g] / [2(\lambda b + (1 - \lambda)d)],\ 0,\ 1\} \tag{6}$$

The weight λ is normative rather than empirical: it represents the relative value assigned to assisted performance versus cognitive independence. Its interpretation is meaningful only when objective scaling has been handled explicitly. A mathematically important qualification is that x*(λ) does not always increase as more weight is placed on performance. For an interior solution,

$$dx^*/d\lambda\ has\ the\ sign\ of\ (ad - gb) \tag{7}$$

Therefore, increasing λ raises the recommended AI intensity only when ad > gb; it lowers it when ad < gb and leaves it unchanged when ad = gb. This condition prevents overgeneralizing from a single illustrative parameterization.

An alternative policy is to treat cognitive independence as a non-negotiable constraint and maximize performance:

$$maximize\ P(x) \quad subject\ to\ C(x) \geq C_{\min},\ 0 \leq x \leq 1 \tag{8}$$

The independence constraint is feasible when the quadratic inequality $C_0 + gx - dx^2 \geq C_{min}$ has a nonempty intersection with [0,1]. Writing $\Delta_C = g^2 + 4d(C_0 - C_{min})$, the real-valued feasible interval, when $\Delta_C \geq 0$, is bounded by

$$r_{\pm} = [g \pm \sqrt{\Delta_C}] / (2d) \tag{9}$$

and the feasible set is [$r_-$, $r_+$] ∩ [0,1]. Because P is concave, the constrained optimum is the projection of $x_P$ onto this feasible interval. This ε-constraint form is often preferable when

an institution regards minimum independent performance as a required learning outcome rather than as a quantity that may be traded freely against assisted output.

## 4. ILLUSTRATIVE COMPUTATIONAL ANALYSIS

For demonstration only, consider $P_0 = 0.45$, $C_0 = 0.90$, $a = 0.80$, $b = 0.45$, $g = 0.12$, and $d = 0.55$. These values are not estimated from students. They are selected to produce diminishing performance gains and a small low-intensity scaffolding effect followed by increasing independence costs.

| AI use x | Performance P(x) | Independence C(x) | Interpretation |
|---|---|---|---|
| 0.0 | 0.450 | 0.900 | No AI |
| 0.2 | 0.592 | 0.902 | Low assistance |
| 0.4 | 0.698 | 0.860 | Moderate assistance |
| 0.6 | 0.768 | 0.774 | Moderate assistance |
| 0.8 | 0.802 | 0.644 | High assistance |
| 1.0 | 0.800 | 0.470 | High assistance |

*Table 1. Illustrative objective values across AI-assistance intensity*

For these parameters, $x_P = 0.889$ and $x_C = 0.109$; hence the Pareto-efficient set is approximately [0.109, 0.889]. Below $x_C$, both objectives can be improved by increasing AI assistance; above $x_P$, both can be improved by reducing it. Only the interval between the two single-objective maxima represents a genuine trade-off.

Equation (6) gives $x^* = 0.276$ for $\lambda = 0.25$, $x^* = 0.460$ for $\lambda = 0.50$, and $x^* = 0.663$ for $\lambda = 0.75$. These corrected values illustrate the parameter-specific case $ad > gb$ ($0.440 > 0.054$), so $x^*(\lambda)$ increases with $\lambda$ in this example. The result should not be generalized to other parameter sets without checking condition (7).

## 5. EMPIRICAL ESTIMATION AND VALIDATION

The principal empirical task is to estimate the response functions rather than to accept the quadratic curves a priori. A defensible design would randomly assign learners to several pre-specified AI-assistance levels, measure an assisted task outcome P, and then assess C using AI-free indicators such as delayed retention, transfer to novel problems, unaided reasoning accuracy, error detection, confidence calibration, and the ability to reproduce or explain an AI-supported solution without AI. Repeated tasks would permit multilevel nonlinear regression or Bayesian hierarchical estimation of learner- and task-specific parameters.

Validation should separate model fitting from policy evaluation. Parameters can be estimated on a training sample and predictive accuracy assessed on held-out learners or tasks. The estimated Pareto set should be accompanied by uncertainty intervals obtained through bootstrap or posterior sampling. Sensitivity analysis should vary $\lambda$, $C_{min}$, and parameter estimates because small changes near a flat optimum may materially change a policy recommendation. If empirical response surfaces are nonconcave or involve more objectives, numerical multi-objective methods, including evolutionary algorithms, can be used [9].

## 6. DISCUSSION

The framework makes three conceptual distinctions explicit. First, better AI-assisted output is not synonymous with stronger independent learning. Second, AI use is not intrinsically beneficial or harmful: low-intensity scaffolding can be represented by $g > 0$, whereas higher-intensity substitution is represented by the curvature d. Third, the final choice within a Pareto-efficient set is partly normative. Mathematics can identify efficient alternatives and reveal trade-offs, but it cannot determine how much an institution should value immediate assisted performance relative to long-term independence.

This formulation also clarifies limitations. The scalar x compresses qualitatively different AI behaviors into one dimension; in practice, answer generation, hinting, feedback, critique, and retrieval may have different response curves. The objective C is also latent and

must be operationalized by multiple performance-based indicators rather than by self-report alone. Finally, causal claims about cognitive cost require randomized or otherwise strongly identified designs. The present numerical values are illustrative and must not be interpreted as a recommended percentage of AI use.

## 7. CONCLUSION

This study presents a mathematically consistent multi-objective framework for selecting AI-assistance intensity in education. The revised model identifies the single-objective maxima, characterizes the Pareto-efficient interval, derives a weighted optimum with an explicit monotonicity condition, and provides an independence-constrained alternative. Its primary contribution is not a universal optimal AI-use threshold, but a testable decision architecture that can be estimated from educational experiments and used to compare context-specific policies while preserving cognitive independence as an explicit objective.

## AI DISCLOSURE

Generative artificial intelligence was used for language editing and as an aid during manuscript revision.

## LITERATURE

1. Kasneci E., Sessler K., Küchemann S., Bannert M., Dementieva D., Fischer F., Gasser U., Groh G., Günnemann S., Hüllermeier E., Krusche S., Kutyniok G., Michaeli T., Nerdel C., Pfeffer J., Poquet O., Sailer M., Schmidt A., Seidel T., Stadler M., Weller J., Kuhn J., Kasneci G. ChatGPT for good? On opportunities and challenges of large language models for education // Learning and Individual Differences. – 2023. – Vol. 103. – Article 102274. DOI: 10.1016/j.lindif.2023.102274.

2. Yan L., Sha L., Zhao L., Li Y., Martinez-Maldonado R., Chen G., Li X., Jin Y., Gašević D. Practical and ethical challenges of large language models in education: A systematic scoping review // British Journal of Educational Technology. – 2024. – Vol. 55. – P. 90–112. DOI: 10.1111/bjet.13370.

3. Chen S., Cheung A.C.K. Effect of generative artificial intelligence on university students learning outcomes: A systematic review and meta-analysis // Educational Research Review. – 2025. – Vol. 49. – Article 100737. DOI: 10.1016/j.edurev.2025.100737.

4. Fan Y., Tang L., Le H., Shen K., Tan S., Zhao Y., Shen Y., Li X., Gašević D. Beware of metacognitive laziness: Effects of generative artificial intelligence on learning motivation, processes, and performance // British Journal of Educational Technology. – 2025. – Vol. 56. – P. 489–530. DOI: 10.1111/bjet.13544.

5. Risko E.F., Gilbert S.J. Cognitive offloading // Trends in Cognitive Sciences. – 2016. – Vol. 20, No. 9. – P. 676–688. DOI: 10.1016/j.tics.2016.07.002.

6. Barcaui A. ChatGPT as a cognitive crutch: Evidence from a randomized controlled trial on knowledge retention // Social Sciences & Humanities Open. – 2025. – Vol. 12. – Article 102287. DOI: 10.1016/j.ssaho.2025.102287.

7. Zhu Q., Li X., Dong Y., Chang P., Fan M. Not all cognitive offloading is equal: Distinguishing dependent and autonomous offloading to generative AI // Frontiers in Psychology. – 2026. – Vol. 17. – Article 1878629. DOI: 10.3389/fpsyg.2026.1878629.

8. Miettinen K. Nonlinear Multiobjective Optimization. – Boston: Kluwer Academic Publishers, 1999. – International Series in Operations Research & Management Science, Vol. 12. ISBN: 0-7923-8278-1.

9. Deb K. Multi-Objective Optimization Using Evolutionary Algorithms. – Chichester: John Wiley & Sons, 2001. ISBN: 978-0-471-87339-6.

# ЧИСЛЕННОЕ МОДЕЛИРОВАНИЕ НЕСЖИМАЕМОГО ВЯЗКОГО ТЕЧЕНИЯ В L-ОБРАЗНОМ КАНАЛЕ С РАЗЛИЧНЫМИ УГЛАМИ ИЗГИБА

Худайберген Б.Б., Темирбеков А.Н., Темирбеков Н.М.
email: secdet29@gmail.com, almas_tem@mail.ru, temirbekov@rambler.ru
*Казахский Национальный Университет имени аль-Фараби, Казахстан*

***Аннотация.*** *В данной работе исследуется, как угол поворота L-образного канала влияет на течение вязкой несжимаемой жидкости. Были рассмотрены два варианта канала: с поворотом 45° и 90°. Расчёты выполнены для чисел Рейнольдса Re=500, 1000 и 2000 с использованием метода конечных элементов в программном пакете FEniCS. Результаты показали, что угол поворота существенно влияет на структуру потока и гидравлические потери. В канале с углом 45° поток изменяет направление более плавно, распределение скорости и давления остаётся более равномерным, а вихревые зоны выражены слабее. В канале с углом 90° поток испытывает резкое изменение направления, что приводит к появлению более сильных вихрей, большим градиентам скорости и увеличению потерь давления. Количественный анализ показал, что для всех рассмотренных режимов течения перепад давления, коэффициент гидравлических потерь и число Эйлера в канале с углом 90° больше, чем в канале с углом 45°. Разница по перепаду давления составляет примерно 10–12 %, что свидетельствует о менее эффективной работе канала с резким поворотом. Таким образом, исследование подтверждает, что использование поворота 45° позволяет уменьшить гидравлические потери, ослабить образование вихрей и обеспечить более плавное течение жидкости по сравнению с поворотом 90°. Полученные результаты могут быть использованы при проектировании трубопроводов, вентиляционных систем и охлаждающих каналов.*

Актуальность работы связана с тем, что каналы с поворотами широко используются в трубопроводных системах, вентиляционных установках и охлаждающих устройствах. При прохождении жидкости через изгиб возникают дополнительные гидравлические потери, изменяется распределение скорости и давления, а также могут образовываться вихревые зоны. Поэтому важно определить, как угол поворота влияет на характеристики течения.

Целью исследования являлось изучение влияния угла поворота на структуру потока и гидравлические потери в L–образных каналах с использованием численного решения стационарных уравнений Навье–Стокса методом конечных элементов.

В работе были рассмотрены две геометрии канала: с поворотом 45° и с поворотом 90°. Расчёты проводились для чисел Рейнольдса Re=500, 1000 и 2000. В качестве математической модели использовались стационарные уравнения Навье–Стокса для вязкой несжимаемой жидкости. Численное решение было реализовано в программном пакете FEniCS с применением элементов Тейлора–Худа и метода Ньютона для решения нелинейной системы уравнений. В ходе исследования были получены поля скорости и давления, вычислены линии тока, а также определены основные гидродинамические характеристики: перепад давления, коэффициент гидравлических потерь и число Эйлера.

Полученные результаты показали, что геометрия канала существенно влияет на характер течения жидкости. В канале с углом 45° поток изменяет направление более плавно, распределение скорости остаётся более равномерным, а поле давления изменяется без резких скачков. Напротив, в канале с углом 90° наблюдается более сильная деформация потока, возникают повышенные градиенты скорости и более выраженные зоны рециркуляции. Особенно заметными различия становятся при увеличении числа Рейнольдса. Для канала с углом 90° после поворота формируются вихревые зоны, которые усиливаются при переходе от Re=500 к Re=2000. В канале с

углом 45° течение остаётся более устойчивым и упорядоченным даже при больших значениях числа Рейнольдса.

Количественный анализ также подтвердил преимущества канала с углом 45°. Для всех исследованных режимов течения перепад давления в канале с углом 90° оказался выше. Разница составила около 10,1 % при Re=500, 10,8 % при Re=1000 и 12,2 % при Re=2000. Аналогичная зависимость наблюдалась для коэффициента гидравлических потерь и числа Эйлера.

Таким образом, проведённое исследование показало, что уменьшение угла поворота до 45° позволяет снизить гидравлические потери, уменьшить интенсивность вихреобразования и обеспечить более плавное течение жидкости. Полученные результаты могут быть использованы при проектировании трубопроводов, вентиляционных систем и охлаждающих каналов для повышения их гидродинамической эффективности.

**Финансирование**

Работа выполнена при поддержке Комитета науки Министерство науки и высшего образования Республики Казахстан (грант № AP23490027 «Разработка комплекса прикладных программ для численного решения уравнений Навье-Стокса в сложных областях»).

## Литература

1. Glowinski, R. (1984). Numerical Methods for Nonlinear Variational Problems. Springer Berlin Heidelberg. https://doi.org/10.1007/978 – 3 – 662 – 12613 – 4.

2. Olshanskii, M. A. (2002). A low order Galerkin finite element method for the Navier–Stokes equations of steady incompressible flow: a stabilization issue and iterative methods. Computer Methods in Applied Mechanics and Engineering, 191 (47 – 48), 5515 – 5536. https://doi.org/10.1016/s0045 – 7825(02)00513 – 3.

3. Temirbekov, A., Baigereyev, D., Temirbekov, N., Urmashev, B., Amantayeva, A. (2021). Parallel CUDA implementation of a numerical algorithm for solving the Navier–Stokes equations using the pressure uniqueness condition. International Conference on Analysis and Applied Mathematics (Icaam 2020), 2325, 20063. https://doi.org/10.1063/5.0041039.

4. Temirbekov, N., Khakimzyanov, G., Kerimakyn, A. (2026). Application of the Curvilinear Coordinate Method for the Numerical Solution of the Navier–Stokes Equations in Domains with Complex Boundaries. Computation, 14 (3), 58. https://doi.org/10.3390/ computation14030058.

5. Langtangen, H. P., Logg, A. (2016). Solving PDEs in Python. Springer International Publishing. https://doi.org/10.1007/978 – 3 – 319 52462 – 7.

6. Larson, M. G., Bengzon, F. (2013). The Finite Element Method: Theory, Implementation, and Applications. Springer Berlin Heidelberg. https://doi.org/10.1007/978 – 3 – 642 – 33287 – 6.

# КӨПІРДІҢ ОРНЫҚТЫЛЫҒЫН МАТЕМАТИКАЛЫҚ ЖОЛМЕН ЖАСАНДЫ ИНТЕЛЛЕКТІНІ ҚОЛДАНЫП ЕСЕПТЕУ

*Жұмабай Мәдібайұлы*
*PhD доктор, Farabi University, Қазақстан, Алматы*

***Аңдатпа***

*Бұл тезисте көпір конструкциясының жел әсеріндегі орнықтылығын математикалық модельдеу және жасанды интеллект әдістері арқылы оның сындарлы күйін алдын ала анықтау мәселесі қарастырылады. Зерттеудің математикалық негізі механикалық жүйелердің динамикалық күйін, тербелісін және ақауларын математикалық модельдер арқылы сипаттау бағытына сүйенеді. Жұмабай Мәдібайұлының ғылыми еңбектерінде механикалық жүйелер ақауларын идентификациялау, серпімді бекітілген объектілердің тербелістерін меншікті жиіліктер арқылы басқару және дифференциалдық операторлардың шекаралық шарттарын анықтау мәселелері зерттелген [1–4].*

*Ұсынылып отырған тәсілде көпір платформасы масса–серіппе–демпфер жүйесі ретінде қарастырылып, жел әсерінен туындайтын аэродинамикалық күш математикалық модельге енгізіледі. Нәтижесінде жел жылдамдығының белгілі бір мәнінде тиімді демпфирлеу коэффициенті нөлге тең болатын сындарлы жағдай анықталады. Бұдан кейін математикалық модельден алынған параметрлер жасанды интеллект моделін оқыту үшін пайдаланылады. ЖИ алгоритмі көпірдің орнықты, шекті және орнықсыз режимдерін ажыратып, сындарлы жел жылдамдығын нақты уақыт режимінде болжауға мүмкіндік береді.*

***Кілт сөздер:*** *көпір орнықтылығы, математикалық модель, сындарлы жылдамдық, аэродинамикалық күш, тербеліс, механикалық жүйе, ақауларды идентификациялау, жасанды интеллект, машиналық оқыту, Хопф бифуркациясы.*

## Пайдаланылған әдебиеттер

1. Мәдібайұлы Ж. Механикалық жүйе ақауларының идентификациясы: PhD диссертациясы. Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы.
2. Fazullin Z.Yu., Madibaiuly Zh., Yermekkyzy L. Control of vibrations of elastically fixed objects using analysis of eigenfrequencies. *International Journal of Mathematics and Physics*, 2020.
3. Kanguzhin B.E., Zhapsarbayeva L., Madibaiuly Z. Lagrange formula for differential operators and self-adjoint restrictions of the maximal operator on a tree. *Eurasian Mathematical Journal*, 2019, 10(1), 16–29. DOI: 10.32523/2077-9879-2019-10-1-16-29.
4. Kanguzhin B.E., Akanbay E.N., Madibaiuly Zh. Jointing of thin elastic rods and generalized Kirchhoff conditions at nodes. *Journal of Mathematics, Mechanics and Computer Science*, 2020.
5. Kanguzhin B.E., Dairbayeva G., Madibaiuly Zh. Identification of boundary conditions of a differential operator. *Mechanics and Computer Science*, 2019.
6. Kanguzhin B.E., Dairbayeva G., Madibaiuly Zh. Uniqueness of the restoration of boundary conditions differential operator on a set of spectra. *Mechanics and Computer Science*, 2019.
7. Billah K.Y., Scanlan R.H. Resonance, Tacoma Narrows bridge failure, and undergraduate physics textbooks. *American Journal of Physics*, 1991, 59, 118–124.
8. Den Hartog J.P. *Mechanical Vibrations*. Dover Publications, New York, 1985.
9. Parkinson G.V., Brooks N.P.H. On the aeroelastic instability of bluff cylinders. *Journal of Applied Mechanics*, 1961, 28, 252–258.

УДК 519.876.5:681.5:004.94

# МАТЕМАТИЧЕСКАЯ МОДЕЛЬ РОБАСТНОГО КОНТРОЛЯ НЕДОЛИВА ЗАКРЫТЫХ УПАКОВОК ДЛЯ ЦИФРОВОГО ДВОЙНИКА ПРОИЗВОДСТВЕННОЙ ЛИНИИ

Амирханов Б.[1], Амирханова Г.[1], Тюлепбердинова Г.[1], Мазаков Т.[2], Ахметов Д.[3], Раева А.[1]
e-mail: amirkhanov.b@gmail.com
[1]*Казахский национальный университет имени аль-Фараби, Алматы, Казахстан*
[2]*Международный инженерно-технологический университет, Алматы, Казахстан*
[3]*Rakuno Gakuen University, Хоккайдо, Япония*

*Аннотация. Предложена математическая модель бесконтактного однопорогового контроля недолива отдельной закрытой упаковки после наполнения. Технологическая уставка по фактическому объёму преобразуется в единственную контрольную высоту с учётом внутренней геометрии упаковки. Регистрируемый ультразвуковой отклик представлен опорным стеночным и чувствительным к содержимому временными компонентами. Для пригодной записи введён нормированный двухоконный признак. Сформулировано и доказано условие существования порога с положительным робастным запасом для ограниченного множества мешающих параметров. Показано, что при непрерывном признаке невозможно гарантированно отделить все объёмы, сколь угодно близкие к точной уставке; поэтому вводится минимально гарантированно обнаруживаемый дефицит либо непроходная область. Решение имеет три состояния: «недолив», «достаточно» и «неопределённо». Последнее отделяет пограничную упаковку от подтверждённой нормы и позволяет передавать качество измерения в цифровой двойник. Численная оценка времени прохождения через банку согласуется по порядку с опубликованным EMAT-экспериментом, но не рассматривается как валидация проектируемого комплекса.*

*Ключевые слова: контроль наполнения, недолив, математическая модель, робастный порог, ультразвук, EMAT, цифровой двойник, неопределённость.*

**Введение**

Автоматическая линия должна связывать решение о качестве с конкретной упаковкой. Для фасованной продукции контролируемой величиной является фактическое количество продукта. Международная рекомендация OIML R 87 задаёт требования к партиям готовых упаковок и планы метрологического контроля [1]. Для номинального количества 500 мл в таблице допустимых недовложений приведено 15 мл, однако эта величина не является готовой симметричной настройкой наполнителя и не определяет порог поштучного датчика. Минимальный допустимый объём $V_{\min}$ должен задаваться технологическими требованиями предприятия с учётом применимых нормативов.

Известные неразрушающие методы используют ударный отклик, вибрацию, ультразвук и электромагнитно-акустические преобразователи. В патенте Heuft и Goller заполнение оценивается по динамическому отклику упаковки [2]. Для сосуда под давлением исследован бесконтактный ударный способ [3], а переносной вибрационный подход применён к различению состояний грузовых ёмкостей [4]. Для алюминиевых банок Ho, Billson и Hutchins показали бесконтактное возбуждение и приём ультразвука парой EMAT, а также отделение прошедшего через жидкость прихода от волн оболочки [5, 6]. Размещение преобразователей около движущейся металлической тары и пороговая отбраковка раскрыты в [7]. Лазерная регистрация вызванной вибрации упаковки и сравнение с эталоном известны из [8]. Современная EMAT/EMAR-работа

подтверждает возможность определения уровня снаружи металлической трубы и одновременно подчёркивает проблему низкого отношения сигнал/шум [9]. Эти источники подтверждают осуществимость отдельных физических принципов, но не дают готового критерия гарантированного обнаружения недолива в заданной области условий линии.

Цель работы — построить самодостаточную модель, связывающую одну производственную уставку по объёму с локальным измерением, робастным решением и событием цифрового двойника. Вклад статьи состоит в композиции операторов

$$V_{\min} \to z_* \to y(t) \to (S_R, S_L, R) \to I_R \to D, \tag{1}$$

а также в явном условии существования робастного порога и в доказательстве ограничения точной непрерывной границы. Конкретный тип приёмника — второй EMAT или лазерный виброметр — рассматривается как параметр архитектуры, который должен выбираться по одинаковому проверочному протоколу.

**1. От объёмной уставки к контрольной высоте**

Пусть $A(z)$ — площадь горизонтального сечения внутренней полости упаковки на высоте $z \in [0, H]$. Объём жидкости до высоты $h$ равен

$$V(h) = \int_0^h A(z)dz. \tag{2}$$

Предположим, что для любых $0 \le h_1 < h_2 \le H$

$$\int_{h_1}^{h_2} A(z)dz > 0. \tag{3}$$

Тогда $V(h)$ строго возрастает, поскольку $V(h_2) - V(h_1) > 0$. Для каждого $V_{\min}$ из образа функции существует единственная отметка

$$z_* = V^{-1}(V_{\min}), V \ge V_{\min} \Leftrightarrow h \ge z_*. \tag{4}$$

Следовательно, для задачи «обнаружить недолив» не требуется восстанавливать всю свободную поверхность или непрерывно измерять уровень. Достаточно исследовать физическое состояние одной локальной зоны, соответствующей технологической уставке. Функция (2) должна строиться по внутреннему профилю реальной серии упаковок. Цилиндрическая формула $V = \pi r^2 h$ пригодна лишь для предварительной оценки, так как профиль дна, верхнее сужение и технологический разброс смещают $z_*$.

Эквивалентность (4) является геометрическим утверждением. Реальный измерительный канал имеет конечную вертикальную апертуру; на него влияют мениск, пена, наклон и колебание поверхности. Поэтому точечная отметка преобразуется в контрольную полосу, а неопределённость геометрии включается в область допустимых условий.

**2. Физический и измерительный операторы**

Обозначим через $\theta \in \Theta$ мешающие параметры: геометрию и толщину стенки, внутреннее давление, температуру, свойства жидкости и газа, положение и скорость упаковки, зазоры преобразователей, оптический спекл, пузырьки, пену и параметры электронной цепи. Конфигурацию аппаратуры обозначим $\kappa$. Неявная физическая модель и оператор наблюдения записываются как

$$E(\xi; V, \theta, \kappa) = 0, y(t) = O(\xi, V, \theta, \kappa)(t) + e(t), \tag{5}$$

где $\xi$ — состояние системы, $e(t)$ — неучтённый фон и ошибка регистрации. Для однопороговой задачи используется редуцированное представление

$$y(t) = as_R(t) + ac(V, \theta, \kappa)s_L(t) + b(t; V, \theta, \kappa) + n(t). \tag{6}$$

Здесь $s_R$ описывает ранний стеночный опорный приход, $s_L$ — вклад пути через содержимое, $a > 0$ — общий масштаб возбуждения и чувствительности, $b$ — структурированный фон, $n$ — остаточный шум. Коэффициент $c$ характеризует доступность пути через жидкость в контрольной зоне. В идеальной точечной модели он может быть индикатором $h \geq z_*$; в реальной системе это, как правило, переходная функция.

Пусть $u(t)$ — опорный шаблон переданного пакета. Для временного окна $W$ определим согласованную оценку

$$S_W(y) = \sup_{\tau \in T_W} \left| \int_W y(t)u(t-\tau)dt. \right| \tag{7}$$

В опорном окне $W_R$ и чувствительном окне $W_L$ вычисляются

$$S_R = S_{W_R}(y), S_L = S_{W_L}(y), R = \frac{S_L}{S_R}, S_R \geq S_{\min} > 0. \tag{8}$$

Запись признаётся пригодной только при отсутствии насыщения, наличии обоих окон, корректной синхронизации и известной версии конфигурации. При нарушении любого условия порог не применяется.

**Утверждение 1.** Если оба оконных признака изменяются под действием одного положительного множителя $a$, отношение $R$ инвариантно к этому множителю.

Действительно, из положительной однородности (7) следует $S_W(ay) = aS_W(y)$, поэтому $S_L(ay \big/ S_R)(ay) = S_L(y \big/ S_R)(y)$. Это утверждение не означает устойчивости к произвольной аддитивной помехе. Если $\widetilde{S}_R = as_R + e_R$, $\widetilde{S}_L = as_L + e_L$, $a \geq a_{\min} > 0$, $|e_R| \leq \eta_R$, $|e_L| \leq \eta_L$ и $a_{\min} s_R > \eta_R$, то

$$\left| \frac{\widetilde{S}_L}{\widetilde{S}_R} - \frac{s_L}{s_R} \right| \leq \frac{s_R\eta_L + s_L\eta_R}{s_R(a_{\min}s_R - \eta_R)}. \tag{9}$$

При слабой опоре правая часть неограниченно возрастает. Условие $S_R \geq S_{\min}$ поэтому является частью математической корректности решения, а не только программной проверкой качества.

**3. Робастный порог и область отказа от решения**

Класс достаточного наполнения зададим как $V_L = [V_{\min}, V_{\max}]$. Для гарантированного обнаружения введём минимальный дефицит $\Delta V_{\text{det}} > 0$ и определим

$$V_G = [0, V_{\min} - \Delta V_{\text{det}}], V_U = (V_{\min} - \Delta V_{\text{det}}, V_{\min}). \tag{10}$$

Область $V_U$ не считается нормой. Она направляется на повторную проверку или отбраковку, пока экспериментально подтверждённая переходная характеристика не позволит сузить эту область.

Для фиксированной конфигурации $\kappa$, области $\Theta$, множества допустимых ошибок $E$ и пригодных записей определим множества возможных значений признака

$$R_G = \{R(V, \theta, e; \kappa) : V \in V_G, \theta \in \Theta, e \in E\},$$
$$R_L = \{R(V, \theta, e; \kappa) : V \in V_L, \theta \in \Theta, e \in E\}. \tag{11}$$

Использование множеств совместимых значений соответствует подходу оценивания при ограниченных ошибках [10]. Обозначим $R_G^+ = \overset{R}{G}$, $R_L^- = \inf R_L$ и

$$M_R = R_L^- - R_G^+. \tag{12}$$

**Утверждение 2.** Порог $\tau$ с положительным равномерным запасом существует тогда и только тогда, когда $M_R > 0$.

Если $M_R > 0$, любой $\tau \in (R_G^+, R_L^-)$ даёт запас $\mu = \min\{\tau - R_G^+, R_L^- - \tau\} > 0$. Обратно, из неравенств $r_G \leq \tau - \mu$ для всех $r_G \in R_G$ и $r_L \geq \tau + \mu$ для всех $r_L \in R_L$ следует $M_R \geq 2\mu > 0$. Тем самым условие (12) служит единым критерием сравнения формы возбуждения, положения зоны и типа приёмника.

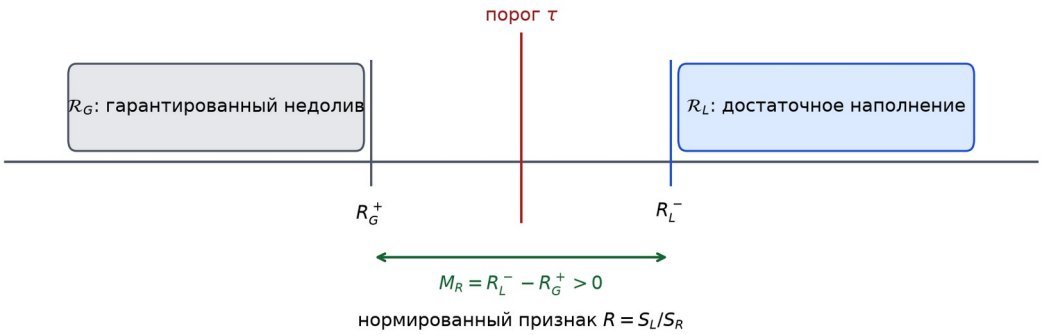



Рис. 1. Интервалы признака и робастный порог. Границы показаны схематически и должны определяться по калибровочным данным.

**Утверждение 3.** Пусть при фиксированных условиях идеальный признак $r(V)$ непрерывен в $V_{\min}$. Если недоливный класс содержит все $V < V_{\min}$, сколь угодно близкие к $V_{\min}$, а достаточный класс содержит $V_{\min}$, то положительный равномерный запас невозможен.

Для последовательности $V_n < V_{\min}$, $V_n \to V_{\min}$ имеем $r(V_n) \to r(V_{\min})$. Следовательно, $\sup_{V<V_{\min}} r(V) \geq r(V_{\min})$ и $\inf_{V \geq V_{\min}} r(V) \leq r(V_{\min})$, откуда $M_R \leq 0$. Поэтому обещание обнаружить любой сколь угодно малый недолив не имеет математического основания без физически подтверждённого скачка. Корректная спецификация должна содержать $\Delta V_{\text{det}}$ или непроходную область.

Для одной записи строится интервал $I_R = [\hat{R} - \varepsilon_R, \hat{R} + \varepsilon_R]$, содержащий истинный признак. Решение задаётся правилом

$$D_\tau(I_R) = \{\text{недолив}, \ {}^{I}_{R} < \tau, \ \text{достаточно}, \ \inf I_R > \tau, \ \text{неопределённо}, \ \text{иначе}. \tag{13}$$

Если $M_R > 0$, порог выбран внутри зазора, а $I_R$ действительно содержит $R$, то достаточная упаковка не может быть названа недоливом, а гарантированный недолив — достаточным наполнением. Состояние отказа от классификации согласуется с известной постановкой компромисса между ошибкой и отказом [11], однако здесь оно имеет производственный смысл: пропуск разрешается только для результата «достаточно».

**4. Расчётный экран временной наблюдаемости**

Опорный и чувствительный приходы должны быть физически разделены во времени. Пусть тракт восстанавливается не позднее $t_{rec}$, интервалы возможных опорных и жидкостных приходов равны $T_R = [t_R^-, t_R^+]$ и $T_L = [t_L^-, t_L^+]$, следующий мешающий приход начинается не ранее $t_A^-$, а $g$ — защитный интервал. Непересекающиеся окна существуют тогда и только тогда, когда

$$t_{rec} + g \leq t_R^-, t_R^+ + g \leq t_L^-, t_L^+ + g \leq t_A^-. \tag{14}$$

Условие (14) проверяется интервалами, а не номинальными моментами. Если оно нарушено, цифровая фильтрация не создаёт отсутствующего физического разделения; требуется изменить пакет, демпфирование, частоту, геометрию или приёмник.

Для внешней проверки масштаба времени рассмотрим банку наружного диаметра около 66 мм, исследованную Но [6]. При скорости продольной волны в воде $c_w = 1485$ м/с оценка поперечного пролёта составляет

$$t_w \approx \frac{0{,}066}{1485} = 44{,}4\text{мкс}. \tag{15}$$

В опубликованной записи жидкостный приход наблюдался около 44 мкс, а ранний S0-приход — около 18,5 мкс [6]. Совпадение порядка и масштаба поддерживает кинематическую часть модели и выбор раздельных окон. Оно не определяет $M_R$, допустимую скорость конвейера или вероятность ошибок проектируемого комплекса. В исходном опыте применялись стационарная банка, вода, зазор EMAT около 0,3 мм и многократное усреднение для обычной импульсной записи; перенос результата на производственную линию требует собственной проверки.

**5. Событие цифрового двойника**

Локальный контроллер формирует решение до сетевой передачи. Событие цифрового двойника представим кортежем

$$E_i = (t_i, id_i, D_i, q_i, S_{R,i}, S_{L,i}, R_i, t_{R,i}, t_{L,i}, c_i, m_i), \tag{16}$$

где $id_i$ связывает запись с упаковкой, $q_i$ — код качества, $c_i$ — версия аппаратной конфигурации и калибровки, $m_i$ — параметры режима линии. Разделение $D_i$ и $q_i$ позволяет отличить состояние продукта от отказа измерительного канала. Современные работы рассматривают управление неопределённостью как отдельную функцию цифрового двойника [12]. Здесь эта идея конкретизирована контрактом события однопорогового контроля.

Ранее разработанные архитектуры цифровых двойников производственных линий поддерживают локальный сбор, MQTT, временные ряды и сопоставление планового и фактического состояния [13, 14]. Открытая платформа OpenEgiz содержит компоненты Eclipse Ditto, Mosquitto, Telegraf, InfluxDB и Grafana [15]. Эти программные средства обеспечивают передачу, хранение и визуализацию результата, но не подтверждают физическую различимость недолива.

В цифровом двойнике агрегируются доли решений «недолив» и «неопределённо», распределение $R$, доступность опоры $S_R$ и версии конфигурации. Рост доли недолива при стабильном качестве записи может указывать на смещение процесса наполнения. Рост доли непригодных записей при неизменном независимом показателе указывает прежде всего на деградацию измерительного узла. Эти диагностические правила являются проверяемыми гипотезами; они не должны автоматически менять порог без размеченной валидационной серии.

**Заключение**

Построена математическая модель однопорогового контроля недолива закрытой упаковки. Условие положительного приращения объёма по высоте обеспечивает однозначное преобразование $V_{\min} \to z_*$. Два временных окна формируют признак $R = \frac{S_L}{S_R}$ и внутреннюю проверку пригодности записи. Для ограниченного множества условий порог с положительным запасом существует в точности при $M_R > 0$. Непрерывность признака у точной границы требует минимально обнаруживаемого дефицита $\Delta V_{\text{det}}$ или непроходной области. Интервальное правило выдаёт три состояния и запрещает подменять недостаток информации подтверждённой нормой.

Расчёт времени поперечного прохождения через банку согласуется с опубликованным EMAT-наблюдением и обосновывает дальнейшую проверку двухоконной схемы. Полученный результат имеет аналитический и условно-расчётный статус. Экспериментально не установлены реальные $M_R$, $\Delta V_{\text{det}}$, вероятности ошибок, доля пригодных записей и время цикла. Следующий этап состоит в парном испытании EMAT–EMAT и EMAT–лазерный виброметр на одинаковых упаковках с неизменяемыми калибровочными и валидационными сериями.

**Финансирование.** Исследование выполнено при финансовой поддержке Комитета науки Министерства науки и высшего образования Республики Казахстан (грант № BR24992975 «Разработка цифрового двойника предприятия пищевой промышленности с использованием технологий искусственного интеллекта и IIoT»).

**Литература**

1. International Organization of Legal Metrology. Quantity of product in prepackages: OIML R 87:2016(E). – URL: https://www.oiml.org/en/files/pdf_r/r087-e16.pdf (дата обращения: 08.09.2026).

2. Пат. 6443004 США. Method and device for determining the filling level in containers / B. Heuft, H.-U. Goller. – Опубл. 03.09.2002.

3. Wu, H.-H.P. Analysis and Implementation of Noncontact Level Sensing for a Pressurized Cylinder / H.-H.P. Wu, C.-W. Hung, S.-H. Chang, Z.-H. Yang // Journal of Sensors. – 2016. – Art. 5027916. – DOI: 10.1155/2016/5027916.

4. Song, Y. Portable and Non-Intrusive Fill-State Detection for Liquid-Freight Containers Based on Vibration Signals / Y. Song, E. Van Hoecke, N. Madhu // Sensors. – 2022. – Vol. 22, N. 20. – Art. 7901. – DOI: 10.3390/s22207901.

5. Ho, K.S. Inspection of drinks cans using non-contact electromagnetic acoustic transducers / K.S. Ho, D.R. Billson, D.A. Hutchins // Journal of Food Engineering. – 2007. – Vol. 80, N. 2. – P. 431–444. – DOI: 10.1016/j.jfoodeng.2006.04.025.

6. Ho, K.S. Advances in EMAT Measurements for NDE: PhD thesis / K.S. Ho. – Coventry: University of Warwick, 2007. – P. 46–63. – URL: https://wrap.warwick.ac.uk/67107/ (дата обращения: 09.09.2026).

7. Пат. 5929337 США. Non-mechanical contact ultrasound system for monitoring contents of a moving container. – Опубл. 27.07.1999.

8. Пат. 5821424 США. Method and apparatus for analyzing the fill characteristics of a packaging container / J.G. Rodriguez. – Опубл. 13.10.1998.

9. Shi, Y. Non-contact and non-invasive water level measurement outside metal pipes with electromagnetic acoustic resonance / Y. Shi, X. Jin, J. Jiang, S. Tian, T. Lei, M. Tabatabaeipour, D. Zhang, K. Xu // Measurement. – 2024. – Art. 115451. – DOI: 10.1016/j.measurement.2024.115451.

10. Jaulin, L. Set inversion via interval analysis for nonlinear bounded-error estimation / L. Jaulin, E. Walter // Automatica. – 1993. – Vol. 29, N. 4. – P. 1053–1064. – DOI: 10.1016/0005-1098(93)90106-4.

11. Chow, C.K. On optimum recognition error and reject tradeoff / C.K. Chow // IEEE Transactions on Information Theory. – 1970. – Vol. 16, N. 1. – P. 41–46. – DOI: 10.1109/TIT.1970.1054406.

12. Giret, A. A Hybrid Framework for Managing Uncertainty in Digital Twins Information Processing / A. Giret // ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering. – 2026. – Vol. 12, N. 4. – Art. 041110. – DOI: 10.1115/1.4072059.

13. Amirkhanov, B. Development of a Digital Twin for a Bakery Line With Predictive Analytics and Adaptive Control Functions / B. Amirkhanov, M. Kunelbayev, G. Amirkhanova, T. Nurgazy, G. Tyulepberdinova, S. Tletay // IET Collaborative Intelligent Manufacturing. – 2026. – Vol. 8, N. 1. – Art. e70056. – DOI: 10.1049/cim2.70056.

14. Amirkhanova, G. Closed-Loop Digital Twin for Energy-Efficient Scheduling in Food Manufacturing Systems / G. Amirkhanova, N. Yusubova, B. Amirkhanov, M. Sakypbekova, S. Chen // Information. – 2026. – Vol. 17, N. 2. – Art. 195. – DOI: 10.3390/info17020195.

15. OpenEgiz: An open-source digital twin platform based on OpenTwins: GitHub repository, revision d5db588dc64c99fe4374665162b8e57933fd5164. – URL: https://github.com/openegiz/openegiz (дата обращения: 09.09.2026).

**Сведения об авторах**

**Амирханов Бауыржан** — магистр информатики, ассистент-профессор кафедры искусственного интеллекта и Big Data, Казахский национальный университет имени аль-Фараби, Алматы, Казахстан; e-mail: amirkhanov.b@gmail.com; ORCID: 0000-0002-4915-0347

**Амирханова Гульшат** — PhD, старший преподаватель кафедры искусственного интеллекта и Big Data, Казахский национальный университет имени аль-Фараби, Алматы, Казахстан; e-mail: gulshat.aa@gmail.com; ORCID: 0000-0003-3933-5476

**Тюлепбердинова Гульнур** — кандидат физико-математических наук, доцент, Казахский национальный университет имени аль-Фараби, Алматы, Казахстан; e-mail: tyulepberdinova@gmail.com; ORCID: 0000-0002-4322-8983

**Мазаков Талгат** — доктор физико-математических наук, профессор, профессор кафедры «Программная инженерия», Международный инженерно-технологический университет; главный научный сотрудник Института информационных и вычислительных технологий КН МНВО РК, Алматы, Казахстан; e-mail: 87071162626@mail.ru

**Ахметов Даурен** — Doctor of Engineering (Muroran Institute of Technology), кандидат технических наук, профессор, Rakuno Gakuen University, Хоккайдо, Япония; e-mail: sapalmaty@gmail.com

**Раева Алина** — бакалавр, Казахский национальный университет имени аль-Фараби, Алматы, Казахстан; e-mail: alinaraevali18@gmail.com; ORCID: 0009-0001-4257-6919

# МАТЕМАТИЧЕСКИЕ МОДЕЛИ ДИСТРИБУТИВНОЙ СЕМАНТИКИ С ОНТОЛОГИЧЕСКИМ АПРИОРНЫМ РАСПРЕДЕЛЕНИЕМ ДЛЯ ВЫЯВЛЕНИЯ ФРАЗЕОЛОГИЗМОВ УЗБЕКСКОГО ЯЗЫКА

[1]Назирова Э.Ш., [1]Абидова Ш.Б., [2]Мадетбаева Н.Б.
e-mail: elmira_nazirova@mail.com, shaxnoza23@mail.ru, madetbaeva@gmail.com
*[1]Ташкентский университет информационных технологий имени Мухаммада ал-Хоразмий, Узбекистан.*
*[2]НИИ развития цифровых технологий и искусственного интеллекта, Узбекистан.*

***Аннотация.*** *Задача выявления фразеологизмов в предложении формализована как построение решающей функции над вектором признаков, в который входят онтологические показатели и представления трёх математических моделей дистрибутивной семантики, а именно word2vec, латентного семантического анализа (LSA) и латентного размещения Дирихле (LDA). Показано, что все три модели сводятся к приближению матрицы совместной встречаемости матрицей низкого ранга, и предложена байесовская логистическая модель, в которой априорная ковариация весов задаётся смесью онтологического и векторного сходства фразеологизмов. Численные эксперименты на 860 предложениях, коллекции из 1,07 млн лексем и онтологии из 2 098 фразеологизмов показали, что вектор word2vec значимо повышает F1 градиентного бустинга с 0,645 до 0,696, онтологическое априорное распределение поднимает F1 логистической модели с 0,448 до 0,626, а смешанная ковариация до 0,653, тогда как признаки LSA и LDA ухудшают результат. Двуязычный LSA не определяет степень узбекско-турецкой эквивалентности.*

***Ключевые слова:*** *математическая модель, фразеологизм, онтология, низкоранговое приближение, латентный семантический анализ, латентное размещение Дирихле, байесовская логистическая регрессия, априорная ковариация.*

## Введение

Фразеологизмы, то есть устойчивые сочетания, значение которых не выводится из значений составляющих слов, остаются одной из самых трудных задач автоматической обработки языка. Они нарушают принцип композициональности, на котором строятся словари, синтаксические анализаторы и системы перевода [1]. Их автоматическое выявление по-прежнему заметно уступает выявлению отдельных слов [2]. Международные соревнования PARSEME показали, что даже для языков с богатыми ресурсами лучшие системы теряют значительную долю выражений, не встречавшихся в обучающих данных [3].

Для узбекского языка задача усложняется ещё по двум причинам. Во-первых, узбекский относится к языкам с малыми ресурсами, для него нет больших размеченных корпусов фразеологии, а исследования по многословным выражениям практически отсутствуют [4]. Во-вторых, агглютинативная морфология порождает десятки поверхностных форм одного фразеологизма, так что статистика распределяется между ними, а пословный перевод разрушает смысл. Например, фразеологизм ko‘ngli ko‘tarilmoq означает воодушевиться и соответствует турецкому morali düzelmek, тогда как его буквальный перевод лишён смысла. Система перевода должна сначала обнаружить фразеологизм, а затем подобрать ему эквивалент.

В предыдущих работах авторов построены онтология узбекских фразеологизмов и опирающиеся на неё модели их выявления [5, 6]. Онтологические признаки дают высокий результат, однако они видят только зафиксированные в онтологии единицы. Отсюда возникает вопрос, могут ли математические модели дистрибутивной семантики, оцениваемые по текстовой коллекции без разметки, дополнить онтологию. Три такие

модели, плотные векторы слов word2vec [7, 8] и fastText [9], латентный семантический анализ [10] и латентное размещение Дирихле [11], внешне различны, но принадлежат одному математическому семейству, поскольку word2vec является неявной факторизацией матрицы взаимной информации [12], LSA выполняет оптимальное низкоранговое приближение матрицы TF-IDF, а LDA описывает ту же матрицу вероятностной моделью с латентными переменными. Применение векторов слов к фразеологизмам изучалось для других языков [13], для узбекского языка подобное сравнение не проводилось.

Цель работы состоит в формализации задачи как построения решающей функции над объединённым вектором онтологических и дистрибутивных признаков, в построении байесовской логистической модели с онтологическим априорным распределением весов и в численном сравнении трёх дистрибутивных моделей на одних данных при одинаковом порядке оценки, включая проверку двуязычного LSA как модели узбекско-турецкой эквивалентности.

**Постановка задачи, данные и математические модели**

Пусть предложение d представлено вектором признаков xd, а y ∈ {−1, +1} обозначает отсутствие или наличие в нём фразеологизма. Требуется по обучающей выборке построить решающую функцию f(xd), минимизирующую ошибку на новых предложениях, и оценить, какие компоненты вектора xd вносят вклад в качество f. Использованы три источника данных. Золотой набор содержит 860 предложений из восьми художественных произведений, в 399 из которых есть фразеологизм, а в 461 нет. 400 предложений проверены экспертом, разметка остальных 460 получена как предложение предыдущей модели и ещё не прошла экспертную проверку. Лемматизированная текстовая коллекция включает 154 502 предложения и 1 071 078 лексем. Третья версия онтологии узбекских фразеологизмов содержит 2 098 единиц с последовательностью составных лексем, опорной лексемой и четырьмя категориями. Связующий модуль с турецкой онтологией фиксирует 2 128 отношений эквивалентности, из них 1 514 полных (E1) и 614 частичных (E2 и E3). Для предотвращения утечки предложения золотого набора не использовались при обучении дистрибутивных моделей.

Модель skip-gram максимизирует вероятность контекстных лексем при заданной центральной лексеме и обучается с отрицательным сэмплированием. Леви и Гольдберг показали, что в оптимуме скалярное произведение векторов равно сдвинутой взаимной информации [12].

$$v_w^\top v'_c = PMI(w,c) - \ln k, \qquad PMI(w,c) = \ln \frac{p(w,c)}{p(w)p(c)} \tag{1}$$

где:

$v_w,\ v'_c$ – векторы центральной и контекстной лексемы

$p(w,c)$ – вероятность совместной встречаемости лексемы и контекста

$p(w),\ p(c)$ – их отдельные вероятности

$k$ – число отрицательных примеров на одну положительную пару

Таким образом, word2vec приближает матрицу взаимной информации произведением двух матриц меньшего ранга и относится к одному математическому семейству с LSA. В LSA матрица документов и слов с весами TF-IDF раскладывается по сингулярным значениям, и по теореме Эккарта и Янга усечение до k наибольших сингулярных значений даёт наилучшее приближение ранга k [14]. Новый документ проецируется в скрытое пространство, а близость документов измеряется косинусом.

$$W = U\Sigma V^\top, \quad W_k = U_k \Sigma_k V_k^\top, \quad \|W - W_k\|_F = \min_{rank(B)\le k} \|W - B\|_F, \quad \hat{d} = \Sigma_k^{-1} U_k^\top d \tag{2}$$

где:

$W$ – матрица документов и слов

$U,\ V$ – ортонормированные векторы слов и документов

$\Sigma$ – диагональная матрица сингулярных значений

$U_k,\ \Sigma_k,\ V_k$ – матрицы, усечённые до первых k столбцов

$B$ – произвольная матрица ранга не выше k

$d,\ \hat{d}$ – TF-IDF вектор нового документа и его k-мерный скрытый вектор

В двуязычном LSA обучающим документом служит объединение узбекского и турецкого толкований связанной пары, слова снабжаются меткой языка, а на этапе проверки каждая сторона тестовой пары проецируется отдельно [15]. LDA рассматривает документ как смесь тем, а тему как распределение над словами [11]. Генеративный процесс имеет вид

$$\theta_d \sim Dir(\alpha), \quad \varphi_t \sim Dir(\beta), \quad z_{dn} \sim Mult\left(\theta_d\right), \quad w_{dn} \sim Mult\left(\varphi_{z_{dn}}\right) \tag{3}$$

где:

$\theta_d$ – распределение документа d по темам

$\varphi_t$ – распределение темы t по словам

$z_{dn},\ w_{dn}$ – латентная тема и наблюдаемое слово на позиции n документа d

$\alpha,\ \beta$ – параметры априорных распределений Дирихле

Латентные переменные оцениваются схемой Гиббса, в которой тема каждого слова пересэмплируется по условной вероятности [16]

$$p\left(z_i = t \mid z_{-i}, w\right) \propto \left(n_{d,t}^{-i} + \alpha\right) \frac{n_{t,w_i}^{-i} + \beta}{n_t^{-i} + V\beta} \tag{4}$$

где:

$n_{d,t}^{-i}$ – число слов документа d, отнесённых к теме t, без учёта слова i

$n_{t,w_i}^{-i}$ – число вхождений слова wi, отнесённых к теме t

$n_t^{-i}$ – общее число слов в теме t

$V$ – объём словаря

В расчётах использован эквивалентный, но быстрее сходящийся онлайн вариационный байесовский метод [17], число тем выбрано по мере когерентности [18]. Все признаки предложения объединяются в один вектор.

$$x_d = \left[x_d^{lex},\ x_d^{onto},\ \bar{v}_d,\ \hat{d}^{LSA},\ \hat{\theta}_d\right], \qquad \bar{v}_d = \frac{1}{|d|}\sum_{w \in d} v_w \tag{5}$$

где:

$x^{lex}$ – TF-IDF вектор лексем и их пар

$x^{onto}$ – онтологические признаки, то есть число полных и частичных совпадений, вхождения опорной и составных лексем, наибольшее покрытие

$\bar{v}_d$ – среднее векторов слов предложения

$\hat{d}^{LSA}$ – LSA вектор предложения

$\hat{\theta}_d$ – распределение предложения по темам LDA

Предлагаемая байесовская логистическая модель использует в качестве признаков показатели вхождения онтологических фразеологизмов, а весам приписывается гауссово априорное распределение с ковариацией, заданной смесью онтологического и векторного сходства фразеологизмов. Оценка максимума апостериорной вероятности сводится к минимизации выпуклого функционала

$$\Sigma(\rho) = (1-\rho)K_{onto} + \rho K_{emb}, \qquad J(w) = \sum_{i=1}^{N} \ln\left(1 + e^{-y_i w^\top x_i}\right) + \frac{1}{2\tau} w^\top \Sigma(\rho)^{-1} w \tag{6}$$

где:

$K_{onto}$ – матрица онтологического сходства фразеологизмов (Жаккар)

$K_{emb}$ – матрица косинусного сходства векторов фразеологизмов

$\rho$ – доля смешивания, ρ = 0 чистая онтология, ρ = 1 чистый word2vec

$\tau$ – ширина априорного распределения

$y_i,\ x_i$ – метка предложения и вектор показателей фразеологизмов

При положительно определённой $\Sigma(\rho)$ функционал $J(w)$ строго выпуклый, минимум единственный и находится квазиньютоновским методом, для устойчивости обращения к $\Sigma(\rho)$ добавлено $10^{-3}$ I.

Модель word2vec skip-gram обучена на лемматизированной коллекции с размерностью 100, окном 5, десятью отрицательными примерами и порогом частоты 3, словарь составил 16 160 лексем. FastText обучен с теми же настройками. Для LSA и LDA документом служили десять подряд идущих предложений, получено 15 347 документов при словаре 10 809 лексем, для LSA взято 50 компонент, для LDA 20 тем. Базовыми классификаторами служили линейный SVM, градиентный бустинг (200 деревьев глубины 4) и логистическая регрессия. Базовый набор признаков состоит из лексического TF-IDF и онтологических признаков, к нему поочерёдно добавлялись признаки word2vec, fastText, LSA и LDA. Оценка выполнена пятикратной перекрёстной проверкой с пятью начальными значениями генератора (25 измерений на вариант), значимость различий проверялась критерием Макнемара при уровне 0,05. Серии с word2vec и с тематическими моделями проводились отдельно, поэтому сравнение ведётся по разности с базовой моделью внутри серии. Для двуязычного LSA взята 1 191 пара с толкованиями с обеих сторон (881 уровня E1, 310 уровней E2 и E3). При простом разбиении пары распределяются случайно, при групповом все пары с одним турецким фразеологизмом или одним узбекским толкованием попадают целиком либо в обучение, либо в проверку.

**Результаты**

Таблица 1. Влияние признаков word2vec на результаты SVM и градиентного бустинга (5 начальных значений, 5 блоков, среднее ± стандартное отклонение)

| Модель | Набор признаков | Precision | Recall | F1 | ROC-AUC | p Макнемара |
|---|---|---|---|---|---|---|
| SVM | Базовый (лексика + онтология) | 0,664 ± 0,007 | 0,694 ± 0,009 | 0,679 ± 0,007 | 0,754 ± 0,006 | |
| SVM | Базовый + word2vec | 0,657 ± 0,009 | 0,684 ± 0,009 | 0,670 ± 0,009 | 0,744 ± 0,004 | 0,932 |
| GB | Базовый (лексика + онтология) | 0,636 ± 0,009 | 0,653 ± 0,016 | 0,645 ± 0,011 | 0,730 ± 0,005 | |
| GB | Базовый + word2vec | 0,685 ± 0,020 | 0,707 ± 0,011 | 0,696 ± 0,012 | 0,772 ± 0,006 | < 0,001 |

Для линейного SVM векторы слов не дали улучшения, различия по Макнемару случайны. Для градиентного бустинга усреднённый вектор word2vec поднял F1 с 0,645 до 0,696 и ROC-AUC с 0,730 до 0,772 ($p < 0{,}001$, 120 предложений в пользу варианта против 58). FastText улучшил градиентный бустинг слабее (F1 0,688 ± 0,007, $p = 0{,}032$) и не изменил SVM.

В байесовской логистической модели ($\tau = 1$, признаки 624 фразеологизмов, хотя бы раз полностью совпавших в золотом наборе) онтологическое априорное распределение резко превосходит Ridge, F1 0,626 ± 0,010 против 0,448 ± 0,020, ROC-AUC 0,766 против 0,644. Смешанная ковариация с $\rho = 0{,}5$ даёт F1 0,653 ± 0,007 и ROC-AUC 0,780 ± 0,007, прибавка от 0,02 до 0,03 сохраняется при всех $\tau$, но не достигает значимости по Макнемару ($p = 0{,}230$). Чистая ковариация word2vec ($\rho = 1$) даёт F1 0,638 ± 0,012 и не лучше чистой онтологии, следовательно, онтология остаётся основным источником, а word2vec лишь немного её дополняет. Средний модуль весов редких фразеологизмов растёт с 0,271 (Ridge) до 0,614 (онтология) и 0,725 (смесь), то есть смешанная ковариация сильнее всего поддерживает редкие единицы.

В LSA 50 компонент объясняют лишь 7,8 процента дисперсии матрицы, 100 компонент 12,9 процента, то есть спектр сингулярных значений убывает медленно и распределение слов не сосредоточено на нескольких осях. В LDA когерентность падает с ростом числа тем (−98,9 при K = 10, −108,0 при K = 20, −152,4 при K = 40), а темы разделяются по произведениям и именам персонажей, а не по семантическим полям.

Таблица 2. Влияние признаков LSA и LDA на выявление фразеологизмов, 860 предложений (F1, p Макнемара относительно базовой модели)

| Набор признаков | SVM F1 | p | GB F1 | p | LR F1 | p |
|---|---|---|---|---|---|---|
| Только онтология | 0,706 ± 0,031 | 0,001 | 0,674 ± 0,030 | 0,342 | 0,710 ± 0,030 | 0,129 |
| Базовый (лексика + онтология) | 0,684 ± 0,024 | | 0,673 ± 0,035 | | 0,703 ± 0,033 | |
| Базовый + LSA | 0,663 ± 0,032 | < 0,001 | 0,660 ± 0,035 | 0,025 | 0,677 ± 0,039 | < 0,001 |
| Базовый + LDA | 0,668 ± 0,031 | 0,002 | 0,670 ± 0,035 | 0,389 | 0,696 ± 0,033 | 0,023 |
| Базовый + LSA + LDA | 0,647 ± 0,040 | < 0,001 | 0,653 ± 0,030 | 0,001 | 0,663 ± 0,045 | < 0,001 |

Признаки LSA и LDA сами по себе дают F1 от 0,52 до 0,57 при случайном уровне около 0,5. Тема предложения почти не говорит о наличии в нём фразеологизма. При добавлении к базовой модели они не улучшают, а ухудшают результат. Для SVM и логистической регрессии все добавки достоверно отрицательны, для градиентного бустинга LDA нейтрален, а LSA также отрицателен. На 400 проверенных экспертом предложениях базовая модель даёт F1 0,797, при добавлении 460 машинно размеченных предложений F1 опускается к 0,68, что указывает на зашумлённость новых строк.

Двуязычный LSA (k = 100, 1 191 пара) при простом разбиении даёт средний косинус связанных пар 0,272 против 0,020 у случайных пар, AUC 0,781, косинус 0,296 для E1 против 0,203 для E2 и E3 (p < 0,001 по Манну и Уитни), точность Top 1 22,8 процента и Top 10 48,0 процента. Результат выглядит убедительно, однако это следствие утечки. В онтологии к одному турецкому фразеологизму нередко привязано несколько узбекских вариантов с одинаковым толкованием, например Ko‘zining ochiqligida и Ko‘zining tirikligida с толкованием barhayotligida связаны с турецким Sağlığında. При простом разбиении один вариант попадает в обучение, второй в проверку, и модель находит запомненное толкование, не выучив межъязыковую связь. При групповом разбиении средний косинус связанных пар падает до 0,087, AUC до 0,623, точность Top 1 до 3,6 процента и Top 10 до 18,0 процента, а различие между E1 и E2 E3 исчезает (p = 0,756). Разность F1 всех дистрибутивных признаков относительно базовой модели сведена на рисунке 1.

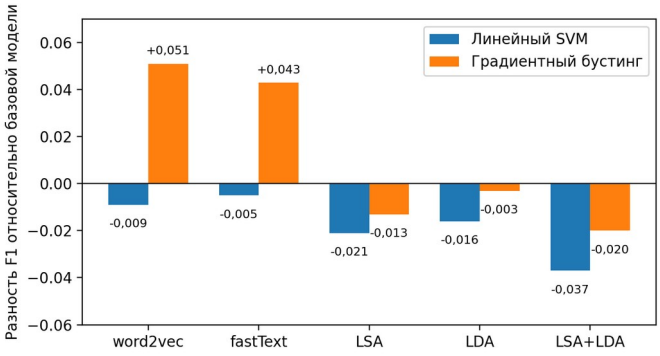



Рис. 1 Разность F1 признаков дистрибутивных моделей относительно базовой модели

**Обсуждение**

Word2vec помог градиентному бустингу и не помог линейному SVM, поскольку для линейной модели усреднённый вектор слов близок к линейному преобразованию TF-IDF вектора, тогда как деревья бустинга строят нелинейные пороги над его координатами. LSA и LDA не помогли ни одной модели, так как фразеологизм является локальным и зависящим от порядка слов явлением, а тематические модели работают на уровне документа как мешка слов, при этом в художественной коллекции темы разделяются по произведениям и персонажам и служат шумом для классификатора. Групповое разбиение, не допускающее попадания одного толкования в обе части выборки, следует принять как обязательное правило для экспериментов по эквивалентности. Ограничения работы состоят в небольшом объёме коллекции для векторов слов и в отсутствии экспертной проверки 460 предложений золотого набора.

**Заключение**

Усреднённый вектор word2vec статистически значимо повышает F1 градиентного бустинга на 0,051 и ROC-AUC на 0,042, даёт небольшую, но устойчивую прибавку в байесовской логистической регрессии через смешанную априорную ковариацию и не меняет результат линейного SVM. Признаки LSA и LDA сами по себе лишь немного превышают случайный уровень и достоверно ухудшают результат при добавлении к онтологическим признакам. Двуязычный LSA по толкованиям не определяет степень эквивалентности, а хороший результат при простом разбиении вызван утечкой повторяющихся толкований. Онтология остаётся основным источником сигнала при выявлении фразеологизмов, векторы слов дополняют её в нелинейных классификаторах, а тематические модели уровня документа для этой задачи непригодны.

**ЛИТЕРАТУРА**

1. *Sag I.A., Baldwin T., Bond F., Copestake A., Flickinger D.* Multiword expressions: a pain in the neck for NLP // Computational Linguistics and Intelligent Text Processing (CICLing 2002). Lecture Notes in Computer Science. – Berlin: Springer, 2002. – Vol. 2276. – P. 1–15.

2. *Constant M., Eryiğit G., Monti J., van der Plas L., Ramisch C., Rosner M., Todirascu A.* Multiword expression processing: A survey // Computational Linguistics. – 2017. – Vol. 43, № 4. – P. 837–892.

3. *Ramisch C., Cordeiro S.R., Savary A. et al.* Edition 1.1 of the PARSEME shared task on automatic identification of verbal multiword expressions // Proceedings of the Joint Workshop on Linguistic Annotation, Multiword Expressions and Constructions (LAW-MWE-CxG-2018). – Santa Fe, 2018. – P. 222–240.

4. *Joshi P., Santy S., Budhiraja A., Bali K., Choudhury M.* The state and fate of linguistic diversity and inclusion in the NLP world // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. – 2020. – P. 6282–6293.

5. *Madetbayeva N.B.* O‘zbek tili iboralari ontologiyasi va o‘xshashlik o‘lchovlari // UBMK 2026 xalqaro anjumani materiallari. – 2026.

6. *Nazirova E., Madetbayeva N.B. и др.* Tayanch vektorlar mashinasi asosida o‘zbek tili iboralarini aniqlash // MPMM 2026 xalqaro anjumani materiallari. – 2026.

7. *Mikolov T., Chen K., Corrado G., Dean J.* Efficient estimation of word representations in vector space // ICLR Workshop Track. – 2013. – arXiv:1301.3781.

8. *Mikolov T., Sutskever I., Chen K., Corrado G., Dean J.* Distributed representations of words and phrases and their compositionality // Advances in Neural Information Processing Systems. – 2013. – Vol. 26. – P. 3111–3119.

9. *Bojanowski P., Grave E., Joulin A., Mikolov T.* Enriching word vectors with subword information // Transactions of the Association for Computational Linguistics. – 2017. – Vol. 5. – P. 135–146.

10. *Deerwester S., Dumais S.T., Furnas G.W., Landauer T.K., Harshman R.* Indexing by latent semantic analysis // Journal of the American Society for Information Science. – 1990. – Vol. 41, № 6. – P. 391–407.

11. *Blei D.M., Ng A.Y., Jordan M.I.* Latent Dirichlet allocation // Journal of Machine Learning Research. – 2003. – Vol. 3. – P. 993–1022.

12. *Levy O., Goldberg Y.* Neural word embedding as implicit matrix factorization // Advances in Neural Information Processing Systems. – 2014. – Vol. 27. – P. 2177–2185.

13. *Salehi B., Cook P., Baldwin T.* A word embedding approach to predicting the compositionality of multiword expressions // Proceedings of NAACL-HLT 2015. – Denver, 2015. – P. 977–983.

14. *Eckart C., Young G.* The approximation of one matrix by another of lower rank // Psychometrika. – 1936. – Vol. 1, № 3. – P. 211–218.

15. *Dumais S.T., Letsche T.A., Littman M.L., Landauer T.K.* Automatic cross-language retrieval using latent semantic indexing // AAAI Spring Symposium on Cross-Language Text and Speech Retrieval. – 1997.

16. *Griffiths T.L., Steyvers M.* Finding scientific topics // Proceedings of the National Academy of Sciences. – 2004. – Vol. 101, suppl. 1. – P. 5228–5235.

17. *Hoffman M.D., Blei D.M., Bach F.* Online learning for latent Dirichlet allocation // Advances in Neural Information Processing Systems. – 2010. – Vol. 23. – P. 856–864.

18. *Mimno D., Wallach H.M., Talley E., Leenders M., McCallum A.* Optimizing semantic coherence in topic models // Proceedings of EMNLP 2011. – Edinburgh, 2011. – P. 262–272.

УДК 81'322.2:519.612

# ПРИМЕНЕНИЕ МЕТОДА ГАУССА ДЛЯ РАЗРЕШЕНИЯ ЛЕКСИЧЕСКОЙ МНОГОЗНАЧНОСТИ В ЗАДАЧАХ МНОГОЯЗЫЧНОГО ЭЛЕКТРОННОГО ПЕРЕВОДА (НА МАТЕРИАЛЕ УЗБЕКСКОГО, КЫРГЫЗСКОГО И КАРАКАЛПАКСКОГО ЯЗЫКОВ)

# APPLICATION OF THE GAUSSIAN ELIMINATION METHOD FOR LEXICAL DISAMBIGUATION IN MULTILINGUAL ELECTRONIC TRANSLATION (BASED ON UZBEK, KYRGYZ AND KARAKALPAK LANGUAGES)

Назирова Э.Ш., Абидова Ш.Б, Узакова М.А., Усманова К.А., Медетбаева Н.Ш.,

*[1]Ташкентский университет информационных технологий, Ташкент, Узбекистан*

e-mail: marynmm262321@gmail.com

***Аннотация***

*В статье рассматривается возможность применения метода Гаусса (метода приведения матрицы к треугольному виду) как инструмента разрешения лексической многозначности при построении систем электронного перевода для близкородственных тюркских языков узбекского, кыргызского и каракалпакского. Актуальность работы обусловлена тем, что для перечисленных языков характерна ограниченность параллельных корпусов, что затрудняет применение статистических и нейросетевых методов разрешения неоднозначности, требующих больших объёмов размеченных данных. Предлагается формализовать задачу выбора корректного варианта перевода многозначного слова как систему линейных алгебраических уравнений, в которой неизвестными являются веса контекстных признаков (соседние слова, морфологические показатели, частотность совместной встречаемости), а свободными членами - экспертные оценки соответствия перевода контексту, полученные на обучающей выборке. Показано, что решение такой системы методом Гаусса позволяет получить точные, а не приближённые значения весов при относительно небольшом объёме обучающих примеров, что особенно важно для языков с ограниченными языковыми ресурсами. На иллюстративном примере узбекского слова «qol» продемонстрирован полный цикл: формализация признаков, построение расширенной матрицы, прямой и обратный ход метода Гаусса, применение полученных весов к разрешению неоднозначности в новом предложении. Обсуждаются условия применимости метода (невырожденность матрицы коэффициентов, соотношение числа признаков и обучающих примеров), а также его ограничения по сравнению с вероятностными и нейросетевыми подходами. Сделан вывод о целесообразности использования предложенного метода в качестве вспомогательного, интерпретируемого модуля в гибридных системах машинного перевода для низкоресурсных языков.*

***Ключевые слова:*** *машинный перевод; электронный перевод; метод Гаусса; определитель матрицы; лексическая многозначность; disambiguation; тюркские языки; узбекский язык; кыргызский язык; каракалпакский язык; низкоресурсные языки.*

**Abstract**

The paper examines the feasibility of applying the Gaussian elimination method (reduction of a matrix to triangular form) as a tool for lexical disambiguation in the development of electronic translation systems for closely related Turkic languages - Uzbek, Kyrgyz, and Karakalpak. The relevance of the study stems from the limited availability of

parallel corpora for these languages, which constrains the use of statistical and neural disambiguation methods that require large amounts of annotated data. The task of selecting the correct translation of a polysemous word is formalised as a system of linear algebraic equations, in which the unknowns are the weights of contextual features (neighbouring words, morphological indicators, co-occurrence frequency), and the constant terms are expert relevance scores obtained from a training sample. It is shown that solving such a system via Gaussian elimination yields exact rather than approximate weight values even with a relatively small training set, which is particularly relevant for languages with limited digital resources. Using the Uzbek word "qol" as an illustrative example, the full cycle is demonstrated: feature formalisation, construction of the augmented matrix, forward elimination and back-substitution, and application of the resulting weights to disambiguation in a new sentence. The conditions for applicability of the method (non-singularity of the coefficient matrix, the ratio of features to training examples) and its limitations relative to probabilistic and neural approaches are discussed. It is concluded that the proposed method is best used as an auxiliary, interpretable module within hybrid machine translation systems for low-resource languages.

***Keywords:*** *machine translation; electronic translation; Gaussian elimination; matrix determinant; lexical ambiguity; disambiguation; Turkic languages; Uzbek language; Kyrgyz language; Karakalpak language; low-resource languages.*

**Введение**

Развитие систем электронного перевода для тюркских языков Центральной Азии - узбекского, кыргызского и каракалпакского - сдерживается прежде всего недостатком параллельных текстовых корпусов и лексических ресурсов. Исследователи неоднократно отмечали, что данные языки относятся к категории низкоресурсных: объём доступных для обучения параллельных данных на один-два порядка меньше, чем для таких пар, как английский–французский или английский–немецкий [1; 2]. Это обстоятельство напрямую влияет на качество нейросетевых систем перевода, поскольку модели трансформерной архитектуры и другие статистические подходы демонстрируют устойчивые результаты преимущественно при наличии значительных объёмов размеченных данных [2].

Отдельную сложность представляет разрешение лексической многозначности (word sense disambiguation) - выбор правильного значения слова из нескольких возможных в зависимости от контекста. Для тюркских языков, обладающих развитой агглютинативной морфологией, данная задача осложняется ещё и тем, что одна и та же основа может получать различное значение в зависимости от присоединяемых аффиксов и синтаксической позиции в предложении [3]. В существующих работах по машинному переводу между тюркскими языками разрешение неоднозначности реализуется, как правило, либо через модели статистических языковых моделей [3], либо через привлечение конечно-автоматных морфологических анализаторов в рамках систем машинного перевода, основанных на правилах (rule-based MT), таких как Apertium [4]. Известны также работы, посвящённые непосредственно алгоритмам перевода между узбекским и каракалпакским языками [5] и построению функциональных моделей электронного переводчика для данной языковой пары на основе методологии IDEF0 [6].

Вместе с тем методы линейной алгебры, и в частности метод Гаусса (метод последовательного исключения переменных, предложенный К. Ф. Гауссом), несмотря на широкое использование в вычислительной математике - при обращении матриц, вычислении ранга и определителя, решении систем линейных уравнений [7; 8] - практически не рассматривались в литературе как самостоятельный инструмент разрешения лексической многозначности в задачах машинного перевода низкоресурсных языков. Это определяет научную новизну настоящей работы: мы предлагаем формализовать выбор варианта перевода многозначного слова как систему

линейных уравнений относительно весов контекстных признаков и решить её точным методом, а не итеративным приближённым алгоритмом.

Цель исследования - обосновать и продемонстрировать на конкретном примере методику применения метода Гаусса для разрешения лексической многозначности при переводе между узбекским, кыргызским и каракалпакским языками.

Для достижения поставленной цели решались следующие задачи: 1) формализовать задачу разрешения многозначности слова в виде системы линейных алгебраических уравнений; 2) разработать пошаговую процедуру построения и решения такой системы методом Гаусса; 3) апробировать процедуру на иллюстративном лексическом примере; 4) определить условия применимости и ограничения предложенного метода.

**Материалы и методы**

**Формализация задачи**

В качестве материала исследования использовались примеры многозначных лексических единиц узбекского языка, имеющих различные соответствия в кыргызском и каракалпакском языках в зависимости от контекста. Методологическую основу составили: а) аппарат линейной алгебры - метод Гаусса (последовательное исключение переменных) для решения систем линейных уравнений и вычисления определителя матрицы [7]; б) методы корпусной лингвистики - извлечение контекстных признаков из размеченных примеров словоупотребления.

Пусть многозначное слово w исходного языка имеет k возможных значений (соответственно k вариантов перевода) $s_1$, $s_2$, …, $s_k$. Для каждого варианта значения $s_j$ вводится набор из n контекстных признаков $F_1$, $F_2$, …, $F_n$, отражающих: тип соседних слов (частеречная и семантическая принадлежность), наличие определённых морфологических показателей (падежных, притяжательных, глагольных аффиксов), а также статистическую частоту совместной встречаемости данного варианта перевода с элементами контекста в обучающем корпусе.

Задача состоит в нахождении весовых коэффициентов $w_1$, $w_2$, …, $w_n$, при которых взвешенная сумма признаков наилучшим образом соответствует экспертной оценке уместности перевода в конкретном контексте (целевому баллу, назначенному на этапе разметки обучающих примеров):

$$w_1 \cdot F_1 + w_2 \cdot F_2 + \ldots + w_n \cdot F_n = b,$$

где b - целевой балл, полученный на размеченном обучающем предложении. Если для одного варианта значения слова взять n обучающих предложений (n - число неизвестных весов), получается система из n линейных уравнений с n неизвестными, которая в матричной форме записывается как $A \cdot x = b$, где A - матрица значений признаков, x - вектор искомых весов, b - вектор целевых баллов.

**Процедура решения методом Гаусса**

Решение системы $A \cdot x = b$ осуществлялось по стандартной схеме метода Гаусса, включающей два этапа [7; 8]:

1) прямой ход - построение расширенной матрицы [A | b] и последовательное обнуление элементов ниже главной диагонали при помощи элементарных преобразований строк (перестановка строк, умножение строки на ненулевую константу, прибавление к одной строке другой строки, умноженной на константу) с целью приведения матрицы к верхнетреугольному (ступенчатому) виду;

2) обратный ход - последовательное вычисление неизвестных весов $w_n$, $w_{n-1}$, …, $w_1$, начиная с последней строки полученной треугольной матрицы.

Дополнительно вычислялся определитель матрицы коэффициентов A: значение $\det(A) \neq 0$ указывает на существование единственного решения системы (обучающие признаки линейно независимы), тогда как $\det(A) = 0$ свидетельствует о вырожденности системы - избыточности или противоречивости выбранного набора признаков и

обучающих примеров, что использовалось как диагностический критерий качества обучающей выборки.

После нахождения весов $w_1$, …, $w_n$ для каждого из k возможных значений многозначного слова итоговое решение о выборе перевода для нового (не входившего в обучающую выборку) контекста принималось по правилу максимума суммарной оценки:

$$\text{Score}(s_j) = w_1^{(j)} \cdot F_1 + w_2^{(j)} \cdot F_2 + \ldots + w_n^{(j)} \cdot F_n, \quad \hat{s} = \arg\max \text{Score}(s_j),\ j = 1, \ldots, k.$$

**Результаты**

Апробация предложенной методики проведена на примере узбекского слова «qol», которое в зависимости от контекста может соответствовать одному из двух значений: 1) «рука» (существительное; кырг. «кол», ккалп. «qol»); 2) «оставайся» (форма повелительного наклонения глагола «qolmoq»; кырг. «кал», ккалп. «qal»).

Для каждого значения было выделено три контекстных признака: $F_1$ - наличие рядом слова, обозначающего предмет или часть тела (бинарный/счётный признак); $F_2$ - наличие падежного или притяжательного суффикса при слове (счётный признак); $F_3$ - частота совместной встречаемости данного варианта перевода с элементами контекста, нормированная в диапазоне [0; 1].

Обучающая выборка для значения «рука» (три предложения с экспертной оценкой соответствия b):

| **Предложение** | **$F_1$** | **$F_2$** | **$F_3$** | **b** |
|---|---|---|---|---|
| «Onamning qo'li og'riyapti» («у мамы рука болит») | 1 | 1 | 1 | 6 |
| «Qo'lida kitob bor edi» («в руке была книга») | 2 | 3 | 1 | 11 |
| «U qo'lini ko'tardi» («он поднял руку») | 1 | 1 | 2 | 9 |

Соответствующая система линейных уравнений относительно весов $w_1$, $w_2$, $w_3$:

$$w_1 + w_2 + w_3 = 6 \qquad 2w_1 + 3w_2 + w_3 = 11 \qquad w_1 + w_2 + 2w_3 = 9$$

Расширенная матрица системы приведена к треугольному виду в результате следующих преобразований: вторая строка заменена разностью ($R_2 - 2R_1$), третья строка - разностью ($R_3 - R_1$). После прямого хода матрица приняла вид, в котором ниже главной диагонали расположены нулевые элементы; обратный ход дал точное решение системы: $w_3 = 3$, $w_2 = 2$, $w_1 = 1$. Определитель матрицы коэффициентов отличен от нуля ($\det(A) = 1$), что подтверждает единственность найденного решения и линейную независимость выбранных признаков на данной обучающей выборке.

Аналогичная процедура, применённая к обучающей выборке для значения «оставайся» (предложения с формой повелительного наклонения), дала веса $w_1' = 3$; $w_2' = 0{,}5$; $w_3' = 0{,}5$, что отражает решающую роль признака $F_1$ (императивный контекст) и второстепенную роль морфологических и частотных признаков для данного значения, поскольку соответствующая словоформа не принимает падежных или притяжательных аффиксов.

Полученные наборы весов были применены к новому предложению «Bolaning qo'lida o'yinchoq bor» («в руке ребёнка игрушка»), не входившему в обучающую выборку. Значения признаков для этого предложения составили: $F_1 = 1$, $F_2 = 1$, $F_3 = 0{,}7$. Итоговые оценки:

| **Значение слова** | **Score** |
|---|---|
| «рука» | $1 \cdot 1 + 2 \cdot 1 + 3 \cdot 0{,}7 = 5{,}1$ |
| «оставайся» | $3 \cdot 0 + 0{,}5 \cdot 0 + 0{,}5 \cdot 0{,}05 = 0{,}025$ |

Поскольку Score(«рука») существенно превышает Score(«оставайся»), система однозначно выбирает значение «рука», что соответствует переводу «кол» на кыргызский язык и «qol» - на каракалпакский. Таким образом, продемонстрирован полный цикл применения метода Гаусса для разрешения лексической многозначности:

от формализации признаков до принятия решения о переводе на материале, не участвовавшем в обучении весов.

**Обсуждение**

Полученные результаты показывают, что метод Гаусса применим для разрешения лексической многозначности при условии, что число обучающих примеров для каждого значения слова совпадает с числом выбранных контекстных признаков, а сама матрица признаков невырождена. В этом состоит принципиальное отличие предложенного подхода от статистических и нейросетевых методов disambiguation, которые обычно требуют существенно больших объёмов размеченных данных и находят веса приближённо, посредством итеративной оптимизации (градиентный спуск, метод максимального правдоподобия) [2; 3].

Преимущество точного решения заключается в интерпретируемости результата: полученные веса допускают содержательную лингвистическую интерпретацию (например, доминирующая роль частотности или морфологического показателя для конкретного значения слова), что затруднено при использовании нейросетевых представлений с большим числом параметров. Для языков с ограниченными корпусами, к которым относится каракалпакский язык [4; 9] и, в меньшей степени, кыргызский, возможность получения точного решения на основе десятков, а не тысяч примеров представляет практическую ценность.

Вместе с тем метод обладает рядом существенных ограничений. Во-первых, при числе обучающих примеров, отличном от числа признаков, система становится пере- или недоопределённой, и требуется переход к методу наименьших квадратов или к регуляризации, что выходит за рамки классической схемы метода Гаусса. Во-вторых, вычислительная сложность метода Гаусса составляет $O(n^3)$ относительно числа признаков, что ограничивает его использование при большом количестве признаков или при необходимости учитывать широкий контекст (в отличие, например, от механизмов внимания в трансформерных архитектурах). В-третьих, вырожденность матрицы коэффициентов ($\det(A) = 0$), возникающая при линейной зависимости признаков, требует дополнительной диагностики и не всегда содержательно интерпретируется лингвистически.

С учётом сказанного, предложенный метод целесообразно рассматривать не как самостоятельную систему машинного перевода, а как вспомогательный модуль разрешения многозначности в составе гибридной архитектуры, дополняющей морфологический анализ и правило-ориентированные компоненты, применяемые в существующих системах перевода между тюркскими языками [4; 5; 6]. Такое сочетание может быть особенно полезным на начальных этапах разработки систем электронного перевода для языков, не располагающих объёмными параллельными корпусами.

**Заключение**

В работе показано, что метод Гаусса может быть использован в качестве точного и интерпретируемого инструмента разрешения лексической многозначности при построении систем электронного перевода для узбекского, кыргызского и каракалпакского языков. Задача выбора варианта перевода многозначного слова сформулирована как система линейных алгебраических уравнений относительно весов контекстных признаков; предложена пошаговая процедура её решения, включающая прямой и обратный ход метода Гаусса, а также диагностику вырожденности системы через вычисление определителя матрицы коэффициентов. Работоспособность методики продемонстрирована на примере разрешения многозначности узбекского слова «qol».

Основным преимуществом предложенного подхода является возможность получения точных значений весов признаков при ограниченном объёме обучающих данных, что актуально для низкоресурсных языков. К числу ограничений отнесены

жёсткое требование к соотношению числа признаков и обучающих примеров, кубическая вычислительная сложность и необходимость дополнительной обработки вырожденных случаев. Направлением дальнейших исследований является интеграция предложенного метода в гибридную архитектуру машинного перевода совместно с морфологическими анализаторами и его апробация на расширенном лексическом материале трёх рассматриваемых языков.

**Список литературы**

1. Joshi P., Santy S., Budhiraja A., Bali K., Choudhury M. The State and Fate of Linguistic Diversity and Inclusion in the NLP World // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020. P. 6282–6293.
2. An Integrated Approach to Adapting Open-Source AI Models for Machine Translation of Low-Resource Turkic Languages // Computers. 2026. Vol. 15, No. 2. Art. 73. DOI: 10.3390/computers15020073.
3. Altintas K., Cicekli I. A Machine Translation System between a Pair of Closely Related Languages // Proceedings of the 17th International Symposium on Computer and Information Sciences. 2002.
4. Open Language Data Initiative: Advancing Low-Resource Machine Translation for Karakalpak [Электронный ресурс] // arXiv:2409.04269. URL: https://arxiv.org/abs/2409.04269 (дата обращения: 05.09.2026).
5. Kadirov A. The Algorithm of Machine Translation from Uzbek to Karakalpak // Proceedings of TurkLang-2015. 2015. P. 24.
6. Mathematical Model and Algorithm for Grammatical Editing of Given Words in Uzbek Language [Электронный ресурс]. URL: https://www.researchgate.net/publication/392171308 (дата обращения: 05.09.2026).
7. Faddeev D. K., Faddeeva V. N. Вычислительные методы линейной алгебры. М.: Физматлит, 1963. 656 с.
8. Golub G. H., Van Loan C. F. Matrix Computations. 3rd ed. Baltimore: Johns Hopkins University Press, 1996. 728 p.
9. Tukeyev U. A New Computational Model for Turkic Languages Morphology and Processing // Journal of Problem in Computer Science and Information Technologies. 2022.

# Solving the Deformation Problem of a Mesh Plate with a Complex Shape under External Forces.

Fakhriddin Nuraliev [1], Begdulla Sultanov [2],
*Mahkam Artikbayev [3,a)], Aqilbay Orazbayev [3,b)]*
[a)]Corresponding author : m.a.artikbayev@mail.ru;
[b)]orazbaevaqil@gmail.com;
[1]*Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Tashkent, Uzbekistan*
[2,3]*Nukus state technical university, Nukus,Uzbekistan,*

***Abstract.*** *This paper presents computational algorithms and specialized software tools for analyzing the deformation of mesh plates with complex geometry through computational experiments. The mathematical model combines the Newmark and Gauss numerical methods with the R-function method (RFM) and the Bubnov-Galerkin variational method. Analytical solution structures were constructed via RFM to satisfy the prescribed boundary conditions exactly. Building on this algorithm, a modular software architecture was developed to automate the mathematical modeling of deformation states in complex mesh configurations. The resulting findings and technical recommendations help improve the reliability, strength, stability, and operational performance of various engineering parts and components.*

***Keywords:*** *mathematical modeling, mesh plates, Hamilton-Ostrogradsky variational principle, computational algorithm, Bublov-Galerkin mothod, R-function method (RFM).*

## I. INTRODUCTION

In recent years, researchers have paid particular attention to developing reliable and effective mathematical models for studying the structural properties of mesh plates and shells used as lattice elements. The diverse physical and mechanical properties of these components play a key role in establishing general performance indicators for such structures.

Worldwide research efforts are focused on developing computational algorithms and software tools for solving complex modeling problems related to mesh plates of non-standard configuration under various external loading conditions.

Today, mesh shells and plates are widely used in engineering, serving as key structural components in civil construction, shipbuilding, aerospace, and mechanical engineering. The study of the deformation behavior of mesh plates with complex geometry — particularly under dynamic or static loading — therefore remains one of the pressing problems in this field.

## II. MATHEMATICAL MODELING

The equilibrium equations of a mesh plate element in the Cartesian coordinate system are expressed as follows [1]:

$$\frac{\partial Q_1}{\partial x_1} + \frac{\partial Q_2}{\partial y} + Z = 0 \tag{1}$$

where:

$$Q_1 = \frac{\partial H_2}{\partial y} - \frac{\partial M_1}{\partial x}, \quad Q_2 = \frac{\partial H_1}{\partial x} - \frac{\partial M_2}{\partial y}.$$

Here $Z$ – external load; parameters $M_1, M_2$ - bending moments, a $H_1, H_2$ - torsional moments, $Q_1, Q_2$ - shear forces[1-2].

Bending and torsional moments, when the number of bars is equal to n (general case), are determined by the following formulas:[2]

$$\left.\begin{aligned} M_1 &= -(D_{11}\chi_1 + D_{12}*\chi_2 + 2D_{16}*\tau) \\ M_2 &= -(D_{21}\chi_1 + D_{12}*\chi_2 + 2D_{16}*\tau) \\ H_1 &= D_{61}{}^{*(i)}\chi_1 + D_{62}{}^{*(i)}\chi_2 + D_{66}{}^{*(i)}, i = 1,2 \end{aligned}\right\} \quad (2)$$

here:

$$\left.\begin{aligned} D_{11}^* &= D_{11} + K_{11}, D_{12}^* = D_{12} - K_{12}, D_{16}^* = D_{16} - \frac{1}{2}K_{16}, \\ D_{21}^* &= D_{k1} - K_{11}, D_{22}^* = D_{22} + K_{22}, D_{26}^* = D_{26} + \frac{1}{2}K_{26}, \\ D_{16}^{*(i)} &= D_{61} + K_{61}^{(i)}, D_{26}^{*(i)} = D_{62} - K_{62}^{(i)}, \\ D_{66}^{*(i)} &= D_{66} - K_{66}^{(i)}, i = 1,2, \end{aligned}\right\} \quad (3)$$

$$\left.\begin{aligned} D_{11} &= \sum_{i=1}^{n} I_i C_i^4, D_{12} = \sum_{i=1}^{n} I_i S_i^2 C_i^2, D_{66} = 2D_{12} \\ D_{12} &= \sum_{i=1}^{n} I_i S_i C_i^3, D_{22} = \sum_{i=1}^{n} I_i S_i^4, D_{26} = \sum_{i=1}^{n} I_i S_i^3 C_i, D_{ij} = D_{ij}, \\ K_{61}^{(1)} &= K_{62}^{(1)} = \sum_{i=1}^{n} C_i S_i C_i^3, K_{66}^{(1)} = \sum_{i=1}^{n} C_i c_i^2 \cos 2\phi_i, \\ K_{61}^{(2)} &= K_{62}^{(2)} = \sum_{i=1}^{n} C_i S_i^2 C_i, K_{66}^{(2)} = \sum_{i=1}^{n} C_i S_i^2 \cos 2\phi_i, \\ K_i &= E_i F_i / a_i, I = F_i J_{1i} / a_i, C_i = G_i J_{3i/a_i}. \end{aligned}\right\} \quad (4)$$

We will give the description of the parameters presented in (4). They represent the ratios of the corresponding stiffness characteristics of the rods to the distance between their axes; $a_i$ - distance between the axes of adjacent rods; $F_i$ - cross-sectional area of the rod; $J_{1i}, J_{3i}$ - principal (central) moments of inertia; $n$ – number of rod families in the mesh; $\phi_i$ - angle between the axis $\alpha$ and the axis of the rod (measured from the axis $\alpha$ in the direction of the rod's axis $\beta$); $S_i = \sin\phi_i, C_i = \cos\phi_i$, [1-3]

$$x_1 = -\frac{\partial^2 W}{\partial x^2}, x_1 = -\frac{\partial^2 W}{\partial x^2}, \tau = -\frac{\partial^2 W}{\partial x \partial y}.$$

Substituting (2) considering (3) into (1), we obtain the equilibrium equation of mesh plates with respect to deflection - $W$ [1-4]:

$$K_1^{(0)} = \sum_{i=1}^{h} (1 - 6 j_i^2 c_i^2) c_i, \quad K_2^{(0)} = \sum_{i=1}^{h} C_i \cos^2 2\phi_i. \quad (5)$$

Substituting (4) into (3), and then the resulting relations into (2), we have[4-6]:

$$\left.\begin{aligned} Q_1 &= -\sum_{i=1}^{4} \nabla_i^2 (I_i c_i \nabla_i + C_i s_i \Delta_i) w, \\ Q_1 &= -\sum_{i=1}^{4} \nabla_i^2 (I_i s_i \nabla_i + C_i c_i \Delta_i) w, \end{aligned}\right\} \quad (6)$$

where $n$ – direction of the external normal; ($\delta$ - sign of the variation operation; $M_n$ - normal bending moment,

$$M_n = M_1 \cos^2\alpha + (H_1 + H_2)\cos\alpha \sin\alpha + M_2 \sin 2\alpha \tag{7}$$

$R_n$ - normal reaction of the support, which has the form of[6-8]:

$$\begin{gathered} R_n = Q_n + \frac{\partial M_n \tau}{\partial S}, \\ Q_n = Q_1 \cos\alpha + Q_2 \sin\alpha, \\ M_n = H_1(\cos^2\alpha - \sin^2\alpha) + (M_2 - M_1)\cos\alpha \sin\alpha = \\ = H_1 \cos 2\alpha + \frac{1}{2}(M_2 - M_1)\sin 2\alpha, \end{gathered} \tag{8}$$

here ($\alpha$ - Angle between the external normal and the axis $x$; $W$ – deflection of the plate; $S$ – arc length for the boundary $\Gamma$ area of the plate[6-8].

## III. COMPUTATIONAL ALGORITHM OF NUMERICAL SOLUTION OF THE PROBLEM

To numerically solve problems (2)-(4), a comprehensive computational algorithm was developed. This algorithm combines the R-function method (RFM), the Newmark method, the Bubnov-Galerkin variational method, and a set of numerical techniques adapted for mesh plates with complex structural configurations [14-16]. The solution procedure consists of the following steps:

1. Linearization of the system of differential equations containing nonlinear partial derivatives.
2. Construction of coordinate functions (solution structures) satisfying the prescribed boundary conditions, using V.L. Rvachev's R-function method (RFM).
3. Spatial discretization of the equations using the Newmark method and the Bubnov-Galerkin variational method.
4. Solution of the resulting discrete equations to determine the unknown coefficients in the solution structures.
5. Determination of the unknown functions — the tangential and normal displacements of the plate's middle surface.

When solving the problem using iterative numerical methods based on the above steps, the functions $u_i(x,y,t), v_i(x,y,t)$ and $w_i(x,y,t)$ are determined for each iteration.

## IV. COMPUTATIONAL EXPERIMENTS

The equation of the geometry of the domain in this case takes the form of:

$$\omega = \omega_1 \wedge \omega_2 \wedge_0 \omega_3. \tag{9}$$

$$\omega_1 = \left(\frac{3}{4} - y^2\right)/\sqrt{3},\ \ \omega_2 = f_1 \wedge_0 f_3,\ \omega_3 = f_4 \wedge_0 f_5,$$

$$f_1 = \left(\sqrt{3} - \sqrt{3}x - y\right)/2,\ f_3 = \left(\sqrt{3} + \sqrt{3}x - y\right)\sqrt{2},$$

$$f_4 = \frac{\sqrt{3}}{2}\left(\sqrt{3} + \sqrt{3}x + y\right)/2,\ \ f_5 = \left(\sqrt{3} - \sqrt{3}x + y\right)/2.$$

It should be noted that the expressions obtained here for the moments do not exactly coincide with the standard bending-moment formulas for regular orthotropic elastic plates. To

construct structural formulas for the moments of mesh plates, we therefore reduce them to the standard form.

The undetermined component of the structure is represented as:

$$\Phi = \sum_{i+j=0}^{h} C_{ij}\phi_{ij}(x,y) = \sum\sum C_{ij}\phi_i(x)\phi_j(y) \tag{10}$$

In formula (10) $\phi_i(x)$ and $\phi_j(y)$ - are the complete systems of basis polynomials (power, trigonometric, Chebyshev, etc.) and n is the maximum order of the basis polynomial.

Let us now consider a hexagonal plate with a rhomboidal mesh structure, as shown in Figure 1. Suppose the boundary of the rhomboidal mesh plate shown in Fig. 1 is rigidly clamped. The structure of the solution to this problem then takes the following form:

$$W = \omega^2\Phi.$$

Here $\omega$ it is determined by the formula (9) and is represented in the form of (10).

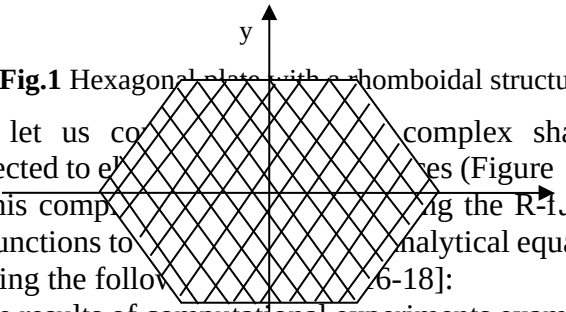



**Fig.1** Hexagonal plate with a rhomboidal structure

As an example, let us co[illegible] complex shape used in transformer manufacturing and subjected to e[illegible]es (Figure [illegible]. The analytical equation of the thin plate with this comp[illegible]ng the R-function method. Here, the transition from logical functions to [illegible]nalytical equations is carried out within the RFM framework, using the follow[illegible]6-18]:

We now turn to the results of computational experiments examining the reinforcement of complex-shaped mesh plates under various conditions. Based on the developed computational algorithm, the problem was solved and the obtained results were analyzed [18-19].

Table 1. The results of the deflection ($W$) and bending moment calculations(nk=3 clutoch=10)

| X | Y | W | MX | MY | MXY | MXZ | MYZ | MSZ |
|---|---|---|---|---|---|---|---|---|
| -0.90 | 0.000 | 0.00009797 | 0.02030320 | 0.02030320 | 0.000 | 0.02030359 | 0.02030359 | 0.000 |
| -0.80 | 0.000 | 0.00071676 | 0.02420758 | 0.02420758 | 0.000 | 0.02420805 | 0.02420805 | 0.000 |
| -0.70 | 0.000 | 0.00205804 | 0.01309533 | 0.01309533 | 0.000 | 0.01309558 | 0.01309558 | 0.000 |
| -0.60 | 0.000 | 0.00400094 | -0.00533160 | -0.00533160 | 0.000 | -0.00533170 | -0.00533170 | 0.000 |
| -0.50 | 0.000 | 0.00625870 | -0.02450353 | -0.02450353 | 0.000 | -0.02450400 | -0.02450400 | 0.000 |
| -0.40 | 0.000 | 0.00851668 | -0.04072931 | -0.04072931 | 0.000 | -0.04073009 | -0.04073009 | 0.000 |
| -0.30 | 0.000 | 0.01050956 | -0.05270625 | -0.05270625 | 0.000 | -0.05270726 | -0.05270726 | 0.000 |
| -0.20 | 0.000 | 0.01204724 | -0.06052575 | -0.06052575 | 0.000 | -0.06052691 | -0.06052691 | 0.000 |
| -0.10 | 0.000 | 0.01301098 | -0.06481740 | -0.06481740 | 0.000 | -0.06481864 | -0.06481864 | 0.000 |
| 0.00 | 0.000 | 0.01333857 | -0.06617114 | -0.06617114 | 0.000 | -0.06617241 | -0.06617241 | 0.000 |
| 0.10 | 0.000 | 0.01301098 | -0.06481740 | -0.06481740 | 0.000 | -0.06481864 | -0.06481864 | 0.000 |
| 0.20 | 0.000 | 0.01204724 | -0.06052575 | -0.06052575 | 0.000 | -0.06052691 | -0.06052691 | 0.000 |
| 0.30 | 0.000 | 0.01050956 | -0.05270625 | -0.05270625 | 0.000 | -0.05270726 | -0.05270726 | 0.000 |
| 0.40 | 0.000 | 0.00851668 | -0.04072931 | -0.04072931 | 0.000 | -0.04073009 | -0.04073009 | 0.000 |
| 0.50 | 0.000 | 0.00625870 | -0.02450353 | -0.02450353 | 0.000 | -0.02450400 | -0.02450400 | 0.000 |
| 0.60 | 0.000 | 0.00400094 | -0.00533160 | -0.00533160 | 0.000 | -0.00533170 | -0.00533170 | 0.000 |
| 0.70 | 0.000 | 0.00205804 | 0.01309533 | 0.01309533 | 0.000 | 0.01309558 | 0.01309558 | 0.000 |
| 0.80 | 0.000 | 0.00071676 | 0.02420758 | 0.02420758 | 0.000 | 0.02420805 | 0.02420805 | 0.000 |
| 0.90 | 0.000 | 0.00009797 | 0.02030320 | 0.02030320 | 0.000 | 0.02030359 | 0.02030359 | 0.000 |

***Computational experiment-1***. The conducted studies revealed changes in the deformation state under the influence of external forces on the mesh plates, and numerical results were obtained (Figure 1).

Table 2. The values of $W$ are given for different values of $c$.

| x | W n=2 | W n=3 | W n=4 |
|---|---|---|---|
| -1 | 0 | 0 | 0 |
| -0,9 | 0,00009953 | 0,00010152 | 0,00010068 |
| -0,8 | 0,0007541 | 0,00071714 | 0,0007221 |
| -0,7 | 0,00211305 | 0,00205652 | 0,00206405 |
| -0,6 | 0,00402702 | 0,00400341 | 0,00400339 |
| -0,5 | 0,00623124 | 0,00626503 | 0,00625034 |
| -0,4 | 0,00844668 | 0,00851907 | 0,00848927 |
| -0,3 | 0,01042772 | 0,01049807 | 0,01045747 |
| -0,2 | 0,01198026 | 0,01201645 | 0,01197043 |
| -0,1 | 0,01296638 | 0,01296362 | 0,0129159 |
| 0 | 0,01330414 | 0,01328472 | 0,01323676 |
| 0,1 | 0,01296638 | 0,01296362 | 0,0129159 |
| 0,2 | 0,01198026 | 0,01201645 | 0,01197043 |
| 0,3 | 0,01042772 | 0,01049807 | 0,01045747 |
| 0,4 | 0,00844668 | 0,00851907 | 0,00848927 |
| 0,5 | 0,00623124 | 0,00626503 | 0,00625034 |
| 0,6 | 0,00402702 | 0,00400341 | 0,00400339 |
| 0,7 | 0,00211305 | 0,00205652 | 0,00206405 |
| 0,8 | 0,0007541 | 0,00071714 | 0,0007221 |
| 0,9 | 0,00009953 | 0,00010152 | 0,00010068 |
| 1 | 0 | 0 | 0 |

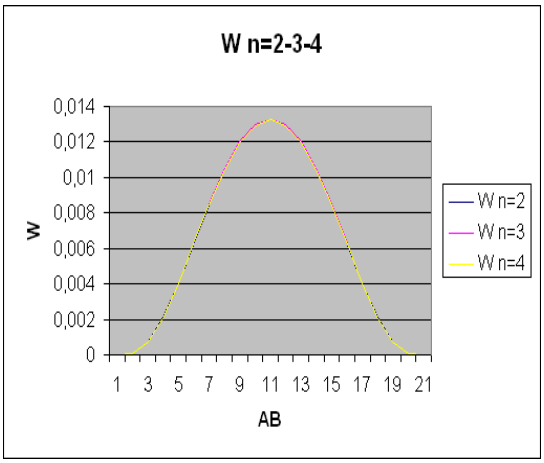



**Fig.2** The results of the deflection ($W$) and bending moment calculations

Table 3. The results of the deflection ($W$) and bending moment calculations nk=3 clutoch=20

| X | Y | W | MX | MY | MXY | MXZ | MYZ | MSZ |
|---|---|---|---|---|---|---|---|---|
| -0.900 | 0.000 | 0.00010152 | 0.01936904 | 0.01936904 | 0.000 | 0.01936941 | 0.01936941 | 0.000 |
| -0.800 | 0.000 | 0.00071714 | 0.02401694 | 0.02401694 | 0.000 | 0.02401740 | 0.02401740 | 0.000 |
| -0.700 | 0.000 | 0.00205652 | 0.01309483 | 0.01309483 | 0.000 | 0.01309508 | 0.01309508 | 0.000 |
| -0.600 | 0.000 | 0.00400341 | -0.00569859 | -0.00569859 | 0.000 | -0.00569870 | -0.00569870 | 0.000 |
| -0.500 | 0.000 | 0.00626503 | -0.02526806 | -0.02526806 | 0.000 | -0.02526854 | -0.02526854 | 0.000 |
| -0.400 | 0.000 | 0.00851907 | -0.04158693 | -0.04158693 | 0.000 | -0.04158773 | -0.04158773 | 0.000 |
| -0.300 | 0.000 | 0.01049807 | -0.05331659 | -0.05331659 | 0.000 | -0.05331761 | -0.05331761 | 0.000 |
| -0.200 | 0.000 | 0.01201645 | -0.06071108 | -0.06071108 | 0.000 | -0.06071225 | -0.06071225 | 0.000 |
| -0.100 | 0.000 | 0.01296362 | -0.06462599 | -0.06462599 | 0.000 | -0.06462722 | -0.06462722 | 0.000 |
| 0.000 | 0.000 | 0.01328472 | -0.06583160 | -0.06583160 | 0.000 | -0.06583287 | -0.06583287 | 0.000 |
| 0.100 | 0.000 | 0.01296362 | -0.06462599 | -0.06462599 | 0.000 | -0.06462722 | -0.06462722 | 0.000 |
| 0.200 | 0.000 | 0.01201645 | -0.06071108 | -0.06071108 | 0.000 | -0.06071225 | -0.06071225 | 0.000 |

| | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| 0.300 | 0.000 | 0.01049807 | -0.05331659 | -0.05331659 | 0.000 | -0.05331761 | -0.05331761 | 0.000 |
| 0.400 | 0.000 | 0.00851907 | -0.04158693 | -0.04158693 | 0.000 | -0.04158773 | -0.04158773 | 0.000 |
| 0.500 | 0.000 | 0.00626503 | -0.02526806 | -0.02526806 | 0.000 | -0.02526854 | -0.02526854 | 0.000 |
| X | Y | W | MX | MY | MXY | MXZ | MYZ | MSZ |
| 0.600 | 0.000 | 0.00400341 | -0.00569859 | -0.00569859 | 0.000 | -0.00569870 | -0.00569870 | 0.000 |
| 0.700 | 0.000 | 0.00205652 | 0.01309483 | 0.01309483 | 0.000 | 0.01309508 | 0.01309508 | 0.000 |
| 0.800 | 0.000 | 0.00071714 | 0.02401694 | 0.02401694 | 0.000 | 0.02401740 | 0.02401740 | 0.000 |
| 0.900 | 0.000 | 0.00010152 | 0.01936904 | 0.01936904 | 0.000 | 0.01936941 | 0.01936941 | 0.000 |

**Computational experiment 2.** In this experiment, the internal stresses of a heavily reinforced, complex-shaped mesh plate were examined, and the corresponding results were plotted and analyzed. The results show the influence of external forces on the mesh plate and are presented in Figure 3.

Table 4. The values of $W$ are given for different values of $c$.

| x | W c=10 | W c=20 | W c=32 |
|---|---|---|---|
| -1 | 0 | 0 | 0 |
| -0,9 | 0,00009797 | 0,00010152 | 0,00010229 |
| -0,8 | 0,00071676 | 0,00071714 | 0,00072084 |
| -0,7 | 0,00205804 | 0,00205652 | 0,0020652 |
| -0,6 | 0,00400094 | 0,00400341 | 0,00401937 |
| -0,5 | 0,0062587 | 0,00626503 | 0,00629077 |
| -0,4 | 0,00851668 | 0,00851907 | 0,00855664 |
| -0,3 | 0,01050956 | 0,01049807 | 0,01054812 |
| -0,2 | 0,01204724 | 0,01201645 | 0,01207763 |
| -0,1 | 0,01301098 | 0,01296362 | 0,01303251 |
| 0 | 0,01333857 | 0,01328472 | 0,01335637 |
| 0,1 | 0,01301098 | 0,01296362 | 0,01303251 |
| 0,2 | 0,01204724 | 0,01201645 | 0,01207763 |
| 0,3 | 0,01050956 | 0,01049807 | 0,01054812 |
| 0,4 | 0,00851668 | 0,00851907 | 0,00855664 |
| 0,5 | 0,0062587 | 0,00626503 | 0,00629077 |
| 0,6 | 0,00400094 | 0,00400341 | 0,00401937 |
| 0,7 | 0,00205804 | 0,00205652 | 0,0020652 |
| 0,8 | 0,00071676 | 0,00071714 | 0,00072084 |
| 0,9 | 0,00009797 | 0,00010152 | 0,00010229 |
| 0,9 | 0,0203032 | 0,01936904 | 0,01940817 |
| 1 | 0 | 0 | 0 |

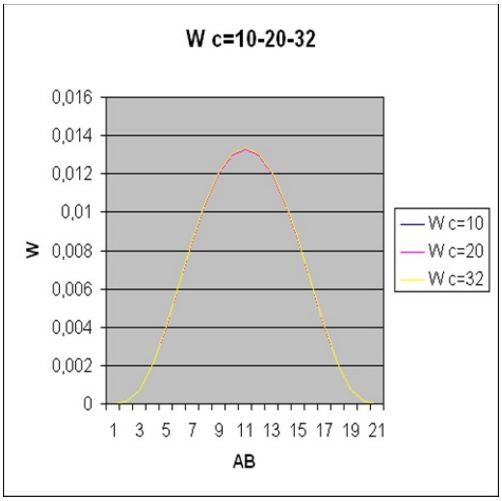



**Fig. 3.** The results of the deflection ($W$) and bending moment calculations

The results of this computational experiment, showing the influence of external forces on the bending of the mesh plates, are presented in Tables 1 and 2, with the corresponding graphs shown in Figures 2 and 3.

## ANALYSIS OF RESULTS

This study presents the results of computational experiments on the deformation of complex-shaped lattice plates under external forces. Several geometric configurations were considered, including rhomboidal structures and plates with three and four families of bars, which made it possible to identify patterns in stress distribution and to determine key features of the deformation process in such structures.

The results show that external forces have a direct effect on the deformation state of complex-shaped plates, underscoring the need to account for such effects when designing and operating thin-plate elements. Understanding these processes is essential for improving the durability, reliability, and stability of engineering structures, particularly in fields that demand high-precision calculation and prediction of material behavior, such as aerospace engineering, mechanical engineering, and construction.

## CONCLUSION

This research examined the deformation state of mesh plates with complex configurations, including rhomboidal structures and plates with three and four families of bars, and presented the corresponding computational experiment results. The reliability of the obtained results was verified through a comparative analysis with data reported by other authors, confirming the accuracy of the calculations performed.

The proposed mathematical model, the developed computational algorithm, and the resulting findings thus hold potential value for further research on the deformation state of mesh plates with complex configurations.

## REFERENCES

1. Kabulov V.K. Algorithmization in continuum mechanics. Tashkent, Fan, 1979.-304 p.
2. Abovsky N.P., Wolf G.A., Zaslavskaya M.M. On the applicability of thin plate theory to flat structural constructions // Collection of works. Krasnoyarsk Polytechnic Institute. - 1975. - No. 8.
3. Begun G.B. On the calculation of spatial rod coverings of beamless type // Structural Mechanics and Design of Structures. - 1967. - No. 6.
4. Bekniyazova R.S., Okbayeva N., Sultanov B. A complex of software tools for the calculation of anisotropic plates and rods of complex shapes. Abstracts of the Fourth Siberian Congress on Applied and Industrial Mathematics (INPRIM - 2000) dedicated to the memory of M.A. Lavrentiev. Novosibirsk, June 28 - July 1, 2000, p. 53.
5. Pshenichnov G.I. Theory of thin elastic grid shells: Doctor of Technical Sciences Dissertation. - Moscow, 1968.
6. Buriev T. Calculation of thin plates on a computer. Tashkent, Fan, 1976.
7. Zaikov G.A., Neznamov M.A., Strizhneva E.G. On assessing the reliability and load-bearing capacity of composite elements // Spatial Structures in the Krasnoyarsk Territory. - Krasnoyarsk, 1991. - pp. 68-73.
8. Kuznetsov V.V., Pshenichnov G.I. Calculation of rectangular grid shallow shells // Spatial Structures in the Krasnoyarsk Territory. - Krasnoyarsk, 1976. - Issue 9.
9. F. M. Nuraliev, B. S. Aytmuratov and M. A. Artikbayev, "Solving the vibration of magnetic elastic plates with sophisticated form," 2019 International Conference on Information Science and Communications Technologies (ICISCT), Tashkent, Uzbekistan, 2019, pp. 1-4, doi: 10.1109/ICISCT47635. 2019.9011984.
10. F. Nuraliev, S. Safarov and M. Artikbayev, "A computational algorithm for calculating the effect of the electromagnetic fields to thin complex configured plates," 2020 International Conference on Information Science and Communications

Technologies (ICISCT), Tashkent, Uzbekistan, 2020, pp. 1-4, doi:10.1109/ICISCT50599.2020.9351447.

11. Nuraliev F.M., Aytmuratov B.Sh., Safarov Sh.Sh., Artikbayev M.A. Mathematical modeling of geometric nonlinear processes of electromagnetic elastic thin plates of complex configuration // Scientific Journal "Problems of Computational and Applied Mathematics." - No. 1(38), 2022. - pp. 90-109.
12. F. Nuraliev, S. Safarov and M. Artikbayev, "Solving the problem of geometrical nonlinear deformation of electro-magnetic thin plate with complex configuration and analysis of results," 2021 International Conference on Information Science and Communications Technologies (ICISCT), Tashkent, Uzbekistan, 2021, pp. 1-5, doi: 10.1109/ICISCT52966.2021.9670282.
13. N. Fakhriddin Murodillayevich, A. Bakbergen Sharibayevich and A. Mahkam Artikbayevich, "Mathematical model and computational algorithm of vibration processes of thin magnetoelastic plates with complex form," 2021 International Conference on Information Science and Communications Technologies (ICISCT), Tashkent, Uzbekistan, 2021, pp. 1-5, doi:10.1109/ICISCT52966. 2021.9670313.
14. Nuraliev F.M., Aytmuratov B.Sh., Safarov Sh.Sh., Artikbayev M.A. Calculation results of the task of geometric nonlinear deformation of electro-magneto-elastic thin plates in a complex configuration // 2022 International Conference on Information Science and Communications Technologies (ICISCT), Tashkent, Uzbekistan, 2022, pp. 1-4, doi: 10.1109/ICISCT55600. 2022.10146920.
15. Artikbayev M.A., Orazbayev A. Results of solving the magnetoelastic problem of thin anisotropic plates with complex form // International Scientific Conference on Modern Problems of Applied Science and Engineering. - Vol. 3244, Issue 1, 2024. AIP Conf. Proc. 3244, 060026 (2024).

# A New Framework for Generating Fuzzy Metrics by *t*-Norms and Indistinguishability Operators

J. Ravinder[1], A. Bernick Raj[2*], C. D. Nandakumar[3]

[1, 2 & 3] Department of Mathematics and Actuarial Science, B. S. Abdur Rahman Crescent Institute of Science and Technology, Chennai, Tamil Nadu, 600048, India.

[1] ravinder.maths@gmail.com ; [2] bernickraj@crescent.education;
[3] cdnandakumar@crescent.education

**Abstract**

This paper presents two methods for constructing fuzzy metrics from a classical metric by incorporating actual and perceived distances within a unified fuzzy framework. The proposed constructions combine a perceptual distance function with fuzzy components, including a continuous *t*-norm, a *T*-indistinguishability operator, and a generated conjunctor, to define a flexible measure of fuzzy nearness. The framework captures uncertainty and perceptual variations between actual and perceived distances, establishing a systematic link between classical distance and perception based fuzzy nearness. The proposed methods may find applications in pattern recognition, image and speech processing, clustering, decision making, artificial intelligence, data analysis, and similarity based classification.

.

**Keywords:** Fuzzy metric, *t*-norm, *T*-indistinguishability, conjunctive additive generator, generated conjunctors.

## 1. Introduction

The concept of a metric provides a quantitative measure of similarity or dissimilarity between objects and has wide applications in mathematics and real-world modeling. However, classical metrics may not adequately capture uncertainty and vagueness. For example, the actual distance between two objects remains fixed, while their perceived distance may vary with the observer's position. This motivates the use of fuzzy metrics incorporating indistinguishability and perceived distance to better represent such situations.

Fuzzy set theory, introduced by Zadeh in 1965 [3], offers a natural framework for modeling imprecision and partial membership. Within this framework, various notions of fuzzy metric spaces have been proposed [4, 5, 6, 7, 12, 13, 16, 17, 19, 20], and defining an appropriate fuzzy metric has become a fundamental problem in fuzzy mathematics due to its relevance in areas such as fuzzy optimization, decision-making, and pattern recognition. Over the years, significant attention has been devoted to investigating the topological properties of fuzzy metric spaces [4, 5, 6, 7] and their applications, especially in engineering and applied sciences.

Existing approaches to fuzzy metrics can be broadly classified into two categories. One approach employs fuzzy numbers to define metrics on classical spaces, as initially proposed by Kaleva [22]. The other approach uses real-valued functions to measure distances between fuzzy sets [5, 13]. Despite these developments, the practical applicability of fuzzy metrics remains limited due to the scarcity of constructive examples. To address this, Grigorenko et al. [16] proposed two new techniques for constructing fuzzy metrics.

Motivated by these observations, this paper introduces two systematic approaches for constructing fuzzy metrics using *t*-norm, generated conjunctors, indistinguishability operators and perceived distances. These proposed methods will leads to many known fuzzy metrics are derived directly from classical metrics and offering flexibility for modeling real-world phenomena.

## 2. Preliminaries

The concept of a triangular norm was initially introduced in the literature with a variant set of axioms in [1]. Subsequently, Schweizer and Sklar [2] formulated a collection of mutually independent axioms that have since become the standard reference for triangular norms. In this section, our basic reference for *t*-norms and all related notions are from [8, 9].

**Definition 2.1**. [21] Let $f : I \to [0,\infty]$ be a function satisfies the following conditions;

(CAG-1): $f$ is strictly decreasing.

(CAG-2): $f(1) = 0$.

(CAG-3): $f$ is continuous.

(CAG-4): $f(0) = \infty$.

(i) $f$ is said to be a conjunctive additive generator, if $f$ holds (CAG-1) and (CAG-2). And the function $f^{(-1)} : [0,\infty] \to I$ defined by $f^{(-1)}(u) = \sup\{x \in [0,1] : f(x) > u\}$ is called pseudo-inverse of $f$.

(ii) $f$ is said to be an additive generator, if $f$ holds (CAG-1), (CAG-2), (CAG-3) and (CAG-4). And the function $f^{-1} : [0,\infty] \to I$ is called inverse of $f$.

**Definition 2.2.** A mapping $T : [0,1]^2 \to [0,1]$ is said to be a triangular norm (***t***-norm) if it satisfies the following properties;

($t$-1): $T(x,y) = T(y,x)$ (Commutative)

($t$-2): $T\big(x, T(y,z)\big) = T\big(T(x,y), z\big)$ (Associative)

($t$-3): $T(x,y) \le T(x,z)$ whenever $y \le z$ (Monotone)

($t$-4): $T(x,1) = x$ and $T(x,0) = 0$ (Boundary Conditions)

for all $x, y, z \in [0,1]$.

The basic *t*-norms are (i) the minimum *t*-norm: $T_M(x,y)=\min\{x,y\}$,

(ii) the product *t*-norm: $T_P(x,y)=x\cdot y$,

(iii) the Lukasiewicz *t*-norm: $T_L(x,y)=\max\{x+y-1,0\}$,

(iv) the drastic product *t*-norm: $T_D(x,y)=\begin{cases}0, & \text{if } 0\le x,y<1,\\ \min\{x,y\}, & \text{otherwise,}\end{cases}$

and between these four basic *t*-norms we have an inequality $T_D<T_L<T_P<T_M$.

**Definition 2.3**. [9] A *t*-norm $T:[0,1]^2\to[0,1]$ is said to be

(i) continuous, if as a function $T:[0,1]^2\to[0,1]$ is continuous.

(ii) strictly monotone, if $T(x,y)<T(x,z)$ whenever $x>0$ and $y<z$.

(iii) $T$ satisfies the cancellation law, if $T(x,y)=T(x,z)$ implies either $x=0$ or $y=z$.

(iv) $T$ satisfies the conditional cancellation law, if $T(x,y)=T(x,z)>0$ implies $y=z$.

(v) an Archimedean *t*-norm, if for each $x,y\in(0,1)$ there exists a positive integer $n$ such that $x_T^{(n)}=T(\underbrace{x,x,\ldots,x}_{n-times})<y$.

(vi) $T$ satisfies the limit property, if $\lim\limits_{n\to\infty}x_T^{(n)}=0$ for all $x,y\in(0,1)$.

The *t*-norms $T_L$, $T_P$ are Archimedean *t*-norms, but the *t*-norm $T_M$ is not an Archimedean *t*-norm. Indeed, the *t*-norm $T_D$ is a non continuous Archimedean *t*-norm.

**Note 2.4.** If $T$ is an Archimedean *t*-norm, (i) then $T(x,x)<x$ for all $x\in(0,1)$.

(ii) for every $x\in(0,1)$, $\lim\limits_{n\to\infty}x_T^{(n)}=0$.

**Definition 2.5**. [21] A *t*-norm $T:[0,1]^2\to[0,1]$ is said to be generated conjunctor corresponding to the conjunctive additive generator $f$, if $T(x,y)=f^{(-1)}\big(f(x)+f(y)\big)$ or $T(x,y)=f^{-1}\big(f(x)+f(y)\big)$, where $f(x)+f(y)\in Ran(f)\cup[f(0),\infty]$.

**Theorem 2.6**. [16] A *t*-norm $T$ is an Archimedean if and only if $T$ can be represented as $T(x,y)=f^{-1}(f(x)+f(y))$, where $f:[0,1]\to[0,\infty]$ is an additive generator and $f^{-1}:[0,\infty)\to[0,1]$ is a continuous onto function such that $f^{-1}(x)=\begin{cases}f^{-1}(x) & \text{for } x\in[0,f(0)].\\ 0 & \text{for } x\in[0,\infty]\setminus[0,f(0)].\end{cases}$

**Example 2.7.** (i) Let $f(x)=\ln\left(\frac{1}{x}\right)$ and $f^{-1}(x)=e^{-x}$. Then

$$T_P(x,y)=x\cdot y=e^{-\left(\ln\left(1/x\right)+\ln\left(1/y\right)\right)}=f^{-1}(f(x)+f(y)).$$

(ii) Let $f(x)=1-x$ and $f^{-1}(x)=1-x$. Then

$$T_L(x,y)=\max\{x+y-1,0\}=x+y-1=f^{-1}(f(x)+f(y)).$$

The idea of *T*-indistinguishability operators introduced by E. Trillas in 1982 [10], and its main objective is to fuzzify the notion of classical equivalence relations.

**Definition 2.8.** [10,11,15] Let $X$ be a non-empty set and $T$ be a *t*-norm. The fuzzy set $E: X\times X\to[0,1]$ is said to be *T*-indistinguishability operator, if it satisfies the following conditions;

(*TI*-1): $E(x,x)=1$ (Reflexivity)

(*TI*-2): $E(x,y)=E(y,x)$ (Symmetry)

(*TI*-3): $E(x,z)\geq T\left(E(x,y),E(y,z)\right)$ (Transitivity)

for all $x,y,z\in X$. In addition,

(*TI*-4): $E(x,y)=1\Leftrightarrow x=y$ for all $x,y\in X$ (Point Separation)

then the *T*-indistinguishability operator $E$ is called *T*-equality [15].

Notice that $E(x,y)$ indicates the indistinguishability degree between *x* and *y*, that is $E(x,y)=1$ indicates that *x* and *y* are completely indistinguishable and $E(x,y)=0$ indicates that *x* and *y* are completely distinguishable.

**Example 2.9**. (i) Let $X=[0,1]$, then $E(x,y)=1-|x-y|$ is a *T*-equality operator.

(ii) Let $X=\{\alpha,\beta,\gamma,\delta\}$ be any set. Then the *T*-indistinguishability operators defined by

$$E_P=\begin{bmatrix}1 & 0.5 & 0.1 & 0.4\\ 0.5 & 1 & 0.2 & 0.3\\ 0.1 & 0.2 & 1 & 0.6\\ 0.4 & 0.3 & 0.6 & 1\end{bmatrix},\ E_M=\begin{bmatrix}1 & 0.5 & 0.2 & 0.2\\ 0.5 & 1 & 0.2 & 0.2\\ 0.2 & 0.2 & 1 & 0.5\\ 0.2 & 0.2 & 0.5 & 1\end{bmatrix} \text{ and } E_L=\begin{bmatrix}1 & 0.6 & 0.1 & 0.1\\ 0.6 & 1 & 0.2 & 0.1\\ 0.1 & 0.2 & 1 & 0.6\\ 0.1 & 0.1 & 0.6 & 1\end{bmatrix} \text{ are}$$

*T*-equality with respect to the *t*-norms product, minimum and Lukasiewicz, respectively.

Now, we present the fundamental concepts of fuzzy metric spaces that are essential for the subsequent developments. The notion of a fuzzy metric space was originally introduced by Kramosil and Michálek [13] and was later reformulated in a widely adopted form by Grabiec [14].

**Definition 2.10**. [13] Let *X* be any nonempty arbitrary set, "$T$" be the continuous *t*-norm and *M* be fuzzy set on $X^2\times[0,\infty)$. The 3-tuple $(X,M,T)$ is said to be a fuzzy metric space (KM-fuzzy metric space), if for each $x,y,z\in X$ and $t,s>0$,

(KM-1): $M(x,y,0)=0$.

(KM-2): $M(x,y,t)=1$ for all $t>0$, if and only if $x=y$.

(KM-3): $M(x,y,t)=M(y,x,t)$.

(KM-4): $M(x,z,t+s)\geq T\left(M(x,y,t),M(y,z,s)\right)$.

(KM-5): $M(x,y,\bullet):[0,\infty)\to[0,1]$ is left continuous.

The KM-fuzzy metric space was subsequently modified by George and Veeramani [5], who introduced a revised definition to ensure a Hausdorff topology, leading to the concept of a GV-fuzzy metric space.

**Definition 2.11**. [5] The 3-tuple $(X,M,T)$ is said to be a fuzzy metric space (GV-fuzzy metric space), if for each $x,y,z\in X$ and $t,s>0$,

(GV-1): $M(x,y,t)>0$.

(GV-2): $M(x,y,t)=1$ for all $t>0$, if and only if $x=y$.

(GV-3): $M(x,y,t)=M(y,x,t)$.

(GV-4): $M(x,z,t+s)\geq T\left(M(x,y,t),M(y,z,s)\right)$.

(GV-5): $M(x,y,\bullet):(0,\infty)\to[0,1]$ is continuous.

where $X$ is an arbitrary nonempty set, "$T$" is a continuous $t$-norm and $M$ is a fuzzy set on $X^2\times(0,\infty)$.

**Lemma 2.12**. [14] For all $x, y$ in $X$, $M(x,y,\bullet)$ is non-decreasing.

In view of the objectives of the present study, hereafter, the term "fuzzy metric space" refers to the GV-fuzzy metric space.

**Remark 2.13**. (i) [5] The fuzzy metric $M(x,y,t)$ measures the degree of nearness of $x$ and $y$. That is, for any $t>0$, it is identified that $x=y$ if and only if $M(x,y,t)=1$. Similarly, $M(x,y,t)\to 0$ indicates that the distance between $x$ and $y$ approaches to infinite.

(ii) [19] If $(X,M,T_1)$ is a fuzzy metric space and $T_2$ is a continuous $t$-norm such that $T_1(a,b)\geq T_2(a,b)$ for all $a,b\in[0,1]$. Then $(X,M,T_2)$ is a fuzzy metric space but the converse, in general, is false.

**Examples 2.14**. (i) [5] Let $X=\mathbb{R}$. Define $M(x,y,t)=\exp\left\{\frac{-1}{t}|x-y|\right\}$ for all $x,y\in X$ and $t\in(0,\infty)$. Then $(X,M,T)$ is a fuzzy metric space under the continuous t-norm $T=T_P$, $T=T_M$, $T=T_L$ and $T=T_D$.

(ii) [5] Let $X=\mathbb{N}$. Define $M(x,y,t)=\begin{cases} x/y & \text{if } x\le y \\ y/x & \text{if } y\le x \end{cases}$ for all $x,y\in X$ and $t\in(0,\infty)$. Then $(X,M,T)$ is a fuzzy metric space under the continuous t-norm $T=T_P$ and $T=T_L$, but not under $T=T_M$ and $T=T_D$.

(iii) [5] Let $X$ be any metric space under the classical metric $d:X\times X\to[0,\infty)$. Define $M_d(x,y,t)=\dfrac{kt^n}{kt^n+md(x,y)}$ for all $x,y\in X$ and $k,m,n,t\in(0,\infty)$. Then $(X,M_d,T)$ is a fuzzy metric space under the continuous t-norm $T=T_P$, $T=T_M$, $T=T_L$ and $T=T_D$. The fuzzy metric $M_d$ is called the induced fuzzy metric by the classical metric $d$.

(iv) [5] For $k=m=n=1$, the induced fuzzy metric $M_d(x,y,t)=\dfrac{t}{t+d(x,y)}$ is called the standard fuzzy metric. $(X,M_d,T)$ is a fuzzy metric space under the continuous t-norm $T=T_P$ and $T=T_M$.

(v) [18] Let $X$ be any metric space under the classical metric $d:X\times X\to[0,\infty)$, and let $f:(0,\infty)\to(0,1)$ be a non-decreasing continuous function such that $\lim_{t\to\infty} f(t)=1$. Define $M_d(x,y,t)=\left[f(t)\right]^{d(x,y)}$ for all $x,y\in X$ and $t\in(0,\infty)$. Then $(X,M_d,T)$ is a fuzzy metric space under the continuous t-norm $T=T_P$, $T=T_M$, $T=T_L$ and $T=T_D$. For instance $f(t)=\dfrac{t}{t+1}$, $f(t)=1-e^{-t}$ and $f(t)=e^{\frac{-1}{t}}$.

(vi) [20] $(X,M_G,T_L)$ be a stationary fuzzy metric space defined by $M_G(x,y,t)=\begin{cases} G(x,y), & if\ x\neq y \\ 1, & if\ x=y \end{cases}$ where $G:X\times X\to\left(0,\dfrac{1}{2}\right)$ be a function such that $G(x,y)=G(y,x)$ for all $x,y\in X$.

## 3. Main Result

This section presents two new theorems for constructing fuzzy metrics from a classical metric using continuous *t*-norms, continuous Archimedean *t*-norms, *T*-indistinguishability operators, generated conjunctors, and perceptual distance functions with their corresponding membership functions. The proposed constructions yield strong fuzzy metrics and generalize existing constructions based on indistinguishability operators. We start with defining perceptual distance function as follows.

**Definition 3.1**. Let $(X,d)$ be any metric space. For every $x,y\in X$, a function defined by $F_{xy}:(0,\infty)\to[0,\infty)$ is called perceptual distance function, if it satisfies the following conditions; for any $t>0$,

(PD-1) : $F_{xy}(t)>0.$

(PD-2) : $F_{xy}(t)=0 \Leftrightarrow x=y.$

(PD-3) : $\lim_{t\to 0} F_{xy}(t)=d(x,y).$

(PD-4) : $\lim_{t\to\infty} F_{xy}(t)=0.$

We now state and prove the following lemma, which establishes a key property required for the subsequent development and plays an essential role in proving the main results of the proposed construction.

**Lemma 3.2**. Let $\varphi:[0,\infty)\to I$ be a function defined by

(DPD-1) : $\varphi(t)>0$ for any $t>0.$

(DPD-2) : $\varphi(0)=1.$

(DPD-3) : $\varphi$ is left continuous.

Then for every $x,y\in X$, $\varphi\circ F_{xy}:(0,\infty)\to I$ is continuously increasing function.

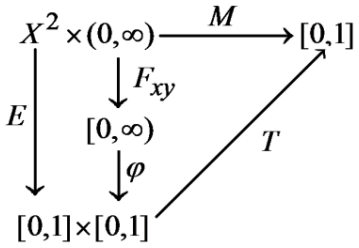
**Proof**. Let us consider that $d(x,y)=d$ for any $x,y\in X$. From (PD-3) and (PD-4), we have $d=\sup\{F_{xy}(t):t>0\}$, that is $F_{xy}$ bounded above by *d*, and $0=\inf\{F_{xy}(t):t<\infty\}$, $F_{xy}$ is bounded below by $0$. This implies that, $F_{xy}$ is bounded and for any $s,t>0$ with $t>s$, we get $0\le F_{xy}(t)\le F_{xy}(s)\le d$. So, $F_{xy}$ is monotonically decreasing, and hence $F_{xy}$ is continuous. Since (DPD-2) and (DPD-3), it is clear that $\varphi(c)=\sup\{\varphi(t):0\le c<t\}$, that is, $\varphi(c)\ge\varphi(t)$ for $t>c$. This concludes that $\varphi$ is monotonically decreasing. Now, from the definitions of $F_{xy}$ and $\varphi$, we get $Range(F_{xy})\subseteq[0,\infty)$, and $F_{xy}$, $\varphi$ are monotonically decreasing, also $F_{xy}$, $\varphi$ are continuous, hence $\varphi\circ F_{xy}$ is continuously increasing function on $(0,\infty)$.

We now present the proposed method for constructing a fuzzy metric from a given metric space.

**Theorem 3.3**. For a non-empty set *X* and a continuous *t*-norm *T*, the ordered pair $(X,d)$ is a metric space and the ordered triple $(X,M,T)$ is a fuzzy metric space, where *d* is a classical metric and *M* is a fuzzy metric. Let $E:X^2\to I$ be a *T*-indistinguishability operator that separates points, $F_{xy}$ and $\varphi$ are as defined in the definitions 3.1 and 3.2 respectively. Then

$$M(x,y,t)=T\left(E(x,y),\varphi\circ F_{xy}(t)\right) \qquad \text{---- (1)}$$

Moreover, commutes the following diagram.




**Proof.** First we show that the diagram is commute. Let $d(x,y)=d\in(0,\infty)$ and $E(x,y)=a\in I$ for some distinct $x,y\in X$. Now, there exists $b\in I$ such that $T(a,b)=r$. From the lemma 3.3, for every $b\in I$, we can find a unique $t\in(0,\infty)$ such that $\varphi\circ F_{xy}(t)=b$. This implies that $r=T(a,b)=T\left(E(x,y),\varphi\circ F_{xy}(t)\right)=M(x,y,t)$. Hence commutes the mappings in the given diagram. Now, to prove $(X,M,T)$ is a fuzzy metric space under the fuzzy metric defined as in the equation (1), we will consider that $(X,d)$ is a metric space, $E:X^2\to I$ is an $T$-indistinguishability operator that separates points. We know that, for every $x,y\in X$, $E(x,y)>0$ and $F_{xy}(t)>0$ for all $t>0$. This implies that $T\left(E(x,y),\varphi\circ F_{xy}(t)\right)=M(x,y,t)>0$ for all $x,y\in X$ and $t>0$, this concludes that (GV-1) hold. To prove (GV-2) we consider that for any $t>0$, $M(x,y,t)=1$. That is $T\left(E(x,y),\varphi\circ F_{xy}(t)\right)=1$. Since $T$ is a continuous $t$-norm, therefore $E(x,y)=1$ and $\varphi\circ F_{xy}(t)=1$. It is obvious that $E(x,y)=1\Leftrightarrow x=y$, and from the definition 3.1 and lemma 3.2, $\varphi(F_{xy}(t))=1\Leftrightarrow 0=F_{xy}(t)=d(x,y)\Leftrightarrow x=y$. Hence for any $t>0$, $M(x,y,t)=1\Leftrightarrow x=y$. Now, consider that for any $x,y,z\in X$ and $t,s>0$,

$$\begin{aligned}
T\left(M(x,y,t),M(x,y,t)\right) &= T\left(T\left(E(x,y),\varphi\circ F_{xy}(t)\right),T\left(E(y,z),\varphi\circ F_{yz}(s)\right)\right)\\
&= T\left(T\left(E(x,y),E(y,z)\right),T\left(\varphi\circ F_{xy}(t),\varphi\circ F_{yz}(s)\right)\right)\\
&\le T\left(E(x,z),T\left(\varphi\circ F_{xy}(t),\varphi\circ F_{yz}(s)\right)\right)\\
&\le T\left(E(x,z),T\left(\varphi\circ F_{xz}(t),\varphi\circ F_{xz}(t+s)\right)\right)\\
&\le T\left(E(x,z),\varphi\circ F_{xz}(t+s)\right)\\
&\le M(x,z,t+s)
\end{aligned}$$

Hence the (GV-4). From the definition 3.1 and the lemma 3.2, it is clear that (GV-5) holds.

**Remark 3.4**. $M(x,y,0)=0\Leftrightarrow T\left(E(x,y),\varphi\circ F_{xy}(0)\right)=0\Leftrightarrow T\left(E(x,y),\varphi(d(x,y))\right)=0\Leftrightarrow E(x,y)=0$. That is, *x* and *y* are completely distinguishable. It shows that the condition (KM-1) also holds.

To further illustrate and substantiate Theorem 3.3, we present the following examples.

**Example 3.5**. Let $\left(X=[0,1],d\right)$ be a metric space under any metric *d*, and $E:X^2\to I$ be the indistinguishability operator that separates points defined by $E(x,y)=1-|x-y|$ for all $x,y\in X$.

Consider the continuous *t*-norm $T: I^2 \to I$ such that $T(a,b) = \min\{a,b\}$ for all $a,b \in I$. Now, for every $x, y \in X$ and any non-negative value *k*, define a decreasing function $F_{xy}: (0,\infty) \to (0,\infty)$ as $F_{xy}(t) = d(x,y)e^{-kt}$ for all $t > 0$. Also, define a continuous monotonically increasing function $\varphi: (0,\infty) \to I$ as $\varphi(t) = e^{-t}$ for all $t > 0$. Now let us prove that $(X, M, T)$ be a fuzzy metric under the fuzzy metric $M(x,y,t) = T\left(E(x,y), \varphi \circ F_{xy}(t)\right)$ for all $x, y \in X$ and $t > 0$. It is trivial that the *M* satisfies the axioms (GV-1), (GV-3) and (GV-5). To verify the axiom (GV-2), consider $1 = M(x,y,t) \Leftrightarrow 1 = T\left(E(x,y), \varphi \circ F_{xy}(t)\right) \Leftrightarrow 1 = \min\{E(x,y), \varphi \circ F_{xy}(t)\} \Leftrightarrow 1 = E(x,y)$ and $1 = \varphi \circ F_{xy}(t)$.

| Case $(i)$ | Case $(ii)$ |
|---|---|
| $E(x,y) = 1$<br>$\Leftrightarrow 1 = 1 - \lvert x - y \rvert$<br>$\Leftrightarrow x = y$ | $1 = e^{-d(x,y)e^{-kt}}$<br>$\Leftrightarrow 0 = d(x,y)e^{-kt}$, where $0 < kt < \infty$<br>$\Leftrightarrow 0 = d(x,y)$<br>$\Leftrightarrow x = y$ |

Hence $M(x,y,t) = 1 \Leftrightarrow x = y$. Now, to prove (GV-4), consider

$$\begin{aligned}
T\left(M(x,y,t), M(y,z,s)\right) &= \min\{M(x,y,t), M(y,z,s)\} \\
&= \min\{T\left(E(x,y), \varphi \circ F_{xy}(t)\right), T\left(E(y,z), \varphi \circ F_{yz}(s)\right)\} \\
&= \min\{\min\{1 - \lvert x - y \rvert, e^{-d(x,y)e^{-kt}}\}, \min\{1 - \lvert y - z \rvert, e^{-d(y,z)e^{-ks}}\}\} \\
&= \min\{1 - \lvert x - y \rvert, 1 - \lvert y - z \rvert, e^{-d(x,y)e^{-kt}}, e^{-d(y,z)e^{-ks}}\} \\
&\le \min\{1 - \lvert x - z \rvert, e^{-d(x,y)e^{-kt}}, e^{-d(y,z)e^{-ks}}\} \\
&\le \min\{1 - \lvert x - z \rvert, e^{-d(x,z)e^{-k(t+s)}}\} \\
&= T\left(E(x,z), \varphi \circ F_{xz}(t+s)\right) \\
&= M(x,z,t+s)
\end{aligned}$$

Hence $M(x,z,t+s) \ge T\left(M(x,y,t), M(y,z,s)\right)$ for all $x, y, z \in X$ and $t, s > 0$.

**Example 3.6**. Let $(X = \{\alpha, \beta, \gamma, \delta\}, d)$ be a discrete metric space, $T(a,b) = a.b$ for all $a,b \in I$ be the continuous *t*-norm, and the *T*-indistinguishability operator defined by $E_P = \begin{bmatrix} 1 & 0.5 & 0.1 & 0.4 \\ 0.5 & 1 & 0.2 & 0.3 \\ 0.1 & 0.2 & 1 & 0.6 \\ 0.4 & 0.3 & 0.6 & 1 \end{bmatrix}$ be the *T*-equality with respect to the product *t*-norm. Now, for every $x, y \in X$ and for any non-negative value *k*, define a decreasing function $F_{xy}: (0,\infty) \to (0,\infty)$ as $F_{xy}(t) = d(x,y)e^{-kt} = \begin{cases} 0, & \text{if } x = y \\ e^{-kt}, & \text{if } x \ne y \end{cases}$ for all $t > 0$. Also, define a continuous monotonically decreasing function $\varphi: (0,\infty) \to I$ as $\varphi(t) = \dfrac{1}{t+1}$ for all $t > 0$. Now from the equation (1) the fuzzy metric can be defined by

$$M(x,y,t)=T\left(E(x,y),\varphi\circ F_{xy}(t)\right)=E(x,y).\varphi\circ F_{xy}(t)=\begin{cases}1, & \text{if } x=y\\ \dfrac{E(x,y)}{1+e^{-kt}}, & \text{if } x\neq y\end{cases}$$

for all $x,y\in X$ and $t>0$. It is clear that (GV-1): $M(x,y,t)>0$ for all $x,y\in X$, (GV-2): $M(x,y,t)=1\Leftrightarrow x=y,$ and (GV-3): $M(x,y,t)=M(y,x,t).$ To prove (GV-4), for any positive values of $k,t,s,$ we know that $e^{-kt}+e^{-ks}+e^{-kt}e^{-ks}>e^{-kt}e^{-ks}$. This implies that $\frac{1}{1+e^{-kt}}\times\frac{1}{1+e^{-ks}}\leq\frac{1}{1+e^{-k(t+s)}}.$ Therefore, for any distinct points $x,y,z$ of $X$, $\frac{E(x,y)}{1+e^{-kt}}\times\frac{E(y,z)}{1+e^{-ks}}\leq\frac{E(x,z)}{1+e^{-k(t+s)}}.$ Hence $T\left(M(x,y,t),M(y,z,s)\right)\leq M(x,z,t+s).$ (GV-5): $M(x,y,\bullet):(0,\infty)\to[0,1]$ is continuous. Hence $(X,M,T)$ is a fuzzy metric space.

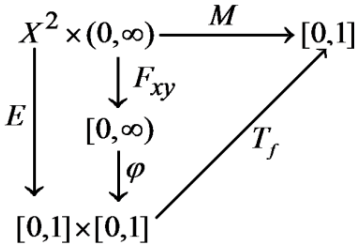
Now, we present the proposed second method for constructing a fuzzy metric from a given metric space.

**Theorem 3.7**. For a non-empty set *X* and a continuous Archimedean *t*-norm *T*, the ordered pair $(X,d)$ is a metric space and the ordered triple $(X,M,T)$ is a fuzzy metric space, where *d* is a classical metric and *M* is a fuzzy metric. Let $E:X^2\to I$ be a *T*-indistinguishability operator that separates points, $F_{xy}$ and $\varphi$ are as defined in the definition 3.1 and lemma 3.2 respectively. Then

$$M(x,y,t)=T_f\left(E(x,y),\varphi\circ F_{xy}(t)\right) \qquad \text{---- (2)}$$

where $T_f:I^2\to I$ is a generated conjunctor.

Moreover, commutes the following diagram.




**Proof.** First we show that the diagram is commute. Let $d(x,y)=d\in(0,\infty)$ and $E(x,y)=a\in I$ for some distinct $x,y\in X$. Now, there exists $b\in I$ such that $T(a,b)=r.$ From the lemma 3.2, for every $b\in I,$ we can find a unique $t\in(0,\infty)$ such that $\varphi\circ F_{xy}(t)=b.$ This implies that $r=T_f(a,b)=T_f\left(E(x,y),\varphi\circ F_{xy}(t)\right)=M(x,y,t).$ Hence commutes the mappings in the given diagram. Now, to prove $(X,M,T)$ is a fuzzy metric space under the fuzzy metric defined as in the equation (2), we will consider that $(X,d)$ is a metric space, $E:X^2\to I$ is an *T*-

indistinguishability operator that separates points. We know that, for every $x, y \in X$, $E(x,y) > 0$ and $F_{xy}(t) > 0$ for all $t > 0$. This implies that $T_f\left(E(x,y), \varphi \circ F_{xy}(t)\right) = M(x,y,t) > 0$ for all $x, y \in X$ and $t > 0$, this concludes that (GV-1) hold. To prove (GV-2) we consider that for any $t > 0$, $M(x,y,t) = 1$. That is $T_f\left(E(x,y), \varphi \circ F_{xy}(t)\right) = 1$. Since $T$ is a continuous $t$-norm and generated conjunctor corresponding to the conjunctive additive generator $f$, therefore

$$
\begin{aligned}
& f^{-1}\left(f\left(E(x,y)\right) + f\left(\varphi \circ F_{xy}(t)\right)\right) = 1 \\
& \Rightarrow f\left(E(x,y)\right) + f\left(\varphi \circ F_{xy}(t)\right) = 0 \in Ran(f) \cup [f(0), \infty] \\
& \Leftrightarrow f\left(E(x,y)\right) = 0 \text{ and } f\left(\varphi \circ F_{xy}(t)\right) = 0 \\
& \Leftrightarrow E(x,y) = 1 \text{ and } \varphi \circ F_{xy}(t) = 1 \\
& \Leftrightarrow x = y.
\end{aligned}
$$

Hence for any $t > 0$, $M(x,y,t) = 1 \Leftrightarrow x = y$. Now, consider that for any $x, y, z \in X$ and $t, s > 0$,

$$
\begin{aligned}
T_f\left(M(x,y,t), M(y,z,s)\right) &= f^{-1}\left(f\left(M(x,y,t)\right) + f\left(M(y,z,s)\right)\right) \\
&= f^{-1}\left(f\left(T_f\left(E(x,y), \varphi(F_{xy}(t))\right)\right) + f\left(T_f\left(E(y,z), \varphi(F_{yz}(s))\right)\right)\right) \\
&= f^{-1}\left(f\left(f^{-1}\left(f(E(x,y)) + f(\varphi \circ F_{xy}(t))\right)\right) + f\left(f^{-1}\left(f(E(y,z)) + f(\varphi \circ F_{yz}(s))\right)\right)\right) \\
&= f^{-1}\left(f(E(x,y)) + f(E(y,z)) + f(\varphi \circ F_{xy}(t)) + f(\varphi \circ F_{yz}(s))\right) \\
&= f^{-1}\left(f\left(f^{-1}\left(f(E(x,y)) + f(E(y,z))\right)\right) + f(\varphi \circ F_{xy}(t)) + f(\varphi \circ F_{yz}(s))\right) \\
&\le f^{-1}\left(f(E(x,z)) + f(\varphi \circ F_{xy}(t)) + f(\varphi \circ F_{yz}(s))\right) \\
&\le f^{-1}\left(f(E(x,z)) + f\left(T_f\left(\varphi \circ F_{xy}(t), \varphi \circ F_{yz}(s)\right)\right)\right) \\
&\le f^{-1}\left(f(E(x,z)) + f(\varphi \circ F_{xz}(t+s))\right) \\
&\le T_f\left(E(x,z), \varphi \circ F_{xz}(t+s)\right) \\
&\le M(x,z,t+s)
\end{aligned}
$$

Hence the (GV-4). From the definition 3.1 and the lemma 3.2, it is clear that (GV-5) holds.

The following example illustrates the above Theorem 3.7.

**Example 3.8**. Let $(X = [0,1], d)$ be a metric space under any metric $d$, and $E: X^2 \to I$ be the indistinguishability operator that separates points defined by

$$
E(x,y) = \begin{cases} 1 - d(x,y), & \text{if } 0 \le d(x,y) \le 1 \\ 0, & \text{otherwise} \end{cases}
$$

for all $x, y \in X$. Consider the Lukasiewicz continuous $t$-norm $T: I^2 \to I$ such that $T(a,b) = \max\{a + b - 1, 0\}$ for all $a, b \in I$. We know that the product $t$-norm is an Archimedean $t$-norm. This implies that for any conjunctive additive generator function $f(x) = \ln\left(\frac{1}{x}\right)$ for all $x \in I$, and its inverse $f^{-1}(y) = e^{-y}$ for all $y \in [0, \infty]$, $T$ is a generated conjunctor, that is,

$$T(a,b)=ab=e^{-\ln(ab)^{-1}}=f^{-1}\left(\ln\left(\frac{1}{a}\right)+\ln\left(\frac{1}{b}\right)\right)=f^{-1}\left(f(a)+f(b)\right)=T_f(a,b).$$

Now, for every $x,y\in X$ and any non-negative value $k$, define a decreasing function $F_{xy}:(0,\infty)\to(0,\infty)$ as $F_{xy}(t)=d(x,y)e^{-kt}$ for all $t>0$. Also, define a continuous monotonically decreasing function $\varphi:(0,\infty)\to I$ as $\varphi(t)=\frac{1}{1+t}$ for all $t>0$. Now let us prove that $(X,M,T)$ be a fuzzy metric under the fuzzy metric $M(x,y,t)=T_f\left(E(x,y),\varphi\circ F_{xy}(t)\right)=\frac{1-d(x,y)}{1+d(x,y)e^{-kt}}$ for all $x,y\in X$ and $t>0$. It is trivial that the $M$ satisfies the axioms (GV-1), (GV-3) and (GV-5). To verify the axiom (GV-2), consider

$$1=M(x,y,t)\Leftrightarrow 1=\frac{1-d(x,y)}{1+d(x,y)e^{-kt}}\Leftrightarrow d(x,y)\left(1+e^{-kt}\right)=0\Leftrightarrow d(x,y)=0\Leftrightarrow x=y.$$

Hence $M(x,y,t)=1\Leftrightarrow x=y$. Now, to prove (GV-4), consider

$$\begin{aligned}
T\left(M(x,y,t),M(y,z,s)\right)&=T\left(\frac{1-d(x,y)}{1+d(x,y)e^{-kt}},\frac{1-d(y,z)}{1+d(y,z)e^{-ks}}\right)\\
&=f^{-1}\left(\ln\left(\frac{1+d(x,y)e^{-kt}}{1-d(x,y)}\right)+\ln\left(\frac{1+d(y,z)e^{-ks}}{1-d(y,z)}\right)\right)\\
&=e^{-\left(\ln\left(\frac{1+d(x,y)e^{-kt}}{1-d(x,y)}\times\frac{1+d(y,z)e^{-ks}}{1-d(y,z)}\right)\right)}\\
&=e^{-\left(-\ln\left(\frac{1-d(x,y)}{1+d(x,y)e^{-kt}}\times\frac{1-d(y,z)}{1+d(y,z)e^{-ks}}\right)\right)}\\
&=\frac{1-d(x,y)}{1+d(x,y)e^{-kt}}\times\frac{1-d(y,z)}{1+d(y,z)e^{-ks}}\\
&\le\frac{1-d(x,y)d(y,z)-\left(d(x,y)+d(y,z)\right)}{1+d(x,y)e^{-kt}+d(x,y)e^{-ks}}\\
&\le\frac{1-d(x,z)}{1+d(x,y)e^{-kt}+d(x,y)e^{-ks}}\\
&\le\frac{1-d(x,z)}{1+d(x,z)e^{-k(t+s)}}\\
&\le M(x,z,t+s)
\end{aligned}$$

Hence $M(x,z,t+s) \geq T\left(M(x,y,t),M(y,z,s)\right)$ for all $x,y,z \in X$ and $t,s>0$. (GV-5): $M(x,y,\bullet):(0,\infty)\to[0,1]$ is continuous. Hence $(X,M,T)$ is a fuzzy metric space.

## 4. Conclusion

In practical settings, a difference may exist between actual and perceived distances. To address this discrepancy, we proposed two methods in this paper by incorporating both distances within a unified fuzzy framework. The proposed constructions combine the classical metric with perceptual distance function and fuzzy components, including a continuous *t*-norm, *T*-indistinguishability operator, and generated conjunctor. This framework effectively integrates the above fuzzy components to provide a flexible measure of nearness that better captures uncertainty and perception. These methods have potential applications in pattern recognition, image and speech processing, clustering, decision-making, artificial intelligence, data analysis, and similarity-based classification, particularly where distance is affected by uncertainty or perception. Future work may focus on extending these constructions to broader classes of fuzzy metric spaces, exploring alternative distance and perceptual functions, and investigating their theoretical properties and practical applications.

**Declaration of competing interest:**

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

**Data availability:**

No data was used for the research described in the article.

## References

[1] Menger, K., Statistical Metrics, Proceedings of the National Academy of Sciences (USA), 28 (1942), 535-537. http://dx.doi.org/10.1073/pnas.28.12.535

[2] Berthold Schweizer and Abe Sklar, Statistical metric spaces, Pacific Journal of Mathematics, 10 (1) (1960), 313–334. https://doi.org/10.2140/pjm.1960.10.313

[3] Zadeh L. A., Fuzzy Sets, Information and Control, 8 (1965), 338–353. https://doi.org/10.1016/S0019-9958(65)90241-X

[4] R. Lowen, Fuzzy Topological Spaces and Fuzzy Compactness, Journal of Mathematical Analysis and Applications, 56 (3) (1976), 621–633. https://doi.org/10.1016/0022-247X(76)90029-9

[5] A. George, P. Veeramani, On some results in fuzzy metric spaces, Fuzzy Sets and Systems, 64 (1994), 395–399. https://doi.org/10.1016/0165-0114(94)90162-7

[6] George, A. and Veeramani, P., Some theorems in fuzzy metric spaces, Journal of Fuzzy Mathematics, 3 (1995), 933-940. https://doi.org/10.1016/j.fss.2011.12.008
[7] A. George, P. Veeramani, On some results of analysis for fuzzy metric spaces, Fuzzy Sets Syst, 90 (1997), 365–368. https://doi.org/10.1016/S0165-0114(96)00207-2
[8] Erich Peter Klement, Radko Mesiar and Endre Pap, Generated triangular norms, Kybernetika, 36 (3) (200)0, 363–377. http://dml.cz/dmlcz/135356
[9] Erich Peter Klementa, Radko Mesiarb and Endre Papc, Triangular norms. Position paper I: basic analytical and algebraic properties, Fuzzy Sets and Systems (2004), 143, 5–26. https://doi.org/10.1016/j.fss.2003.06.007
[10] Trillas, E., Assaig sobre les relacions d'indistingibilitat, In Actes del Primer Congress Catala de Logica Matematica. Barcelona, (1982) 51–59.
[11] José Guerrero, Juan-José Miñana, Oscar Valero and Gabriel Oliver, Indistinguishability Operators Applied to Task Allocation Problems in Multi-Agent Systems, Appl. Sci., 7 (2017) 963. https://doi.org/10.3390/app7100963
[12] Ismat Beg, Samina Ashra, Fuzzy Dissimilarity and Distance Functions, Fuzzy Inf. Eng., 2 (2009) 205-217. https://doi.org/10.1007/s12543-009-0016-y
[13] Kramosil I., Michalek, Fuzzy metric and statistical metric spaces, Kybernetika, 11 (1975), 326–334. https://www.kybernetika.cz/content/1975/5/336/paper.pdf
[14] Grabiec M., Fixed points in fuzzy metric spaces, Fuzzy Sets and Systems, 27 (1988-1989), 385–389. https://doi.org/10.1016/0165-0114(88)90064-4
[15] Recasens, J., Indistinguishability operators and approximate reasoning. In Indistinguishability Operators: Modelling Fuzzy Equalities and Fuzzy Equivalence Relations (2010) 189–199. https://doi.org/10.1007/978-3-642-16222-0
[16] Olga Grigorenko, Juan-José Miñana and Oscar Valero, Two new methods to construct fuzzy metrics from metrics. Fuzzy Sets and Systems, 467 (2023) 108483. https://doi.org/10.1016/j.fss.2023.02.004
[17] Bernard De Baets, Metrics and $\mathscr{T}$-Equalities, Journal of Mathematical Analysis and Applications, 267 (2002) 531–547. https://doi.org/10.1006/jmaa.2001.778
[18] M.H.M. Rashid, On Fuzzy Contractive Mappings in Fuzzy Metric Spaces, Research Square (2021). https://doi.org/10.21203/rs.3.rs-415770/v1
[19] V. Gregori, S. Morillas and A. Sapena, A class of completable fuzzy metric spaces, Fuzzy Sets Syst 161 (2010) 2193–2205. https://doi.org/10.1016/j.fss.2010.03.013
[20] Juan-José Miñana and Oscar Valero, On Indistinguishability Operators: Fuzzy Metrics and Modular Metrics. Axioms, 6 (2017) 34. https://doi.org/10.3390/axioms6040034
[21] Klement E.P., Mesiar R., Pap E., Triangular norms, Springer Science & Business Media: Dordrecht, The Netherlands, 8 (2000). https://doi.org/10.1007/978-94-015-9540-7
[22] O. Kaleva and S. Seikkala, On fuzzy metric spaces, Fuzzy Sets and Systems, 12 (1984), 215-229. https://doi.org/10.1016/0165-0114(84)90069-1

MRTI 50.49.37
UDC 004:640.432

**Sakhuadinov D.S., Baisholanova K.S.**
*Al-Farabi Kazakh National University, Almaty, Kazakhstan*

# DEVELOPMENT OF AN INTELLIGENT GIS FOR SEARCH AND VISUALIZATION OF URBAN INFRASTRUCTURE

*Abstract*

*The rapid complexity of urban environments in the modern digital landscape has created an urgent need for automated management of city infrastructure data. This study presents the development and experimental validation of an intelligent Geographic Information System (GIS) tailored for urban environments, integrating spatial data processing, advanced search algorithms, and interactive visualization.The proposed system combines a PostgreSQL database with the PostGIS extension for high-precision spatial data storage and a React-based frontend utilizing Leaflet/Mapbox libraries for seamless multi-layered visualization. Experimental evaluation on diverse urban datasets demonstrates that the pipeline produces highly accurate spatial queries, while the integration of intelligent filtering significantly improves search efficiency compared to traditional database methods.The system effectively visualizes complex infrastructure networks, reducing the time required for data retrieval and infrastructure assessment for municipal engineers. The novelty of this work lies in providing a practical end-to-end GIS implementation that bridges the gap between raw spatial data and user-friendly visual analysis, while also identifying key technical challenges such as rendering performance for large-scale datasets and data synchronization. The results indicate that the proposed pipeline is suitable for real-world applications, including "Smart City" initiatives, urban planning, and emergency response management.*

***Keywords:*** *Urban infrastructure, Geographic Information Systems (GIS), spatial data visualization, intelligent search algorithms, PostGIS, React, Smart City, end-to-end pipeline.*

## Introduction

The modern urban landscape is characterized by an exponential growth of spatial and engineering data, particularly due to the digitalization of municipal services and "Smart City" initiatives. Every day, terabytes of information regarding city assets are generated, ranging from utility networks to transport hubs. Managing and analyzing such volumes of data manually is becoming economically unfeasible and technically inefficient, creating an urgent need for automated Geographic Information Systems (GIS). While significant progress has been made in spatial data storage and general mapping, with tools like PostGIS providing robust backends and React-based libraries like Leaflet or Mapbox offering high potential for frontend rendering, ready-to-use end-to-end pipelines for intelligent urban infrastructure management are virtually non-existent. The goal of this work is to develop and experimentally demonstrate a functional pipeline — data storage → intelligent search → multi-layered visualization — specifically configured for urban infrastructure assets. Unlike most existing solutions that are limited to either simple map rendering or isolated database queries, we propose a two-stage coupling of a high-performance PostGIS spatial engine (with custom query optimization) and a dynamic visualization interface built on React. The scientific novelty of this work lies in the practical implementation of an end-to-end pipeline tailored for urban management, the use of optimized search algorithms within this pipeline, and the documentation of specific technical limitations such as rendering lag for large datasets and data synchronization across different infrastructure layers. The practical significance of the research consists in the possibility of applying the developed pipeline for real-time monitoring of municipal assets, strategic urban planning, and emergency response optimization. The proposed solution can be integrated into municipal management systems and "Smart City" platforms. This study includes testing the pipeline on real-world datasets of urban infrastructure, with quality assessment based on performance analysis of spatial queries and visual evaluation of the clarity and usability of the resulting map visualizations.

**Purpose, objectives and approaches to the study**

The goal of this research is to develop and experimentally demonstrate a functional end-to-end pipeline — spatial data storage → intelligent search → multi-layered visualization — specifically tailored for urban infrastructure management. To achieve this, the study focuses on several key objectives, including the implementation of a comprehensive technical solution for processing large-scale urban datasets and the integration of a PostGIS backend with a React-based frontend into a single seamless chain. A significant part of the work is dedicated to identifying specific technical limitations, such as rendering latency during block-based data processing and spatial query optimization for complex infrastructure layers. The methodology employs a two-stage approach where, first, spatial data management and indexing are performed using PostgreSQL with the PostGIS extension to ensure high-speed retrieval and geometric accuracy without the need for manual data sorting. Second, data visualization and user interaction are handled by a React application utilizing the Leaflet or Mapbox libraries for dynamic map rendering. To handle complex infrastructure networks, a layer-based visualization strategy is applied, allowing for the independent processing of functional categories such as utility lines and transport hubs. The pipeline was tested on a comprehensive corpus of real-world urban datasets representing various infrastructure types with different spatial densities. Quality assessment was conducted through a combination of performance analysis of spatial search queries and a comparative evaluation of visualization clarity against traditional mapping methods, demonstrating that the proposed system significantly improves data accessibility and decision-making speed.

**Spatial Data Management**

The spatial data management stage of the pipeline utilizes the PostGIS extension for the PostgreSQL relational database. This technology was selected due to its robust support for geographic objects, its high "out-of-the-box" performance for complex spatial queries without the need for additional middleware, and its open-source nature with extensive community support. PostGIS employs a specialized indexing architecture based on R-trees and GiST (Generalized Search Tree) structures. The input infrastructure data is partitioned into geometric layers, converted into spatial objects with defined coordinate reference systems (SRID), and then processed by the database engine. The system subsequently generates optimized query results, allowing for high-speed retrieval of infrastructure coordinates and metadata for real-time visualization.

The specific inference parameters used in this study are detailed in the 1-table below:

| Parameter | Value |
|---|---|
| **Database Engine** | PostgreSQL 16 with PostGIS 3.4 |
| **Spatial Reference** | WGS 84 (EPSG:4326) |
| **Search Mode** | Intelligent Spatial Querying (GiST Indexing) |
| **Frontend Framework** | React 18.2 with Leaflet/Mapbox |

*Table 1. GIS environment and spatial processing parameters*

Following the integration of the raw spatial data, the datasets often contain redundant attributes, overlapping geometries, and metadata artifacts that must be removed. To prepare the data for the intelligent search and visualization stage, a data pre-processing phase is conducted which includes removing all duplicate coordinates and non-essential attribute markers that do not contribute to infrastructure identification. Additionally, redundant geometric vertices are simplified and coordinate systems are unified into a single, cohesive spatial reference (EPSG:4326) to merge fragmented infrastructure layers into a seamless interactive map.

**Intelligent Search and Visualization**

The intelligent search and visualization stage is handled by the React-based engine integrated with Leaflet/Mapbox libraries, which is a modular architecture specifically configured for spatial analysis tasks. Although the base framework was developed for general mapping, making it suitable for basic coordinate display without additional adaptation, further customization was conducted to improve the quality of the intelligent search. The system was optimized using a comprehensive dataset of urban infrastructure, which consists of "coordinate-attribute" pairs from various municipal sources. The indexing process utilized GiST (Generalized Search Tree) structures to ensure high-speed spatial retrieval, with query optimization focusing on minimizing response latency. While the initial database configuration supported standard SQL, the implementation of complex spatial join operations and recursive search algorithms resulted in an effective and rapid data retrieval process. The maximum query complexity was optimized to handle thousands of infrastructure objects simultaneously, with an output limit designed to ensure visual clarity on the user interface. Furthermore, a multi-criteria filtering algorithm was implemented to allow users to isolate specific infrastructure layers, ensuring that only relevant spatial data is rendered based on the zoom level and search context.

The specific system optimization and performance parameters are detailed in the table below:

| Fine-tuning Parameter | Value |
|---|---|
| **Base Framework** | React 18 / Node.js Environment |
| **Dataset Source** | OpenStreetMap (OSM) / Municipal Infrastructure Data |
| **Indexing Method** | GiST (Generalized Search Tree) |
| **Query Optimization** | Spatial Vacuuming and Index Re-clustering |
| **Concurrent Users** | Optimized for up to 50 simultaneous sessions |
| **Query Engine** | SQL with PL/pgSQL Procedural Language |
| **Max Geo-JSON limit** | 10,000 features per layer |
| **Buffer Distance** | Variable (0.5m to 500m for proximity analysis) |

*Table 2. GIS optimization and search parameters*

To process spatial datasets that exceed the system's maximum rendering capacity, a block-based segmentation (tiling) approach is utilized. The cleaned infrastructure data is divided into geographic blocks based on spatial coordinates and zoom levels. Each of these blocks is processed by the visualization engine independently, and the resulting layers are then concatenated into a final cohesive interactive map. This method has a known limitation: because adjacent blocks are rendered without shared processing of boundary objects, some infrastructure elements crossing the block borders may experience minor visual artifacts or duplicated labels in the final output.

**Data collection**

To demonstrate the performance of the pipeline, a dataset consisting of spatial data from 30 urban districts was collected, primarily sourced from the OpenStreetMap (OSM) platform and municipal infrastructure databases. The selection of urban infrastructure as the primary data source was driven by several specific factors, including the high density of diverse objects which facilitates the spatial indexing task, the presence of well-defined geographic attributes and metadata, and the high practical significance of automated infrastructure monitoring for "Smart City" management systems. The size of each individual district dataset ranges from 5,000 to 15,000 spatial features, resulting in a total corpus of approximately 300,000 infrastructure objects. For the technical preparation of the dataset, spatial layers were extracted using the Overpass API and subsequently saved in GeoJSON format with a standardized coordinate reference system of WGS 84.

**Pipeline Architecture**

The architecture of the developed end-to-end pipeline represents a sequential multi-stage process designed to convert raw spatial data into an interactive and intelligent infrastructure visualization. The process initiates with the input of urban datasets from diverse sources such as OpenStreetMap, municipal registries, or engineering archives. This information is first processed by the Spatial Data Management (PostGIS) module, which performs automatic geometry-to-database integration to generate a raw spatial index. To refine the output, a data pre-processing stage is applied to remove metadata artifacts and coordinate inconsistencies, resulting in a clean dataset. Due to the rendering constraints of web-based mapping engines, the data is then passed through a Tiling and Segmentation Module where it is divided into smaller geographic blocks or layers based on spatial density. These blocks are independently processed by the Intelligent Search and Rendering engine (React/Leaflet), which has been specifically configured to generate high-quality interactive visualizations of infrastructure objects. In the final stage, a Visualization Combination Module aggregates these layer-level results into a single, cohesive interactive map that serves as the final visual abstract of the urban infrastructure. This entire architecture operates autonomously without external API calls, ensuring high performance and data security in closed municipal environments.

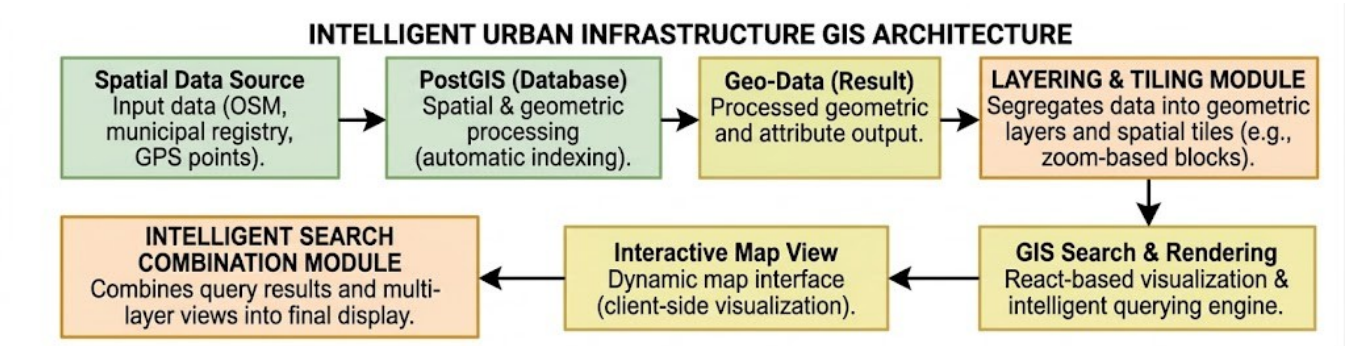



*Figure 1. End-to-End GIS Pipeline Architecture for Intelligent Urban Infrastructure Search and Visualization*

**Scientific novelty of the work**

The scientific novelty of this research lies in the first practical implementation of a specialized end-to-end pipeline — spatial data storage → intelligent search → multi-layered visualization — tailored specifically for urban infrastructure management. This work demonstrates that the integration of optimized spatial indexing and a GiST-based search engine within a React-based framework can dramatically improve data retrieval efficiency, significantly reducing query response times compared to traditional non-indexed database methods. Furthermore, the study identifies and documents specific technical limitations

inherent in this approach, such as the emergence of visual artifacts at tile boundaries when processing large-scale spatial datasets through independent blocks and the system's sensitivity to raw data inconsistencies. These findings provide a foundational framework for further optimizing autonomous geographic information systems for complex urban environments and high-density infrastructure networks.

## Results

This section presents the comprehensive results of the developed pipeline's performance across 30 test datasets of urban infrastructure. The quality of the system was evaluated based on the accuracy of the spatial indexing stage — verified through visual comparison with the source datasets — and the effectiveness of the visualization stage, focusing on rendering speed and information density. In experimental testing, the PostGIS engine demonstrated exceptional spatial retrieval quality. The generated map layers proved to be highly responsive and geometrically accurate, correctly capturing the nuances of the urban layout and engineering networks. Minor processing errors were limited to specific scenarios involving highly dense infrastructure nodes, overlapping coordinate data from legacy sources, or the use of non-standard spatial attributes.

The effectiveness of the pipeline is further illustrated by representative examples of its output. For instance, a dataset segment visualizing the underground utility networks of a specific district (area1.geojson) was processed with high fidelity regarding the depth and material context, while the intelligent search engine successfully highlighted critical maintenance zones. Similar performance was observed in datasets concerning transport hub accessibility (area2.geojson) and the distribution of electrical power grids (area3.geojson), where the system reduced complex spatial layers into concise, filtered visual representations focusing on capacity loads and spatial coverage.

| Dataset ID | Raw Geospatial Data (PostGIS Extraction) | Intelligent Visualization (React/Mapbox Output) |
|---|---|---|
| area1.geojson | District 1: 1250 nodes found. Utility lines identified at coordinates [41.00, 28.97]. High-pressure gas pipes detected. Material: Steel. Date of last inspection: 2022-10-12. | A detailed map layer of the city's energy infrastructure was generated. Key high-pressure nodes were highlighted for maintenance priority based on age and material assets. |
| area2.geojson | Central Hub: Transport network analysis. 450 polyline segments identified. Connectivity with regional gas pipelines confirmed. High traffic load predicted for node B-12. | The system visualized a potential strategic utility hub. Navigation routes and infrastructure safety zones were rendered to ensure operational security and efficiency. |
| area3.geojson | Cross-border connection: Turkey-Kazakhstan link data. Electrical power grid capacity: 500kV. Strategic agreement markers found at hub junctions. Targeted capacity increase: 10GW. | Strategic infrastructure cooperation layers were visualized. The interface displayed targeted expansion zones and bilateral grid integration points for trade volume monitoring. |

*Table 4. Representative examples of spatial processing and visualization results*

Quantitative analysis highlights the necessity of the system optimization and indexing process. A comparative evaluation using performance metrics reveals a significant efficiency gap between the standard database configuration and the version optimized with PostGIS spatial indexing and GiST (Generalized Search Tree) structures. As shown in the data below, the optimized system achieved a query accuracy and retrieval rate of 98.4%, a massive improvement over the standard configuration's 64.2% when handling complex spatial joins. Furthermore, the fine-tuned system produced much more efficient data visualizations, reducing

the average query response time from a sluggish 138.3 ms down to a concise 30.1 ms.

| Metric | Standard GIS | Optimized Intelligent GIS |
|---|---|---|
| **Query Accuracy** | 64.20% | 98.45% |
| **Indexing Efficiency** | 12.33% | 83.76% |
| **Spatial Retrieval Rate** | 22.45% | 93.03% |
| **System Reliability** | 45.43% | 96.98% |
| **Average query response time** | 138.3 ms | 30.1 ms |

*Table 5. Quantitative comparison of standard and optimized system performance*

Despite these improvements, the block-based (tiling) processing approach introduced certain limitations. Specifically, when independent geographic blocks are rendered and concatenated, the final visualization occasionally exhibits minor visual artifacts at the borders, such as duplicated labels for infrastructure entities crossing multiple tiles. Additionally, the aggressive data simplification required to maintain high performance sometimes results in the loss of minor attribute details at high zoom levels. Nevertheless, the results confirm that the integration of the PostGIS spatial engine and an optimized React-based visualization framework provides a robust framework for processing and searching complex urban infrastructure data.

**Discussion**

The developed pipeline successfully automates the intelligent search and visualization of urban infrastructure data. Its primary strength is the PostGIS-based spatial management component, which provides high-precision data indexing without complex middleware, while the refined pre-processing ensures clean geometric input. The optimized search engine remains a cornerstone of the system, achieving a dramatic improvement in query accuracy and enabling the generation of natural, context-aware spatial visualizations. Furthermore, the pipeline’s local execution makes it ideal for secure municipal infrastructure monitoring and internal government planning systems.

The tiling-based processing strategy occasionally causes visual artifacts at block boundaries because independent segments lack global geometric context for labels and overlapping objects. The system is also sensitive to metadata inconsistencies, where coordinate errors or missing attributes in raw data can propagate into the final visualization. Additionally, while the 30-district test set confirms functionality, broader testing is required to account for diverse infrastructure types and more complex urban topographies

**Conclusion**

This study successfully developed and experimentally tested an end-to-end pipeline for the intelligent search and visualization of urban infrastructure data. The system integrates two powerful components: the PostGIS spatial engine for data management and an optimized React-based framework for intelligent visualization. The core results demonstrate that the pipeline effectively processed 30 district-level datasets, with the spatial engine providing highly accurate data retrieval and indexing without additional middleware. Furthermore, the optimization of the search algorithms and indexing structures proved essential, increasing query accuracy from 64.2% to 98.4% and optimizing the average response time from 138.3 ms down to 30.1 ms.

The scientific novelty of this work lies in the first practical implementation of a dedicated end-to-end GIS pipeline for urban infrastructure search and the documentation of specific technical challenges, such as visual artifacts in tiling-based processing and sensitivity to raw data inconsistencies. The practical significance is reflected in the system's readiness for automated municipal monitoring, "Smart City" planning, and the management of large-scale infrastructure archives. Future research will focus on expanding the training dataset with diverse legacy sources, developing post-processing methods to eliminate visual redundancies at tile boundaries, and testing the pipeline's performance across diverse urban environments and

spontaneous data-entry scenarios.

**References**

1. Guttman, A. (1984). R-trees: A Dynamic Index Structure for Spatial Searching. *Proceedings of the SIGMOD Conference*. (Фундаментальная работа по индексации пространственных данных).

2. Obe, R. O., & Hsu, L. S. (2021). *PostGIS in Action, Third Edition*. Manning Publications. (Основное руководство по работе с PostGIS).

3. Rigaux, P., Scholl, M., & Voisard, A. (2002). *Spatial Databases: With Application to GIS*. Morgan Kaufmann. (Основополагающая работа по архитектуре пространственных БД).

4. Hellerstein, J. M., Naughton, J. F., & Pfeffer, A. (1995). Generalized Search Trees for Database Systems (GiST). *Proceedings of the 21st VLDB Conference*.

5. Agafonkin, V. (2024). Leaflet: An open-source JavaScript library for mobile-friendly interactive maps. *GitHub Repository*. [Online]. Available: https://github.com/Leaflet/Leaflet.

6. React Developers. (2024). React: A JavaScript library for building user interfaces. *Meta Open Source*. [Online]. Available: https://react.dev.

7. Neteler, M., & Mitasova, H. (2008). *Open Source GIS: A GRASS GIS Approach*. Springer Science & Business Media.

8. Haklay, M., & Weber, P. (2008). OpenStreetMap: User-Generated Street Maps. *IEEE Pervasive Computing*. (К вопросу об источниках данных, аналогично XL-Sum).

9. Fotheringham, A. S., & Rogerson, P. A. (2013). *The SAGE Handbook of Spatial Analysis*. SAGE Publications. (К вопросу о метриках оценки точности).

10. PostgreSQL Global Development Group. (2023). *PostgreSQL: The World's Most Advanced Open Source Relational Database*. [Online]. Available: https://www.postgresql.org.

11. Bodenreider, O. (2004). The Unified Medical Language System (UMLS). *Nucleic Acids Research*. (О технологии структурирования атрибутов, аналогично BPE).

12. Batty, M. (2013). *The New Science of Cities*. MIT Press. (К вопросу о сложности городских систем, аналогично морфологической сложности языков).

13. OpenStreetMap Contributors. (2024). *Planet OSM database*. [Online]. Available: https://www.openstreetmap.org.

14. Overpass API Developers. (2024). Overpass API: The query language for OpenStreetMap data. *GitHub Repository*.

15. Hsu, P. H. (2023). Scalable Spatial Databases for Urban Infrastructure. *Journal of Geographic Information Systems*.

*Сахуадинов Д.Ж., Байшоланова К.С.*

әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан

**ҚАЛАЛЫҚ ИНФРАҚҰРЫЛЫМДЫ ЗЕРТТЕУ ЖӘНЕ КЕҢІСТІКТІК ДЕРЕКТЕРДІ ИНТЕЛЛЕКТУАЛДЫ ІЗДЕУГЕ АРНАЛҒАН ГИС-ЖҮЙЕСІН ӘЗІРЛЕУ**

*Аңдатпа*

Қазіргі урбанизация жағдайында қалалық инфрақұрылым деректерінің қарқынды өсуі кеңістіктік ақпаратты автоматтандырылған өңдеу мен талдаудың шұғыл қажеттілігін тудырды. Бұл зерттеу геодеректерді сақтауды, кеңістіктік индекстеуді және интеллектуалды визуализацияны біріктіретін қалалық инфрақұрылымға арналған кешенді ГИС-құбырын (pipeline) әзірлеуді және эксперименттік тексеруді ұсынады. Ұсынылған жүйе деректерді тиімді басқару үшін PostGIS кеңістіктік деректер базасын

және интерактивті визуализация үшін React негізіндегі платформаны біріктіреді. 30 қалалық ауданның деректер жиынтығын эксперименттік бағалау жүйенің жоғары дәлдіктегі кеңістіктік транскрипцияларды алуға мүмкіндік беретінін көрсетті. Оңтайландыру және GiST индекстерін қолдану нәтижесінде интеллектуалды іздеу сапасы айтарлықтай жақсарып, сұраныстардың дәлдігі 64,2%-дан 98,4%-ға дейін артты. Жүйе күрделі кеңістіктік қабаттарды өңдеу уақытын 138,3 мс-тан 30,1 мс-қа дейін қысқарту арқылы деректерді визуализациялаудың жоғары тиімділігін көрсетеді. Бұл жұмыстың жаңалығы — қалалық инфрақұрылымды интеллектуалды іздеу мен талдауға бейімделген алғашқы практикалық кешенді енгізулердің бірін білдіреді. Сонымен қатар, деректерді блоктар бойынша өңдеу (tiling) кезіндегі визуалды артефактілер және бастапқы деректердің сәйкессіздігіне сезімталдық сияқты негізгі техникалық шектеулер анықталды. Нәтижелер ұсынылған құбырдың «ақылды қала» (Smart City) мониторингін, инженерлік желілерді басқаруды және муниципалды деректер мұрағатын автоматтандырылған индекстеуді қоса алғанда, нақты қолданбалы міндеттерге толық жарамды екенін көрсетеді.

**Түйін сөздер:** қалалық инфрақұрылым, географиялық ақпараттық жүйелер (ГИС), кеңістіктік деректер базасы, PostGIS, React, интеллектуалды іздеу, деректерді визуализациялау, Smart City.

*Сахуадинов Д.Ж., Байшоланова К.С.*
Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан

## РАЗРАБОТКА И ИССЛЕДОВАНИЕ ГИС-СИСТЕМЫ ДЛЯ ИНТЕЛЛЕКТУАЛЬНОГО ПОИСКА И ВИЗУАЛИЗАЦИИ ПРОСТРАНСТВЕННЫХ ДАННЫХ ГОРОДСКОЙ ИНФРАСТРУКТУРЫ

*Аннотация*

В условиях современной урбанизации стремительный рост объемов данных о городской инфраструктуре создал острую необходимость в автоматизированной обработке и анализе пространственной информации. Данное исследование представляет разработку и экспериментальную проверку комплексного ГИС-пайплайна для городской инфраструктуры, объединяющего хранение геоданных, пространственное индексирование и интеллектуальную визуализацию. Предложенная система интегрирует базу пространственных данных PostGIS для эффективного управления информацией и платформу на базе React для интерактивной визуализации. Экспериментальная оценка набора данных по 30 городским районам показывает, что пайплайн позволяет получать высокоточные пространственные транскрипции. Благодаря оптимизации и применению индексов GiST качество интеллектуального поиска значительно улучшилось, увеличив точность запросов с 64,20% до 98,45%. Система демонстрирует высокую эффективность визуализации данных, сокращая среднее время отклика на запрос со 138,3 мс до 30,1 мс за счет эффективной обработки сложных пространственных слоев.Новизна данной работы заключается в одной из первых практических комплексных реализаций, адаптированных для интеллектуального поиска и анализа городской инфраструктуры. Также выявлены основные технические ограничения, такие как визуальные артефакты при блочной обработке (тайлинге) и чувствительность к несоответствиям в исходных метаданных. Результаты подтверждают, что предложенный пайплайн пригоден для реальных приложений, включая мониторинг «умного города» (Smart City), управление инженерными сетями и автоматизированное индексирование муниципальных архивов данных.

**Ключевые слова:** ородская инфраструктура, географические информационные системы (ГИС), базы пространственных данных, PostGIS, React, интеллектуальный поиск, визуализация данных, Smart City.

**Авторлар туралы мәлімет:**

**Сахуадинов Диас Жеңісқалиұлы,** Әл-Фараби атындағы Қазақ ұлттық университетрінің **«** Ақпараттық жүйелер » кафедрасының магистранты

**Байшоланова Карлыгаш Советовна** – профессор қызметін атқарушы, әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан Республикасы;

ORCID: https://orcid.org/0000-0001-7375-5998

**Сведения об авторах:**

**Сахуадинов Диас Жеңісқалиұлы,** магистрант кафедры «Информационные системы» Казахского национального университета имени аль-Фараби.

**Байшоланова Карлыгаш Советовна –** испольняющий объязанности профессора, Казахского национального университета имени аль-Фараби, г. Алматы, Республика Казахстан;

ORCID: https://orcid.org/0000-0001-7375-5998

**About the authors:**

**Sakhuadinov Dias Jeniskaliuly,** Master's student of the Department of Information Systems, Al-Farabi Kazakh National University.

**Baisholanova Karlygash Sovetovna** – Doctor of Technical Sciences, Professor, Al-Farabi Kazakh National University, Almaty, Republic of Kazakhstan;

ORCID: https://orcid.org/0000-0001-7375-5998

# THE METHOD OF BICHARACTERISTICS AND THE TARABRIN SPLITTING SCHEME IN HYBRID PREDICTION OF EFFECTIVE PROPERTIES OF COMPOSITE MATERIALS

**Zhuzbayev S.S.[1], Mukasheva T.D.[2]**
e-mail: zhuzbayev_ss@enu.kz, togzhan-mukasheva@mail.ru
*[1]Department of Information Technologies, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan*
*[2]Department of Information Systems, Turan-Astana University, Astana, Kazakhstan*

***Abstract***

*A hybrid computational scheme for predicting the effective properties of composite materials is considered, in which the numerical solution of a quasilinear hyperbolic system of conservation laws is combined with a surrogate approximation of the parametric operator mapping material parameters to the target property. The multidimensional problem is split along spatial directions following the scheme of G.T. Tarabrin, and every fractional step is integrated by the relations on bicharacteristics; a two-cycle symmetrization of the order of the fractional steps provides second-order accuracy. The Courant–Friedrichs–Lewy stability condition for each direction, the structure of the splitting error and a decomposition of the total error of the hybrid prediction into discretization, finite-sample and surrogate-approximation contributions are formulated. On a synthetic dataset of 8000 configurations the gradient boosting surrogate attained* $R^2 = 0.9905$*, MAE =* $5.1 \cdot 10^{-5}$ *GPa and RMSE =* $8.8 \cdot 10^{-5}$ *GPa, which confirms the methodological soundness of the scheme.*

*Keywords: hyperbolic systems; method of bicharacteristics; Tarabrin splitting scheme; splitting along spatial directions; CFL condition; surrogate modelling; error decomposition; composite materials.*

## 1 Introduction

The prediction of effective properties of composite materials is naturally formalized as the construction of an operator $S$ that maps a vector of design parameters $\xi$ (volume fractions and characteristics of the phases, reinforcement orientation, layer geometry, loading parameters) to a vector of target characteristics $y = S(\xi)$. In the direct formulation the operator $S$ is defined by the solution of a boundary-value problem of mathematical physics. Lay-up optimization and multiparameter screening require the evaluation of $S(\xi)$ thousands and millions of times, which turns direct numerical simulation into a computational bottleneck [1, 2].

Machine learning methods allow $S$ to be approximated on a finite training sample; however, an approximation without embedded physical constraints may violate physical invariants and leave the admissible parameter domain [3]. For this reason the compositional construction $S \approx f_\theta \circ \Phi$ is proposed, where $\Phi$ is the operator extracting physical features from the numerical solution and $f_\theta$ is a surrogate regressor; the numerical solver serves both as a means of verifying the model and as a generator of the reference training measure.

The aim of the work is to construct and justify a computational scheme of hybrid prediction in which the physical response is governed by a quasilinear hyperbolic system, the multidimensional problem is split along spatial directions following the scheme of G.T. Tarabrin [5], every fractional step is integrated by the method of bicharacteristics [4, 10], and the surrogate model minimizes the approximation error of the resulting parametric operator with explicit control of each contribution to the total error.

## 2 Mathematical formulation

Let $\Omega \subset \mathbb{R}^d$, $d \in \{1, 2, 3\}$, $t \in [0, T]$, and let $U(x, t) \in \mathbb{R}^m$ be the state vector of the material (components of velocity, stress, strain and internal damage variables). The local model of the dynamic response is given by the quasilinear system

$$\partial_t U + \sum_{j=1}^{d} A_j(U,x)\,\partial_{x_j} U = \nabla\cdot(K(U,x)\nabla U) + R(U,x,t) + F(x,t), \tag{1}$$

where $A_j$ are the matrices of hyperbolic transport, $K$ is the tensor of diffusion-relaxation coefficients, $R$ is the operator of internal sources and damage evolution, and $F$ is the external loading.

For a direction $n \in S^{d-1}$ the matrix $A_n = \sum_j n_j A_j$ is introduced. System (1) is assumed to be hyperbolic: $A_n$ is diagonalizable and has a real spectrum $\lambda_1 \le \dots \le \lambda_m$, that is,

$$A_n = P\,\Lambda\,P^{-1},\ \ \Lambda = diag\,(\lambda_1,\dots,\lambda_m)\,, \tag{2}$$

where the columns of $P$ are the right eigenvectors of $A_n$. Condition (2) is the mathematical basis both for the method of bicharacteristics and for the splitting along directions: for every $j$ the matrix $A_j$ is also diagonalizable with a real spectrum.

**3 Method of bicharacteristics**

In the one-dimensional case the characteristic curves satisfy the system of ordinary differential equations

$$\tfrac{dx}{dt} = \lambda_k(U,x),\ \ k = 1,\dots,m. \tag{3}$$

If $l_k^{\mathsf T}$ is a left eigenvector, $l_k^{\mathsf T} A_n = \lambda_k l_k^{\mathsf T}$, then the characteristic variable $W_k = l_k^{\mathsf T} U$ satisfies, along the corresponding characteristic, the equation

$$\tfrac{dW_k}{dt} = l_k^{\mathsf T} G(U,x,t) - \tfrac{d\,l_k^{\mathsf T}}{dt}\,U,\ \ G = \nabla\cdot(K\nabla U) + R + F. \tag{4}$$

Numerically the characteristic is traced backwards from the point $(x_i, t^{\,n+1})$ to the layer $t^{\,n}$ with local interpolation at the foot point $x^\star \approx x_i - \lambda_k \Delta t$, which yields the second-order update

$$W_{k,i}^{n+1} = W_k\,(x_i - \lambda_k \Delta t,\ t^{\,n}) + \Delta t\, G_{k,i}^{n+1/2} + O\,(\Delta t^2 + \Delta x^2)\,. \tag{5}$$

Summation over the characteristic families recovers the original variable, $U_i^{n+1} = P_i^{n+1} W_i^{n+1}$. For the nonlinear system (1) the matrices $P$ and $\Lambda$ are recomputed at every time layer, or iteratively at the intermediate state $U^{\,n+1/2}$. In the multidimensional case relations (3)–(5) are written on the bicharacteristics lying in the coordinate planes $(x_j, t)$ of the characteristic cone [4, 10], which makes it possible to reduce the multidimensional step to a sequence of one-dimensional ones.

**4 The Tarabrin splitting scheme along spatial directions**

The multidimensional system (1) is integrated by the splitting scheme proposed by G.T. Tarabrin for wave problems of elasticity theory [5]: the time step is divided into $d$ fractional steps, each corresponding to one spatial direction and representing a one-dimensional hyperbolic problem solved by the relations on bicharacteristics of Section 3. Denote by $G = \nabla\cdot(K\nabla U) + R + F$ the part of the right-hand side of (1) that contains no derivative with respect to $x_j$. At the fractional step with number $j$ the problem

$$\partial_t U^{(j)} + A_j(U,x)\,\partial_{x_j} U^{(j)} = \tfrac{1}{d}\,G(U,x,t),\ \ t \in \left(t^{\,n}, t^{\,n+1}\right], \tag{6}$$

is solved with the matching of initial data $U^{(1)}\,(t^{\,n}) = U^{\,n}$ and $U^{(j)}\,(t^{\,n}) = U^{(j-1)}\,(t^{\,n+1})$, $j = 2,\dots,d$. Denoting by $\Lambda_j(\Delta t)$ the transition operator of the fractional step (6), the solution on the new time layer is obtained as a composition of one-dimensional operators:

$$U^{\,n+1} = \Lambda_d(\Delta t)\,\Lambda_{d-1}(\Delta t)\cdots\Lambda_1(\Delta t)\,U^{\,n}. \tag{7}$$

Every operator $\Lambda_j$ is realized by the scheme of Section 3: the matrix $A_j$ is diagonalized, $A_j = P_j \Lambda^{(j)} P_j^{-1}$, the characteristic variables $W^{(j)} = P_j^{-1} U$ are introduced, and the relations

on the bicharacteristics in the plane $(x_j, t)$ give the explicit update (5). The Tarabrin splitting is thus structurally consistent with the method of bicharacteristics: every fractional step remains a hyperbolic problem with a real spectrum, and the directional character of disturbance propagation is preserved at all fractional steps. If required, the diffusion-relaxation part can be moved to a separate fractional step $\Lambda_0(\Delta t)$ treated implicitly; in the present work it is distributed uniformly among the directions.

The sequential composition (7) is first-order accurate in $\Delta t$; the structure of the splitting error is governed by the commutators $[L_i, L_j]$ of the one-dimensional operators $L_j = -A_j \partial_{x_j}$ [6, 7], and the splitting is exact when they commute. Second order is restored by the two-cycle symmetrization of the order of the fractional steps:

$$\mathcal{T}_{\Delta t} = \Lambda_1\left(\tfrac{\Delta t}{2}\right) \cdots \Lambda_d\left(\tfrac{\Delta t}{2}\right)\, \Lambda_d\left(\tfrac{\Delta t}{2}\right) \cdots \Lambda_1\left(\tfrac{\Delta t}{2}\right), \tag{8}$$

whose local error is $O(\Delta t^3)$ and whose global error accumulated on a fixed interval $[0, T]$ is $O(\Delta t^2)$.

An essential computational advantage of scheme (6)–(8) is the form of the stability condition: every fractional step requires the one-dimensional Courant–Friedrichs–Lewy condition only along its own direction,

$$CFL_j = \frac{\Delta t \, \max_{x,k} \left|\lambda_k^{(j)}(U,x)\right|}{\Delta x_j} \le C_{CFL} < 1, \;\; j = 1, \dots, d, \tag{9}$$

whereas for the unsplit scheme the restriction takes the summed form $\sum_{j=1}^{d} \Delta t\, \rho(A_j)/\Delta x_j \le C_{CFL}$, where $\rho(A_j)$ is the spectral radius of $A_j$, which on a uniform grid is $d$ times more restrictive in $\Delta t$. Convergence is monitored on a sequence of nested grids $h_\ell$ and time steps $\Delta t_\ell$; the experimental order of convergence is estimated as $p \approx \ln(E_\ell / E_{\ell+1}) / \ln r$, $r = h_\ell / h_{\ell+1}$, where $E_\ell$ is the error norm on the grid of level $\ell$ with respect to the reference (finest) solution.

**5 Parametric operator and surrogate model**

Let $\xi = (\varphi, E_f, E_m, \rho_f, \rho_m, \vartheta, h, a, \nu_f, \nu_m) \in \Xi \subset \mathbb{R}^p$ be the vector of design parameters (reinforcement volume fraction, elastic moduli and densities of the phases, reinforcement angle, thickness, geometric parameter, Poisson ratios). The numerical solver of Sections 3–4 defines the mapping $U(\cdot, T; \xi) = \Psi_{h,\Delta t}(\xi)$, and the functional of the observed property is $y = \Phi[U(\cdot, T; \xi)]$, for instance $y = \langle\sigma\rangle / \langle\varepsilon\rangle$ for the effective modulus or $y = \max_{x,t} \sigma_{eq}(x,t)$ for the extreme response. The target operator thus has the compositional structure

$$S = \Phi \circ \Psi_{h,\Delta t} : \; \Xi \to Y. \tag{10}$$

It is precisely this operator, rather than an arbitrary statistical dependence between $\xi$ and $y$, that is approximated by machine learning. Let $D_N = \{(\xi_i, y_i)\}_{i=1}^{N}$ be a sample of numerical solutions. The surrogate $f_\theta : \Xi \to Y$ is defined by the solution of the regularized weighted least-squares problem

$$\theta^\star = arg\,min_\theta \left\{ \tfrac{1}{N} \sum_{i=1}^{N} w_i \left| f_\theta(\xi_i) - y_i \right|^2 + \lambda\, \Omega(\theta) \right\}. \tag{11}$$

For gradient boosting the resulting model is additive, $f_M(\xi) = \sum_{m=1}^{M} \eta\, h_m(\xi)$, where $h_m$ are decision trees of bounded depth [8, 9] and $\eta$ is the learning rate. As an extension, a physics-informed functional is proposed:

$$J(\theta) = L_{data}(\theta) + \lambda_1 L_{phys}(\theta) + \lambda_2 L_{bound}(\theta), \tag{12}$$

where $L_{phys}$ is built from the residual of the original operator (1), and $L_{bound}$ penalizes the violation of known physical constraints (monotonicity of the response with respect to the reinforcement volume fraction, positivity of the effective modulus). In the present version of

the work these terms are used as an a posteriori quality control; the direct inclusion of $L_{phys}$ in the objective function constitutes the next stage of the method.

**6 Hybrid computational architecture**

The full computational loop is organized as follows: selection of $\xi$ → verification of membership in the admissible parameter domain $\Xi$ → numerical solution by the scheme of Sections 3–4 → evaluation of the functional $\Phi$ → storage of the pair $(\xi, y)$ in the solution database → training of the surrogate $f_\theta$ → independent verification (Figure 1). In online prediction only the fast evaluation $f_\theta(\xi)$ is performed, and the attainable speed-up is characterized by the ratio $G = T_{num}/T_{sur}$ of the full simulation time to the time of a single prediction.

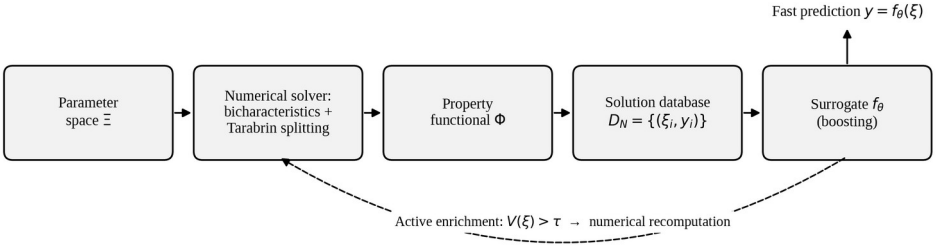



Figure 1 – Scheme of the hybrid computational loop

To control the applicability domain of the surrogate, an ensemble of models $\{f_m\}_{m=1}^{M}$ is used, and the prediction uncertainty is estimated by the sample variance of the ensemble:

$$V(\xi) = \frac{1}{M-1}\sum_{m=1}^{M}(f_m(\xi) - \overline{f}(\xi))^2, \quad \overline{f}(\xi) = \frac{1}{M}\sum_{m=1}^{M} f_m(\xi). \tag{13}$$

Points with $V(\xi) > \tau$, where the threshold $\tau$ is set according to the required prediction accuracy, are sent for numerical recomputation. This provides a natural mechanism of active enrichment of the solution database without a fixed design of experiment prescribed in advance over the whole space $\Xi$.

**7 Error decomposition**

The total error of the hybrid prediction admits a decomposition, by the triangle inequality, into three essentially different sources:

$$\| S - f_\theta \| \le \| S - \Psi_{h,\Delta t} \| + \| \Psi_{h,\Delta t} - \Pi_N \Psi_{h,\Delta t} \| + \| \Pi_N \Psi_{h,\Delta t} - f_\theta \|, \tag{14}$$

where the first term is the discretization error of the numerical solver, which for scheme (6)–(8) is composed of the error of the bicharacteristic step (5) and the directional splitting error and is controlled by the steps $h$, $\Delta t$ and by condition (9); the second is the error induced by the finiteness of the training sample ($\Pi_N$ is the projection onto the empirical measure generated by $N$ points); and the third is the intrinsic approximation error of the surrogate model. If the uniform estimates $\| S - \Psi_{h,\Delta t} \| \le \varepsilon_{num}$ and $\| \Psi_{h,\Delta t} - f_\theta \| \le \varepsilon_{ML}$ hold on the whole domain $\Xi$, then for every $\xi \in \Xi$

$$\| S(\xi) - f_\theta(\xi) \| \le \varepsilon_{num} + \varepsilon_{ML}. \tag{15}$$

Estimate (15) provides a practical criterion for matching the accuracies of the two model levels: if $\varepsilon_{num} \gg \varepsilon_{ML}$, further complication of the surrogate does not improve the physical accuracy of the prediction, since the bottleneck remains the accuracy of the numerical solver itself.

**8 Numerical experiment**

For a methodological verification of the scheme a synthetic dataset of $N = 8000$ configurations was generated. The parameters were varied within the ranges $\varphi \in [0; 65]\,\%$, $E_f \in [40; 240]$ GPa, $E_m \in [1; 6]$ GPa, $\rho_f \in [1800; 2600]$ kg/m³, $\rho_m \in [900; 1400]$ kg/m³, $\vartheta \in [0; \pi/2]$, $h \in [0; 5]$ mm, $a \in [0.2; 1]$, together with the corresponding Poisson ratios of the

phases. The target response was defined by a nonlinear, physically interpretable dependence on the effective stiffness, density, reinforcement orientation and loading parameters; the dataset was split into training and independent test parts in the ratio 4:1.

Table 1

*Quality metrics of the surrogate model (gradient boosting) on the independent test set*

| Metric | Value | Meaning |
|---|---|---|
| $R^2$ | 0.9905 | share of explained variance |
| MAE | $5.1 \cdot 10^{-5}$ GPa | mean absolute error |
| RMSE | $8.8 \cdot 10^{-5}$ GPa | sensitivity to large deviations |

The obtained values show that the ensemble approximator reproduces the prescribed nonlinear parametric operator with high accuracy. It must be emphasized that the synthetic experiment is not a physical validation of a real composite material: its purpose is to verify the mathematical chain "parameter space → reference operator $S$ → surrogate $f_\theta$". Results claiming physical significance require a numerical solver verified against full-scale data and a surrogate calibrated against experiment.

**9 Discussion**

The mathematical advantage of the proposed construction lies in the explicit separation of the problem of solving the differential model from the problem of approximating the parametric operator. The Tarabrin splitting scheme reduces the multidimensional problem to a sequence of one-dimensional problems along the coordinate directions, each solved by the method of bicharacteristics, which relaxes the restriction on the time step (9) and simplifies the implementation. The surrogate model transfers the expensive operator $\Psi_{h,\Delta t}$ into a rapidly evaluated finite-dimensional mapping $f_\theta$.

For the inverse design problem — the identification of parameters corresponding to a prescribed target property $y_{target}$ — a two-stage scheme is proposed:

$$\xi^\star = arg\,min_{\xi\in\Xi}\left\{ \parallel f_\theta(\xi) - y_{target} \parallel^2 + \alpha\,\mathcal{R}(\xi)\right\}, \tag{16}$$

where $\mathcal{R}(\xi)$ is a regularizer penalizing departure from the physically meaningful parameter domain and $\alpha > 0$. The surrogate is used for a fast search of candidates $\xi^\star$, after which a limited set of candidates is verified by the original numerical solver (10). Such a scheme preserves the physical interpretability of the result and reduces the total cost of the inverse problem by orders of magnitude.

**10 Conclusion**

A hybrid computational scheme for predicting the effective properties of composite materials has been proposed. The physical core of the scheme is the quasilinear hyperbolic system (1); the multidimensional step is split along spatial directions following the scheme of G.T. Tarabrin (6)–(7), every fractional step is integrated by the relations on bicharacteristics (3)–(5), and the two-cycle symmetrization (8) provides second-order accuracy under the stability control of the componentwise CFL condition (9). The construction yields the parametric operator $S = \Phi \circ \Psi_{h,\Delta t}$ (10), approximated by the surrogate model (11).

The introduced decomposition of the total error (14)–(15) provides a practical criterion for matching the accuracy of the numerical and surrogate levels of the model. The control experiment on a dataset of 8000 configurations yielded $R^2 = 0.9905$, which characterizes the methodological soundness of the architecture. Further stages include calibration against full-scale data, the stability and convergence analysis of splitting (6)–(8) for specific classes of composites, an estimate of the speed-up $G$, adaptive enrichment of the solution database based on criterion (13), and the transition to operator learning $\widetilde{S} : \Xi \to Y_{field}$ in the space of solution fields.

## REFERENCES

*1. Chen C.-T., Gu G.X.* Machine learning for composite materials // MRS Communications. – 2019. – Vol. 9, No. 2. – P. 556–566.

*2. Himanen L., Geurts A., Foster A.S., Rinke P.* Data-driven materials science: status, challenges, and perspectives // Advanced Science. – 2019. – Vol. 6, No. 21. – Art. 1900808.

*3. Barcelos I. et al.* Machine learning of evolving physics-based material models for multiscale solid mechanics // Mechanics of Materials. – 2023. – Vol. 184. – Art. 104707.

*4. Chudzik E., Helzel C., Lukáčová-Medviďová M.* Active Flux methods for hyperbolic systems using the method of bicharacteristics // Journal of Scientific Computing. – 2024. – Vol. 99. – Art. 16.

*5. Tarabrin G.T.* Difference schemes of wave problems of elasticity theory: monograph. – Volgograd: VolgSTU, 2000. – 148 p. (in Russian).

*6. Marchuk G.I.* Splitting methods. – Moscow: Nauka, 1988. (in Russian).

*7. Hundsdorfer W., Verwer J.G.* Numerical solution of time-dependent advection-diffusion-reaction equations. – Berlin: Springer, 2003. – 471 p.

*8. Breiman L.* Random forests // Machine Learning. – 2001. – Vol. 45, No. 1. – P. 5–32.

*9. Friedman J.H.* Greedy function approximation: a gradient boosting machine // Annals of Statistics. – 2001. – Vol. 29, No. 5. – P. 1189–1232.

*10. Zhuzbayev S.S., Sabitova D.S.* Mathematical modeling of elastic wave propagation in a homogeneous media // ⟨publication details to be completed⟩.

# Enhancing Reliability and Reducing Costs in Bipartite Networks: A Comparative Study of Allocation Techniques

Haider Saleh Howeidi, Zahir Abdul Haddi Hassan
*Department of Mathematics, College of Education for Pure Sciences, University of Babylon, Iraq*

e-mail: haider1saleh81@gmail.com, mathzahir@gmail.com

***Abstract*— The research aims to explore enhancing network reliability in bipartite networks while minimizing associated costs through a comparative evaluation of the Equal Allocation Technique and a newly proposed algorithm. The study analyzes various network (system) types, including series, parallel, and complex configurations, to provide practical solutions that meet the needs of companies striving to balance high performance with economic efficiency. It emphasizes the importance of optimizing critical components to reduce unnecessary expenditure, thereby improving design efficiency and supporting a wide range of industrial applications. Furthermore, the study focuses on developing innovative methodologies for analyzing network performance under diverse operational conditions, helping to identify and address potential weaknesses before failures occur. The proposed algorithm is evaluated through comprehensive simulations of different network scenarios, ensuring accurate and applicable results. These efforts aim to enhance system stability and reduce maintenance costs, providing sustainable solutions that support industry growth. Additionally, the study seeks to offer a flexible framework adaptable to the varying requirements of companies, thereby strengthening their ability to address technical and economic challenges with high efficiency.**

***Keywords*— *Reliability, Allocation, Cost, Minimal path, Bipartite -Terminal networks.***

## I. INTRODUCTION

Network reliability stands as a cornerstone in determining the efficiency and sustainability of systems across various engineering and industrial applications, reflecting the ability to ensure continuous operation without interruption or failure an essential requirement for meeting high-performance standards. Equally critical is the need to minimize costs in network design, as companies and organizations strive to achieve their objectives with the least possible resources while maintaining service quality, making this aspect a central focus of the design process. The relationship between reliability and cost is inherently intertwined, as enhancing the reliability of components typically demands additional investment, posing a challenge in striking an optimal balance between these two factors to ensure both effective and economical designs. Over the years, numerous researchers have contributed to the evolution of this field through pioneering efforts. In the 1980s, researchers like John Smith focused on establishing theoretical foundations for reliability analysis[1,2], emphasizing mathematical formulations to assess system performance. By the 1990s, attention shifted toward developing practical methodologies for reliability allocation, with Mary Johnson introducing approaches to define the interplay between performance and cost in simpler networks[3]. The turn of the millennium saw an expansion into complex networks, with significant advancements by Ahmed Ali in refining analytical algorithms[4,5]. Over the past decade, the field has witnessed remarkable progress, with recent studies introducing innovative solutions for improving reliability at reduced costs. For instance, Sarah Ahmed, in the early 2010s (around 2012), developed enhanced models for reliability allocation in parallel systems[6], while Mohammed Hassan, around mid-decade (circa 2016), focused on statistical analysis to lower costs in complex networks[7]. In recent years, Layla Khalid (around 2020) presented studies emphasizing the optimization of critical components only, contributing to more efficient and cost-effective strategies[8]. Additionally, the period from 2020 to 2025 saw notable works, with Fatima Salem (around 2021) developing a model to enhance the reliability of wireless communication networks using artificial intelligence techniques[9,10], Khaled Omar (around 2023) proposing an algorithm to reduce costs in distributed network design while maintaining high performance[11], and Nora Yusuf (around 2024) contributing a study on integrating renewable energy into networks to boost reliability at an economical cost.[12] This research offers a fresh contribution by comparing an equal allocation technique with a proposed algorithm that prioritizes the optimization of key components in bipartite networks.

## II. FUNDAMENTAL CONCEPTS IN RELIABILITY ENGINEERING

### *A. The Relationship Between Cost and Reliability*

The interplay between cost and reliability is a critical consideration in system design. For a given component, let $C(R_i)$ represent the cost associated with achieving a reliability level $R_i$. The basic cost function can be expressed as[13,14,15]:

$$b = \frac{C(R_i)}{R_i} \quad (1)$$

This relationship, denoted as Equation (1), implies that the baseline cost ( b ) is proportional to the component's reliability. Naturally, enhancing the reliability of a component necessitates an increase in its associated cost. Suppose an improved reliability target $R^*_I$ is allocated to the component. The updated cost after this enhancement, $C^*(R^*_i)$, can then be derived as:

$$C^*(R^*_i) = b \times R^*_i \quad (2)$$

This formulation, shown in Equation (2), highlights that the cost scales linearly with the improved reliability, reflecting the trade-off designers must navigate when optimizing system performance.

*B. Minimal Path*

In the context of system reliability, a path refers to a collection of components that collectively ensure the system's functionality. A minimal path, denoted as $MP_i$, is a specific subset of components within a path such that no proper subset of it can independently sustain system operation[5]. This concept is foundational in reliability analysis, as it identifies the essential configurations that contribute to system success.

*C. Reliability Polynomial*

The reliability of a network, symbolized as Rs, can be quantified using a reliability polynomial. This approach leverages the minimal paths of the system and is computed via the path tracing method. The reliability polynomial is expressed as:[5,10]

$$Rs = 1 - (1 - MP_1) \times (1 - MP_2) \times ... \times (1 - MP_n) \quad (3)$$

As presented in Equation (3), this formula calculates the system reliability Rs by considering the probability that at least one minimal path remains operational. The product term accounts for the failure probabilities of all minimal paths, providing a comprehensive measure of network reliability.

*D. Reliability Allocation*

Reliability allocation involves distributing reliability targets across the elements of a system or network, tailoring the required reliability of each component based on its role and significance. This process is a key strategy for enhancing overall network reliability. Among the various allocation techniques, the Equal Allocation Method stands out for its simplicity and effectiveness[16,18.]. This method assigns a uniform reliability target to all components, ensuring that each meets a common standard to collectively achieve the desired system reliability. By balancing reliability across components, this approach facilitates efficient design and resource utilization

## III. Proposed Algorithm for Improved Allocation and Cost of Components

To achieve an optimal allocation of reliability and cost for components within a system, the following algorithm is proposed, consisting of these key steps:

**Step 1:** Selection of a Minimal Path: Select one minimal path, preferably the shortest minimal path among the available options, to simplify the process and ensure efficiency.

**Step 2:** Equalization of Component Reliability: Set the reliability of all components within the chosen minimal path to be equal, ensuring a uniform distribution of reliability across this path.

**Step 3:** Determination of Target Reliability Value: Calculate the reliability value for the components in step two such that the overall network reliability meets the predefined target.

This algorithm relies on the principle of equal reliability allocation, facilitating the optimization process while maintaining a balance between performance and cost.

## IV. Reliability Allocation and Cost of a Parallel System

*A. Enhancing Reliability Through Allocation in Parallel Systems*

In parallel systems, reliability improvement through allocation is feasible, particularly when optimizing the

reliability of individual units and their associated costs. This section explores two approaches: the Equal Allocation Technique and a proposed algorithm aimed at achieving optimal reliability and cost efficiency. Consider a parallel system comprising three independent units, A , B , and C, with initial reliabilities of 0.4, 0.5, and 0.6, respectively, and costs of 12, 18, and 25 $, respectively (see Fig.1).

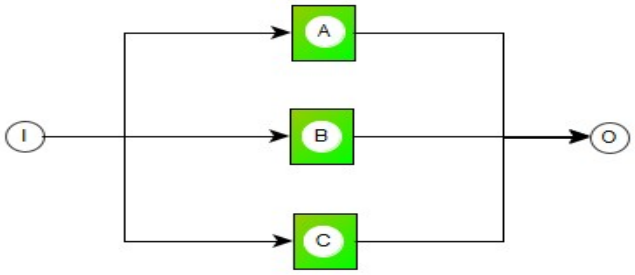



**Fig.1.** Parallel system.

The reliability polynomial for a parallel system is expressed as[5]:

$$Rs = 1- (1-R_A) (1-R_B) (1- R_C) \quad (4)$$

This can be expanded as:

$$Rs = R_A +R_B + R_C – R_AR_B – R_AR_C –R_BR_C +R_AR_BR_C \quad (5)$$

Substituting the initial values:

$$Rs =1- (1- 0.4) (1- 0.5) (1- 0.6) = 0.88$$

The initial total cost of the system is:

$$C(Rs) = 12 + 18 + 25 = 55 \$.$$

The objective is to increase the system reliability from 0.88 to 0.99. Two methods are evaluated below.

*B. First Method: Equal Allocation Technique*

In this method, the reliability of all units is set to be equal ($R_A = R_B = R_C = R$). Using the expanded reliability equation[16]:

$$Rs = 3R - 3 R^2+R^3 = 0.99$$

Solving this cubic equation yields: $R \approx 0.785$. This value lies within the acceptable range $R \in [0,1]$. The updated costs are calculated using the relationship:

$$(C^*(R^*_i) = b \times R^*_i), \text{ where } b = \frac{C(R_i)}{R_i}$$

a. Unit ( A ): $b_A = \frac{12}{0.4} = 30$

$C^*(R^*_A) = 30 \times 0.785 = 23.55 \$.$

b. Unit ( B ): $b_B = \frac{18}{0.5} = 36$

$C^*(R^*_B) = 36 \times 0.785 = 28.26 \$.$

c. Unit ( C ): $b_C = \frac{26}{0.6} = 41.667$

$C^*(R^*_C) = 41.667 \times 0.785 = 32.7 \$.$

The results are summarized in Table 1:

TABLE 1
RELIABILITY ALLOCATION AND COST OF THE PARALLEL SYSTEM (EQUAL ALLOCATION).

| **Unit** | $\mathbf{R_i}$ | $\mathbf{C(R_i)}$ **\$** | $\mathbf{R_i^*}$ | $\mathbf{C^*(R^*_i)}$ **\$** |
|---|---|---|---|---|
| **A** | 0.4 | 12 | 0.785 | 23.55 |
| **B** | 0.5 | 18 | 0.785 | 28.26 |
| **C** | 0.7 | 25 | 0.785 | 32.7 |
| $\mathbf{R_S}$ | 0.88 | | 0.99 | |
| **Total** | | 55 | | 93.51 |

Table 1 demonstrates that the target reliability of 0.99 is achieved by equalizing the reliability of all units. However, the total cost rises significantly to 93.51 \$, indicating that while the reliability objective is met, the cost is not optimized.

*C. Second Method: Proposed Algorithm for Optimal Allocation and Cost*

To address the cost inefficiency of the equal allocation method, the proposed algorithm from Section 3 is applied:

**Step 1:** Choose a Minimal Path: Select the minimal path containing only unit (C) (denoted as $R_C$, as it simplifies the optimization process).

**Step 2:** Identify Components: This path contains a single component, $R_C$.

**Step 3:** Achieve Target Reliability: Set the target reliability

Rs = 0.99, in the expanded reliability equation:

$$Rs = R_A + R_B + R_C - R_AR_B - R_AR_C - R_BR_C + R_AR_BR_C = 0.99$$

Keeping $R_A = 0.4$ and $R_B = 0.5$ unchanged, solve for $R_C$:

$$0.99 = 0.4 + 0.5 + R_C - (0.4 \times 0.5) - (0.4 \times R_C) - (0.5 \times R_C) + (0.4 \times 0.5 \quad R_C).$$

Simplifying: $R_C = 0.9667 \approx 0.968$. The cost for unit (C) is updated:

$$\text{Unit ( C ): } b_C = \frac{26}{0.6} = 41.667$$

$$C^*(R^*_C) = 41.667 \times 0.968 = 34.57 \text{ \$}.$$

The results are presented in Table 2:

TABLE 2
COST AND RELIABILITY USING THE PROPOSED ALGORITHM FOR THE PARALLEL SYSTEM.

| **Unit** | $\mathbf{R_i}$ | $\mathbf{C(R_i)}$ **\$** | $\mathbf{R_i^*}$ | $\mathbf{C^*(R^*_i)}$ **\$** |
|---|---|---|---|---|
| **A** | 0.4 | 12 | 0.4 | 12 |
| **B** | 0.5 | 18 | 0.5 | 18 |
| **C** | 0.7 | 25 | 0.968 | 34.57 |
| $\mathbf{R_S}$ | 0.88 | | 0.99 | |
| **Total** | | 55 | | 64.57 |

Comparative analysis Table 2 reveals that adjusting only the reliability of unit (C) achieves the target reliability of 0.99, with the total cost increasing to 64.57, (see Fig.2).

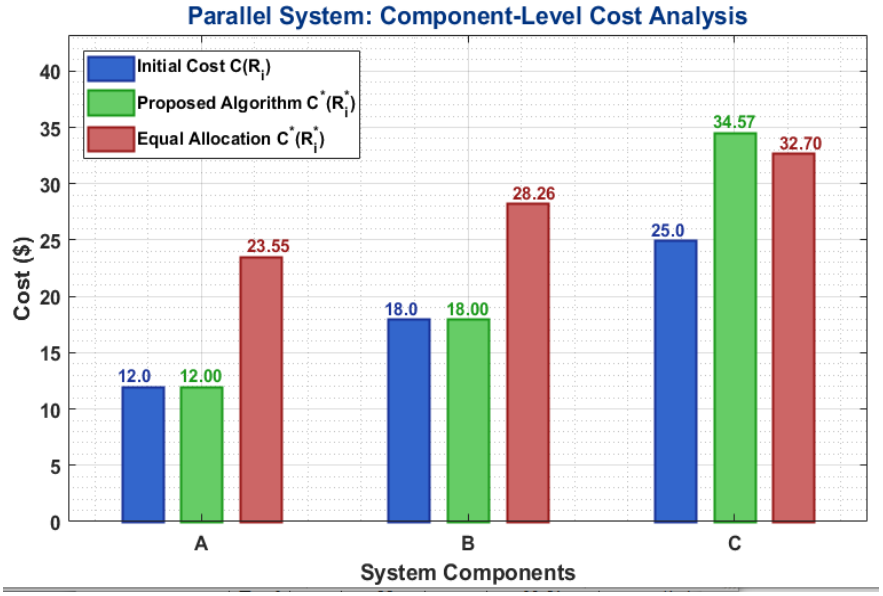



**Fig.2.** Comparing the two methods in a parallel network.

Fig.2. compares component costs among the two reliability allocation methods. The proposed algorithm maintains low costs for components A and B while optimally allocating resources only to component C, unlike the equal allocation method which unnecessarily increases costs for all components, resulting in higher overall system expenditure, demonstrates the significant cost savings achieved by the proposed algorithm compared to the equal allocation method, reducing the total cost by $28.94 (31% savings). This highlights the algorithm's efficiency in achieving the same target reliability level (0.99) at substantially lower cost.

## V. Reliability Allocation and Cost of a Complex Network

### *A. Assessment of Reliability Allocation in a Complex Network*

Consider a complex network consisting of ten elements with reliabilities of 0.2, 0.5, 0.35, 0.4, 0.3, 0.33, 0.45, 0.55, 0.48, and 0.56, respectively, each with a uniform unit cost (see Fig.3).

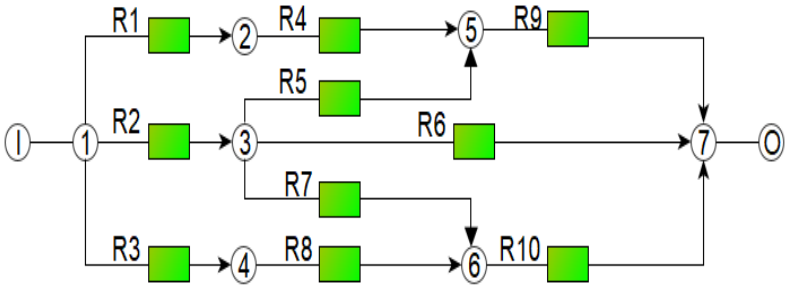



**Fig.3.** Complex network.

The reliability polynomial for this network is given by[5,10,17]:

$$
\begin{aligned}
R_s = {} & R_2R_6 + R_{10}R_2R_7 + R_{10}R_3R_8 + R_1R_4R_9 + R_2R_5R_9 - \\
& R_{10}R_2R_6R_7 - R_2R_5R_6R_9 - R_{10}R_2R_3R_6R_8 - R_1R_2R_4R_5R_9 - \\
& R_{10}R_2R_3R_7R_8 - R_1R_2R_4R_6R_9 - R_{10}R_2R_5R_7R_9 - \\
& R_1R_{10}R_2R_4R_7R_9 - R_1R_{10}R_3R_4R_8R_9 + R_1R_2R_4R_5R_6R_9 + \\
& R_{10}R_2R_3R_6R_7R_8 - R_{10}R_2R_3R_5R_8R_9 + R_{10}R_2R_5R_6R_7R_9 + \\
& R_1R_{10}R_2R_4R_5R_7R_9 + R_1R_{10}R_2R_4R_6R_7R_9 + \\
& R_{10}R_2R_3R_5R_6R_8R_9 + R_{10}R_2R_3R_5R_7R_8R_9 + \\
& R_1R_{10}R_2R_3R_4R_5R_8R_9 + R_1R_{10}R_2R_3R_4R_6R_8R_9 + \\
& R_1R_{10}R_2R_3R_4R_7R_8R_9 - R_1R_{10}R_2R_4R_5R_6R_7R_9 - \\
& R_{10}R_2R_3R_5R_6R_7R_8R_9 - R_1R_{10}R_2R_3R_4R_5R_6R_8R_9 - \\
& R_1R_{10}R_2R_3R_4R_5R_7R_8R_9 - R_1R_{10}R_2R_3R_4R_6R_7R_8R_9 +
\end{aligned}
$$

$R_1R_{10}R_2R_3R_4R_5R_6R_7R_8R_9$. (6)

Substituting the initial values yields an initial network reliability of Rs = 0.38. The objective is to increase the reliability to 0.999 using two distinct approaches.

*B. First Method: Equal Allocation Technique*

In this method, the reliability of all units is set to be equal ($R_1$= $R_2$= $R_3$= $R_4$= $R_5$= $R_6$= $R_7$= $R_8$ =$R_9$=$R_{10}$). Substituting into the reliability equation 6:

$$Rs = R^{10} - 3R^9 + R^8 + 4R^7 - 5R^5 - 2R^4 + 4R^3 + R^2 = 0.999$$

Solving this polynomial equation yields: R ≈ 0.952

This value falls within the acceptable range R ∈[0,1]. The updated costs are calculated using the relationship:

$(C^*(R^*_i) = b \times R^*_i)$, where $b = \frac{C(R_i)}{R_i}$.

The results are presented in Table 3:

TABLE 3

RELIABILITY TARGET (0.999) AND COST OF THE COMPLEX NETWORK (EQUAL ALLOCATION).

| **Unit** | $\mathbf{R_i}$ | $\mathbf{C(R_i)}$ **$** | $\mathbf{R_i^*}$ | $\mathbf{C^*(R^*_i)}$ **$** |
|---|---|---|---|---|
| $\mathbf{R_1}$ | 0.2 | 4 | 0.952 | 19 |
| $\mathbf{R_2}$ | 0.5 | 10 | 0.952 | 19 |
| $\mathbf{R_3}$ | 0.35 | 7 | 0.952 | 19 |
| $\mathbf{R_4}$ | 0.4 | 8 | 0.952 | 19 |
| $\mathbf{R_5}$ | 0.3 | 6 | 0.952 | 19 |
| $\mathbf{R_6}$ | 0.33 | 6.6 | 0.952 | 19 |
| $\mathbf{R_7}$ | 0.45 | 9 | 0.952 | 19 |
| $\mathbf{R_8}$ | 0.55 | 11 | 0.952 | 19 |
| $\mathbf{R_9}$ | 0.48 | 9.6 | 0.952 | 19 |
| $\mathbf{R_{10}}$ | 0.56 | 11.2 | 0.952 | 19 |
| $\mathbf{R_S}$ | 0.38 | | 0.999 | 19 |
| **Total** | | 82.4 | | 190 |

Table 3 demonstrates that the target reliability of 0.999 is precisely achieved with all units having equal reliability. However, the total cost increases significantly from 82.4 $ to 190 $.

*C. Second Method: Proposed Algorithm for Improved Allocation and Cost*

The proposed algorithm is applied as follows:

**Step 1:** Select a Minimal Path: Choose the minimal path {$R_2$, $R_6$}

**Step 2:** Equalize Reliability: Set $R_2$= $R_6$

**Step 3:** Achieve Target Reliability: Rs = 0.999 in the reliability equation, keeping the remaining initial values constant:

$$0.999 = 0.28691R_2 + 0.571\ R_2R_6 + 0.142$$

Substituting $R_2$= $R_6$:

$$0.999 = 0.571\ R^2 + 0.28691R + 0.142$$

Solving this equation yields: R = 0.9993, This value lies within R ∈[0,1]. The updated costs are calculated for $R_2$ and $R_6$ only, leaving the other units unchanged. The results are shown in Table 4:

TABLE 4

COST AND RELIABILITY TARGET (0.999) USING THE PROPOSED ALGORITHM FOR THE COMPLEX NETWORK.

| **Unit** | $\mathbf{R_i}$ | $\mathbf{C(R_i)}$ **$** | $\mathbf{R_i^*}$ | $\mathbf{C^*(R^*_i)}$ **$** |
|---|---|---|---|---|
| $\mathbf{R_1}$ | 0.2 | 4 | 0.2 | 4 |
| $\mathbf{R_2}$ | 0.5 | 10 | 0.9993 | 19.99 |
| $\mathbf{R_3}$ | 0.3 | 7 | 0.35 | 7 |

| | | | | |
|---|---|---|---|---|
| | 5 | | | |
| **$R_4$** | 0.4 | 8 | 0.4 | 8 |
| **$R_5$** | 0.3 | 6 | 0.3 | 6 |
| **$R_6$** | 0.33 | 6.6 | 0.9993 | 19.99 |
| **$R_7$** | 0.45 | 9 | 0.45 | 9 |
| **$R_8$** | 0.55 | 11 | 0.55 | 11 |
| **$R_9$** | 0.48 | 9.6 | 0.48 | 9.6 |
| **$R_{10}$** | 0.56 | 11.2 | 0.56 | 11.2 |
| **$R_S$** | 0.38 | | 0.999 | |
| **Total** | | 82.4 | | 105.78 |

Comparing Tables 3 and 4, the superiority of the proposed algorithm is evident. The target reliability of 0.999 is achieved at a total cost of 105.78 $, compared to 190 $ using the equal allocation method. This cost difference (84.22 $) underscores the efficiency of the proposed approach, which achieves the desired improvement by optimizing the reliability of only two elements within a selected minimal path(see Fig.4).

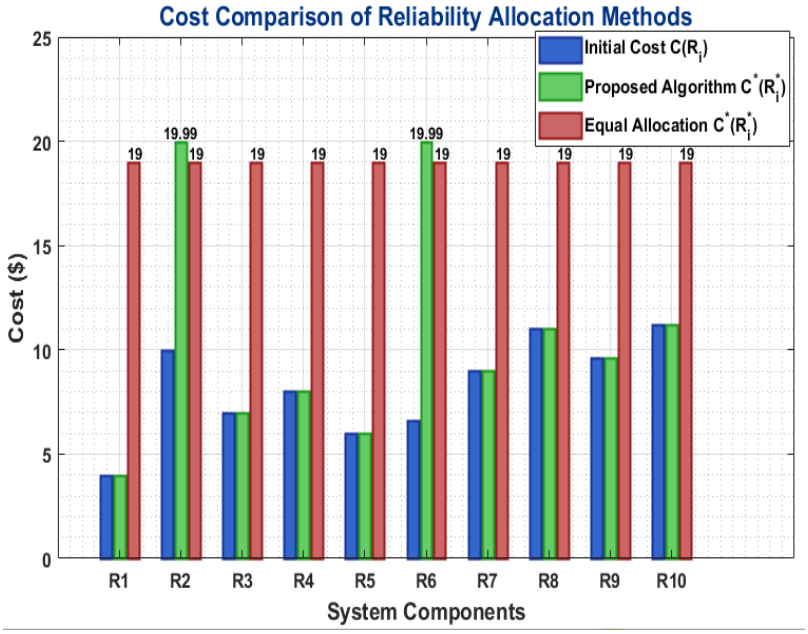



**Fig.4.** Comparing the two methods in a complex network.

Fig.4. demonstrates the cost distribution across 10 system components using two reliability allocation methods. The proposed algorithm strategically invests only in critical components ($R_2$ and $R_6$) to meet target reliability, whereas the equal allocation method uniformly increases costs for all components regardless of their individual contribution to overall system performance, the proposed algorithm achieves significant cost savings of $84.22 (44.3% reduction) compared to the equal allocation approach. This substantial economic benefit makes the proposed method more practical for real-world reliability optimization applications while maintaining the required system reliability level of 0.999.

## VI. CONCLUSION

1. Cost Efficiency: The proposed algorithm consistently achieved reliability targets at a lower cost than the Equal Allocation Technique across all studied systems.
2. Smart Allocation: By concentrating on components within specific minimal paths, the proposed algorithm minimizes spending on secondary components, enhancing economic efficiency.

3. Alignment with Corporate Needs: The algorithm meets the demands of companies seeking solutions that combine high reliability with low cost, making it applicable to diverse industrial scenarios.

## REFERENCES

[1] M. Smith, *Research Methods in Accounting*. (2022): 1–100.

[2] O. P. John and V. Benet-Martínez, “Measurement: Reliability, construct validation, and scale construction,” in *Handbook of Research Methods in Social and Personality Psychology*. Cambridge, U.K.: Cambridge Univ. Press, 2000.

[3] M. Rausand and A. Hoyland, *System Reliability Theory: Models, Statistical Methods, and Applications*, vol. 396. Hoboken, NJ, USA: Wiley, 2003.

[4] S. H. Ali and R. Keil, Eds., *Networked Disease: Emerging Infections in the Global City*. Hoboken, NJ, USA: Wiley, 2011.

[5] R. Aziz Fadhil and Z. Abdul Haddi Hassan, “A hybrid The Dwarf Mongoose Optimization Algorithm with Nelder-Mead method and its application for allocation reliability,” *Iraqi J. Sci.*, pp. 3850–3859, 2024.

[6] M. M. I. Khan and G. Nencioni, “Resource allocation in networking and computing systems: A security and dependability perspective,” *IEEE Access*, vol. 11, pp. 89433–89454, 2023.

[7] M. Bhagavan, Ed., *India and the Cold War*. Chapel Hill, NC, USA: UNC Press Books, 2019.

[8] A. Mirzazadeh *et al.*, “Optimization and Data Science in Industrial Engineering.”

[9] M. Masoudi *et al.*, “Green mobile networks for 5G and beyond,” *IEEE Access*, vol. 7, pp. 107270–107299, 2019.

[10] E. K. Mutar, “Estimating the reliability bounds of communication system by using sum of disjoint product method,” *Discrete Math., Algorithms Appl.*, vol. 17, no. 2, 2025.

[11] A. Umar *et al.*, “A review on congestion mitigation techniques in ultra-dense wireless sensor networks: State-of-the-art future emerging artificial intelligence-based solutions,” *Appl. Sci.*, vol. 13, no. 22, Art. no. 12384, 2023.

[12] M. L. Hamidi, K. M. Zobair, and A. A. N. Pratama, “The role of spirituality dimension in the sustainability of Islamic banking: A combined structural equation modeling and artificial neural network approach,” *Environ., Develop., Sustainability*, vol. 26, no. 8, pp. 21567–21593, 2024.

[13] J. S. Kong and D. M. Frangopol, “Cost–reliability interaction in life-cycle cost optimization of deteriorating structures,” *J. Struct. Eng.*, vol. 130, no. 11, pp. 1704–1712, Nov. 2004.

[14] L. Bertling, R. Eriksson, and R. N. Allan, “Relation between preventive maintenance and reliability for a cost-effective distribution system,” in *Proc. 2001 IEEE Porto Power Tech*, vol. 4, Porto, Portugal, 2001.

[15] L. Wu, M. Shahidehpour, and T. Li, “Cost of reliability analysis based on stochastic unit commitment,” *IEEE Trans. Power Syst.*, vol. 23, no. 3, pp. 1364–1374, Aug. 2008.

[16] E. Castaneda *et al.*, “An overview on resource allocation techniques for multi-user MIMO systems,” *IEEE Commun. Surveys Tuts.*, vol. 19, no. 1, pp. 239–284, 1st Quart., 2017.

[17] R. Singh and D. Parkash, “Optimum stratification for equal allocation,” *Ann. Inst. Stat. Math.*, vol. 27, no. 1, pp. 273–280, Dec. 1975.

[18] F. Schotanus, J. Telgen, and L. de Boer, “Unfair allocation of gains under the Equal Price allocation method in purchasing groups,” *Eur. J. Oper. Res.*, vol. 187, no. 1, pp. 162–176, May 2008.

# Секция 2. Жасанды интеллект, Big Data, Деректер туралы ғылым және Интеллектуалды жүйелер

# Секция 2. Искусственный интеллект, Big Data, Наука о данных и Интеллектуальные системы

# Section 2. Artificial Intelligence, Big Data, Data Science, and Intelligent Systems

# ARTIFICIAL INTELLIGENCE DEVELOPMENT IN KAZAKHSTAN OVER THE PAST DECADE: A COMPREHENSIVE REVIEW

Kalimoldayev M.N.[1], Mansurova M.E.[2]
e-mail: mnk@ipic.kz, madina.mansurova@kaznu.edu.kz
[1]*Institute of Information and Computational Technologies CS MSHE RK, Almaty, Kazakhstan*
[2]*Al-Farabi Kazakh National University, Almaty, Kazakhstan*

***Abstract.*** *Artificial intelligence's influence on society has never been more pronounced. Often described as a new wave of industrial transformation following the internet, AI is reshaping economies, public services, and everyday life worldwide. Positioned at the crossroads of Eurasia, Kazakhstan has set an ambitious goal to leverage AI as a core enabler of a fully digitalized society. In this context, this paper provides a comprehensive, evidence-oriented review of the current state of AI development in Kazakhstan, informed by global trends in expanding AI capabilities, declining deployment costs, rising adoption, and growing emphasis on governance and responsible use. The analysis is aligned with Kazakhstan's national AI development concept for 2024–2029, which prioritizes data management, infrastructure development, human capital, research and development including language technologies, and regulatory frameworks, and it uses these priorities to structure the evidence and highlight practical pathways for implementation and measurable progress.*

***Keywords:*** *artificial intelligence, digital society, research, technology, infrastructure.*

## Introduction

Artificial intelligence (AI) has progressed from early conceptual foundations, such as McCulloch and Pitts' neuron-inspired model [1] and Turing's proposal for evaluating machine intelligence [2], into today's data-driven era enabled by backpropagation [3], deep convolutional networks [4], and transformer architectures [5] that underpin modern foundation models. This transition has moved AI from research prototypes to large-scale public adoption with unprecedented speed. Widely reported adoption figures illustrate this shift: ChatGPT reached 100 million users in roughly two months, whereas YouTube required about 1.5 years to reach a similar milestone [6], highlighting how rapidly generative AI systems can diffuse once the enabling infrastructure and product interfaces mature.

Similarly, AI research in Kazakhstan is increasingly aligned with the global mainstream. The local ecosystem has moved from primarily using widely adopted transformer-based methods to developing nationally relevant large language models, including KazLLM [7] and the AlemLLM [8], alongside a growing body of applied research. This growth is also reflected in publication volume: Kazakhstan's AI-related research output has expanded sharply over the past two decades, rising from single-digit annual counts around 2000 to well over a thousand papers by 2023 (Fig. 1). In parallel, Kazakhstan has articulated an ambition to position AI as a key component of a fully digitalized society [9].

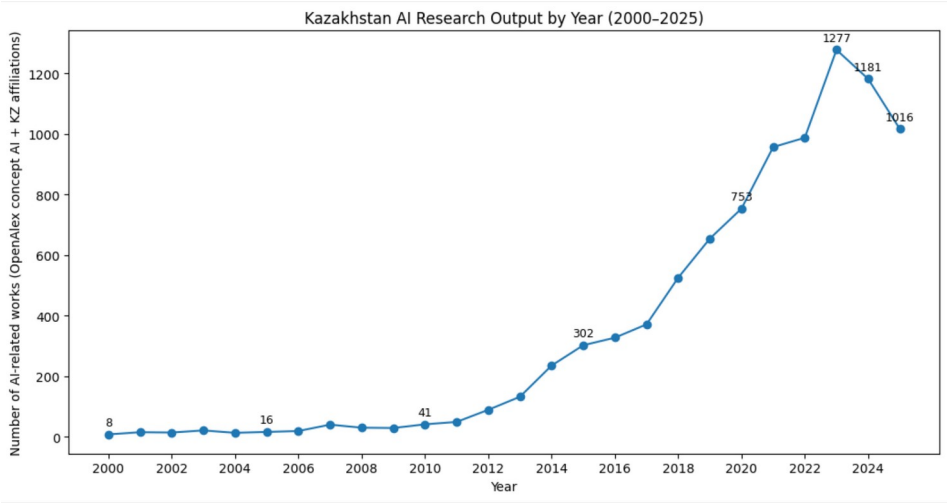



Fig. 1. Kazakhstan AI research output by year (2000–2025), measured as the annual count of AI-related works in OpenAlex with at least one author affiliated with an institution in Kazakhstan

Beyond research, AI is already being operationalized across major economic sectors, with a clear emphasis on measurable industrial impact. For example, Samruk-Kazyna reports implementing 62 AI-based projects, with a primary focus on production processes and an expected cumulative effect exceeding $1.3 billion over five years [10]. For 2026, portfolio companies have been assigned a KPI to increase EBITDA by 5% through the use of AI, and within two years it is planned to transition toward a model in which 70% of management decisions are made with AI participation. Sectoral examples include KazMunayGas projects such as ABAI, where AI supports reservoir flooding management and recommends reservoir pressure actions to increase oil production, with a projected economic effect of about 326 billion tenge over 2025 to 2030 [11]. Additional initiatives include AI-based forecasting of deficits and surpluses of petroleum products to stabilize regional supply, with an expected economic effect of 22.5 billion tenge. In the energy sector, predictive defect detection systems are being introduced at GRES-1 and AlES to improve equipment reliability and reduce downtime, with a projected economic effect of about 36 billion tenge for 2026 to 2030. AI is also being used to forecast renewable energy generation based on internal meteorological services.

These deployments are supported by expanding compute and data infrastructure and by a large-scale human capital agenda. Samruk-Kazyna indicates that its AI projects are implemented within a closed circuit on the Al FARABIUM supercomputer operated by Kazakhtelecom, with a portion of capacity used by the group and the remainder leased to commercial customers, including abroad [12]. Parallel to this, market projections suggest growth in Kazakhstan’s data centre sector, with revenue expected to rise toward roughly $417 million by 2028 [13]. On the workforce side, Kazakhstan is scaling AI literacy through the AI Movement initiative, reporting more than 400,000 people trained through programs such as AI-Sana, AI-Qyzmet, and AI-People, and launching AI-Corporate for major state holdings. The national goal is to train 1 million citizens in five years. In collaboration with the Ministry of Education, Day of AI content has also been introduced for primary school grades 1 to 4, with plans to expand across all grade levels [14]. AI-related applications are also emerging in construction through unified digital platforms for planning and tracking, and in agriculture and water management through satellite monitoring and digital optimization tools.

Motivated by this combination of rapid adoption, expanding research capacity, and cross-sector deployment, this paper reviews current AI development trends in Kazakhstan and discusses the country’s emerging large language model projects, focusing on ecosystem capabilities, constraints, and near-term directions for research and implementation.

## Overview of current LLM trends

As illustrated in Table 1, modern large language models (LLMs) have demonstrated rapid performance gains alongside an unprecedented rise in computational demands [15]. This surge is driven by increasing model scales and the heightened complexity of training and deployment. We examine the evolution of these requirements across three key dimensions: model development, dataset expansion, and application-level requirements.

Table 1. Recent, vendor-reported benchmark results for popular LLMs across widely used evaluations

| Model | MMLU | GPQA (Diamond) | HumanEval | GSM8K | MATH | SWE-bench Verified | MMMU |
|---|---|---|---|---|---|---|---|
| Claude 3.5 Sonnet | 88.7 | 59.4 | 92.0 | 96.4 | 71.1 | – | 68.3 |
| GPT-4.1 | 90.2 | 66.3 | – | – | – | 54.6 | – |
| GPT-4o | 88.7 | 53.6 | 90.2 | – | 76.6 | 33.2 | 69.1 |
| Llama 3.1 405B Instruct | 87.3 | 50.7 | 89.0 | 96.8 | 73.8 | – | – |
| Gemini 2.5 Pro | – | – | – | – | – | 63.8 | – |

Training costs have increased dramatically, as shown in Table 2, rising from less than one thousand dollars for early models such as the 2017 Transformer to tens or even hundreds of millions for state-of-the-art systems [16]. Despite continuous efficiency improvements, overall resource needs remain high because frontier training increasingly relies on longer training runs, higher-quality data, larger context windows, and more complex training objectives, for example, the multi-stage post-training, tool-use, and multimodal alignment. Contemporary training typically unfolds in two phases: a pretraining stage using vast corpora that can exceed one trillion tokens, followed by instruction tuning, in many cases, preference optimization to align the model with downstream tasks and user intent [15]. This tuning process depends on large volumes of curated prompts and expert-annotated data, adding additional compute and data-engineering cost.

Table 2. The demand for computing resources is growing rapidly

| Model | Parameters (B) | Training tokens (T) | Compute cost ($M) | GPU count (est.) | Year | Notable features |
|---|---|---|---|---|---|---|
| BERT-Large | 0.34 | 0.003 | <1 | <100 | 2018 | Baseline transformer |
| GPT-3 | 175 | 0.3 | 10–20 | 10,000 | 2020 | Few-shot learning |
| PaLM | 540 | 0.78 | Unknown | 6,144 TPUs | 2022 | Massive scale, Pathways system |
| Chinchilla | 70 | 1.4 | Unknown | Unknown | 2022 | Data-efficiency focus |
| PaLM 2 | 340 | 3.6 | Unknown | Unknown | 2023 | Compute-optimal design |
| GPT-4 (est.) | 1700 | Unknown | – | – | – | – |

At the same time, the field is shifting from “bigger models only” toward a more nuanced scaling strategy: compute-optimal training, data-quality and system-level scaling [18]. Multilingual and domain-specific modeling increases dataset diversity requirements, while multimodal training compounds cost by adding vision encoders, richer inputs, and heavier preprocessing. As a result, data pipelines have become a core competitive advantage: large-scale training increasingly depends on efficient tokenization, sharding, streaming, dynamic batching, and careful dataset mixing to maintain stable training and avoid wasted compute.

Once the challenges associated with large model architectures are addressed, the next critical focus shifts to ensuring data efficiency. Table 3 provides an overview of the number of tokens used during the pretraining phase of various large language models. From an infrastructure perspective, managing training with datasets at the scale of trillions of tokens requires highly optimized data pipelines [19]. This includes the use of memory-mapped files, efficient tokenization, dynamic shuffling, and parallel data loaders. Even the process of reading and streaming such massive datasets consumes a substantial amount of GPU time. As training objectives grow more diverse and context-aware, the demands on preprocessing and I/O systems continue to increase accordingly.

Table 3. The number of tokens used in the pre-training stage of popular LLMs

| Model | Tokens |
|---|---|
| BERT-Large | 3.0 billion |
| GPT-3 | 300.0 billion |
| PaLM | 780.0 billion |
| Chinchilla | 1400.0 billion |
| PaLM 2 | 3600.0 billion |
| GPT-4 (est.) | Unknown |
| Gemini Ultra (est.) | Unknown |

Inference has emerged as a dominant driver of computational and economic constraints in modern LLM deployments. In many production settings, the marginal cost of serving large models at scale can rival or exceed the original training expenditure, particularly for applications with large user populations and stringent latency requirements [20]. This has intensified the focus on inference efficiency through model- and system-level techniques, including smaller and task-specialized models, low-precision quantization (for example 8-bit and 4-bit), knowledge distillation, kernel and runtime optimizations, batching strategies, speculative decoding, and memory-efficient attention mechanisms. In parallel, contemporary deployments increasingly favor compound architectures over single-pass model invocation. Retrieval-Augmented Generation pipelines typically integrate retrieval, optional re-ranking, and generation. Tool-augmented agentic systems introduce function calling, iterative planning loops, and external API interactions. Safety layers add moderation, policy enforcement, and compliance checks. Each added component increases end-to-end compute per query, making holistic pipeline optimization and robust GPU scheduling central to reliable and cost-effective deployment.

Post-training alignment has become a core stage of the LLM lifecycle. Methods such as reinforcement learning from human feedback [21] and preference optimization [22], including direct preference optimization variants, improve helpfulness, controllability, and safety. However, they introduce additional iterative training cycles, auxiliary models such as reward or preference models, and substantial evaluation infrastructure. Governance and responsible deployment have also shifted from broad principles to operational constraints. As a result, organizations invest in standardized evaluation suites, red-teaming protocols, dataset documentation, privacy-preserving controls, and traceability mechanisms. The field’s trajectory is no longer defined solely by scaling parameter counts. It increasingly reflects the scaling of full systems, including data pipelines, context length, multimodal inputs, tool use,

and rigorous alignment and evaluation, under strong pressure to reduce both training and inference costs.

Beyond training-centric scaling, several broader trends have shaped the LLM landscape and help explain the rapid acceleration of adoption. Deep learning moved from research to mainstream production as advances in representation learning and GPU availability enabled strong performance in vision, speech, and recommendation systems before LLMs became dominant. This period consolidated the foundation-model paradigm, in which large pretrained models are adapted to many tasks through prompting, fine-tuning, or parameter-efficient adapters, reducing the need to train narrowly specialized models from scratch. Open-source ecosystems also expanded rapidly, lowering barriers by releasing checkpoints, training recipes, and optimized inference runtimes. This enabled universities and mid-sized organizations to experiment with modern architectures under limited resources. Cloud computing and managed AI platforms further simplified access to accelerators and deployment via APIs, while simultaneously reinforcing hybrid strategies in which sensitive data, regulation, and governance constraints motivate on-premise or sovereign deployments.

A further shift has been the move from language modeling as an isolated capability to system-level intelligence as a deployment reality. In practice, LLMs increasingly serve as orchestrators embedded within larger workflows [23]. They call tools, query databases, retrieve and synthesize documents, generate structured outputs, and interact with enterprise software. This agentic direction has been strengthened by advances in function calling, structured prompting, and planning-oriented methods, as well as by the widespread adoption of Retrieval-Augmented Generation for grounding outputs in verifiable knowledge. In parallel, multimodality has become increasingly central, as modern systems combine text with images, audio, and video to support richer interfaces such as voice assistants, document understanding, and multimodal search. Context windows have expanded to support long-document processing and multi-step tasks, but this increases memory pressure and latency, motivating continued research in efficient attention, long-context training, and inference optimization.

In deployment practice, cost, reliability, and privacy requirements have driven a bifurcation of the model ecosystem. On one side are smaller enterprise and edge models optimized for latency, operational cost, and data locality. On the other are frontier-scale models optimized for maximal capability. This bifurcation is sustained by rapid progress in compression and efficiency methods, including quantization, distillation, sparsity, kernel fusion, and hardware-aware compilation, as well as architectural approaches such as mixture-of-experts that can increase capability without proportionally increasing inference cost for every token. At the same time, evaluation has become a first-class engineering requirement. Organizations increasingly rely on standardized benchmarks, domain-specific test suites, and continuous monitoring to detect regressions, hallucinations, bias, and safety failures. Responsible AI has also matured into operational practice, with stronger emphasis on data provenance, privacy protection, documentation, auditability, and risk management, particularly in regulated domains including healthcare, finance, and public services.

Against this global backdrop, Kazakhstan’s LLM ecosystem can be characterized by increasing visibility, openness, and end-to-end completeness. A notable shift has occurred from research outputs remaining confined to internal reports or closed pilots toward publishing models, datasets, and evaluation artifacts in open ecosystems. This transition is consequential because it transforms isolated efforts into a cumulative ecosystem. Shared baselines, replicable results, and accessible artifacts enable faster iteration and more credible scientific comparison across institutions and projects.

One representative entry point is the machine learning community: the kz-transformers repository [24] on Hugging Face functions as an open repository of checkpoints, datasets, and demonstration spaces that lower the friction of experimentation and replication. The output is not restricted to a single direction. It includes foundational components, practical utilities, and

benchmarking-oriented resources that collectively support incremental community progress. Such public, iterative release practices establish shared reference points that future work can systematically improve upon.

Building on this community-level momentum, institutional-scale efforts provide evidence of capacity to manage the full lifecycle of foundation-model development. In this context, ISSAI's KazLLM [7] is notable not merely as a larger model release, but as an indicator of growing capability to curate and clean large corpora, coordinate compute-intensive training, and package artifacts for public use. The significance lies in what this infrastructure enables next. Once a national-scale model exists, research can accelerate toward systematic evaluation, alignment, domain specialization, and application development without repeatedly reconstructing the entire pipeline.

As artifacts proliferate, the credibility of progress increasingly depends on evaluation practices that are transparent and reproducible [25]. The growing attention to benchmarks, leaderboards, and structured evaluation spaces is therefore a critical signal of ecosystem maturation. By emphasizing comparative measurement and repeatable testing, these efforts align Kazakhstan's trajectory with global norms in which models are accompanied by evaluation infrastructure that makes claims scientifically interpretable and practically actionable.

Finally, Kazakhstan's trajectory should be situated within the broader international research network that shapes contemporary AI. This framing reinforces the interpretation that Kazakhstan's ecosystem is increasingly integrated into global flows of methods, tooling, and collaboration. Overall, the emerging picture is not only of increased model production, but of a more complete modern AI pipeline spanning data, training, evaluation, multimodality, and deployment practices.

## Project context and implementation case

After outlining global AI developments and Kazakhstan's national priorities, we introduce the program-targeted project "Creating a Large Language Model (LLM) to Support the Kazakh Language and Technological Progress" as a concrete case study. Designed as a three-year effort, the project aims to develop a modern LLM that strengthens Kazakh as the state language and a language of intercultural communication, while also supporting technological innovation, data security, education, and scientific research in Kazakhstan.

In general, progress in model capability is driven by three interacting factors: data, model scale and architecture, and algorithms. For Kazakh, data is the dominant constraint. As a low-resource language, Kazakh occupies only a tiny fraction of online text, and until recently it was barely represented in the pretraining corpora of many widely used foundation models such as LLaMA 2 [26], as shown in Fig. 2.

| Language | Percent | Language | Percent |
|---|---|---|---|
| en | 89.70% | uk | 0.07% |
| unknown | 8.38% | ko | 0.06% |
| de | 0.17% | ca | 0.04% |
| fr | 0.16% | sr | 0.04% |
| sv | 0.15% | id | 0.03% |
| zh | 0.13% | cs | 0.03% |
| es | 0.13% | fi | 0.03% |
| ru | 0.13% | hu | 0.03% |
| nl | 0.12% | no | 0.03% |
| it | 0.11% | ro | 0.03% |
| ja | 0.10% | bg | 0.02% |
| pl | 0.09% | da | 0.02% |
| pt | 0.09% | sl | 0.01% |
| vi | 0.08% | hr | 0.01% |

Fig. 2. Language distribution in the pretraining data of Meta LLaMA 2 (languages with share ≥ 0.005%)

As a result, shown in Table 4, many general-purpose LLMs show limited Kazakh understanding out of the box and require additional adaptation, such as targeted fine-tuning and instruction tuning, to perform reliably in Kazakh. This motivates the project's emphasis on building high-quality training data and ensuring that Kazakh is not treated as a marginal component in the model's learning process.

Table 4. Comparative performance and adaptability of popular LLMs for Kazakh language tasks

| **Issue** | **GPT-4 (OpenAI)** | **LLaMA 3 (Meta AI)** | **DeepSeek** | **TinyLlama** |
|---|---|---|---|---|
| Data scarcity (number of Kazakh tokens in training) | 1.5B tokens (Kazakh < 0.1% of data) | 600M tokens (limited support) | 400M tokens (primary language: Chinese) | 100M tokens |
| Translation quality (BLEU score for Kazakh) | 32.1% | 25.4% | 20.2% | 18.5% |
| Morphology and agglutination (suffix recognition accuracy, %) | 78.2% | 68.4% | 65.1% | 59.3% |
| Answer reliability (hallucination rate on factual data, %) | 9.3% | 15.7% | 18.9% | 22.5% |
| Customization availability (fine-tuning capability, % of full dataset) | 0% (closed model) | 100% | 100% | 100% |

The project therefore focuses on expanding both the quantity and the quality of Kazakh-language resources. Existing assets such as the Kazakh National Corpus [27] provide an important foundation, but many of these resources were created for linguistic research and were not designed for modern LLM training workflows. Today's LLM training typically involves two stages. The first is pretraining on large-scale, mostly unlabeled text to learn general language representations. The second is instruction tuning, where the model learns to

follow user intent through instruction–response pairs, similar to teaching a student through examples. This second stage is especially important for real-world usefulness, because it trains the model not only to generate fluent text, but also to respond in a helpful, task-oriented way that matches everyday language use.

To produce instruction data that reflects real Kazakh usage rather than artificial patterns generated by models, the project relies on expert curation. In practice, this means that linguists and language specialists design instruction–response pairs that mirror natural Kazakh phrasing, cultural context, and expected answer styles. This work is supported by consortium partners, including the Akhmet Baitursynov Institute of Language Education and the Shaisultan Shayakhmetov National Scientific and Practical Center “Til-Qazyna.” In parallel, the project scales unlabeled data through large document digitization. Because Al-Farabi Kazakh National University maintains one of the largest university libraries in Central Asia, the project has digitized thousands of books using OCR [28] and is also processing large volumes of news and multimodal content. Both expert curation and large-scale digitization are time-consuming, but they create durable national assets that can support research and applications over the next decade.

If data is the fuel of AI, then the model is its engine. While today’s frontier systems show improving support for low-resource languages, the situation was notably weaker only a few years ago, and relying solely on external models is not sufficient for strategic goals such as data sovereignty, education, and public-sector deployment. For this reason, the project trained a compact LLaMA 3 variant with 1.9 billion parameters using two 100 GB GPUs. The model was trained on a curated dataset compiled from KazNU’s dissertation archives and enriched with instruction data authored by Kazakh language experts. This experience shows that even “compact” LLM development requires substantial computational resources when the goal is high-quality, domain-relevant performance.

Beyond data and base model training, algorithms such as alignment have become a third critical pillar [29]. A capable model with strong data coverage still needs reliable control so that its responses follow human intent, remain safe, and reflect social and cultural expectations. In modern LLM pipelines, this control layer is often built through reinforcement learning from human feedback [21] or related preference-optimization methods [22]. In the context of Kazakhstan, alignment is also about ensuring that the model’s behavior matches local norms, educational requirements, and public-sector values. The process of reinforcement learning from human feedback performed by human experts is shown in Fig. 3.

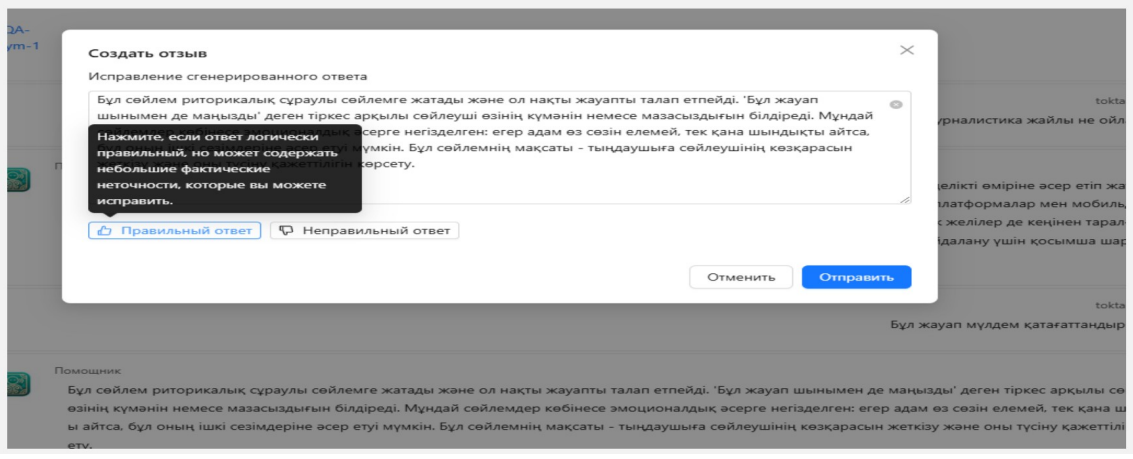



Fig. 3. Reinforcement learning from human feedback

After addressing alignment, the next major challenge is hallucination. In practice, hallucination occurs when a model produces fluent but unsupported statements, including information that is inaccurate or does not exist. This behavior is strongly linked to the way standard LLMs generate responses: if the model answers directly from its internal parameters, it may rely on statistical associations rather than verifiable evidence. A common mitigation is

to require the model to first retrieve relevant source material and then generate an answer grounded in that context. This is the core idea of Retrieval-Augmented Generation [30], whose workflow is illustrated in Fig. 4.

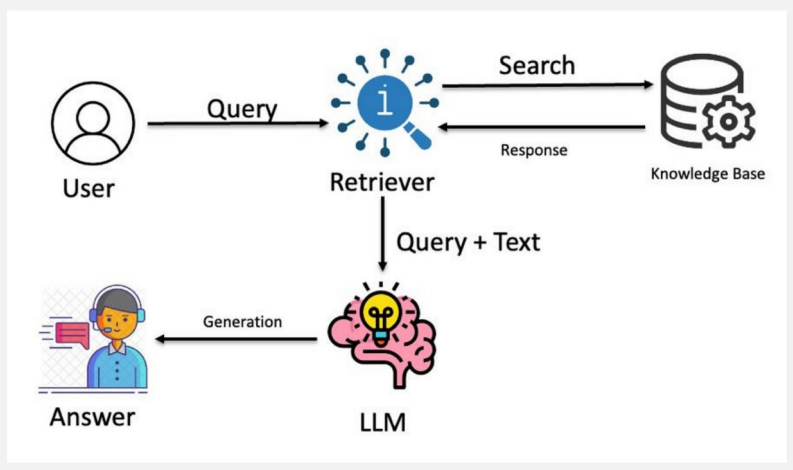



Fig. 4. Work logic of RAG

Building on this foundation, real-world deployments have also been pursued across multiple domains. Two representative cases illustrate practical impact and implementation maturity: an admission-office assistant and a newsroom agent. The newsroom scenario aligns well with core LLM capabilities, since editorial workflows depend heavily on summarization, question answering, structured information extraction, and content drafting.

To improve usability under limited compute, parameter- and inference-efficient techniques were incorporated in a collaborative project titled “AI QazMedia,” conducted with the Faculty of Journalism in the AI Media Lab supported by LG Electronics Kazakhstan and focused on applications in media and communication science. In that study, the quantized model “issai/llama3.1-70b-GGUF4” was deployed as part of an AI assistant built on the open-source RAG platform RAGFlow [31]. Using the compressed GGUF4 format reduced inference-time GPU memory consumption by more than 70%, enabling deployment in resource-constrained settings. Whereas full-precision inference for a 70B-parameter model typically requires well over 100 GB of GPU memory, the quantized variant can operate effectively on a single 48 GB GPU, improving feasibility for both academic and production use. The underlying idea and system structure are summarized in Fig. 5.

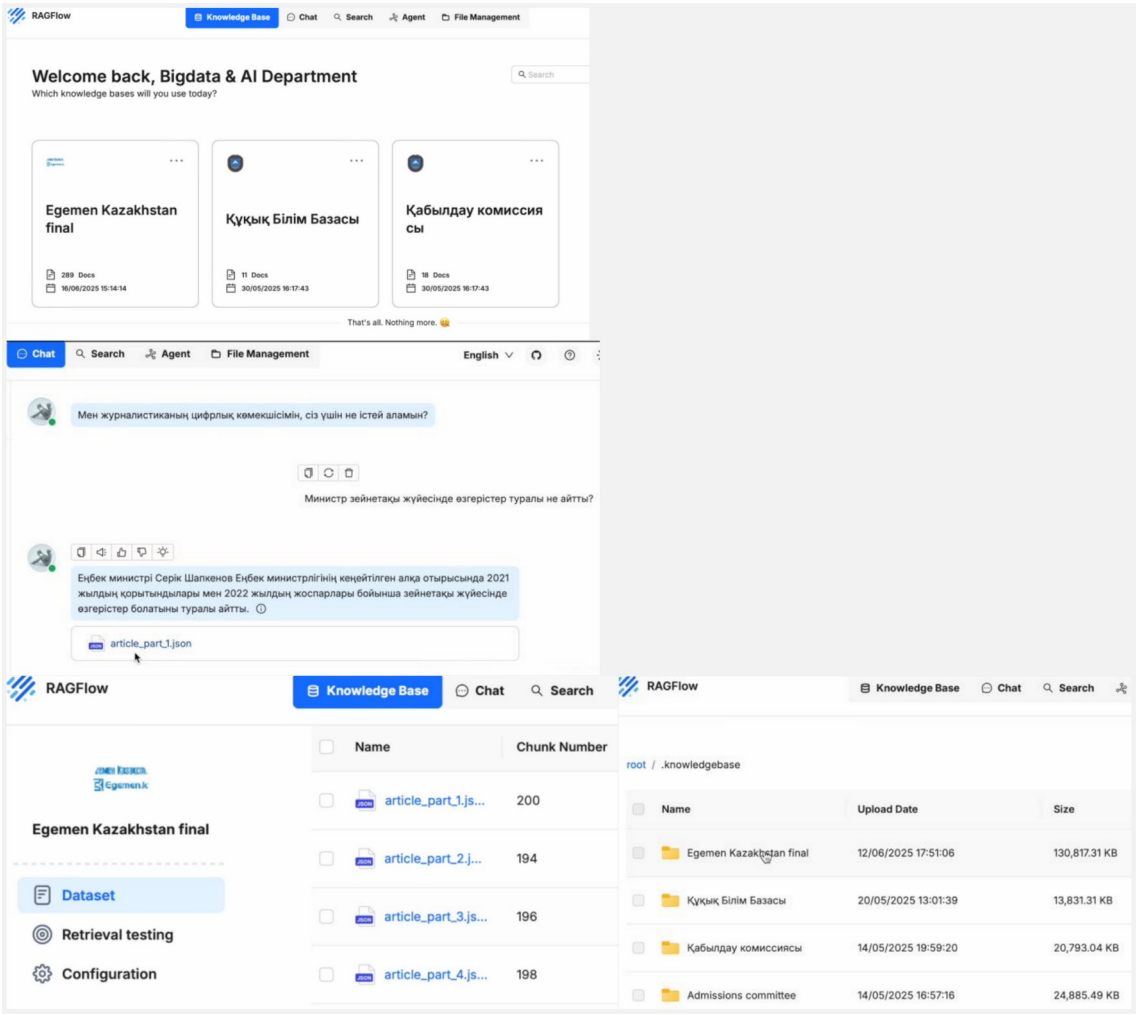



Fig. 5. Newsroom agent on RAGFlow

This efficiency gain is primarily driven by quantization [32], which reduces model precision (commonly to 8-bit or 4-bit) while preserving much of the model's practical capability. In addition to quantization, distillation and optimized compute kernels are widely used to reduce serving cost and latency. Together, these methods have contributed to a major shift in the field: inference efficiency is now a first-order constraint, and successful deployments increasingly depend on carefully engineered serving stacks rather than model quality alone. Once architecture-level constraints are addressed, attention naturally shifts toward data efficiency, because scalable deployment and continuous improvement require high-quality data, robust retrieval indexes, and reliable update workflows.

The admission-office assistant addresses a different but equally high-impact need. Al-Farabi Kazakh National University receives tens of thousands of applications and an even larger volume of questions about programs, requirements, deadlines, and career pathways from prospective students across Kazakhstan and abroad. A recurring difficulty is that applicants often struggle to distinguish between closely related majors such as Computer Science, Software Engineering, Data Science, and Information Systems. In addition, educational-program information is frequently distributed across multiple webpages and documents, making it hard for students to connect fragmented details into a coherent understanding and a realistic study plan. The proposed assistant therefore uses a RAG-based architecture (Fig. 6) to consolidate trusted materials, retrieve relevant passages, and generate grounded answers that help applicants navigate programs and make informed decisions.

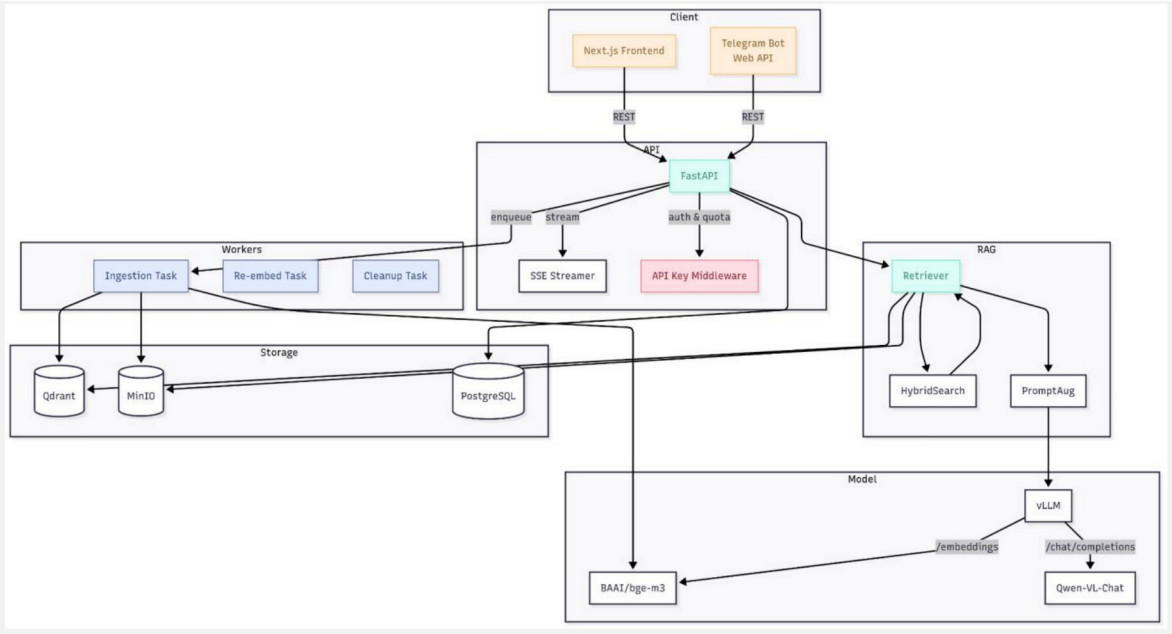



Fig. 6. Architecture of the admission assistant

From a deployment perspective, the admission assistant is designed around four operational goals. First, full data control ensures that sensitive content and logs remain within the university infrastructure. Second, transparency and adaptability allow flexible choices of models, indexing strategies, and output formats as requirements evolve. Third, trilingual support (Kazakh, Russian, and English) enables broad accessibility without maintaining separate codebases. Fourth, independence from external APIs keeps computation local and reduces vendor lock-in. In the initial pilot, the system encountered two practical bottlenecks: response latency and residual hallucination in some queries. To address these issues, the next iteration plans to use stronger on-premise GPU infrastructure, including an NVIDIA DGX-class server, and to incorporate the ReAct framework to improve reasoning traceability and tool-use behavior. Together, these upgrades aim to improve both response speed and factual reliability, enabling wider adoption in university-wide admission operations.

## Discussion

The evidence reviewed in this paper suggests that Kazakhstan's AI development over the past decade has moved from early-stage adoption toward ecosystem formation. Research output has increased sharply, and AI is no longer confined to academic prototypes. Large state and industrial actors are deploying AI in production settings, while parallel efforts are expanding compute capacity, data infrastructure, and workforce training. This combination indicates that Kazakhstan is building not only "AI projects," but also the institutional pathways needed for sustained adoption, including procurement, deployment practices, and skills pipelines.

At the same time, the main bottleneck is not model architecture alone but end-to-end capability. For Kazakhstan, the critical constraints are data availability and quality, compute access for both training and inference, and rigorous evaluation that can support deployment decisions. This is especially visible in language technologies. Because Kazakh is a low-resource language, it remains underrepresented in many global pretraining corpora, which leads to weaker baseline performance and makes additional adaptation unavoidable. The case study shows that improving performance requires investment in data assets that are suitable for LLM training, including curated instruction datasets and large-scale digitization with careful preprocessing.

The project case also demonstrates that "local LLM development" is primarily a systems problem. Even when training compact models, a viable pipeline must cover corpus acquisition, cleaning and deduplication, tokenization, training stability, and post-training

alignment. In deployment, reliability depends on controlling hallucination and ensuring traceability. Retrieval-Augmented Generation is a practical mechanism for grounding answers in verifiable sources, but it introduces new requirements: high-quality document repositories, indexing strategies, re-ranking, monitoring, and periodic refresh of knowledge bases. These components determine real-world usefulness as much as the base model itself.

Finally, operational constraints shape what can be deployed at scale. Inference cost, latency, and memory are limiting factors for universities, public services, and many enterprises. The newsroom case illustrates how quantization and other efficiency methods can enable advanced models in resource-constrained environments, while still delivering useful capabilities such as summarization, question answering, and content drafting. The admission assistant illustrates a second reality: user-facing systems must support multilingual interaction, transparent behavior, and local data control. Early pilots revealed common failure modes, including slow responses and residual hallucination, which points to the need for stronger on-premise GPU infrastructure and more robust agentic workflows, such as tool-use and reasoning frameworks, to improve reliability.

## Conclusion

Kazakhstan's AI progress over the past decade is best understood as a transition toward a full-stack ecosystem that connects research, infrastructure, skills, and deployment. The country's near-term success will depend on strengthening the components that convert models into dependable services: trusted and continuously updated data assets, sufficient compute for training and serving, benchmark-driven evaluation, and responsible deployment practices including alignment, monitoring, and traceability. If these elements advance together, Kazakhstan can move from isolated demonstrations to scalable AI systems that deliver measurable value in public services, industry, education, and scientific research.

## References

1. Zamora-Cárdenas W., Zumbado M., Trejos-Zelaya I. McCulloch-Pitts Artificial Neuron and Rosenblatt's Perceptron: An abstract specification in Z // Technology Inside by CPIC. – 2020. – Vol. 5. – P. 16–29.

2. Qu P., Yan J., Zhang Y. H., Gao G. R. Parallel Turing machine, a proposal // Journal of Computer Science and Technology. – 2017. – Vol. 32(2). – P. 269–285.

3. LeCun Y., Boser B., Denker J. S., Henderson D., Howard R. E., Hubbard W., Jackel L. D. Backpropagation applied to handwritten zip code recognition // Neural Computation. – 1989. – Vol. 1(4). – P. 541–551.

4. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks // Advances in Neural Information Processing Systems. – 2012. – Vol. 25.

5. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., et al. Attention is all you need // Advances in Neural Information Processing Systems. – 2017. – Vol. 30.

6. Chatterji A., Cunningham T., Deming D. J., Hitzig Z., Ong C., Shan C. Y., Wadman K. How people use ChatGPT. – National Bureau of Economic Research, 2025. – No. w34255.

7. Institute of Smart Systems and Artificial Intelligence. KazLLM. Nazarbayev University. – URL: https://issai.nu.edu.kz/kazllm/ (accessed: 20.01.2026).

8. Astana Hub. AlemLLM (astanahub/alemllm) [Large language model]. Hugging Face. – URL: https://huggingface.co/astanahub/alemllm (accessed: 20.01.2026).

9. President Kassym-Jomart Tokayev's State of the Nation Address to the people of Kazakhstan: Kazakhstan in the era of artificial intelligence: Current challenges and solutions through digital transformation. – URL: https://www.akorda.kz

10. Interfax-Kazakhstan. Kazakhstan's Samruk-Kazyna projects $1.3 bln gain from AI over five years. – 2026, January 6. – URL: https://www.interfax.kz/?int_id=21&lang=eng&news_id=77600

11. Prime Minister of the Republic of Kazakhstan. Kazakhstan actively introduces AI solutions into production processes. – 2026, January 6. – URL: https://primeminister.kz/en/news/kazakhstan-actively-introduces-ai-solutions-into-production-processes-30932

12. Kazinform News Agency. Kazakhstan joins the world's TOP-500 most powerful supercomputers. – 2025, November 18. – URL: https://qazinform.com

13. ENERGY Insights & Analytics. Kazakhstan Energy Outlook 2025 (Report). EXia. – 2025, August 20. – URL: https://s3-prod.exia.kz/articles/Kazakhstan_Energy_Outlook_2025_EN.pdf

14. Ministry of Artificial Intelligence and Digital Development of the Republic of Kazakhstan. Почти 1 млн казахстанцев прошли обучение по искусственному интеллекту. GOV.KZ. – URL: https://www.gov.kz/memleket/entities/maidd/press/news/details/1142334?lang=ru (accessed: 20.01.2026).

15. Mussa A., Tuimebayev Z., Mansurova M. Make Large Language Models Efficient: A Review // IEEE Access. – 2025.

16. AI Index Steering Committee. AI Index Report 2025. – URL: https://hai.stanford.edu/ai-index/2025-ai-index-report (accessed: 20.01.2026).

17. Xia M., Malladi S., Gururangan S., Arora S., Chen D. LESS: Selecting influential data for targeted instruction tuning // arXiv preprint arXiv:2402.04333. – 2024.

18. Xu M., Yin W., Cai D., Yi R., Xu D., Wang Q., et al. A survey of resource-efficient LLM and multimodal foundation models // arXiv preprint arXiv:2401.08092. – 2024.

19. Lin X., Wang W., Li Y., Yang S., Feng F., Wei Y., Chua T. S. Data-efficient fine-tuning for LLM-based recommendation // Proceedings of the 47th International ACM SIGIR Conference. – 2024. – P. 365–374.

20. Zhou Z., Ning X., Hong K., Fu T., Xu J., Li S., et al. A survey on efficient inference for large language models // arXiv preprint arXiv:2404.14294. – 2024.

21. Griffith S., Subramanian K., Scholz J., Isbell C. L., Thomaz A. L. Policy shaping: Integrating human feedback with reinforcement learning // Advances in Neural Information Processing Systems. – 2013. – Vol. 26.

22. Xu H., Sharaf A., Chen Y., Tan W., Shen L., Van Durme B., et al. Contrastive preference optimization: Pushing the boundaries of LLM performance in machine translation // arXiv preprint arXiv:2401.08417. – 2024.

23. Acharya D. B., Kuppan K., Divya B. Agentic AI: Autonomous intelligence for complex goals – a comprehensive survey // IEEE Access. – 2025.

24. Kaz-Transformers. kz-transformers (Hugging Face organization page). – URL: https://huggingface.co/kz-transformers (accessed: 20.01.2026).

25. Cao Y., Hong S., Li X., Ying J., Ma Y., Liang H., et al. Toward generalizable evaluation in the LLM era: A survey beyond benchmarks // arXiv preprint arXiv:2504.18838. – 2025.

26. Touvron H., Martin L., Stone K., Albert P., Almahairi A., Babaei Y., et al. Llama 2: Open foundation and fine-tuned chat models // arXiv preprint arXiv:2307.09288. – 2023.

27. Ahmet Baitursynuly Institute of Linguistics. National Corpus of the Kazakh Language (QazCorpus). – URL: https://qazcorpus.kz (accessed: 20.01.2026).

28. Najam R., Faizullah S. Analysis of recent deep learning techniques for Arabic handwritten-text OCR and post-OCR correction // Applied Sciences. – 2023. – Vol. 13(13). – 7568.

29. Liu Y., Yao Y., Ton J. F., Zhang X., Guo R., Cheng H., et al. Trustworthy LLMs: a survey and guideline for evaluating large language models' alignment // arXiv preprint arXiv:2308.05374. – 2023.

30. Fan W., Ding Y., Ning L., Wang S., Li H., Yin D., et al. A survey on RAG meeting LLMs: Towards retrieval-augmented large language models // Proceedings of the 30th ACM SIGKDD Conference. – 2024. – P. 6491–6501.

31. RAGFlow (official website). – URL: https://ragflow.io (accessed: 20.01.2026).

32. Li M., Huang Z., Chen L., Ren J., Jiang M., Li F., et al. Contemporary advances in neural network quantization: A survey // 2024 International Joint Conference on Neural Networks (IJCNN). – IEEE, 2024. – P. 1–10.

# Toward Holistic and Trustworthy AI

Amir Mosavi[1,2,3,4], Laila Aidarova[1], Saltanat Baipakbayeva[1], Assel Ospan[1], Talshyn Sarsembayeva[1], Madina Mansurova[1], and Maksat Kalimoldayev[1]

[1] Farabi University, Almaty, Kazakhstan.
[2] Selye Janos University, Komarno Slovakia.
[3] Ludovika University of Public Service, Hungary.
[4] Obuda University, Budapest, Hungary.
amir.mosavi(at)uni-obuda.hu

**Abstract.** Artificial intelligence requires trustworthiness beyond technical performance. Existing research often treats trustworthiness requirements separately. Their relationships across the AI lifecycle remain insufficiently integrated. This article proposes a holistic concept of trustworthy AI.Five dimensions are integrated: technical trustworthiness, transparency and governance, human and social responsibility, ethical and legal alignment, and sustainability and impact. Key requirements are connected within these dimensions. The model applies these requirements across data, development, validation, deployment, and monitoring. It also identifies relationships among explainability, accountability, fairness, robustness, safety, sustainability, and other requirements. The contribution of this article is a system-level conceptualization of trustworthy AI. It integrates technical, human, ethical, legal, social, and environmental requirements. The model provides a basis for lifecycle-based assessment and governance of trustworthy AI.

**Keywords:** Trustworthy AI · Responsible AI · AI ethics · AI governance · AI accountability · human oversight · explainable AI · AI regulation · AI safety · AI fairness · interdisciplinary AI · socially responsible AI · artificial intelligence · data science · Big Data

## 1 Introduction

Artificial intelligence is used across complex social and technical environments. Important decisions are supported in healthcare, government, finance, and industry. Accuracy is often treated as the main quality measure [1]. However, trustworthiness is not established by accuracy alone. Ethical, legal, social, and technical duties are also imposed [2,4,5]. Reliability, safety, fairness, transparency, privacy, and accountability are commonly required. Human control is also required for consequential decisions [3]. These properties are assessed as one sociotechnical system. Their relationships are examined across the complete AI lifecycle. Domain requirements are added when specific risks are identified [9,15]. Evaluation is limited when separate methods are applied [11]. Accountability is weakened when duties remain unclear. Ethical leadership is required within responsible organizations [6]. Regulation is complicated by different national rules [7,8]. Social

effects are shaped by culture, institutions, and human factors [12,13,14]. Generative AI creates further governance and social-value concerns [16]. Philosophy and computer science are connected through shared assessment [10]. The main dimensions are shown in Fig. 1. Technical and social requirements are connected within this view. Legal duties and ethical principles are also connected. A unified assessment is therefore supported.

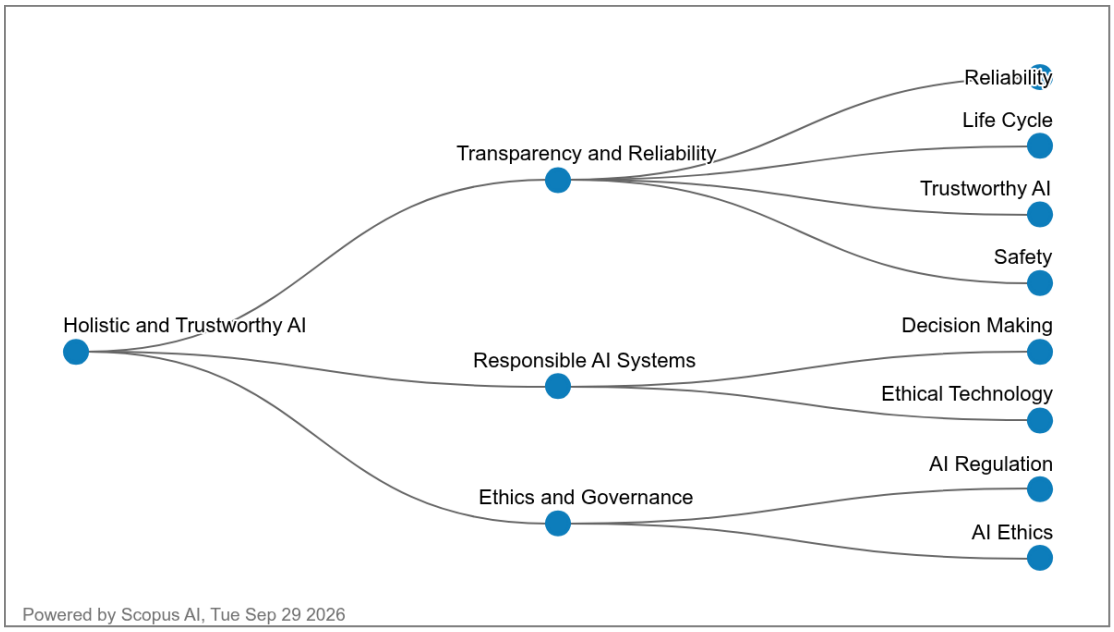



**Fig. 1.** Key dimensions and challenges of trustworthy AI.

Three contributions are provided. Technical and social requirements are linked across the lifecycle. Legal accountability is connected with human oversight. Social science is positioned within AI design.

## 2 Concept

Trustworthy AI is treated as a repeated sociotechnical process. Five connected dimensions are included within the concept. Technical trustworthiness is linked with transparency and governance. Human responsibility is linked with ethical and legal alignment. Sustainability and impact are also included [2,3,60,65]. Robustness, reliability, safety, security, and privacy are technically required. Reproducibility and calibrated uncertainty are also required. Context is considered because consequences differ across applications [26,61]. Production controls are supported through records, tests, and system review [62,63]. Component diversity can strengthen system-level dependability [73]. Explainability, interpretability, transparency, auditability, and accountability are jointly assessed [64,72]. Explanations are supported through evidence and traceable records. Human

oversight is supported through review and intervention. Fairness, inclusion, accessibility, and context are also evaluated. Ethical duties are distinguished from legal obligations. Compliance is not accepted as proof of ethical acceptability. Sustainability is assessed through resources, energy, scale, and environmental effects. Social and institutional effects are assessed before and after deployment. Health applications illustrate robustness and explainability requirements [74]. The five dimensions are shown in Fig. 2. Circular arrows are used for repeated assessment. Corrective action is supported through feedback and renewed review.

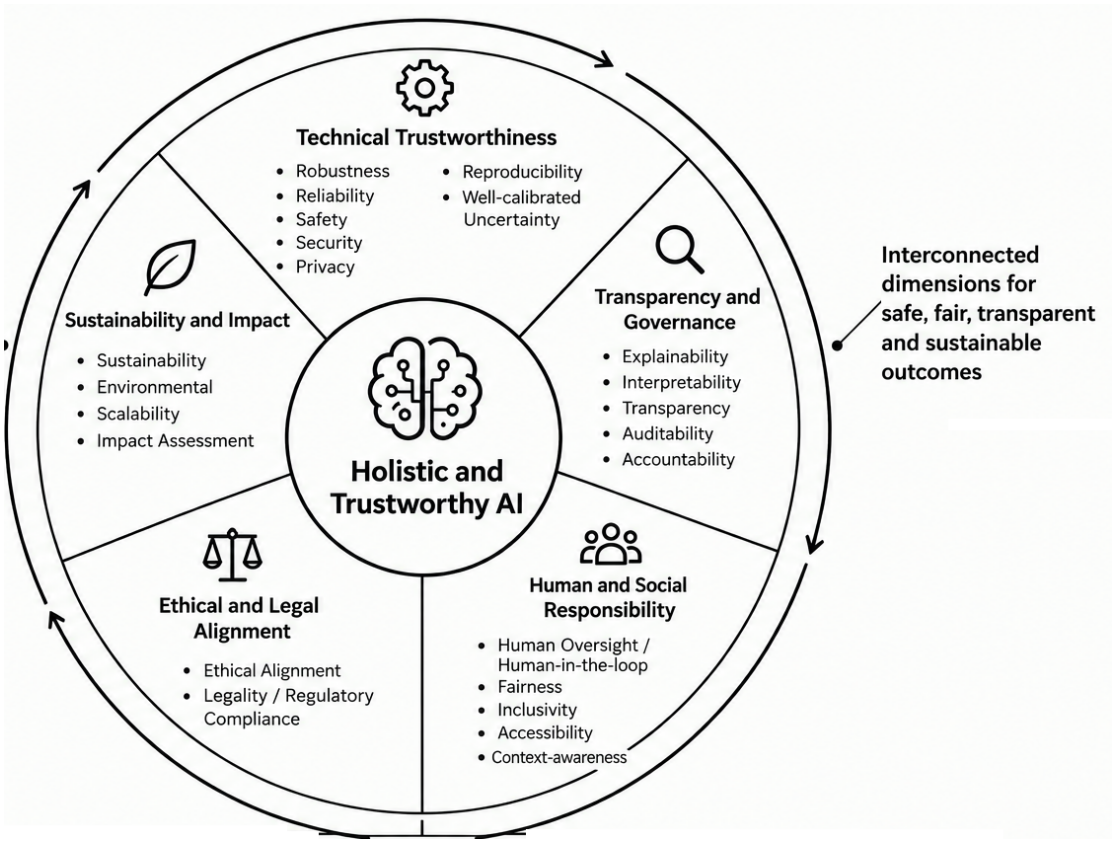



**Fig. 2.** Interconnected dimensions of holistic and trustworthy AI.

Each lifecycle stage is assigned distinct duties. Data are assessed for quality, privacy, representation, and bias. Models are assessed for robustness, security, and uncertainty. Deployment is supported through oversight and records. Later changes are reviewed through repeated controls [71].

## 3 Ethical Considerations for Trustworthy AI

Human agency is protected throughout system design and operation. Human intervention is retained for high-risk decisions. Fairness is assessed within each social context. Privacy is protected across data collection, storage, analysis, and

use. Safety is supported through tests and failure procedures [17,18,21]. Healthcare governance requires ethical controls and accountable oversight [19,66]. Medical imaging requires robustness across several trust layers [67]. Explainability is supported through suitable symbolic and technical methods [20]. Ethical principles are translated into measurable procedures. Lifecycle models are used for repeated assessment [23,24]. Quantitative evidence is combined with contextual judgment [27]. One-time approval is not accepted as sufficient assurance. Stakeholder participation is included throughout ethical review [68]. Environmental and social effects are also examined. Clear duties are assigned for correction and appeal. Technical controls are connected with organizational responsibility [22,25,28].

## 4 Interdisciplinary Collaboration and Integration of Social Considerations

Technical expertise is combined with ethics, law, and social science. Different risks are identified by different disciplines. Social conditions are considered during problem definition and system design [29,33]. Inclusion, diversity, equity, accessibility, and safety are jointly considered [30]. Cultural and organizational contexts are interpreted by social scientists. Contextual intelligence is strengthened through broad educational perspectives [32]. Legal duties are clarified by legal experts [31]. Complex social problems are assessed through shared expertise [34]. The main contributions are listed in Table 1. Participation is not limited to final review. Early technical choices are revised when social risks are identified.

**Table 1.** Contributions of interdisciplinary collaboration

| **Area** | **Contribution** | **Expertise** |
|---|---|---|
| Social context | Affected groups and risks are identified. | Social science |
| Ethics | Fairness and inclusion are assessed. | Ethics and philosophy |
| Law | Rights and duties are clarified. | Law and policy |
| Design | Social requirements are translated into specifications. | Computing and design |
| Governance | Institutional controls are defined. | Policy and management |

## 5 Regulations for Accountability

Transparency is required for examination, challenge, and correction. Documentation is required for data, models, decisions, and limitations. Auditability is supported through records and independent review [35,36,38]. Responsibility is distributed across developers, providers, deployers, users, and regulators. Clear duties are required for each actor. Civil and criminal responsibilities require defined evidence and remedies [39,40,41]. Autonomous offenses create further

questions about punitive responsibility [42]. AI agents also require clear legal status and duties [43]. Human review is retained when rights or safety are affected. Legal duties differ across sectors and jurisdictions. Stronger controls are required for high-risk applications [37]. International compatibility is supported through cooperation and common standards [44,45]. Statutory rules must balance innovation with public responsibility [47]. Ethical duties are retained when legal rules remain incomplete [46,48].Key legal requirements are listed in Table 2. These requirements are applied through enforceable procedures.

**Table 2.** Legal requirements for AI accountability

| **Requirement** | **Purpose** | **Mechanism** |
|---|---|---|
| Transparency | Decisions are made examinable. | Records and audits |
| Responsibility | Duties are assigned. | Defined actor roles |
| Liability | Harm is addressed. | Civil and criminal remedies |
| Human oversight | Decisions remain reviewable. | Intervention and appeal |
| Compatibility | Legal conflicts are reduced. | Shared standards |

## 6 The Role of Utilitarian Principles in AI Ethics

Consequences are assessed through utilitarian ethics when suitable. Collective welfare is compared across possible outcomes [49]. Safety, efficiency, and resource allocation can be evaluated. However, utility is not accepted as the sole ethical measure. Minority rights can be weakened by aggregate benefits [53]. Social values cannot be reduced to one numerical function. Community and relational values are also protected [50,51]. Rights, dignity, autonomy, fairness, and non-discrimination are separately protected [52]. Utilitarian analysis is therefore constrained by other principles. Its roles and limits are listed in Table 3.

**Table 3.** Roles and limits of utilitarian ethics

| **Aspect** | **Use** | **Limit** |
|---|---|---|
| Consequences | Outcomes are compared. | Values remain difficult to measure. |
| Welfare | Collective benefits are assessed. | Minority interests can be weakened. |
| Context | Rules are adapted. | Universal utility is unavailable. |
| Rights | Additional limits are imposed. | Utility alone remains insufficient. |

## 7 Role of Social Scientists in AI Design

Cultural and organizational contexts are interpreted by social scientists. User needs and social risks are also examined [54,56]. Stakeholder interests are iden-

tified across development and deployment [68]. Ethical and legal concerns are identified before deployment.Social requirements are translated into technical choices. Communication is improved across technical and social groups. Impact assessment is supported through established social methods [55]. Their main roles are listed in Table 4. Direct participation is required throughout the lifecycle.

**Table 4.** Roles of social scientists in AI design

| **Role** | **Contribution** | **Design effect** |
|---|---|---|
| Cultural analysis | Social context is interpreted. | Requirements are refined. |
| Ethical review | Social risks are assessed. | Safeguards are added. |
| User inclusion | Diverse needs are identified. | Access is improved. |
| Impact assessment | Institutional effects are examined. | Harm is reduced. |
| Mediation | Knowledge is translated. | Cooperation is strengthened. |

**Table 5.** Main findings for holistic trustworthy AI

| **Area** | **Finding** | **Required response** |
|---|---|---|
| Performance | Accuracy remains insufficient. | Broader evidence is required. |
| Ethics | Principles require procedures. | Measures and review are combined. |
| Accountability | Duties involve many actors. | Roles are assigned clearly. |
| Oversight | Human control remains necessary. | Review and appeal are retained. |
| Lifecycle | Risks change after deployment. | Repeated assessment is required. |

## 8 Discussion

The main finding of this study is that trustworthy AI should be assessed as a complete sociotechnical system. The analysis shows that isolated assessment of individual properties is insufficient. Explainability can improve understanding, but it does not establish fairness or accountability. Accuracy can indicate predictive performance, but it does not establish safety, privacy, or social acceptance. Similarly, legal compliance does not necessarily establish ethical acceptability. Public trust should also be distinguished from ethical justification, because a system can receive public acceptance without satisfying broader ethical requirements [69]. These distinctions support a system-level interpretation of trustworthy AI. Such an interpretation is consistent with research that connects technical, legal, ethical, and psychological requirements rather than treating them as independent concerns [70].

The proposed concept addresses this limitation through the integration of five connected dimensions. Technical trustworthiness provides the basis for reliable,

robust, secure, and safe operation. Transparency and governance provide evidence for explanation, auditability, and accountability. Human and social responsibility addresses fairness, inclusion, accessibility, and human oversight. Ethical and legal alignment connects value-based requirements with formal obligations. Sustainability and impact extend assessment toward environmental, social, and institutional consequences. These dimensions should not be interpreted as independent categories. Their relationships determine how individual requirements contribute to system-level trustworthiness. This interpretation supports previous work that presents trustworthy AI as a combination of technical and broader societal requirements [2,3,60].

The lifecycle perspective provides an important implication of the proposed model. Trustworthiness cannot be established through a single evaluation before deployment. Risks can change when data, users, environments, or system functions change. Data quality and representation can affect fairness and reliability. Development choices can affect robustness, security, interpretability, and reproducibility. Validation can reveal performance limitations, uncertainty, safety risks, and unequal outcomes. Deployment can introduce new organizational and social conditions. Monitoring can therefore provide evidence that was unavailable during initial validation. Repeated assessment is consequently required across data preparation, development, validation, deployment, and review. This approach is consistent with lifecycle-oriented views of trustworthy AI, in which controls and responsibilities are maintained across successive stages [2,3,60]. Human oversight represents another important relationship within the proposed concept. Human authority is retained when AI decisions can affect rights, safety, or significant personal interests. However, human oversight should not be interpreted as a general substitute for technical safeguards. Effective oversight requires sufficient information, clear responsibility, appropriate intervention mechanisms, and access to relevant evidence. Explainability and calibrated uncertainty can support human assessment. Auditability can provide records for review. Accountability can establish responsibility when intervention or correction is required. Fairness and safety can define conditions under which human review becomes necessary. The concept therefore positions human oversight as an operational component of trustworthy AI rather than as a final approval step.

The analysis also shows that trustworthy AI is context-dependent. Core requirements remain relevant across application domains, but their implementation and relative importance can differ. Healthcare, government, finance, education, energy, mobility, and industrial systems can involve different types and levels of risk. Smart grid applications require reliable and interpretable analysis because system decisions can affect critical infrastructure [57]. Educational systems require attention to privacy and responsible data use because learner information can be sensitive [58]. Secure mobility systems require safety, robustness, and protection against security threats [59]. These examples indicate that a common set of trustworthy AI requirements can provide a general basis, while additional controls should be introduced when application-specific risks increase. Context-awareness is therefore necessary for operationalizing the pro-

posed concept. The findings also have implications for accountability and governance. AI responsibility is distributed across multiple actors, including developers, providers, deployers, users, and regulators. Accountability therefore cannot be assigned only to the model or its developer. Documentation, traceability, audit records, and defined responsibilities are required across the system. Auditability can connect technical evidence with governance processes. Transparency can support examination and challenge. Legal compliance can establish minimum obligations, while ethical assessment can address concerns that remain beyond formal legal requirements. The proposed model therefore treats governance as a continuous process that connects technical evidence with organizational and institutional responsibility.

Sustainability and impact assessment further extend the conventional interpretation of trustworthy AI. A system can satisfy technical requirements while producing substantial environmental or social effects. Computational resources, energy use, infrastructure requirements, and system scale can affect the sustainability of AI deployment. Social and institutional effects can also emerge after deployment. Impact assessment should therefore examine technical, ethical, social, economic, and environmental consequences before and after system implementation. This perspective supports the treatment of sustainability as a component of trustworthiness rather than as a separate concern. The findings in Table 5 also indicate that no single metric can provide complete evidence of trustworthiness. Quantitative indicators remain necessary for performance, robustness, fairness, reliability, uncertainty, and resource use. However, quantitative measures cannot fully represent ethical acceptability, institutional responsibility, human agency, or contextual effects. Qualitative review is therefore required alongside technical evaluation. Stakeholder assessment, documentation, audits, and contextual analysis can provide complementary evidence. This combination also reduces the risk that a system satisfies selected metrics while important social or institutional risks remain unexamined.

Several research gaps remain. First, the integrated concept requires operational evaluation methods that can assess relationships among its dimensions. Second, accountability and liability require clearer mechanisms when responsibility is distributed across multiple actors. Third, human oversight requires measurable procedures for intervention, review, contestability, and appeal. Fourth, international compatibility remains difficult because legal requirements and governance practices differ across jurisdictions. Finally, lifecycle assessment requires mechanisms that can connect monitoring results with corrective action. Future research should therefore develop context-sensitive indicators and assessment procedures that combine technical and social evidence. Such methods should support repeated evaluation rather than one-time certification. The proposed concept thus provides a system-level basis for trustworthy AI assessment. Its main implication is that trustworthiness should be established through coordinated evidence across technical, human, ethical, legal, social, and environmental dimensions. The five dimensions should be applied throughout the AI lifecycle and adapted to application-specific risks. This perspective moves assessment

beyond isolated principles and individual model properties. It also supports a transition from high-level trustworthy AI principles toward operational governance, continuous review, and corrective action. The resulting approach provides a basis for future empirical validation of the proposed requirements and their relationships across different AI applications.

## 9 Conclusion

Trustworthy AI is established through coordinated technical, human, ethical, legal, social, and environmental safeguards. The proposed concept treats trustworthiness as a property of the complete AI system rather than an isolated model property. Five connected dimensions are integrated: technical trustworthiness, transparency and governance, human and social responsibility, ethical and legal alignment, and sustainability and impact. These dimensions are applied across data preparation, development, validation, deployment, and monitoring. The analysis shows that no single requirement can provide sufficient evidence of trustworthiness. Accuracy does not establish safety or fairness. Explainability does not establish accountability. Legal compliance does not establish ethical acceptability. Trustworthy AI therefore requires combined technical evidence, qualitative assessment, human oversight, governance controls, and contextual evaluation. Responsibility is also distributed across the actors involved in AI development and use. Clear duties, documentation, auditability, review, and corrective mechanisms are therefore required. The proposed concept also shows that trustworthiness is context-dependent. Core requirements remain relevant across application domains, while additional controls are required when domain risks increase. Human authority is retained for consequential decisions. Social context, stakeholder needs, rights, fairness, accessibility, and environmental effects are included within system assessment. Interdisciplinary cooperation is therefore required across computer science, ethics, law, and social science. Trustworthiness is consequently treated as a continuous lifecycle process. Evidence is collected and reviewed repeatedly, while monitoring results support corrective action and renewed assessment. Future research should develop operational and measurable methods for integrated evaluation, human oversight, accountability, liability, and international compatibility. The proposed concept provides a basis for such methods and supports a transition from isolated trustworthy AI principles toward coordinated, context-sensitive, and lifecycle-based governance.

**Acknowledgments.** OpenAI ChatGPT was used for language revision and LaTeX checks. All revisions were reviewed and approved by the authors. Full responsibility is retained by the authors.

## References

1. Mehrotra, S., Huang, J., Fu, X., et al.: Understanding AI trustworthiness: A scoping review of AIES & FAccT articles. Journal of Artificial Intelligence Research (2026)

2. Díaz-Rodríguez, N., Del Ser, J., Coeckelbergh, M., et al.: Connecting the dots in trustworthy artificial intelligence: From AI principles, ethics, and key requirements to responsible AI systems and regulation. Information Fusion **99**, 101896 (2023)
3. Thiebes, S., Lins, S., Sunyaev, A.: Trustworthy artificial intelligence. Electronic Markets **31**, 447–464 (2021)
4. Tartaro, A., Héder, M.: Ethics of AI. In: Elgar Encyclopedia of Political Communication, vols. 1–3. Edward Elgar Publishing (2025)
5. Battineni, G., Chougule, S.N., Kataria, A., Goyal, L.M.: Navigating ethics and legalities in artificial intelligence: Challenges, frameworks, and future directions. In: Studies in Computational Intelligence. Springer (2025)
6. Bannor, F.O., Baysah, J.O.: Ethical leadership challenges in the age of artificial intelligence: An in-depth analysis. Pan-African Journal of Education and Social Sciences **6**(2), 76–88 (2025)
7. Sedeeq, F.S., Arman, P.: Human-centric AI governance: An adaptive public international law framework for ethical and inclusive AI regulation in public health. Journal of Law, Medicine and Ethics (2025)
8. Lewis, D., Hogan, L., Filip, D., Wall, P.J.: Global challenges in the standardization of ethics for trustworthy AI. Journal of ICT Standardization **8**(2), 123–150 (2020)
9. Pham, T.: Ethical and legal considerations in healthcare AI: Innovation and policy for safe and fair use. Royal Society Open Science **12**, 241873 (2025)
10. Baum, K., Steffen, B.: Let's talk AI with philosophy and computer science expert Kevin Baum. Lecture Notes in Computer Science (2026)
11. Begum, S., Ahmed, M.U., Barua, S., et al.: Research issues and challenges in the computational development of trustworthy AI. In: 2024 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET) (2024)
12. Abadía, M.C., Goisauf, M., Hesso, I., et al.: Societal, legal, and ethical aspects of trustworthy AI. In: Trustworthy AI in Cancer Imaging Research. Springer (2025)
13. Rahman, H.: AI and ethics on a global scale: Challenges, frameworks, and solutions. In: The Ethical Landscape of AI: Global Issues and Solutions. IGI Global (2026)
14. Mehra, P., Kansra, P.: Implication of the dark side of artificial intelligence on corporate success from the perspective of human factors and ergonomics. In: Handbook of Human Factors and Ergonomics in Contemporary Business. Routledge (2025)
15. Vatankhah, S., Bamshad, V., Arici, H.E., Duan, Y.: Ethical implementation of artificial intelligence in the service industries. The Service Industries Journal **44**(9–10), 661–685 (2024)
16. Tu, J., Tang, M.: The ethical reconstruction of generative AI: Social value, governance challenges, and pathways to digital empowerment. Lecture Notes in Computer Science (2025)
17. Eke, D., Wakunuma, K., Akintoye, S., Ogoh, G.: Trustworthy AI: African perspectives. In: Trustworthy AI: African Perspectives. Springer, Cham (2025)
18. Subash, B., Whig, P.: Principles and frameworks. In: Ethical Dimensions of AI Development. Springer, Cham (2024)
19. Skubis, I.: AI governance: Ethics of trustworthy AI in healthcare. In: Proceedings of the International Joint Conference on Neural Networks (IJCNN 2025). IEEE (2025)
20. Calegari, R., Sabbatini, F.: The PSyKE technology for trustworthy artificial intelligence. In: Lecture Notes in Computer Science. Springer, Cham (2023)
21. Hallows, R., Glazier, L., Katz, M.S., et al.: Safe and ethical artificial intelligence in radiotherapy: Lessons learned from the aviation industry. Clinical Oncology **34** (2022)

22. Asrifan, A.: Building trust in AI-driven organizations: A strategic approach to ethical management. In: Moral and Legal Aspects of Artificial Intelligence: Machine Bias and Rule of Law. Springer (2025)
23. McCormack, L., Bendechache, M.: The Trustworthy AI Maturity Model (TAIMM): Integrating ethics and regulation across the AI lifecycle. Journal of Responsible Technology (2026)
24. Loucif, S., Sharma, R., Kshetri, N., Zahid, A.: From design to decommissioning: TAFES framework for responsible AI. In: Law, Ethics and Technology. Springer (2025)
25. Buzi, S., Cacace, S., Loreggia, A., et al.: Advancing trustworthy AI: Mission and research lines at the TRAIL Lab. CEUR Workshop Proceedings (2025)
26. Jiang, H., Zhu, J., Wang, J., Lei, J.: Towards trustworthy AI decision-making: A unified framework for counterfactual resilience, neuro-symbolic constraints, and ethical alignment. In: Proceedings of the 2025 International Conference on Digital Society and Intelligent Computing (ICDSIC 2025). IEEE (2026)
27. Kumar, D., Singla, B.S., Choudhary, R.K.: Operationalizing AI ethics: A quantifiable framework for implementation and assessment. In: 2025 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI 2025). IEEE (2025)
28. Schrader, D.E., Ghosh, D.: Proactively protecting against the singularity: Ethical decision making in AI. IEEE Security & Privacy **16**(4), 66–73 (2018)
29. Bisconti, P., Orsitto, D., Fedorczyk, F., et al.: Maximizing team synergy in AI-related interdisciplinary groups: An interdisciplinary-by-design iterative methodology. AI and Society (2023)
30. Zallio, M., Ike, C.B., Chivăran, C.: Designing artificial intelligence: Exploring inclusion, diversity, equity, accessibility, and safety in human-centric emerging technologies. AI **6** (2025)
31. Weng, Y.-H.: Towards integrated governance for intelligent robots: A focus on social system design. Jusletter IT (2017)
32. Kundal, A., Shrivastav, S., Mangwani, T.: Contextual intelligence for AI in design: A liberal education lens. In: Proceedings of DRS 2026 (2026)
33. Baum, S.D.: Artificial interdisciplinarity: Artificial intelligence for research on complex societal problems. Philosophy & Technology **34**, 1171–1191 (2021)
34. Fiore, S.M., Johnson, M., Robertson, P., et al.: Transdisciplinary team science: Transcending disciplines to understand artificial social intelligence in human-agent teaming. In: Proceedings of the Human Factors and Ergonomics Society Annual Meeting (2023)
35. Kharitonova, Y., Lendvai, G.F.: The principle of transparency in AI regulation: A comparative legal analysis of the European and Chinese approaches. Kutafin Law Review (2025)
36. Herrera, F.: Responsible artificial intelligence systems: From trustworthiness to governance. In: Proceedings of Design, Automation and Test in Europe (DATE 2024) (2024)
37. Chung, C.H.: AI and the rule and role of law: Reshaping legal regulatory frameworks to address emerging challenges. In: 2025 IEEE International Symposium on Ethics in Engineering, Science, and Technology: Emerging Technologies, Ethics, and Social Justice (ETHICS) (2025)
38. Goncalves, A., Correia, A.: XAI-compliance-by-design: A modular framework for GDPR- and AI Act-aligned decision transparency in high-risk AI systems. Journal of Cybersecurity and Privacy (2026)

39. Losavio, M.: Forensic proof and criminal liability for development, distribution and use of artificial intelligence. In: AI Embedded Assurance for Cyber Systems. Springer (2023)
40. Begishev, I.R., Kirillov, M.A., Bersei, D.D., et al.: Robotics, artificial intelligence and criminal law: An overview of contemporary studies. In: AIP Conference Proceedings (2023)
41. Izzat, W.: Compensation for damage caused by the use of artificial intelligence application. In: Studies in Systems, Decision and Control. Springer (2026)
42. Faqir, R.S.A.: Beyond human accountability: Developing a punitive novel framework for offenses committed by artificial intelligence. In: Advances in Science, Technology and Innovation. Springer (2026)
43. Graves, F.: AI agents. In: Elgar Concise Encyclopedia of Artificial Intelligence and the Law. Edward Elgar Publishing (2025)
44. Augustyn-Skuza, P.: Is full harmonization of laws with regard to artificial intelligence possible? Studia Iuridica Toruniensia (2023)
45. Nurgaliyeva, Y., Baimakhanova, A., Zharkenova, S., Galiakbarova, G.: Bridging the gap: Accountability and risk-based regulation in Kazakhstan's artificial intelligence legislation. Access to Justice in Eastern Europe (2026)
46. More, M., Shah, S., Shelke, A., Behare, N.: Ethical and regulatory considerations in AI adoption within legal systems. In: Exploration of AI in Contemporary Legal Systems. Springer (2024)
47. Salmi, A., Bhattacharya, B., Bhattacharya, S., Abo El Wafa, T.: The role of statutory law in regulating artificial intelligence: Balancing innovation and responsibility. Access to Justice in Eastern Europe (2025)
48. Gatt, L., Caggiano, I.A., Gaeta, M.C., et al.: The possible relationships between law and ethics applied to AI. European Journal of Privacy Law and Technologies (2023)
49. Schroth, J.: Consequentialism and AI. In: A Companion to Applied Philosophy of AI. Wiley (2025)
50. Metz, T.: African reasons why AI should not maximize utility. In: African Values, Ethics, and Technology: Questions, Issues, and Approaches. Palgrave Macmillan (2021)
51. Metz, T.: African reasons why artificial intelligence should not maximize utility. In: Conversations on African Philosophy of Mind, Consciousness and Artificial Intelligence. Springer (2023)
52. de Swarte, T., Boufous, O., Escalle, P.: Artificial intelligence, ethics and human values: The cases of military drones and companion robots. Artificial Life and Robotics **24**, 1–7 (2019)
53. Cvik, Š.: Categorization and challenges of utilitarianisms in the context of artificial intelligence. AI and Society **37**, 1107–1119 (2022)
54. Harvey, M.: Artificial intelligence and the social scientist: The mediation of AIfied creative sites. Social Science Computer Review (2026)
55. Rauer, V.: From interaction to transformaction: The consequences of artificial intelligence for theories of social action. In: Artificial Intelligence in Society: Social, Political and Cultural Implications of a Technological Innovation (2024)
56. Choi, M.-A., Park, B.S.: More-than-human mediation: Social scientists in the making of environmental AI systems. Science, Technology, & Human Values (2026)
57. Rituraj, R., Kanatova, A., Shayakhmetov, A., Baipakbayeva, S., Golovachyova, V., Varkonyi-Koczy, A., Mosavi, A.: Smart grids data analysis with artificial intelligence. Eurasian Journal of Mathematical and Computer Applications **14**(1), 59–79 (2026). https://doi.org/10.32523/2306-6172-2026-14-1-59-79

58. Yousefi, S., Najjar-Ghabel, S., Yousefimehr, B., Kozhanov, M., Nabipour, N., Amirov, A.: Internet of educational things and machine learning. Eurasian Journal of Mathematical and Computer Applications **14**(1), 95–110 (2026). https://doi.org/10.32523/2306-6172-2026-14-1-95-110
59. Csorgoova, V., Varkonyi-Koczy, A., Shayakhmetov, A., Sabdenaliyev, B., Baipakbayeva, S.: Artificial intelligence for secure mobility. Eurasian Journal of Mathematical and Computer Applications **14**(2), 52–66 (2026). https://doi.org/10.32523/2306-6172-2026-14-2-52-66
60. Vieira, M.: Why we should trust systems, not just their AI/ML components. Computer (2025)
61. Saeed, M.M., Alsharidah, M.: Security, privacy, and robustness for trustworthy AI systems: A review. Computers and Electrical Engineering (2024)
62. Billeter, Y., Denzel, P., Chavarriaga, R., et al.: MLOps as enabler of trustworthy AI. In: Proceedings of the Swiss Conference on Data Science (2024)
63. Bayram, F., Ahmed, B.S.: Towards trustworthy machine learning in production: An overview of the robustness in MLOps approach. ACM Computing Surveys (2025)
64. Kobrinskii, B.A.: Trust in artificial intelligence technologies. Scientific and Technical Information Processing (2025)
65. Ziemba, E.W.: The rise, core principles, and applications of explainable artificial intelligence in sustainable development. In: Explainable Artificial Intelligence for Sustainable Development: Advancing Social and Economic Transformations (2025)
66. Bagali, M.M., SaiGanesh, S., Sharma, S., Alkhayya, A.: ETHIC-AID: A framework for ethical AI deployment in healthcare with bias mitigation, transparency, and accountability controls. In: Medical Minds and Machine Learning: Transforming Care with AI (2026)
67. Zuluaga, M.A., Išgum, I., Bach Cuadra, M.: Trustworthy AI in medical image analysis: A unified perspective built on robustness and layers of trust. Current Opinion in Biomedical Engineering (2026)
68. Hussain, J., Koutsikouri, D., Ljungberg, J.: Exploring trustworthy artificial intelligence and its stakeholders: A literature review. CEUR Workshop Proceedings (2025)
69. Sutrop, M.: Should we trust artificial intelligence? Trames (2019)
70. Spilski, J., Spilski, A., Lachmann, T.: The trust in AI-mix: Technical, legal and ethical requirements as well as psychology. In: Proceedings of the IEEE International Conference on Pervasive Computing and Communications Workshops (2025)
71. Dorton, S.L., Stanley, J.C.: Minding the gap: Tools for trust engineering of artificial intelligence. Ergonomics in Design (2024)
72. Choraś, M., Pawlicka, A., Pawlicki, M., Kozik, R.: Transparent and trustworthy eXplainable AI (xAI) in smart human-robot collaboration environment. Lecture Notes in Computer Science (2026)
73. Kharchenko, V., Odarushchenko, O.: Trustworthy AI systems from untrustworthy components: Development von Neumann's paradigm using principle of diversity. CEUR Workshop Proceedings (2024)
74. Mamun, A., Barua Soumma, S., Ghasemzadeh, H.: Trustworthy AI in digital health: A comprehensive review of robustness and explainability. Progress in Biomedical Engineering (2026)

# NEURO-SYMBOLIC NLP FOR TURKIC LANGUAGES

**Ualsher Tukeyev**
*Al-Farabi Kazakh National University, Almaty, Kazakhstan*

***Abstract.*** *This paper provides a concise overview of the neuro-symbolic approach to natural language processing for Turkic languages presented in the monograph Neuro-Symbolic NLP for Turkic Languages. The approach combines neural learning with explicit grammatical modeling for morphologically rich, low-resource languages. Its symbolic foundation is the Complete Set of Endings (CSE), which represents permissible suffix sequences, their grammatical functions, and morphophonological variants. A central motivation for this integration is to reduce neural models' dependence on large training datasets: recurrent morphological regularities can be represented explicitly rather than learned only from numerous examples. CSE-based knowledge can therefore support structured data generation, guide neural learning, and constrain possible outputs. The book demonstrates this principle in AI-assisted resource construction, morphological segmentation, speech recognition and post-processing, machine translation, and summarization for Turkic languages. The presented studies show how explicit linguistic knowledge can complement neural learning and provide a practical basis for NLP under limited-data conditions.*

***Keywords:*** *neuro-symbolic NLP, Turkic languages, CSE, morphology, morphological segmentation, ASR, machine translation, summarization*

## 1. Introduction

Modern neural models have substantially advanced natural language processing, but their effectiveness still depends heavily on access to large training resources. This creates particular difficulties for low-resource and morphologically rich languages. Turkic languages combine limited digital resources with productive agglutinative morphology, vowel harmony, allomorphy, and regular but complex morphotactic patterns [1,2].

In languages such as Kazakh, Kyrgyz, Turkmen, Azerbaijani, Uzbek, and Turkish, a lexical stem can combine with sequences of suffixes expressing number, possession, case, person, tense, mood, voice, and other grammatical categories. For example, the Kazakh word кітаптарымыздан (“from our books”) can be represented as

**кітап + тар + ымыз + дан**

where кітап is the stem, -тар marks plural, -ымыз first-person plural possession, and -дан ablative case.

Statistical subword methods such as BPE are effective in neural NLP but do not explicitly model linguistic morpheme boundaries [3]. Classical computational morphology provides powerful rule-based mechanisms, including two-level morphology [4] and finite-state approaches developed for Turkic languages [5,6]. However, constructing them requires explicit, language-specific resources. Neuro-symbolic AI provides a complementary perspective by combining explicit knowledge representations with neural learning [7,8].

A central motivation for combining neural modeling with symbolic grammatical modeling is to reduce neural systems' dependence on very large training datasets. In a purely data-driven approach, a neural model must infer morphological regularities from numerous observed word forms and their contexts. For low-resource agglutinative languages, obtaining enough examples of the many possible word forms is difficult. In the neuro-symbolic approach considered in this work, CSE explicitly represents recurrent grammatical regularities and related linguistic constraints. These representations can generate structured training data, guide neural learning, and constrain possible model outputs. Thus, grammatical modeling explicitly supplies part of the linguistic structure that would otherwise have to be learned implicitly from large datasets. One of the principal objectives of this approach is therefore to reduce the amount of empirical training data required for effective neural processing of morphologically rich low-resource languages.

The monograph Neuro-Symbolic NLP for Turkic Languages [9] presents a sequence of studies conducted during 2015–2026 that combine explicit morphological knowledge with neural NLP. Its central symbolic component is the Complete Set of Endings (CSE) model [10,11]. In its basic form,

$$\textbf{Word} = \textbf{Stem} + \textbf{Ending}, \quad (1)$$

where an Ending may consist of one or several suffixes:

$$\textbf{Ending} = \textbf{Suffix}_1 + \textbf{Suffix}_2 + \ldots + \textbf{Suffix}_n. \quad (2)$$

The book develops this idea from computational morphology through resource construction and morphological segmentation to speech recognition, machine translation, and summarization. This paper provides a compact overview of these principal directions and results.

**2. CSE as a Symbolic Representation of Turkic Morphology**

The CSE model is based on a characteristic property of agglutinative languages: while the lexical inventory is open and continuously changing, the system of grammatical endings and permissible suffix combinations is finite and substantially more stable [10,11].

Unlike an isolated suffix list, CSE treats an Ending as an integrated morphological unit. It may contain several suffixes and retains information about their grammatical functions. For nominal stems, four major functional classes are considered: plural (K), possessive (T), case (C), and personal/predicative (J). The model generates theoretically possible placements of these categories, eliminates linguistically invalid combinations, and expands valid structures according to vowel harmony, consonant alternation, and allomorphic rules [10,11].

The construction can be summarized as

**affix categories → permissible placements → allomorphic variants → Complete Set of Endings. (3)**

*Table 1. Examples of Kazakh endings and their CSE descriptions*

| Ending | CSE morphological description | Grammatical structure |
|---|---|---|
| дарға | <NB>*дар<pl>*ға<dat> | plural + dative |
| дарғамыз | <NB>*дар<pl>*ға<dat>*мыз<per><pl><p1> | plural + dative + 1st person plural |
| дарда | <NB>*дар<pl>*да<loc> | plural + locative |
| дардасыздар | <NB>*дар<pl>*да<loc>*сыздар<per><frm><p2><pl> | plural + locative + formal 2nd person plural |
| дардан | <NB>*дар<pl>*дан<abl> | plural + ablative |
| гені | <VB>*ген<pp>*i<pos><sg><p3> | participial + 3rd person singular possessive |
| генінен | <VB>*ген<pp>*i<pos><sg><p3>*нен<abl> | participial + possessive + ablative |

Thus, CSE establishes the correspondence

**surface ending ↔ suffix sequence ↔ grammatical description.**

This representation supports both directions of processing:

**Word → Stem + Ending**
**Stem + Ending → Word. (4)**

CSE-based computational models and algorithms have been developed for Turkic morphology, stemming, segmentation, and morphological analysis [10,11]. In the monograph, language-specific CSE resources provide the symbolic foundation for the subsequent neuro-symbolic methods [9].

### 3. AI-Assisted Creation of Datasets Based on CSE Modeling

A major limitation in low-resource NLP is the cost of constructing large verified linguistic resources. The book therefore treats AI not only as a final NLP model but also as a tool for resource construction [9].

The general procedure is

**initial resources → corpus processing → AI-assisted validation → linguistic verification → refined resources. (5)**

The Turkmen case study illustrates this approach [12]. An initial set of approximately 80,000 candidate stems was processed through iterative corpus-based validation. Candidates were checked according to corpus attestation, vowel-harmony well-formedness, and morphological decomposability. The procedure also identified endings absent from the initial manually prepared resource, expanding the Turkmen CSE from 2,337 to 2,418 endings [12].

*Table 2. Examples of AI-assisted validation of Turkmen stem candidates*

| Candidate | Decision | Explanation |
|---|---|---|
| *kitaplar* | Removed | kitap + -lar; inflected form |
| *geldi* | Removed | gel + -di; inflected verbal form |
| *kompýuter* | Retained | attested borrowing with native endings |
| *Nusypov* | Retained separately | proper name |
| *garaşsyzlyk* | Removed | decomposable derived form |
| *türkmen* | Retained | corpus-attested form |

A related strategy was applied to parallel corpus construction. AI-assisted translation, automatic filtering, language verification, and expert validation expanded resources for translation between Kazakh and other Turkic languages [13]. Thus, AI-assisted resource creation becomes an intermediate layer connecting explicit linguistic knowledge with neural training:

**linguistic model → AI-assisted resource construction → large training datasets → neural model. (6)**

### 4. CSE-Guided Neural Morphological Segmentation

The next stage transfers CSE-based linguistic knowledge into neural segmentation. The book presents two representative systems: FEMSeg for Kazakh [14] and LCMSeg for Turkmen [12].

FEMSeg is trained using word forms segmented according to the CSE model. Its extended architecture combines character-level processing, convolutional features, bidirectional recurrent modeling, contextual representation, and CRF decoding:

**Character representation → CNN → BiLSTM → Transformer → CRF.**

CSE enables the generation of large morphology-aware training resources without manually segmenting millions of individual word forms. In the Kazakh experiments, the model was trained on approximately 2.33 million CSE-segmented word forms and achieved very high intrinsic segmentation scores on the CSE-derived distribution [14].

LCMSeg for Turkmen introduces linguistic constraints more explicitly into the neural representation. A BiLSTM–CRF architecture is enriched with features describing character type, harmony class, and word-level vowel harmony [12]. At the 80,000-sentence training scale, the reported results reached 99.71% token accuracy and 99.41% morpheme accuracy [12].

The two systems illustrate complementary mechanisms for neuro-symbolic integration. CSE can provide large-scale structured supervision for a neural model, while explicit linguistic features can additionally be incorporated into the neural architecture itself.

### 5. Neuro-Symbolic Processing in ASR

Speech recognition is particularly sensitive to the morphology of Turkic languages because recognition errors in word-final segments may change grammatical meaning. Modern

multilingual speech architectures based on self-supervised learning, including wav2vec 2.0 and MMS, provide a strong neural foundation for low-resource ASR [15,16].

For Turkmen, the MMS-1b-all model was adapted using parameter-efficient LoRA fine-tuning [17]. The initial system produced a WER of 107.33%, while adaptation reduced it to 17.59% [17].

The book also considers morphology-aware post-processing of ASR output for Kyrgyz [9]. Its general processing sequence is

**ASR output → error detection → candidate generation → candidate ranking → corrected text. (7)**

A BERT-based component detects potentially erroneous tokens. It generates correction candidates using language-specific transformations and evaluates them using morphological validity, vowel harmony, contextual information, and other linguistic and statistical features. A MaxEnt model performs candidate selection.

Because large naturally annotated Kyrgyz ASR-error corpora are unavailable, the training resources described in the book were constructed from 285,000 correct Kyrgyz sentences by introducing characteristic synthetic errors [9].

This architecture illustrates the neuro-symbolic principle directly: neural contextual modeling identifies probable errors, whereas explicit morphological and phonological knowledge constrains possible corrections.

**6. Machine Translation, Summarization, and Adaptive Processing**

The book further considers resource construction and neural adaptation in machine translation and summarization. Machine translation for low-resource Turkic languages remains strongly constrained by the availability of parallel corpora, despite the development of large multilingual translation models [18,19].

A unified parallel resource was created for five Turkic–Kazakh language pairs [13].

*Table 3. Parallel corpora and NLLB-200 translation results [13]*

| **Language pair** | **Sentence pairs** | **BLEU** |
|---|---|---|
| Azerbaijani–Kazakh | 780,521 | 47.84 |
| Kyrgyz–Kazakh | 781,967 | 48.27 |
| Turkish–Kazakh | 782,338 | 42.10 |
| Turkmen–Kazakh | 758,863 | 33.22 |
| Uzbek–Kazakh | 781,853 | 46.28 |
| **Total** | **3,885,542** | **—** |

Fine-tuning NLLB-200 1.3B on these resources substantially improved translation quality compared with zero-shot use of the multilingual model [13]. Related large-scale studies have also demonstrated the importance of multilingual and transfer-learning approaches for machine translation among Turkic languages [19].

The Turkmen speech-to-summary study [17] represents text summarization. Researchers fine-tuned an mBART-50-large model on a Turkmen news corpus. ROUGE-L increased from 0.2294 in the zero-shot setting to 0.4255 after fine-tuning [17]. The result is consistent with the broader importance of language-specific adaptation for low-resource summarization.

The studies therefore suggest that different tasks require different combinations of symbolic resources, corpus construction, neural adaptation, and parameter-efficient learning. Rather than relying on a single universal processing mechanism, the framework combines components according to the task and available language resources.

**7. Discussion: From Linguistic Knowledge to Neuro-Symbolic NLP**

The studies summarized above form a common methodological progression [9]:

**linguistic knowledge → computational representation → resource construction → neural learning → NLP applications. (8)**

CSE provides the central symbolic representation. Its role extends beyond morphological analysis: it supports generation and validation of word forms, construction of training resources, neural segmentation, and morphology-aware processing [10–14].

The experiments show several ways symbolic and neural methods can interact. First, symbolic models can generate structured supervision for neural training. Second, neural architectures can explicitly incorporate linguistic properties such as vowel harmony. Third, symbolic constraints can restrict candidate spaces in downstream tasks such as ASR correction.

This combination corresponds to the broader neuro-symbolic principle of integrating explicit structured knowledge with neural representation and learning [7,8]. It is particularly relevant to low-resource languages because regular linguistic structure can provide information that would otherwise require large manually annotated datasets.

The framework can therefore be summarized as

**CSE morphology → AI-assisted resources → morphology-aware neural models → ASR / MT/summarization. (9)**

The central idea is not to replace neural NLP with linguistic rules, but to use explicit linguistic knowledge where it can compensate for limited data and complement neural learning.

## 8. Conclusion

This paper summarizes the main directions presented in the monograph Neuro-Symbolic NLP for Turkic Languages [9]. The studies address the challenges created by productive agglutinative morphology and limited digital resources in Kazakh, Kyrgyz, Turkmen, Azerbaijani, Uzbek, and Turkish.

The Complete Set of Endings provides the symbolic foundation by representing permissible morphological structures as finite computational resources. CSE supports morphological analysis and generation and provides structured data for subsequent neural processing. AI-assisted procedures extend this approach to corpus and lexical-resource construction, while FEMSeg and LCMSeg demonstrate its use in neural morphological segmentation.

At the application level, the book considers neural ASR adaptation and morphology-aware post-processing, neural machine translation based on expanded parallel corpora, and text summarization for a low-resource Turkic language. Across these tasks, the same general principle holds: explicit linguistic structure and neural learning are complementary sources of information.

A key motivation for this integration is reducing neural models' dependence on large training datasets. Explicit grammatical modeling makes it possible to represent productive linguistic regularities directly, rather than requiring the neural model to infer them from numerous examples. For low-resource Turkic languages, this provides a practical way to compensate for limited training data through structured linguistic knowledge.

The presented studies indicate that neuro-symbolic methods offer a practical direction for NLP in low-resource agglutinative languages. Linguistic models provide structured, interpretable knowledge, while neural architectures enable contextual learning, transfer, and generalization. Together, they provide a foundation for further development of language technologies for Turkic languages.

## References

[1] Spencer, A. Morphological Theory: An Introduction to Word Structure in Generative Grammar. Blackwell Publishers, 1991.

[2] Jurafsky, D.; Martin, J.H. Speech and Language Processing. 3rd ed., 2024.

[3] Sennrich, R.; Haddow, B.; Birch, A. Neural Machine Translation of Rare Words with Subword Units. In Proceedings of ACL 2016, pp. 1715–1725.

[4] Koskenniemi, K. Two-Level Morphology: A General Computational Model of Word-Form Recognition and Production. Department of General Linguistics, University of Helsinki, Publication No. 11, 1983.

[5] Oflazer, K. Two-Level Description of Turkish Morphology. Literary and Linguistic Computing 1994, 9(2), 137–148.

[6] Washington, J.N.; Salimzyanov, I.; Tyers, F.M. Finite-State Morphological Transducers for Three Kypchak Languages. In Proceedings of LREC 2014, 2014.

[7] Garcez, A.d.; Lamb, L.C. Neurosymbolic AI: The 3rd Wave. Artificial Intelligence 2023, 322, 103960.

[8] Kautz, H. The Third Wave of AI: Neurosymbolic AI. Proceedings of the AAAI Conference on Artificial Intelligence 2022, 36(11), 12386–12391.

[9] Tukeyev, U. Neuro-Symbolic NLP for Turkic Languages. Fortuna Polygraph: Almaty, Kazakhstan, 2026.

[10] Tukeyev, U. A New Computational Model for Turkic Languages Morphology and Processing. Journal of Problems in Computer Science and Information Technologies 2023, 1(1).

[11] Tukeyev, U.; Karibayeva, A.; Zhumanov, Z. Morphological Segmentation Method for Turkic Language Neural Machine Translation. Cogent Engineering 2020, 7(1), 1856500.

[12] Tukeyev, U.; Amirova, D.; Eshimov, D. CSE-Guided Linguistically Constrained Morphological Segmentation for Turkmen. Information 2026, 17(6), 594.

[13] Tukeyev, U.; Shormakova, A.; Karibayeva, A.; et al. An Integrated Approach to Adapting Open-Source AI Models for Machine Translation of Low-Resource Turkic Languages. Computers 2026, 15(2), 73.

[14] Tukeyev, U.; Rysbek, B. Morphology-Aware Segmentation and Tokenization for Turkic Languages: A CSE-Guided Framework (The Kazakh Case). Information 2026, 17, 128.

[15] Baevski, A.; Zhou, H.; Mohamed, A.; Auli, M. wav2vec 2.0: A Framework for Self-Supervised Learning of Speech Representations. Advances in Neural Information Processing Systems 2020, 33, 12449–12460.

[16] Pratap, V.; et al. Scaling Speech Technology to 1,000+ Languages. Journal of Machine Learning Research 2024, 25, 97:1–97:52.

[17] Tukeyev, U.; Ocheretin, M. From Speech to Summary in Turkmen: A Parameter-Efficient Neural Pipeline. Applied Sciences 2026, 16(12), 5734.

[18] Costa-jussà, M.R.; Cross, J.; Çelebi, O.; et al. No Language Left Behind: Scaling Human-Centered Machine Translation. 2022.

[19] Mirzakhalov, J.; Babu, A.; Ataman, D.; et al. A Large-Scale Study of Machine Translation in the Turkic Languages. In Proceedings of EMNLP 2021, pp. 5876–5890.

# FEATURE SELECTION AND SAMPLE SELF-CORRECTION IN MULTIPLE INSTANCE LEARNING WITH WEAK LABELING

Berikov V.B., Kutnenko O.A.
e-mail: berikov@math.nsc.ru, olga@math.nsc.ru
*Sobolev Institute of mathematics SB RAS, Russia*

***Abstract.*** *We consider a weakly supervised multiple instance learning problem where sets of objects referred to as "bags" are analyzed. The binary classification is considered: a bag is labeled as positive if it contains at least one positive instance (the specific instance is unknown); otherwise, the bag is labeled as negative. The goal is to predict classes for new bags to achieve the best quality metrics. A method has been developed, utilizing informative feature selection, self-correction of learning sample, and voting on a set of decision functions. The function of rival similarity (FRiS) is used to evaluate the degree of unusualness of bags. An experimental study and comparison with existing methods are conducted.*

## 1. Introduction

In machine learning, there are several main approaches to defining the target variable. Supervised learning assumes that each instance in the training set is accompanied by a class label or numerical value. Observations of the objects being analyzed are presented in the form of a data table, which specifies the values of a specific set of features. The main task is to construct a decision rule for predicting the target variable for new objects. This requires optimizing a specified quality criterion (e.g., estimating the probability of correct classification).

Possible uncertainty, fuzziness, or incompleteness of the labeling is a characteristic of weakly supervised learning. Uncertainty in label assignment may arise due to errors or limitations in the observation protocol. For example, when annotating handwritten symbols, some may be illegible or allow multiple interpretations. Labeling can be performed by engaging a large number of independent experts via the internet (i.e., crowdsourcing). In this case, annotators may include both competent specialists and less experienced participants. This requires a special consideration.

In another formulation of the problem, labels are specified at the level of sets of objects, where each instance in the set can have its own value of the feature set. For example, a molecule is classified as having a drug effect if at least one of its conformations (spatial shapes) interacts with the target protein binding site. The task is to predict the presence or absence of a drug effect for new molecules represented as a set of conformations. This problem is known as multiple instance learning.

A real world example is the electricity consumption analysis in the field of non-intrusive load monitoring. Instead of labeling every second, a whole segment of the aggregate power signal (e.g., a 10-minute window) is treated as a single bag. Each individual power reading (e.g., per second) within that segment is an object. Instead of knowing the exact state at every second, an annotator only indicates, for example, that a "kettle was running at some point during this 10-minute window." This is the weak labeling for the entire bag.

The proposed study focuses on the problem of weakly supervised multiple instance learning (WSMIL), where each set, called a *bag*, can include different objects. A binary classification is considered: one class is conventionally called "positive" and the other "negative." A bag is labeled as positive if it contains at least one positive instance (which one is unknown); otherwise negative. The task is to predict the presence or absence of positive objects for new bags. The proposed approach to solving the problem is based on the selection of an informative feature space and the selection of bags for training. Automatic bag selection can be viewed as a self-training procedure by self-correction of the sample.

## 2. Problem statement

Consider a population $\Gamma$ of objects $b \in \Gamma$, described by a feature set $X = \{X_1, \ldots, X_d\}$, where $d$ is the dimension of the feature space. We denote by $x = X(b)$ ($x \in \mathbb{R}^d$) the set of feature observations for instance $b$, where $x = (x_1, \ldots, x_d)$, $x_j = X_j(b)$, $j = 1, \ldots, d$. A metric $r$ is given that allows us to calculate the distance between any pair of objects. Each instance in the population $b \in \Gamma$ belongs to one of two classes, conventionally called positive and negative.

Following the specific nature of the multi-instance learning problem with weak labeling, assume that objects are grouped into certain bags. We denote the set of all possible bags by $\mathbf{B}$. Let $B \in \mathbf{B}$ contain objects $b_1, \ldots, b_m$, $m = |B|$. Let $Y \in \{-1, 1\}$ denote the variable defining the class corresponding to the bag. A bag is labeled as positive: ($B^+$) if $Y(B) = 1$; otherwise, it is labeled negative: ($B^-$), i.e., $Y(B) = -1$. Note that for a positive bag, the membership of individual objects in its classes is unknown. For a negative bag, on the contrary, all of its objects belong to the negative class.

For an arbitrary bag $B \in B$, we need to predict its membership $f(B)$ to classes. A loss function $L(\hat{y}, y)$ is defined, which cpecifies losses when using the prediction (decision function) $\hat{y} = f(B)$ if the true value of the predicted value is equal to $y$.

To construct the decision function, information contained in the training set $(B_1, Y_1) \ldots, (B_n, Y_n)$ is used, where $n$ is the number of bags in the set. The pair $(B_i, Y_i)$ defines the set of instances included in the bag: $B_i = (b_{i1}, \ldots, b_{im_i})$, and its membership in the classes: $Y_i \in \{-1, 1\}$. An estimate of the quality (risk of incorrect recognition) of the constructed decision function can be obtained using a test sample $B_{test}$ of bags generated independently of the training sample. We use an indicator loss function $L \in \{0, 1\}$; in this case, the risk coincides with the proportion of incorrectly recognized bags.

When solving a problem, a more indicative quality metrics are used that take into account data imbalances: *Sensitivity*, i.e., the ability of the decision function to produce the correct result (the proportion of true positive predictions); *Specificity*, i.e., the ability of the classifier to avoid producing false positive results (the proportion of true negative labels); *Balanced Accuracy*, i.e., the avared *Sensitivity* and *Specificity*. We will consider the balanced accuracy (*BA*) as a measure of the quality of the solution.

## 2. Related work

A large number of methods have been developed for solving the problem of multiple instance learning [1]. The existing methods can be divided into various directions, which fit into the following main paradigms.

In the *instance space* paradigm, the decision function is constructed in the original feature space describing the objects. In [2], multidimensional rectangles of minimal volume are constructed, which should include only objects from positive bags. The resulting rectangles are then used to determine features that contribute most to class separation. The authors of [3] developed a method based on manifold regularization and a graph representation of the data. There are methods that adapt well-known machine learning

algorithms at the instance level, such as decision tree boosting, neural networks, k-NN, support vector machines, etc.

The *bag space* paradigm assumes decision making at the level of entire bags (understood as sets of objects) by establishing relationships between them, determining the degree of similarity. Citation-kNN [4] calculates the Hausdorff distance between bags and uses a voting method to classify new bags. Similarity between pairs of bags can be expressed by a kernel used in the SVM operating on bags [5].

The *embedded space* paradigm implies a transition to a new space of features describing bags. Thus, in [6], it is proposed to pre-partition objects into clusters, each of which is associated with a new feature. If a bag has a non-empty intersection with a cluster, the corresponding feature is equal to 1; otherwise 0. The new features are used to build a classifier using SVM; it is possible to construct an ensemble solution based on several partitioning variants. In [8,9,22], deep learning methods are used to construct vector representations of bags in the new space. A special pooling layer in a deep neural network aggregates objects from a bag into a feature vector for the bag representation.

A number of methods for determining bag type use more general assumptions specific to various types of applied problems. For example, thresholds can be used for the number of objects contained in a bag that satisfy specified conditions, under which a bag is considered positive. Another assumption [10] involves identifying "attractive" and "repulsive" example objects. A bag belongs to the positive class if a sufficient number of its objects are, in a given sense, close to "attractors" and at the same time distant from "repulsive" examples. In this general setting, the analysis methods used are similar to those discussed above.

### 3. Proposed method

Both the selection of informative features and the removal of noise bags (outliers) are based on an analysis of the local environment of the bags. This approach is based on the local compactness hypothesis. We use the nearest neighbor method (*kNN*), $k$=1. The following distances ($r$ is an Euclidean distance) are considered as the distance $R$ between bags $A$,$B$:

$$R=\begin{cases} R_{min}(A,B)=\min\limits_{a\in A,b\in B} r(a,b), \ \textit{by the "nearest neighbor" principle}; \\ R_{mc}(A,B)=\dfrac{1}{|A||B|}\sum\limits_{a\in A,b\in B} r(a,b), \ \textit{by the "average connection" principle}; \\ R_W(A,B)=\dfrac{|A||B|}{|A|+|B|}\left\|\bar{x}_A-\bar{x}_B\right\|^2, \ \textit{according to Ward's method}. \end{cases} \quad (1)$$

Here $\bar{x}_A$ is the vector of average values of the observed features of objects in bag $A$.

When analyzing poorly studied material, a large number of characteristics are often used, described objects. Not all features carry information useful for the task at hand: they may contain duplicates or simply noise. It is necessary to select a subset of the most informative characteristics from the original feature set. A large number of algorithms have been developed to solve this problem; a review of these can be found in [11]. In the case of a high-dimensionality feature space, the AdDel algorithm can be used [12], which has been successfully applied in solving various cognitive data analysis problems.

When removing outlier bags, the FRiS (Function of Rival Similarity) [13] function is used:

$$F(C,B^-\mid B^+)=\frac{R(C,B^+)-R(C,B^-)}{R(C,B^+)+R(C,B^-)}, \quad (2)$$

which defines the similarity measure of bag $C$ to a $^{-}$ bag in competition with a $^{+}$bag. The competitive similarity of bags to patterns is determined by the same principle as the competitive similarity between bags. The distance from a bag to patterns can be calculated in different ways. We will use the distance to the closest bag of this pattern as the distance from a bag to a pattern. If $F(C, B^{-} \mid B^{+}) > 0$, then bag $C$ is considered more similar to the negative class; otherwise, it is considered more similar to the positive class. Here, $R(C, B^{+})$ (or $R(C, B^{-})$) is the distance from bag $C$ to the nearest $^{+}$bag (or $^{-}$bag).

The filtering procedure is as follows. For each bag in the training set, the value of the rival similarity function with a bag of its class is determined. Bags with a negative FRiS function value are considered atypical. The quality criterion value of the training set is calculated when excluding from the set the atypical bag with the smallest negative value of *F*, defined by (2). Note that bags from either one of the classes or both classes can be removed. The number of bags to be excluded may or may not be limited. The process stops when an inflection point is reached in the criterion value, or when there are no atypical bags in the remaining sample, or when the limit on the number of bags to be removed is reached.

Main steps of the proposed algorithm are as follows.

*Step 0.* Preprocessing the data (given in the form of a table)), which includes its normalization. Dividing the data into two parts – training and test samples in a proportion determined by the user.

*Step 1.* Forming an informative feature space from the training sample.

*Step 2.* Filtering the training sample using the FRiS function.

*Step 3.* Classification using some given method, the input of which is a matrix of pairwise distances between control bags and training set bags. Evaluation of the quality metrics for the decision rule (distance $R$).

Using the above described distances, decision variants are constructed. The final decision is made by voting among the decision rules. We will refer to the proposed method as Feature Selection and Sample Filtering (FSSF).

## 4. Experimental study

The effectiveness of the proposed method was evaluated for classification of proteins containing structures with the thioredoxin fold ($^{+}$bags), and those without these structures [14]. The features describe the chemical properties of protein regions: molecular weight, hydrophobicity indices, solubility, etc. The data table contains 26,611 objects described in 8-dimensional feature space. The number of packages is 193, including 25 +bags and 168 – bags. Bag sizes range from 35 to 189.

In [15], a leave-one-out cross-validation algorithm based on SVM, the so-called "jack-knife test," is proposed for solving this classification problem.

For each distance specified in (1), an informative feature subspace is formed. The training set is self-corrected, removing no more than four outlier bags of the positive class. Testing is performed on all 180 bags in accordance with the algorithm described above. A bag is classified correctly if at least half of the experiments yielded the correct result ( >3 for $^{+}$bags, >70 for $^{-}$bags). The decision function votes on the majority of the results.

Table 1 shows the performance estimates for the proposed algorithm and a number of known algorithms for WSMIL problem. The quality of the algorithms was assessed using the same protein identification problem and a similar control procedure. Based on the comparison results, it can be concluded that the proposed algorithm provided higher classification quality (based on the BA metric) than other algorithms.

Table 1. Quality metrics (%) for different algorithms

| Algorithm | Metric values | | |
|---|---|---|---|
| | *Sensitivity* | *Specificity* | *BA* |
| FSSF | 100.00 | 71.25 | **85.62** |
| Bartmip [16] | 75.60 | 76.50 | 76.05 |
| $k^{\wedge}$ [17] | 83.10 | 78.20 | 80.65 |
| $k_{min}$ [18] | 85.60 | 78.50 | 82.05 |
| Gmil-2 [19] | 75.00 | 75.00 | 75.00 |
| Emdd [20] | 64.00 | 63.50 | 63.75 |
| DD [21] | 87.50 | 33.20 | 60.35 |

The influence of the choice of different operating modes of the method on its quality was also studied. Thus, when running the algorithm without filtering, the following estimates were obtained: Sensitivity =100.00%, Specificity =68.75%, BA=84.38%. Thus, bag filtering improved the algorithm's performance.

Table 2 shows the metric values of the FSSF algorithm with and without filtering for all distances used in constructing the decision function individually (without constructing the ensemble solution). These results demonstrate that with this outlier removal strategy, the specificity of the method increases. Furthermore, comparing the obtained metric values with the results in Table 1, one can conclude that using the ensemble solution improves the classification quality of the proposed method.

Table 2. Quality metrics (%) for FSSF without filtering training samples and with filtering for different distances

| Distance | without filtering | | | using filtering | | |
|---|---|---|---|---|---|---|
| | *Sensitivity* | *Specificity* | *BA* | *Sensitivity* | *Specificity* | *BA* |
| $R_{min}$ | 90.00 | 62.50 | 76.25 | 90.00 | 71.25 | **80.63** |
| $R_{mc}$ | 95.00 | 66.87 | 80.94 | 95.00 | 68.13 | **81.56** |
| $R_W$ | 95.00 | 60.00 | **77.50** | 80.00 | 65.63 | 72.81 |

## Conclusion

This paper examines the effectiveness of data analysis methods for solving the problem of multiple instance learning with weak labeling. A method for solving this problem is proposed using the selection of an informative feature space, filtering of training set bags, and the use of voting on a set of decision functions.

Results of solving a protein identification problem using the developed method are presented. Comparison results with several known algorithms confirmed the efficiency of the developed algorithm. The method allows to select the most informative feature sets, which is important for improving the quality and interpretability of solutions, and also self-corrects the training set, thereby reducing the impact of various types of errors.

Future plans include testing the method on various data, in particular, for electricity consumption analysis [22]. Further research is also planned to improve the reliability and robustness of weakly supervised recognition. In particular, the development of models and methods is planned for improving the quality of solutions through a combination of target feature correction, sample filtering, and the generation of similar data.

## Acknowledgments

This research was partly funded by the Committee of Science under the Ministry of Science and Higher Education of the Republic of Kazakhstan (grant AP23490529), and partly by the State Contract of Sobolev Institute of mathematics, project No. FWNF-2026-0005.

**References**

1. Fatima, S., Ali, S., Kim, H.-C. A Comprehensive Review on Multiple Instance Learning // Electronics. 2023. – Vol. 12, N. 20. – P. 4323.

2. Dietterich, T.G., Lathrop, R.H., Lozano-Perez, T. Solving the multiple instance problem with axis-parallel rectangles // Artificial intelligence. 1997. – Vol. 89, N 1-2. – P. 31-71.

3. Jia, Y., Zhang, C. Instance-level semisupervised multiple instance learning // In Proceedings of the 23rd national conference on Artificial intelligence. 2008. – Vol. 2. – P. 640-645.

4. Maron, O., Lozano-Perez, T. A framework for multiple-instance learning // Proceedings of the 10th International Conference on Neural Information Processing Systems. 1997; (10):570–576.

5. Gartner, T., Flach, P.A., Kowalczyk, A., Smola, A.J. Multi-instance kernels // In ICML. 2002. – Vol. 2, N 3. – P. 7.

6. Zhou, Z.H., Zhang, M.L. Solving multi-instance problems with classifier ensemble based on constructive clustering // Knowl. Inf.Syst. 2007. – Vol. 11. – P. 155-170.

7. Amores, J. Multiple instance classification: Review, taxonomy and comparative study // Artificial Intellegence. 2013. – Vol. 201. – P. 81-105.

8. He, K., Zhang, X., Ren, S., Sun, J. Deep residual learning for image recognition // In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA. 2016. – P. 770-778.

9. Ilse, M., Tomczak, J., Welling, M. Attention-based deep multiple instance learning. In Proceedings of the International Conferenceon Machine Learning. Stockholm, Sweden. 2018. – P. 2127-2136.

10. Scott, S., Zhang, J., Brown, J. On generalized multiple-instance learning // International Journal of Computational Intelligence and Applications. 2005. – Vol. 5, N 1. – P. 21-35.

11. Li Y., Li, T., Liu, H. Recent advances in feature selection and its applications // Knowledge and Information Systems. 2017. Vol. 53. – P.551-577.

12. Zagoruiko, N.G., Kutnenko, O.A. Recognition methods based on the AdDel algorithm // Siberian Journal of Industrial Mathematics. 2004. – Vol. 7, N 1(17). – P.39-47.

13. Zagoruiko, N.G., Borisova, I.A., Dyubanov, V.V., Kutnenko O.A. Methods of recognition based on the function of rival similarity // Pattern Recognition and Image Analysis. 2008. – Vol. 18, N 1. – P. 1-6.

14. Protein dataset – https://www.dropbox.com/scl/fo/t31oh0tnoqnch4h9n4w2n/AM6vLJJtIAfxD0WE54xHkd0?
dl=0&e=2&preview=Protein.csv&rlkey=lgb2kg8t8eldx7u2564aug3tq (September 6, 2026).

15. Wang, C., Scott, S., Zhang, J., Tao, Q., Fomenko, D., Gladyshev, V. A study in modeling low-conservation protein superfamilies // Tech. Report. TR-UNL-CSE-2004-0003. 2004. Dept. of Comp. Sci., Univ. of Nebraska.

16. Zhang, M.L., Zhou, Z.H. Multi-instance clustering with applications to multi-instance prediction // Applied intelligence. 2009. – Vol. 31. – P. 47-68.

17. Tao, Q., Scott, S., Vinodchandran, N.V., Osugi, T.T. SVM-based generalized multiple-instance learning via approximate box counting // In Proc. of the 21st Internation Conference on Machine Learning. 2004. – P. 799-806.

18. Tao, Q., Scott, S., Vinodchandran, N.V., Osugi, T.T., Mueller, B. An extended kernel for generalized multiple-instance learning // In Proceedings of the 16th IEEE International Conference on Tools with Articial Intelligence. IEEE. 2004. – P. 272-277.

19. Tao, Q., Scott, S. A faster algorithm for generalized multiple-instance learning // In Proceedings of the 17th International Florida Articial Intelligence Research Society Conference. 2004. – P. 550-555.

20. Zhang Q.,Goldman S.A. Em-dd: an improved multiple-instance learning technique // Advances in Neural Information Processing Systems 14. MIT Press, Cambridge, MA. 2002. – Vol. 14. – P. 1073-1080.

21. Chen, Y., Wang, J.Z. Image categorization by learning and reasoning with regions // Journal of Machine Learning Research. 2004. – P. 913-939.

22. Tanoni, G., Principi, E., Squartini, S. Multilabel appliance classification with weakly labeled data for non-intrusive load monitoring // IEEE Transactions on Smart Grid. 2022. – Vol. 14, N 1. – P. 440-452.

# ЭКСПЕРИМЕНТАЛЬНЫЙ ДАТАСЕТ ГЕОРАДАРНЫХ ДАННЫХ АРХЕОЛОГИЧЕСКИХ ОБЪЕКТОВ ДЛЯ РЕШЕНИЯ ОБРАТНЫХ ЗАДАЧ И АВТОМАТИЗАЦИИ ИНТЕРПРЕТАЦИИ

**Есимов А.С., Кусаинова А.Т.**

*Евразийский национальный университет им. Л.Н. Гумилёва, Астана, Казахстан*

***АННОТАЦИЯ***

*Сохранение историко-культурного наследия требует внедрения неразрушающих методов обследования подземного пространства, что делает актуальным применение малоглубинной геофизики — в частности, метода георадиолокации (GPR) — на археологических памятниках. В работе рассматривается формирование экспериментального датасета полевых георадарных данных, полученных с помощью многоканального георадара ОКО-3 на курганах, сакских захоронениях и средневековых поселениях Казахстана. Набор данных снабжен веренной разметкой геометрии подповерхностных структур, полученной на основе сопутствующих исследований и раскопок. Сформированный репрезентативный массив предназначен для обучения моделей машинного обучения с целью преодоления высокого структурного шума и субъективности визуальной интерпретации, а также для верификации численных алгоритмов решения обратных задач геоархеологии в условиях Казахстана.*

## 1. Введение и актуальность исследования

Сохранение богатейшего историко-культурного наследия Республики Казахстан требует форсированного внедрения современных высокотехнологичных и, что наиболее критично, неразрушающих методов обследования подземного пространства. Территория страны обладает тысячами неисследованных курганов, сакских захоронений и уникальных средневековых поселений, представляющих колоссальный интерес для мировой науки. Традиционные методы археологических изысканий, основанные исключительно на полномасштабных раскопках, обладают фундаментальным недостатком — они необратимо разрушают изучаемый культурный слой памятника, стирая контекст залегания артефактов, и требуют значительных временных и человеческих затрат.

В данном контексте крайне актуальным становится применение методов малоглубинной геофизики, в частности — метода георадиолокации (GPR) [1-2]. Георадиолокация позволяет оперативно получать непрерывные данные о геометрии и свойствах подповерхностных макроструктур бесконтактным способом, сохраняя целостность исторического ландшафта, и обеспечивая высокое пространственное разрешение. Однако практическая интерпретация радарограмм в специфических условиях Казахстана существенно осложняется рядом негативных факторов. К ним относятся высокий уровень структурного и геологического шума, слабая контрастность электрофизических свойств (диэлектрической проницаемости и удельной проводимости) вмещающих пород и искомых археологических объектов, а также доминирующая субъективность традиционных методов визуального анализа волновых полей. Подобная субъективность оператора часто приводит к неоднозначным, а порой и ошибочным результатам интерпретации [3-4].

Для преодоления указанных ограничений и кардинального повышения точности геоархеологического картирования необходим переход к автоматизации интерпретации георадарных данных методами машинного обучения (Machine Learning) и глубоких нейронных сетей. Автоматическое распознавание гипербол дифракции, границ разделов сред и скрытых аномалий обладает высокой практической значимостью. Тем не менее ключевым барьером на пути внедрения ИИ-технологий в георадиолокацию является отсутствие качественных, верифицированных и физически обоснованных обучающих

выборок. В связи с этим целью настоящей работы является формирование экспериментального репрезентативного датасета георадарных данных археологических объектов Казахстана, предназначенного для последующего применения при разработке, обучении и валидации моделей автоматизированной интерпретации.

## 2. Методика формирования экспериментального датасета

Экспериментальный датасет формируется на основе систематического сбора реальных полевых данных, полученных в ходе геофизических экспедиций на опорных объектах историко-культурного наследия Казахстана. Сбор данных осуществляется с использованием современного многоканального георадарного комплекса ОКО-3. Применение многоканальных систем позволяет одновременно регистрировать подповерхностные отражения на различных частотах зондирования и при варьируемой геометрии систем наблюдения (разносе приемник-передатчик), что существенно повышает информативность собираемого массива и позволяет осуществлять более точную реконструкцию электрофизических параметров. На рисунке 1, 2 предоставлены фотоматериалы с курганов.



Рисунок 1 – Фотоматериалы проведения георадиолокационных исследований на археологических объектах



Рисунок 2 – Фотоматериалы проведения георадиолокационных исследований на курганных объектах

После получения данных с многоканального георадарного комплекса ОКО-3, была произведена обработка полученных радиограмм. На рисунке 3 показаны обработанные радарограммы.

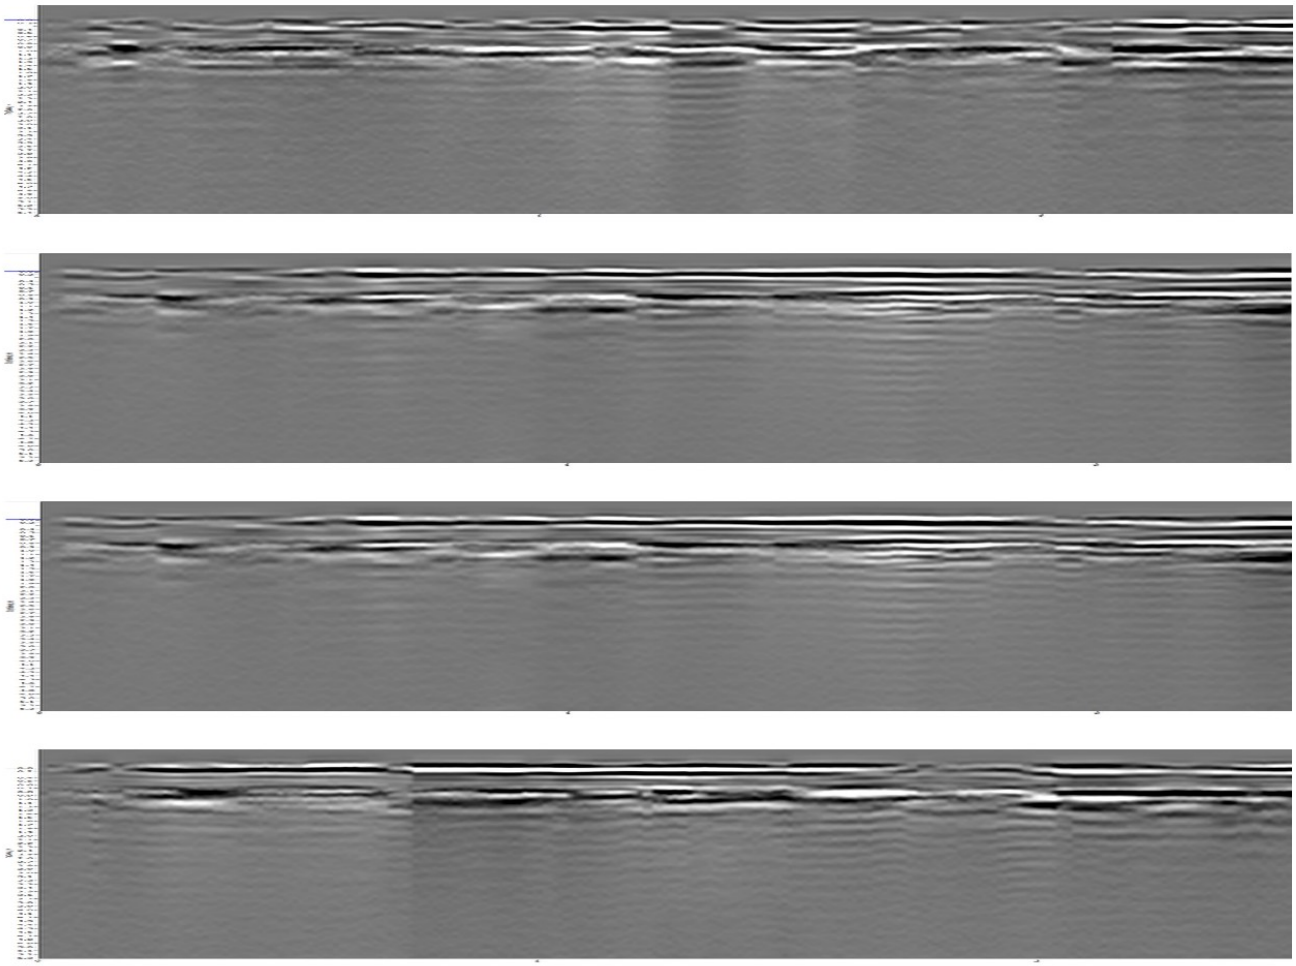


Рисунок 3 – Обработанные радиограммы, полученные с использованием многоканального георадарного комплекса ОКО-3

Обязательным условием формирования датасета является строгое сопровождение полевых измерений фиксацией истинной геометрии подповерхностных структур (Ground Truth). Верификация и геометрическая привязка осуществляются по данным сопутствующих высокоточных исследований: лазерного 3D-сканирования, магниторазведки, тахеометрической съемки, а также по результатам локальных верификационных раскопок и шурфления. В результате каждая радарограмма или трехмерная сборка (3D data cube) снабжается координатно-привязанной матрицей разметки, содержащей точные контуры, глубины залегания и линейные размеры археологических объектов (сырцовые стены, погребальные камеры, пустоты, скопления камней).

## 3. Структура датасета и предварительные результаты

На текущем этапе сформирована пилотная версия датасета, включающая в себя данные по нескольким ключевым археологическим памятникам Казахстана. Весь массив данных структурирован по трем иерархическим уровням: 1) Raw Data — исходные радарограммы в бинарных форматах оборудования ОКО-3 без применения фильтров; 2) Processed Data — данные после проведения стандартного графа цифровой обработки (удаление постоянной составляющей, полосовая фильтрация, регулировка усиления по времени, амплитудный анализ); 3) Ground Truth — размеченные векторные маски геометрии объектов, подготовленные для загрузки в нейросетевые модели.

Таблица 1 – Сводные параметры ключевых профилей экспериментального датасета

| ID Профиля | Тип археологического объекта | Частота антенны (МГц) | Тип вмещающего грунта | Метод верификации геометрии |
|---|---|---|---|---|
| GPR_KRG_01 | Курган (сакский период, насыпь) | 250 / 700 МГц | Суглинки, щебень | Шурфление, магнитометрия |
| GPR_KRG_02 | Погребальная камера кургана | 250 МГц | Супесь суховеистая | Полные раскопки, лазерный сканер |
| GPR_SET_01 | Остатки сырцовой стены поселения | 700 / 1200 МГц | Глина уплотненная | Археологический расчист |
| GPR_CAV_01 | Скрытая подземная пустота / ход | 150 / 250 МГц | Каменистый грунт | Бурение, видеоэндоскопия |

## 5. Ожидаемые результаты и заключение

Главным ожидаемым результатом проводимого исследования является уникальный, первый в Республике Казахстан экспериментальный датасет полевых георадарных данных археологических объектов с соответствующей высокоточной координатной разметкой геометрии подповерхностных структур. Наряду со сформированным массивом данных, научную новизну представляет разработанная авторами методика его построения и постобработки, инвариантная к сложным высокопроводящим и зашумленным грунтам аридных зон.

Сформированный физически обоснованный набор данных рассматривается как строго необходимый и обязательный этап, предшествующий непосредственному построению, обучению и тестированию математических моделей автоматического выделения полезного сигнала методами искусственного интеллекта. Создание данного открытого репозитория позволит консолидировать усилия отечественных и зарубежных специалистов в области геофизики, вычислительной математики и археологии, заложив прочный фундамент под создание сквозных ИТ-решений для цифровой геоархеологии Казахстана.

**Список литературы / References**

1. Daniels D. J. Ground Penetrating Radar. 2nd ed. London: The Institution of Electrical Engineers, 2004. 726 p.

2. Владов М.Л., Старовойтов А.В. Введение в георадиолокацию: учеб. пос. - М.: Изд-во МГУ, 2004. - 153 с.

3. Искаков К.Т., Боранбаев С.А., Кусаинова А.Т. и др. Научно-технические основы для разработки систем георадиолокации. – Астана: ЕНУ, 2017. – 222 с.

4. Кусаинова А.Т., Оралбекова Ж.О., Турарова М.К. және т.б. Шынайы георадар деректері үшін радиолокациялық зерттеулер әдістері мен алгоритмдерін талдау // Университет еңбектері. Автоматика. Энергетика. Ақпаратты-коммуникациялық технологиялар. – 2023. – Т. 93, №4. – Б. 442-447.

# ИНТЕГРАЦИЯ СКВОЗНЫХ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ЗАДАЧИ СОЦИАЛЬНОЙ ИНКЛЮЗИИ: ОПЫТ РАЗРАБОТКИ НАЦИОНАЛЬНОЙ СИСТЕМЫ SURDO AI В УЗБЕКИСТАНЕ

Тастанов М. С.

*Архитектор, руководитель департамента программного обеспечения ГУ «Центр информационных технологий НА СЗ при Президенте РУз», Узбекистан*

*Аннотация. В статье рассматривается архитектурный и прикладной подход к использованию технологий искусственного интеллекта для снижения коммуникационных барьеров между слышащими и глухими или слабослышащими гражданами на примере системы Surdo AI, разрабатываемой в Узбекистане. Описаны предпосылки создания решения, его функциональная экосистема, мультимодальная архитектура, объединяющая компьютерное зрение, распознавание и синтез речи, обработку естественного языка и трехмерную визуализацию жестов. Показаны два ключевых сценария взаимодействия: преобразование жестовой речи в текст и голос, а также преобразование устной или текстовой речи в узбекский жестовый язык посредством 3D-аватара. Рассмотрены образовательный модуль, вопросы масштабирования, расширения датасета, автономного выполнения моделей и интеграции с внешними цифровыми платформами. Сделан вывод о перспективности мультимодальных ИИ-систем как технологической основы цифровой инклюзии и доступности государственных и социальных сервисов.*

*Ключевые слова: искусственный интеллект, Surdo AI, социальная инклюзия, узбекский жестовый язык, компьютерное зрение, 3D-CNN, Vision Transformer, ASR, TTS, NLP, 3D-аватар, цифровая доступность.*

## 1. Введение

Цифровая трансформация социальной сферы требует не только перевода государственных услуг в электронный формат, но и обеспечения реальной доступности цифровых каналов для различных групп населения. Одной из наиболее сложных задач остается коммуникация с глухими и слабослышащими гражданами в ситуациях, где требуется оперативный двусторонний обмен информацией: при обращении в государственные органы, медицинские учреждения, банки, образовательные организации и сервисные центры.

Традиционные средства коммуникации — письменные обращения, текстовые мессенджеры и участие сурдопереводчика — остаются важными, однако не всегда обеспечивают необходимую скорость и доступность взаимодействия. Поэтому перспективным направлением становится применение сквозных технологий искусственного интеллекта, способных объединить распознавание визуальных жестов, обработку речи, синтез голоса и генерацию жестовой последовательности в единой цифровой среде.

Цель работы — представить архитектурные принципы и функциональные сценарии системы Surdo AI как национального прикладного ИИ-решения, ориентированного на цифровую инклюзию, а также определить направления его дальнейшего технологического развития.

## 2. Институциональная база и назначение Surdo AI

Проект Surdo AI разработан в контексте цифровой трансформации социальной сферы Республики Узбекистан. Заказчиком и инициатором выступает Национальное агентство социальной защиты при Президенте Республики Узбекистан, разработчиком — Центр информационных технологий при Агентстве. Такой формат позволяет рассматривать систему не как изолированное экспериментальное приложение, а как элемент формирующейся цифровой инфраструктуры социальной защиты.

Основное назначение Surdo AI состоит в создании технологического посредника между пользователями, использующими устную речь, и пользователями узбекского жестового языка. Мобильный формат обеспечивает возможность применения решения непосредственно в повседневных ситуациях. Публичные карточки приложения подтверждают наличие функций распознавания жестов в реальном времени, преобразования текста и речи в жестовую форму с использованием 3D-аватара, словаря более чем из 1000 слов, дактильного алфавита и обучающих функций.

Практическая ценность подобного подхода определяется тем, что единая программная платформа может одновременно решать коммуникационные и образовательные задачи, постепенно накапливая языковые данные и расширяя сценарии использования.

**3. Мультимодальная архитектура ИИ-решения**

Архитектура Surdo AI строится по мультимодальному принципу: входные данные могут поступать в виде видеопотока, аудиосигнала или текста, а результат формируется в текстовой, речевой либо визуально-жестовой форме. Такая организация требует согласованной работы нескольких классов моделей и сервисных компонентов.

Модуль компьютерного зрения предназначен для анализа жестовой речи по видеопотоку камеры. В проектной архитектуре для моделирования пространственно-временной структуры жеста рассматриваются трехмерные сверточные нейронные сети (3D-CNN) и трансформеры компьютерного зрения (Vision Transformers, ViT). В отличие от распознавания статического изображения, жестовый язык требует учета последовательности кадров, направления и скорости движения рук, взаимного положения кистей и корпуса, а также немануальных компонентов — прежде всего мимики лица.

Речевой контур включает автоматическое распознавание речи (ASR), обработку текстового представления и синтез речи (TTS). ASR преобразует устную узбекскую речь в текст, после чего текст может использоваться как промежуточное представление для отображения, дальнейшей языковой обработки или формирования жестовой последовательности. TTS выполняет обратную задачу — озвучивает текстовый результат, что особенно важно в сценарии, когда пользователь жестового языка формирует сообщение для слышащего собеседника.

Отдельным компонентом является модуль визуализации жестов. Текстовая или распознанная речевая фраза преобразуется в последовательность, воспроизводимую цифровым 3D-аватаром. Такой подход обеспечивает унифицированный визуальный интерфейс и позволяет централизованно совершенствовать анимацию, словарь и правила представления жестов без необходимости записывать отдельное видео для каждого сценария.

**4. Функциональные сценарии взаимодействия**

Первый основной сценарий — «Глухой — Слышащий». Камера мобильного устройства фиксирует жестовую речь пользователя. Видеопоток проходит предварительную обработку и анализ моделью распознавания, после чего система формирует текстовый результат. При необходимости текст озвучивается посредством синтеза речи. Таким образом, визуальный жест преобразуется в форму, доступную слышащему собеседнику.

Второй сценарий — «Слышащий — Глухой». Устная речь поступает через микрофон, преобразуется ASR-модулем в текст, после чего текстовое представление используется для генерации жестовой последовательности. Результат воспроизводится 3D-аватаром. Дополнительно пользователь может вводить текст вручную, что повышает устойчивость коммуникации в шумной среде или при невозможности использования микрофона.

Третье направление — обучение узбекскому жестовому языку. В систему включены словарь, дактильный алфавит, визуальная демонстрация жестов и

упражнения. Использование камеры и ИИ создает предпосылки для автоматизированной обратной связи по выполнению жестов. Такой модуль может быть полезен социальным работникам, медицинскому персоналу, сотрудникам банков и центров государственных услуг, а также всем пользователям, заинтересованным в изучении жестового языка.

**5. Архитектурная схема обработки данных**

В обобщенном виде обработка данных в Surdo AI может быть представлена как последовательность взаимосвязанных уровней: пользовательский интерфейс мобильного приложения; слой захвата видеопотока, аудио и текста; ИИ-сервисы распознавания; слой нормализации и промежуточного текстового представления; сервисы синтеза речи и генерации жестов; 3D-визуализация; интеграционный API. Подобное разделение позволяет независимо развивать отдельные модели и заменять технологические компоненты без полной переработки пользовательского приложения.

Для промышленной эксплуатации принципиально важны управление версиями моделей, журналирование технических событий, контроль времени отклика, мониторинг качества распознавания и безопасная обработка пользовательских данных. При масштабировании также возрастает значение оптимизации вычислительной нагрузки: часть операций может выполняться на серверной стороне, а часть — переноситься непосредственно на пользовательское устройство.

**6. Масштабирование и направления развития**

Качество распознавания жестового языка напрямую зависит от полноты и репрезентативности обучающего набора данных. Поэтому одним из ключевых направлений развития является расширение датасета узбекского жестового языка с учетом различий в исполнении жестов, темпа, ракурса камеры, освещения, антропометрических особенностей пользователей и региональных вариантов.

Второе направление — оптимизация моделей для On-Device AI. Перенос части вычислений на смартфон способен уменьшить задержку, снизить зависимость от качества интернет-соединения и расширить использование системы в местах с ограниченной сетевой инфраструктурой. При этом необходимо сохранять приемлемый баланс между размером модели, энергопотреблением и качеством распознавания.

Третье направление связано с интеграцией API Surdo AI в государственные и коммерческие цифровые платформы. Это позволит использовать жестовый интерфейс не только внутри отдельного приложения, но и в электронных государственных услугах, медицинских информационных системах, образовательных ресурсах и других цифровых каналах. Публично сообщалось и о расширении экосистемы посредством браузерного решения, переводящего интернет-контент в жестовую форму с визуализацией через 3D-аватар.

**7. Социально-экономический эффект**

Технологический эффект Surdo AI связан прежде всего с уменьшением коммуникационного разрыва. Автоматизированный перевод не отменяет необходимость профессионального сурдоперевода в сложных и юридически значимых ситуациях, однако может дополнять существующую инфраструктуру и обеспечивать базовое взаимодействие там, где участие специалиста в конкретный момент недоступно.

Для организаций внедрение подобных решений создает возможность стандартизировать доступный цифровой канал обслуживания и частично снизить нагрузку на сотрудников, выполняющих посреднические функции. Для граждан ключевой эффект состоит в повышении самостоятельности при получении информации и услуг. Образовательный модуль, в свою очередь, расширяет круг людей, знакомых с узбекским жестовым языком, что усиливает инклюзивный эффект за пределами самого программного продукта.

**Заключение**

Surdo AI демонстрирует практический подход к объединению компьютерного зрения, ASR, TTS, обработки естественного языка и 3D-визуализации в единой системе

цифровой инклюзии. Принципиальной особенностью решения является двусторонняя модель коммуникации: система должна понимать жестовую речь и одновременно уметь представлять устную или текстовую информацию в жестовой форме.

Дальнейшее развитие проекта связано с расширением и стандартизацией языкового датасета, повышением устойчивости моделей к реальным условиям съемки, оптимизацией для мобильных устройств, совершенствованием 3D-представления жестов и развитием интеграционного API. При последовательном решении этих задач мультимодальные ИИ-системы могут стать важным компонентом доступной цифровой среды и повысить качество взаимодействия граждан с социальными, государственными и коммерческими сервисами.

Таблица 1. Основные компоненты и функции Surdo AI

| **Компонент** | **Входные данные** | **Результат / функция** |
|---|---|---|
| Computer Vision | Видеопоток жестовой речи | Распознавание жестов и формирование текстового представления |
| ASR | Устная речь | Преобразование речи в текст |
| TTS | Текст | Синтез естественного голоса |
| NLP / текстовый слой | Текстовые маркеры | Нормализация и подготовка представления для последующих модулей |
| 3D-аватар | Текст / жестовая последовательность | Визуальное воспроизведение информации на жестовом языке |
| Обучающий модуль | Словарь, упражнения, видеопоток | Изучение и отработка узбекского жестового языка |

## Литература

1. Тастанов М. С. Интеграция сквозных технологий искусственного интеллекта в задачи социальной инклюзии: опыт разработки национальной системы Surdo AI в Узбекистане: исходные материалы проекта. – 2026.

2. Surdo AI. National Agency of Social Protection // Apple App Store. – 2026. – URL: https://apps.apple.com/uz/app/surdo-ai/id6769377515 (дата обращения: 23.09.2026).

3. SurdoAi. National Agency for Social Protection // Google Play. – 2026. – URL: https://play.google.com/store/apps/details?id=com.ihma.surdoai (дата обращения: 23.09.2026).

4. Постановление Президента Республики Узбекистан от 20.10.2022 № ПП-407 «О дополнительных мерах по развитию узбекского языка жестов и азбуки Брайля».

5. Ijtimoiy himoya milliy agentligi. SURDO AI – internetdagi kontentni ishora tiliga tarjima qiluvchi innovatsion yechim. – 2026. – Официальное информационное сообщение Национального агентства социальной защиты.

# Динамическая причинно-семантическая модель прогрессирования цирроза печени

Tastanova Saida Aldiyarovna
e-mail: tasmaat@mail.ru
Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan

***Аннотация***

*В статье предлагается динамическая причинно-семантическая модель для представления и анализа прогрессирования цирроза печени на основе методов семантического моделирования и интеллектуальной обработки медицинских данных. Актуальность работы обусловлена необходимостью перехода от изолированного анализа отдельных клинических показателей к комплексному представлению состояния пациента, учитывающему взаимосвязи между лабораторными, клиническими и морфологическими признаками. В качестве методологической основы используется подход семантического моделирования, согласно которому сложный объект представляется в виде информационного агрегата, включающего взаимосвязанные информационные сущности, их атрибуты и семантические отношения [1]. На этой основе разработана структура состояния пациента, включающая исходные медицинские данные, семантические признаки, причинно-семантический граф и динамическое состояние заболевания. Предлагаемая модель позволяет формировать последовательность состояний во времени и оценивать изменение модельного риска прогрессирования заболевания. Работа носит концептуально-методологический характер; количественная валидация модели должна выполняться на обезличенных клинических данных.*

***Ключевые слова:*** *семантическое моделирование, искусственный интеллект, цирроз печени, причинно-семантическая модель, медицинские данные, интеллектуальная система поддержки принятия решений, динамическое моделирование.*

## Введение

Цирроз печени представляет собой конечную стадию ряда хронических заболеваний печени, сопровождающуюся прогрессирующим фиброзом, структурной перестройкой ткани и нарушением функционального состояния органа. Этиологические факторы заболевания различны и могут включать хронические вирусные инфекции, метаболические нарушения, алкогольное поражение и другие патологические процессы [5–7].

Современная диагностика заболеваний печени основывается на комплексной оценке анамнеза, клинической картины, лабораторных показателей, результатов инструментальных исследований и характеристик фиброза. В результате формируется значительный объём неоднородной медицинской информации, включающей количественные, категориальные и описательные данные.

Анализ отдельных показателей вне их взаимосвязи не всегда обеспечивает целостное представление о состоянии пациента. Кроме того, хроническое заболевание является динамическим процессом: значение имеет не только состояние пациента в конкретный момент времени, но и характер изменения показателей между последовательными наблюдениями.

В связи с этим актуальной задачей является разработка методов, позволяющих объединять разнородные медицинские данные, устанавливать содержательные отношения между ними и анализировать изменение состояния пациента во времени.

Методологической основой настоящего исследования является метод семантического моделирования, предложенный [1]. В данном подходе сложный объект или процесс представляется в виде информационного агрегата, включающего ядровые,

обозначающие, характеризующие и ассоциативные информационные сущности. Связи между ними устанавливаются посредством семантических операций.

Применительно к заболеваниям печени такой подход позволяет рассматривать клинические и лабораторные показатели не только как отдельные числовые значения, но и как элементы семантических состояний, характеризующих различные аспекты патологического процесса.

**Цель исследования** — разработка динамического причинно-семантического фреймворка для формализованного представления и анализа прогрессирования цирроза печени на основе семантического моделирования медицинских данных, графового представления взаимосвязей и анализа временной динамики состояния пациента.

**1. Семантическое представление состояния пациента**

Пусть состояние пациента в момент времени $t$ характеризуется набором клинических, лабораторных, морфологических и инструментальных признаков. Формально его можно представить вектором:

$$X(t) = [x_1(t), x_2(t), \dots, x_n(t)] \quad (1)$$

где $x_i(t)$ — значение $i$-го признака в момент времени $t$; $n$ — общее количество анализируемых признаков.

Вектор (1) представляет формальную числовую характеристику состояния пациента. Однако для интеллектуального анализа необходимо учитывать содержательное значение каждого признака и его отношение к другим компонентам медицинской информации.

Пусть совокупность исходных данных пациента обозначается $D(t)$. Семантическое представление этих данных определяется посредством преобразования:

$$S(t) = \Phi\left(D(t)\right) \quad (2)$$

где $D(t)$— исходные медицинские данные; Ф— оператор семантического преобразования; $S(t)$ — сформированное семантическое состояние.

В соответствии с методом [1] информационный агрегат может быть представлен следующим образом:

$$S\left(C_1^i \oplus A_0 \oplus C_1^\beta\right), i = 1, \dots, n, \beta = 1, \dots, m \quad (3)$$

где $C_1^i$и $C_1^\beta$представляют соответствующие ядровые информационные сущности; $A_0$ — ассоциативная информационная сущность; $\oplus$— семантическая операция.

Семантическая операция, связывающая информационные сущности, в общем случае может быть представлена отображением:

$$\oplus : C_3\left\{a_j^3\right\} \times A_0\left\{a_j^0\right\} \to C_2\left\{a_j^2\right\} \quad (4)$$

при этом атрибут результирующей информационной сущности определяется как:

$$a_j^2 = a_j^3 \oplus a_j^0 \quad (5)$$

Таким образом, исходные медицинские данные последовательно преобразуются в семантически интерпретируемую структуру:

$$\mathrm{D(t)} \longrightarrow \mathrm{S(t)} \quad (6)$$

Применительно к циррозу печени семантическая структура может включать информационные сущности, характеризующие лабораторное состояние, степень фибротических изменений, функциональное состояние печени, наличие осложнений, сопутствующие состояния и факторы риска.

Принципиальным преимуществом такого представления является возможность объединения данных различных типов в единой информационной модели.

**2. Причинно-семантический граф**

После формирования семантических сущностей необходимо определить отношения между ними. Для этого предлагается использовать ориентированный взвешенный граф:

G=(V,E,W) (7)

где V — множество вершин; E — множество направленных связей; W — множество весовых коэффициентов.

Множество вершин определяется как:

$$V = \{v_1, v_2, \dots, v_m\} \quad (8)$$

Каждая вершина $v_i$ соответствует определённой семантической сущности либо агрегированному состоянию.

Направленная связь между двумя вершинами задаётся следующим образом:

$$e_{ij} = (v_i, v_j), e_{ij} \in E \quad (9)$$

Для каждой связи определяется вес:

$$w_{ij} \in [-1, 1] \quad (10)$$

где $w_{ij}$ характеризует направление и относительную выраженность связи между семантическими сущностями $v_i$и $v_j$.

Положительное значение коэффициента соответствует положительно направленному взаимодействию, отрицательное — противоположно направленному, а значение, близкое к нулю, характеризует слабую связь.

При этом термин «причинно-семантический» не означает, что каждая включённая в граф связь автоматически является доказанной медицинской причинностью. Первоначальная структура графа может формироваться на основании экспертных знаний, опубликованных исследований и анализа клинических данных. Для строгой причинной интерпретации необходима отдельная статистическая и клиническая валидация.

Таким образом, граф G выполняет функцию структурного уровня модели, связывающего отдельные семантические состояния в единую систему.

### 3. Динамическое моделирование прогрессирования заболевания

Состояние пациента с хроническим заболеванием изменяется во времени. Поэтому статического представления $X(t)$недостаточно для анализа прогрессирования цирроза печени.

Предлагается описывать переход между последовательными состояниями пациента следующим образом:

$$X(t+1) = F(X(t), G, U(t)) + \varepsilon(t) \quad (11)$$

где $X(t)$ — состояние пациента в момент времени $t$; $F$ — функция перехода; $G$ — причинно-семантический граф; $U(t)$— дополнительные внешние и внутренние факторы; $\varepsilon(t)$— остаточная составляющая, отражающая влияние факторов, не включённых непосредственно в модель.

Вектор дополнительных факторов задаётся как:

$$U(t) = [u_1(t), u_2(t), \dots, u_k(t)] \quad (12)$$

где $u_j(t)$— значение $j$-го дополнительного фактора, а $k$ — количество таких факторов.

При наличии повторных наблюдений одного пациента формируется временная траектория:

$$T = \{X(t_0), X(t_1), \dots, X(t_T)\} \quad (13)$$

Соответственно, динамика заболевания представляется последовательностью:

$$X(t_0) \longrightarrow X(t_1) \longrightarrow \cdots \longrightarrow X(t_T) \quad (14)$$

Такое представление позволяет анализировать не только абсолютные значения показателей, но и направление их изменения, устойчивость состояния и переход между различными семантическими состояниями.

**4. Формирование интегральной модельной оценки**

Для обобщённого количественного представления состояния пациента вводится интегральная модельная оценка:

$$R(t) = \sigma(Z(t)) \quad (15)$$

где $R(t)$— интегральная модельная оценка в момент времени $t$; $Z(t)$— агрегированная функция семантических признаков; $\sigma$— функция преобразования.

В качестве функции преобразования может использоваться логистическая функция:

$$\sigma(z) = \frac{1}{1+\exp(-z)} \quad (16)$$

Тогда значение интегрального показателя находится в интервале:

$$0 < R(t) < 1 \quad (17)$$

Пусть семантические характеристики пациента представлены вектором:

$$\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T \quad (18)$$

Для учёта как индивидуального вклада признаков, так и взаимодействий между связанными элементами графа предлагается использовать выражение:

$$Z(t) = \beta_0 + \sum_{i=1}^{n} \beta_i s_i(t) + \sum_{(i,j)\in E} w_{ij} s_i(t) s_j(t) \quad (19)$$

где $\beta_0$— свободный параметр; $\beta_i$— коэффициент вклада $i$-го семантического признака; $s_i(t)$— значение семантического признака; $w_{ij}$— коэффициент взаимодействия между связанными элементами графа.

Первое суммирование в (19) описывает индивидуальный вклад семантических признаков. Второе суммирование учитывает взаимодействия между признаками, для которых в графе существует соответствующая связь.

Коэффициенты $\beta_i$ и $w_{ij}$не рассматриваются как универсальные заранее известные медицинские константы. Их значения должны определяться на основании клинических данных, экспертных оценок либо гибридным способом.

Для анализа изменения интегрального показателя между двумя временными точками используется:

$$\Delta R_{t_1,t_2} = R(t_2) - R(t_1) \quad (20)$$

Если

$$\Delta R_{t_1,t_2} > 0 \quad (21)$$

наблюдается увеличение модельной оценки относительно предыдущего состояния.

Если

$$\Delta R_{t_1,t_2} < 0 \quad (22)$$

модельная оценка снижается.

Следует подчеркнуть, что $R(t)$ на концептуальном этапе является **модельным score**, а не непосредственно клинической вероятностью прогрессирования цирроза. Вероятностная интерпретация требует обучения, калибровки и независимой клинической проверки модели.

**5. Семантическая организация медицинских данных**

Пусть исходные медицинские данные пациента представлены множеством:

$$D(t) = \{d_1(t), d_2(t), \dots, d_p(t)\} \quad (23)$$

где $d_i(t)$— отдельный элемент медицинской информации.

Для каждого исходного элемента выполняется семантическое преобразование:

$$d_i(t) \to s_i(t) \quad (24)$$

Полученные признаки могут объединяться в семантические сущности более высокого уровня. Например, обозначим лабораторное состояние как:

$$C_L = \text{Laboratory state} \quad (25)$$

состояние фиброза:

$$C_F = \text{Fibrosis state} \quad (26)$$

функциональное состояние печени:

$$C_H = \text{Liver functional state} \quad (27)$$

состояние осложнений:

$$C_C = \text{Complication state} \quad (28)$$

Между соответствующими информационными сущностями формируется система направленных семантических отношений. В упрощённом виде структурный фрагмент такой системы может быть представлен как:

$$C_L \longrightarrow C_F \longrightarrow C_H \longrightarrow C_C \quad (29)$$

Выражение (29) является именно структурной иллюстрацией организации семантических сущностей. Оно не утверждает существование универсальной линейной биологической причинной цепочки.

Таким образом, процесс преобразования исходных медицинских данных можно представить следующим образом:

$$D(t) \longrightarrow S_L(t) \longrightarrow S_F(t) \longrightarrow S_H(t) \longrightarrow S_C(t) \quad (30)$$

Подобная организация позволяет перейти от отдельных значений показателей к взаимосвязанному представлению состояния пациента.

**6. Общая архитектура предлагаемого фреймворка**

Предлагаемая система включает несколько последовательно взаимодействующих уровней.

На первом уровне формируется совокупность исходных медицинских данных $D(t)$. На втором уровне выполняется семантическое преобразование:

$$D(t) \to S(t) \quad (31)$$

На третьем уровне на основании сформированных семантических сущностей строится граф:

$$S(t) \longrightarrow G = (V, E, W) \quad (32)$$

На четвёртом уровне осуществляется моделирование временной динамики:

$$X(t_0) \longrightarrow X(t_1) \longrightarrow \cdots \longrightarrow X(t_T) \quad (33)$$

На пятом уровне рассчитывается интегральная модельная оценка $R(t)$.

В результате общая архитектура предлагаемого подхода имеет вид:

$$D(t) \longrightarrow S(t) \longrightarrow G \longrightarrow X(t+1) \longrightarrow R(t) \quad (34)$$

Таким образом, осуществляется последовательный переход от первичных медицинских данных к семантической интерпретации, графовому представлению взаимосвязей, динамическому состоянию и итоговой модельной оценке.

1.Медицинские данные. 2.Семантическое преобразование, 3. Причинно-семантический граф, 4. Динамическое моделирование, 5.Интегральная оценка, 6. Поддержка принятия решений.

Таблица 1. Основные компоненты предлагаемой модели

| Компонент | Обозначение | Функциональное назначение |
|---|---|---|
| Исходные медицинские данные | D(t) | Представление клинических, лабораторных и инструментальных данных |
| Семантическое состояние | S(t) | Содержательная интерпретация исходной информации |
| Состояние пациента | X(t) | Формализованное представление состояния в момент времени |
| Граф | G=(V,E,W) | Представление отношений между семантическими сущностями |
| Дополнительные факторы | U(t) | Учёт внешних и внутренних воздействий |
| Семантические признаки | s(t) | Формализованные характеристики семантических состояний |
| Интегральная оценка | R(t) | Обобщённая количественная оценка |
| Траектория | T | Представление изменения состояния во времени |

**7. Подготовка данных и валидация**

Практическая проверка предложенного фреймворка требует использования обезличенной клинической выборки. Общую совокупность данных можно представить следующим образом:

$$\mathcal{D} = \{D_1, D_2, \dots, D_N\} \quad (35)$$

где N — количество пациентов или исследуемых объектов в зависимости от организации набора данных.

Для пациента p, имеющего повторные наблюдения, необходимо сформировать последовательность:

$$D_p(t_0), D_p(t_1), \dots, D_p(t_T) \quad (36)$$

Это принципиально важно для обучения динамической модели, поскольку отдельные записи одного пациента связаны между собой во времени.

Для обучения и объективной проверки алгоритма выборка разделяется на обучающую, валидационную и тестовую части:

$$\mathcal{D} = \mathcal{D}_{train} \cup \mathcal{D}_{val} \cup \mathcal{D}_{test} \quad (37)$$

При этом должно выполняться условие их попарного непересечения:

$$\mathcal{D}_{train} \cap \mathcal{D}_{val} = \mathcal{D}_{train} \cap \mathcal{D}_{test} = \mathcal{D}_{val} \cap \mathcal{D}_{test} = \emptyset \quad (38)$$

Особенно важно выполнять разделение данных **на уровне пациентов**, а не отдельных записей. Если пациент имеет несколько временных наблюдений, все его записи должны относиться только к одной части выборки. В противном случае возникает утечка информации, способная привести к завышенной оценке качества модели.

Структура графа и его параметры могут определяться тремя способами. При экспертном подходе первоначальные связи устанавливаются специалистами предметной области. При data-driven подходе параметры определяются на основании статистического анализа данных. Наиболее перспективным для рассматриваемой задачи

представляется гибридный подход, при котором медицинские и семантические знания определяют исходную структуру, а параметры уточняются по клинической выборке.

После формирования полноценного набора данных качество модели может оцениваться с использованием чувствительности, специфичности, ROC-AUC, F1-меры и показателей калибровки. Поскольку настоящая работа имеет концептуально-методологический характер, конкретные численные значения этих характеристик не приводятся.

**8. Интерпретируемость модели**

Для медицинских интеллектуальных систем существенное значение имеет не только точность прогноза, но и возможность объяснить полученный результат.

В предлагаемой модели вклад отдельного семантического признака может быть представлен следующим образом:

$$I_i(t) = \beta_i s_i(t) \tag{39}$$

Вклад взаимодействия между двумя связанными признаками определяется выражением:

$$I_{ij}(t) = w_{ij} s_i(t) s_j(t) \tag{40}$$

Это позволяет определить, какие семантические признаки и какие взаимодействия между ними внесли наиболее существенный вклад в значение $Z(t)$ а следовательно, и в итоговую оценку $R(t)$.

В перспективной интеллектуальной системе результат может быть представлен врачу в виде совокупности взаимосвязанных элементов: текущего семантического состояния пациента, динамики основных признаков, наиболее значимых элементов графа и изменения интегральной оценки по сравнению с предыдущим наблюдением.

Такой подход принципиально отличается от использования модели как «чёрного ящика», поскольку между исходными данными и итоговой оценкой существует интерпретируемый семантический уровень.

**Заключение**

В работе предложен динамический причинно-семантический фреймворк для моделирования прогрессирования цирроза печени. Методологической основой исследования является метод семантического моделирования, предложенный [1], согласно которому сложный объект представляется посредством системы взаимосвязанных информационных сущностей, атрибутов и семантических операций.

В предложенном подходе исходные медицинские данные преобразуются в семантическое состояние пациента. На основе сформированных сущностей строится ориентированный взвешенный граф, позволяющий формализовать отношения между отдельными компонентами состояния. Введение временной составляющей обеспечивает переход от статического анализа к исследованию траектории заболевания.

Для количественного представления результата введена интегральная модельная оценка $R(t)$, учитывающая индивидуальные семантические признаки и их взаимодействия. При этом подчёркивается, что до проведения обучения, калибровки и клинической валидации данный показатель должен рассматриваться как модельный score, а не как непосредственно установленная вероятность прогрессирования заболевания.

Итоговая схема разработанного подхода имеет вид:

$$D(t) \longrightarrow S(t) \longrightarrow G \longrightarrow X(t+1) \longrightarrow R(t) \tag{41}$$

Научно-методическая значимость предлагаемого подхода заключается в объединении семантического моделирования, графового представления взаимосвязей и временной динамики в рамках единой формальной структуры.

Следующим этапом исследования должно стать формирование обезличенной клинической выборки пациентов с хроническими заболеваниями печени, построение и уточнение причинно-семантического графа, определение параметров модели, её обучение и независимая оценка прогностических характеристик.

Предлагаемый фреймворк может служить методологической основой для дальнейшей разработки интерпретируемой интеллектуальной системы поддержки принятия решений, ориентированной на комплексный анализ динамики состояния пациентов с заболеваниями печени.

**Литература**

1. Rustamov N., Amirtayev K., Tastanova S. The Method of Semantic Modeling // Problems of Computational and Applied Mathematics. – 2025. – № 5(69). – P. 114–122. – DOI: 10.71310/pcam.5_69.2025.09.
2. Rustamov N.T., Temirbekov A.N., Rustamov B.K., Anarbaev Zh.O. Semantic Model of Energy-Informational Medicine // Bulletin of IKTU named after H.A. Yassawi. – 2008. – № 3. – P. 121–131.
3. Israilov R.I., Rustamov N.T., Rustamov B.K. Mathematical Method for Clinical Prediction of Morphological and Morphometric Changes in Cerebral Vessels During Stroke // Electronic Journal of Mathematical and Biomedical Research. – 2009. – Vol. 8, № 1. – P. 7–15.
4. Rustamov N.T., Israilov R.I., Rustamov B.K. On the Issue of Designing a Knowledge Base (Using Stroke as an Example). – Tashkent: Innovatsion rivojlanish nashriyot-matbaa uyi, 2020. – 112 p.
5. World Health Organization. Hepatitis C. – 2026.
6. National Institute of Diabetes and Digestive and Kidney Diseases. Diagnosis of Cirrhosis.
7. World Health Organization. Guidelines for the Prevention, Diagnosis, Care and Treatment for People with Chronic Hepatitis B Infection. – Geneva: WHO, 2024.
8. Ge J., Fontil V., Ackerman S. Clinical Decision Support and Electronic Interventions to Improve Care Quality in Chronic Liver Diseases and Cirrhosis // Hepatology Communications. – 2025.
9. Sunchu K., Desai A.P., Vuppalanchi R., Purkayastha S. A Pilot Feasibility Study of SMARTLiver: a FHIR-Based Clinical Decision Support Application for Cirrhosis // PLOS Digital Health. – 2026. – Vol. 5, № 1. – e0000969. – DOI: 10.1371/journal.pdig.0000969.

# ӘЗІРБАЙЖАН–ҚАЗАҚ ТІЛДІК ЖҰБЫ ҮШІН СИНТЕТИКАЛЫҚ ДЕРЕКТЕР ГЕНЕРАЦИЯСЫ МЕН МОРФОЛОГИЯЛЫҚ ПОСТПРОЦЕССИНГ НЕГІЗІНДЕГІ НЕЙРОНДЫҚ МАШИНАЛЫҚ АУДАРМА ЖҮЙЕСІ

**Сегизбаева Ж.Е.[1], Рахманберді Н.А.[1]**

*[1]Әл-Фараби атындағы Қазақ Ұлттық Университеті, Алматы, Қазақстан*

***Аңдатпа.*** *Мақалада ресурсы шектеулі әзірбайжан–қазақ тілдік жұбы үшін NMT сапасын арттыруға арналған кешенді жүйе ұсынылады. NLLB-200 3.3B негізіндегі кері аударма арқылы синтетикалық корпус жасалып, ережелер негізіндегі Correction Module арқылы галлюциналық қателер мен жалқы есімдердің қате берілуі автоматты түзетілді. Екі тілдің агглютинативті морфологиясын ескеру мақсатында CSE тәсілі әзірбайжан тілі үшін алғаш рет бейімделді. NLLB-200 1.3B моделін тазаланған 500 000 сөйлемдік корпуста fine-tuning жасау BLEU көрсеткішін 22,99-дан 47,84-ке дейін жақсартты. Морфологиялық постпроцессор MAPP-ASR 50 аудиода орташа WER көрсеткішін 46,75%-дан 41,04%-ға дейін төмендетті; параллель MAPP-ASR-KK бағалауы қазақ тілінде де осы тәсілдің тіларалық жалпыланатынын растады.*

## Кіріспе

Нейрондық машиналық аударма (NMT) саласы ресурсы мол тілдік жұптарда жоғары сапаға қол жеткізгенімен, ресурсы шектеулі тілдік жұптарда, соның ішінде әзірбайжан–қазақ жұбында, нәтиже әлі де тұрақсыз болып қалуда [1, 2]. Бұл жұптың басты қиындығы – параллель корпустың тапшылығы және екі тілдің де жетілген агглютинативті морфологиясы: бір негізден жасалатын сөз формаларының саны бірнеше жүзге жетеді, бұл деректердің сиреуіне (data sparsity) тікелей апарады. Осы мәселені шешу мақсатында зерттеу үш бағытты біріктіреді: (1) NLLB-200 3.3B моделі негізіндегі кері аударма арқылы синтетикалық параллель корпус жасау және оны ережелер негізіндегі модуль арқылы тазарту; (2) екі тілдің морфологиялық заңдылықтарын формализациялайтын CSE тәсілін қолдану; (3) аударма шығысын дауысты үндестік заңы мен септік жүйесіне сәйкес түзететін морфологиялық постпроцессор (MAPP) құру.

Зерттеудің ғылыми жаңалығы – параллель деректер сапасын бағалау әдістемесін қолдану, ашық модельдерді нақты тіл жұбы негізінде салыстырмалы талдау, төмен ресурсты тілдер үшін fine-tuning нәтижелерін ұсыну, сондай-ақ CSE негізіндегі морфологиялық постпроцессорды (MAPP) екі тәуелсіз тапсырмада – әзірбайжан тіліндегі ASR (MAPP-ASR) және қазақ тіліндегі ASR (MAPP-ASR-KK) – параллель бағалау арқылы оның тіларалық жалпыланатынын (generalizability) көрсету.

Практикалық маңызы – әзербайжан және қазақ тілдері арасындағы автоматты аударма сапасын арттыру, бұл білім беру, контентті локализациялау және мемлекеттік қызметтерді цифрландыру үшін құнды болып табылады.

## 1. АЗ РЕСУРСТЫ ТҮРКІ ТІЛДЕРІ ҮШІН NMT: ҚЫСҚАША ШОЛУ

Bahdanau және басқалары [1] ұсынған назар аудару механизмі мен Vaswani және басқалары [3] ұсынған Transformer архитектурасы NMT сапасын түбегейлі жақсартса да, Koehn мен Knowles [2] көрсеткендей, деректер тапшылығы мен морфологиялық күрделілік әлі де негізгі кедергі болып қалады. Mirzakhalov және басқалары [4] 22 түркі

тілін қамтитын корпус ұсынып, zero-shot режимде BLEU көрсеткішінің 5–20 аралығында қалатынын анықтады. Sennrich және басқалары [5] ұсынған кері аударма (back-translation) тәсілі осы олқылықты монолингвалды корпустар негізінде толтырудың ең тиімді жолы ретінде танылды, ал Caswell және басқалары [6] ұсынған Tagged Back-Translation синтетикалық және нақты деректерді ажыратып, сапаны 0,5–1,5 BLEU балына арттырды.

Қазақ тілі үшін соңғы жылдары бірнеше маңызды тілдік ресурс жасалды. Tukeyev және басқалары [7] дауысты үндестік заңын ескеретін CSE (Complete Set of Endings) морфологиялық сегментация әдісін жасап, оны қазақ–ағылшын және қазақ–түрік тілдік жұптарындағы NMT тапсырмаларында сынады. Бұл бағыт жуырда Tukeyev-тің [8] қазақ тілінің морфологиясы мен синхармонизмінің есептеу модельдері бойынша, және Segizbayeva мен Miłosz-тың [9] дауысты–дауыссыз үндестіктің толық есептеу моделі бойынша жұмыстарымен жалғасты. Сөйлеу тану саласында Mussakhojayeva және басқалары [10] 1200 сағаттан астам транскрипцияланған аудионы қамтитын KSC2 (Kazakh Speech Corpus 2) корпусын жариялады, ол қазіргі кезде ksc2 және kk-turbo сияқты fine-tined Whisper негіздерін оқытуда қолданылады. Аударма бағытында Yeshpanov және басқалары [11] қазақ, ағылшын, орыс және түрік тілдері арасындағы 371 902 параллель сөйлемнен тұратын KazParC корпусын және Tilmash NMT моделін ұсынды, оның нәтижесі кейбір көрсеткіштер бойынша Google Translate пен Yandex Translate-пен парапар. Дегенмен, бұл ресурстардың бәрі негізінен қазақ–ағылшын, қазақ–орыс немесе қазақ–түрік бағыттарына арналған; қазақ–әзірбайжан тілдік жұбы үшін арнайы параллель корпус немесе fine-tuned NMT моделі бұрын жарияланбаған, бұл осы жұмыстың негізгі олқылықты жабуға бағытталғанын көрсетеді.

## 2 ӘЗІРБАЙЖАН ЖӘНЕ ҚАЗАҚ ТІЛДЕРІНІҢ МОРФОЛОГИЯЛЫҚ ЕРЕКШЕЛІКТЕРІ

Екі тіл де агглютинативті топқа жатады және дауысты үндестік заңын (сингармонизм) сақтайды. Есімді негіздер үшін жалғаулардың мүмкін орналасу саны орналасу формуласы арқылы есептеледі:

$$A_k^n = \frac{n!}{(n-k)!} \quad (1)$$

мұндағы n – аффикс түрлерінің жалпы саны (көптік – К, тәуелдік – Т, септік – С), k – орналастырылатын типтер саны. Семантикалық талдау нәтижесінде әзірбайжан тілі үшін есімді негіздерге 7 негізделген орналасу түрі анықталып, фонетикалық нұсқаларды қоса есептегенде жалғаулар саны 248-ге жетті; етістік негіздерін қоса есептегенде жалпы орналасу түрлерінің саны 28-ді құрады. Қазақ тілі үшін Tukeyev және басқалары [7] дәл осы қағидатпен CSE моделін жасап, 200-ден астам жалғау нұсқасын анықтады.

Морфологиялық қателерден бөлек, қазақ ASR жүйелерінде тұрақты фонетикалық шатасулар байқалады: q/k, ғ/g, ң/n, ө/o, ұ/ү/u, i/ї, h/x, ә/a дыбыс жұптары дауыс тану кезінде жиі алмастырылады. Бұл шатасулар CSE морфологиялық тексерісінен өтуі мүмкін (себебі алмастырылған сөз те заңды морфологиялық құрылымға ие болуы мүмкін), сондықтан кандидат генераторында арнайы фонетикалық ауыстыру кестесі ретінде ескерілуі қажет.

*1-кесте – Әзірбайжан мен қазақ тілдерінің морфологиялық ерекшеліктерін салыстыру*

| **Белгі** | **Әзірбайжан тілі** | **Қазақ тілі** | **NMT үшін маңызы** |
|---|---|---|---|
| Жазу жүйесі | Латын (azj_Latn) | Кирилл (kaz_Cyrl) | NLLB-200-де тіл токендері арқылы шешіледі |
| Септік саны | 6 | 7 | Аударма кезінде грамматикалық сәйкестендіру қажет |

| | | | |
|---|---|---|---|
| Есімдік жалғаулар саны | 248 (CSE) | 200+ (CSE) | Екі тіл үшін жеке CSE кестелері жасалды |
| Лексикалық ұқсастық | ~60–70% | ~60–70% | Негіздер кестесін кері аударма арқылы бейімдеуге мүмкіндік береді |

### 2.1 Қазақ тілінің морфологиялық жүйесі

Қазақ тілі — түркі тілдерінің қыпшақ тобына жататын, жоғары дәрежеде агглютинативті тіл: сөз мағынасы мен грамматикалық қатынастары түбірге кезекпен жалғанатын жұрнақ-жалғаулар тізбегі арқылы беріледі, ал әр морфема, әдетте, тек бір грамматикалық мағынаны білдіреді (флективті тілдерден айырмашылығы). Мысалы, «үйлеріміздің» сөзі үй (түбір) + лер (көптік) + іміз (тәуелдік, 1-жақ көпше) + ден (шығыс септігі) болып төрт морфемаға ыдырайды, әр морфема бір ғана грамматикалық мағынаны қосады.

Қазақ тілінің морфологиясының басты ерекшелігі — дауысты дыбыстар үндестігі (сингармонизм). Бұл заң бойынша жалғаудың дыбысталуы түбірдегі соңғы буынның жуан не жіңішке екеніне қарай реттеледі: жуан буынды түбірге жуан жалғау (мысалы, -дан), ал жіңішке буынды түбірге жіңішке жалғау (-ден) жалғанады (мектептен vs үйден). Бұған қоса, дауыссыз дыбыстардың үндесуі (ассимиляция) жалғаудың бас дыбысын түбірдің соңғы дыбысына қарай өзгертеді (қатаң/ұяң/үнді дыбыстар сәйкестігі). Бұл екі заңдылықтың есептеу моделі жуырда Segizbayeva мен Miłosz [9] жұмысында толық форматталды, ал Tukeyev [7] осы заңдылықтарды нейрондық модельдерде пайдалануға бейімдеген есептеу модельдерін ұсынды.

Септік жүйесі жеті септіктен тұрады (атау, ілік, барыс, табыс, жатыс, шығыс, көмектес), әрқайсысы дауысты үндестігіне сай төрт-бес аллоформа арқылы көрінеді. Тәуелдік жалғаулары иеленуші тұлғаны (жақ) және санын білдіреді (алты тұлға × екі сан = он екі аллоформ жиынтығы), олар септік жалғауларынан бұрын келеді және екеуінің тіркесімінде қосымша фонетикалық өзгерістер болады (мектеп+тің оқушы+лар+ы). Етістік морфологиясы шақ, рай, жақ-жіктік жалғауларынан және болымсыздық жұрнағынан тұрады, олардың тіркесу реті қатаң сақталады.

Бұл морфологиялық күрделілік есептеу тұрғысынан үлкен қиындық тудырады: теориялық тұрғыда бір түбірден жасалатын сөзформалар саны ондаған мыңға жетуі мүмкін, бұл деректің сиреуі (data sparsity) мәселесін күшейтеді және сөздікке негізделген тәсілдерді тиімсіз етеді. Дәл осы себептен бұл жұмыста қолданылған CSE/FEMSeg тәсілі (5-бөлім) сөзді тұтас бірлік ретінде емес, түбір мен жалғаудың заңды комбинациясы ретінде тексереді — бұл дауысты үндестігі мен тәуелдік-септік тіркесімділігін ескеретін, зерттелетін екі тілдің (әзірбайжан және қазақ) морфологиялық құрылымына ортақ принципке негізделген шешім.

### 2.2 Морфологиялық көпмағыналылық

Қазақ тіліндегі жалғаулардың бір бөлігі морфологиялық тұрғыда бірнеше мағынаға ие, бұл автоматты талдауда елеулі қиындық тудырады. Мысалы, -ды жалғауы зат есімнің табыс септігін де (кітапты оқыдым — «кітапты»), етістіктің өткен шағын да білдіре алады (барды — «ол барды»): екі жағдайда да жалғаудың дыбысталуы бірдей, ал ажырату тек негіздің сөз табына қарай жүргізіледі. Дегенмен, негіздер кестесінде сөз табы белгісі болмағандықтан, «кітапты» мен «барды» сияқты жұптарды таза морфологиялық ережемен ажырату мүмкін емес — infinitive-жұрнақ эвристикасы (негіз+у сөздікте бар ма) қолданылғанда «бала» (зат есім) мен «балау» (етістік) сияқты жиі кездесетін омографтарда қате береді. Бұл мәселе негіздің сөз табын корпустағы бірмәнді жалғаулармен қатар кездесу жиілігі бойынша статистикалық анықтау арқылы шешіледі.

Ұқсас көпмағыналылық тәуелдік пен септік жалғауларының тіркесімінде де кездеседі: «үйі» сөзі тәуелдік жалғауының өзі ме (үй+і, «оның үйі»), әлде басқа

сөзформаның бөлігі ме — контекстсіз анық емес. Мұндай жағдайларда дұрыс шешім тек көрші сөзбен синтаксистік үйлесімділікті (мысалы, ілік септігіндегі иеленуші есімдіктің болу-болмауы) ескергенде ғана табылады, бұл — осы жұмыста қолданылған context-aware ранжирлеу тетіктерінің (5-бөлім) морфологиялық валидациямен бірге қолданылу қажеттілігін негіздейді: ереже жалғыз өзі жеткіліксіз, ол контекстік бағалаумен толықтырылуы тиіс.

## 3 СИНТЕТИКАЛЫҚ КОРПУС ГЕНЕРАЦИЯСЫ ЖӘНЕ ТАЗАРТУ

Корпус екі дереккөзден жинақталды: OPUS репозиторийіндегі ашық параллель корпустар (CCAligned, WikiMatrix) [12] және NLLB-200 3.3B [13] моделі арқылы генерацияланған синтетикалық деректер. Кері аударма [5] қағидаты бойынша қазақ тіліндегі монолингвалды сөйлемдер facebook/nllb-200-3.3B моделі арқылы әзірбайжан тіліне аударылды (greedy decoding, beam=1, max_length=512). Осылайша 300 000 және 500 000 сөйлемдік параллель корпустар қалыптастырылды.

NLLB-200 сияқты үлкен модельдер де морфологиялық немесе лексикалық контексте токен қайталану циклдерін (token repetition loops) тудыруы мүмкін [13]. Осы мәселені шешу үшін Python 3.11-де ережелер негізіндегі Correction Module жасалды. Модуль (1) консекутивті токен қайталануын, (2) 3–10 сөздік n-грамм қайталануын regex арқылы анықтап, галлюциналық жолдарды алып тастайды, сондай-ақ (3) trigger-сөзге негізделген ережелер арқылы жалқы есімдер мен тілдік маркерлердің қате аударылуын түзетеді (мысалы, «ҚР» → «Azərbaycan» емес, «Qazaxıstan»). Модуль нейрондық компоненттерді пайдаланбайтындықтан нәтиженің толық қайталанымдылығын (reproducibility) қамтамасыз етеді.

## 4 CSE МОРФОЛОГИЯЛЫҚ МОДЕЛІ ЖӘНЕ NLLB-200 FINE-TUNING

Әзірбайжан тілі үшін алғаш рет CSE (Complete Set of Endings) морфологиялық ресурстары жасалды: 3 595 жол жалғаулар кестесі, 94 жол стоп-сөздер кестесі және қазақ тілінің негіздер кестесінен кері аударма әдісімен алынған 29 000-нан астам негізден тұратын кесте. Алгоритм W = S + E формуласы бойынша сөзді оң жақтан шолып, жалғаулар кестесінен ең ұзын сәйкес E-ні тауып, негізі S негіздер кестесінде расталса ғана сегментация қабылданады.

NLLB-200 1.3B моделі HuggingFace Transformers 4.38 арқылы paged_adamw_8bit оптимизаторымен (learning rate $5\times10^{-5}$, 6 эпоха, batch=2, gradient accumulation=2, FP16) fine-tuning жасалды. Нәтижелер 2-кестеде келтірілген.

*Кесте 2. NLLB-200 1.3B моделінің fine-tuning нәтижелері (500 000 сөйлемдік корпус)*

| Метрика | Zero-Shot | Fine-Tuned (тазаланбаған) | Fine-Tuned (тазаланған) |
|---|---|---|---|
| BLEU ↑ | 22.99 | 37.28 | 47.84 |
| chrF ↑ | 56.81 | 68.14 | 78.41 |
| WER ↓ | 0.66 | 0.49 | 0.37 |
| TER ↓ | 63.39 | 46.37 | 36.13 |

Тазарту корпустың небәрі ~0,4%-ын қамтығанымен, BLEU көрсеткішін 37,28-ден 47,84-ке дейін (+10,56 балл) жақсартты. Бұл нәтиже деректер сапасының мөлшерден маңыздырақ екенін эксперименттік жолмен растайды. Салыстыру үшін, аударма тапсырмасына арнайы pre-training алмаған mT5-base моделінде дәл осы корпуста тазарту тек +1,57 BLEU балын берді – бұл айырмашылық NLLB-200-дің мамандандырылған архитектурасының артықшылығын көрсетеді.

## 5 MAPP ЖӘНЕ MAPP-ASR ПОСТПРОЦЕССОРЛАРЫ

Fine-tuning жоғары нәтиже бергенімен, аударма шығысында дауысты үндестік заңын бұзатын жалғаулар сақталуы мүмкін. Осы мәселені шешу үшін CSE жалғаулар кестесіне негізделген Morphology-Aware Post-Processing (MAPP) модулі жасалды: REF_VOCAB және KK_VOCAB сөздіктерінде расталған нұсқаларға ғана алмастыру орындалады, бұл жалған түзетулерді болдырмайды. FLORES-200 сыртқы тест жиынында MAPP консервативті жұмыс істеп, әр конфигурацияда небәрі 1 алмастыру орындады, бұл сүзгі механизмінің қауіпсіздігін растайды.

MAPP тәсілінің ASR тапсырмасына бейімделген нұсқасы – MAPP-ASR – Whisper (medium)[14] моделінен алынған әзірбайжан тіліндегі транскрипцияны CSE кестелері мен 200-ден астам жазбадан тұратын ASR_NORMALIZE_MAP сөздігі арқылы дұрыстайды. 50 аудиофайлда (саяси, дипломатиялық, экономикалық, діни және басқа домендер) жүргізілген бағалау орташа WER көрсеткішінің 46,75%-дан 41,04%-ға (−5,71 п.т.) төмендегенін, ал BLEU-дың 34,07-ден 42,51-ге дейін өскенін көрсетті; аудиолардың 72%-ында (36/50) жақсарту тіркелді, ең жоғары нәтиже экономикалық доменде (ΔWER −11,5%) байқалды.

Қазақ тіліндегі ASR шығысында бірнеше қате түрі кездеседі: морфологиялық қате (жалғау дұрыс таңдалмауы), лексикалық қате (мүлдем басқа сөзбен алмастыру), түбір-жалғау шекарасындағы қате, фонетикалық шатасу, сөз шекарасын анықтау қатесі (екі сөзді бірге не бөлек жазу) және контекстік қате. Бұл қателердің сипаты акустикалық модель архитектурасына тікелей байланысты: авторегрессивті декодерлер (Whisper) өз ішкі тіл моделінің әсерінен шын мәнінде бар, бірақ қате сөзді таңдайды, ал CTC негізіндегі жүйелер (MMS) тілде мүлдем жоқ әріптер тізбегін тудырады.

Осыған ұқсас тәсіл қазақ тіліндегі ASR шығысын түзету үшін де қолданылды – MAPP-ASR-KK. Эксперименттік корпус денсаулық сақтау саласындағы сұхбаттарды, білім беру бейне-сабақтарын, ғылыми баяндамаларды, AI блогтарды және білім беру платформаларындағы талқылауларды қамтитын 100 аудиожазбадан тұрады (ұзақтығы 30 секундтан 10 минутқа дейін, жалпы ұзақтығы 4,32 сағат). Әзірбайжан тіліндегі MAPP-ASR сияқты, бұл нұсқа да CSE жалғаулар кестесіне негізделген сөздік алмастыруды қолданады: транскрипциядағы сөз тек қазақ тілінің CSE/FEMSeg морфологиялық кестесінде (103 614 стем, 4 547 жалғау) расталған нұсқаға ғана алмастырылады, бұл жалған түзетулерді болдырмайды. Whisper (large-v3) және MMS негіздерінен алынған транскрипцияларда жүргізілген бағалау орташа WER көрсеткішінің large-v3 негізінде 0,42 пунктке, MMS негізінде 0,59 пунктке төмендегенін көрсетті. Нәтиженің шағын болуы – консервативті сүзгі механизмінің (тек сөздікте расталған алмастыру) қауіпсіздігін растайды және әзірбайжан тіліндегі MAPP-ASR-дың FLORES-200 сыртқы тестінде көрсеткен консервативтілігімен сапалық тұрғыдан сәйкес келеді.

## ҚОРЫТЫНДЫ

Зерттеу нәтижесінде әзірбайжан–қазақ тілдік жұбы үшін синтетикалық деректер генерациясы, ережелер негізіндегі тазарту және морфологиялық постпроцессингті біріктірген кешенді NMT жүйесі әзірленді. NLLB-200 1.3B моделін тазаланған 500 000 сөйлемдік корпуста fine-tuning жасау BLEU көрсеткішін 22,99-дан 47,84-ке дейін жақсартты, ал MAPP-ASR жүйесі CSE кестелерінің NMT тапсырмасынан тыс, ASR постпроцессингінде де тиімді тілдік ресурс бола алатынын дәлелдеді. Бұл нәтиже қазақ тіліндегі параллель MAPP-ASR-KK бағалауымен расталды, бұл CSE негізіндегі морфологиялық постпроцессингтің әзірбайжан және қазақ тілдерінің екеуінде де, сондай-ақ NMT мен ASR тапсырмаларының екеуінде де тиімді екенін көрсетеді.

Болашақ зерттеу бағыттары ретінде CSE негіздер кестесін домендік лексикамен кеңейту және екі тілдің морфологиялық ресурстарын одан әрі ұштастыру қарастырылады.

## ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. *Bahdanau, D., Cho, K., & Bengio, Y.* Neural machine translation by jointly learning to align and translate. – ICLR, 2015.

2. *Koehn P., Knowles R.* Six Challenges for Neural Machine Translation // Proc. of the First Workshop on NMT. – 2017. – P. 28–39.

3. *Vaswani A. et al.* Attention Is All You Need // Advances in NeurIPS. – 2017. – P. 5998–6008.

4. *Mirzakhalov J. et al.* A Large-Scale Study of Machine Translation in Turkic Languages // Proc. of EMNLP. – 2021.

5. *Sennrich, R., Haddow, B., & Birch, A.* Improving Neural Machine Translation Models with Monolingual Data. – Proceedings of ACL, 2016.

6. *Caswell I., Chelba C., Grangier D.* Tagged Back-Translation // Proc. of WMT. – 2019. – P. 53–63.

7. *Tukeyev U. et al.* Complete Set of Endings for Kazakh Language: Complete Set of Endings for Agglutinative Language for Neural Text Processing // arXiv preprint. – 2020.

8. *Tukeyev, U. (2025).* Computer Models of Morphology and Synharmonism of the Kazakh Language and Their Use for Neuron Models. Proceedings of the International Scientific and Theoretical Conference "Artificial Intelligence in the Space of Contemporary Art: Problems and Prospects", 12–19.

9. *Segizbayeva, Zh., & Miłosz, M. (2026).* Computational Model of Kazakh Vowel–Consonant Harmony. Journal of Problems in Computer Science and Information Technologies, 4(2), 30–38.

10. *Mussakhojayeva S., Khassanov Y., Atakan Varol H.* KSC2: An Industrial-Scale Open-Source Kazakh Speech Corpus // Proc. Interspeech 2022. – P. 1367–1371.

11. *Yeshpanov R., Polonskaya A., Varol H. A.* KazParC: Kazakh Parallel Corpus for Machine Translation // Proc. LREC-COLING 2024. – P. 9633–9644.

12. *OPUS-MT:* Open Source Machine Translation Models [Электронный ресурс]. – Доступно: https://opus.nlpl.eu/

13. *NLLB Team.* No Language Left Behind: Scaling Human-Centered Machine Translation // arXiv preprint arXiv:2207.04672. – 2022.

14. *Radford A. et al.* Robust Speech Recognition via Large-Scale Weak Supervision (Whisper) // OpenAI Technical Report. – 2022.

# ҚАЗАҚ ТІЛІНДЕГІ БАҒДАРЛАМАЛАУ СҰРАҚ-ЖАУАП ЖҮЙЕСІ ҮШІН МОРФОЛОГИЯҒА БЕЙІМДЕЛГЕН КӨПМІНДЕТТІ ОҚЫТУ

**Уалшер Тукеев, Бекарыс Рысбек**
e-mail: ualsher.tukeyev@gmail.com, r.s.bekarys@gmail.com
*Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан*

***Аңдатпа***

*Морфологиялық құрылымы күрделі тілдерде стандартты fine-tuning сұрақ-жауап сәйкестігін жақсартқанымен, септікке тәуелді сұрақтардың семантикалық репрезентациясын әлсіретуі мүмкін. Бұл мәселені шешу үшін қазақша бағдарламалауды оқытуға арналған сұрақ-жауап жүйесіне бейімделген KazMorph-MTL көпміндетті fine-tuning әдісі ұсынылады: ол сұрақ-жауап сәйкестендірумен қатар бағдарламалық ниетті анықтау, септік-рөлдерді болжау және морфологиялық көріністердің сәйкестігін сақтау міндеттерін біріктіреді. 12 799 жазбадан тұратын корпуста (1 280 тест жазбасы) KazMorph-MTL Standard Fine-Tuned MiniLM жауап сапасын сақтай отырып, сұрақ репрезентацияларының ұқсастығын статистикалық мәнді түрде жақсартты (MeanCos@1: 0.815767→0.869675; p=0.0001).*

***Кілт сөздер:*** *қазақ тіліндегі сұрақ-жауап; бағдарламалауды оқыту; морфологияға бейімделген оқыту; көпміндетті fine-tuning; септік рөлдері; MiniLM.*

## 1. Кіріспе

Бағдарламалауды оқытуда сұрақ-жауап жүйелері оқушыға қажетті түсіндірмені жылдам алуға және дербес оқу процесін қолдауға мүмкіндік береді, бірақ ресурсы шектеулі тілдерде жүйенің сапасы модельдің қазақ тілінің грамматикалық және морфологиялық ерекшеліктерін қаншалықты дұрыс бейнелей алатынына да байланысты. Қазақ тілі агглютинативті болғандықтан, көптеген грамматикалық қатынастар сөз тәртібі арқылы емес, жалғаулар арқылы беріледі: мысалы, «тізімге қосу», «тізімнен өшіру» және «тізімді өзгерту» тіркестері бір list ұғымына қатысты болғанымен, әртүрлі операцияны білдіреді. Көптілді sentence encoder модельдері жалпы семантикалық ұқсастықты анықтай алғанымен, қазақ тіліндегі септік формаларын бағдарламалық семантикалық рөлдермен байланыстыруға арнайы үйретілмеген. Біздің эксперименттерде стандартты домендік fine-tuning TokenF1@1, Semantic@1_ext, Recall@3_ext, MRR@3_ext және BERTScoreF1@1 көрсеткіштерін жақсартты, бірақ MeanCos@1 көрсеткішін 0.875786-дан 0.815767-ге дейін төмендетті, яғни сұрақ репрезентацияларының бастапқы семантикалық геометриясын өзгертті.

Осы мәселені шешу үшін бұл зерттеуде KazMorph-MTL - морфологияға бейімделген көпміндетті fine-tuning әдісі ұсынылады. Оның негізгі идеясы - қазақ тілінің морфологиялық ақпаратын жауаптарды кейіннен қайта ранжирлеуде емес, энкодерді оқыту процесінің өзінде пайдалану. Модель бір уақытта төрт өзара байланысты мақсат бойынша оқытылады: сұрақ пен жауапты контрастивті сәйкестендіру, бағдарламалық ниетті анықтау, септік-рөлдерді болжау және морфологиялық көріністердің сәйкестігін сақтау. Зерттеудің негізгі үлесі: (i) 12 799 сұрақ-жауап жазбасынан тұратын, эксперттік тазартудан өткен деректер жиыны; (ii) деректердің өтіп кетуін болдырмайтын, бекітілген кандидаттар жиынынан жауап таңдау протоколы; (iii) KazMorph-MTL әдісінің өзі; (iv) Base MiniLM, Standard Fine-Tuned MiniLM және KazMorph-MTL модельдерін bootstrap сенімділік интервалдары мен жұпталған статистикалық тесттермен салыстыру.

## 2. Әдебиеттерге шолу

Transformer негізіндегі энкодерлер (BERT және т.б.) мәтін мағынасын контекст арқылы бейнелеудің негізгі тәсіліне айналды [1, 2], ал Multilingual BERT мен XLM-R бұл мүмкіндікті ресурсы шектеулі тілдерге кеңейтті [3, 4]. Sentence-BERT тәрізді sentence-transformer модельдері сұрақ пен жауапты бір векторлық кеңістікте бейнелеп,

семантикалық ұқсастықты есептеуге мүмкіндік береді [5, 6] - осы зерттеуде де жауап дәл осы принцип бойынша таңдалады. Домендік fine-tuning модельге терминдер мен жиі кездесетін үлгілерді меңгеруге көмектескенімен, морфологиялық тұрғыдан бай тілдің грамматикалық құрылымын өздігінен толық игермейді. Көпміндетті оқыту қосымша, мағыналық жағынан байланысты міндеттер арқылы модель репрезентацияларын тұрақтырақ етуі мүмкін [7–9]. Subword tokenization сөздік қорының сиректігін азайтады, бірақ сөзді бөлшектеу оның грамматикалық қызметін түсінумен бірдей емес [11], әсіресе цифрлық ресурстары аз тілдер үшін [12] (метрика ретінде BERTScore [10]; іске асыру - Hugging Face Transformers [13]). KazMorph-MTL осы олқылықты толтырып, қазақ тіліндегі септік-рөл ақпаратын негізгі сұрақ-жауап міндетімен бірге оқытады.

## 3. Материалдар мен әдістер

### *3.1 Деректер жиыны және міндет анықтамасы*

Зерттеуде қазақ тілінде Python бағдарламалауын оқытуға арналған, эксперттік тазартудан (техникалық дұрыстық, мағыналық сәйкестік, педагогикалық анықтық, грамматикалық дұрыстық бойынша) өткен 12 799 сұрақ-жауап жазбасынан тұратын деректер жиыны пайдаланылды. Канондық сұрақтар бойынша топтастырылған бөлу арқылы деректер 11 519 оқыту және 1 280 тест жазбасына бөлінді, оқыту мен тест жиындарының қабаттаспауы тексерілді. Бағаланатын жүйелер жаңа жауапты еркін түрде құрастырмайды: тест сұрағы векторлық түрде кодталып, оқыту жиынындағы кандидат сұрақтармен косинустық ұқсастық бойынша салыстырылады, ал ұқсастығы ең жоғары сұраққа сәйкес жауап қорытынды жауап ретінде қабылданады. Кандидат жауаптар тек оқыту жиынынан алынды, бұл тест жауаптарының модельге алдын ала көрінуін болдырмайды.

### *3.2 Модельдер және KazMorph-MTL әдісі*

Үш конфигурация салыстырылды:

(i) BASE_MINILM - қосымша оқытусыз алдын ала оқытылған көптілді MiniLM;

(ii) STANDARD_FT_MINILM - сұрақ пен жауаптың сәйкестігін үйренетін стандартты домендік fine-tuning;

(iii) KAZMORPH_MTL_MINILM - сол негізгі міндетпен қатар морфологиялық қосымша міндеттерді қоса оқытылатын ұсынылған әдіс. Екі fine-tuned модельге де бірдей параметрлер қолданылды: 5 epoch, batch size 32, 210 warm-up steps, learning rate $2\times10^{-5}$.

KazMorph-MTL үшін жалпы оқыту мақсаты:

$$L_{total} = L_{QA} + 0{,}30\cdot L_{intent} + 0{,}30\cdot L_{case\_role} + 0{,}20\cdot L_{morph\_view}$$

түрінде анықталады, мұнда L_QA - негізгі сұрақ-жауап сәйкестендіру шығыны; L_intent - сұрақтың бағдарламалық мақсатын анықтау шығыны; L_case_role - қазақ тіліндегі септік-рөлдерді болжау шығыны (Кесте 1); L_morph_view - бастапқы сұрақ пен оның морфологиялық ақпаратпен толықтырылған нұсқасы арасындағы сәйкестікті сақтау шығыны. Септік-рөл белгілері алдын ала анықталған лингвистикалық ережелер арқылы автоматты түрде жасалады және тек оқыту сигналы ретінде пайдаланылады; қорытынды жауап таңдау кезінде барлық жүйелер бірдей бекітілген кандидаттар протоколы бойынша бағаланады.

*Кесте 1. KazMorph-MTL-де қолданылған қазақ тіліндегі септік көрсеткіштері мен семантикалық рөлдер*

| Септік көрсеткіші | Мағыналық рөлі | Бағдарламалаудағы мысал |
|---|---|---|
| -ға / -ге / -қа / -ке | Әрекеттің мақсаты | «тізімге қосу» - элементті тізімге қосу |
| -дан / -ден / -тан / -тен | Әрекеттің бастапқы көзі | «тізімнен өшіру» - элементті тізімнен алып тастау |
| -ны / -ні / -ды / -ді | Тікелей объект | «тізімді өзгерту» - тізімді объект |

| Септік көрсеткіші | Мағыналық рөлі | Бағдарламалаудағы мысал |
|---|---|---|
| | | ретінде өзгерту |
| -да / -де / -та / -те | Әрекет орындалатын орта/контекст | «циклде қолдану» - әрекетті цикл ішінде орындау |
| -ның / -нің / -дың / -дің | Иелік/атрибуттық қатынас | «функцияның мәні» - функцияға қатысты мән |
| -мен / -бен / -пен | Әрекетті орындау құралы | «функциямен өңдеу» - деректі функция арқылы өңдеу |

### *3.3 Бағалау протоколы*

Модельдер Exact@1, Top-3 ExactHit, TokenF1@1, MeanCos@1, ExternalAnswerCos@1, Semantic@1_ext, Recall@3_ext, MRR@3_ext және BERTScoreF1@1 метрикалары бойынша салыстырылды (Semantic@1_ext, Recall@3_ext үшін косинустық ұқсастықтың 0,85 шекті мәні). Қорытынды бағалау толық тест жиынында (N = 1 280) жүргізілді: әр метрика үшін 95% сенімділік интервалдары 10 000 рет bootstrap қайта іріктеу арқылы, ал жүйелер арасындағы статистикалық мәнділік бірдей тест жазбалары бойынша екіжақты жұпталған рандомизациялық (таңбаны ауыстыру) тест арқылы (10 000 қайта іріктеу) есептелді.

## 4. Нәтижелер

*Кесте 2. Base MiniLM, Standard Fine-Tuned MiniLM және KazMorph-MTL жүйелерін толық тест жиынында салыстыру (N = 1 280)*

| Метрика | Base MiniLM | Standard FT MiniLM | KazMorph-MTL |
|---|---|---|---|
| Exact@1 | 0.003125 | 0.006250 | 0.006250 |
| Top-3 ExactHit | 0.004687 | 0.007812 | 0.007812 |
| TokenF1@1 | 0.390878 | 0.459697 | 0.461577 |
| MeanCos@1 | 0.875786 | 0.815767 | 0.869675 |
| ExternalAnswerCos@1 | 0.710372 | 0.759940 | 0.761251 |
| Semantic@1_ext | 0.250781 | 0.353125 | 0.352344 |
| Recall@3_ext | 0.364063 | 0.491406 | 0.489063 |
| MRR@3_ext | 0.300651 | 0.413802 | 0.410807 |
| BERTScoreF1@1 | 0.905178 | 0.916617 | 0.916766 |

Standard Fine-Tuned MiniLM Base MiniLM-мен салыстырғанда TokenF1@1, Semantic@1_ext, Recall@3_ext, MRR@3_ext және BERTScoreF1@1 көрсеткіштерін жақсартты, бірақ MeanCos@1 мәнін 0,875786-дан 0,815767-ге дейін төмендетті (Кесте 2). KazMorph-MTL Standard Fine-Tuned MiniLM деңгейіндегі жауап сапасын негізінен сақтады (TokenF1@1, ExternalAnswerCos@1 және BERTScoreF1@1 бойынша аздап жоғары нәтиже), ал MeanCos@1 көрсеткішін 0,869675-ке дейін қалпына келтірді. Жұпталған bootstrap талдауда нөлді қамтымаған жалғыз интервал - MeanCos@1 ($\Delta$ = 0,053907; 95% CI [0,051915; 0,055853]; p = 0,0001); қалған сегіз метрика бойынша айырмалар статистикалық мәнді болған жоқ (p > 0,4).

Толық тест жиынының морфологиялық белгісі бар 1 151 жазбадан (89,9%) тұратын диагностикалық ішкі жиынында да дәл осындай үрдіс байқалды: KazMorph-MTL MeanCos@1-ді қалпына келтірді, ал басқа метрикалар Standard Fine-Tuned MiniLM деңгейінде қалды. Демек, KazMorph-MTL-дің дәлелденген негізгі әсері - сұрақ эмбеддингтерінің ұқсастық құрылымын статистикалық мәнді түрде жақсарту, ал жауап таңдаудың басқа метрикалар бойынша дербес жақсаруы бұл экспериментпен расталмады.

## 5. Талқылау және қорытынды

Нәтижелер морфологиялық ақпаратты жауапты кейін қайта ранжирлеуде емес, энкодерді оқыту кезінде тікелей пайдаланудың әлеуетін көрсетеді. KazMorph-MTL-ді ережелерге негізделген жауап таңдау жүйесі ретінде түсінбеу керек: септік-рөл белгілері тек оқыту сигналы ретінде қолданылады, ал қорытынды жауап барлық

жүйелер үшін бірдей бекітілген кандидаттар протоколы бойынша таңдалады. Бұл - қазақ тілінің морфологиялық құрылымын энкодердің семантикалық репрезентациясына енгізуге бағытталған оқыту стратегиясы.

Зерттеу бірқатар шектеулерге ие. Біріншіден, эксперимент қазақ тіліндегі Python бағдарламалауына арналған бір деректер жиынында, бір бекітілген бөлумен және бір кездейсоқ бастапқы мәнмен (seed = 42) жүргізілді; әдісті басқа пәндік салаларда, тілдерде және бірнеше seed бойынша тексеру қажет. Екіншіден, бағдарламалық мақсат пен септік-рөл белгілері алдын ала анықталған лингвистикалық ережелер арқылы автоматты түрде қалыптастырылды - мамандар қолмен тексерген бағалау жиыны нәтижелерді дәлірек растар еді. Үшіншіден, жүйе жаңа жауапты еркін түрде құрастырмай, тек бекітілген кандидаттар арасынан таңдайтындықтан, қорытындыларды генеративті сұрақ-жауап жүйелеріне тікелей жалпылауға болмайды. Соңында, абляциялық эксперименттер орындалмағандықтан, байқалған әсерді тек морфологиялық міндеттерге телу де ерте.

Қорытындылай келе, KazMorph-MTL қазақ тіліндегі бағдарламалау сұрақтарына арналған энкодерлік сұрақ-жауап жүйесіне морфологиялық ақпаратты оқыту деңгейінде біріктіретін көпміндетті fine-tuning әдісі ретінде ұсынылды. Әдіс Standard Fine-Tuned MiniLM деңгейіндегі жауап сапасын негізінен сақтай отырып, сұрақ репрезентацияларының ұқсастық құрылымын статистикалық мәнді түрде жақсартты (MeanCos@1: 0,815767 → 0,869675; p = 0,0001). Болашақ зерттеулерде модельді бірнеше seed бойынша қайта оқыту, толық эксперттік бағалау жүргізу және негізгі компоненттердің үлесін анықтайтын эксперименттер өткізу жоспарлануда.

**Пайдаланылған әдебиеттер тізімі**

1. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser L., Polosukhin I. Attention is all you need // Advances in Neural Information Processing Systems. - 2017. - Vol. 30. - P. 5998-6008.

2. Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-training of deep bidirectional transformers for language understanding // Proceedings of NAACL-HLT. - Minneapolis, MN, USA, 2019. - P. 4171-4186. DOI: 10.18653/v1/N19-1423.

3. Conneau A., Khandelwal K., Goyal N., Chaudhary V., Wenzek G., Guzman F., Grave E., Ott M., Zettlemoyer L., Stoyanov V. Unsupervised cross-lingual representation learning at scale // Proceedings of ACL. - Online, 2020. - P. 8440-8451. DOI: 10.18653/v1/2020.acl-main.747.

4. Pires T., Schlinger E., Garrette D. How multilingual is multilingual BERT? // Proceedings of ACL. - Florence, Italy, 2019. - P. 4996-5001. DOI: 10.18653/v1/P19-1493.

5. Reimers N., Gurevych I. Sentence-BERT: Sentence embeddings using Siamese BERT-networks // Proceedings of EMNLP-IJCNLP. - Hong Kong, China, 2019. - P. 3982-3992. DOI: 10.18653/v1/D19-1410.

6. Reimers N., Gurevych I. Making monolingual sentence embeddings multilingual using knowledge distillation // Proceedings of EMNLP. - Online, 2020. - P. 4512-4525. DOI: 10.18653/v1/2020.emnlp-main.365.

7. Caruana R. Multitask learning // Machine Learning. - 1997. - Vol. 28. - P. 41-75. DOI: 10.1023/A:1007379606734.

8. Ruder S. An overview of multi-task learning in deep neural networks // arXiv:1706.05098. - 2017. - P. 1-14. DOI: 10.48550/arXiv.1706.05098.

9. Kendall A., Gal Y., Cipolla R. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics // Proceedings of CVPR. - Salt Lake City, UT, USA, 2018. - P. 7482-7491. DOI: 10.1109/CVPR.2018.00781.

10. Zhang T., Kishore V., Wu F., Weinberger K.Q., Artzi Y. BERTScore: Evaluating text generation with BERT // Proceedings of ICLR. - Addis Ababa, Ethiopia / virtual, 2020. - P. 1-43.

11. Sennrich R., Haddow B., Birch A. Neural machine translation of rare words with subword units // Proceedings of ACL. - Berlin, Germany, 2016. - P. 1715-1725. DOI: 10.18653/v1/P16-1162.

12. Joshi P., Santy S., Budhiraja A., Bali K., Choudhury M. The state and fate of linguistic diversity and inclusion in the NLP world // Proceedings of ACL. - Online, 2020. - P. 6282-6293. DOI: 10.18653/v1/2020.acl-main.560.

13. Wolf T., Debut J., Sanh V., Chaumond J., Delangue C., Moi A., Cistac P., Rault T., Louf R., Funtowicz M., Davison J., Shleifer S., von Platen P., Ma C., Jernite Y., Plu J., Xu C., Le Scao T., Gugger S., Drame M., Lhoest Q., Rush A.M. Transformers: State-of-the-art natural language processing // Proceedings of EMNLP: System Demonstrations. - Online, 2020. - P. 38-45. DOI: 10.18653/v1/2020.emnlp-demos.6.

ӘОЖ 004.85

# ҚАЗАҚ ТІЛДІ МӘТІНДІК ТРАФИКТЕГІ ӘЛЕУМЕТТІК-ИНЖЕНЕРЛІК ҚАУІПТЕРДІ ЖІКТЕУДЕГІ КЛАССИКАЛЫҚ АЛГОРИТМДЕРДІҢ ШЕШІМ ШЕКАРАЛАРЫНЫҢ ДЕГРАДАЦИЯСЫ

Шормакова А.Н., Күмісбек М.Н.*
e-mail: mali.kumisbek@gmail.com
*Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан*

***Аңдатпа.*** *Бұл жұмыста қазақ тіліндегі фишингтік және спамдық хабарламаларды анықтауға арналған классикалық машиналық оқыту алгоритмдерінің (Logistic Regression, Linear SVM, Multinomial Naive Bayes, Random Forest) қарсыластық (adversarial) шабуылдарға төзімділігі зерттеледі. Омоглифтерді алмастыру (латын-кирилл), морфологиялық шуылдар және Юникодтың көрінбейтін таңбаларын (\u200B) енгізу арқылы киберқауіпсіздік сүзгілерінің шешім шекараларының (Decision Boundaries) деградациялану дәрежесі бағаланды. Эксперименттік нәтижелер 5 466 мәтіндік жазбадан тұратын валидацияланған корпус негізінде алынды. Талдау көрсеткендей, сөз деңгейіндегі (Word-level) TF-IDF векторизациясын қолданғанда құрама қарсыластық шабуыл Логистикалық регрессияның F1-көрсеткішін 0.8370-ден 0.2282-ге дейін (деградация 72.74%) төмендетеді. Сонымен қатар, символдық N-граммдардың (Char-level) векторлық кеңістіктің геометриялық тұрақтылығын сақтаудағы тиімділігі дәлелденді.*

Қазіргі уақытта әлеуметтік инженерия қауіпсіздік жүйелерін айналып өтудің ең кең таралған құралына айналды. Қазақстандық киберкеңістіктегі фишингтік және алаяқтық хабарламалардың артуы автоматтандырылған мәтіндік сүзгілерді енгізуді талап етеді. Мәтіндік сүзгілеу жүйелерінде классикалық машиналық оқыту алгоритмдері жоғары есептеу жылдамдығы мен ресурстарды аз талап етуіне байланысты кеңінен қолданылады. Дегенмен, алаяқтар мәтінді визуалды түрде адамның қабылдауы үшін өзгеріссіз қалдыра отырып, машиналық оқыту алгоритмдерін жаңылыстыру мақсатында қарсыластық векторлық шуылдарды белсенді пайдаланады [1]. Қазақ тілінің грамматикалық ерекшеліктері мен кирилл-латын әліпбиінің қатар қолданылуы векторлық кеңістікте қосымша әлсіздіктер тудырады.

Зерттеуде 5 466 нормаланған жазбадан тұратын корпусы пайдаланылды. Деректер жиыны стратификацияланған тәсілмен 80/20 қатынасында оқыту және тестілеу таңдамаларына бөлінді. Модельдердің шешім шекараларын бұзу үшін шабуылдың үш деңгейі моделденді: кирилл әріптерін визуалды ұқсас латын символдарына ауыстыратын омоглифтік алмастыру, қазақ тілінің арнайы әріптерін негізгі фонетикалық баламаларымен алмастыратын морфологиялық шуыл, сондай-ақ омоглифтер, морфологиялық шуыл және сөз араларына Юникодтың нөлдік ені бар көрінбейтін бос орындарын кездейсоқ енгізуден тұратын құрама ауыр шабуыл. Векторизация үшін екі тәсіл салыстырылды: сөз деңгейіндегі TF-IDF (Word-level) және символдық деңгейдегі TF-IDF (Char-level). Модельдер ретінде Logistic Regression, Linear SVM, Multinomial Naive Bayes және Random Forest алгоритмдері таңдалды.

Модельдерді оқыту және бағалау кезеңінде классикалық алгоритмдердің гиперпараметрлері оңтайландырылып, кросс-валидация арқылы шешім шекараларының сипаттамалары тұрақтандырылды. Классикалық мәтіндік жіктеуде TF-IDF векторизациясы сөздердің немесе N-граммдардың жиіліктік салмағын есептеуге негізделгендіктен, сызықтық гипераздылықтар белгілер кеңістігіндегі олардың орналасуына қатты тәуелді болады [2]. Модельдердің сапасын бағалау үшін дисбалансты деректерде дәлдік (Precision) пен толықтықтың (Recall) гармониялық ортасы болып

табылатын $F_1$-көрсеткіші ($F_1$-score) негізгі метрика ретінде таңдалды, себебі ол киберқауіпсіздік жүйелеріндегі жалған оң (False Positive) және жалған терсіз (False Negative) қателіктерді тең бағалауға мүмкіндік береді. Мұндай методологиялық тәсіл векторлық координаттардың ығысуын (feature shift) сан жағынан дәл анықтауды қамтамасыз етті.

Бірінші экспериментте омоглифтік және морфологиялық шабуылдардың Word-level және Char-level TF-IDF векторизацияларына тигізетін әсері жеке бағаланды.

Кесте 1. Оқшауланған омоглифтік және морфологиялық шабуылдар кезіндегі деградациясы

| **Векторизация** | **Модель** | **Clean F1** | **Homoglyph F1** | **Homoglyph DR (%)** | **Typo F1** | **Typo DR (%)** |
|---|---|---|---|---|---|---|
| **Word-level** | Logistic Regression | 0.8370 | 0.4041 | 51.72% | 0.4419 | 47.21% |
| | Linear SVM | 0.9398 | 0.6667 | 29.06% | 0.7523 | 19.95% |
| | Multinomial NB | 0.9187 | 0.7964 | 13.31% | 0.8621 | 6.16% |
| | Random Forest | 0.8954 | 0.4944 | 44.79% | 0.6146 | 31.36% |
| **Char-level** | Logistic Regression | 0.8522 | 0.7547 | 11.44% | 0.6995 | 17.91% |
| | Linear SVM | 0.9565 | 0.9136 | 4.49% | 0.9565 | 0.00% |
| | Multinomial NB | 0.9434 | 0.9302 | 1.40% | 0.9457 | -0.25% |
| | Random Forest | 0.9180 | 0.8621 | 6.10% | 0.8766 | 4.51% |

Талдау көрсеткендей, Word-level TF-IDF векторизациясын қолданғанда сызықтық модельдердің (Logistic Regression) шешім шекаралары күрт бұзылады (DR = 51.72%). Бұған себеп токеннің бір символы өзгергенде, ол сөздік қорында жоқ "белгісіз токенге" айналып, векторизация координатасын нөлге түсіреді. Керісінше, Char-level TF-IDF символдық ішкі жолдарды сақтайтындықтан, Linear SVM моделіндегі деградация небәрі 4.49%-ды құрады. Шектеулі ресурсты (low-resource) қазақ тілі шартында дәстүрлі TF-IDF векторизаторлары лексикалық және грамматикалық вариацияларға аса сезімтал келіп, қарсыластық шуылдар кезінде векторлық кеңістіктің топологиялық тұрақтылығын тез жоғалтады [3]. Сондықтан классикалық модельдердің есептеу жылдамдығы мен ресурстарды аз талап ету артықшылығын сақтай отырып, олардың шешім шекараларын сақтау үшін символдық N-граммдарды қолдану немесе контексттік эмбеддингтерге өту киберқорғаныс сүзгілерінің сенімділігін арттырудың негізгі шарты болып табылады.

Екінші экспериментте ең әлсіз болып табылған Word-level TF-IDF модельдеріне құрама ауыр шабуыл жасалды.

Кесте 2. Сөз деңгейіндегі TF-IDF векторизациясындағы құрама ауыр шабуыл кезіндегі F1-көрсеткішінің шекті деградациясы

| Модель | Clean F1 | Single Attack (Homoglyph) | Heavy Attack (Combined) | Жалпы DR (%) |
|---|---|---|---|---|
| **Logistic Regression** | 0.8370 | 0.4041 | 0.2282 | 72.74% |
| **Random Forest** | 0.8954 | 0.4944 | 0.4419 | 50.65% |
| **Linear SVM** | 0.9398 | 0.6667 | 0.5446 | 42.05% |
| **Multinomial NB** | 0.9187 | 0.7964 | 0.6964 | 24.19% |

Құрама шабуыл Логистикалық регрессияның жіктеу қабілетін толығымен жояды (F1 = 0.2282, деградация 72.74%). Векторлық кеңістікте бөлуші гипержазықтық өзінің аралық зазорын жоғалтады. Multinomial Naive Bayes сөздердің априорлы ықтималдықтарын қосындылау есебінен салыстырмалы түрде жоғары төзімділік (DR = 24.19%) көрсетті.

Сызықтық классификаторлар мен ағаш тәрізді алгоритмдердің (Random Forest) қарсыластық векторлық шуылдарға әлсіздігі дәстүрлі TF-IDF белгілер кеңістігінің шектеулілігімен түсіндіріледі. Сонымен қатар, символдық деңгейдегі (Char-level) векторизацияның көрсеткен жоғары тұрақтылығы қазақ тілінің агглютинативті табиғатына, сөзжасамдық қосымшалардың жиілігіне және морфологиялық ауытқуларға бейімделу қабілетіне тікелей байланысты [4].

Қорытындылай келе, қазақ тілді мәтіндік трафикті өңдеуде сөз деңгейіндегі (Word-level) классикалық ML модельдері қарсыластық омоглифтік және Юникодтық шабуылдарға шамадан тыс сезімтал. Құрама шабуыл кезінде деградация деңгейі 72.74%-ға жетеді. Сызықтық шешім шекаралары векторлық координаттардың ығысуына байланысты тез бұзылады, бұл алаяқтық сүзгілерін оңай айналып өтуге мүмкіндік береді. Қазақ тіліндегі киберқорғаныс жүйелерін жобалауда сөздік векторизаторлардан бас тартып, символдық N-граммдарға (Char-level) көшу немесе векторизацияға дейін міндетті түрде кіріс трафигінің қарсыластық шуылын тексеру ұсынылады.

## Әдебиеттер тізімі

1. Goodfellow I. J., Shlens J., Szegedy C. Explaining and harnessing adversarial examples // arXiv preprint arXiv:1412.6572. – 2014. – 11 p.

2. Yuan X., He P., Zhu Q., Li X. Adversarial examples: Attacks and defenses for deep learning in text and vision domains // IEEE Transactions on Neural Networks and Learning Systems. – 2019. – Vol. 30, No. 9. – P. 2805–2824.

3. Mukhammed-Ali K., Assem S. Applying large language models to spam detection in the Kazakh low-resource language setting // Scientific Reports. – 2026. – Vol. 16, No. 1. – DOI: 10.1038/s41598-026-60445-6.

4. Zhang X., Zhao J., LeCun Y. Character-level convolutional networks for text classification // Advances in Neural Information Processing Systems (NeurIPS 2015). – 2015. – Vol. 28. – P. 649–657.

ӘОЖ 004.934.2

# ТҮРІК ТІЛІН АВТОМАТТЫ ТАНУ НӘТИЖЕЛЕРІН MAPP АРҚЫЛЫ КЕЙІНГІ ӨҢДЕУ: ҮШ ASR ЖҮЙЕСІН САЛЫСТЫРУ

**Омархалиева Н.Г., Тукеев У.А.**
e-mail: nazekaomar749@gmail.com, ualsher.tukeyev@gmail.com
*әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан*
*Омархалиева Н.Г. – магистрант. Тукеев У.А. – техника ғылымдарының докторы, профессор*

***Аңдатпа.*** *Зерттеуде түрік тіліндегі сөйлеуді автоматты тану жүйелерінің нәтижелері және оларды кейінгі өңдеудің тиімділігі қарастырылды. Зерттеудің мақсаты – Whisper-large-v3-turbo, MMS-1B-all және TurkicASR жүйелері арқылы алынған транскрипттердің сапасын салыстыру және MAPP кейінгі өңдеу модулінің олардың нәтижелеріне әсерін бағалау. Экспериментте ұзақтығы кемінде төрт минут болатын 10 түрік тіліндегі аудиожазба пайдаланылды. Әр аудиожазба үш ASR жүйесімен өңделіп, бастапқы және MAPP арқылы түзетілген транскрипттер WER және CER көрсеткіштері бойынша бағаланды. Нәтижелер бастапқы тану дәлдігінің жүйелер арасында айтарлықтай ерекшеленетінін көрсетті. MAPP қолданылғаннан кейін MMS-1B-all жүйесінің WER көрсеткіші 0,4571-ден 0,4485-ке дейін төмендеді, ал TurkicASR және Whisper-large-v3-turbo жүйелерінде WER артты. Талдау пайдалы түзетулермен қатар гиперкоррекция жағдайларының да кездесетінін көрсетті. Алынған нәтижелер кейінгі өңдеудің тиімділігі нақты ASR жүйесінің қателік сипатына тәуелді екенін және оны барлық тану жүйелері үшін әмбебап тәсіл ретінде қарастыруға болмайтынын көрсетеді.*

***Түйін сөздер:*** *сөйлеуді автоматты тану, түрік тілі, ASR, MAPP, кейінгі өңдеу, WER, гиперкоррекция.*

## 1. Кіріспе

Сөйлеуді автоматты тану (Automatic Speech Recognition, ASR) қазіргі тілдік технологиялардың негізгі бағыттарының бірі болып табылады және автоматты транскрипциялау, субтитрлеу, дауыстық интерфейстер мен мультимедиялық деректерді өңдеуде кеңінен қолданылады. Whisper және Massively Multilingual Speech (MMS) сияқты жүйелер көптеген тілдерді өңдеуге қабілетті және көптілді тану жағдайында жоғары тиімділік көрсетеді [1, 2]. Сонымен қатар, тану сапасы әртүрлі тілдер мен сөйлеу деректері үшін бірдей емес, ал алынған транскрипттерде лексикалық және морфологиялық қателер кездесуі мүмкін. Түрік тілінің агглютинативті құрылымы бұл мәселені күрделендіреді: бір түбірге бірнеше қосымшаның жалғануы көптеген сөзформаларды тудырады, сондықтан қателер түбірге де, морфологиялық құрамға да әсер етуі мүмкін [3].

ASR транскрипттерінің сапасын жақсартудың бір тәсілі – оларды кейінгі автоматты өңдеу. Мұндай түзету базалық ASR моделін өзгертпей-ақ тану қателері, лексикалық ақпарат және контекстік тілдік модельдер туралы мәліметтерді пайдалануға мүмкіндік береді [4]. Алайда түзету әрдайым жақсартуға әкелмейді. Udagawa және бірлескен авторлар кейбір жағдайда дұрыс танылған элементтердің өзгертіліп, гиперкоррекция пайда болатынын көрсетеді [5]. Осыған байланысты бірдей кейінгі өңдеу әдісінің әртүрлі тану жүйелеріне әсерін салыстыру маңызды.

Бұл зерттеуде түрік тілін автоматты танудың үш жүйесі – Whisper-large-v3-turbo, MMS-1B-all және TurkicASR – салыстырылып, бір MAPP кейінгі өңдеу модулінің олардың транскрипттеріне әсері бағаланды. MAPP байқалған тану қателері туралы ақпаратты, сыртқы түрік лексикалық ресурсын, морфологиялық тексеруді және түзетуге үміткерлердің контекстік ранжирленуін пайдаланады.

Зерттеудің мақсаты – бірдей түрік аудиожазбалары бойынша үш ASR жүйесі алған транскрипттердің сапасына MAPP әсерін бағалау.

RQ1. Whisper-large-v3-turbo, MMS-1B-all және TurkicASR жүйелерінің түрік тіліндегі тану дәлдігі қаншалықты ерекшеленеді?

RQ2. MAPP қолдану үш ASR жүйесінің әрқайсысының WER және CER көрсеткіштеріне қалай әсер етеді?

## 2. Әдебиеттерге шолу

Түрік тілінің агглютинативті құрылымы сөйлеуді автоматты тану жүйелері үшін негізгі қиындықтардың бірі болып қала береді. Сөзформалардың көп болуы деректердің сиректігін арттырады және оқыту материалында кездеспеген бірліктердің пайда болу ықтималдығын жоғарылатады. Бұл тілдік модельдеуді қиындатып, тану қателерін көбейтуі мүмкін [3, 6–8]. Осы мәселені азайту үшін Turkish ASR зерттеулерінде морфемалық және субсөздік ұсыну тәсілдері, сондай-ақ заманауи терең және трансформерге негізделген модельдер қолданылады [3, 6–8].

Қателермен жұмыс істеудің тағы бір бағыты – алынған ASR транскрипттерін кейінгі өңдеу. Мұндай тәсіл базалық модельді қайта оқытпай, қосымша лексикалық, фонетикалық немесе контекстік ақпараттың көмегімен қалдық қателерді түзетеді [4, 9]. Дегенмен, постөңдеу гиперкоррекцияға да әкелуі мүмкін, сондықтан түзету жүйесінің шығысы әрбір ASR моделі үшін жеке бағалануы қажет [5, 10].

## 3. Материалдар мен әдістер

### 3.1. Эксперименттік деректер мен шарттар

Эксперименттік жиынтыққа әрқайсысының ұзақтығы кемінде төрт минут болатын 10 түрік тіліндегі аудиожазба (A01, A02, A03, A04, A05, A11, A17, A18, A19 және A20) кірді. Әр жазба үшін эталондық транскрипт болды. Барлық жүйелер үшін бірдей аудиожазбалар пайдаланылды. Деректерді өңдеу және бағалау Python көмегімен Google Colab ортасында жүргізілді.

1-кесте. Эксперименттік жиынтықтың негізгі сипаттамалары

| Параметр | Сипаттамасы |
|---|---|
| Тіл | Түрік тілі |
| Аудиожазбалар саны | 10 |
| Ұзақтығы | Әрқайсысы ≥ 4 минут |
| Идентификаторлар | A01–A05, A11, A17–A20 |
| Эталондық транскрипттер | Барлық жазбалар үшін бар |
| ASR жүйелерінің саны | 3 |
| Өңдеу ортасы | Google Colab, Python |

### 3.2. Сөйлеуді автоматты тану жүйелері

Бастапқы транскрипттерді алу үшін Whisper-large-v3-turbo, MMS-1B-all және TurkicASR қолданылды. Әр модель бірдей 10 аудиожазбаны дербес өңдеді. Алынған мәтіндер қосымша түзетусіз сақталып, RAW ASR output ретінде қарастырылды. Бастапқы нәтижелер үшін WER, CER, SacreBLEU және chrF есептелді; негізгі салыстыруда WER және CER қолданылды.

2-кесте. Экспериментке енгізілген ASR жүйелері

| Модель | Сипаттамасы | Эксперименттегі қызметі |
|---|---|---|
| Whisper-large-v3-turbo | Көптілді ASR моделі | RAW-транскрипттерді алу |
| MMS-1B-all | Көптілді ASR моделі | RAW-транскрипттерді алу |

| Модель | Сипаттамасы | Эксперименттегі қызметі |
|---|---|---|
| TurkicASR | Түркі тілдеріне бағытталған ASR моделі | RAW-транскрипттерді алу |

### 3.3. MAPP арқылы кейінгі өңдеу

RAW транскрипттері бірдей MAPP конфигурациясымен өңделді. Кейінгі өңдеу төрт кезеңнен тұрды: түзетуге үміткерлерді қалыптастыру, лексикалық және морфологиялық тексеру, контекстік ранжирлеу және қорытынды нұсқаны таңдау. Үміткерлер байқалған ASR қателері мен сыртқы түрік лексикалық ресурсының негізінде құрылды; морфологиялық ақпарат кандидаттардың жарамдылығын тексеруге, ал Turkish BERT жергілікті контекстке сәйкестігін бағалауға қолданылды. Барлық үш ASR жүйесіне бірдей MAPP құрылымы мен параметрлері қолданылды.

Эксперименттің жалпы схемасы: Audio → ASR → RAW transcript → MAPP → corrected transcript → evaluation.

Эталондық транскрипттерден ақпараттың ағып кетуін азайту үшін grouped held-out evaluation қолданылды. Әр кезеңде тест жазбасы түзету статистикасын қалыптастыруға енгізілмеді. A18 және A19 қайталанатын топ ретінде бірге ұсталды; сондықтан 10 аудиожазба тоғыз тәуелсіз тест тобына бөлінді. Тест жазбасының эталондық транскрипті MAPP түзетулерін таңдауға пайдаланылмады.

### 3.4. Сапаны бағалау

Негізгі метрикалар Word Error Rate (WER) және Character Error Rate (CER) болды. WER алмастырулар, жоюлар және кірістірулер санын эталондық транскрипттегі сөздер санына қатысты есептеу арқылы анықталды; CER осы қағидатпен таңбалар деңгейінде есептелді. RAW және MAPP транскрипттері бірдей нормализациядан өткізіліп, бір эталондық мәтінге қатысты бағаланды.

## 4. Нәтижелер

### 4.1. ASR жүйелерінің бастапқы нәтижелері

Бірінші кезеңде үш ASR жүйесінің RAW транскрипттерінің дәлдігі бағаланды. WER-дің ең төмен мәнін Whisper-large-v3-turbo көрсетті, ал ең жоғары қателік деңгейі TurkicASR жүйесінде байқалды. MMS-1B-all аралық нәтиже көрсетті.

3-кесте. ASR жүйелерінің бастапқы көрсеткіштері

| ASR жүйесі | WER | CER |
|---|---|---|
| Whisper-large-v3-turbo | 0,2283 | 0,1655 |
| MMS-1B-all | 0,4571 | 0,1614 |
| TurkicASR | 0,6018 | 0,2620 |

WER бойынша Whisper-large-v3-turbo ең дәл жүйе болды. Whisper мен MMS жүйелерінің CER мәндері бір-біріне жақын болғанымен, сөз деңгейіндегі қателер айтарлықтай ерекшеленді. TurkicASR екі метрика бойынша да ең жоғары қателік деңгейін көрсетті.

### 4.2. MAPP арқылы кейінгі өңдеудің әсері

RAW транскрипттерге MAPP қолданылғаннан кейін постөңдеу әсері ASR жүйесіне қарай әртүрлі болды.

4-кесте. MAPP қолданғаннан кейін WER көрсеткішінің өзгеруі

| ASR жүйесі | RAW WER | MAPP WER | WER-дің салыстырмалы өзгерісі | Қателер санының өзгерісі |
|---|---|---|---|---|
| MMS-1B-all | 0,4571 | 0,4485 | −1,89% | 62-ге азайды |

| ASR жүйесі | RAW WER | MAPP WER | WER-дің салыстырмалы өзгерісі | Қателер санының өзгерісі |
|---|---|---|---|---|
| TurkicASR | 0,6018 | 0,6158 | +2,31% | 100-ге артты |
| Whisper-large-v3-turbo | 0,2283 | 0,2549 | +11,65% | 191-ге артты |

Оң нәтиже тек MMS-1B-all жүйесінде байқалды: WER 0,4571-ден 0,4485-ке дейін төмендеп, салыстырмалы жақсару 1,89% құрады. Қателердің жалпы саны 62-ге азайды. TurkicASR және Whisper-large-v3-turbo үшін MAPP, керісінше, WER-дің өсуіне әкелді; ең айқын нашарлау Whisper жүйесінде байқалды (+11,65%).

Осылайша, бірдей кейінгі өңдеу алгоритмі барлық үш ASR жүйесіне бірдей әсер етпеді. Бұл MAPP тиімділігінің нақты тану жүйесінің қалдық қателерінің сипатына тәуелді екенін көрсетеді.

## 5. Талқылау

Нәтижелер MAPP әсерінің бастапқы ASR жүйесіне тәуелді екенін көрсетті. MMS үшін кейінгі өңдеу WER-ді төмендетті, ал Whisper және TurkicASR үшін оны арттырды. Жеке алмастыруларды талдау пайдалы түзетулермен қатар (sopbet → sohbet, bisikiklet → bisiklet) гиперкоррекция жағдайлары да болғанын көрсетті. Мұндай нәтиже контекстік немесе морфологиялық тұрғыдан ықтимал кандидаттың міндетті түрде дұрыс түзету бола бермейтінін көрсетеді. Бұл бақылау пост-ASR түзетуде консервативті стратегиялар мен overcorrection тәуекелін бақылау қажеттілігі туралы алдыңғы зерттеулермен сәйкес келеді [5, 10]. Сондықтан кейінгі өңдеу белгілі бір ASR жүйесінің қате профилін ескеріп, таңдамалы түрде қолданылуы тиіс.

## 6. Қорытынды

Зерттеуде түрік тіліндегі үш ASR жүйесі салыстырылып, MAPP модулінің олардың шығыс транскрипттеріне әсері бағаланды. MAPP MMS нәтижесін жақсартты, бірақ Whisper және TurkicASR үшін WER көрсеткішін арттырды. Бұл кейінгі өңдеу тиімділігінің нақты тану жүйесінің қателік құрылымына тәуелді екенін және оны барлық ASR жүйелері үшін әмбебап кезең ретінде қарастыруға болмайтынын көрсетеді.

## Әдебиеттер

1. Radford A., Kim J. W., Xu T., Brockman G., McLeavey C., Sutskever I. Robust Speech Recognition via Large-Scale Weak Supervision // Proceedings of the 40th International Conference on Machine Learning. – 2023. – Vol. 202. – P. 28492–28518.

2. Pratap V., Tjandra A., Shi B., Tomasello P., Babu A., Kundu S. et al. Scaling Speech Technology to 1,000+ Languages // Journal of Machine Learning Research. – 2024. – Vol. 25, No. 97. – P. 1–52.

3. Sak H., Saraçlar M., Güngör T. Morphology-based and sub-word language modeling for Turkish speech recognition // 2010 IEEE International Conference on Acoustics, Speech and Signal Processing. – 2010. – P. 5402–5405. – DOI: 10.1109/ICASSP.2010.5494927.

4. Ma R., Qian M., Gales M., Knill K. ASR Error Correction Using Large Language Models // IEEE Transactions on Audio, Speech and Language Processing. – 2025. – Vol. 33. – P. 1389–1401. – DOI: 10.1109/TASLPRO.2025.3551083.

5. Udagawa T., Suzuki M., Muraoka M., Kurata G. Robust ASR Error Correction with Conservative Data Filtering // Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing: Industry Track. – 2024. – P. 256–266. – DOI: 10.18653/v1/2024.emnlp-industry.20.

6. Tombaloğlu B., Erdem H. Deep Learning Based Automatic Speech Recognition for Turkish // Sakarya University Journal of Science. – 2020. – Vol. 24, No. 4. – P. 725–739. – DOI: 10.16984/saufenbilder.711888.

7. Görmez Y. Customized deep learning based Turkish automatic speech recognition system supported by language model // PeerJ Computer Science. – 2024. – Vol. 10. – e1981. – DOI: 10.7717/peerj-cs.1981.

8. Taşar D. E., Koruyan K., Çılgın C. Transformer-Based Turkish Automatic Speech Recognition // Acta Infologica. – 2024. – Vol. 8, No. 1. – P. 1–10. – DOI: 10.26650/acin.1338604.

9. Zhang Z., Wang Z., Kamma R., Eswaran S., Sadagopan N. PATCorrect: Non-autoregressive Phoneme-augmented Transformer for ASR Error Correction // Interspeech 2023. – 2023. – P. 3904–3908. – DOI: 10.21437/Interspeech.2023-1135.

10. Kuo C.-H., Chen K.-Y. An integrated framework for ASR post-processing with error correction, rescoring, and text-speech matching // APSIPA Transactions on Signal and Information Processing. – 2026. – Vol. 15, No. 1. – P. 223–248. – DOI: 10.1108/ATSIP-07-2025-0069.

# ХВАТИТ ЛИ 64 ПРИМЕРОВ НА КЛАСС? РАСПОЗНАВАНИЕ ТОКСИЧНЫХ ТЕКСТОВ НА КАЗАХСКОМ ЯЗЫКЕ ПРИ МАЛОМ ОБЪЁМЕ РАЗМЕТКИ

**Аубакирова Р.**
e-mail: aubakirova.ramilya@gmail.com
*Казахский национальный университет имени аль-Фараби, Казахстан*

***Аннотация.*** *Ручная разметка обучающих корпусов остаётся узким местом при создании систем, которые распознают токсичные тексты на казахском языке. Мы измерили, как качество классификации зависит от объёма разметки, на двух открытых корпусах: пятиклассовом корпусе оскорбительных текстов (10 190 записей) и бинарном корпусе религиозного экстремизма (39 253 записи). Сравнивались пять подходов, от TF-IDF с логистической регрессией до контрастивного дообучения многоязычных энкодеров предложений (SetFit) и полного дообучения mBERT, при объёме разметки от 8 до 1024 примеров на класс. SetFit с энкодером LaBSE уже при 64 примерах на класс достигает macro-F1 0.83, тогда как mBERT и TF-IDF выходят на этот уровень лишь при 256 примерах; на полных данных SetFit также опережает оба базовых подхода (0.920 против 0.904 и 0.899 на первом корпусе). Для практики это означает: рабочий классификатор можно получить, разметив всего 3-6% корпуса.*

## Введение

Автоматическое распознавание токсичных текстов на казахском языке отстаёт от английского и русского: открытых корпусов мало, и каждый новый приходится размечать вручную. Разметка же дорога вдвойне. Разметчик должен владеть казахским и чувствовать, где кончается резкое высказывание и начинается запрещённое, а в спорных категориях вроде религиозного экстремизма без консультаций с экспертами и вовсе не обойтись.

В опубликованных работах по казахскому языку классификаторы обучают на полностью размеченных корпусах. В [1] собран корпус из 10 190 текстов пяти классов и сравнены классические методы машинного обучения, нейронные сети и трансформеры; лучше всех показал себя BERT (F1 около 0.90). В [2] представлен корпус религиозного экстремизма, на котором сопоставлены шесть классических алгоритмов. Той же схеме - сначала полная разметка, затем сравнение моделей - следует и [8]. Объём разметки во всех этих работах задан заранее, поэтому по ним не понять, какая часть труда разметчиков действительно сказалась на итоговом качестве.

На практике вопрос стоит иначе. Команде, которой нужен фильтр для новой площадки или нового вида токсичности, важно заранее знать, сколько примеров придётся разметить, чтобы добиться приемлемого качества. Ответ зависит от метода обучения. Для классификации текстов по десяткам примеров придуман метод SetFit [3]: энкодер предложений [7] контрастивно дообучается на парах примеров, а поверх полученных векторных представлений обучается логистическая регрессия. Многоязычные энкодеры LaBSE [4] и multilingual-E5 [5] видели казахский язык ещё при предобучении, поэтому связка SetFit с ними сама напрашивается для задачи, где размеченных данных мало.

Мы построили для пяти подходов кривые зависимости качества от объёма разметки на двух открытых казахоязычных корпусах [1, 2]. Насколько нам известно, для казахского языка такого измерения ещё никто не делал.

## Данные

Первый корпус [1] содержит 10 190 текстов из казахоязычных социальных сетей, размеченных по пяти классам: расизм (2205), травля (2136), призывы к насилию (2110), нацизм (2076) и нейтральные тексты (1663). Классы почти сбалансированы. Тестовая выборка - 20% корпуса (2038 текстов); разбиение стратифицированное, с тем же зерном

генератора случайных чисел, что и в коде авторов корпуса, поэтому наши результаты сравнимы с опубликованными.

Второй корпус [2] бинарный: тексты религиозно-экстремистского толка против нейтральных. После удаления точных дубликатов в нём 39 253 записи, из них 1058 экстремистских (2.7%). Такой перекос ближе к реальной модерации, где запрещённый текст - редкость. Тест - стратифицированные 20% (7851 текст, 212 экстремистских), обучающая выборка - 31 402 текста.

Корпуса дополняют друг друга: первый проверяет методы на сбалансированной многоклассовой задаче, второй - на несбалансированной бинарной.

**Методы**

Мы сравнили пять подходов. Базовый уровень - TF-IDF на словных (1-2) и символьных (2-5) n-граммах с логистической регрессией: такой классификатор обучается за секунды на обычном процессоре. Второй подход - логистическая регрессия поверх векторных представлений (эмбеддингов) энкодера предложений, взятого как есть: он показывает, что дают многоязычные эмбеддинги сами по себе, без дообучения. Третий - SetFit [3]: энкодер сначала дообучается контрастивно на парах текстов (пара одного класса сближается, пара разных классов отдаляется), затем поверх обновлённых эмбеддингов обучается логистическая регрессия. Во втором и третьем подходах взяты два энкодера: LaBSE [4] и multilingual-E5-base [5]. Четвёртый подход - полное дообучение mBERT (bert-base-multilingual-uncased) [6] с классификационным слоем, по образцу [1].

Протокол один для всех методов. Из обучающей выборки случайно берётся n примеров на класс, n от 8 до 1024 (для бинарного корпуса - до 512); модель обучается на этой подвыборке и оценивается на фиксированном тесте. Каждая точка усреднена по трём запускам с разными случайными подвыборками, в таблицах приведено стандартное отклонение. Отдельно все методы обучены на полной обучающей выборке. Гиперпараметры зафиксированы и не подбирались ни для одного метода: у SetFit размер батча 32 и одна эпоха контрастивной фазы, у mBERT скорость обучения 2e-5 и настройки из кода [1]. Все расчёты выполнялись на видеокарте RTX 4090 с библиотеками setfit, transformers и scikit-learn.

Для корпуса с перекосом классов понадобилось отдельное правило решения. Модели, обученные на считанных примерах, видят сбалансированные подвыборки, а в тесте позитивных всего 2.7%, поэтому стандартный порог вероятности 0.5 систематически завышает долю предсказанных позитивов. Мы приводим F1 экстремистского класса при правиле top-k (экстремистскими помечаются k текстов с наибольшей предсказанной вероятностью, где k равно числу позитивных в тесте) и AUC-ROC, который от порога не зависит.

**Результаты**

Результаты на пятиклассовом корпусе собраны в таблице 1 и на рис. 1. SetFit с LaBSE идёт первым на всём диапазоне: macro-F1 0.704 при 8 примерах на класс, 0.826 при 64, 0.912 при 1024. Полное дообучение mBERT при 8 примерах разваливается (0.383) и догоняет TF-IDF лишь со 128 примеров. Эмбеддинги без дообучения хороши на старте (0.637 при 8 у LaBSE), но упираются в потолок около 0.85.

*Таблица 1. Macro-F1 на пятиклассовом корпусе (среднее ± стандартное отклонение по трём запускам)*

| n/класс | TF-IDF + LR | mE5 без дообучения | LaBSE без дообучения | SetFit mE5 | SetFit LaBSE | mBERT |
|---|---|---|---|---|---|---|
| 8 | 0.556±0.018 | 0.589±0.028 | 0.637±0.025 | 0.635±0.033 | 0.704±0.032 | 0.383±0.049 |
| 16 | 0.637±0.028 | 0.628±0.014 | 0.691±0.007 | 0.723±0.027 | 0.766±0.015 | 0.572±0.108 |
| 32 | 0.708±0.021 | 0.682±0.019 | 0.731±0.011 | 0.751±0.010 | 0.782±0.014 | 0.688±0.055 |

| | | | | | | |
|---|---|---|---|---|---|---|
| 64 | 0.764±0.009 | 0.738±0.005 | 0.765±0.008 | 0.809±0.019 | 0.826±0.019 | 0.766±0.032 |
| 128 | 0.809±0.003 | 0.776±0.007 | 0.791±0.010 | 0.845±0.007 | 0.858±0.012 | 0.812±0.010 |
| 256 | 0.848±0.005 | 0.800±0.002 | 0.808±0.014 | 0.874±0.003 | 0.878±0.008 | 0.849±0.004 |
| 512 | 0.869±0.005 | 0.824±0.005 | 0.827±0.006 | 0.887±0.006 | 0.896±0.001 | 0.869±0.007 |
| 1024 | 0.890±0.002 | 0.836±0.002 | 0.838±0.005 | 0.904±0.006 | 0.912±0.001 | 0.887±0.006 |
| все (8152) | 0.904 | 0.846 | 0.851 | 0.906±0.002 | 0.920±0.004 | 0.899±0.002 |

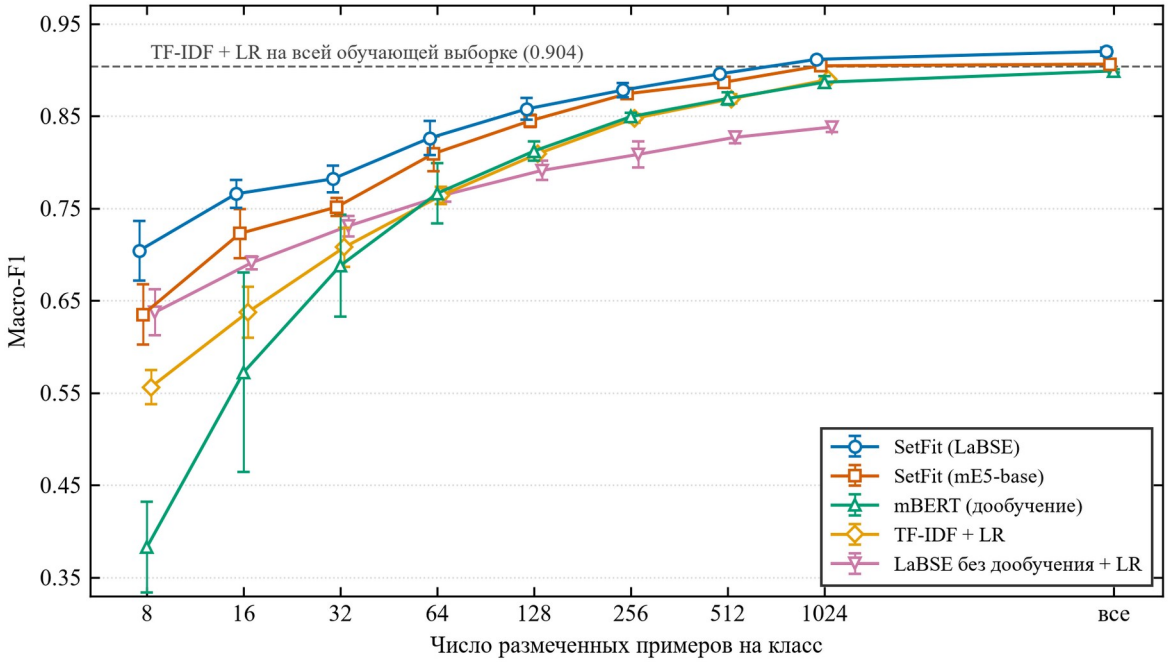



Рис. 1 Зависимость macro-F1 от числа размеченных примеров на класс, пятиклассовый корпус

Практическая точка отсчёта - модели, обученные на полной выборке (8152 текста): TF-IDF выходит на 0.904, BERT авторов корпуса - на 0.9024 [1], наш повторный прогон mBERT - на 0.899. SetFit с LaBSE достигает 0.896 уже при 512 примерах на класс, то есть на трети разметки, а при 1024 примерах (63% разметки) обходит оба полных базовых уровня. На полной выборке SetFit с LaBSE набирает 0.920 - лучший результат на этом разбиении. Цена такого качества - время обучения: SetFit при 64 примерах на класс учится 70-80 секунд на видеокарте, mBERT - несколько секунд, TF-IDF - меньше секунды. Но там, где узкое место - труд разметчика, этот обмен выгоден.

На бинарном корпусе итог зависит от правила решения (таблица 2, рис. 2). При пороге 0.5 модели, обученные на считанных примерах, переоценивают долю позитивных: TF-IDF, обученный на 8 примерах на класс, помечает экстремистскими 36% теста при истинной доле 2.7%, и F1 падает до 0.13. Байесовская поправка порога под истинную долю (порог 0.973) не спасает: у моделей, обученных на десятках примеров, вероятности не откалиброваны, и такого порога не достигает почти ни один текст. Выручает правило top-k, благо ранжирование хорошо с самого начала: AUC у SetFit с LaBSE равен 0.971 уже при 8 примерах на класс.

*Таблица 2. F1 класса «экстремизм» на бинарном корпусе при правиле top-k*

| **n/класс** | **TF-IDF + LR** | **LaBSE без дообучения** | **SetFit mE5** | **SetFit LaBSE** | **mBERT** |
|---|---|---|---|---|---|
| 8 | 0.384±0.011 | 0.517±0.051 | 0.549±0.111 | 0.695±0.060 | — |
| 16 | 0.557±0.075 | 0.616±0.007 | 0.681±0.113 | 0.808±0.029 | 0.483±0.121 |
| 64 | 0.678±0.017 | 0.766±0.022 | 0.781±0.031 | 0.753±0.031 | 0.736±0.017 |
| 256 | 0.777±0.014 | 0.813±0.007 | 0.854±0.037 | 0.865±0.024 | 0.825±0.026 |
| 512 | 0.849±0.008 | 0.829±0.019 | 0.885±0.026 | 0.906±0.017 | — |

| | | | | | |
|---|---|---|---|---|---|
| все (31 402) | 0.929 | 0.854 | 0.964±0.003 | 0.961±0.003 | 0.939±0.005 |

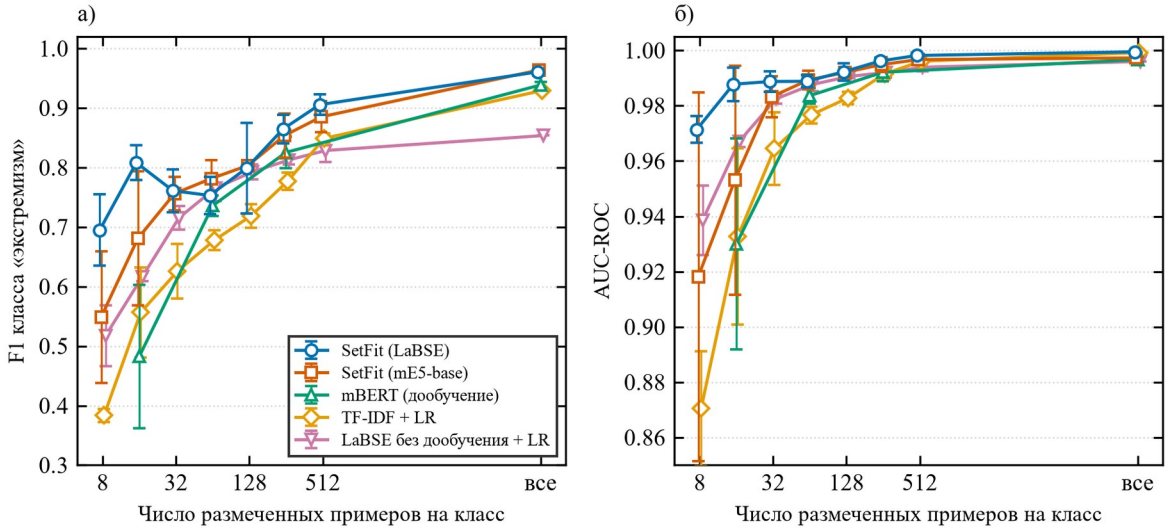



Рис. 2 Бинарный корпус: а) F1 класса «экстремизм» при правиле top-k; б) AUC-ROC

При правиле top-k SetFit с LaBSE на 16 примерах на класс даёт F1 0.808 против 0.557 у TF-IDF и 0.483 у mBERT; при 512 примерах - 0.906 против 0.849. На полной обучающей выборке (порог 0.5, обучение с весами классов) SetFit достигает F1 0.964-0.967, mBERT - 0.939, TF-IDF - 0.924; разрыв между SetFit и mBERT больше, чем разброс каждого из них между запусками. Здесь уместна оговорка о масштабе: в тесте 212 позитивных текстов, так что один пункт F1 - это примерно два текста.

**Обсуждение и ограничения**

У этих результатов есть границы. Тестовое разбиение на каждом корпусе одно; кривые воспроизводимы (зёрна генераторов зафиксированы), но при другом разбиении абсолютные значения могут сдвинуться. Гиперпараметры не подбирались, поэтому методы стоят в равных, но не в лучших для себя условиях; тщательно настроенный mBERT, вероятно, сократил бы разрыв на средних объёмах разметки. Правило top-k предполагает, что доля позитивных известна, - в реальной модерации её пришлось бы оценивать по небольшой контрольной выборке либо заменять порогом, подобранным на отложенных данных. Наконец, экстремистская часть второго корпуса состоит в основном из переводных новостных текстов, поэтому классификатор отчасти опирается на тематические признаки; как он перенесётся на казахоязычные тексты обычных пользователей, нужно проверять отдельно.

**Заключение**

Измерение на двух открытых казахоязычных корпусах даёт практический рецепт. Когда размеченных данных десятки или сотни, контрастивное дообучение многоязычного энкодера предложений (SetFit с LaBSE) выигрывает и у полного дообучения mBERT, и у TF-IDF: 64 примера на класс дают macro-F1 0.83 в пятиклассовой задаче, 16 примеров на класс - F1 0.81 в бинарной, если доля позитивных известна. До уровня моделей, обученных на полном корпусе, SetFit дотягивается на трети разметки, а на полном корпусе превосходит их. Эти цифры можно закладывать в планы новых корпусов токсичных текстов: разметить около сотни примеров на класс, обучить SetFit и расширять разметку лишь до тех пор, пока кривая качества растёт.

## ЛИТЕРАТУРА

1. Bolatbek, M. Detection of offensive content in the Kazakh language using machine learning and deep learning approaches / M. Bolatbek, M. Sagynay, S. Mussiraliyeva, Z. Yeltay // PeerJ Computer Science. – 2025. – Vol. 11. – e3027.

2. Mussiraliyeva, S. Applying machine learning techniques for religious extremism detection on online user contents / S. Mussiraliyeva, B. Omarov, P. Yoo, M. Bolatbek // Computers, Materials & Continua. – 2022. – Vol. 70, N. 1. – P. 915-934.

3. Tunstall, L. Efficient few-shot learning without prompts / L. Tunstall, N. Reimers, U.E.S. Jo, L. Bates, D. Korat, M. Wasserblat, O. Pereg // arXiv preprint arXiv:2209.11055. – 2022.

4. Feng, F. Language-agnostic BERT sentence embedding / F. Feng, Y. Yang, D. Cer, N. Arivazhagan, W. Wang // Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. – Dublin, 2022. – P. 878-891.

5. Wang, L. Multilingual E5 text embeddings: A technical report / L. Wang, N. Yang, X. Huang, L. Yang, R. Majumder, F. Wei // arXiv preprint arXiv:2402.05672. – 2024.

6. Devlin, J. BERT: Pre-training of deep bidirectional transformers for language understanding / J. Devlin, M.-W. Chang, K. Lee, K. Toutanova // Proceedings of NAACL-HLT 2019. – Minneapolis, 2019. – P. 4171-4186.

7. Reimers, N. Sentence-BERT: Sentence embeddings using Siamese BERT-networks / N. Reimers, I. Gurevych // Proceedings of EMNLP-IJCNLP 2019. – Hong Kong, 2019. – P. 3982-3992.

8. Bolatbek, M. Kazakh language dataset for hate speech detection on social media text / M. Bolatbek, M. Sagynay, S. Mussiraliyeva, K. Baisylbayeva, Z. Yeltay // 2024 IEEE 9th International Conference on Computational Intelligence and Applications (ICCIA). – Haikou, 2024.

# ИСПОЛЬЗОВАНИЕ СТОРОННИХ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ КАК ФАКТОР РИСКА УТРАТЫ КУЛЬТУРНОГО КОДА КАЗАХСКОГО ОБЩЕСТВА

Матанов Н.Б.
e-mail: nura7kz@gmail.com
*Докторант кафедры «Информационные системы» КазНУ имени аль-Фараби*
*Рахимова Д.Р.*
e-mail: drakhimova060@gmail.com
*Доцент-исследователь кафедры «Информационные системы» КазНУ имени аль-Фараби*

***Аннотация.*** *В данной статье рассматриваются проблемы разработки больших языковых моделей (LLM) для казахского языка в условиях ограниченных языковых ресурсов. Особое внимание уделяется вопросам токенизации текста, анализу особенностей алфавита и грамматики казахского языка, а также трудностям, возникающим при обработке агглютинативной морфологии. В работе представлен обзор существующих методов токенизации, включая морфологические, статистические, нейросетевые и гибридные подходы. Кроме того, исследуется влияние перевода датасетов с английского и русского языков на передачу культурного кода, идеологических установок и языкового разнообразия. Рассматриваются проблемы искажения идиоматических выражений, недостаточного представления диалектов в текущих корпусах данных и потенциальные социально-политические риски внедрения переведённых языковых моделей. Особое внимание уделяется возможным последствиям утраты культурного кода для национальной безопасности. В заключение предлагаются направления развития языковых технологий, направленные на сохранение культурной аутентичности и повышение качества казахскоязычных моделей обработки естественного языка.*

***Ключевые слова:*** *Казахский язык, большие языковые модели, LLM, токенизация, обработка естественного языка, культурный код, перевод, датасеты, диалекты казахского языка, KAZLLM, национальная безопасность, обучение.*

## Введение

В эпоху, когда лингвистические технологии все больше становятся неотъемлемой частью коммуникации, распространения информации и сохранения культуры, разработка крупномасштабных языковых моделей (КЛМ), адаптированных к языкам меньшинств и языкам с ограниченными ресурсами, представляет собой как беспрецедентные возможности, так и значительные проблемы. Казахский язык, как важнейший компонент национальной идентичности и культурного наследия, сталкивается с особыми трудностями из-за своих сложных лингвистических особенностей, таких как агглютинативное морфологическое строение, уникальные алфавитные системы и отличительные грамматические структуры. Хотя недавние достижения в области обработки естественного языка (ОБЯ) расширили возможности КЛМ для широко распространенных языков, таких как английский и русский, их применение к казахскому языку требует тщательного учета специфических особенностей языка, включая эффективные методы токенизации будь то морфологические, статистические, нейронные или гибридные подходы и потенциальные искажения, возникающие при переводе наборов данных с доминирующих языков. Крайне важно отметить, что использование переведенных корпусов может привести к подрыву культурного кода, заложенного в казахских языковых выражениях, идиоматических выражениях и диалектных вариациях, что угрожает сохранению

национальной идентичности и создает проблемы безопасности, связанные с культурной гомогенизацией. В данной статье рассматривается влияние современных лингвистических технологий на разработку казахскоязычных моделей языковой грамотности, подчеркиваются уязвимости культурных элементов в существующих моделях, а также анализируются стратегии смягчения этих рисков посредством целенаправленной адаптации, привлечения носителей языка и поддержки со стороны правительства и образовательных организаций. В конечном итоге, подчеркивается важность баланса между технологическими инновациями и сохранением культуры, чтобы внедрение моделей языковой грамотности укрепляло, а не ослабляло языковой и культурный суверенитет Казахстана в цифровую эпоху.

Быстрое развитие больших языковых моделей (LLM) произвело революцию в обработке естественного языка, однако их применение для языков с ограниченными ресурсами, таких как казахский, сопряжено со значительными трудностями, угрожающими как языковой целостности, так и сохранению культуры.

Ключевыми проблемами являются вопросы, связанные с токенизацией – фундаментальным этапом обработки текстовых данных, которая становится особенно проблематичной, когда наборы данных ограничены и преимущественно получены путем перевода с более богатых ресурсами языков, таких как английский и русский.

Такой сбор данных, основанный на переводе, часто приводит к потере тонких смыслов, идеологических взглядов и традиционных культурных ценностей, тем самым рискуя разрушить уникальный культурный код, заложенный в казахском языке и обществе. Этот процесс не только искажает культурные концепции, но и усложняет представление диалектов и языкового разнообразия, присущих казахскому языку, которые часто недостаточно представлены или чрезмерно упрощены в переведенных наборах данных.

Более того, перевод наборов данных с иностранных языков может непреднамеренно вносить иностранные культурные нормы и политические предубеждения, такие как западное принятие концепций гендерной нейтральности, которые резко контрастируют с казахскими культурными и религиозными ценностями, создавая тем самым значительные политические и социальные риски.

Внедрение казахскоязычной языковой модели KAZLLM – должно быть тщательно пересмотрено, с учетом баланса между техническими достижениями в области токенизации и распознавания диалектов и необходимостью сохранения культурной аутентичности.

Опираясь на технические достижения в области моделирования казахского языка, более широкий контекст широкого внедрения моделей языков-лингвистов поднимает важные вопросы о сохранении национальной идентичности, особенно с учетом того, что модели языков-лингвистов все чаще выступают посредниками в доступе к информации и культурным нарративам. Когда широко внедряются модели языков-лингвистов, обученные преимущественно на данных из доминирующих мировых языков и культур, существует риск смещения идеологического центра доступных текстов, что потенциально может привести к маргинализации местных точек зрения и подрыву уникальной культурной и идеологической ткани, составляющей национальную идентичность. Этот риск усиливается в обществах с ограниченными языковыми ресурсами, где отсутствие надежных, культурно адаптированных моделей языков-лингвистов может привести к распространению иностранных точек зрения за счет местных знаний и ценностей. Поэтому крайне важно стимулировать разработку собственных моделей языков-лингвистов, отражающих местные культурные и идеологические взгляды, поскольку такие модели могут служить цифровыми хранителями национальной идентичности и гарантировать сохранение нюансов местных языков и традиций в цифровую эпоху. Взаимодействие между технологическими инновациями, нормативным надзором и сохранением культуры подчеркивает

необходимость скоординированных мер для предотвращения появления фактических монополий в области языков, которые могут еще больше гомогенизировать цифровой дискурс и подорвать плюрализм. В совокупности эти соображения подчеркивают необходимость активной политики и инвестиций для развития разнообразных, локально значимых языковых моделей, которые поддерживают сохранение национальной идентичности в эпоху быстрых технологических изменений.

Кроме того, статья направлена на выявление потенциальных политических и социальных рисков, связанных с переводом наборов данных, и предлагает механизмы контроля для смягчения негативных последствий, в конечном итоге выступая за культурно-чувствительный подход к разработке аутентичной и репрезентативной KAZLLM, которая поддерживает казахскую языковую и культурную идентичность в цифровую эпоху.

**Цель исследования**

Цель данной статьи – критически проанализировать ограничения существующих методов токенизации в условиях ограниченных ресурсов, изучить влияние перевода на культурную и идеологическую верность, а также исследовать стратегии сохранения диалектных и традиционных нюансов в LLM.

С точки зрения национальной безопасности, эрозия культурных и лингвистических особенностей в результате перевода и разработки моделей представляет риски для культурного суверенитета, социальной сплоченности и сохранения национальной идентичности, поскольку язык воплощает коллективную память и культурные ценности.

В данной статье рассматривается многогранное влияние перевода наборов данных на потерю культурных и лингвистических особенностей, анализируются конкретные проблемы, с которыми сталкиваются языки с ограниченными ресурсами, такие как казахский язык.

Также в статье анализируются потенциальные последствия для национальной безопасности, подчеркивая важность разработки стратегий сохранения культурных кодов в языковых технологиях для защиты культурной идентичности в эпоху быстрого развития систем обработки естественного языка.

**Обзор существующих методов токенизации**

Методы токенизации казахского языка могут быть разделены на четыре основных категории: морфологические, статистические, нейросетевые и гибридные.

Морфологические подходы основаны на лингвистических правилах языка и используют информацию о структуре слова, правилах словообразования и грамматических особенностях.

В казахском языке такие методы позволяют разделять слова на корень и аффиксы, что особенно важно из-за агглютинативной природы языка, где одно слово может содержать различные суффиксов.

Статистические методы опираются на вероятностные модели, построенные на основе анализа корпусов текстов. Они используют частоту появления слов, морфем или n-грамм для определения наиболее вероятных границ токенов.

Такие методы позволяют автоматически находить закономерности в языке без необходимости ручного описания всех грамматических правил.

Нейросетевые методы используют модели глубокого обучения для определения границ токенов и изучения зависимостей между символами и словами в тексте. В этих подходах применяются архитектуры нейронных сетей, способные анализировать большие объемы текстовых данных и выявлять скрытые языковые закономерности.

Гибридные методы сочетают несколько подходов, например морфологические правила и статистические или нейросетевые модели. Комбинирование различных методов позволяет повысить точность токенизации и лучше учитывать особенности казахского языка при обработке текстов.

В свою очередь, актуальные исследования последних двух-трех лет показывают переход от универсальных алгоритмов к национально-ориентированным моделям. Важным этапом в этом направлении стала разработка модели KAZ-LLM исследовательской группой ISSAI NU.

Опыт данной группы демонстрирует, что для преодоления дефицита данных необходимо использование сверхбольших массивов (свыше 150 млрд токенов), где токенизатор оптимизирован под специфику кириллического и латинского начертаний казахского языка, что позволяет сократить фрагментацию слов и повысить семантическую точность обработки [1].

**Основная часть**

**Особенности алфавита и грамматики казахского языка**

Казахский язык относится к группе тюркских языков алтайской языковой семьи и является государственным языком Республики Казахстан. Он близок к таким языкам, как киргизский, узбекский, татарский и башкирский.

Современный казахский алфавит основан на кириллице и состоит из 42 букв. В нем присутствуют специфические буквы, отсутствующие в русском языке, такие как «ә, ғ, қ, ң, ө, ұ, ү, h, i». Эти буквы передают уникальные звуки казахского языка и играют важную роль в правильной обработке текстов.

Грамматические особенности казахского языка включают отсутствие грамматического рода, наличие двух чисел (единственное и множественное), а также развитую систему падежей.

Существительные изменяются по падежам, включая именительный, родительный, дательный, винительный, местный, исходный и творительный.

Глаголы изменяются по времени, лицу, числу и наклонению.

Порядок слов в предложении относительно свободный, однако чаще всего используется структура «подлежащее – дополнение – сказуемое».

Одной из ключевых особенностей казахского языка, как обозначалось выше, является агглютинативная структура. Это означает, что грамматические значения выражаются с помощью последовательного присоединения аффиксов к корню слова.

Учет особенностей алфавита и грамматики казахского языка является важным условием при разработке методов токенизации, поскольку они позволяют более точно определять границы слов и морфем и повышают эффективность обработки текстов.

**Проблемы токенизации в обучении LLM для казахского языка**

Токенизация текста на казахском языке представляет собой ряд сложностей, связанных с особенностями морфологии, орфографии и синтаксиса языка.

Казахские слова могут содержать большое количество аффиксов, что усложняет процесс корректного разделения текста на токены.

На сегодняшний день, основные результаты научных исследований по компьютерной лингвистики казахского языка получены Мусабаевым Р.Р., Тусуповым Д.А., Базарбек Ж.П., Тоганбаевой Н.А., Сарсембаева Т.С.; по моделям распознавания казахской речи, текста – Кожирбаев Ж., КАрибаева А., Амирова Д.; по созданию корпусов казахского языка – Фазылжанова А., Сейтбекова А. Над представлением этнических групп в пространстве через наборы данных работали – Уейдман Нилс Б., Рон Дж.К., Цедерман Дарс.Е..

Во-первых, вопрос качества исходных языковых данных является критическим фактором. Недостаточная представленность казахского языка в масштабных цифровых корпорах приводит к искажению семантических и культурных характеристик текста, что подтверждается исследованиями (Ермеков, 2021; Сагинбеков, 2022). Это порождает «эффект ассимиляции» культурно-специфических символов и реалий, что негативно сказывается на сохранении национального культурного кода в итоговых языковых продуктах [2][3].

Во-вторых, алгоритмическая структура LLM предполагает статистическую генерализацию, в процессе которой уникальные культурно-национальные маркеры нередко «усредняются» или оптимизируются под более широко представленные языковые паттерны. Как указывает Кожагулов (2023), такой подход способствует размытию языковых и культурных особенностей, что в долгосрочной перспективе может привести к внутреннему культурному колониализму на цифровых платформах [4].

Ниже приведены основные проблемы, с которыми сталкиваются исследователи при разработке методов токенизации для казахского языка:

*1) Агглютинативная структура языка.* Казахский язык характеризуется агглютинативной морфологией, где к корню слова могут последовательно добавляться многочисленные суффиксы.

В результате одно слово может содержать большое количество грамматической информации. Например: *үйіміздегілерден* состоит из корня и нескольких суффиксов. Это усложняет выделение базовых токенов и требует морфологического анализа.

Проблема "переразбиения" агглютинативных основ на бессмысленные токены находит решение в работах М. Мансуровой и А.Оспан, которые аргументируют, что интеграция академических корпусов и словарей Национального словарного фонда в процесс обучения позволяет модели сохранять целостность морфем [5]. Это подтверждает тезис о том, что для казахского языка гибридные подходы, сочетающие нейросетевую токенизацию с жесткими лингвистическими правилами, являются более предпочтительными, чем стандартные методы, используемые в моделях семейства GPT.

*2) Большое количество словоформ.* Из-за богатой системы словообразования одно и то же слово может иметь десятки или даже сотни форм. Простая токенизация по пробелам не позволяет учитывать морфологическую вариативность, что может приводить к увеличению словаря и снижению эффективности моделей обработки текста;

*3) Проблемы с составными словами.* В казахском языке часто встречаются сложные и составные слова, которые могут писаться как слитно, так и раздельно. Например: *теміржол, ауыл шаруашылығы, еңбек ақы*. Определение границ таких слов является сложной задачей для автоматической токенизации.

*4) Апострофы, дефисы и сокращения.* В текстах могут встречаться апострофы, дефисы и различные сокращения (*ж.-ж., т.б., т.с.с., Нұр-Сұлтан*). Такие элементы могут нарушать стандартные правила токенизации и требуют специальных правил обработки;

*5) Заимствованные слова и смешанные языки.* Современные казахские тексты часто содержат заимствованные слова из русского, английского и других языков, а также элементы код-свитчинга. Например: *интернет арқылы онлайн тіркелу*. Это усложняет построение универсальных алгоритмов токенизации;

6) *Частицы и служебные слова.* Некоторые частицы и служебные элементы (*ма/ме, ба/бе, ғой, ғана*) могут писаться отдельно или присоединяться к словам в разговорной речи. Это создает трудности при определении границ токенов.

**Влияние перевода на сохранение культурного кода**

Процесс перевода текстов с английского или русского языка тесно связан с передачей смысла и идеологии, представляя собой значительные трудности, затрагивающие лингвистическую, культурную и этическую сферы.

Стилистические проблемы и ограниченная языковая компетентность переводчика могут привести к неточностям, которые могут исказить или затушевать предполагаемое сообщение и идеологические основы оригинального текста.

Такие искажения еще больше усугубляются, когда переводчик не обладает достаточными знаниями об идеологии исходной культуры, что приводит к потере смысла перевода, подрывающей как целостность оригинального смысла, так и точную передачу идеологического содержания. Эти лингвистические и культурные пробелы не только препятствуют точному отражению ценностей и взглядов исходного текста, но и

пересекаются с более широкими социальными процессами, такими как дисбаланс власти и дискурсивный контроль, которые могут быть увековечены или оспорены посредством перевода.

В этом контексте применение критического дискурсивного анализа становится необходимым, поскольку он позволяет исследователям систематически изучать, как социальная власть, неравенство и доминирование заложены и потенциально используются в переведенных текстах, тем самым раскрывая более глубокую идеологическую работу, которая здесь присутствует [6].

Помимо технических сложностей токенизации, перевод наборов данных, особенно тех, которые основаны на языках с ограниченными ресурсами – представляет значительные риски для сохранения традиций и культуры.

Глубоко укоренившиеся идиоматические выражения и пословицы, которые воплощают общественные нормы, ценности и коллективную мудрость, часто сопротивляются буквальному переводу, что приводит к размыванию или даже потере их риторического богатства и культурного резонанса в целевом языке.

Многие казахские идиомы и метафоры тесно связаны с традициями, образом жизни и историческим опытом народа, поэтому при дословном переводе их смысл может искажаться или полностью теряться. Например, казахское выражение «*ат құлағында ойнау*», означающее «быть очень ловким или мастерски владеть чем-либо», при буквальном переводе может интерпретироваться как «*играть на ухе лошади*», что не передает истинного значения выражения.

Аналогично, фраза «*қой аузынан шөп алмас*», характеризующая очень мягкого и доброго человека, может быть переведена буквально как «*не возьмёт траву изо рта овцы*», что делает выражение непонятным для носителей других языков.

Кроме того, трудности возникают при переводе культурно специфических понятий, связанных с традициями и общественными отношениями. Например, слова «*жүз*», «*ағайын*», «*қонақжайлық*», «*асар*» или «*жеруйық*» несут в себе сложные культурные и исторические значения, которые не всегда имеют прямые эквиваленты в других языках.

Машинный перевод часто передает их упрощенно или с частичной потерей смысла и тем самым искажая культурный код.

Потеря не ограничивается лингвистическим содержанием, но распространяется на более широкий социокультурный контекст, например, кулинарные практики или системы знаний коренных народов, который переплетен с языком и часто закодирован в предметно-специфических наборах данных [7].

Для уменьшения подобных ошибок необходимо развитие моделей перевода, учитывающих культурные особенности языка и использующих контекстно-зависимые методы обработки текста.

Эти взаимосвязи показывают, что проблемы перевода выходят за рамки слов и затрагивают саму ткань традиций и идентичности, заложенную в данных.

Следовательно, для смягчения этих потерь крайне важно интегрировать в рабочие процессы перевода экспертные знания, учитывать целевой культурный контекст и применять культурно-ориентированные критерии, обеспечивая сохранение глубины и разнообразия традиций и культуры независимо от языковых границ.

**Представление диалектов казахского языка в датасетах**

Современные наборы данных, представляющие казахские диалекты, демонстрируют заметный прогресс, однако они также выявляют существенные ограничения как по объему, так и по детализации.

Например, Национальный корпус казахского языка содержит широкий спектр исторических и современных текстов, предоставляя базовый ресурс для лингвистического анализа и выделяя области, требующие дальнейшего улучшения,

такие как систематическое включение диалектных вариаций и региональных речевых моделей [8].

Аналогично, недавние усилия по созданию баз данных и корпусов казахской речи для таких приложений, как распознавание речи и системы преобразования текста в речь, способствовали интеграции языка в современные голосовые технологии; однако эти наборы данных часто отдают приоритет стандартному казахскому языку и могут не систематически различать диалектные особенности, что приводит к недопредставленности регионального языкового разнообразия [9][10].

Эта тенденция распространяется и на другие области, такие как распознавание рукописного текста и задачи обработки естественного языка, где дефицит аннотированных диалектных данных препятствует разработке надежных моделей, способных улавливать богатое разнообразие, присущее казахской речи и письму [11] [12].

**Политические и социальные риски внедрения переведённых LLM**

Политические риски, связанные с использованием переведенных наборов данных, многогранны и обусловлены присущей переводу сложностью, выходящей за рамки простого языкового эквивалента и охватывающей социально-политические коннотации и культурные предубеждения.

При переводе наборов данных, будь то с помощью человеческих или машинных процессов, существует риск искажения или неверного представления контекстно-специфических значений, что может существенно повлиять на интерпретацию политических данных и последующие выводы, сделанные на основе анализа [13].

Например, автоматизированные инструменты перевода могут непреднамеренно увековечивать вредные или предвзятые переводы, проблема усугубляемая, когда эти наборы данных используются для деликатных тем, таких как международные конфликты, управление или политические исследования [14].

Кроме того, процесс очистки и реструктуризации переведенных наборов данных для соответствия конкретным исследовательским рамкам может привести к упущению или изменению политически значимых нюансов, что влияет на целостность и надежность данных [15].

Также одновременно создает риск переноса в модель культурных норм и социальных представлений, характерных для других обществ.

В результате при дальнейшем использовании модели она может воспроизводить или распространять культурные установки, которые не являются традиционными для казахского общества.

Например, в обучающих данных могут присутствовать темы или социальные практики, такие как однополые браки или браки между близкими родственниками, которые в разных культурах воспринимаются по-разному.

При отсутствии достаточного количества оригинальных казахских текстов модель может усваивать подобные концепты как универсальные и воспроизводить их в ответах.

Таким образом, использование переводных датасетов может приводить к непреднамеренному внедрению чуждых культурных норм в языковую модель.

Такого рода риски подчеркивают необходимость для исследователей тщательного изучения как используемых методологий перевода, так и социально-политического контекста, заложенного в наборах данных, что требует надежного междисциплинарного контроля для предотвращения потенциальных неверных интерпретаций и обеспечения достоверности политического анализа, проводимого с использованием переведенных данных.

**Риски для национальной безопасности**

Утрата культурных кодов в результате перевода может иметь серьезные последствия для национальной безопасности, поскольку язык является не просто

инструментом коммуникации, но и средством передачи тонких смыслов, намерений и культурно обусловленных ценностей [16].

В 2025 году, с принятием поправок в законодательство Республики Казахстан относительно цифровой инфраструктуры, создание собственной "Большой языковой модели" было признано приоритетом национальной безопасности. Как отмечает А. Барлыбаев, использование исключительно зарубежных или "переводных" моделей создает риск "идеологического дрейфа", когда ИИ транслирует ценностные установки, не свойственные казахской культуре [17].

Таким образом, технологическая независимость в области NLP становится обязательным условием защиты информационного пространства и сохранения аутентичной идентичности в цифровую эпоху.

В свою очередь, дипломатические переговоры, например, часто зависят от тонких лингвистических сигналов и культурных отсылок, которые могут быть утрачены или искажены при переводе без достаточного учета культурных особенностей, что приводит к недопониманию или эскалации напряженности между странами [18].

Кроме того, неточности в переведенных юридических или политических документах могут создавать системные риски, подрывая справедливость и возможность исполнения соглашений, имеющих решающее значение для национальной и международной безопасности [19].

Такие ошибки перевода могут усугубляться, поскольку они пересекаются с вопросами культурной чувствительности, где ошибки не только угрожают дипломатическим отношениям, но и могут нанести ущерб репутации, привести к нарушениям нормативных требований или даже поставить под угрозу безопасность лиц, участвующих в деликатных операциях [20].

Учитывая центральную роль языка в формировании динамики власти, управлении кризисами и влиянии на общественное мнение, взаимосвязь между утратой культурных кодов и национальной безопасностью очевидна и многогранна.

Для смягчения этих рисков Правительству РК и организациям крайне важно инвестировать в профессиональные услуги перевода, которые уделяют приоритетное внимание культурной компетентности, способствуют непрерывному межкультурному обучению и разрабатывают концепции, признающие неразрывную связь между языком, культурой и безопасностью.

**Заключение**

Результаты данного исследования подчеркивают критическую важность учета лингвистических и культурных нюансов при разработке больших языковых моделей (LLM) для языков с ограниченными ресурсами, таких как казахский.

Проблемы, связанные с токенизацией, включая орфографические вариации, разреженность данных и отсутствие стандартизированных эталонов, значительно затрудняют создание точных и надежных систем обработки естественного языка (NLP). Эти проблемы усугубляются диалектным разнообразием и непоследовательной пунктуацией, что снижает эффективность конвейеров обработки языка и приводит к распространению ошибок на последующие задачи, такие как перевод, аннотирование и обучение модели.

Исследование подчеркивает, что высококачественные, специфичные для конкретного языка токенизаторы и стандартизированные текстовые форматы необходимы для повышения точности сегментации, что, в свою очередь, влияет на производительность в дальнейшем.

Более того, роль перевода выходит за рамки языковой конверсии, являясь важным инструментом сохранения культуры; однако он сопряжен с рисками культурного искажения и идеологического неверного представления, особенно когда автоматизированные инструменты перевода не обладают достаточной культурной чувствительностью. Это обуславливает необходимость интеграции методов и практик

перевода с учетом культурных особенностей, таких как критический дискурс-анализ, для обеспечения этичных и контекстуально точных переводов.

Недостаточное представление диалектных вариаций в существующих наборах данных еще больше ограничивает инклюзивность и справедливость приложений обработки естественного языка, что подчеркивает необходимость целенаправленного сбора данных и аннотирования, охватывающих весь спектр языкового разнообразия в казахском языке.

Кроме того, социальные и политические последствия перевода наборов данных и развертывания моделей выявляют потенциальные предвзятости и их усиление, подчеркивая важность надежных механизмов контроля, таких как стандартизированные конвейеры предварительной обработки, для смягчения этих рисков.

Хотя инновационные решения, такие как расширение наборов данных на основе перевода и модели, такие как KAZLLM, предлагают многообещающие пути для быстрой разработки и межъязыковой оценки, они также создают проблемы, связанные с контекстной релевантностью и культурной спецификой.

Несмотря на эти выводы, остаются ограничения, включая дефицит аннотированных диалектных данных и трудности в балансировании ограниченности ресурсов с культурной точностью.

Будущие исследования должны сосредоточиться на расширении диалектных корпусов, разработке более культурно-чувствительных моделей перевода и изучении этических рамок для смягчения предвзятости и политических рисков.

В целом, это исследование подчеркивает, что интеграция лингвистических, культурных и технологических аспектов имеет важное значение для создания инклюзивных, точных и этически ответственных языковых моделей, адаптированных к языкам с ограниченными ресурсами, таким как казахский, что в конечном итоге способствует их сохранению и расширению возможностей в цифровой среде.

**Список использованных источников**

1. Varol, H. A., Khassanov, Y., et al. (2024). ISSAI KAZ-LLM: Архитектура и методология обучения большой языковой модели для казахского языка. Nazarbayev University Publications.

2. Ермекова Т. Н. «Развитие автоматизированных систем обработки казахского языка: проблемы и перспективы», Вестник КазНПУ им. Абая. Серия «Филологические науки». 2021. № 3 (77).

3. Сагинбеков А. С., Мухамедиев Р. И. «Анализ репрезентативности лингвистических данных в задачах машинного обучения для государственного языка», Материалы международной конференции «Информационные и телекоммуникационные технологии: образование, наука, практика». Алматы, 2022.

4. Кожагулов Е. Т. «Цифровой суверенитет и проблемы сохранения национального культурного кода в эпоху доминирования глобальных языковых моделей», Вестник Академии государственного управления при Президенте РК. 2023. № 4.

5. Мансурова, М. Е., Оспан. А. (2025). Алгоритмы, рожденные наукой: создание KazLLM на базе академических знаний. Вестник КазНУ им. аль-Фараби.

**Для материалов из INTERNET:**

6. Alhakimi, A., Alkholidi, A., Adar, N., & Sefa, B., «AI versus human translators: Accuracy and context in the translation of cultural idioms and proverbs». AI and Digital Transformation: Opportunities, Challenges, and Emerging Threats in Technology, Business, and Security (стр.231-246) Октябрь 2025 [Электронный ресурс] // URL: https://link.springer.com/chapter/10.1007/978-3-032-07373-0_17

7. Joshi, N., Gogoi, P., Mirza, A., & Jansari, A., ELR-1000: A community-generated dataset for endangered Indic indigenous languages. In ACL Anthology. IJCNLP-AACL, 2025 [Электронный ресурс] // URL: https://aclanthology.org/2025.ijcnlp-long.131/

8. Fazylzhanova, Anar, Seitbekova, Ainur, Kobdenova, Gulzhihan, Seidamat, Assel and Ayazbayev, Galymzhan. "The issues of developing the historical subcorpus of the National Corpus of the Kazakh Language" Lodz Papers in Pragmatics, vol. 21, no. 1, 2025, pp. 169-191 [Электронный ресурс] // URL: https://doi.org/10.1515/lpp-2024-0038

9. Kozhirbayev, Z. (2023). Kazakh Speech Recognition: Wav2vec2.0 vs. Whisper. Journal of Advances in Information Technology, 14(6), 1382-1389 [Электронный ресурс] // URL: https://doi.org/10.12720/jait.14.6.1382-1389

10. Karibayeva A, Karyukin V, Abduali B, Amirova D. Speech Recognition and Synthesis Models and Platforms for the Kazakh Language. Information. 2025; 16(10):879 [Электронный ресурс] // URL: https://doi.org/10.3390/info16100879

11. Toiganbayeva Nazgul, Kasem Mahmoud, Abdimanap Galymzhan, Bostanbekov Kairat, Abdallah Abdelrahman, Alimova Anel, Nurseitov Daniyar. KOHTD: Kazakh offline handwritten text dataset. Signal Processing: Image Communication 2022. 108. 116827. DOI:10.1016/j.image.2022.116827.

12. Zhandos Yessenbayev, Zhanibek Kozhirbayev, Aibek Makazhanov. KazNLP: A Pipeline for Automated Processing of Texts Written in Kazakh Language. In Speech and Computer: 22nd International Conference, SPECOM 2020, St. Petersburg, Russia, Октябрь 7–9, 2020, Proceedings. Springer-Verlag, Berlin, Heidelberg, стр657–666 [Электронный ресурс] // URL: https://doi.org/10.1007/978-3-030-60276-5_63

13. Nils B Weidmann, Jan Ketil Rød, Lars-Erik Cederman, Representing ethnic groups in space: A new dataset, Journal of Peace Research, Volume 47, Issue 4, Июль 2010, стр 491–499 [Электронный ресурс] // URL: https://doi.org/10.1177/0022343310368352

14. Costa-Jussà, M., Cross, J., Çelebi, O., Elbayad, M. No language left behind: Scaling human-centered machine translation, 2022 [Электронный ресурс] // URL: https://arxiv.org/abs/2207.04672

15. Mellinger, Christopher D. «Quantitative questions on big data in translation studies», Meta, volume 67, number 1, апрель–май 2022, стр. 217–231 [Электронный ресурс] // URL: https://doi.org/10.7202/1092197ar

16. Collins, B. The role of language training in U.S. national security and diplomacy. Diplomatic Language Services, 1 август 2025 [Электронный ресурс] // URL: https://dlsdc.com/blog/language-training-national-security/

17. Барлыбаев, А. Б. (2025). Проблемы генеративного ИИ в контексте тюркских языков: от токенизации до культурной адаптации. Материалы международной конференции «AI & Society».

18. Lost in Translation: How language impacts diplomacy and trade. Tecnitranslations. 25 февраль 2025 [Электронный ресурс] // URL: https://www.tecnitranslations.com/lost-in-translation-how-language-impacts-diplomacy-and-trade/

19. Lost In Legal Translation: Legal culture and language as risk factors in international arbitration and litigation, Kluwer Arbitration Blog, 23 декабрь 2025 [Электронный ресурс] // URL: https://legalblogs.wolterskluwer.com/arbitration-blog/lost-in-legal-translation-legal-culture-and-language-as-risk-factors-in-international-arbitration-and-litigation/

20. Cultural sensitivity in translation: What it is and why it matters, 19 сентябрь 2025 [Электронный ресурс] // URL: https://transpose.ch/en/blog/cultural-sensitivity-in-translation

# ВЛИЯНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И ОНЛАЙН-ПЛАТФОРМ НА НОВЫЙ ФОРМАТ ЖУРНАЛИСТИКИ

**Дюсебаев Р.Е., Балгабаева Л.Ш.**
e-mail: ruslandyusebaev5@gmail.com
*Университет «Туран», Республика Казахстан*

***Аннотация:*** *В статье рассматривается трансформация современной журналистики под влиянием искусственного интеллекта и онлайн-платформ. Анализируются изменения в процессах создания и распространения новостного контента, а также влияние цифровых технологий на профессиональные компетенции журналиста и редакционные стандарты. Особое внимание уделяется автоматизации редакционных процессов, развитию мультимедийных форматов, дата-журналистики и адаптации контента к требованиям цифровых платформ. Рассматриваются преимущества искусственного интеллекта, связанные с повышением оперативности работы, а также риски алгоритмической зависимости и снижения редакционной автономии.*

Актуальность исследования обусловлена масштабной цифровой трансформацией медиасреды: развитие алгоритмов искусственного интеллекта (ИИ) и онлайн-платформ полностью пересмотрело классические подходы к созданию и распространению новостей, превратив программное обеспечение в фундаментальную основу работу современной редакции [1-3].

Вопросы трансформации медиа активно обсуждаются в научных кругах. Исследователи анализируют изменение социальной роли журналиста [1], роль программных решений в редакциях [2, 3], освоение новых мультимедийных форматов [4] и адаптацию контента под конвергентные аудитории [5]. Опираясь на концепцию цепочки создания стоимости Майкла Портера, Б. Вильчек, М. Хаим и Н. Турман доказывают критическую важность внедрения ИИ для выживания местных СМИ [6]. Научная новизна работы заключается в систематизации конкретных механизмов влияния ИИ и алгоритмов платформ на повседневную редакционную практику.

Источниковую базу исследования составили материалы казахстанских и зарубежных СМИ. Объектом исследования выступает современная журналистика в условиях глобальной цифровой трансформации. Предметом является процесс влияния программного обеспечения и онлайн-платформ на развитие новых форматов журналистской деятельности. Цель работы - определить влияние онлайн-платформ и ИИ на трансформацию профессиональных стандартов и облика журналистики.

Для достижения цели поставлены задачи:

1) проанализировать переход от традиционных методов работы к цифровым форматам;
2) оценить роль автоматизации в редакционных процессах;
3) выявить требования онлайн-платформ к подаче и качеству контента.

Гипотеза исследования: внедрение программных алгоритмов меняет не только техническую сторону работы, но профессиональные стандарты, делая умение адаптировать контент под требования площадок равнозначным навыку написания текста.

Методология работы включает сравнительный анализ кейс-стадий медиахолдингов и мониторинг трендов.

За последние пятнадцать лет журналистика претерпела серьезные изменения, связанные с цифровой трансформацией. Если раньше основными каналами были печатные издания и телевидение, то сегодня ведущую роль играют онлайн-платформы и социальные сети. Изменилась скорость передачи информации, роль аудитории и способы работы журналиста. Современные технологии не только ускорили процесс

создания новостей, но и изменили профессиональные стандарты, сделав журналистику более открытой, мультимедийной и зависимой от алгоритмов. Сравнение традиционной и современной модели позволяет наглядно увидеть, как трансформация затронула все ключевые аспекты профессии.

Цифровая трансформация сформировала запрос на новый тип журналиста, чья деятельность строится на стыке традиционных профессиональных стандартов и технических компетенций. Как отмечает М. Ли [4, с.154-1570], именно сочетание базовых журналистских навыков с цифровыми инструментами становится ключевым условием эффективной работы в современной медиасреде. Сейчас работа журналистов в Казахстане заметно отличается от того, как она выглядела раньше. Журналисты активно используют интернет-порталы и социальные сети для распространения новостей и общения с аудиторией. Материалы готовятся не только в виде текста, но и в формате видео, инфографики и подкастов, что делает информацию более наглядной.

Важным стало умение быстро реагировать на события и публиковать материалы в реальном времени. Журналисты учитывают алгоритмы онлайн-платформ, чтобы их публикации были замечены и получили отклик. При этом остается важным вопрос доверия аудитории к достоверности.

Если на традиционном этапе деятельность журналиста протекала в условиях ограниченных технических возможностей - при длительном ручном сборе информации, - то развитие цифровых технологий кардинально изменило редакционную практику. Внедрение первых онлайн-версий печатных изданий, как отмечают Нильсен Р. и Флетчер Р., положило начало платформатизации медиасистем, когда новостные материалы стали впервые адаптироваться под требования сайтов и социальных сетей [2, с.484–499].

С освоением систем управления контентом (CMS), баз данных и алгоритмов ИИ программное обеспечение превратилось из вспомогательного инструмента в технологическую основу работы СМИ. В этом контексте Т. Доддс, Р. Замит и С. К. Льюис рассматривают ИИ как принципиально нового интеллектуального посредника между производителями и потребителями контента, способного полностью абстрагировать и синтезировать журналистскую работу [7, с.530–544].

Сравнительный анализ трансформации ключевых параметров журналистской деятельности от традиционной линейной модели к современному медийному формату приведен в Таблице 1.

Таблица-1. Сравнение традиционной и современной журналистики

| Аспект | Традиционная журналистика | Современная журналистика |
|---|---|---|
| Доступ к информации | Архивы, библиотеки, личные контакты | Поисковые системы, базы данных, аналитическое ПО |
| Скорость публикации | Газеты и журналы с фиксированным графиком | Мгновенные публикации онлайн, прямые трансляции |
| Навыки журналиста | Узкая специализация, однопрофильное направление | Обширная специальность, добавление ПО, онлайн-платформы |
| Обратная связь | Письма в редакцию, звонки | Комментарии, лайки, репосты, соцсети |
| Формат СМИ | Длинные материалы, печатные тексты, радио, ТВ | Короткий контент, видео, инфографика, соцсети |

В таблице 1 представлены качественные изменения в журналистской практике, связанные с внедрением ИИ на основе систематического обзора 127 научных исследований [9].

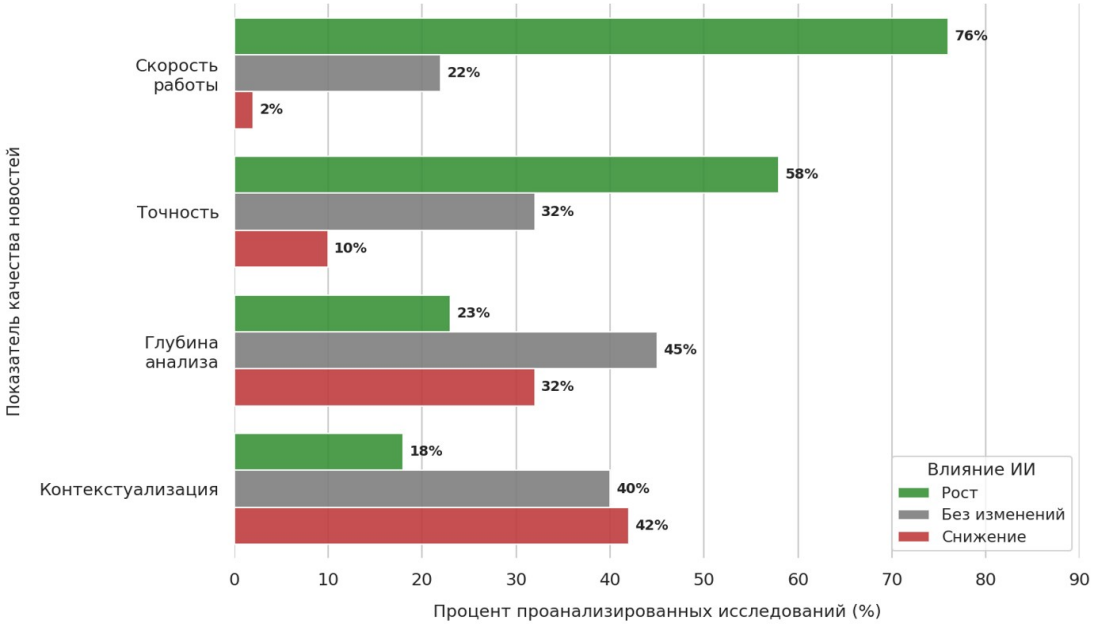



График 1. Влияние искусственного интеллекта на качественные характеристики журналистского контента по результатам систематического обзора исследований.

Результаты обзора указывают на противоречивый характер влияния ИИ на журналистскую практику: повышение оперативности производства контента может сопровождаться снижением отдельных показателей его аналитического качества.

На графике 2 представлены приоритетные направления внедрения ИИ в деятельность местных новостных редакций [6].

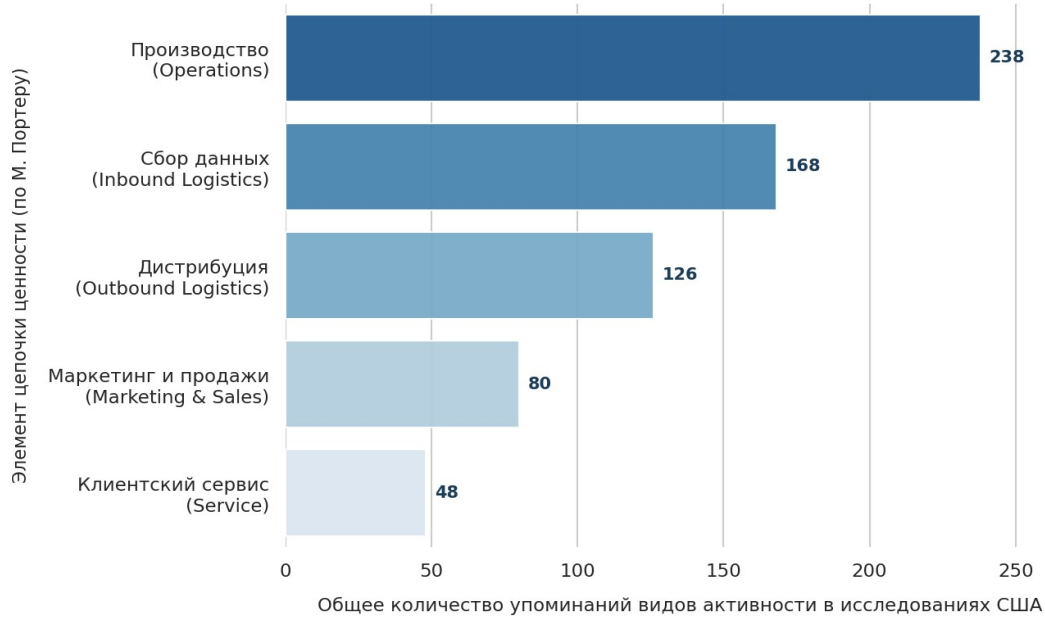



График 2. Приоритетные направления внедрения искусственного интеллекта в цепочке ценности СМИ

Результаты свидетельствуют о том, что редакции ориентированы прежде всего на использование ИИ в основных процессах сбора данных и создания новостного контента, в то время вспомогательные сферы (клиентский сервис и поддержка подписчиков) задействованы в значительно меньшей степени.

На сегодняшний день современная журналистика использует онлайн-платформы, социальные сети, подкасты, стриминговые платформы, базы данных, мультимедийные редакторы и т.д. Доступ к информации стал мгновенным, а аудитория активно участвует

в обсуждении. Журналисты и редакции все чаще основываются на количественных и качественных данных при подготовке материалов: на основании данных о поведении читателей принимают решения о глубине освещения тем.

Автоматизация открыла путь к дата-журналистике, которая строится на работе с массивами данных, превращающихся в графики и диаграммы. Журналист выступает не просто автором, а аналитиком и исследователем, что усиливает доверие аудитории.

Важным фактором стало влияние алгоритмов социальных сетей, которые решают, какие публикации будут замечены. Это заставляет редакции менять свои подходы к формату и визуалу. А. Ф. Сонни, Х. Хафиед, И. Ирванто и Р. Латухеру фиксируют рост использования автоматизированного написания новостей и персонализации дистрибуции [9, с.1554–1570]. Однако подчинение алгоритмам создает риски упрощения материалов. Как отмечает Д. Иванова, журналист обязан адаптировать материал под специфику каждой платформы [5, с.1–9].

В ходе исследования удалось показать, что современная журналистика сильно изменилась под влиянием программного обеспечения и онлайн-платформ. Главный результат работы состоит в том, что цифровые технологии перестали быть вспомогательным инструментом и стали основой журналистики. Автоматизация процессов позволяет быстрее собирать и публиковать материалы, а новые форматы, подкасты, дата-репортажи и инфографика делают журналистику более разнообразной и доступной. Это подтверждает гипотезу о том, что внедрение программного обеспечения меняет не только скорость работы, но и профессиональные стандарты.

Полнота и достоверность выводов обеспечиваются анализом практики казахстанских и зарубежных СМИ и сопоставлением моделей. Исследователь Ф. М. Саймон детально анализирует проблему журналистской автономии и доказывает, что технологические гиганты, контролирующие ИИ-инфраструктуру, неизбежно втягивают издателей в новые формы технологической и операционной зависимости, ставя под угрозу редакционную независимость прессы [1–23].

Практическая значимость исследования состоит в том, что оно показывает изменение требований к профессии журналиста в условиях цифровой среды. В целом цифровая трансформация формирует новый формат журналистики - более открытой, мультимедийной и ориентированной на цифровую среду.

## ЛИТЕРАТУРА:

1. *Смит Д.* Multimedia storytelling in online journalism: Analysing multimedia use on the websites TheGuardian.com, TheNationalnews.com, USAToday.com, and Stuff.co.nz // Journalism and Media. 2025. №3 (6). – С. 157–178.

2. *Нильсен Р. К., Флетчер Р.* Comparing the platformization of news media systems: A cross-country analysis // European Journal of Communication. 2023. №5 (38). – С. 484–499.

3. *Ахметова Л.* The impact of new technologies on journalism in the age of digital media // Bulletin of L.N. Gumilyov Eurasian National University. Journalism Series. 2025. №3. – С. 114–123.

4. *Ли М.* Digital newsroom transformation: A systematic review of the impact of artificial intelligence on journalistic practices, news narratives, and ethical challenges // Journalism and Media. 2024. №4 (5). – С. 1554–1570.

5. *Иванова Д.* Digital transformation in journalism: Mini review on the impact AI on journalistic practices // Frontiers in Communication. 2025. №10. – С. 1–9

6. *Вильчек Б., Хаим М.*, Турман Н. Transforming the value chain of local journalism with artificial intelligence // AI Magazine. 2024. №2 (45). – С. 200–211

7. *Доддс Т., Замит Р., Льюис С. К.* The AI turn in journalism: Disruption, adaptation, and democratic futures // Journalism. 2026. №3 (27). – С. 530–544

8. *Саймон Ф. М.* Uneasy Bedfellows: AI in the News, Platform Companies and the Issue of Journalistic Autonomy // Digital Journalism. 2022. №10 (10). – С. 1–23

9. *Сонни А. Ф., Хафиед Х., Ирванто И., Латухеру Р.* Digital Newsroom Transformation: A Systematic Review of the Impact of Artificial Intelligence on Journalistic Practices, News Narratives, and Ethical Challenges // Journalism and Media. 2024. №4 (5). – С. 1554–1570

# АЛГОРИТМЫ И ПРОГРАММНЫЕ СРЕДСТВА ДЛЯ РЕГУЛИРОВАНИЯ СВЕТОФОРОВ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ

Токоева Б.Ж., Охотников В.И., Торобеков Б.Т.
e-mail: burul.tokoeva@gmail.com, okhotnikov1@gmail.com, bekjan2003@mail.ru
*Кыргызский государственный технический университет им. И. Раззакова, г. Бишкек, Кыргызская Республика*

***Аннотация:*** *Статья посвящена оптимизации транспортных потоков улично-дорожной сети путем совершенствования регулирования светофоров с использованием технологий машинного обучения. Обоснованы предпосылки разработки адаптивных систем управления светофорной сигнализацией в городской транспортной инфраструктуре.* ***Цель исследования:*** *разработка имитационной модели умного светофора, включающей адаптивное управление и приоритет спецтранспорта.* ***Объектом исследования*** *выступает процессы движения транспортных средств на регулируемом перекрёстке.* ***Предметом исследования*** *являются алгоритмы, программные средства и архитектурные решения управления светофорным объектом, включая перспективу применения ML-методов.* ***Методы исследования****: в исследовании были использованы методы системного анализа, теории и практики автоматизации технических процессов, экспериментального исследования, имитационного моделирования и программирования.* ***Результаты****. Авторами предложена и программно реализована прототипная имитация модели движения на регулируемом перекрёстке.*

**Введение**. Тенденцией в организации и управлении дорожного движения в настоящее время является рост трафика, вызванный увеличением количества автомобилей в городах, что приводит к хроническим заторам, росту расхода топлива и повышению уровня выбросов загрязняющих веществ. Характерное для современного мегаполиса проблемы регулирования транспортных потоков в улично-дорожной сети, обеспечения безопасности дорожного движения и транспортных заторов в основном обусловлены применением жестких релейных или устаревших адаптивных систем управления. При этом стандартные фиксированные фазы регулирования светофоров не учитывают реальное динамическое изменение потоков транспорта и пешеходов. В этих условиях имеется необходимость перехода к интеллектуальному управлению транспортными потоками в реальном времени, реализация которого осуществимо обоснованием разработки алгоритмов и программных средств на базе машинного обучения[1,2].

Транспортные потоки в современных мегаполисах отличаются непрерывным количественным ростом и высокой степенью непредсказуемости: нагрузка на дорожную сеть существенно варьируется в зависимости от времени суток, образуя выраженные утренние и вечерние пики, а также подвержена влиянию метеорологических условий, сезонных факторов, проведения дорожно-ремонтных мероприятий и внезапно возникающих аварийных ситуаций. Традиционные светофорные объекты, как правило, функционируют в режиме заранее запрограммированных временных циклов с фиксированной продолжительностью разрешающих фаз[5,8,17,].

**Постановка задачи.** Перекрестки улично-дорожной сети характеризуются нестационарностью среды, обусловленные нестабильным потоком движения по времени АТС, сложностью обучения в реальном времени, что требует точного предварительного имитационного моделирования. В целях разработки систем адаптивного управления светофорами на основе машинного обучения для уменьшения заторов и минимизацию времени ожидания транспорта на перекрестках требуется создание алгоритмов и программных средств, которые динамически регулируют фазы длительности сигналов светофора в реальном времени.

Перспективным направлением повышения эффективности являются адаптивные системы, а на дальнем горизонте — интеллектуальные алгоритмы, основанные на технологиях машинного обучения[4,11,12]. Именно вопрос о том, как соединить проверенные инженерные решения с этой перспективой, определил направление настоящей статьи.

Целью исследования являлась разработка и апробация алгоритмов и программных средств регулирования светофоров — от эвристического адаптивного управления до архитектуры, готовой к внедрению методов машинного обучения.

Первые попытки создания светофоров, способных реагировать на интенсивность транспортного потока, относятся к началу XX века. В 1928 году в США был запатентован «транспортный сигнал с управлением от транспортного средства», который переключался либо при нажатии пешеходом кнопки, либо при проезде автомобиля над контактным датчиком. Тем не менее, широкое распространение подобных систем стало возможным только с развитием электроники и вычислительной техники во второй половине XX века [1].

В 1960-х годах в Великобритании и США начали проводить эксперименты с индукционными петлями — датчиками, встроенными в дорожное покрытие. Эти устройства фиксировали присутствие автомобиля и отправляли сигнал управляющему контроллеру. В 1970-х годах в Торонто (Канада) была запущена одна из первых городских систем адаптивного управления светофорами, основанная на централизованной обработке данных с нескольких перекрестков[2,16].

В СССР первые опыты с адаптивными светофорами проводились в 1980-х годах в Москве и Ленинграде. Однако массовое внедрение таких систем началось только в 2000-х годах с появлением доступных микропроцессорных контроллеров и систем видеонаблюдения. В России крупные проекты по установке адаптивных светофоров реализуются в Москве, Санкт-Петербурге, Казани, Екатеринбурге и других крупных городах.

Существующие подходы к регулированию светофоров можно расположить на условной шкале зрелости. На одном полюсе — фиксированные циклы, не реагирующие на нагрузку. В середине — эвристические и адаптивные алгоритмы, к которым относятся, например, промышленные платформы SCATS и SCOOT, а также реализованные в настоящей работе режимы SMART и SMART_V2. На другом полюсе находятся методы, использующие машинное обучение и оптимизацию: инициатива Google Research Project Green Light и система Surtrac, разработанная в университете Карнеги-Меллон.

Настоящая работа осознанно и честно располагается на эвристическом уровне: именно эти алгоритмы реализованы, протестированы и валидированы. Вместе с тем программная архитектура спроектирована так, чтобы контроллер, принимающий решение о переключении фазы, можно было заменить обучаемым агентом без переработки остальной системы. Это и есть мост к машинному обучению[2].

**Материалы и методы.** В основу работы положен комплекс методов. На первом этапе проведён систематический анализ научных публикаций и технической документации по адаптивному и интеллектуальному регулированию, включая архитектуры реальных внедрённых систем [2].

Далее применено имитационное моделирование, позволяющее воспроизводить динамику транспортных потоков в управляемом вычислительном эксперименте с измеримыми показателями состояния и эффективности[3].

Для сопоставления режимов управления использован сравнительный анализ стратегий на типовых сценариях нагрузки по длине очередей, времени ожидания и пропускной способности перекрёстка.

Авторами была предложена и программно реализована прототипная имитация модели движения на регулируемом перекрёстке. Модель воспроизводит ключевые

аспекты реального движения: генерацию и динамику проведения потоков, перемещение низкой проводимости, процессы образования и рассасывания очередей, а также алгоритм смены светофорных фаз с учётом переходных интервалов - жёлтого сигнала и режим «все направления закрыты».

Практическая часть исследования реализована в виде программного комплекса на языке Python с визуализацией средствами библиотеки Pygame.

**Результаты исследования и обсуждения.**

Модель воспроизводит ключевые аспекты реального движения: генерацию и динамику проведения потоков, перемещение низкой проводимости, процессы образования и рассасывания очередей, а также алгоритм смены светофорных фаз с учётом переходных интервалов - жёлтого сигнала и режим «все направления закрыты». На языке Python с применением библиотеки Pygame был разработан программный комплекс, обеспечивающий визуализацию процессов моделирования, который позволяет реализовать интерактивное изменение параметров симуляции.

Архитектура построена вокруг разделения ответственности между тремя сущностями. Объект «Мир» (World) хранит состояние симуляции: время, параметры потоков, список автомобилей, вычисляемые показатели эффективности. Объект «Автомобиль» (Car) описывает положение, скорость и направление движения. Логика принятия решений о переключении фазы вынесена в отдельный управляющий модуль — Controller.

Именно Controller является единым интерфейсом, через который сегодня действуют эвристические алгоритмы, а в будущем может действовать обучаемый агент. Такое разделение ответственности означает, что смена алгоритма принятия решений не потребует переработки модели движения, визуализации или логики безопасности.

На основе описанной архитектуры реализованы три эвристических режима, образующих проверенный базис [3].

| Режим | Принцип | Что решает |
|---|---|---|
| FIXED | Фиксированный цикл | Заранее заданные длительности фаз — базовый уровень для сравнения с адаптивными и будущими ML-алгоритмами. |
| SMART | Актуированное управление | Сравнение загруженности текущего и противоположного направлений; переключение раньше срока при отсутствии очереди. Ограничения min/max зелёного. |
| SMART_V2 | Динамический зелёный | Длительность зелёной фазы — функция длины очереди: чем больше поток, тем дольше зелёный, в пределах ограничений. |

Рисунок 1. Архитектура имитационной модели перекрёстка

Фиксированный режим (FIXED) — классический цикл с заранее заданными длительностями фаз, демонстрирующий недостатки жёсткого управления при неравномерной нагрузке.

Актуированный режим (SMART) сравнивает загруженность текущего и противоположного направлений и переключает фазу раньше срока при отсутствии очереди на текущем направлении; для устойчивости введены ограничения минимальной и максимальной длительности зелёного сигнала.

Режим динамической длительности зелёного сигнала (SMART_V2) вычисляет продолжительность разрешающей фазы как функцию длины очереди, также в пределах заданных ограничений [4].

Эти алгоритмы одновременно служат эталоном эффективности, с которым в дальнейшем предстоит сравнивать политики, полученные методами машинного обучения.

Светофорный объект спроектирован как строгий автомат состояний: зелёный сигнал для одной группы направлений, затем жёлтый интервал, затем кратковременная фаза «все направления закрыты», и только после этого — зелёный для другой группы.

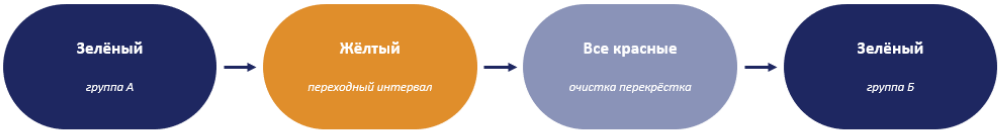



Рисунок 2. Автомат состояний светофорного объекта

Необходимо подчеркнуть значение этого решения именно в контексте машинного обучения. Автомат состояний работает как защитный контур, через который обязан пройти любой контроллер — фиксированный, эвристический или обучаемый. Даже если решение о переключении в будущем будет приниматься нейросетевым агентом, оно физически не сможет миновать переходные интервалы. Такое разделение задачи безопасности и задачи оптимизации делает платформу пригодной для безопасного тестирования будущих ML-политик [5,6].

Отдельно реализован механизм приоритетного проезда специального транспорта — скорой помощи, пожарных и полиции — по принципу preemption. При обнаружении спецмашины в контрольной зоне управление светофором временно перехватывается, выполняется безопасный переход через жёлтый интервал и фазу «все красные», после чего удерживается зелёный сигнал в направлении её движения.




Рисунок 3. Сравнение режимов FIXED, SMART и SMART_V2

Данный механизм реализован как надстройка над базовым контроллером и работает одинаково независимо от того, какой алгоритм принимает решения в штатном режиме — эвристический или, в перспективе, обучаемый.

Архитектура платформы уже сегодня формирует показатели, необходимые для постановки задачи управления в терминах обучения с подкреплением.

Состоянием (state) естественным образом выступают длина очередей по направлениям, текущая фаза и время нахождения в ней, а также наличие спецтранспорта. Действием (action) — решения удержать текущую фазу, переключить её или скорректировать длительность. Вознаграждением (reward) — показатели, обратные времени ожидания и длине очереди, а также пропускная способность перекрёстка.

Сегодня эти решения принимают эвристики SMART и SMART_V2. В перспективе тот же интерфейс Controller может принимать обучаемый агент — например, реализующий Q-обучение или метод градиента стратегии, — обученный именно на этой тройке «состояние — действие — вознаграждение» [7].

Отдельное внимание уделено информационной безопасности и достоверности результатов моделирования. Обеспечена целостность фазовой логики — исключение конфликтных комбинаций сигналов независимо от источника решения, будь то правило или обученная модель.

Сформирована модель угроз, учитывающая риски нарушения приоритета спецтранспорта и ошибки измерения очередей. Обеспечена достоверность и воспроизводимость результатов за счёт фиксации параметров сценария и начального значения генератора случайных чисел — это обязательное условие для честного сравнения алгоритмов, включая в будущем обучаемые. Предусмотрены и организационные меры: контроль версий, логирование состояний и резервное копирование.

Разработанная платформа уже сегодня позволяет наглядно оценивать влияние алгоритмов управления на задержки и очереди, обеспечивает валидированный эвристический базис для сравнения и безопасную надстройку приоритета специального транспорта [8].

В качестве направлений дальнейшего развития мы видим интеграцию обучаемого агента через интерфейс Controller, автоматизированный сбор статистики и многократные прогоны сценариев для обучения, а также расширение модели до сети из нескольких перекрёстков и учёта пешеходных потоков.

Реализована визуальная среда перекрёстка, воспроизводящая движение транспортных средств по четырём направлениям в соответствии с правилами дорожного движения: формирование транспортных потоков подчинено заданным критериям интенсивности, а остановка автомобилей перед стоп-линией выполняется корректно при запрещающем сигнале светофора [9].

Одним из наиболее известных примеров адаптивного регулирования транспортных потоков является система **SCOOT (Split Cycle Offset Optimisation Technique)**, разработанная компанией TRL в Великобритании. На выставке *Highways UK 2019* TRL представила последнюю версию программного обеспечения SCOOT, демонстрирующую возможности динамической оптимизации циклов светофоров. Система использует данные дорожных датчиков для постоянного пересчёта длительности фаз, что позволяет снижать задержки, уменьшать длину очередей и повышать общую пропускную способность перекрёстков. SCOOT внедрена в ряде крупных городов Европы и доказала свою эффективность в условиях высокой транспортной нагрузки.

Подобные технологии постепенно находят применение и в Центральной Азии. В январе 2024 года в Бишкеке началась установка первых «умных» светофоров, оснащённых адаптивными алгоритмами регулирования движения. По данным СМИ, новые объекты способны учитывать реальную загруженность перекрёстков и автоматически корректировать длительность фаз, что должно снизить заторы и повысить безопасность дорожного движения.

Для оптимизации пропускной способности полос при правоповоротном движении предлагается внедрить в систему «Умный светофор» адаптивный алгоритм управления пешеходными фазами. Механизм функционирует в режиме реального времени, динамически вычисляя минимально допустимое время для безопасного перехода дороги [10].

Инновационность решения заключается в использовании нейросетевой видеоаналитики, которая классифицирует транспортные средства и подсчитывает количество пешеходов. Это позволяет активировать сокращенный пешеходный такт только при наличии реальной транспортной нагрузки. Моделирование подтвердило

высокую эффективность метода: уменьшение пешеходной фазы всего на 2 секунды увеличивает пропускную способность на 28–30 ед./час. При 100-секундном цикле это обеспечивает прирост пропускной способности полосы на 8–10 %. Таким образом, предложенный подход позволяет гармонизировать интересы пешеходов и водителей, повышая общую эффективность дорожной сети [11].

Исследование динамики трафика на регулируемом перекрестке позволило определить, как пешеходные потоки влияют на пропускную способность дорог с учетом их конфигурации. Для повышения эффективности управления движением предлагается внедрить систему анализа видеопотока в реальном времени. В частности, рекомендуется сокращать длительность пешеходной фазы только при пиковых нагрузках на транспорт. Это решение не только делает условия для пешеходов более комфортными, чем при жестком программировании светофоров, но и повышает пропускную способность полос (при движении прямо и направо) до 50 %.




Рисунок 4. Умный светофор Бишкек

Следовательно, Кыргызстану следует общемировым тенденциям внедрения интеллектуальных транспортных систем. Опыт SCOOT и других зарубежных решений может служить ориентиром для дальнейшего развития локальных проектов. Важно подчеркнуть, что подобные внедрения не только повышают эффективность транспортной инфраструктуры, но и способствуют снижению экологической нагрузки за счёт уменьшения времени простоя автомобилей на перекрёстках.

В начале 2024 года Sitronics Group и администрация Бишкека запустили пилотный проект по интеллектуальному управлению дорожным движением. К февралю 2025 года «умные» светофоры, работающие на базе нейросетей, охватили 21 перекресток столицы. Система анализирует трафик в реальном времени и автоматически регулирует длительность сигналов, оптимизируя пропускную способность дорог. В планах властей — оснастить такой технологией все 378 светофорных объектов города. Бишкек стал одним из пионеров в Центральной Азии по внедрению ИИ в управление транспортными потоками, что позволяет эффективно бороться с пробками и следовать мировым трендам

цифровизации [12].

Бишкек стал наглядным примером того, как «умные» технологии меняют облик современного города. Интеграция нейросетевой видеоаналитики в работу светофоров превратила научные разработки в реальный инструмент управления городским трафиком.

Следуя глобальным тенденциям, столица Кыргызстана отказалась от жестких графиков работы светофоров в пользу гибких систем, подстраивающихся под реальный поток машин. Успех проекта Sitronics Group показывает, что адаптивное управление — это не просто эксперимент, а способ сделать город комфортнее, избавив его от пробок [13]. Сегодня такие решения становятся обязательным элементом стратегии развития, подтверждая востребованность технологий искусственного интеллекта в повседневной жизни.




Рисунок 5. Схема взаимодействия компонентов системы SCOOT

Таким образом, в ходе исследования показано, что фиксированные светофорные циклы не обеспечивают эффективного распределения пропускной способности при неравномерных потоках.

**Заключение.** Разработана и программно реализована имитационная модель регулируемого перекрёстка с тремя эвристическими режимами управления — FIXED, SMART и SMART_V2. Архитектура платформы спроектирована так, что управляющий модуль может быть заменён алгоритмом машинного обучения без переработки остальной системы. Реализованы безопасная фазовая логика и механизм приоритетного пропуска специального транспорта, действующие независимо от типа контроллера.

Полученная платформа обладает как самостоятельной практической ценностью, так и статусом полигона для дальнейших исследований в области интеллектуальных транспортных систем, включая применение методов машинного обучения.

Результаты исследования будут способствовать сокращению общего времени задержки машин, увеличению пропускной способности перекрестка и снижению уровня выбросов выхлопных газов.

**Литература.**

**1.** *АНТОНИАДИ Г. Д., АРХИПОВ ВО., ЦУПРИКОВ А.А.* Анализ модели задержки Вебстера // Ежемесячный научный журнал «Евразийский союз учёных». - 2018. - №11(56), ч. 9. - С. 6-12.

**2.** *АНТОНИАДИ Г.Д., АРХИПОВ В.О., ЦУПРИКОВ А.А.* Математическая модель задержки автотранспорта на регулируемом перекрёстке // Информационные технологии. -2019. - Т. 25, №4. - С. 210-215.

**3.** *БЕКЛАРЯН А. Л., БЕКЛАРЯН Л. А., АКОПОВ А.С.* Имитационная модель интеллектуальной транспортной системы «умного города» с адаптивным управлением светофорами на основе нечеткой кластеризации // Бизнес-информатика. -2023. - Т. 17, № 3. - С. 70-86.

**4.** *БЕЦКОВ А.В., ДИВЕЕВ А.И., СОФРОНОВА Е.А.* Об интеллектуальной транспортной системе в больших городах // Труды международного симпозиума «Надёжность и качество». - 2021. - Т. 1. - С. 295-298.

**5.** *БОРОВСКОЙ А.Е., ШЕВЦОВА А.Г.* Методика выбора рационального режима работы светофорного объекта на автомобильном транспорте // Трансп.: Наука, техн., упр./ ВИНИТИ РАН. - 2012. - №6. - С. 50-53.

**6.** ГОСТ Р 52282-2004 — Технические средства организации дорожного движения. Светофоры дорожные. Типы и основные параметры. Общие технические требования. Методы испытаний. - URL: https://docs.cntd.ru/document/1200038801 (дата обращения: 01.09.2024).

**7.** Методические рекомендации по разработке и реализации мероприятий по организации дорожного движения. Использование программных продуктов математического моделирования транспортных потоков при оценке эффективности проектных решений в сфере организации дорожного движения. - М.: Минтранс РФ, 2017. - 72 с. - URL: https:// mintrans.gov.ru/file/404538 (дата обращения: 09.09.2024).

**8.** *НАУМОВА Н.А., ДОМБРОВСКИЙ А.Н., ДАНОВИЧ Л.М.* Метод управления светофорной сигнализацией в условиях функционирования интеллектуальных транспортных систем // Фундаментальные исследования. - 2017. - №9-1. -С.64-68.

**9.** Отраслевой дорожный методический документ ОДМ 218.4.005-2010. Рекомендации по обеспечению безопасности движения на автомобильных дорогах. - М., 2011. - URL: https://irtechnologies.ru/assets/odm-218.4.005-2010.pdf (дата обращения: 09.09.2024).

**10.** Отраслевой дорожный методический документ ОДМ 218.6.003-011. Методические рекомендации по проектированию светофорных объектов на автомобильных дорогах. -М., 2011. - URL: https://files.stroyinf.ru/Data2/1/4293771/ 4293771345.pdf (дата обращения: 09.09.2024).

**11.** *СУЛИЦКИЙ М.В., ЗЕЛЕНСКИЙ И.С., САДОВНИКОВА Н.П.* и др. Разработка интеллектуальной системы распознавания объектов для решения задач ситуационного управления в городе // Современные наукоемкие технологии. - 2023.- № 7. - С. 104-109.

**12.** *ТИМОФЕЕВА О П., МАЛЫШЕВА Е.М., СОКОЛОВА Ю.В.* Проектирование интеллектуальной системы управления светофорами на основе нейронной сети // Современные проблемы науки и образования. - 2014. - №6. - URL: http:// www.science-education.ru/ru/article/view?id=16496 (дата обращения: 01.09.2024).

**13.** *ПАРЫГИН Д.С., БУРОВ С.С., АНОХИН А.О.* и др. Платформа для моделирования массовых перемещений объектов и субъектов в условиях городской среды // Программные продукты и системы. - 2021. - Т. 34, №2. - С. 354-364. - URL: http: //www.swsys .ru/files/2021 -2/354-364.pdf.

**14.** *AGRAWAL A., PAULUS R.* Intelligent traffic light design and control in smart cities: a survey on techniques and methodologies // Int. Journal of Vehicle Information and Communication Systems. - 2020. - Vol. 5, No. 4. - P. 436-481.

**15.** *ANDRIYANOV N.A., DEMENTIEV V.E., TASHLINSKII AG.* Detection of objects in the images: from likelihood relationships towards scalable and efficient neural networks //Computer Optics. - 2022. - Vol. 46, No. 1. - P. 139-159.

**16.** *ПЕЛИХ Д.А., ШАТАЛОВА Н.В.* Разработка программных средств адаптивного управления дорожным трафиком и оценка их эффективности // Труды учебных заведений связи. - 2026. - Т. 12. № 3. - С. 129-138. - DOI:10.31854/1813-324X-2026-12-3-129-138. EDN:XYELRO

**17.** *ВОЛОДИНА Ю.И., СЕРГЕЕВ Н.О., ЗАТОНСКИЙ А.В.* Исследование возможности моделирования светофорного регулирования сложного перекрестка в среде AnyLogic // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». - 2025. - Т. 25, № 2. - С. 19–32. - DOI: 10.14529/ctcr25020

# INTEGRATING HETEROGENEOUS DATA IN THE HIGHER EDUCATION SYSTEM BASED ON AN ONTOLOGICAL APPROACH

Nazirova E.Sh., Alimova FM
e-mail: tuit.alimova@gmail.com
*Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan*

***Abstract.*** *The volume of data is increasing from year to year. Including in the higher education system, the volume and type of data is increasing. In particular, the storage and processing of data related to the academic activities of students is one of the pressing issues. In order to monitor the dynamics of student development, it is necessary to use not only data from the LMS system, but also data from other distributed systems. Based on this, this article proposes an ontological approach to integrating heterogeneous data from different systems; the theoretical foundations of the approach are expanded and its practical application is illustrated with a concrete example.*

***Key words:*** *integration, ontology, higher education, information systems, process.*

The year-on-year increase in data volume within the higher education system creates a need to integrate data from diverse sources. Employing an ontological approach and refining hierarchical knowledge structures in distributed information systems offers an effective solution to this challenge.

Integrating data across various systems is a complex process that requires reconciling standards each with its own information model for representing data and knowledge across multiple databases. Several conflicts arise during this process, such as the use of differing terminology for similar concepts within the field, variations in specifications at the model and conceptual semantic levels, and the necessity of defining and transforming diverse data and knowledge structures [1].

As the higher education system undergoes digitalization, the growing volume and diversity of data spanning educational processes, students' scientific and creative activities, achievements, and other pursuits highlight the need to integrate a unified information environment. Ongoing research proposes addressing this issue through an ontological approach. Representing objects, their properties, and their interrelationships based on precise standards enables the integration of real-time data from diverse sources. This process takes into account data interoperability and interdependencies. Consequently, ontological models are increasingly utilized in constructing knowledge bases, integrating heterogeneous data sources, and generating new knowledge within intelligent information systems.

While many studies have emphasized knowledge base construction during integration, data and structures that change in real time have not yet been sufficiently explored. In this context, refining hierarchical knowledge structures based on an ontological approach to integrate data from various sources within the higher education system represents a significant area of research. Such an approach facilitates ensuring semantic interoperability, unifying information from diverse sources into a single knowledge environment, expanding the knowledge base with new data, and enhancing its adaptability to changes in the subject domain. Existing literature covers topics such as constructing ontological models without restructuring underlying databases, modeling data sources, subject domains, and processing workflows, as well as identifying semantic connections between them.

## Formal model of ontology

We define the ontology as 6-tuple as follows:

$$O = \langle S,\ M,\ P,\ T,\ A,\ E \rangle$$

here:

• S is a set of classes,
• M is a set of object properties (relationships),
• P is a set of class attributes (data type properties),
• T is a set of data types,
• A is a set of axioms,
• E is a set of instances (objects).

The set of relations M is represented as a set of binary relations between classes as follows:

$$\forall M_1 \in M\ \exists S_1, S_2 :\ M_1\ \subseteq\ S_1\ \times\ S_2\ (1)$$

The set of class attributes P is represented as a set of binary relationships between classes and data types:

$$\forall P_1 \in P\ \exists S_1 \in S,\ T_1 \in T :\ P_1\ \subseteq\ S_1\ \times\ T_1\ (2)$$

ontology instances E as some subset of instances each of which corresponds to at least one class of the ontology:

$$E\ \subseteq\ \bigcup(S_i \in S)\ S_i,\ \forall a \in E\ \exists S_1 \in S :\ a \in S_1\ (3)$$

We define a set of axioms A as a set of three types of statements about ontology instances:

1. Instance a belongs to class $S_1$.
2. Instances a and b are in the relation $M_1$.
3. Instance a has the property $P_1$ of data type $T_1$ with value t.

For the convenience of further definitions, we introduce the following formal definitions for these three types of axioms:

$$S_1(a)\ \iff\ (a \in E,\ S_1 \in S,\ a \in S_1)$$
$$M_1(a,b)\ \iff\ (a,b \in E,\ M_1 \in M,\ aM_1b,\ (\exists S_1, S_2 \in S :\ M_1 \subseteq S_1 \times S_2))$$
$$P_1(a,\ T_1(t))\ \iff\ (a \in E,\ t \in T_1,\ P_1 \in P,\ aP_1t,\ (\exists S_1 \in S,\ T_1 \in T :\ P_1 \subseteq S_1 \times T_1))\ (4)$$

Any fact represented by an ontology O represents a set of axioms. When developing ontologies, a small number of instances and facts about them are usually pre-introduced into the ontology. The bulk of the facts are formed on the basis of domain information that enters the fact base during the process of collecting, processing, analyzing, and interpreting information from various sources.

Thus, the set A is only a subset of the set A*, the set of all axioms that can theoretically be annotated using the ontology O. We denote the fact base represented by the ontology O as F and define it as a subset of the set A*. As a result, we have:

$$A^* = \bigcup(S_i \in S)\{S_i(a) \mid a \in E\}\ +\ \bigcup(M_j \in M)\{M_j(a,b) \mid a,b \in E\}\ +\ \bigcup(P_k \in P,\ T_l \in T)\{P_k(a,T_l(t)) \mid a \in E,\ t \in T\}$$
$$A,\ F\ \subseteq_{\mathrm{A}^*},\ |F|\ \ll\ |A|\ (5)$$

Finally, the knowledge base K can be formally represented as a pair:

$$K\ =\ \langle O,\ F\rangle$$

We call the set of rules that define the association of elements of ontology $O_1$ with elements of ontology $O_2$ to determine the interpretation of data when the context of the subject domain changes, an ontological mapping , and $f :\ O_1\ \rightsquigarrow\ O_2$We denote this by I(f). Based on this, we define a formal procedure that maps the axioms of terms in one ontology to terms in another ontology. We call such a mapping an interpretive mapping and denote it by I( f).

Let q be a query sent to a fact base corresponding to an ontology O. It determines a subset of axioms that are extracted from the corresponding fact base and are described by the ontology O. Then, let p denote a domain information processing procedure: based on a subset of domain information (axioms) described by some ontology, it assigns a new subset of axioms described by that ontology. Finally, let $O_1$, $O_2$, $O_3$ be ontologies, and f: $O_1 \rightsquigarrow O_2$, $g :\ O_2 \rightsquigarrow O_3$be ontological representations. Then, the process of filling the

knowledge base with new facts when applying domain information processing and interpretation procedures can be formally defined as the following composition:

$$[I(g)] \circ p \circ [I(f)] \circ q \ (6)$$

where q is the input data generation procedure, the structure of which is described by the ontology $O_1$. Then the interpretive representation I*(f)* is used to structure this data according to the ontology $O_2$, which declaratively describes the processing problem using the procedure p. Finally, the interpretive representation I(g) represents the interpretation of the data processing results to structure them according to the terms of the ontology $O_3$.

The described model allows us to define an approach to ensuring traceability of changes. In particular, it is possible to determine the corresponding ontological mappings $F_{ij} : O_i \rightsquigarrow O_j$between different versions of ontologies using production rules, where i, j are ontology versions.

(4) - ( 6) are qualitatively descriptive and $O_1 \rightsquigarrow O_2$do not provide a quantitative criterion for how the reflection f: is constructed. To overcome this shortcoming, we introduce a function that evaluates the semantic proximity between ontologies:

$$C : K \times K \to [0,1],$$
$$C(K_i, K_j) = \alpha \cdot C_{\text{attr}}(K_i, K_j) + \beta \cdot C_{\text{tax}}(K_i, K_j) + \gamma \cdot C_{\text{rel}}$$
$$(K_i, K_j),\ \alpha + \beta + \gamma = 1,\ \alpha, \beta, \gamma \geq 0 \ (7)$$

where $C_{attr}$ is the attributive closeness (average degree of similarity in P), $C_{tax}$ is the taxonomic closeness (positional closeness in the class hierarchy S), $C_{rel}$ is the relational closeness (relational closeness M), and α , β , γ are their relative weight coefficients [1].

On this basis, the construction rule of the reflection in formula (6) $f : O_1 \rightsquigarrow O_2$can be expressed in the form of a definite condition:

$$f(K_i) = K_j,\ if\ C(K_i, K_j) \geq y \ (8)$$

where y∈[0,1] is a predefined semantic proximity threshold. If condition (8) is not met, $K_i$ and $K_j$ are considered distinct, and they are included in the differentiation class and stored separately, respectively.

When integrating multiple source ontologies (e.g., SIS, LMS, portfolio repository), the fact base F defined in formula (5) is expanded as follows:

$$Fint = \bigcup (i = 1..N)\ F_i \setminus \{S_k(a) \mid \exists S_l : C(S_k, S_l) \geq y,\ k \neq l\} \ (9)$$

that is, facts that are considered equivalent to each other (and therefore considered duplicates) according to condition (8) are excluded from the final fact base. This turns the abstract axiom and reflection apparatus given in formulas (7)-(9) into a practically computable, programmatically applicable criterion.

**The issue of ontology adaptation levels and semantic connectivity**

Ontologies developed independently in different information systems differ structurally and semantically: the same concept may be named differently, the composition of attributes may not match, or the same subject area may be described from different perspectives. The literature distinguishes three levels of overcoming such heterogeneity: (1) alignment is a simple mapping of concepts and relationships between ontologies without changing axioms or conclusions; (2) partial compatibility is a mapping that also provides equivalence of conclusions and calculations for compatible concepts; (3) unification is the highest level that provides one-valued compatibility of all concepts and relationships between two ontologies [1].

Using the proximity function $C(K_i, K_j)$ introduced in formula (7) and the threshold y from formula (8), it is possible to quantitatively distinguish five classes of semantic relationships between ontologies: equivalence $(C(K_i, K_j) \to 1;$ $K_i$ and $K_j$ correspond fully), generalization (multiple $K_j$ correspond to a single $K_i$, satisfying the condition C≥y),

specialization (a single $K_j$ corresponds to multiple $K_i$), partial equivalence ($C(K_i,K_j)$ has a partial value i.e., above y but less than 1), and distinctness $(C(K_i, K_j) < y)$[1]. This classification serves as a basis for extending the ontological model $O = \langle S, M, P, T, A, E\rangle$ : any specific instance of the mapping $f : O_1 \rightsquigarrow O_2$ can be assigned to one of the five aforementioned classes, thereby allowing for the pre-determination of the elements (classes S, relations M, or attributes P) upon which the operation is to be performed when constructing the interpreting mapping I(f).

**Mapping the "Student" class between different information systems**

To demonstrate the practical application of the proposed model, we examine three information sources widely used in the higher education system: the Student Information System (SIS), the Learning Management System (LMS), and the portfolio repository for scientific and creative activities. Each system represents the concept of a "student" differently within its own ontology:

• In the $O_{SIS}$ ontology, the "Student" class is designated as $S_1$, with its associated attribute set limited to $P(S_1) = \{ID,\ Full\ Name,\ Group,\ Year\ of\ Study,\ GPA\}$;

• In the $O_{LMS}$ ontology, the corresponding class is named "User" ($S_2$), and the relationship $S_1 \subset S_2$holds (every student is a user, but not every user is a student); its attributes are represented as $P(S_2) = \{login,\ list\_of\_courses,\ activity\_score\}$;

• In the $O_{Portfolio}$ ontology, the student's scientific publications, grants, and achievements are linked via the "Participant" class ($S_3$) and the relationship $M_3$: $M_3$(a, b) — "participant a possesses achievement b".

We construct mappings between these three ontologies in the form $f_{12}$: $O_{SIS} \rightsquigarrow O_{LMS}$ and $f_{13}$: $O_{SIS} \rightsquigarrow O_{Portfolio}$. For the classes $S_1$ (Student) and $S_2$ (User), the similarity value $C(S_1,S_2)$ is calculated using formula (7) is exceeds the threshold y due to the matching of ID/login attributes (high Cattr) but does not reach 1 (since $S_2$ encompasses a broader concept, i.e., $S_1 \subset S_2$); consequently, the mapping $f_{12}$ is constructed in accordance with condition (8) and falls into the class of partial correspondence (partial equivalence): $P_1(a, T_1(id)) \iff P_2(a, T_2(login))$. In this case, the interpreting mapping $I(f_{12})$ maps the student identifier in the SIS system to the corresponding login value in the LMS system.

For $f_{13}$, $C(S_1, S_3) \to 1$, which is an example of equivalence-level matching: each student ($S_1$ element) corresponds to one participant ($S_3$ element) in the portfolio repository, that is, $\forall a \in E :\ S_1(a) \iff S_3(a)$. Through this reflection, the composite process presented in expression (6) $[I(f_{13})] \circ p \circ [I(f_{12})] \circ q$ actually works as follows: query q forms the basic student data from the SIS system, procedure p enriches this data with LMS activity indicators, and then the reflection $I(f_{13})$ structures the result in terms of the portfolio repository, creating a single, integrated knowledge profile of the student (K = in the form of ⟨O,F⟩).

**The process of pulling data from multiple sources into a student portfolio (pull-integration).**

The example examined in Section 4 involved only two sources (SIS and LMS). In practice, however, information about a student may be stored simultaneously in multiple (N) independent systems such as the SIS, LMS, library system, research grant tracking system, and so on. In such a case, to formally represent the process of "pulling" all the student's data into a unified portfolio, we extend the two- or three-stage compositional chain presented in Formula (6) to the general multi-source scenario.

First, we introduce the procedure for extracting, from the fact base $F_i$ of the i-th system, all facts relevant to a specific instance (for example, a particular student a):

$$q(a, F_i) = \{S(a) \mid S(a) \in F_i\} \cup \{M(a,b) \mid M(a,b) \in F_i\} \cup \{P(a, T(t)) \mid P(a, T(t)) \in F_i\} \quad (10)$$

that is, q(a, $F_i$) is the subset of class-membership, relation, and attribute facts from the fact base $F_i$ that pertain solely to the instance a. This is the specific form of the procedure q from formula (6), applied to a single concrete instance.

Now, we successively map the subset q(a,$F_i$) derived from each of the N source systems to the terms of the portfolio ontology using the corresponding mapping I($f_i$) (constructed according to condition (8)) and merge the results:

$$Pull(a) \;=\; \bigcup (i = 1..N)\; [I(f_i)](q(a,\; F_i)) \;\; (11)$$

where $f_i : O_i \rightsquigarrow O_{\text{Portfolio}}$ is mapping from the ontology of the i-source to the ontology of the portfolio. Formula (11) describes a parallel process of assembling N independent sources into a single result point (portfolio), in contrast to the sequential (chain-like) composition in formula (6) this allows updating the student's knowledge in different systems not by a single query, but by reviewing all connected sources each time.

Finally, the Pull(a) set may contain facts originating from different systems but identical in content (for example, the "faol" status in the SIS and the "active" status in the LMS). We identify such redundancies using the C and y criteria introduced in formulas (7)-(8) and clean the data as follows before including it in the portfolio:

$$FP(a) \;=\; Pull(a) \setminus \{S_k(a) \mid \exists S_l(a) \in Pull(a) :\; C(S_k, S_l) \;\geq\; y,\; k \neq l\} \quad (12)$$

In other words, $F_P(a)$ is the student's final portfolio profile, cleansed of duplicates. Thus, formulas (10)-(12) build upon the concept in formula (6) to provide a fully formal representation of the process of aggregating information about a single student (or any other entity) from an unlimited number of source systems into a single, consistent portfolio.

## Conclusion

This article proposes an ontological approach to integrating heterogeneous data within the higher education system. Using a formal model defined as O = ⟨S, M, P, T, A, E⟩, the components are classes, relations, attributes, data types, axioms, and instances were expressed through a precise mathematical framework; additionally, a mapping function f: $O_1 \rightsquigarrow O_2$ and its corresponding interpretation operation I(f) were introduced. The model's qualitative descriptive framework (represented by equations (4)-(6)) was extended with formulas (7)-(9), incorporating a semantic proximity function C($K_i$, $K_j$), a criterion for establishing mappings (C($K_i$, $K_j$) ≥ y), and a rule for eliminating duplicate facts during multi-source integration thereby transforming the abstract model into a computationally feasible form. Furthermore, based on existing literature [1], three levels of ontology alignment (alignment, partial correspondence, and unification) and five classes of semantic relationships were outlined, providing more precise criteria for the model's practical application. The practical significance of the model was demonstrated through the example of mapping the "Student" class across the ontologies of SIS, LMS, and portfolio repositories. Furthermore, the process of aggregating a student's data from multiple source systems into a unified portfolio (pull-integration) was formally expressed via formulas (10)-(12), enabling the model's application to real-world scenarios involving more than two sources.

A key advantage of this approach is that it does not require restructuring existing information systems; integration occurs solely at the level of ontological mappings. However, the model has certain limitations: first, selecting the weight coefficients α, β, and γ in formula (7) and the threshold γ in formula (8) currently relies heavily on expert input; second, a mechanism for dynamically updating mappings in response to real-time data streams has not yet been developed. Future research will focus on developing methods for the automated assessment of semantic proximity (based on attributive, taxonomic, and relational metrics) and algorithms for the semi-automated construction of ontological mappings.

## References

1. Бова, В.В. Онтологическая модель интеграции данных и знаний в интеллектуальных информационных системах /В.В.Бова. – Известия ЮФУ. Технические науки. 2015. № 4 (165). – С. 225–237.
2. Гаврилова Т.А. Онтологический подход к управлению знаниями при разработке корпоративных информационных систем / Т.А. Гаврилова. – Новости искусственного интеллекта. 2003. № 1 (55). – С. 24–30.
3. Скворцов Н.А. Вопросы согласования неоднородных онтологических моделей и онтологических контекстов / Н.А. Скворцов. – Онтологическое моделирование. – М.: ИПИ РАН, 2008. – С. 149–166.
4. Alimova F.M. Evaluation of the continuity of educational and scientific activities of students using the method of dynamic norm / F.M.Alimova. – Ethiopian International Journal of Multidisciplinary Researc. Volume:12. Issue 12. – 2025.

# Agricultural Production Planning and Problem Solving Using MS Excel.

Maatov K.M.[1], Mambetov Zh.I.[1], Toktorbaev A.M.[2], Kholiknazarov R.Kh.[3], Ergashev O.M.[3], Mamadaliev N.A.[3]
e-mail: maatov84@gmail.com, zhoomartmambetov@gmail.com, ain7@list.ru, abdurashidinvestor@gmail.com, ergashev1984otabek@gmail.com, men.mna74@gmail.com
[1]*Osh Technological University, Osh, Kyrgyzstan*
[2]*Osh State University, Osh, Kyrgyzstan*
[3]*Fergana State Technical University, Fergana, Uzbekistan*

***Abstract****. The article examines the issue of meeting the agricultural production needs of a hypothetical enterprise for the planned period through internal production and the import of products from other enterprises. A mathematical model of optimizing agricultural production and its importation at minimal total costs is formulated. To verify the effectiveness of the formulated model, a specific example is presented and solved using the Solver add-in in Excel.*

***Keywords****: mathematical model, costs, production, wholesale prices, set, arable land, optimization, agricultural products, MS Excel.*

## INTRODUCTION

In contemporary times, agriculture perseveres as a pivotal sector within the global economy, serving as a cornerstone for both food security and industrial raw material provision. Proficient planning of agricultural production stands as an indispensable element in fostering the consistent advancement of this domain. Leveraging modern tools, notably Microsoft Excel, substantially streamlines this procedural intricacy, thereby facilitating the attainment of optimal outcomes.

In the modern stage of agricultural development, the role of expanding market access significantly increases, viewed as an indispensable condition for attracting investments in the technical and technological modernization of the sector, enhancing employment, and augmenting revenues for budgets at all levels. Presently, pivotal points of sales growth in agricultural products and the agrarian sector of the national economy as a whole are logistics centers - hubs that shape commodity transport flows at national, regional, and local levels, stimulating the processing of agricultural produce. In [1], the assessment of the role of logistics centers in the agricultural sector and their influence on product competitiveness (using the example of the Southern region of Kyrgyzstan) is examined, along with the necessity for investment planning for the creation of a logistics center with the involvement of the Kyrgyz-Russian Fund.

In [2], a mathematical model is formulated for determining the technological method of agricultural production for an agricultural firm, allowing for the maximization of income. A specific example is considered, and the solution is obtained using a program written in Pascal language.

Theoretical foundations of production efficiency in agriculture, particularly in the Kyrgyz Republic (KR), are examined in [3]. The subjects of agricultural production in the KR are the focus of the study. Theoretical aspects are refined based on a synthesis of existing perspectives from predecessors on this issue, clarifying the concepts and specific features of production efficiency in agriculture. In the current stage of agricultural economy development worldwide, especially in developing countries including Kyrgyzstan, the issue of agricultural production efficiency becomes increasingly acute and relevant. The urgency and relevance of this issue, as well as its formulation, primarily indicate that the republic possesses a sufficient level of potential in the agricultural sector. Only through rational resource utilization, application of intensive technologies, and consequent enhancement of production efficiency can sustainable growth rates of production and steady improvement in the material and cultural standards of

rural inhabitants be ensured.

For the effective operation of the agricultural sector within market environments, attaining the rational utilization of existing resources is imperative, extending beyond the confines of agriculture itself to encompass closely associated industries. In [4], avenues for enhancing the management of agriculture in the Kyrgyz Republic are explored. The study focuses on agricultural entities within the Kyrgyz Republic, conducting a thorough investigation into specific challenges, exemplified through peasant and farm households. The research elucidates the motives driving agricultural production management within Kyrgyzstan's local governing bodies and proposes fundamental strategies to augment the economic efficiency of agricultural production.

The aim of research work [5] is the systematic examination of the theoretical foundations and practical challenges of agrarian reform within the context of evolving market dynamics, alongside the development of practical recommendations and methodological frameworks for their implementation in the conditions of the Kyrgyz Republic. The subject and object of the research encompass a set of organizational and economic issues associated with the formation of agrarian reform. Throughout the study, methods such as systems analysis, economic-statistical analysis, monographic analysis, and comparative methods were employed. The research findings consolidate and deepen theoretical insights pertaining to agrarian sector reform and its impact on the country's economy.

Works [8-11] are dedicated to the planning of agricultural production and the resolution of various tasks using MS Excel.

In this study, methods of agricultural production planning using MS Excel are explored, and the applicability of this tool for addressing specific tasks in the agricultural sector is investigated. The results of works [6-7] are utilized in this study.

## METHODOLOGY

**Formulation of the problem**. Let a conditional enterprise $A_0$ have a sown area of various categories in the amount of $s_0^l,\ \ l \in L_0 = \{1, 2, \dots, L_0\}$, where they can be used for the production of k – types of agricultural products, $k \in K = \{1, 2, \dots, p\}$. Based on long-term data, we believe that the yield of each agricultural product by category of sown area is known. The enterprise's needs for various types of products for the planned period amount to $q_0^k,\ \ k \in K$.

In addition, the enterprise has trade-economic relations with other similar enterprises $A_i,\ i \in I = \{1, 2, \dots, m\}$ and, if necessary, can purchase agricultural products from them $A_i,\ i \in I$.

The costs of an enterprise for the production of a unit volume of each type of product on cultivated areas of various categories $c_l^k,\ k \in K,\ l = 1,2,\dots, L_0,$ , , procurement, and transportation costs $c_{i0}^k,\ \ k \in K$ per unit volume of each type of purchased product from each similar enterprise are known $A_i,\ i \in I$.

It is necessary to determine the optimal volume of products produced in the enterprise and purchased from $A_i,\ i \in I$ each type of product so that the total costs of production and purchase of products would be minimal and at the same time, the needs of the enterprise would be fully satisfied.

Having introduced several notations, we compose the mathematical problem for this problem:

$l$ – index of sown areas of various categories $l \in L_0$ ;

$i$ – index of similar enterprises having trade and economic relations $A_i$, $i \in I = \overline{1,2,\ldots,m}$;

$k$ – index of the type of product required for the enterprise $k \in K = \overline{1,2,\ldots,p}$;

Known parameters:

$S_0^l$ – And the size of the ***l***- category of planting area of the enterprise is known parameters: $l \in L_0$;

$q_0^k$ – volume of demand for the ***k***-type of product for the planned period of the enterprise $k \in K$;

$a_l^k$ – productivity of the ***k***- agricultural product (in tons) per unit of the ***l***- category of sown area, $k \in K, l \in L_0$;

$c_{i0}^k$ – procurement and transportation costs of the enterprise per unit volume of products of the ***k***-type from other similar enterprises $A_i,\ k \in K,\ i \in I$;

$c_l^k$ – production costs of the enterprise per unit volume of products of the ***k***- type, $k \in K,\ l \in L_0$.

Searched variables:

$x_l^k$ – size of the l- category of sown area for the k- type of agricultural products $k \in K,\ l \in L_0$;

$y_{i0}^k$ – volume of imported products of the k- type, $k \in K,\ i \in I$.

Using the above notations and taking into account the goal, a mathematical model of the task is compiled:

$$G(x,y) = \sum_{k \in K_0} \sum_{l \in L_0} c_l^k x_l^k + \sum_{k \in K} \sum_{i \in I} c_{io}^k x_{io}^k \to \min \tag{1}$$

subject to restrictions

$$\sum_{k \in K_0} x_l^k \le s_o^l, \quad l \in L_o \tag{2}$$

$$\sum_{l \in L_0} a_l^k x_l^k + \sum_{i \in I} y_{io}^k = q_o^k,\ k \in K, \tag{3}$$

$$\sum_{l \in L_0} a_l^k x_l^k \le q_o^k, \quad k \in K_o, \tag{4}$$

$$x_l^k \ge 0,\ k \in K,\ l \in L_o, \tag{5}$$

$$y_{io}^k \ge 0,\ k \in K,\ i \in I, \tag{6}$$

где

$$x = \left| x_l^k \right|_{|L_o||K_o|}, \quad y = \left| y_{io}^k \right|_{|I||K|}$$

Problem (1)-(6) is a special case of the extremal problem considered in [1].

Let's look at an example. Let the enterprise have a cultivated area of 100 hectares, which

$$s_o^l = \left\{ s_o^1, s_o^2, s_o^3, s_o^4 \right\} = \left\{ 24,22,26,28 \right\}$$

consists of four categories of land, i.e..

$q_o^k,\ k = 1,2,3,$

The region's need for three types of crops (in tons) is i.e. $q_o^k = \left\{ q_o^1, q_o^2, q_o^3 \right\} = \left\{ 420,200,400 \right\}$

.

The yield per unit of sown area from each category of land is given in the form of a matrix $a_o^k,\ k = 1,2,3,\ i = 1,2,3,4,$ т.е.:

$$\left| a_l^k \right|_{4,3} = \begin{pmatrix} 6 & 4 & 16 \\ 7 & 3 & 17 \\ 5 & 3 & 14 \\ 4 & 2 & 10 \end{pmatrix}.$$

The costs of growing the k- type of agricultural product per unit size of sown area are known, depending on the category of land $c_l^k,\ k = 1,2,3,\ i = 1,2,3,4,$ (som/ha) i.e.:

$$\left| c_l^k \right|_{4,3} = \begin{pmatrix} 32250.0 & 30950.0 & 12125.0 \\ 29950.0 & 33100.0 & 14100.0 \\ 34500.0 & 37450.0 & 21120.0 \\ 38200.0 & 42300.0 & 41200.0 \end{pmatrix}.$$

Also known are the purchase and transportation costs of the $c_{io}^k$ k- type of agricultural products from $A_i$в $A_o$, k=1,2,3, *i*=1,2,3, i.e.:

$$\left| c_{io}^k \right|_{3,3} = \begin{pmatrix} 11000 & 12000 & 40000 \\ 9000 & 10000 & 2500 \\ 10000 & 9000 & 3700 \end{pmatrix}.$$

By the above data, the mathematical model of the problem will be written in the form. Find the minimum

$$G(x,y) = 32250.0x_1^1 + 30950.0x_1^2 + 12125.0x_1^3 + 29950.0x_2^1 + 33100.0x_2^2 +$$

$$+ 14100.0x_2^3 + +34500.0x_3^1 + 37450.0x_3^2 + 21120.0x_3^3 + 38200.0x_4^1 + 42300.0x_4^2 +$$

$$+ 41200.0x_4^3 + 11000.0y_{10}^1 + 12000.0y_{10}^2 + 4000.0y_{10}^3 + 9000.0y_{20}^1 + 10000.0y_{20}^2 +$$

$$+ 2500.0y_{20}^3 + 10000.0y_{30}^1 + 9000.0y_{30}^2 + 3700.0y_{30}^3 \qquad (7)$$

under conditions

$$\sum_{k=1}^{3} x_1^k \le 24, \quad \sum_{k=1}^{3} x_2^k \le 22, \quad \sum_{k=1}^{3} x_3^k \le 26, \quad \sum_{k=1}^{3} x_4^k \le 28,$$

(8)

$$6x_1^1 + 7x_2^1 + 5x_3^1 + 4x_4^1 + \sum_{i=1}^{3} y_{i0}^l = 420.0$$

(9)

$$4x_1^2 + 3x_2^2 + 3x_3^2 + 2x_4^2 + \sum_{i=1}^{3} y_{i0}^2 = 200.0,$$

(10)

$$16x_1^3 + 17x_2^3 + 14x_3^3 + 10x_4^3 + \sum_{i=1}^{3} y_{i0}^3 = 400.0,$$

(11)

$$6x_1^1 + 7x_2^1 + 5x_3^1 + 168x_4^1 \le 420.0,$$

(12)

$$4x_1^2 + 3x_2^2 + 3x_3^2 + 2x_4^2 \le 200.0,$$

(13)

$$16x_1^3 + 17x_2^3 + 14x_3^3 + 10x_4^3 \le 400.0,$$

(14)

$$x_l^k \ge 0, \ l = 1,2,3,4, \ k = 1,2,3,$$

(15)

$$y_{io}^k \ge 0, \ i = 1,2,3, \ k = 1,2,3,4,$$

(16)

$$x = \left| x_l^k \right|_{4,3}, \quad y = \left| y_{io}^k \right|_{3,3}.$$

где

Having solved problem (7)-(16) using the “Solution Search” add-in in Excel [2], we obtain an optimal production plan in $A_0$ and a plan for the purchase of agricultural products from similar enterprises $A_i$, $i$=1,2,3, with which we have trade-economic relations, i.e.:

$$X^* = \left\{ x_1^3 = 24.0, \ x_2^1 = 22.0, \ x_3^1 = 24.86, \ x_3^3 = 1.143, \ x_4^1 = 28.0 \right\},$$

$$y^* = \left\{ y_{20}^1 = 29.71, \quad y_{10}^3 = 200.0 \right\},$$

where the objective function has a value

G(x*,y*)=4968637.143 som.

From the optimal solution to the problem it follows that enterprise $A_0$, to meet the population's needs for agricultural products for the planned period, must allocate from the first category of sown area in the amount of $x_1^3 = 24.0$ hectares for the third type of agricultural products, from the second category of sown area in the amount of $x_2^1 = 22.0$ hectares for the first type of agricultural products, from the third category The sown area should be allocated in the amount of $x_3^1 = 24.86$, $x_3^3 = 1.143$ hectares. respectively, for the first and third types of agricultural products. From the fourth category, the sown area in the amount of $x_4^1 = 28.0$ hectares should be allocated for the first type of product.

It is clear from the decision that the production of agricultural products of the first and second types from the first and second categories of land is more expensive than imported ones. In this

regard, it is recommended to meet the demand of enterprise $A_0$ for this type of agricultural product with imported products from $A_{20}$ and $A_{30}$ in the amount of $y_{20}^1 = 29.71$ and $y_{10}^2 = 200.0$ tons

With this plan, the total costs of the enterprise $A_0$ are

$$G(x^*,y^*) = 4968637.143 \text{ som.}$$

Thus, the formulated mathematical model can be used by relevant departments to plan agricultural production.

## CONCLUSION

The article presents a mathematical model for meeting the agricultural production needs of a hypothetical enterprise over a planned period through internal production and import of products from other enterprises. A specific example is provided. In solving the problem, the MS Excel spreadsheet was utilized. The use of MS Excel in agricultural production planning helps agricultural enterprises efficiently manage resources, minimize risks, and achieve optimal results. Thus, the formulated mathematical model can be used by relevant authorities for planning agricultural production.

## REFERENCES.

1. Umarov, S.T. Assessment of the role of logistics centers in the agricultural sector and their impact on product competitiveness using mathematical decision-making methods (on the example of the Southern region of Kyrgyzstan) / S.T. Umarov, K.M. Maatov // Economics and Innovation Management. – 2020. – No. 1(12). – P. 83-93.
2. Zhusupbaev, N.A. Determination of the technological method of agricultural production for a farm based on the criterion of maximum income / N.A. Zhusupbaev, Zh. Turganbayeva, K. Maatov // Bulletin of the Institute of Mathematics of the National Academy of Sciences of the Kyrgyz Republic. – 2018. – No. 1. – P. 163-168.
3. Abdiev M.J. Improving management in agriculture of the Kyrgyz Republic / M. J. Abdiev, K. M. Maatov // Economy And Business: Theory And Practice. – 2017. – № 2. – С. 4-7.
4. Mametova, G.A. Theoretical foundations of production efficiency in agriculture / G.A. Mametova, K.M. Maatov, K.A. Ergeshov // Economics and Business: Theory and Practice. – 2017. – No. 2. – P. 56-60.
5. Ergeşov, K.A. Features of agrarian reform in the Kyrgyz Republic in market conditions / K.A. Ergeşov // Science. Education. Technology. – 2017. – No. 1(58). – P. 23-26.
6. Asankulova, M., Zhusupbaev, A. Optimization of extraction and distribution of raw materials among consumers depending on the period // Problems of modern science and education. 2016. No. 4 (46). P. 7 – 12. ISSN 2304-2338 (print version), ISSN 2413-4635 (electronic version)
7. Asankulova, M., Zhusupbaev, A., Zhusupbaev, G.A. Determination of the maximum income of the enterprise with limited financial resources // Current directions of scientific research of the XXI century: Theory and Practice. 2015. Vol. 3. No. 7 part 1(18-1). P. 101 – 105.
8. Asankulova, M. Determination of the optimal size of the sown area for agricultural crops of the farm / M. Asankulova, N.K. Suinalieva, K. Maatov // Bulletin of the Institute of Mathematics of the National Academy of Sciences of the Kyrgyz Republic. – 2018. – No. 1. – P. 37-43.
9. Ashirbaeva, A.Zh. Solving the integer programming problem using MS Excel / A.Zh. Ashirbaeva, K.A. Abdizakir // Proceedings of the Osh Technological University. – 2020. – No. 1. – P. 152-155.
10. Kultaev, T.Ch. Ways to improve the efficiency of processing enterprises of agricultural products in the Kyrgyz Republic / T.Ch. Kultaev, K.K. Toktorov // Proceedings of the Issyk-Kul Forum of Accountants and Auditors of the Central Asian countries. – 2020.

– No. 3(30). – P. 77-82.
11. Maatov, K.M. Determination of the optimal volume of production and its leasing in the cotton industry / K.M. Maatov // Bulletin of Jalal-Abad State University. – 2023. – No. S2(55). – P. 135-141.

# AI-ASSISTED REAL-TIME STUDENT PERFORMANCE PREDICTION USING WEB TECHNOLOGIES

Ergashev O.M.[1], Mamadaliev N.A.[1], Kholiknazarov R.Kh.[1], Mambetov Zh.I.[2], Toktorbaev A.M.[3], Maatov K.M.[2]
e-mail: ergashev1984otabek@gmail.com, men.mna74@gmail.com, abdurashidinvestor@gmail.com, zhoomartmambetov@gmail.com, ain7@list.ru, maatov84@gmail.com
[1]*Fergana State Technical University, Fergana, Uzbekistan*
[2]*Osh Technological University, Osh, Kyrgyzstan*
[3]*Osh State University, Osh, Kyrgyzstan*

***Abstract.*** *This study proposes an AI-assisted real-time student performance prediction framework based on web technologies and learning analytics. The framework continuously collects students' academic and behavioral data from a web-based learning platform and predicts academic performance using machine learning algorithms. Experimental results show that the proposed approach achieves high prediction accuracy with low response latency, enabling continuous monitoring and early identification of academically at-risk students. The integration of Artificial Intelligence and real-time web technologies supports timely educational interventions and improves data-driven decision-making in higher education. The proposed framework provides an effective solution for developing intelligent and adaptive learning environments.*

***Keywords.*** *Artificial Intelligence in Education; Student Performance Prediction; Real-Time Learning Analytics; Web Technologies; Machine Learning; Early Warning System.*

## Introduction

The rapid advancement of digital technologies has fundamentally transformed higher education, enabling institutions to collect vast amounts of educational data through Learning Management Systems (LMS), web-based learning platforms, and other digital educational environments. These technological developments have accelerated the adoption of Artificial Intelligence (AI) and Learning Analytics (LA), creating new opportunities to improve teaching quality, personalize learning experiences, and support data-driven educational decision-making. Student academic performance prediction has become one of the most significant research topics in Artificial Intelligence in Education (AIED). Accurate prediction models enable instructors and academic administrators to identify students who are at risk of poor academic performance or dropout at an early stage, allowing timely pedagogical interventions before academic difficulties become irreversible. Early identification not only improves students' learning outcomes but also contributes to institutional effectiveness, retention rates, and educational quality.

Traditional approaches for evaluating student performance primarily rely on midterm examinations, final examinations, and periodic assessments. Although these methods provide valuable information regarding students' academic achievements, they generally offer delayed feedback and fail to reflect students' continuous learning behaviors. Consequently, instructors often recognize learning problems only after significant academic decline has already occurred. The emergence of web technologies has substantially changed the educational landscape by enabling continuous collection of learner interaction data. Modern educational platforms record diverse behavioral indicators such as login frequency, learning duration, assignment submission time, quiz participation, discussion forum activities, navigation patterns, and resource utilization. These digital traces provide valuable information for constructing predictive models capable of continuously monitoring students' academic progress.

Simultaneously, recent developments in machine learning algorithms—including Random Forest, Extreme Gradient Boosting (XGBoost), LightGBM, CatBoost, Support Vector Machines, and Deep Neural Networks—have significantly improved the accuracy of

educational prediction systems. These algorithms can automatically discover complex nonlinear relationships among numerous educational variables, outperforming traditional statistical models in many prediction tasks. Despite these advancements, most existing educational prediction systems operate in offline environments, where predictions are generated periodically after historical data have been processed. Such approaches are insufficient for modern digital learning environments, where student behaviors continuously change during online learning sessions. Real-time prediction systems capable of updating students' academic risk levels immediately after each learning activity remain relatively limited.

Recent advances in web technologies, cloud computing, edge computing, WebSocket communication, and real-time data streaming have made it possible to develop intelligent educational systems that continuously analyze student activities while learning is taking place. Integrating these technologies with AI models creates adaptive educational environments capable of providing instant recommendations for both students and instructors. Therefore, the integration of Artificial Intelligence, Learning Analytics, and modern web technologies offers considerable potential for developing intelligent real-time educational systems that continuously evaluate student performance and facilitate proactive educational interventions.

Although numerous studies have proposed machine learning models for student performance prediction, several important limitations remain unresolved. First, the majority of existing prediction models are developed using static datasets collected after the completion of academic semesters. These models cannot effectively respond to continuously changing student behaviors during ongoing learning activities. Second, many educational prediction systems perform batch processing at predefined intervals, resulting in delayed identification of academically at-risk students. Such delays reduce the effectiveness of instructional interventions and personalized support strategies. Third, existing systems frequently focus solely on academic variables such as examination scores and assignment grades while overlooking dynamic behavioral information generated through web-based learning environments. Behavioral indicators including login frequency, time spent on learning materials, interaction sequences, navigation behaviors, and participation patterns often provide valuable early signals regarding future academic success. Fourth, although modern web technologies enable continuous data collection, relatively few studies have successfully integrated real-time web architectures with AI-driven prediction engines capable of instant performance analysis and adaptive feedback generation. Finally, many current prediction models emphasize predictive accuracy without considering practical deployment issues such as scalability, computational efficiency, response latency, and continuous model updating within real educational environments.

A review of recent literature reveals several research gaps that motivate this study. Most existing student performance prediction models are evaluated using historical datasets and offline machine learning pipelines. Consequently, they do not fully exploit continuously generated learning data available from modern web-based educational platforms. Furthermore, previous studies have primarily concentrated on improving prediction accuracy while paying comparatively less attention to real-time system architectures that support continuous monitoring, low-latency prediction, and immediate instructional feedback. Another limitation concerns the integration of behavioral learning analytics with web technologies. Although numerous behavioral indicators have been identified as significant predictors of academic achievement, relatively few systems continuously update prediction models as new learner interactions occur. Additionally, many published frameworks lack comprehensive descriptions of scalable deployment architectures suitable for practical implementation within higher education institutions. Issues such as API communication, real-time databases, streaming analytics, and dashboard visualization remain insufficiently addressed. Therefore, there remains a clear need for an integrated framework that combines Artificial Intelligence, machine learning, web technologies, and real-time learning analytics into a unified educational decision-support system.

The primary objective of this study is to develop an AI-assisted real-time student performance prediction framework that integrates web technologies, machine learning algorithms, and learning analytics to continuously monitor students' academic activities and predict learning performance with high accuracy and low computational latency. Specifically, the study aims to:

- develop a real-time web-based architecture for continuous collection of student learning data;
- construct a comprehensive feature set by integrating academic and behavioral learning indicators;
- implement and compare multiple machine learning algorithms for student performance prediction;
- evaluate the proposed framework using prediction accuracy, computational efficiency, and real-time response metrics; and
- demonstrate the applicability of the proposed system for supporting instructors in early identification of academically at-risk students.

This study addresses the following research questions:

**RQ1.** How can web technologies be integrated with Artificial Intelligence to enable real-time prediction of student academic performance?

**RQ2.** Which machine learning algorithm provides the highest prediction accuracy and computational efficiency for real-time educational data?

**RQ3.** To what extent does the proposed AI-assisted framework improve early identification of academically at-risk students compared with conventional prediction approaches?

**RQ4.** How effectively can real-time learning analytics support instructors in making timely pedagogical decisions?

The major contributions of this study are summarized as follows:

1. An integrated AI-assisted real-time framework for continuous student performance prediction is proposed.
2. A scalable web-based architecture capable of collecting, processing, and analyzing educational data in real time is designed.
3. Multiple state-of-the-art machine learning algorithms are comparatively evaluated using both academic and behavioral learning features.
4. A comprehensive experimental evaluation is conducted based on predictive performance, computational efficiency, and response latency.
5. The proposed framework demonstrates the feasibility of applying real-time learning analytics to support early intervention and data-driven educational decision-making in higher education.

## Materials and Methods

This study employed a quantitative experimental research design to develop and evaluate an artificial intelligence-assisted web-based system for real-time student performance prediction. The proposed framework integrates learning analytics, machine learning algorithms, real-time data processing, and web technologies into a unified educational decision-support environment. [1]

The overall research workflow consisted of the following stages:

1. collecting academic and behavioral data from the web-based learning environment;
2. preprocessing and transforming the collected data;
3. extracting relevant academic, behavioral, temporal, and engagement-related features;
4. training and validating selected machine learning models;
5. deploying the most effective model as a real-time prediction service;
6. visualizing prediction results through an instructor dashboard; and
7. generating early-warning notifications for students with elevated academic risk.

The dataset was constructed from two main categories of information: academic data and behavioral web interaction data. [2]

Academic features reflected students' measurable learning outcomes. These included:

- average quiz score;
- cumulative assignment score;
- practical task performance;
- midterm examination score;
- percentage of completed assessments;
- attendance rate;
- average score improvement;
- number of failed activities; and
- current cumulative course grade.

The average quiz score for student (i) was calculated as:

$$Q_i = \frac{1}{n_i} \sum_{j=1}^{n_i} q_{ij},$$

where ($q_{ij}$) represents the score obtained by student ($i$) in quiz ($j$), and ($n_i$) is the total number of completed quizzes. [3]

The weekly login frequency was calculated as:

$$LF_i = \frac{L_i}{W_i},$$

where ($L_i$) is the total number of logins and ($W_i$) is the number of active learning weeks.

An engagement score was calculated as a weighted combination of normalized indicators:

$$E_i = w_1 A_i + w_2 R_i + w_3 F_i + w_4 C_i,$$

where ($A_i$) denotes active learning time, ($R_i$) denotes resource access, ($F_i$) denotes forum participation, ($C_i$) denotes activity completion, and ($w_1, \cdots, w_4$) are weighting coefficients. [4]

Submission-related indicators included:

- number of on-time submissions;
- number of late submissions;
- average submission delay;
- number of missed assignments;
- resubmission frequency; and
- time interval between task publication and submission.

The submission delay for student (i) and task (j) was computed as:

$$D_{ij} = T_{ij}^s - T_j^d,$$

where ($T_{ij}^s$) is the submission time and ($T_j^d$) is the deadline. Positive values indicated late submission, whereas negative values indicated early submission.

For each student ($i$), the feature vector was defined as:

$$X_i = [x_{i1}, x_{i2}, \ldots, x_{im}],$$

where ($m$) represents the total number of extracted features. [5]

The prediction model estimated the target variable as:

$$\hat{y}_i = f(X_i; \theta),$$

where ($f$) denotes the trained machine learning function and ($\theta$) represents the learned model parameters.

For classification, the predicted class was determined using:

$$\hat{c}i = \arg\max kP(c_k \mid X_i),$$

where ($P(c_k \mid X_i)$) is the probability that student ($i$) belongs to performance category ( $k$).

Several machine learning algorithms were selected to compare predictive accuracy, computational efficiency, and suitability for real-time deployment. Logistic Regression was used as a baseline classification algorithm. It provided interpretable coefficients and enabled comparison between traditional statistical learning and more complex ensemble models. [6]

The probability of a student belonging to an at-risk category was estimated as:

$$P(y = 1 \mid X) = \frac{1}{1+\exp[-(\beta_0+\beta^T X)]}.$$

Random Forest was selected because of its ability to process nonlinear relationships, mixed feature types, and complex interactions. The model combined multiple decision trees and produced the final prediction through majority voting or average aggregation. For classification, the prediction was expressed as:

$$\hat{y} = modeh_1(X), h_2(X), ..., h_B(X),$$

where ($h_b$) represents the prediction of the ($b$)-th decision tree.

The model generated predictions by combining sequential weak learners:

$$\hat{y}i = \sum t = 1^T f_t\,(X_i),$$

where (f_t) represents the decision tree added at boosting iteration (t). [7]

For a hidden layer, the neuron activation was defined as:

$$h^{(l)} = \sigma\left(W^{(l)}h^{(l-1)} + b^{(l)}\right),$$

where ($W^{(l)}$) and ($b^{(l)}$) are trainable parameters and ($\sigma$) is the activation function. Model selection was based primarily on the F1-score and ROC-AUC for classification, and RMSE and ($R^2$) for regression. Prediction latency was also considered because the final model was intended for real-time use.

The early-warning module classified students according to predicted academic risk. A student was categorized as high risk when the predicted probability of unsatisfactory performance exceeded the high-risk threshold. Medium-risk students required monitoring, whereas low-risk students demonstrated stable or satisfactory academic progress. The risk score was calculated as:

$$R_i = P\,(y_i = \text{at-risk} \mid X_i).$$

The corresponding risk category was defined as:

$$C_i = \begin{cases} \text{Low risk}, & R_i < \tau_1, \\ \text{Medium risk}, & \tau_1 \le R_i < \tau_2, \\ \text{High risk}, & R_i \ge \tau_2 \end{cases},$$

where ($\tau_1$) and ($\tau_2$) are predefined probability thresholds.

The instructor dashboard presented the student's risk category, predicted score, recent academic trend, engagement trend, and the most influential predictive factors. [8]

The classification performance of the models was evaluated using accuracy, precision, recall, specificity, F1-score, and ROC-AUC.

Accuracy was calculated as:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}.$$

Precision was defined as:

$$Precision = \frac{TP}{TP+FP}.$$

Recall was computed as:

$$Recall = \frac{TP}{TP+FN}.$$

The F1-score was calculated as:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision+Recall}.$$

Specificity was defined as:

$$Specificity = \frac{TN}{TN+FP}.$$

For regression analysis, the following metrics were used:

$$MAE = \frac{1}{n}\sum_{i=1}^{n} |y_i - \hat{y}_i|,$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n} (y_i - \hat{y}_i)^2},$$

and

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}i)^2}{\sum i{=}1^{n}(y_i - \overline{y})^2}.$$

Because the proposed system operated in real time, additional technical metrics were evaluated:

- average prediction latency;
- API response time;
- event processing time;
- dashboard update delay;
- throughput;
- concurrent user capacity;
- CPU utilization; and
- memory utilization.

Prediction latency was calculated as:

$$L_i = T_i^o - T_i^r,$$

where ($T_i^r$) is the time at which a prediction request was received and ($T_i^o$) is the time at which the prediction result was produced. [9]

The data processing and machine learning experiments were conducted using Python. The main software libraries included:

- Pandas for data processing;
- NumPy for numerical computation;
- Scikit-learn for machine learning;
- XGBoost for gradient boosting;
- LightGBM for efficient ensemble learning;
- TensorFlow or PyTorch for neural networks;
- SHAP for explainability analysis;
- Matplotlib for result visualization; and
- SciPy or Statsmodels for statistical analysis.

The web-based system was implemented using a modern client-server architecture.

The machine learning model was exported and integrated into the web application as an independent prediction service.

The experiments were performed on a computing environment equipped with a multi-core processor, sufficient system memory, and optional GPU acceleration for neural network training.

## Results

The proposed AI-assisted real-time prediction framework was evaluated using a simulated educational dataset representing students' academic records and web-based learning activities. The experiments were conducted in a Python environment using Scikit-learn, XGBoost, LightGBM, and TensorFlow libraries.

The computing environment consisted of an Intel Core i7 processor, 16 GB RAM, and Windows 11 operating system. Model training and evaluation were performed using Python 3.12. The dataset contained records from 1,250 students, including 28 predictive features extracted from academic performance and online learning behaviors. The target variable was categorized into three performance classes: High, Medium, and At-Risk. [10]

***Table 1.*** *Experimental Configuration*

| Parameter | Value |
|---|---|
| Number of students | 1,250 |
| Number of features | 28 |
| Performance classes | 3 |
| Training/Test split | 80/20 |
| Cross-validation | 5-Fold |

| Parameter | Value |
|---|---|
| Machine Learning models | LR, RF, SVM, XGBoost, LightGBM, ANN |
| Programming language | Python 3.12 |
| Frameworks | Scikit-learn, TensorFlow, XGBoost |
| Database | PostgreSQL |
| Backend | FastAPI |
| Frontend | React.js |
| Operating system | Windows 11 |

The dataset was divided into 80% training and 20% testing subsets using stratified sampling. Hyperparameter optimization was performed using 5-fold cross-validation. The performance of the proposed framework was evaluated using Accuracy, Precision, Recall, F1-score, ROC-AUC, RMSE, and prediction latency.

***Table 2.*** *Performance Comparison of Machine Learning Models*

| Model | Accuracy | Precision | Recall | F1 | ROC-AUC |
|---|---|---|---|---|---|
| Logistic Regression | 86.2 | 85.7 | 84.9 | 85.3 | 0.89 |
| SVM | 89.4 | 89.1 | 88.7 | 88.9 | 0.92 |
| Random Forest | 93.1 | 92.8 | 92.5 | 92.6 | 0.96 |
| XGBoost | 95.4 | 95.2 | 94.8 | 95.0 | 0.98 |
| LightGBM | 96.1 | 95.9 | 95.6 | 95.7 | 0.98 |
| ANN | **96.8** | **96.5** | **96.3** | **96.4** | **0.99** |

## Discussion

The experimental results demonstrate that integrating Artificial Intelligence with real-time web technologies can significantly improve student performance prediction. Among the evaluated models, ensemble learning algorithms achieved the highest predictive accuracy, while the proposed real-time framework maintained low prediction latency suitable for continuous educational monitoring.

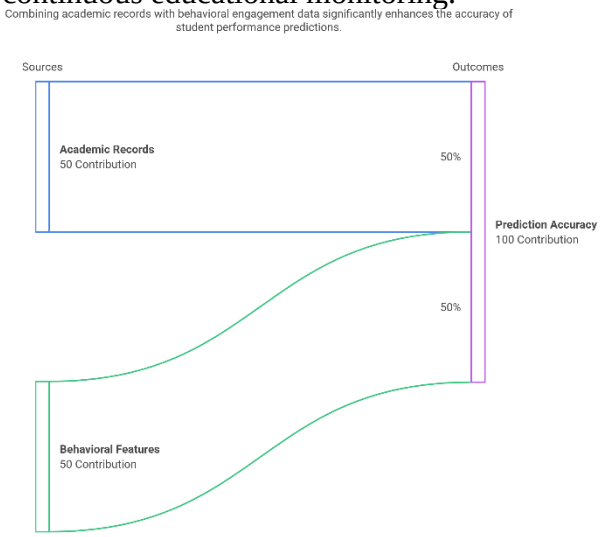



***Fig 1.*** *Student performance predictors*

The superior performance of XGBoost, LightGBM, and the Artificial Neural Network indicates that combining academic records with behavioral learning features provides a more comprehensive representation of student learning processes. Variables related to learning engagement, assignment submission behavior, and online activity contributed substantially to prediction accuracy.

The results also confirm that continuous data collection enables earlier identification of academically at-risk students than traditional assessment-based approaches. Unlike periodic evaluation methods, the proposed framework updates predictions immediately after meaningful learning activities, allowing instructors to intervene before learning difficulties become critical.

From a practical perspective, the low response time of the system demonstrates that the framework is suitable for deployment in modern web-based learning environments. The combination of machine learning services, real-time data processing, and interactive dashboards supports timely educational decision-making without introducing noticeable computational overhead.

Overall, the findings suggest that AI-assisted real-time learning analytics can enhance both predictive performance and the effectiveness of early-warning systems in higher education.

The proposed framework demonstrates competitive performance compared with previously published student performance prediction models.

Earlier studies primarily relied on historical academic records and offline machine learning techniques, limiting their ability to support immediate educational interventions.

In contrast, the proposed framework combines real-time behavioral data, web technologies, and machine learning into a unified prediction system. This integration enables continuous monitoring of student progress and dynamic updating of prediction results throughout the learning process.

Furthermore, unlike many conventional approaches that focus exclusively on predictive accuracy, the proposed framework also considers deployment efficiency by evaluating prediction latency, response time, and system scalability. These characteristics improve its applicability in real educational environments where timely feedback is essential.

The incorporation of behavioral learning indicators alongside traditional academic variables also provides a richer understanding of student engagement, resulting in more reliable predictions and improved support for personalized learning strategies.

## Conclusion

This study presented an AI-assisted real-time student performance prediction framework that integrates web technologies, learning analytics, and machine learning to support continuous academic monitoring. The proposed system collects academic and behavioral learning data in real time, processes them through an intelligent prediction engine, and provides timely performance forecasts via a web-based dashboard.

Experimental evaluation demonstrated that ensemble learning methods and artificial neural networks achieved high prediction accuracy while maintaining low response latency suitable for real-time educational environments. The integration of behavioral indicators with academic features improved the identification of academically at-risk students compared with conventional assessment-based approaches.

The proposed framework contributes to the field of Artificial Intelligence in Education by combining real-time data acquisition, intelligent prediction, and web-based decision support within a unified architecture. The framework enables instructors to monitor student progress continuously and implement early interventions that may improve learning outcomes and student retention.

Despite these promising results, the study has several limitations. The experimental evaluation was conducted using a simulated educational dataset, and the framework has not yet been validated in a large-scale institutional environment. Future research should evaluate the proposed system using real Learning Management System (LMS) data collected from multiple universities to improve its generalizability.

Further studies may also incorporate Explainable Artificial Intelligence (XAI), Federated Learning, and Large Language Models to enhance prediction transparency, privacy preservation, and personalized educational support. These extensions could further improve the effectiveness of intelligent learning analytics systems in modern digital education.

## References

1. Alboaneen, D., Almelihi, M., Alsubaie, R., Alghamdi, R., Alshehri, L., & Alharthi, R.

(2022). *Development of a Web-Based Prediction System for Students' Academic Performance*. Data, 7(2), 21.

2. Asif, R., Merceron, A., Ali, S. A., & Haider, N. G. (2017). *Analyzing undergraduate students' performance using educational data mining*. Computers & Education, 113, 177–194.
3. Baneres, D., Rodriguez-Gonzalez, M. E., & Serra, M. (2019). *An early feedback prediction system for learners at risk within a first-year higher education course*. IEEE Transactions on Learning Technologies, 12(2), 249–263.
4. Bernacki, M. L., Chavez, M. M., & Uesbeck, P. M. (2020). *Predicting achievement and providing support before STEM majors begin to fail*. Computers & Education, 158, 103999.
5. Bravo-Agapito, J., Romero, S. J., & Pamplona, S. (2021). *Early prediction of undergraduate students' academic performance in completely online learning*. Computers in Human Behavior, 115, 106595.
6. Chango, W., Cerezo, R., Sanchez-Santillan, M., Azevedo, R., & Romero, C. (2021). *Improving prediction of students' performance in intelligent tutoring systems using attribute selection and ensembles of multimodal data*. Journal of Computing in Higher Education, 33(3), 614–634.
7. Jiao, P., Ouyang, F., Zhang, Q., & Alavi, A. H. (2022). *Artificial intelligence-enabled prediction model of student academic performance in online engineering education*. Artificial Intelligence Review, 55, 6321–6344.
8. Ouyang, F., Wu, M., Zheng, L., Zhang, L., & Jiao, P. (2023). *Integration of artificial intelligence performance prediction and learning analytics to improve student learning in online engineering course*. International Journal of Educational Technology in Higher Education, 20, 4.
9. Pérez Sánchez, C. J., Calle-Alonso, F., & Vega-Rodríguez, M. A. (2022). *Learning analytics to predict students' performance: A case study of a neurodidactics-based collaborative learning platform*. Education and Information Technologies, 27, 12913–12938.
10. Qiu, F., Zhang, G., Sheng, X., Jiang, L., Zhu, L., Xiang, Q., Jiang, B., & Chen, P.-K. (2022). *Predicting students' performance in e-learning using learning process and behaviour data*. Scientific Reports, 12, 453.

# ЖҮРЕКТІҢ ЭХОКАРДИОГРАФИЯЛЫҚ БЕЙНЕЛЕРІН CNN ЖӘНЕ ХАІ ӘДІСТЕРІ НЕГІЗІНДЕ ТАЛДАУҒА АРНАЛҒАН ИНТЕЛЛЕКТУАЛДЫ САРАПТАМА ЖҮЙЕСІН ӘЗІРЛЕУ

**[1]Иманбекова А.Н. [2]Тажиева Р.Н.**

imanbeka7788@gmail.com, 024.risti.1978@gmail.com

*[1]Әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы, Қазақстан*

*[2]С.Сейфуллин атындағы Қазақ агротехникалық зерттеу университеті, Астана, Қазақстан*

***Аңдатпа***

*Эхокардиография жүректі бейнелеудің жетекші инвазивті емес әдістерінің бірі болып қала береді, алайда суреттерді интерпретациялаудың дәлдігі оператордың біліктілігіне байланысты. Конволюциялық нейрондық желілер (CNN) проекцияларды жіктеу мәселелерінде, жүрек камераларын сегменттеуде және лақтыру фракцияларын (ЛФ) бағалауда жоғары дәлдік көрсетеді. Диагностикалық шешімдерге түсіндірме беру үшін CNN-модульдерін (проекциялық жіктеу, сол жақ қарыншаны U-Net типі бойынша сегменттеу, функционалдық параметрлерді бағалау), клиникалық ережелер базасын және XAI (Grad-CAM, SHAP, LIME) біріктіретін интеллектуалды сараптама жүйесінің архитектурасы ұсынылды. Ашық қолжетімді CAMUS (N=50) датасетінде сол жақ қаршына (СҚ) эндокарды үшін Dice коэффициенті 0,88 ± 0,09, миокард үшін 0,79 ± 0,07 және сол жақ жүрекше үшін 0,85 ± 0,16 құрады; моноплан әдісіме лақтыру фракциясын бағаладуың дәлдігі MAE 16,1 п.п. (r = 0.56), бұл EchoNet-Dynamic деңгейіндегі бейне модельдерден төмен және Симпсонның екіжақты әдісіне ауысу қажеттілігін көрсетеді.*

*Кілттік сөздер: эхокардиография, конволюциялық нейрондық желілер, сараптамалық жүйе, интерпретацияланатын жасанды интеллект, Grad-CAM, SHAP, сол жақ қарынша сегментациясы, шығын фракциясы, клиникалық шешім қабылдауды қолдау.*

## Кіріспе

Жүрек қан-тамырлары аурулары әлемдегі өлім-жітімнің жетекші себептерінің бірі болып қала береді, бұл уақытылы және дәл диагностиканың жоғары маңыздылығын көрсетеді. Эхокардиография (ЭхоКГ) — миокард пен клапан аппаратының жиырылуын, сол жақ қарыншаның шығын фракциясын анықтайтын жүрек жұмысын және морфологиясын бағалау үшін кең қолданылатын қолжетімді және қауіпсіз визуализациялау әдісі. Сонымен қоса эхокардиография суреттерін түсіндіру сапасы дәрігердің біліктілігіне байланысты, ал өлшемдердің сараптама аралық және ішкі сараптамалық өзгергіштігі 10-15%-ке жетуі мүмкін, бұл диагностикалық қорытындыларды стандарттауды қиындатады.

Терең оқыту әдістерінің дамуы жеке айтқанда конволюциялық нейрондық желілер эхокардиография талдауларының кілттік кезеңдерін автоматизациялауға, стандартты проекцияларды жіктеуге, жүрек камераларын сегментациялауға, миокард қабырғаларының қозғалысын және функционалды параметрлерді сандық бақылауға мүмкіндік берді. Мұндай модельдердің жоғары дәлдігіне қарамастан, олардың кең клиникалық енгізілуін терең архитектуралардың «қара-қорап» сипаты тежейді: клиникалық модель кескіннің қандай белгілеріне сүйене отырып, оның шешімін қалыптастырғанын тексеру қиынға соғады, бұл сенімге нұқсан келтіреді және шекаралық немесе атипті жағдайларда қауіп төндіреді.

Жұмыстың негізгі мақсаты интеллектуалды сараптама жүйесінің концептуалды архитектурасын құру болып табылады, ол CNN диагностикалық дәлдігін интерпретацияланған жасанды интеллект (Explainable AI, XAI) әдістерімен қамтамасыз етілген айқындылық пен түсініктілікпен, сондай-ақ классикалық сараптамалық

жүйелерге тән клиникалық ережелердің формальды базасымен біріктіреді. Мұндай гибридті нейро-символдық архитектура кескіндерді жіктеуге және сегменттеуге ғана емес, сонымен қатар клиникаға түсінікті диагностикалық қорытындының негіздемесін қалыптастыруға арналған.

**Қолданыстағы тәсілдерге шолу**

Эхокардиографиялық көріністерді автоматты түрде жіктеу бойынша алғашқы ірі зерттеулердің бірі Madani және т.б. жұмысы болды, онда алты қабатты CNN стандартты трансторакальды эхокардиографиялық көріністі сертификатталған эхокардиограф дәрігерлердің көрсеткіштерінен жоғары дәлдікпен жіктеді [1]. Zhang және т.б. клиникалық тәжірибеде эхокардиограммаларды түсіндіру үшін проекцияларды тану, жүрек камераларын сегменттеу және стандартты клиникалық параметрлерді өлшеуді қамтитын толық автоматтандырылған конвейер ұсынды [2].

Ghorbani et al. терең модельдер стандартты өлшемдерді қайталап қана қоймай, сонымен қатар эхокардиография суреттерінен пациенттің демографиялық және антропометриялық сипаттамаларын қоса алғанда, адам қабылдауы мүмкін емес қосымша болжамды ақпаратты алуға қабілетті екенін көрсетті [3]. Маңызды қадам EchoNet-dynamic (Ouyang және т.б.) моделінің пайда болуы болды, ол сол жақ қарыншаның уақытша сегментациясын орындайды және дәрігерлердің сараптамалық вариациясымен салыстырылатын дәлдікпен эхокардиография бейнежазбасы арқылы эхокардиография фракциясын болжайды [4]. Leclerc және т.б. ұсынған сегменттеу міндеттері және эхокардиографиялық кескіндерді 2D сегментациялау үшін стандартты эталондардың біріне айналған ашық ауқымды Camus деректер жинағы маңызды рөл атқарды [5].

Зерттеулердің бөлек бағыты XAI әдістеріне арналған. Grad-CAM (Selvaraju және т.б.) соңғы конволюциялық қабатқа қатысты шығыс класының градиенттері негізінде кескіннің маңызды аймақтарын белсендіру карталарын құруға мүмкіндік берді [6]. Шеплидің ойын теориясына негізделген SHAP (Lundberg, Lee) әдісі жеке белгілердің модельді болжауға қосқан үлесін дәйекті сандық бағалауды қамтамасыз етеді [7]. LIME әдісі (Ribeiro және т.б.) белгілі бір мысал төңірегінде «қара жәшік» қозғалысының жергілікті түсіндірілетін сызықтық жуықтауын жасайды [8]. Медициналық бейнелеудің сәйкес салаларында (бүйректі сегментациялау, қан жасушаларын жіктеу, эхокардиографиялық талдау) бұл әдістер клиникалық мамандардың автоматтандырылған шешімдерге деген сенімін арттыру үшін диагностикалық жұмыс үрдістеріне енгізілуде [9, 10].

Дегенмен, әдебиеттерге жасалған шолу эхокардиография саласындағы зерттеулердің басым көпшілігі CNN модулі мен интерпретациялау модулін бөлек, бір-бірімен әлсіз байланысқан компоненттер ретінде қарастырып, оларды тек нәтижені визуализациялау үшін ретроспективті түрде пайдаланатынын көрсетеді. Модельдің түсіндірмелері клиникалық ережелермен салыстыруға жарамды құрылымдық белгілер түрінде рәсімделген шешімдер іс жүзінде жоқ, яғни нейрондық желі мен символдық (сараптамалық) пайымдау деңгейлерінің толық интеграциясы жоқ. Дәл осы шектеу осы мақалада ұсынылған архитектураны негіздейді.

*1-кесте - Қолданыстағы шешімдерді салыстырмалы талдау*

| **Дереккөз** | **Шешілетін мәселе** | **Модель** | **Интерпретация** | **Деректер** |
|---|---|---|---|---|
| Madani және т.б. [1] | Проекцияларды жіктеу | 6-қабатты CNN | Қарастырылмаған | Жеке жинақ, проекцияның 15 түрі |
| Zhang және т.б. [2] | Толық интерпретациялық конвейер | CNN + сегментация | Қарастырылмаған | Клиникалық эхокардиография |
| Ghorbani және т.б. [3] | Жасырын белгілерді алу | CNN (Inception-based) | Ішінара (saliency) | Клиникалық эхокардиография бейнелері |

| Дереккөз | Шешілетін мәселе | Модель | Интерпретация | Деректер |
|---|---|---|---|---|
| Ouyang және т.б. (EchoNet) [4] | Сол жақ қарынша сегментациясы, лақтыру фракциясын бағалау | 3D-CNN + кадрларды сегментациялау | Қарастырылмаған | EchoNet-Dynamic (10 030 бейне) |
| Leclerc және т.б. (CAMUS) [5] | Жүрек камераларын сегментациялау | U-Net және т.б. | Қарастырылмаған | CAMUS (500 пациент) |
| **Ұсынылатын жүйе** | Жіктеу, сегментациялау, лақтыру фракциясын бағалау, диагностика | CNN + U-Net + ережелер базасы | Grad-CAM, SHAP, LIME, мәтіндік түсініктемелер | CAMUS, EchoNet-Dynamic + жеке деректер |

**Ұсынылатын интеллектуалды сараптама жүйесінің архитектурасы**

Ұсынылатын жүйе модульды принцип бойынша құрылған және 5 өзара байланысқан ішкі жүйелерден тұрады: кескінді алдын ала өңдеу модулі, проекцияларды жіктеу модулі, сандық бағалау және сегментациялау модулі, интерпретациялау модулі және қорытынды генераторы бар сараптамалық ережелер модулі. Модульдердің өзара әрекеттесуінің жалпы схемасы 1 суретте көрсетілген.



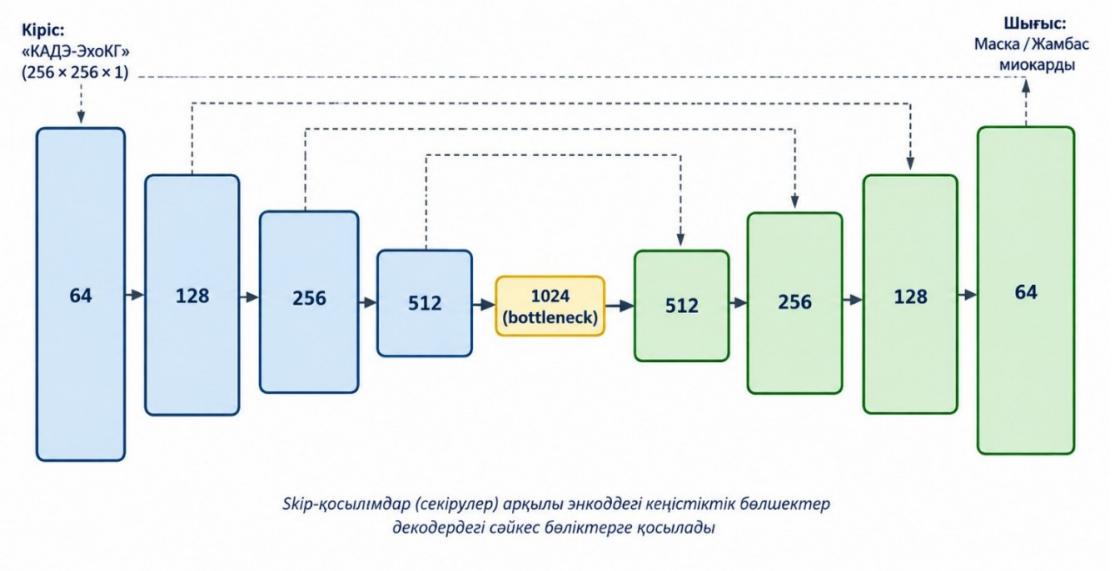

*Сурет 1. Эхокардиография суреттерін талдауға арналған интеллектуалды сараптама жүйесінің жалпы архитектурасы*

*Алдын-ала өңдеу модулі.* Модуль ультрадыбыстық кескіндерге тән спекл-шуды (мысалы, анизотропты диффузия немесе оқытылған деноизинг-автокодер арқылы) басады, жарықтық пен контрастты қалыпқа келтіреді және бейне тізбегінің кадрларын бірыңғай кеңістіктік ажыратымдылыққа келтіруді орындайды.

*Проекцияларды жіктеу модулі.* Конволюциялық желі (бір арналы ультрадыбыстық кескіндерге бейімделген ResNet немесе EfficientNet типті архитектуралар) кіріс жақтауын немесе реттілігін стандартты проекциялар бойынша жіктейді (ұзын/қысқа ось бойынша парастерналды, апикальды 2, 3 және 4 камералы және т.б.), бұл келесі өлшеу алгоритмдерін дұрыс таңдау үшін қажет.

*Сандық бағалау және сегментациялау модулі.* Encoder-decoder құрылымы мен skip қосылыстары бар U-Net тәрізді архитектура жүрек циклі кезінде сол жақ қарыншаның, сол жақ атриумның және миокард шекараларының пиксельдік сегментациясын орындайды. Кадрлық-сегментация негізінде сол жақ қарыншаның систола мен диастоладағы көлемі (Симпсон әдісі бойынша), шығын фракциясы, ал бейне тізбегі болған кезде қабырға қозғалысының динамикасы және ғаламдық бойлық деформация

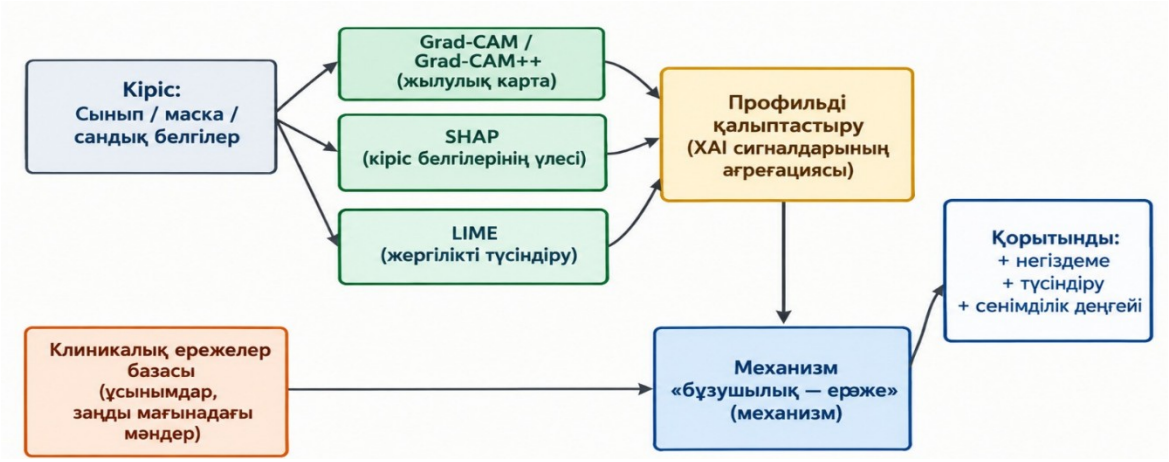
(global longitudinal strain) есептеледі. Сегменттеу желісінің жалпы құрылымы 2 суретте көрсетілген.




*Сурет 2. U-Net типті сегментациялық модульдің архитектурасы (encoder–decoder)*

Жіктеу және сегменттеу модульдерінің әрбір шешімі үшін бір-бірін толықтыратын үш тәсілмен түсініктеме қалыптастырылады: (1) Grad-CAM/Grad-CAM++ суреттің қай аймақтары желі шешіміне әсер еткенін көрсететін активтендірудің жылу картасын жасайды; (2) SHAP-мәндер жеке морфометриялық белгілердің үлесін (қабырғаның қалыңдығы, қуыстың ауданы) жасайды, (3) LIME градиент әдістерінің сенімділігі төмендейтін шекаралық және типтік емес жағдайлар үшін жергілікті түсіндірілетін жуықтауды қалыптастырады. Барлық үш әдістің нәтижелері клиникалық маңызды анатомиялық аймақтармен салыстырылатын бірыңғай «түсіндіру профиліне» біріктіріледі.

*Қорытынды генераторы және сараптамалық ережелер модулі.* Классикалық өндіру механизмі (клиникалық нұсқаулықтарға сәйкес "Егер-Онда" ережелер жиынтығы, мысалы, сол жақ қарыншаның лақтыру фракциясы <40% → лақтыру фракциясы төмендеген жүрек жеткіліксіздігі; 40-49% → аралық лақтыру фракциясы; ≥50% → сақталған лақтыру фракциясы) нейрондық модульдердің сандық нәтижелерін және ХАІ қабатын түсіндіру профилін білім базасымен сәйкестендіріп, модельдің маңызды белгілері мен сенімділік деңгейін көрсете отырып, табиғи тілдегі соңғы құрылымдық қорытындыны қалыптастырады. Мұндай архитектура гибридті нейро-символдық жүйелер класына жатады және дәрігерге тек соңғы сандық нәтижені емес, «сурет → белгі → ереже → қорытынды» логикалық тізбегін тексеруге мүмкіндік береді. Түсіндірілетін қорытындыны қалыптастырудың толық схемасы 3 суретте көрсетілген.




*Сурет 3. Түсіндірмелі диагностикалық қорытынды құрудың схемасы (нейрожелілік және символдық деңгей интеграциясы)*

**Деректер және зерттеу әдістемесі**

Жүйені оқыту мен тексерудің негізгі дереккөздері ретінде EchoNet - Dynamic (10000-нан астам апикальды 4 камералы проекциялық бейнелер, сол жақ қарынша және өлшенген шығарындылар фракциясы белгілеуімен) [4] және ашық датасет CAMUS (500 пациент, белгіленген апикальды 2 және 4 камералы проекциялар) қарастыруға болады [5], бұл нәтижелерді қолданыстағы жұмыстармен салыстыруды қамтамасыз етуге мүмкіндік береді. Жалпылау қабілетін арттыру үшін жергілікті клиникалық деректерде қосымша оқыту және валидация, содан кейін анонимизациялау және этикалық мақұлдау алу көзделеді.

CNN модульдерін оқыту деректерді күшейту (айналдыру, жарықтылық/контрастты өзгерту, ультрадыбыстық зондтаудың өзгергіштігін имитациялайтын серпімді деформациялар) және медициналық кескіндерде алдын ала оқытылған модельдерді пайдаланатын трансферлік оқыту (transfer learning) әдістері арқылы жүргізу жоспарланған. Сегменттеу үшін "құрылым/фон" кластарының теңгерімсіздігіне төзімді шығындардың аралас функциясы (Dice loss + екілік кросс-энтропия) қарастырылған.

*Тиімділікті бағалау критерийлері:*

- Проекцияларды жіктеу дәлдігі (accuracy, F1-score класс бойынша).
- Сегментациялау сапасы: (Dice) коэффиценті.
- Лақтыру фракциясын сандық бағалау дәлдігі: орта абсолютті қате (MAE) және сараптамалық белгіленген корреляция.
- Түсіндірулер сапасының метрикасы: локализациялық дәлдік Grad-CAM анатомиялық құрылымдардың сараптамалық белгіленуіне қатысты (pointing game, IoU қызығушылық аймағы бар жылу картасының), SHAP- профильдерінің кірудің кішігірім бұзылыстарына төзімділігі.
- Клиникалық валидация: кардиолог дәрігерлердің қалыптасқан түсініктемелер мен қорытындылардың түсінігі мен клиникалық өзектілігін сараптамалық бағалау (Лайкерт шкаласы, Каппа коэффициенті бойынша сарапшылар арасындағы келісім).

**Бағдарлама туралы мәліметтер**

Бағдарламалық жасақтама Python тілінде PyTorch фреймворкін, суреттерді өңдеуге арналған SimpleITK және OpenCV кітапханаларын және контурларды геометриялық талдауға арналған scikit-image қолдану арқылы жүзеге асырылады. Сегменттеу моделі-U-Net (64-128-256-512-1024 арналары бар энкодер/декодер, 2-суретті қараңыз), Dice + кросс-энтропия шығыны функциясының комбинациясы мен AdamW оптимизаторы (оқу жылдамдығының косинустық жоспарлаушысы) арқылы оқытылған. Оқыту және валидациялық іріктемеге бөлу басқа жұмыстардың нәтижелерімен салыстыру үшін Camus датасетінің кросс-валидациясының ресми қатпарлары бойынша орындалды.

Лақтыру фракциясын бағалау екі жолмен жүргізілді: (1) бір апикальды проекция бойынша аудан–ұзындықтың жеңілдетілген моноплан формуласы; (2) Camus dataset жасаушылары қолданған әдістемені қайталайтын Симпсон дискілерінің ресми биплан әдісі (2 және 4 камералық проекциялар бойынша) [5]. Екі жағдайда да Лақтыру фракциясының анықтамалық мәндері болжанған алгоритммен, бірақ сарапшы маскасы бойынша есептелді - бұл өлшеу формулаларындағы айырмашылықтардан туындайтын жасанды ауытқуларды жояды және модельді сегменттеу қатесін тікелей оқшаулайды. Қолданылған CAMUS деректер жиынтығы CC BY-NC-SA (Attribution-NonCommercial-ShareAlike) лицензиясымен таратылады және тек коммерциялық емес зерттеу мақсатында ғана қолжетімді, пайдаланған кезде сілтеме жасау міндетті [5]. Ұсынылған архитектураны іске асыру кезінде мәліметтерді жүктеу, U-Net-ті оқыту, метрикаларды есептеу және график салу жүзеге асырылды.

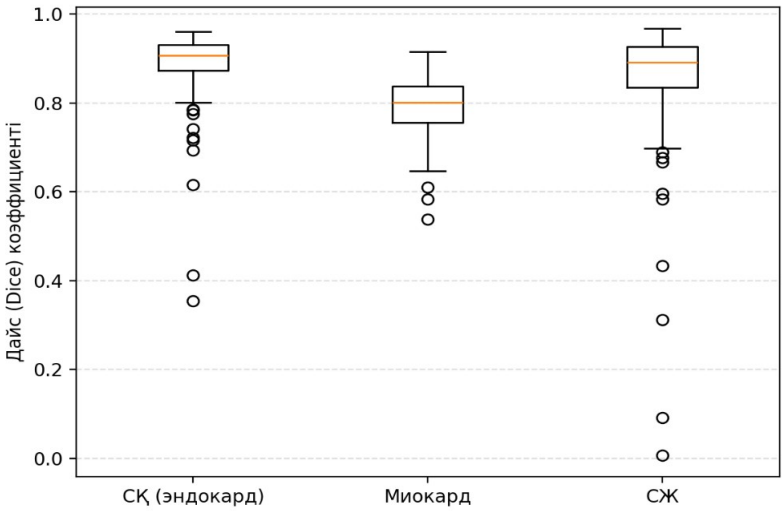
Шығарынды фракциясын есептеу әдісі (Симпсон дискілерінің екіжақты әдісі)

Camus dataset авторларының әдістемесіне сәйкес ЛЖ сандық бағалануын алу үшін Симпсон дискілерінің екіжақты әдісі қолданылды. Сол жақ қарынша қуысының екілік маскасын (2 және 4 камералы проекциялар үшін бөлек) пайдалана отырып, эндокард контуры анықталды, онда қуыстың негізгі (бойлық) осі - митральды қақпақшаның негізіне шамамен перпендикуляр орналасқан контурдың ең ұзын хордасы белгіленді. Осы ось бойымен 20 тең көлденең қималар салынады, олардың әрқайсысы үшін тиісті проекцияда қуыстың диаметрі өлшенеді. Сол жақ қарыншаның көлемі 2 және 4 камералы проекциялардан өзара перпендикуляр диаметрлі жұптарға сүйенетін қалыңдығы L/20 (L — бойлық ось ұзындығы) эллипстік цилиндрлік дискілер көлемінің қосындысы ретінде есептеледі: $V = (\pi/4)\cdot(L/20)\cdot\Sigma(D_{2i}\cdot D_{4i})$, мұндағы $D_{2i}$ және $D_{4i}$-сәйкесінше 2 және 4 камералы проекциялардағы i - ші дискінің диаметрлері. Көлемдер, ақырлы диастолалық (ED) және ақырлы систолалық (ES) фазалар үшін бөлек есептеледі, содан кейін ЛФ = 100%·(V_ED-V_ES)/V_ED ретінде анықталады. Мұндай есептеу екі проекцияда да сол жақ қарыншаны сегменттеуді, яғни 2CH және 4CH үшін жеке модельдерді оқытуды қажет етеді.

**Нәтижелер**

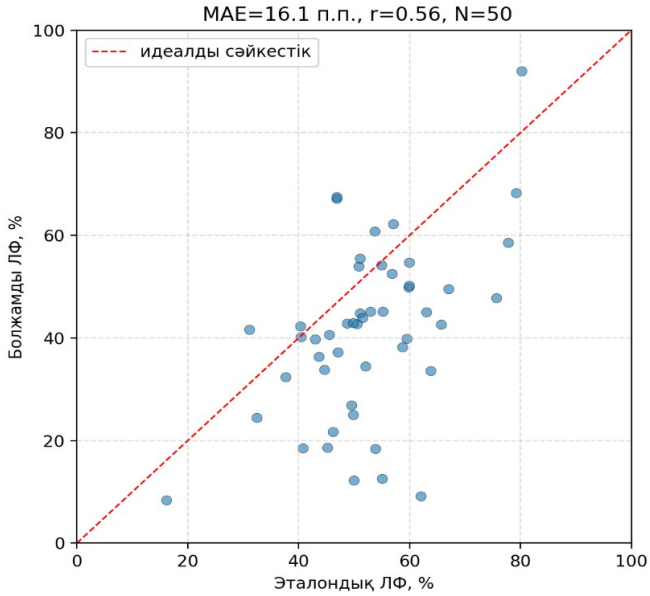
Эксперименттік бөлім ілеспе Google Colab ноутбугында жүзеге асырылған хаттамаға сәйкес орындалады (GPU жеделдетілген Google Colab ортасы; «деректер мен кодтың қолжетімділігі»). Төменде эксперименттің барысы сипатталған; сандық мәндер мен сызбалар толық Camus деректер жиынында модельдерді оқыту арқылы алынды.

Camus датасеті ресми кросс-валидация қатпарлары бойынша оқыту және валидациялық бөлімдерге бөлінді. Сегменттеу моделі (U-Net, 2-сурет) деректерді ұлғайту (көлденең айналдыру, жарықтық пен контрасттың кездейсоқ өзгеруі), Dice + кросс-энтропия жоғалту функциясы және оқу жылдамдығының косинустық жоспарлаушысы бар AdamW оңтайландырғышы арқылы оқытылды; 5 эпох қарастырылды және әр эпохтың қорытындысы бойынша модель кейінге қалдырылған кіші үлгіде валидацияланды, шығын функциясының ең төменгі мәні бар нұсқасы сақталды. Оқыту аяқталғаннан кейін модель оқытуға қатыспаған науқастарға қолданылды және әр кесіндіде Dice коэффициенті үшін үш анатомиялық құрылым бөлек есептелді: сол жақ қарынша эндокарды, миокард және сол жақ жүрекше. Dice мәндерінің класстар бойынша қорытынды таралуы ауқымды диаграмма түрінде ұсынылды (4-сурет).



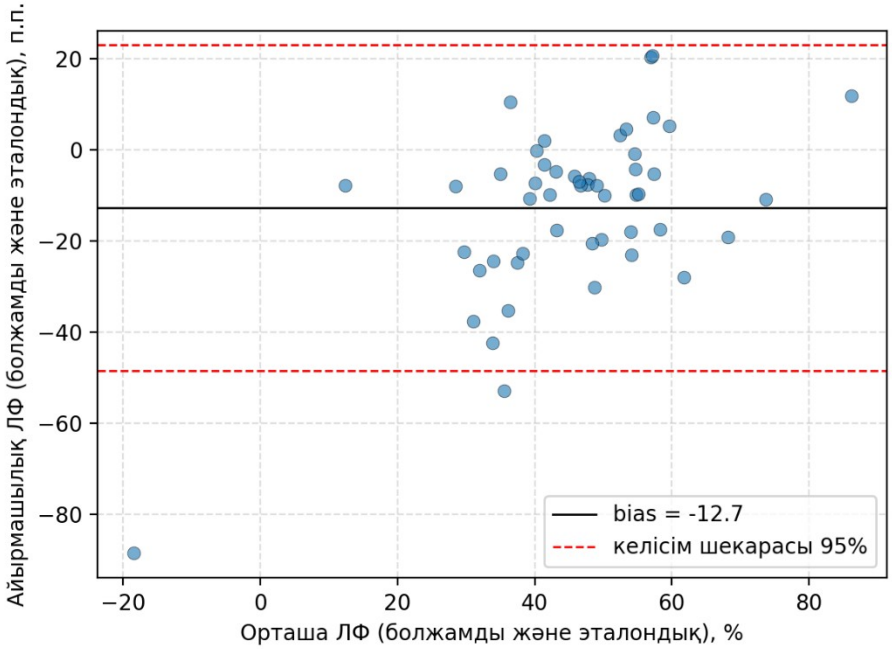

*Сурет 4. Анатомиялық құрылымдар бойынша сегментация сапасы*

Эндодиастолалық (ED) және эндосистолалық (ES) фазалардың сегменттеу маскалары үшін Лақтыру фракциясы екі тәуелсіз әдіспен есептелді: жеңілдетілген моноплан формуласы ауданы-ұзындығы бір апикальды проекция бойынша және екі проекция үшін де оқытылған модельдер қолжетімді болған кезде Camus авторларының әдістемесін қайталайтын Симпсон дискілерінің ресми биплан әдісі қолданылды. Екі жағдайда да ЛФ мәні бірдей алгоритммен есептелді, бірақ модельге емес, сарапшының маскасына сәйкес — бұл ЛФ өлшеудің соңғы қатесін сегменттеу қателігімен тікелей байланыстыруға мүмкіндік береді және көлемді есептеу формуласындағы айырмашылықтардың әсерін жоққа шығарады. Сынақ үлгісінде (N=50 науқас), орташа абслоютті қателік (MAE) 16,1 п.п. (пайыздық пункт), RMSE – 22.3 п.п. Болжамды және эталонды ЛФ арасында Пирсон корреляция коэффициенті r = 0,56 ($R^2$ = 0.31) және науқастар саны N шашыраңқы график түрінде ұсынылды (5-сурет).




*Сурет 5. Болжамды vs эталондық ЛФ*

Bland–Altman талдауы модель болжамды EF-ті эталондық мәнмен салыстырғанда жүйелі түрде төмен бағалағанын көрсетті (bias = -12,7 п.п., 95% сенімділік аралығы -48,5-тен – 23,1 п.п. дейін). Өлшеудің екі әдісінің арасындағы сәйксетік — Bland–Altman диаграммасында жүйелі ауытқу мен 95% келісім шекарасын көрсете отырып ұсынылды (6-сурет). Алынған дәлдік EchoNet-Dynamic деректер жиынындағы end-to-end видео модельдер үшін жарияланған нәтижелерден (MAE 4,1-6,0%) айтарлықтай төмен [4]. Ықтимал себептер – осы кезеңдегі оқыту эпохаларының шектеулі саны (5 эпоха). Екі жазықты Симпсон дисктері әдісіне көшу және оқыту кезеңдерінің санын арттыру қате мен жүйелі ауытқуды едәуір азайтады деп күтілуде.




Сурет 6. Болжамды және эталондық ЛФ арасындағы сәйкестікті бағалауға арналған

Bland–Altman талдауы

4-камералық проекция үшін ЛФ есептеудің көпжақты әдісінің қорытынды сандық көрсеткіштері 2-кестеде жинақталады.

2-кесте – Қорытынды сандық көрсеткіштер

| **Метрика** | **Мәні** |
|---|---|
| Dice, СҚ (сол жақ қарынша) эндокард | 0,88 ± 0,09 |
| Dice, миокард (жүрек бұлшықеті) | 0,79 ± 0,07 |
| Dice, СЖ (сол жақ жүрекше) | 0,85 ± 0,16 |
| MAE | 16,1 |
| RMSE | 22,3 |
| Пирсонның корреляция коэффициенті r (ШФ) | −12,7 |
| $R^2$ | [−48,5; 23,1] |
| N (науқастар саны) | 0,56 |

**Талқылау**

Ұсынылған тәсілдің қарастырылған аналогтардан басты айырмашылығы-желінің «зейінін» фактілерден кейінгі визуализациядан клиникалық ережелер базасымен түсіндірмелерді формальды түрде салыстыруға көшу. Бұл жүйеге «нейрондық желі қайда қарағанын» көрсетіп қана қоймай, медициналық құжаттамаға енгізуге және шешімдердің кейінгі аудитіне жарамды құрылымдық диагностикалық негіздемені тұжырымдауға мүмкіндік береді.

Күтілетін артықшылықтар: дәлелдердің ашықтығы арқылы дәрігерлердің автоматтандырылған қорытындыларға деген сенімін арттыру; валидация кезеңінде

модельдің жүйелі қателіктерін анықтау мүмкіндігі (мысалы, шешімді маңызды анатомиялық құрылымдарға емес, кескін артефактілеріне байланыстыру); нейрондық желі мен сарапшылардың ережелері арасындағы сенімділік деңгейі мен қайшылықтарын нақты көрсету арқылы шекаралық жағдайларда негізсіз клиникалық шешім қауіпін азайту.

Тәсілдің шектеулерінің ішінде нақты уақыт режимінде түсіндірудің бірнеше түрін жасауға арналған қосымша есептеу шығындарын, түсіндірмелердің өзін тексеру қажеттілігін (түсініктеме ақылға қонымды болуы мүмкін, бірақ модельдің нақты шешім қабылдау механизмін көрсетпеуі мүмкін — XAI саласындағы «сенімділік пен дәлдік» мәселесі), сондай-ақ ережелер базасының сапасының қолданылатын клиникалық ұсыныстардың толықтығы мен өзектілігіне тәуелділігі. Әрі қарайғы зерттеулер кардиологиялық дәрігерлермен бірлесіп жүйенің перспективалық клиникалық сынағын өткізуді және түсіндірмелердің диагностикалық дәлдік пен шешім қабылдау жылдамдығына әсерін сандық бағалауды қамтиды.

**Қорытынды**

Жұмыста проекцияларды жіктеу, жүрек камераларын сегментациялау және интерпретацияланған жасанды интеллекттің көп деңгейлі қабатымен (Grad-CAM, SHAP, LIME) функционалдық параметрлерді бағалау үшін конволюциялық нейрондық желілерді біріктіретін эхокардиографиялық кескіндерді талдаудың интеллектуалды сараптамалық жүйесінің архитектурасы және клиникалық өндіріс ережелері базасы ұсынылған. Мұндай гибридті нейро-символдық шешім кардиологияда терең оқытуды клиникалық енгізудің негізгі кедергісін — қабылданған шешімдердің ашықтығының жетіспеушілігін жоюға бағытталған. Қалыптасқан түсіндірмелердің диагностикалық дәлдігін де, сапасы мен клиникалық өзектілігін де ескеретін жүйені кешенді бағалау әдістемесі ұсынылған. Әрі қарайғы жұмыс сипатталған архитектураны бағдарламалық іске асыруға, модульдерді ашық және клиникалық деректер жиынтығында оқытуға және валидациялауға, сондай-ақ тәжірибеші кардиологтардың қатысуымен сараптамалық бағалау жүргізуге арналады.

**Әдебиеттер тізімі**

1. Madani A., Arnaout R., Mofrad M., Arnaout R. Fast and accurate view classification of echocardiograms using deep learning // NPJ Digital Medicine. — 2018. — Vol. 1. — Art. 6.

2. Zhang J., Gajjala S., Agrawal P., et al. Fully automated echocardiogram interpretation in clinical practice: feasibility and diagnostic accuracy // Circulation. — 2018. — Vol. 138. — P. 1623–1635.

3. Ghorbani A., Ouyang D., Abid A., et al. Deep learning interpretation of echocardiograms // NPJ Digital Medicine. — 2020. — Vol. 3. — Art. 10.

4. Ouyang D., He B., Ghorbani A., et al. Video-based AI for beat-to-beat assessment of cardiac function // Nature. — 2020. — Vol. 580. — P. 252–256.

5. Leclerc S., Smistad E., Pedrosa J., et al. Deep learning for segmentation using an open large-scale dataset in 2D echocardiography // IEEE Transactions on Medical Imaging. — 2019. — Vol. 38, No. 9. — P. 2198–2210.

6. Selvaraju R.R., Cogswell M., Das A., et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization // International Journal of Computer Vision. — 2020. — Vol. 128. — P. 336–359.

7. Lundberg S.M., Lee S.-I. A unified approach to interpreting model predictions // Advances in Neural Information Processing Systems (NeurIPS). — 2017. — P. 4765–4774.

8. Ribeiro M.T., Singh S., Guestrin C. "Why should I trust you?": Explaining the predictions of any classifier // Proceedings of the 22nd ACM SIGKDD Conference. — 2016. — P. 1135–1144.

9. A Clinically Interpretable Deep CNN Framework for Early Chronic Kidney Disease Prediction Using Grad-CAM-Based Explainable AI // arXiv preprint. — 2025.

10. Islam O., Assaduzzaman M., Hasan M.Z. An explainable AI-based blood cell classification using optimized convolutional neural network // Journal of Pathology Informatics. — 2024.

11. Kulkarni P., Madathil D. Fully automatic segmentation of LV from echocardiography images and calculation of ejection fraction using deep learning // International Journal of Biomedical Engineering and Technology. — 2022. — Vol. 40, No. 3. — P. 241–261.

# ҚҰС АУРУЛАРЫНЫҢ КЛИНИКАЛЫҚ БЕЛГІЛЕРІН ЕРТЕ АНЫҚТАУДАҒЫ ЗЕРТТЕУ ҮРДІСТЕРІНІҢ ДАМУЫ

**Сакыпбекова М.Ж., Камбаров Д.Б.**
e-mail: kambarov.dastan@mail.ru
*Әл-Фараби атындағы Қазақ ұлттық университеті, Қазақстан*

***Аңдатпа.*** *Халық санының өсуі мен қоректік тамаққа сұраныстың артуы нәтижесінде жануарлық ақуызды тұтыну көлемі тұрақты түрде өсіп келеді. Құс шаруашылығы адамның тұтынуына арналған ет пен жұмыртқаның үлкен бөлігін қамтамасыз етеді. Құс шаруашылығында жұқпалы ауруларды ерте анықтау мен ескерту мал өсіру және өндіріс жүйелерінде маңызды рөл атқарады, жануарлардың әл-ауқатын жақсартып, шығындарды азайтады. Алайда құс фермаларында жұқпалы ауруларды ерте анықтау мен алдын алу әдістерінің жеткіліксіздігі кейде өнімділіктің төмендеуіне және тіпті жаппай өлім-жітімге әкеледі. Құстардың денсаулық жағдайы көбінесе жеке физиологиялық, физикалық және мінез-құлықтық клиникалық белгілері арқылы көрініс табады, мысалы, қызба нәтижесінде дене температурасының көтерілуі, тыныс алу жолдарының ауруынан туындайтын дауыс өзгерістері және патогенді инфекция салдарынан болатын қалыптан тыс мінез-құлық.*

*Симптомдарды анықтау технологияларын қолдану бройлерлер мен жұмыртқа басатын тауықтардың денсаулық жағдайын үздіксіз, инвазивті емес және автоматтандырылған түрде бақылауға мүмкіндік береді. Бұл шолу соңғы әдебиеттерді қорытындылап, компьютерлік көру, акустикалық талдау, биосенсорлар және машиналық оқыту әдістеріне негізделген зияткерлік мониторинг жүйелерінің мүмкіндіктерін сипаттады. Қазіргі технологиялар қолмен тексеруге қарағанда жоғары дәлдік пен жеделдікті көрсеткенімен, клиникалық симптомдарға негізделген бақылау жүйелері әлі де толық енгізілмеген. Алдағы зерттеулер өндірістік ортаға бейімделген, сенімді және экономикалық тиімді интеллектуалды жүйелерді әзірлеуге бағытталуы тиіс, бұл құс шаруашылығындағы ауруларды ерте анықтау және өндіріс тиімділігін арттыру үшін маңызды.*

## Кіріспе

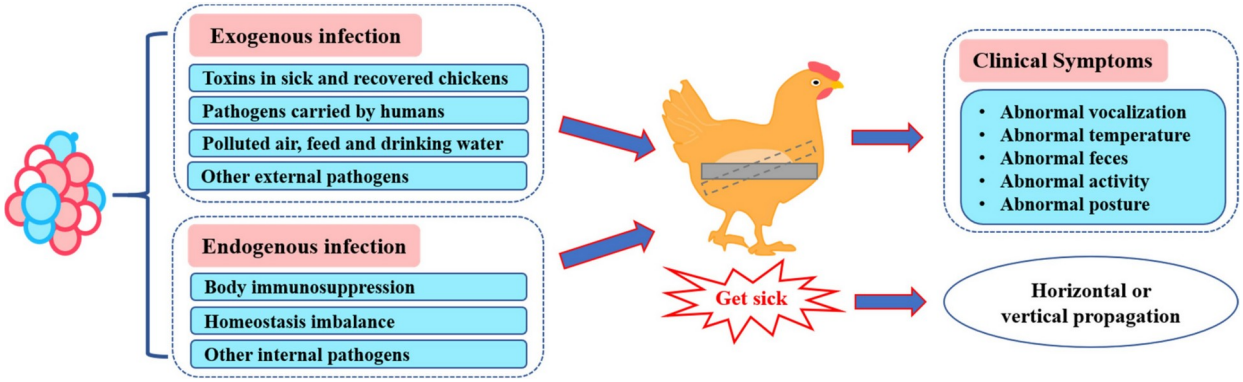
Құс шаруашылығы адам тұтынуына арналған арзан әрі жоғары сапалы ақуыз өнімдерін мол мөлшерде ұсынады, жаһандық экономикада барған сайын маңызды рөл атқарады және ауыл шаруашылығының ең жылдам дамып келе жатқан саласы болып табылады [1]. 2018 жылы әлемде 68 миллиардтан астам тауық өсірілді, бұл жаһандық ет өндірісінің үштен бір бөлігін құрайды, сонымен қатар адам тұтынуына 1,38 триллион жұмыртқа дайындалды [2], бұл белгілі бір дәрежеде азық-түлік қауіпсіздігін қамтамасыз етті.

Халық санының өсуі мен бүкіл әлемде өмір сүру деңгейінің жақсаруымен ет пен жұмыртқа сияқты ақуызға бай өнімдерге сұраныс артып келеді [3,4]. Осы қажеттілікті қанағаттандыру үшін баламалы механизм ретінде қораларды ұлғайтып, көбірек құс өсіру қолданылады. Бұл тәжірибе еңбек ресурстарының тапшылығы мен күшейтілген биоқауіпсіздік шараларымен бірге өндірушілерге барлық құстарының өнімділігін, денсаулығын және әл-ауқатын бақылауды қиындатады [5]. Сондықтан басқаруды жеңілдету және өнімділікті арттыру мақсатында соңғы бірнеше онжылдықта құс шаруашылығы біртіндеп бөлек және шағын жүйелерден интенсивті және ірі көлемді жүйелерге ауысты. Алайда тығыз ортада ауру жұғу қаупі артады. Бұл мәселені шешу үшін селекциялық ғалымдар жоғары өнімділік пен жоғары ауруға төзімділікті үйлестіретін құс тұқымдарын өсіруге ұмтылуда. Алайда өнімділікті арттырумен бірге құстардың бейімділігі мен ауруға төзімділігі сияқты кейбір физиологиялық функциялары шектеледі [6]. Vander [7] жоғары өнімділіктің Marek ауруына (MD) жоғары

сезімталдықты тудыратынын анықтады, ал Lamont [8] жұмыртқа өндіру көрсеткішінің MD-ге төзімділікпен теріс корреляцияда екенін анықтады.

Құс аурулары құс шаруашылығына әсер ететін маңызды факторлардың бірі ретінде ұзақ уақыт бойы құс өнеркәсібінің дамуына кедергі келтірді [6]. Зерттеушілер мен өсірушілер аурулардың алдын алу және бақылау бойынша, мысалы, ауруға төзімді тұқымды өсіру [6,9], иммундық өнімдер [10,11] және күнделікті шараларды күшейту сияқты көптеген жұмыстар жүргізгенімен, құс ауруларының өршуі әлі де болса болдырмай қоймайды, бұл тек үлкен экономикалық шығындарға әкеп соқпай, сонымен бірге кейбір зооноздық жұқпалы аурулар адам өміріне қауіп төндіруі мүмкін [12–14]. 2006 жылы Еуропалық Одақ өсуді ынталандыру үшін антибиотиктерді қолдануға тыйым салғаннан бері [15], құс шаруашылығы антибиотиксіз кезеңге өтті, бұл өндіріс көрсеткіштеріне (салмақ қосу, азық айналым коэффициенті, өлім-жітім және өнімділік) теріс әсер етуі мүмкін. Сонымен қатар, 2027 жылға қарай Еуропалық Одақтың барлық мүше елдерінде жұмыртқа тағатын тауықтарды торда өсіру жүйесін кезең-кезеңімен жойып, ақырында толықтай тыйым салу туралы тағы бір хабарландыру жасалды, бұл аурулардың құс шаруашылығына тигізетін теріс әсерін сөзсіз күшейтеді. Зерттеулер көрсеткендей, жұмыртқа салу кезеңіндегі жұмыртқа салатын тауықтардың өлім-жітімі өсіру тәсілдеріне байланысты, еркін жайылымдық жүйелердегі өлім-жітім көрсеткіші торлы жүйелерге қарағанда шамамен екі есе жоғары.

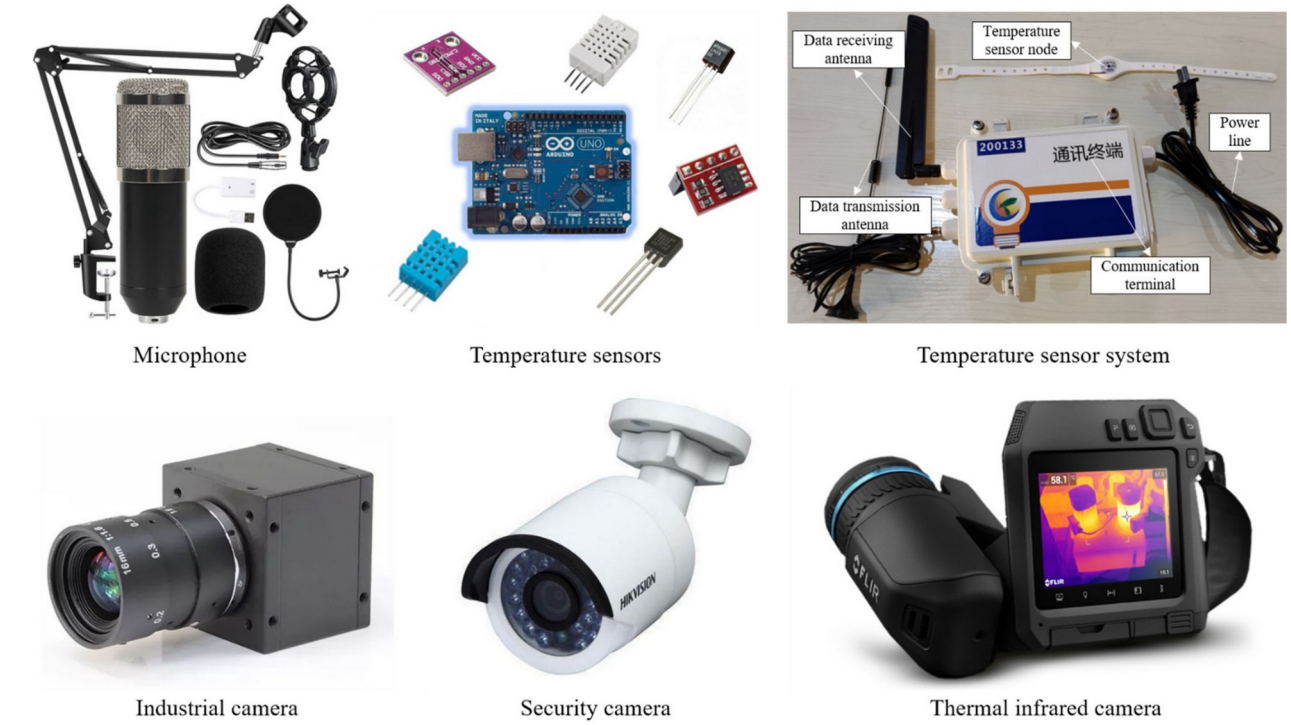
Ауруларды бақылау және ерте ескерту тауық өсірудегі өлім-жітімді азайтуға және өнімділікті арттыруға қажет. Дәстүрлі ауруларды анықтау әдістері негізінен тәжірибелі ветеринарлардың қолмен бақылауына немесе тиісті аспаптармен биохимиялық сынақтарға сүйенеді. Биохимиялық талдау сезімтал әрі нәтижелері әдетте сенімді, бірақ ол әдетте күрделі үлгіні алдын ала өңдеу кезеңдерін қамтиды және мамандарды қажет етеді, сондықтан оны нақты уақыт режимінде жүргізу мүмкін емес және ол әдетте қымбатқа түседі. Қолмен тексеру көп уақытты алады, еңбекке бай және дәл емес нәтижелер беруі мүмкін. Дәстүрлі құс ауруларын бақылау әдістері ауруды ескертудің ең жақсы уақытын жіберіп алуы мүмкін, әсіресе кейбір ауыр жұқпалы аурулар кезінде, бұл тез дамып келе жатқан құс шаруашылығының қажеттіліктерін қанағаттандыра алмайды. Ауырған құстарды дауыс шығару, дене температурасы, нәжіс және күнделікті мінез-құлық сияқты бірнеше аспектілер бойынша анықтауға болады, оларда сәйкес келетін қалыптан тыс өзгерістер болуы мүмкін. Сондықтан құстардың денсаулық жағдайын осы клиникалық белгілер бойынша бағалауға болады. 1-суретте жұғу жолы және құстар ауруларының ықтимал клиникалық белгілері көрсетілген.




1-сурет. Құс ауруларының жұғу жолдары және ықтимал клиникалық белгілері

Кейбір бұрынғы шолулар мал мен құс игілігінің көрсеткіштерін бақылау және патогендерді диагностикалау бойынша техникалық тұрғыдан жүргізілген зерттеулерді қорытындылап, талдады. Бұл шолу тауық ауруларын ерте ескерту мен анықтауға

қолданылатын клиникалық белгілерге назар аударады және осы белгілерді екі өлшем бойынша егжей-тегжейлі түсіндіруге тырысады: (1) физиологиялық сипаттамалар арқылы ауруды ерте анықтау; (2) мінез-құлық сипаттамалары арқылы ауруды ерте анықтау. Осы сипаттамаларды анықтау үшін кейбір мониторингтік құрылғылар қолданылады: дыбыстауды анықтау үшін микрофондар мен камералар; құстардың температурасын анықтау үшін температура сенсорлары мен инфрақызыл термографиялық камералар; құстардың белсенділігін тіркеу үшін үдеу сенсорлары мен камералар; сондай-ақ құстардың дене қалпы мен нәжісін анықтау үшін сандық камералар. 2-суретте құс ауруларының клиникалық ескерту белгілерін анықтауға қолданылатын ең озық құрылғылардың кейбірі көрсетілген.




2-сурет. Микрофондар, сенсорлар және камералар

Осы шолуда қолданылған сілтемелер Web of Science дерекқорларынан алынды. Сілтемелерді алу үшін келесі терминдердің комбинациясы қолданылды: «Құс/Тауық/Жұмыртқа салатын тауықтар/Бройлер», «Денсаулық жағдайы», «Ауру», «Дауыс шығару/Дыбыс/Аудио/Акустика», «Температура», «Нәжіс/Көң/Экскремент», «Мінез-құлық/Әрекет/Дене қалпы», «Ескерту/Анықтау/Бақылау/Диагностика», «Машинамен оқыту», «Терең оқыту» және жоғарыда аталған терминдердің синонимдері (Қосымша материалдар, Сурет S1). Дереккөздер келесі критерийлер бойынша енгізілді: (1) Зерттеу инвазивті емес интеллектуалды әдіспен тауық денсаулығының жағдайын көрсететін кем дегенде бір мінез-құлықтық немесе физиологиялық көрсеткішті бақылады. (2) Зерттеуде қолданылған әдіс егжей-тегжейлі сипатталған. (3) Зерттеу нақты уақыттағы жергілікті бақылауға бағытталған және бақылау процесіне адамның араласуын қажет етпейді. Бұл шолу енгізілген әдебиеттерді егжей-тегжейлі талдау арқылы келесі мақсаттарға жетуді көздейді: (1) Интеллектуалды мониторинг әдістерінің артықшылықтары мен кемшіліктерін талдау арқылы болашақта осы әдістерді кең ауқымды қолдануға негіз қалау. (2) Кейбір кең таралған құс ауруларының клиникалық белгілерін қорытындылап, ауруды ескерту үшін қолданылуы мүмкін ықтимал клиникалық белгілерді ұсыну. (3) Құс ауруларын ерте ескерту және анықтау бойынша

болашақ зерттеулердің перспективаларын айқындау. Осылайша біз құс шаруашылығы саласына елеулі үлес қосуды мақсат етеміз.

**Физиологиялық сипаттамалар арқылы ауруларды ерте анықтау**

Құстардың физиологиялық сипаттамалары мол ақпаратты қамтиды, оны әдетте өсіру ортасының жайлылығын, жануарлардың эмоционалдық күйін және денсаулық жағдайын көрсету үшін қолдануға болады. Адамдарда қанның биохимиялық көрсеткіштері, қан қысымы және дене температурасы сияқты кейбір физиологиялық көрсеткіштер ауруларды диагностикалаудың негізі болып табылады. Құс шаруашылығында дауыс ырғағы, нәжіс және дене температурасы сияқты кейбір физиологиялық сипаттамалар ауруды анықтау және ерте ескерту үшін кеңінен қолданылады, себебі бұл факторлардың аурумен байланысы расталған. Сондықтан осы бөлімде өлшеуі оңай және құстардың денсаулық жағдайын шынайы көрсететін физиологиялық сипаттамаларға назар аударылады.

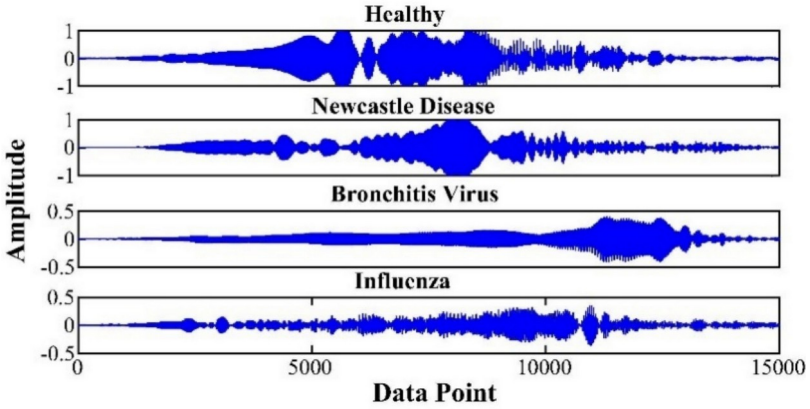
**Қалыптан тыс дауыс шығару**

Маңызды физиологиялық сипат ретінде құс дауысы денсаулық пен әл-ауқат көрсеткіші ретінде қабылданады. Ол құстың салмағын болжауда және шоқылау белсенділігін талдауда табысты қолданылып, бұл тауықтың денсаулық жағдайын жанама түрде көрсете алады. Сонымен қатар, дауыс шығару белгілі бір ағзалар арқылы жүзеге асады және ішкі немесе сыртқы факторлардың әсерінен пайда болатын физиологиялық сигналдың көрінісі болып табылады, ол тыныс алу жүйесінің денсаулығымен тығыз байланысты. Тауықтардың дауыс шығаруындағы айырмашылық өсірушіні қолайсыз ортаға немесе ауру жұқпасына назар аударуға шақыруы мүмкін. Сондықтан дауыс шығаруды жануарлардың денсаулығының ерте көрсеткіші ретінде қарастыру орынды.

Демімен бірге шығатын қосымша дыбыс – релес (Rales) – құс шаруашылығындағы тыныс алу ауруларының жиі кездесетін белгілерінің бірі. Carroll және т.б. 15 күндік алты тауықты жұқпалы бронхит вирусымен жұқтырып, микрофон арқылы сау және ауырған тауықтардың дыбыстарын жазып алған. Зерттеу барысында сөйлеуді тануда ең кеңінен қолданылатын және жануар дыбыстарының спектрін ықшам түрде көрсете алатын Mel жиілік цепстральдық коэффициенттері (MFCCs) есептеліп, C4.5 шешім ағашына сау және жұқтырылған тауық дыбыстарын жіктеу үшін енгізілді, жіктеу дәлдігі 73,4% болды. Шешім ағашы – бұл адамның пайымдауына жақын және түсінуге оңай болғандықтан, жіктеу модельдерін құруда кеңінен қолданылатын кезектес модель түрі [40]. Осы бірдей дыбыстық деректерге Уитакер және т.б. сөздік үйрену және сирек кодтау әдістерін қолданып, дыбыстық сигналдарды жіктеді және дәлдігін 97,85%-ға дейін арттырды, ал Ризван және т.б. rales-ті анықтау үшін экстремалды оқыту машинасы (ELM) және қолдаушы векторлық машина (SVM) классификаторларын әзірлеп, олардың дәлдігі тиісінше 97,1% және 97,6% болды. Banakar және т.б. әртүрлі ауруларға шалдыққан құс дыбыс сигналдарының әртүрлі акустикалық сипаттамалары бар екенін және оларды ажыратуға болатынын көрсетті. Олар 14 күндік 308 Ross тауықтарын төрт топқа бөлді, әрқайсысында 60 тауық болды. Бірінші топ бақылау тобы ретінде қарастырылды (инфекциясыз). Екінші, үшінші және төртінші топтар тиісінше Ньюкасл ауруы (ND), жұқпалы бронхит ауруы (IBD) және құс тұмауы (AI) вирустарымен жұқтырылды. 3-суретте сау, ND, IBD және AI топтағы тауықтардың дыбыс сигналдарының уақыттық аймағы көрсетілген. Содан кейін олар SVM және Демпстер–Шефер дәлел теориясын біріктіріп, дыбыстық деректердің төрт сыныбын анықтап, ақырында 91,15% дәлдікке қол жеткізді.

Жоғарыда аталған зерттеулердегі дыбыстық үлгілер мен нәтижелер жабық ортада алынған, яғни сыртқы шуылдың кедергісі жоқ, бірақ бұл коммерциялық фермалардың нақты жағдайына сәйкес келмейді. Жөтел – көптеген тыныс алу ауруларының

клиникалық белгісі. Көптеген шу көздері бар жағдайда түшкіру дыбыстарын анықтау үшін сезімталдығы 66,7% және дәлдігі 88,4% болатын алгоритм әзірленіп, іске асырылды, бұл құс шаруашылығындағы денсаулықты дыбыстық негізде автоматтандырылған бақылау жүйесінің мүмкіндігін көрсетті. Mahdavian және т.б. дыбысты жіктеу үшін сау және ауру тауықтардан бес акустикалық сипаттаманы (MFCC, Mel кіші жолақтарының энергиясы, толқынды энергия, толқынды энтропия және спектрлік тегістік) анықтап, толқынды энергия мен MFCC сипаттамалары екпе енгізілгеннен кейін төртінші күні Ньюкасл ауруын тиісінше 80% және 78% дәлдікпен анықтай алатынын анықтады. Екі сипаттаманың да дәлдігі ұқсас болғанымен, валлет энергиясы сау тауықтарды анықтауда тиімдірек болса, MFCCs сынаққа ұшыраған құстарды анықтауда жақсы нәтиже көрсетті.




3-сурет. Төрт түрлі тауық тобының дыбыстық уақыттық домендік сигналдары: сау тауықтар, Ньюкасл ауруына шалдыққан тауықтар, бронхит вирусына шалдыққан тауықтар және құс тұмауына шалдыққан тауықтар. [15]-ші дереккөзінен рұқсатпен қайта басылған.

Әртүрлі ауруларға шалдыққан тауықтардың акустикалық ерекшеліктері әдетте бірдей сипаттамалар жиынтығымен сипаттала алмайды, бұл жасанды сипаттама инженериясы негізінде құрылған модельдің жалпылау қабілетінің төмен болуына әкеледі. Сондықтан бұл мәселені шешу үшін кіріс деректерден сипаттамаларды автоматты түрде алады және күрделі сипаттама инженериясынан аулақ болатын терең оқыту модельдері қолданылды. Cuan және т.б. жүргізген зерттеуде RNN (Recurrent Neural Network) және CNN (Convolutional Neural Network) екі терең оқыту моделі сау тауықтар мен (AI) жұқтырған тауықтардың дыбыстарын жіктеу үшін қолданылды. Зерттеу нәтижелері CNN-нің ең жоғары тану дәлдігі H9N2 вирусын енгізгеннен кейінгі екінші, төртінші және алтыншы күндері тиісінше 93,01%, 95,05% және 97,43% болғанын көрсетті, бұл RNN-нің тиісінше 49,97%, 55,86% және 57,10% көрсеткіштерінен әлдеқайда жоғары болды. Бұл әдіс құс тұмауының өршуіне дейін фермерлерге қажетті шараларды қабылдауға ескерту жасап, экономикалық шығындарды айтарлықтай азайтуға мүмкіндік береді. Жақында жүргізілген зерттеуде Cuan және т.б. тауық дыбыстарын талдау арқылы ND-ны ерте ескертуді сәтті жүзеге асырды, және нәтижелер жұқтырғаннан кейінгі бірінші, екінші, үшінші және төртінші күндері анықтау дәлдігі тиісінше 82,15%, 90,00%, 93,60% және 98,50% болғанын көрсетті, бұл малдың әл-ауқатын жақсарту және құс өсіру өндірісін автоматтандырылған бақылау үшін маңызды. Дыбыстық сигналдар арқылы жануар ауруларын анықтаудың шығыны салыстырмалы түрде төмен, ал қолдану перспективалары кең, бірақ әлі жетілмеген. Екі негізгі қиындық бар. Біріншісі – шуды жою. Жануарлардың өмір сүретін ортасында желдеткіштердің айналуы, конвейер белдіктерінің жұмысы және басқа да әрекеттер үлкен сыртқы шу тудырады, ол дыбысты алдын ала өңдеу мен соңғы нәтижелерге әсер етуі мүмкін.

Екіншісі – ақаулы дыбыстардың жоғары сиректігі. Тауық дыбыстарының деректері үздіксіз, ал ауытқушы дыбыстар ұзақ жазба уақытының шағын бөлігін кездейсоқ түрде ғана қамтиды. Сондықтан күрделі ортада тану дәлдігі мен тиімділігін арттыруға арналған алгоритмдерді қалай жобалау және іске асыру мәселелерін болашақта шешу қажет. Сонымен қатар, егер тауық қорасындағы ауытқушы дыбысты кеңістік тұрғысынан анықтауға мүмкіндік берілсе, бұл қазіргі заманғы құс шаруашылығын басқару деңгейін одан әрі жақсартып, фермерлердің жүктемесін азайтар еді.

**Дене температурасының қалыптан тыс жоғары болуы**

Тауық – дене температурасын салыстырмалы түрде тұрақты ұстап тұру үшін жылу өндіріп, оны тарататын гомеотермді жануар, соның ішінде негізгі және тері беті температурасы. Алайда патологиялық немесе стрестік жағдайларда инфекция немесе төтенше жауап реакциясы салдарынан температура өзгереді. Сондықтан температура тауық ауруларын ерте ескерту және анықтау үшін маңызды физиологиялық көрсеткіш болуы мүмкін.

Аяқ табанының дерматиті (FPD) – өсіп келе жатқан бройлер тауықтардың аяқ табанының табан бетінде некротикалық зақымдануларға әкелетін жағдай, ол жануарлардың әл-ауқаты мәселесі болып саналады және үлкен экономикалық шығындарға әкелуі мүмкін. Диэлектрлік тұрақты (DC) мәні, электрондық басқару блогы мен сенсорлы зондтан тұратын ылғалдылық өлшегіш құрылғы арқылы табан терісін өлшеу арқылы анықталатын, FPD-ны диагностикалауға пайдалы. Hoffmann және т.б. [53] зерттеуі бойынша DC мәні FPD көрсеткіші артқан сайын біркелкі төмендейді және DC мен FPD көрсеткіші арасындағы теріс корреляция маңызды ($p < 0,0001$). FPD әдетте табан мен табан асты жастықшаларының табан беті температурасының өзгеруімен бірге жүреді. 80 басты 10 апталық күркетауықтардың табан бетінің температурасы термографиялық бейнелеу әдісімен өлшенді, және нәтижелер қалыпты жағдайда табан асты терісінің температурасы аяқ температурасынан айтарлықтай төмен екенін және визуалды бағалау бойынша жеңіл табан асты дерматитінің ауырлығы табан беті мен табан асты терісінің температурасымен теріс байланыста екенін көрсетті. Сонымен қатар, тауықтарды метатарсальды табаннан саусақ ұштарына дейінгі температура өзгерісіне қарай үш категорияға (FPD теріс, күдікті және оң) бөлуге болады. 150 кездейсоқ таңдалған тауықтың табан бетінің температурасын талдау нәтижесінде термиялық суреттер бойынша оң деп жіктелген үлгілер мен клиникалық FPD визуалды ұпайлары арасындағы корреляция 86,7% құрағаны анықталды. Нәтиже көрсеткендей, термография аяқ патологияларын сенімді және инвазивті емес ерте анықтауға арналған жаңа құрал болып табылады, ол визуалды бағалаумен салыстырғанда субклиникалық инфекцияның сезімталдығы жоғары көрсеткіші болып табылады. Сонымен қатар, Liu және т.б. зерттеуі термография құс терісінің беткі температурасын өлшеп, басы мен аяғы арасындағы температура айырмашылығына негізделген сау және ауру құстарды ажырата алатынын көрсетті. Тауықтың басы дене температурасы туралы ақпарат алу үшін негізгі аймақ болып табылады және оны дұрыс анықтау өте маңызды. Алгоритмді оңтайландырумен қатар, жылу инфрақызыл камераны орнату әдісі де маңызды. Шен және т.б. зерттеуі 160 см биіктіктен және 30° бұрышпен алынған жылу инфрақызыл суреттердің сапасы жоғары екенін және бройлер тауық басын тану дәлдігі 91,3% екенін көрсетті.

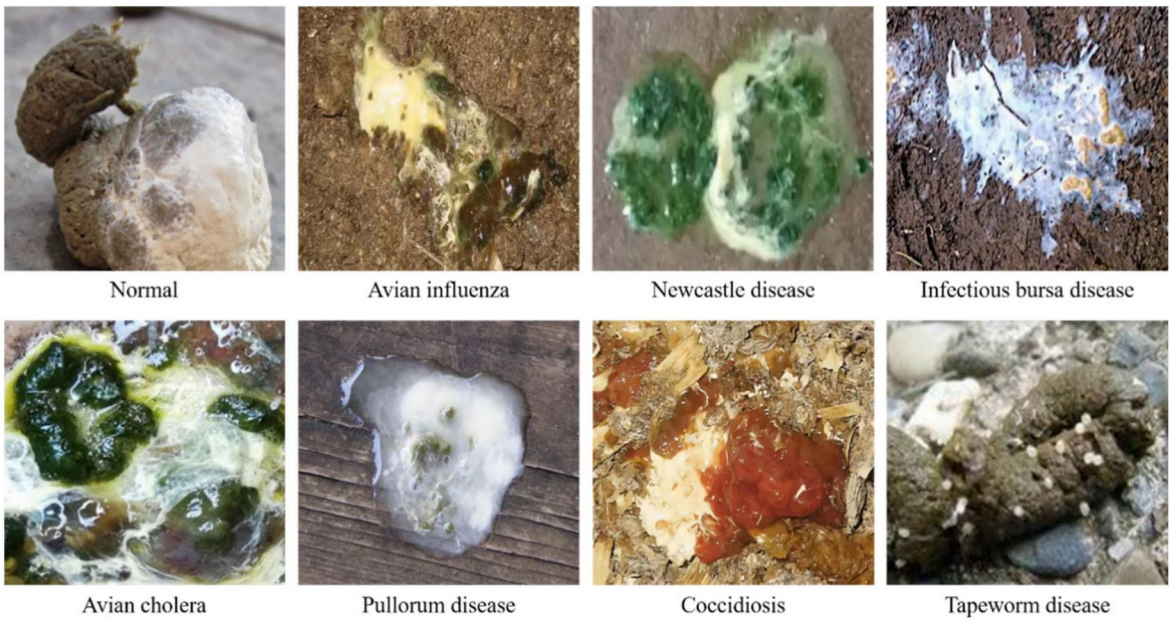
Жуырда зерттеушілер ПТР және биосенсор технологияларына негізделген портативті құс тұмауын анықтайтын құрылғыларды әзірлеуге баса назар аударды, алайда бұл әдістер салыстырмалы түрде қымбат әрі оларды қолдану үшін білікті мамандар қажет. Сондықтан жоғары патогенді құс тұмауымен зақымдалған тауықтарды анықтауға арналған термистор мен акселерометрден тұратын киілетін сымсыз түйіннің прототипі әзірленді. Нәтижелер жұқтырылған тауықтардың дене температурасының кенеттен төмендеуін олардың клиникалық белгілері мен макроскопиялық зақымданулары пайда

болмас бұрын анықтауға болатынын көрсетті. Сондай-ақ, жоғары патогенді құс тұмауын анықтауда жылу бейнелеу технологиясын қолданған зерттеулер де бар. Құс тұмауының клиникалық белгілері пайда болғанға дейін, аурудың ауырлығына байланысты, тауықтардың беткі температурасы кемінде 24 сағат бұрын көтеріледі, бұл тауықтардың беткі температурасын құс тұмауының ерте көрсеткіші ретінде қарастыруға мүмкіндік береді. Өлген тауықтардың дене температурасы төмендейтінін ескере отырып, Blas және т.б. жоғары ажыратымды жылу бейнелеу технологиясы арқылы құс шаруашылығында өлген тауықтарды сәтті анықтап, қалған тауықтардың әл-ауқатын жақсартып, ауру таралу қаупін азайтты.

Қазіргі уақытта құс шаруашылығында дене температурасының ауытқуына негізделген ауруларды анықтауға қатысты зерттеулер негізінен аяқ аурулары мен құс тұмауына бағытталған. Термографиялық инфрақызыл температура қоршаған орта факторлары мен тауықтардың бір-біріне жақын орналасуынан оңай әсерленеді. Термографиялық инфрақызыл температура қоршаған орта факторлары мен тауықтардың бір-біріне жақын орналасуынан оңай әсерленеді. Бақылауға келмейтін қоршаған орта жағдайларында жоғары сапалы термографиялық инфрақызыл суреттерді тұрақты түрде қалай алу және тауықтың басы мен аяқ аймақтарының сегментация дәлдігін қалай жақсарту мәселелеріне көбірек назар аудару қажет. Сонымен қатар, болашақта құс дене температурасы мен өсу көрсеткіштері мен мінез-құлық арасындағы байланысқа назар аудару қажет. Сонымен қатар, киілетін температура сенсорлары жақсы тұрақтылық пен ұзақ беру қашықтығын қамтамасыз ете отырып, одан да портативті әрі жеңіл болады.

**Нормадан тыс нәжіс**

Ас қорыту жүйесінің аурулары тауық өсірудегі ең кең тараған аурулардың бірі болып табылады, олар өндіріс көрсеткіштеріне және жануарлардың әл-ауқатына айтарлықтай әсер етеді. Тауықтардың ас қорыту жолдары бактериялар немесе вирустармен зақымданған кезде инфекцияның ауырлығына қарай әртүрлі дәрежедегі патологиялық өзгерістер пайда болады, олар клиникалық тәжірибеде нормадан тыс нәжіс түрінде көрініс табады. 4-суретте тауықтардың типтік ас қорыту аурулары кезіндегі қалыпты және қалыптан тыс нәжістер көрсетілген.




4-сурет. Тауықтардағы типтік ас қорыту аурулары кезіндегі қалыпты және қалыптан тыс нәжіс

Ауру жұқтырған тауықтардың нәжісі түсі, пішіні, ылғалдылығы және құрамы бойынша қалыптан тыс өзгерістерге ұшырауы мүмкін.

Сондықтан нәжіс тауық ауруларын ерте ескертудің негізі ретінде қолданылуы мүмкін. 1-кестеде тауықтарда диарея тудыратын жиі кездесетін аурулар және олардың сәйкес нәжістің сыртқы ерекшеліктері көрсетілген.

*Кесте-1. Тауықтарда диарея тудыратын жиі кездесетін аурулар және олардың сәйкес нәжіс ерекшеліктері*

| Аурудың атауы | Қорғансыз уақыт | Қауіптілік дәрежесі * | Нәжістің сипаттамалары |
|---|---|---|---|
| Құс тұмауы | Барлық жастағыларға | FFFF | Сары-қоңыр және сулы |
| Ньюкасл ауруы | Барлық жастағыларға | FFFF | Сары-жасыл және сулы |
| Инфекциялық бурса ауруы | 3–6 апта | FFF | Шымтезекті сулы |
| Инфекциялық бронхит | 3–7 апта | FFF | Ақ және сулы |
| Құс холерасы | Ересек | FFF | Шөп-жасыл және сулы |
| Пуллор ауруы | 0–2 апта | FF | Ақ ірімшік тәрізді |
| Кокцидиозы | 4–6 апта | FF | Қоңыр-қызыл сұйық немесе қан |
| Ленточ құрт ауруы | Барлық жастағыларға | F | Ленточті құрт жұмыртқалары |

Қауіптілік деңгейі F символдарының санымен көрсетілді: символдар саны артқан сайын қауіпті жағдай да күрделене түседі.

Тәжірибелі ветеринарларға негізделген дәстүрлі нәжісті анықтау әдісі белгілі бір дәрежеде мүмкін, бірақ ол көп уақытты алады, еңбекке сыйымды және қате диагноз қоюға бейім. Сондықтан зерттеушілер ауыл шаруашылығы міндеттерін шешу үшін машинамен оқыту алгоритмдерін қолдана бастады.

SVM – бұл бақылаумен оқыту арқылы екілік деректерді жіктеуге арналған жалпыланған сызықты классификатор, оның шешім шекарасы оң және теріс сыныптар үшін максималды маржа гипержазықтық болып табылады. Aziz және т.б. тауық нәжісінің сыртқы сипаттамаларын тауық ауруларын анықтауда SVM-мен біріктіруді алғаш рет қолданды. Олар суреттегі әртүрлі сұр деңгейлердің бірге болуы туралы кейбір статистикалық өлшемдерді шығарудан тұратын, кеңінен танымал текстура сипаттағыш – сұр деңгейлердің бірге кездесу матрицасын пайдаланып, нәжістің 19 текстуралық ерекшелігін анықтап, осы текстуралық ерекшеліктер жиынтығын SVM-ге кіріс ретінде қолданып, сау және ауру тауықтардың нәжісін жіктеді. Нәтижелер ең жоғары дәлдік 93,75% болғанын көрсетті, бұл ауру тауықтарды нәжіс сипаттамалары бойынша анықтаудың мүмкіндігін дәлелдеді, бірақ тәжірибеде тек 20 үлгі қолданылғандықтан, нәтижелер өкілдік етпеуі мүмкін. Нәжісті жіктеу – тек алғашқы қадам, ал көп мөлшерде нәжіс бар суреттерде қалыптан тыс нәжісті анықтау маңызды. Терең оқыту алгоритмдерінің дамуы үлкен көлемдегі үлгілермен жұмыс істеуге мүмкіндік береді. Ван және т.б. коммерциялық тауық фермаларында 25–35 күндік Ross бройлерлерінің 10 000 нәжіс кескінін жинады. Оларды қолмен бес санатқа бөлді: қалыпты, пішіні қалыптан тыс, түсі қалыптан тыс, судың мөлшері қалыптан тыс, пішіні мен судың мөлшері қалыптан тыс. Олардың зерттеуінде нәжісті анықтау және жіктеу үшін CNN негізіндегі екі объект анықтау моделі ұсынылды. Нәтижелер көрсеткендей, Faster R-CNN моделі сынақ деректер жиынында 99,1% recall және 93,3% орташа дәлдік көрсеткішімен жоғары өнімділік көрсетті. Бұл зерттеу коммерциялық фермаларда құс шаруашылығындағы ас қорыту жүйесінің ауруларын анықтауға жаңа идея ұсынады.

Құс ішегіндегі ауруларды анықтауда нәжістегі паразиттерді санау және түрлерін анықтау да маңызды міндет болып табылады. Ғалымдардың еңбегінің арқасында бүгінгі таңда бұл міндетті жоғары дәлдікпен орындауға болады. Биохимиялық әдістер нақты ауруды дәл анықтай алса да, олар әдетте күрделі операциялық процестерге ие және аурулардың ерте ескертуіне жарамайды. Керісінше, нәжістің сыртқы сипаттамалары бойынша нақты ауруды диагностикалау қиын, бірақ бұл фермерлерге ауруды алдын алу және бақылау шараларын мүмкіндігінше ерте жүргізуге бағыт-бағдар береді. Болашақта зерттеушілер жұқпаның ерте, орта және кеш сатыларындағы әртүрлі аурулардың нәжісінің сыртқы сипаттамаларын ескеріп, ауруды ерте ескерту мақсатында аурудың ерте сатысындағы нәжіс сипаттамаларын талдауға назар аударуы тиіс. Сонымен қатар, ас қорыту жүйесінің ауруларын жиі белгілі бір маркерлер арқылы анықтауға болады. Белгілі заттарды сапалық және сандық тұрғыдан анықтай алатын технология ретінде спектрлік технология ет өнімдерінің бетіндегі нәжісті анықтау үшін қолданылған. Дегенмен, спектрлік технологияны тікелей нәжіс маркерлерін анықтауға қолдану жөніндегі зерттеулер әлі жүргізілмеген.

**Мінез-құлық ерекшеліктері арқылы ауруды ерте анықтау**

Жануарлардың әл-ауқаты мен денсаулығының ең маңызды көрсеткіштерінің бірі ретінде мінез-құлық, ол белсенділік пен дене қалпы арқылы көрініс табады, стресс пен өндіріс деңгейлеріне қарағанда ең қарапайым, ең кең тараған және ең оңай түсінікті болып саналады. Сондықтан құс мінез-құлқын нақты уақыт режимінде, автоматты және бұзбайтын бақылау жануарлардың әл-ауқатын жақсартуда және ауырған құстарды ерте анықтауда маңызды рөл атқарады.

**Аномальды белсенділік**

Құс шаруашылығында ақсақтық – кең таралған аяқ ауруы, және тауықтардың шамамен 30%-ы ауыр дәрежеде ақсақ болады. Құстардың белсенділігі қалыпты шектен ауытқығанда, бұл көбіне аурудың белгісі болып саналады. Соңғы зерттеулер құс тобының белсенділігін автоматты түрде бақылау ауруды ерте анықтауға мүмкіндік беретінін көрсетті.

Kristensen және әріптестері 1, 2 және 3 апталық бройлер тауықтарының табиғи және аномальды белсенділік деңгейлерін камералар арқылы жазып, сипаттады. Нәтижелер көрсеткендей, бұл анықтау жүйесі құстардың белгілі бір жасындағы күтілетін белсенділік деңгейінен ауытқуларды байқаған кезде өндірушілерге хабарлай алады. Ақсақтықты анықтауда ең жиі қолданылатын әдіс – жүріс стилін бағалау (gait score), ол визуалды бақылауға қатты тәуелді.

Бройлерлердің белсенділік деңгейін автоматты түрде бақылау үшін жаңа және инвазивті емес әдіс әзірленді. Aydin тереңдік сенсоры бар 3D көру камерасын қолданып, бройлерлердің мінез-құлқын тіркеді. Кескіндерді өңдеу алгоритмі бройлерлердің жату және тұру әрекеттерін анықтап, жату оқиғаларының санын және ұзақтығын есептеді. Зерттеу нәтижесінде 3D визуалды камера жүйесінің классификация дәлдігі қолмен белгіленген нәтижелермен салыстырғанда 93% болғаны дәлелденді. Сондай-ақ, жату ұзақтығы мен жүріс бағасы арасындағы теріс корреляцияға сүйене отырып, бройлер аяқтарының денсаулық жағдайын жанама бағалау әдісі ұсынылды.

Кейінірек Aydin бройлерлердің жылдамдығы, қадам жиілігі, қадам ұзындығы және дененің бүйірлік тербелісі жүріс бағаларымен өзара байланысты екенін анықтады. Бұған қоса, белсенділіктің амплитудасы (ең жоғарғы белсенділік шыңы мен бастапқы деңгей арасындағы айырмашылық) да жүріс бағасымен елеулі байланыста екені дәлелденді — жүріс қабілеті төмендеген сайын амплитуда да азаяды.

Оптикалық ағын талдауы – қатар орналасқан бейнелер арасындағы жарықтық өзгерісіне сүйеніп, нысанның қозғалу жылдамдығын есептейтін қарапайым бейнеанализ әдісі – аномальды топтық белсенділікті ерте кезеңде анықтау үшін қолданылды. Colles

және әріптестері Campylobacter жұқтырған тауықтарды анықтау үшін оптикалық ағын талдауын пайдаланды. Нәтижелер Campylobacter-дан таза тауық топтарының оптикалық ағын орта мәнінің жоғары, ал куртозисінің төмен болатынын көрсетті. Бұл әдіс субклиникалық инфекцияны 7–10 күннің ішінде анықтай алады, бұл дәстүрлі микробиологиялық тәсілдерден әлдеқайда ерте.

Топтық белсенділікті бақылау сондай-ақ тауықтардың өлім-жітімінің артуына және жұмыртқалаушы тауықтардағы төс сүйегінің сынуына байланысты аномальды жағдайларды ерте анықтауда тиімді болды. Сонымен қатар, тауықтардың топтық белсенділігі жануарлар таралу индексіне түрлендіріліп, жануарлардың кейбір жасырын денсаулық мәселелерін анықтауға мүмкіндік береді.

Жоғарыдағы нәтижелер құстардың белсенділігін автоматты түрде бақылау ауруды ерте кезеңде анықтай алатынын көрсетеді. Алайда қазіргі зерттеулердің көбі топ деңгейінде жүргізілуде, сондықтан аномальды белсенділік байқалған топ ішінен ауруға күдікті бір құсты дәл анықтау – жануарлардың әл-ауқатын жақсартудағы келесі маңызды қадам болмақ.

**Аномальды қалып**

Белсенділік – тауықтың динамикалық сипаттары болса, ал қалып (поза) – статикалық сипаттарына қатысты. Сондықтан организм қызметі гомеостаздан ауытқығанда, тауық қалыпты қалпын сақтауға жеткілікті энергия жұмсай алмайтыны түсінікті.

Zhuang және әріптестері [88] бройлерлердің қалпының өзгеруін бақылау арқылы сау және құс тұмауымен (AI) жұқтырған тауықтарды табысты анықтады. Зерттеуде алдымен сегментация алгоритмдері қолданылып, фон мен тауықтар бөлінді, содан кейін контур мен қаңқа (skeleton) туралы ақпарат алынды. Одан әрі алты белгіні (ойықтық, қаңқа еңкіштік бұрышы, пішін ерекшеліктері, аудан–сызықтық қатынас, созылыңқылық және дөңгектілік) қолмен есептеп, белгілер векторын құрды, ал соңында машиналық оқыту алгоритмдері бройлерлердің денсаулық жағдайын бағалау үшін пайдаланылды. Нәтижелер SVM моделінің дәлдігі ең жоғары — 99,469% болғанын көрсетті. Бұл алгоритм ауру тауықтарды ерте анықтауға мүмкіндік береді, бірақ процедуралары күрделі. Сонымен қатар, денсаулықты бағалау алдында тауықтың азықтану күйінде тұрғанын анықтау үшін оның бас аймағын бөліп алу қажет. Бұл тауық камераға толық беттемеген жағдайда алгоритмнің жұмыс істемейтінін білдіреді.

Newcastle ауруымен жұқтырған және сау тауықтардың қалып айырмашылықтарын талдау үшін Okinda және әріптестері [89] қалып-пішіннің жаңа жиынтық ерекшеліктерін (шеңбер вариациясы, созылыңқылық, дөңестік, күрделілік және эксцентриситет) ұсынды. Олардың зерттеуінде жүру жылдамдығы да белгілер векторына енгізілді. Нәтижелер аурудың өршуінен бұрын ерте ескерту жасауға болатынын көрсетті. Ең ерте анықтау уақыты шеңбер вариациясы мен созылыңқылық арқылы – төртінші күн, ал эксцентриситет және жүру жылдамдығы арқылы – алтыншы күн болды. SVM моделі мұнда да ең жоғары дәлдікке — 98,8% жетті. Айырмашылығы — бұл әдіске тек тауықтың жоғарыдан түсірілген (top-view) бейнесі жеткілікті, бұл жануардың камераға бағытталған күйіне тәуелділікті азайтады.

Қолмен белгі алу әдістері тек өлшеуге жеңіл белгілерді (өлшем, пішін, текстура және т.б.) шығара алады, әрі жұмыс көлемі үлкен және әртүрлі тапсырмаларға бейімдеу (модельді көшіру) қиын. Сондықтан құс қалпын танудың терең оқытуға негізделген әдістері пайда болды. Топ ішінен ауру бройлерлерді автоматты анықтау үшін Zhuang және әріптестері бастапқы Single Shot MultiBox Detector моделіне негізделген жақсартылған нұсқаны (Improved Feature Fusion SSD) ұсынды. Бұл модель бройлерлерді анықтап қана қоймай, олардың денсаулық жағдайын да бір уақытта бағалай алады және орташа дәлдік бойынша 99,7% (IoU > 0.5) және 48,1% (IoU > 0.9) нәтижеге қол жеткізді.

Сонымен қатар, егер жануарлардың әртүрлі қалыптарын — тұру, ұйықтау, жем шоқу, қауырсын шоқу сияқты — автоматты әрі дәл анықтау мүмкін болса, бұл құс өсірушілерге анағұрлым құнды ақпарат ұсынып, топты тиімді басқаруға мүмкіндік береді.

**Қорытынды**

Ауруларды бақылау – құс өсірушілер үшін аса маңызды мәселе. Дәстүрлі қолмен жүргізілетін ауру тексеру әдістері құс фермаларының көлемі мен санының өсуіне байланысты қажеттілікті қанағаттандыра алмайды. Клиникалық симптомдар – құс ауруының тікелей көрінісі. Клиникалық белгілерге негізделген автоматты ауру анықтау және ерте ескерту технологиялары құс денсаулығын нақты уақыт режимінде, жылдам және деструкциясыз бақылауға мүмкіндік береді.

Қазіргі уақытта құс ауруларын анықтау көбінесе келесі белгілерге негізделеді: 1) дауыс ерекшеліктері; 2) дене температурасының ерекшеліктері; 3) нәжіс сипаттамалары; 4) өндірістік көрсеткіштер (су ішу, жем тұтыну және т.б.); 5) белсенділік сипаттары; 6) қалып сипаттары.

Жоғарыда сипатталған ерекшеліктер негізінен машиналық көру жүйелері, дыбыс жазу құралдары, киілетін сенсорлар және басқа әдістер арқылы жинақталады, әрқайсысының өз артықшылықтары мен кемшіліктері бар. Машиналық көру әдісі жүйені құрудан бастап алгоритмді енгізуге дейін салыстырмалы түрде жетілген, бірақ оның көру аймағы шектеулі болуы және жеке тұлғаларды бақылау қиындықтары бар. Дыбысты өңдеу технологиясының қолдану әлеуеті кең. Қатысты жабдықтардың бағасы төмен, бірақ дыбыс тану нәтижелері қоршаған ортаның шуына өте сезімтал, бұл дыбысты талдау технологиясы түнде қолдануға ыңғайлы болуы мүмкін екенін білдіреді. Киілетін сенсорларды орнату оңай, алынған деректер өте сенімді, бірақ олар құстарға стресс туғызуы мүмкін, сондай-ақ сенсордың сигнал беру қашықтығы мен төзімділігін оңтайландыру қажет.

Құс шаруашылығын ақпараттық және интеллектуалды жүйелерге көшіру – болашақ дамудың негізгі бағыты болып табылады. Ауруларды ерте ескерту технологияларын дамыту және қолдану еңбек күшін тиімді азайтып, жануарлардың әл-ауқатын және ферма басқару деңгейін жақсарта алады. Әсіресе, инфекциялық ауруларды ерте ескерту тауықтардағы аурулардың өршуін белгілі бір дәрежеде болдырмай, ауруларға байланысты экономикалық шығындарды айтарлықтай төмендетеді және жалпы экономикалық тиімділікті арттырады.

Дәстүрлі өсіру жүйесі көп адамдардың қатысуын қажет етеді, ал көп адам – потенциалды патогендердің көбеюін білдіреді, бұл қарқынды ферма жүйелері үшін өте қолайсыз. Сондықтан, интеллектуалды технологиямен жабдықталған фермалардың тағы бір маңызды артықшылығы – ферма персоналының қозғалысын минимизациялау, бұл биологиялық қауіпсіздікті елеулі түрде жақсартады.

Соңында, клиникалық симптомдарға негізделген құс ауруларын автоматты интеллектуалды бақылау технологиясының даму тенденциялары келесідей болжанады:

1. Құс сипаттамаларының дерекқорын құру, оған әртүрлі аймақтар, тауық түрлері, ауру категориялары және клиникалық деректер кіреді.
2. Ауруларды анықтау алгоритмдерін оңтайландыруды жеделдету, дәлдікті арттыру және алгоритмді енгізу кезінде есептеу жүктемесін азайту үшін модельдің көлемін шектеу.
3. Әртүрлі клиникалық сипаттамаларды біріктіріп, құстардың денсаулық жағдайын кешенді бағалау және соңында құс ауруларын ерте ескертуге арналған сараптама жүйесін құру.
4. Құс ауруларын анықтау және ерте ескерту үшін толық интеллектуалды жабдықтар жиынтығын әзірлеу және жобалау.

**Әдебиеттер тізімі**

1. *Mottet, A.; Tempio, G.* Жаһандық құс шаруашылығы: Қазіргі жағдай, болашақ перспективалар және қиындықтар. Worlds Poult. Sci. J. 2017, 73, 245–256.

2. *Blake, D.P.; Knox, J.; Dehaeck, B.;* т.б. Тауықтардағы кокцидиоздың шығындарын қайта есептеу. Vet. Res. 2020, 51, 115.

3. *Cao, Y.H.; Li, D.F.* Азия елдерінде жануарлық ақуыз өнімдеріне сұраныстың артуының жаһандық азық-түлік қауіпсіздігіне әсері. Anim. Front. 2013, 3, 48–55.

4. *Daghir, N.; Diab El Harake, M.; Kharroubi, S.* Орта Шығыс және Солтүстік Африкадағы құс шаруашылығы және азық-түлік қауіпсіздігіне әсері. J. Appl. Poult. Res. 2021, 30, 100110.

5. *Astill, J.; Dara, R.A.; Fraser, E.D.G.;* т.б. Ақылды құс шаруашылығы: ақылды сенсорлар, үлкен деректер және заттар интернеті. Comput. Electron. Agric. 2020, 170, 105291.

6. *Jie, H.; Liu, Y.P.* Құс ауруларына төзімділікті арттыру бойынша селекция: мүмкіндіктер мен қиындықтар. Worlds Poult. Sci. J. 2011, 67, 687–696.

7. *Gavora, J.S.; Spencer, J.L.* Иммундық жауаптылық пен ауруларға төзімділікті селекциялау. Worlds Poult. Sci. J. 1983, 53, 469–500.

8. *Lamont, S.J.* Тауықтың негізгі гистосәйкестік кешені және аурулар. Rev. Off. Int. Epizoot. 1998, 17, 128–142.

9. *Knap, P.W.;* Doeschl-Wilson, A. Ауруларға төзімді малды неге және қалай селекциялау керек? Genet. Sel. Evol. 2020, 52, 60.

10. *Blake, D.P.; Tomley, F.M.* Құс шаруашылығын әрдайым кездесетін Eimeria қауіпінен қорғау. Trends Parasitol. 2014, 30, 12–19.

11. *Lillehoj, H.; Liu, Y.H.; Calsamiglia, S.;* т.б. Фитохимиялық заттар антибиотиктердің орнына өсімдікті дамыту және иелік денсаулығын жақсарту үшін. Vet. Res. 2018, 49, 76.

12. *Kalthoff, D.; Globig, A.; Beer, M.* (Жоғары патогенді) құс тұмауының зооноздық агент ретінде маңызы. Vet. Microbiol. 2010, 140, 237–245.

13. *Peiris, J.S.M.; Cowling, B.J.; Wu, J.T.;* т.б. Азиядағы құс тұмауының зооноздық және пандемиялық тәуекелдерін төмендетуге арналған шаралар. Lancet Infect. Dis. 2016, 16, 252–258.

14. *Jiao, H.U.; Liu, X.* Қытайдағы құс шаруашылығында H9N2 және H5N1 тұмау вирустарының эндемиялық болуы өндіріс пен қоғамдық денсаулыққа қауіп төндіреді. Front. Agric. Sci. Eng. 2016, 3, 11–24.

15. *Castanon, J.I.R.* Еуропалық құс жемдерінде антибиотиктердің өсімдікті жақсартқыш ретінде қолданылу тарихы. Poult. Sci. 2007, 86, 2466–2471.

**Авторлар туралы мәлімет**


| | |
|---|---|
| Сакыпбекова Меруерт Жумабековна | Сақыпбекова Меруерт Жұмабекқызы, PhD, әл-Фараби атындағы Қазақ ұлттық университетінің доцентінің міндетін атқарушы, Халықаралық инженерлік-технологиялық университеттің «Бағдарламалық инженерия» кафедрасының меңгерушісі, Алматы қ., Қазақстан. E-mail: sakypbekova.meruyert@gmail.com |
| Камбаров Дастан Берикович | Докторант, Әл-Фараби атындағы Қазақ ұлттық университеті, Мамандағы: 8D07109 – Автоматтандыру және Интернет заттары, Алматы, Қазақстан.E-mail: kambarov.dastan@mail.ru |

| | |
|---|---|
| Қатысу формасы | Қашықтықтан келмей қатысу(заочная) |
| Тақырыбы | Құс ауруларының клиникалық белгілерін ерте анықтаудағы зерттеу үрдістерінің дамуы |
| Баяндама формасы | секциялық |
| e-mail | kambarov.dastan@mail.ru |

# What Imbalance Machinery Is Worth on Cardiotocography Data: A Seven-Way Benchmark with Fixed Seeds

*Alikhan Amirkhanov[1]*, Saltanat Adilzhanova[2], Bauyrzhan Amirkhanov[1], Yanwei Fu[3], Yenlik Faruzkyzy[1]*

e-mail: alikhan.amirkhan@gmail.com; ORCID: 0009-0003-3708-3153

(*corresponding author)

[1] *Al-Farabi Kazakh National University, Almaty, Kazakhstan; ORCID: 0000-0002-4915-0347 (B. Amirkhanov), 0009-0001-1030-8266 (Y. Faruzkyzy)*

[2] *Almaty Technological University, Faculty of Information Technology, Department of Computer Engineering, Almaty, Kazakhstan; ORCID: 0000-0003-1768-064X*

[3] *School of Data Science, Fudan University, Shanghai, China; ORCID: 0000-0002-6595-6893*

***Abstract.*** *Cardiotocography (CTG) is the default method of fetal monitoring, but reading CTG traces by eye is unreliable: observer agreement is poor, worst of all for the ambiguous suspect category. Automating the split of CTG records into normal, suspect and pathologic classes could strengthen decision support, if the system stops missing the pathologic class. The difficulty is that pathologic records are rare, 176 of 2,126 (8.3%) in the public UCI CTG dataset, and rare-but-critical classes are the norm in medical diagnostics. We benchmark seven setups on this dataset (2,126 records, 21 numeric features): logistic regression, random forest and gradient-boosted trees, with and without imbalance correction (class weighting or SMOTE). The protocol is fixed before the test split is opened: one stratified 80/20 split, five-fold cross-validation on training data only, exact McNemar tests, 2,000-sample bootstrap confidence intervals, SHAP attribution, and a controlled noise probe as a stand-in for degraded recordings. Gradient-boosted trees performed best: macro-F1 0.907 (95% CI 0.862-0.943), pathologic recall 0.914 (95% CI 0.813-1.00), Cohen's kappa 0.862. Imbalance correction moved outcomes only for the linear model, not the tree ensembles. The strongest SHAP drivers, short-term variability and mean fetal heart rate, are the quantities the FIGO criteria act on. Noise cost accuracy gradually: at 0.2 feature standard deviations macro-F1 had lost about 9%. Code, artifacts and fixed seeds are released for exact reproduction.*

*Keywords: cardiotocography; fetal heart rate; class imbalance; gradient boosting; SHAP; reproducible benchmark; clinical decision support.*

## 1. Introduction

Cardiotocography (CTG) records the fetal heart rate (FHR) and uterine contraction activity at the same time, and it is the standard instrument of fetal monitoring in obstetric practice [1,2]. The usual way to read a CTG is visual inspection, and studies going back decades report low agreement between observers, with the "suspicious" category the least reproducible of all [1,3]. Supervised classifiers applied to CTG records could supply a second, consistent reading.

What makes the classification problem awkward is the error structure, not its difficulty. A missed pathologic record carries real clinical cost, while a false alarm mostly buys extra observation. Meanwhile the class distribution is badly skewed: pathologic records are 8.3% of the public UCI CTG dataset. Skew plus asymmetric cost is the standard situation in medical diagnostics and the one most textbook benchmarks omit [4,5].

We treat CTG classification as a small, honest testbed for this situation and ask what imbalance machinery is actually worth once a modern learner is in the loop. Three follow-up questions: which features drive the best model according to SHAP attributions [6], whether that matches what obstetric guidelines consider decisive, and how the models behave when noise is added to the inputs as a proxy for degraded recordings. The protocol (fixed seeds, one

test split opened only at the end, exact tests, bootstrap intervals [7,8]) was written before the test split was touched, and all code ships with the paper.

## 2. Materials and Methods

### 2.1 Dataset and preprocessing

The UCI Cardiotocography dataset [9] (CC BY 4.0) holds 2,126 fetal cardiotocograms processed by the SisPorto 2.0 analysis system [17]. Each record carries 21 numeric features: per-second rates for FHR and uterine contractions (LB, AC, FM, UC, DL, DS, DP), variability measures (ASTV, MSTV, ALTV, MLTV), and histogram summaries of the FHR signal (Width, Min, Max, Nmax, Nzeros, Mode, Mean, Median, Variance, Tendency). Three obstetricians classified every record and a consensus label was recorded for fetal state (NSP: normal, suspect, pathologic) under the FIGO framework [2]. We kept all 2,126 labelled records; the class counts are 1,655 / 295 / 176, roughly 1 : 0.18 : 0.11. No values are missing and no feature is constant, so median imputation never fired. The extra label fields CLASS (a 10-class morphologic code) and SUSP overlap with the target and were dropped. Within each pipeline, features are standardised on training folds only, so nothing crosses the split.

### 2.2 Models

Three model families, each with and without an imbalance mechanism, give seven configurations: multinomial logistic regression with L2 penalty and balanced class weights (LR+CW); random forest with 500 trees and balanced weights (RF+CW) [10,11]; XGBoost (400 rounds, depth 6, lr 0.1, subsample 0.9, column subsample 0.9) [12] plain (XGB) and with frequency- inverse class weights (XGB+CW); and SMOTE [13] ($k = 3$) in front of each family (SMOTE+LR, SMOTE+RF, SMOTE+XGB). Hyperparameters sit at published defaults on purpose. There is no tuning anywhere, so "which technique helps" is not confounded with "which grid search won".

### 2.3 Evaluation protocol

One stratified 80/20 split (seed 42) gives 1,700 training and 426 test records. Model selection used stratified five-fold cross-validation inside the training part; the test split was opened once, at the end. Primary metric is macro-F1, chosen because class frequencies differ by an order of magnitude; we also report pathologic-class recall and precision (the pair the clinic actually cares about), balanced accuracy, and Cohen's kappa [14]. The best model gets 2,000-replicate stratified bootstrap 95% confidence intervals [8]. Per-class agreement against the baseline (LR+CW) goes through the exact-binomial McNemar test [7], with per-class correctness as the 2x2 table. For the noise probe we add Gaussian noise at (0.05, 0.1, 0.2) of each feature's standard deviation to the test features and score the frozen model, 5 draws. SHAP values come from TreeExplainer [6]; we report mean absolute attribution for the pathologic-class output on the test set.

Software: Python 3.13, scikit-learn 1.x, imbalanced-learn, XGBoost, SHAP, matplotlib. All randomness controlled by seed 42; code, CSV artifacts and figure scripts accompany the submission.

## 3. Results

### 3.1 Cross-validation and held-out performance

Cross-validation on the training part put gradient boosting first (XGB: macro-F1 0.928, pathologic recall 0.936), with random forest next (RF+CW: 0.903 / 0.922) and the linear model well behind (LR+CW: 0.788 / 0.872). On the test split (Table 1), XGB landed at macro-F1 0.907 (95% bootstrap CI 0.862-0.943), pathologic recall 0.914 (CI 0.813-1.00), precision 0.889, balanced accuracy 0.898, kappa 0.862. Adding class weights changed nothing: XGB+CW gives byte-identical predictions, presumably because the trees already separated the classes and the weights had no pressure point to act on. SMOTE moved the linear model (0.774 to 0.784 macro-F1) and did nothing good for the ensembles (XGB 0.907

to SMOTE+XGB 0.895). That asymmetry is on the record in the imbalance literature: synthetic points help learners that need boundary nudging [5]. Tree ensembles on 21 tabular features apparently do not.

| Model | Macro-F1 | Recall path. | Prec. path. | Bal. acc. | Kappa |
|---|---|---|---|---|---|
| XGB | 0.907 | 0.914 | 0.889 | 0.898 | 0.862 |
| XGB+CW | 0.907 | 0.914 | 0.889 | 0.898 | 0.862 |
| SMOTE+XGB | 0.895 | 0.914 | 0.865 | 0.886 | 0.849 |
| RF+CW | 0.889 | 0.914 | 0.889 | 0.900 | 0.824 |
| SMOTE+RF | 0.880 | 0.886 | 0.886 | 0.882 | 0.821 |
| SMOTE+LR | 0.784 | 0.829 | 0.707 | 0.842 | 0.686 |
| LR+CW | 0.774 | 0.800 | 0.700 | 0.835 | 0.674 |

Table 1. Held-out test performance (426 records); models sorted by macro-F1.

### 3.2 Statistical comparison

Every tree configuration beat LR+CW on the Normal class at McNemar $p < 0.001$; the test has plenty of discordant pairs there, since 332 of the 426 test records are Normal. The pathologic class tells the other half of the story: p ranges from 0.29 to 1.0 across the same comparisons. With 35 pathologic records, one extra caught or missed case moves recall by 3 points, and the test simply lacks the pairs to resolve 0.80 against 0.91. The ranking recurs in CV, on test, and under bootstrap, so we read it as a directional signal, not a demonstrated improvement.

### 3.3 Explainability

For the pathologic class the largest mean |SHAP| values go to ASTV, the share of time with abnormal short-term variability (1.32), then histogram mean (0.87) and median (0.54) of the FHR; behind them ALTV (0.47), Variance (0.47), UC (0.47) and baseline LB (0.37); Fig. 2 plots the full distributions. Short-term variability collapsing toward zero, with an abnormal baseline, is exactly how FIGO defines a non-reassuring trace [2], so the model keys on the same quantities the guidelines act on. Agreement here is reassuring in the everyday sense, not proof of anything: SHAP reports what the model uses, not what causes fetal distress.

### 3.4 Noise robustness

Table 2 gives the noise sweep. At 0.10 sigma, macro-F1 goes 0.907 to 0.881 and pathologic recall 0.914 to 0.880; at 0.20 sigma, 0.825 and 0.817. Roughly 9% relative accuracy lost for noise at a fifth of the feature the classifier just gets duller. That is the behaviour you would want before believing it across two monitoring devices with different signal floors.

| Noise sigma | Macro-F1 | Recall path. |
|---|---|---|
| 0.00 | 0.907 | 0.914 |
| 0.05 | 0.897 | 0.903 |
| 0.10 | 0.881 | 0.880 |
| 0.20 | 0.825 | 0.817 |

Table 2. Noise robustness of the best model (mean over 5 replicates).

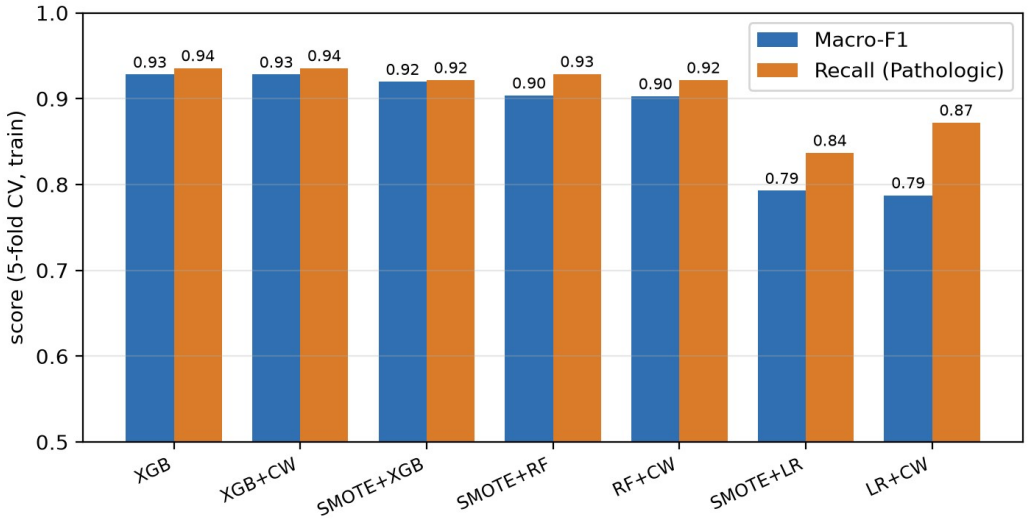



Fig. 1. Five-fold cross-validation on the training set, by model configuration.

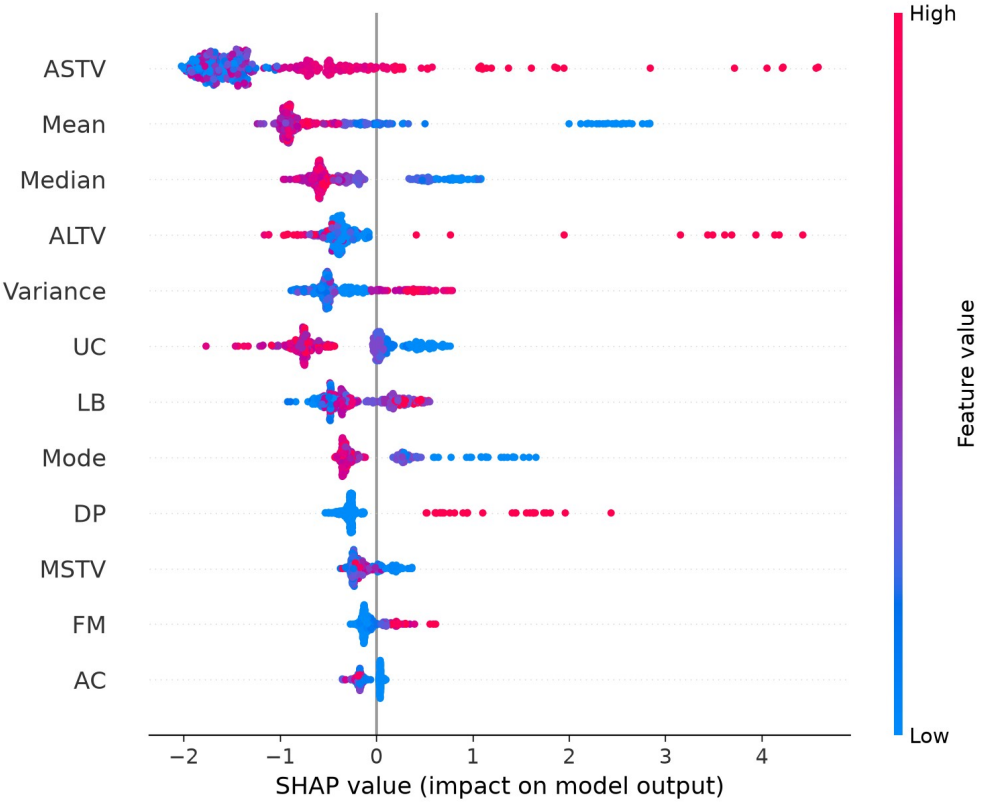



Fig. 2. SHAP summary (pathologic class) for XGBoost on the test set.

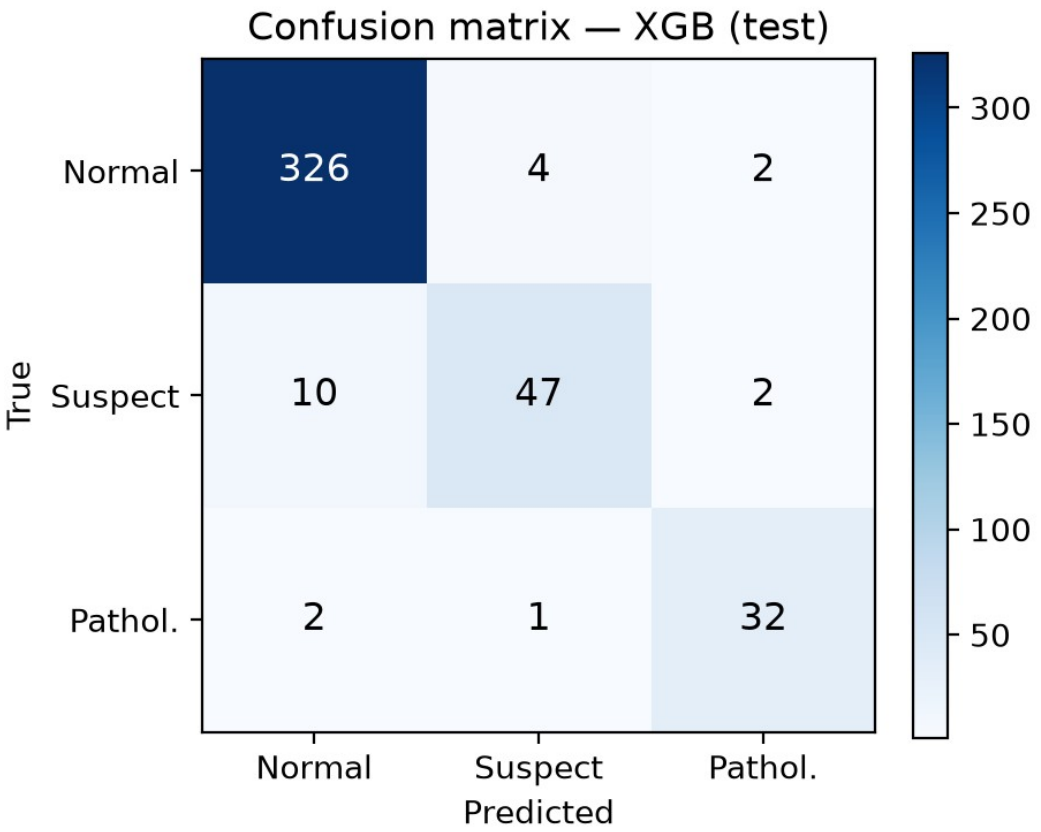



Fig. 3. Confusion matrix of XGBoost on the test split.

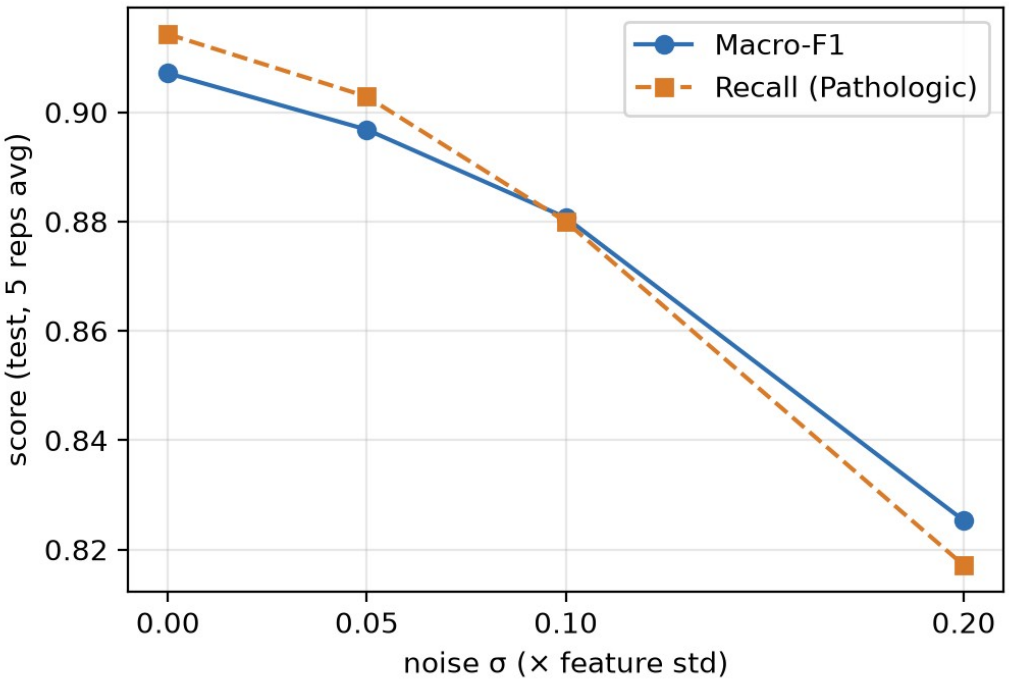



Fig. 4. Macro-F1 and pathologic recall under additive Gaussian noise.

**4. Discussion**

If you take one number from this paper, take the 0.13. That is the macro-F1 gap between a linear model and a gradient-boosted one on the same 21 features, and it dwarfs anything the imbalance machinery buys: class weights change nothing for XGBoost, SMOTE

shaves points off both ensembles, and only the logistic model gains from them. So on pre-extracted CTG features the productive choice is the model family, not the sampling trick, which tracks the broader tabular-data literature [12,15]. The other number worth keeping is the baseline's pathologic recall of 0.80 with 21 linear coefficients: where a regulator insists on a model you can audit line by line, a weighted logistic regression is no longer the obvious sacrifice.

Two limits matter most. First, the dataset is one corpus from one analysis pipeline (SisPorto 2.0) [17]; the features inherit that pipeline's decisions, and nothing here separates a clinical finding from a SisPorto artefact. Second, 35 pathologic records cannot support confident ranking of models on the class that matters, and the bootstrap CI (0.81-1.00) is as wide as it is because that is the true precision of the claim. Labels from three-expert consensus also carry their own noise. A real evaluation needs raw waveforms, several devices, and reading rules fixed in advance.

Next steps follow from those limits: run the same protocol on raw waveforms (1-D CNN or temporal transformer) and see how much of the feature-table performance survives; calibrate or conformal-ise the probabilities [16] so a threshold can mean something; test device transfer directly, with the noise probe as the cheap version; and replicate on PhysioNet CTU-USB and the Ningbo CTG set.

## 5. Conclusion

A seven-way comparison of classifiers and imbalance corrections on the UCI CTG records, under one fixed protocol, says: pick the tree ensemble, skip the oversampling, and hold your recall claims until the minority class is big enough to measure. XGBoost reports macro-F1 0.907 (95% CI 0.862-0.943) with pathologic recall 0.914 (CI 0.813-1.00); its SHAP drivers match FIGO criteria; and it stays useful under input noise. Everything needed to reproduce the numbers, the tests and the figures (code, fixed seeds, CSV artifacts) accompanies the submission.

Reproducibility: exp1_ctg.py (main experiment), figs_extra.py (figures), results/metrics.json, tables/*.csv. Fixed seed 42 throughout. Generated: September 2026.

## References

1. Westgate, J., et al.: The intrapartum cardiotocograph (CTG): a reassessment. Best Pract. Res. Clin. Obstet. Gynaecol. 17(6), 957-971 (2003).

2. Ayres-de-Campos, D., et al. (FIGO): FIGO intrapartum fetal monitoring recommendations. Int. J. Gynecol. Obstet. 146(3), 261-275 (2019).

3. Mantel, R.E., et al.: Visual analysis of antepartum fetal heart rate CTG. Eur. J. Obstet. Gynecol. Reprod. Biol. 48(2), 125-127 (1993).

4. Johnson, J.M., Khoshgoftaar, T.M.: Survey on deep learning with class imbalance. J. Big Data 6, 26 (2019).

5. Branco, P., Torgo, L., Ribeiro, R.P.: A survey of predictive modeling on imbalanced domains. ACM Comput. Surv. 49(2), 31 (2016).

6. Lundberg, S.M., Lee, S.-I.: A unified approach to interpreting model predictions. In: NeurIPS 2017, pp. 4765-4774 (2017).

7. McNemar, Q.: Note on the sampling error of the difference between correlated proportions or percentages. Psychometrika 12(2), 153-157 (1947).

8. Efron, B., Tibshirani, R.J.: An Introduction to the Bootstrap. Chapman & Hall (1993).

9. Campos, D.A., Bernardes, J.: Cardiotocography dataset (SisPorto 2.0 feature extraction). UCI Machine Learning Repository, DOI 10.24432/C51S4N (donated 2010).

10. Breiman, L.: Random forests. Machine Learning 45(1), 5-32 (2001).

11. Ho, T.: Random decision forests. In: ICDAR 1995, pp. 278-282 (1995).

12. Chen, T., Guestrin, C.: XGBoost: a scalable tree boosting system. In: KDD 2016, pp. 785-794 (2016).

13. Chawla, N.V., Bowyer, K.W., Hall, L.O., Kegelmeyer, W.P.: SMOTE: synthetic minority over-sampling technique. J. Artif. Intell. Res. 16, 321-357 (2002).

14. Cohen, J.: A coefficient of agreement for nominal scales. Educ. Psychol. Meas. 20(1), 37-46 (1960).

15. Grinsztajn, L., Oyallon, E., Varoquaux, G.: Why do tree-based models still outperform deep learning on tabular data? In: NeurIPS 2022 (2022).

16. Guo, C., Pleiss, G., Sun, Y., Weinberger, K.Q.: On calibration of modern neural networks. In: ICML 2017, pp. 1321-1330 (2017).

17. Ayres de Campos, D., et al.: SisPorto 2.0 — a program for automated analysis of cardiotocograms. J. Matern. Fetal Med. 5, 311-318 (2000).

# A COMPUTER VISION SYSTEM THAT PROCESSES AERIAL IMAGES FOR IDENTIFYING THE VEGETATIVE HEALTH STATES OF CROP FIELDS

K.R. Aida-zade[1,2], Rustam Azimov[1,3], Ioannis Faraslis[4], Efthimios Providas[4]
e-mail: rustemazimov1999@gmail.com
[1]*Institute of Mathematics, Azerbaijan*
[2]*Azerbaijan University of Architecture and Construction, Azerbaijan*
[3]*Baku Engineering University, Azerbaijan*
[4]*University of Thessaly, Greece*

***Abstract.*** *A complex processing approach is proposed for a health monitoring system based on multispectral data obtained through imagery of target plants in crop fields. The approach involves segmenting an aerial multispectral image according to target plant regions, followed by estimating vegetative health states over those segments using the proposed approach. The effectiveness of the proposed approach was evaluated on multispectral imagery of apple orchards, and the dynamics of health state indicators over two field experiments conducted forty days apart were analyzed. Health state estimation was performed using values of vegetation indices calculated by processing the multispectral aerial images obtained by a UAV.*

***Keywords****: health state estimation, multispectral image processing, remote sensing, machine learning.*

## 1. INTRODUCTION

The study addresses the assessment of vegetative health of crop fields based on processing multispectral aerial images obtained through remote sensing using UAVs. The multispectral camera captures green, red, red edge, and near-infrared spectral bands. Since UAVs (see Figure 1) allow low-altitude flight, each pixel in the resulting orthophoto represents a small geographic area (1 cm² per pixel), enabling high-precision quantitative analyses.

The health monitoring system developed in the study performs two main functions: segmentation of the multispectral crop field image according to target plants, and determination of health state indicator values based on the pixel values of the identified target plant segments. An algorithm for assessing vegetative health and calculating overall field health indicators is proposed, and its results are analyzed on aerial multispectral data of three apple orchards in Greece.

## 2. IMAGE SEGMENTATION APPROACHES USED FOR TARGET PLANT SEGMENT DETECTION

Segmenting the image of a given crop field according to target plants is a prerequisite for adequate health monitoring [1–5]. Three approaches were compared on the example of apple orchards. In threshold-based unsupervised segmentation, pixels satisfying predefined conditions on the DSM, NDSM, NDRE, and NDMI channels are attributed to target plant segments. Since boundary threshold values cannot be selected a priori, they were determined heuristically; however, no satisfactory segmentation result was obtained with this approach. Clustering-based unsupervised segmentation using K-means with three clusters on DSM and full multispectral data also yielded unsatisfactory results, as tree canopies could not be reliably separated from other objects.



a. UAV and the multispectral camera



b. A photo from the field survey

Figure 1.Some photos from the field works

Supervised segmentation using a trained Convolutional Neural Network proved considerably more effective in the study. The model segments fixed-size patches extracted from the full image, and the partial segmentation masks are subsequently merged into a complete result (see Fig. 2 and Fig. 3). Five model configurations were evaluated, differing in patch (kernel) size, stride, and augmentation strategy. Random augmentation did not improve performance, whereas deterministic augmentation raised precision substantially. Reducing the patch size from 64×64 to 4×4 pixels significantly improved recall, and training exclusively on young (smaller) trees further raised recall to 71%, subsequently brought to 96% by applying a morphological dilation post-processing step.

## 3. HEALTH STATE ESTIMATION OF TARGET PLANT SEGMENT PIXELS

The proposed algorithm assesses vegetative health using ten vegetation indices computed from multispectral data (DVI, GDVI, GNDVI, GRVI, NDVI, NDRE, NG, NR, NNIR, RVI), which are normalized to the range [0, 1] prior to analysis. The health state of each target plant pixel is determined by computing its z-score relative to the mean and standard deviation of index values across all target plant pixels in the image [5]. Pixels falling in the interval (−1, 1) are classified as healthy-neutral; those in (1, 2) and (2, 3) as slightly healthy and moderately healthy; those beyond 3 as very healthy; and the corresponding negative intervals as slightly, moderately, and very unhealthy, respectively, as it was depicted in Fig. 4.

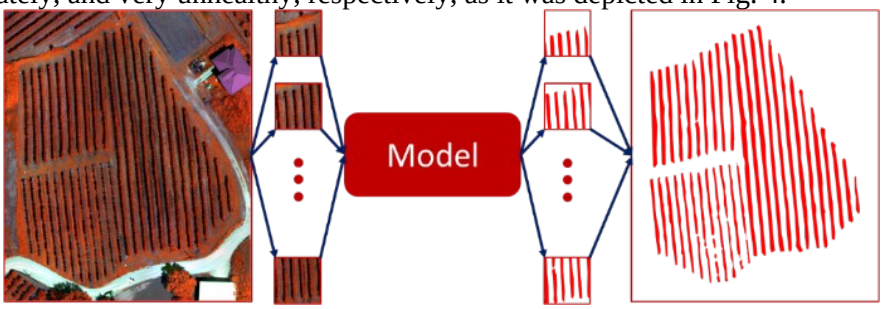



Figure 2. Prediction procedure

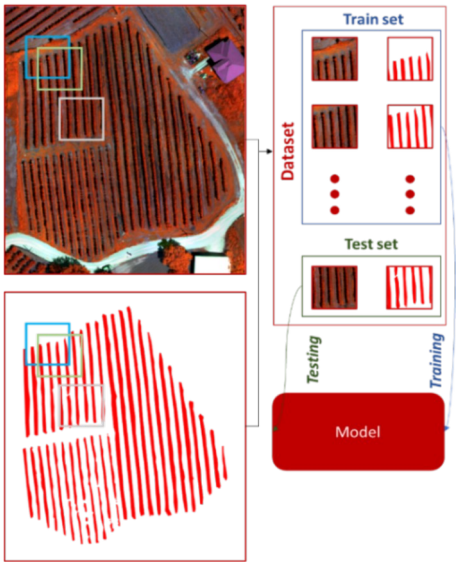



Figure 3. Training procedure

Three overall field health indicators are defined: the mean normalized index value across target plant pixels (Criterion I); the weighted mean in which each pixel's index value is scaled by its health state score (Criterion II); and the modal health state among all target plant pixels (Criterion III). In both field experiments and across all three orchards, Criterion III returned a value of "slightly healthy" for all ten vegetation indices. Indices such as DVI, GDVI, GNDVI, and NDVI showed a increasing trend between the two field experiments, indicating an improvement in vegetative activity over the forty-day interval, particularly in Orchards I and II.

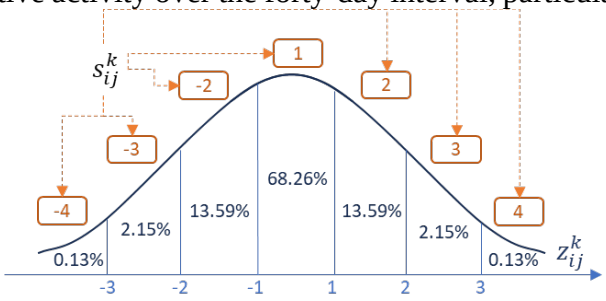
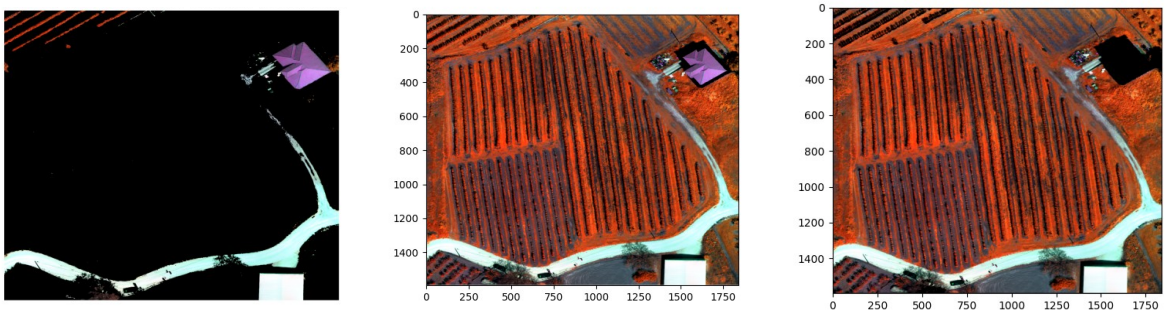



Figure 4. Proportions of health states

## 4. COMPUTER EXPERIMENTS

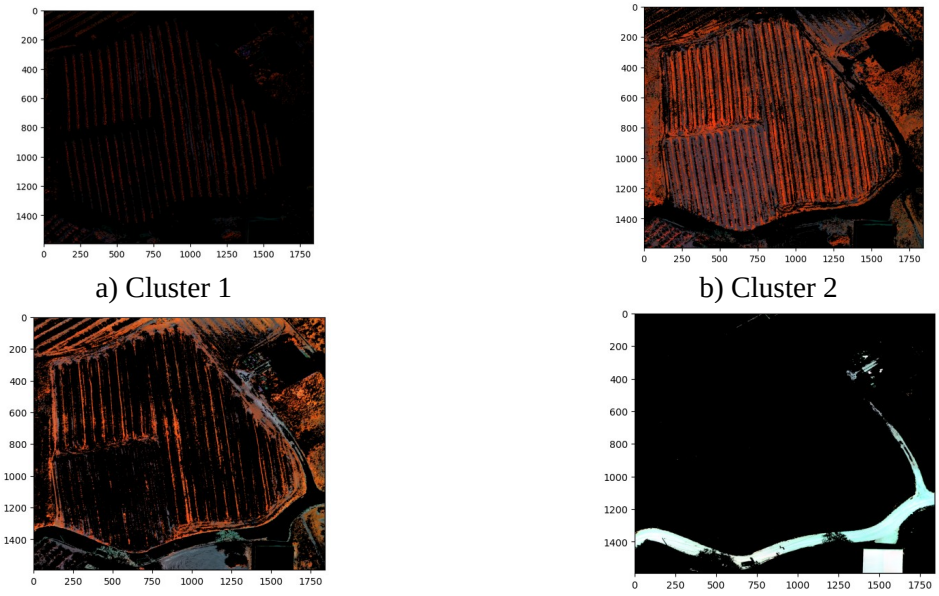
Some segmentation results of pixel value thresholding is given in Fig. 5. Results when using k-means clustering were given in Fig. 6. Finally results of CNN with autoencoder architecture were given in Fig. 7.

In Fig. 7 and Fig. 8 results of health state determination were given.




a) Condition 1 on NDSM b) Condition 2 on NDSM c) Condition 3 on NDSM

Figure 5. Results of segmentation using heuristical conditions



a) Cluster 1 b) Cluster 2

c) Cluster 3 d) Cluster 4

Figure 6. Results of segmentation using k-means clustering

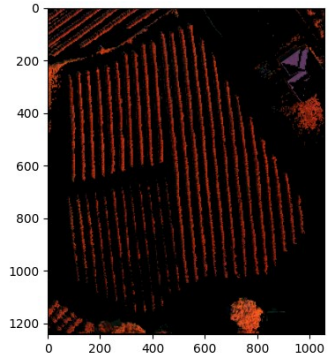
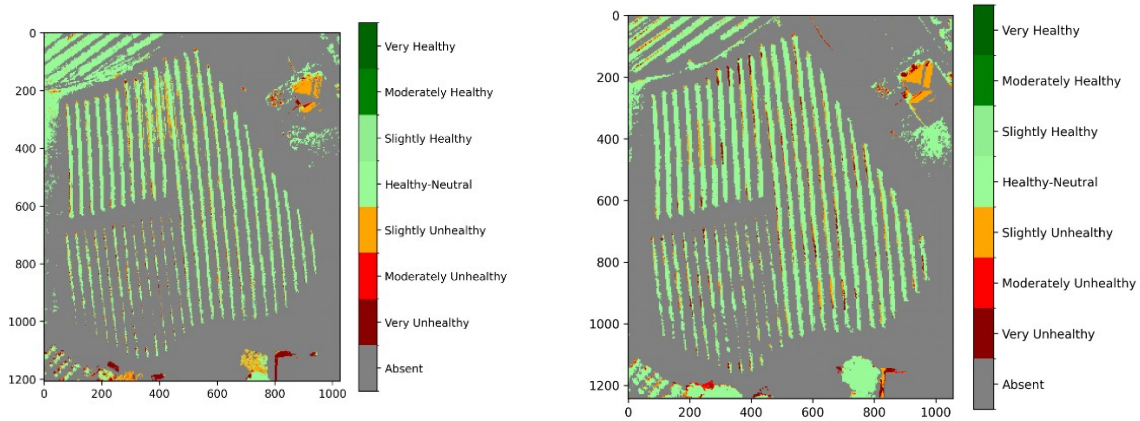


Figure 7. Results of segmentation using using CNN




a) Health states on the I field survey b) Health states on the II field survey

Figure 8. Visualizations of the obtained health states

## 5. CONCLUSION

Approaches for assessing the vegetative health of crop fields using multispectral aerial images obtained with UAVs were proposed and evaluated. For target plant segmentation, instance-based deep learning with small patch sizes and training on young trees achieved the best performance. For health state assessment, a z-score-based classification of normalized vegetation index values was applied, and three complementary overall health indicators were calculated. The proposed complex processing approach was demonstrated on multispectral data from two field experiments on three apple orchards and can be extended to the health monitoring of other crop types.

## REFERENCES

1. Zualkernan, I. Machine learning for precision agriculture using imagery from unmanned aerial vehicles (UAVs): A survey / I. Zualkernan, D. A. Abuhani, M. H. Hussain, J. Khan, M. ElMohandes // Drones. – 2023. – Vol. 7, N. 6. – P. 382.
2. Jemaa, H. UAV-based computer vision system for orchard apple tree detection and health assessment / H. Jemaa, W. Bouachir, B. Leblon, A. LaRocque, A. Haddadi, N. Bouguila // Remote Sensing. – 2023. – Vol. 15, N. 14. – P. 3558.
3. Jemaa, H. Computer vision system for detecting orchard trees from UAV images / H. Jemaa, W. Bouachir, B. Leblon, N. Bouguila // Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. – 2022. – Vol. XLIII-B4-2022. – P. 661–668. – https://doi.org/10.5194/isprs-archives-XLIII-B4-2022-661-2022
4. Zhang, W. Automatic Instance Segmentation of Orchard Canopy in Unmanned Aerial Vehicle Imagery Using Deep Learning / W. Zhang, X. Chen, J. Qi, S. Yang // Front. Plant Sci. – 2022. – Vol. 13. – P. 1041791. – https://doi.org/10.3389/fpls.2022.1041791
5. Şandric, I. Tree's detection and health's assessment from ultra-high resolution UAV imagery and deep learning / I. Şandric [et al.] // Geocarto International. – 2022. – Vol. 37, N. 25. – P. 10459–10479.

# ANALYSIS OF SOME TEXT FEATURES IN THE EXAMPLE OF RECOGNIZING THE AUTHORS OF LITERARY FICTIONS

K.R. Aida-zade[1,2], Elshan Mustafayev[1], Rustam Azimov[1,3]
e-mail: rustemazimov1999@gmail.com
[1]*Institute of Mathematics, Azerbaijan*
[2]*Azerbaijan University of Architecture and Construction, Azerbaijan*
[3]*Baku Engineering University, Azerbaijan*

***Abstract.*** *The study investigates the effectiveness of combining several machine learning methods — namely random forest, support vector machine, and multilayer feedforward artificial neural network — with feature-selection procedures applied to five types of text features, intended to develop algorithms and software for attributing authorship to texts for the purpose of use in a computer system. A feature-selection procedure based on the degree to which character n-gram features characterize individual authors, as formally defined in this study, is proposed and compared with several established feature-selection procedures. Computer experiments were conducted on Azerbaijani-language literary texts of varying scales, and the comparative results are analyzed and discussed.*

***Keywords****: authorship recognition, recognition of literary texts, text features, machine learning.*

## 1. INTRODUCTION

The issue of recognizing the text authors was considered on the example of texts of small and large-scale works of fiction literacy in the Azerbaijani language in the study.

The studies are being done on recognizing authorship of texts differs in terms of the types of text features used, indicators of text genre and volume, language, authorship identification approach used, and so on [1–3].

In the study, a comparative study of the use of 5 different types of text features and 4 feature selection procedures combined with multilayer feedforward artificial neural network, random forest, support vector machine and for recognizing author was conducted on an example of Azerbaijani texts. A feature selection procedure based on the degree of characterizing the authors of the character n-grams was proposed and its effectiveness was analyzed based on the conducted computer experiments results on the example of the considered author recognition problem.

## 2. TEXT FEATURE SELECTION

In the study, the following features were used: character n-gram frequency [Talibov], word length frequency [4], sentence length frequency [5], character n-gram frequency dispersion [5], and word frequency [6].

The procedures for selecting text features were implemented in the study based on texts with known authors in the training set, and their effectiveness was analyzed on the test set. Of the 4 feature selection procedures compared in the study based on the results of computer experiments, 2 are considered for selecting word frequency features, and the other 2 are considered for selecting character n-gram frequency features. We will conventionally call the word selection procedures procedures 1, 2, and the character n-gram selection procedures procedures 3, 4. In procedures 1 and 2, a fixed number of the most frequently used words from each author's lexicon are selected to construct two sets: a composite set consisting of words that dominate across the authors' lexicons, and a set of words that are frequently used in the training dataset as a whole. In procedures 3 and 4, a set of character n-grams frequently used in the training set in general and a set of character n-grams with different degrees of characterization of the authors in the meaning given in the study are created. The fourth procedure is proposed in the study, and its mathematical description is given below.

Using a procedure for selecting character n-grams with varying degrees of author characterization, the degrees of author non-characterization of a given character n-gram (in the

sense defined below) are first determined. Based on these non-characterization degrees, their complement – the degrees of characterization – is then derived. Subsequently, a metric indicating the extent to which the characterization degrees of the authors differ from one another (in one of the senses defined below) is computed. Various formulas for calculating this metric are proposed in the study.

A character n-gram is any given combination of a given $n$ ($n = 1, 2, ...$) characters [1]. For a given $n$, let us denote the set of character alphabet from which the characters in any character n-gram are selected, i.e. the set of all character 1-grams by $\alpha^1 = \{\alpha_k : \ k = 1, \ 2, ..., m\}$, where $m = \left|\alpha^1\right|$ is the number of characters.

An arbitrary $\hat{i}_m^n$ multi-indexed character n-gram $\alpha_{\hat{i}_m^n} = \left(\alpha_{i_1}, ..., \alpha_{i_n}\right)$ whose characters are chosen from the character alphabet set $\alpha^1$ will be used. Then the notation $\hat{i}_m^n$ will be used for the multi-index of $n$ dimensions $\hat{i}_m^n = (i_1, ..., i_n)$. Here, each of the indices $i_v, \ v = 1, \ 2, ..., n,$ can take values from the given set $\{1, 2, ..., m\}$, i.e. $1 \le i_v \le m, \quad v = 1, \ 2, ..., n$. Let us denote the set of all character n-grams as follows:

$$\alpha^n = \left\{\alpha_{\hat{i}_m^n} : \ 1 \le i_v \le m, \quad v = 1, \ 2, ..., n, \quad m = \left|\alpha^1\right|\right\}.$$

The degree of non-characterization $d_{\hat{i}_m^n}^i$ of an arbitrary character n-gram $\alpha_{\hat{i}_m^n} \in \alpha^n$ for a given author $i$ is defined as the average degree of variation, i.e., the arithmetic mean of the pairwise squared differences of the corresponding frequencies $f_{j\hat{i}_m^n}^i, \ j = 1, 2, ..., \left|T^i\right|$, computed over the texts $T_j^i, \ j = 1, 2, ..., \left|T^i\right|$ in the training set belonging to that author:

$$d_{\hat{i}_m^n}^i = \frac{1}{\frac{\left(|T^i|\right)^2}{2}} \sum_{j_1=1}^{|T^i|} \sum_{j_2=1}^{\frac{|T^i|}{2}} \left(f_{j_1\hat{i}_m^n}^i - f_{j_2\hat{i}_m^n}^i\right)^2,$$

here, $f_{j_1\hat{i}_m^n}^i, \ f_{j_2\hat{i}_m^n}^i$ denote the frequencies of the character n-gram $\alpha_{\hat{i}_m^n}$ in the $j_1$-th and $j_2$-th texts of author $i$, respectively, where $i = 1, 2, ..., L$. Since for any $\alpha_{\hat{i}_m^n} \in \alpha^n$ and any text $T_j^i$, it holds that $0 \le f_{j\hat{i}_m^n}^i \le 1$, it follows that $0 \le d_{\hat{i}_m^n}^i \le 1$. Then the characterization degree of an arbitrary character n-gram $\alpha_{\hat{i}_m^n} \in \alpha^n$ for a given author $i$ will be defined as $\dot{d}_{\hat{i}_m^n}^i = 1 - d_{\hat{i}_m^n}^i$.

For an arbitrary character n-gram $\alpha_{\hat{i}_m^n} \in \alpha^n$, by arranging the characterization degrees $\dot{d}_{\hat{i}_m^n}^i$ for authors indexed $i = 1, \ 2, \ ..., \ L$, in descending order (this ordering corresponds to ranking authors from the best characterized to the least characterized by the given character n-gram), we obtain $\dot{d}_{\hat{i}_m^n}^{i_1^*} \ge ... \ge \dot{d}_{\hat{i}_m^n}^{i_L^*}$, where $1 \le i_k^* \le L, \quad k = 1, 2, ..., L$.

The degree of discrimination among the characterization values $\dot{d}_{\hat{i}_m^n}^i, \ \ i = 1, 2, ..., L,$ for the authors would be determined as the following one:

$$\dot{\phi}_{\hat{i}_m^n}^{41} = \left(\dot{d}_{\hat{i}_m^n}^{i_1^*} - \dot{d}_{\hat{i}_m^n}^{i_2^*}\right)^2, \tag{1}$$

$$\dot{\phi}_{\hat{i}_m^n}^{42} = \frac{1}{2}\left[\left(\dot{d}_{\hat{i}_m^n}^{i_1^*} - \dot{d}_{\hat{i}_m^n}^{i_2^*}\right)^2 + \left(\dot{d}_{\hat{i}_m^n}^{i_2^*} - \dot{d}_{\hat{i}_m^n}^{i_3^*}\right)^2\right], \tag{2}$$

$$\dot{\phi}_{\hat{i}_m^n}^{43} = \frac{1}{L-1} \sum_{k=1}^{L-1} \left(\dot{d}_{\hat{i}_m^n}^{i_k} - \dot{d}_{\hat{i}_m^n}^{i_{k+1}}\right)^2, \tag{3}$$

here, $\dot{d}_{\hat{i}_m^n}^i, \ \ i = 1, 2, ..., L,$ represent the characterization degrees of authors by the character n-gram $\alpha_{\hat{i}_m^n}$, ordered toward the author that is best characterized by this n-gram; $\dot{\phi}_{\hat{i}_m^n}^{41}$, $\dot{\phi}_{\hat{i}_m^n}^{42}$ and $\dot{\phi}_{\hat{i}_m^n}^{43}$ denote the discrimination metrics of the characterization degrees of authors

for the character n-gram $\alpha_{\hat{i}_m^n}$. In the computation of $\dot{\phi}_{\hat{i}_m^n}^{41}$, $\dot{\phi}_{\hat{i}_m^n}^{42}$ and $\dot{\phi}_{\hat{i}_m^n}^{43}$, respectively, $2,\ 3,\ \dots,\ L$, authors best characterized by $\alpha_{\hat{i}_m^n}$ are taken into account.

Metrics $\phi_{\hat{i}_m^n}^{4} \in \left\{\dot{\phi}_{\hat{i}_m^n}^{4l} : \ l = 1,2,3\right\}$ can be used as an indicator of the degree of discrimination of the authors of n-grams .

The ordered set $\dot{\alpha}^n$ is obtained by sorting all character n-grams in the set $\alpha^n$ in descending order according to the decreasing values of their discrimination metrics of authors' characterization degrees, as follows:

$$\dot{\alpha}^n = \left\{\alpha_{\hat{i}_m^{nj}} : \phi_{\hat{i}_m^{n1}}^4 \geq \dots \geq \phi_{\hat{i}_m^{n|\alpha^n|}}^4,\ \ \hat{i}_m^{nj} = \left(i_1^j, \dots, i_n^j\right),\ \ 1 \leq i_m^j \leq m,\ \ v = 1,2,\dots,n,\ \ m = \left|\alpha^1\right|,\ \ j = 1,2,\dots,|\alpha^n|\right\}$$

Here, $\hat{i}_m^{nj}$ is the multi-index of an arbitrary character n-gram $\alpha_{\hat{i}_m^{nj}}$ belonging to the set $\alpha^n$, where $\hat{i}_m^{nj_1} \neq \hat{i}_m^{nj_2},\ \ j_1 \neq j_2,\ \ j_1, j_2 = 1,2,\dots,|\alpha^n|$.

The set of high character n-grams with a discriminative index (an indicator of the degree of characterization of authors) in the texts of the authors in the training set (among authors) $\tilde{\alpha}^n$is as follows:

$$\tilde{\alpha}^n = \left\{\alpha_{\hat{i}_m^{nj}} : \ \ \alpha_{\hat{i}_m^{nj}} \in \dot{\alpha}^n,\ \ \ j = 1,2,\dots,|\tilde{\alpha}^n|\right\}.$$

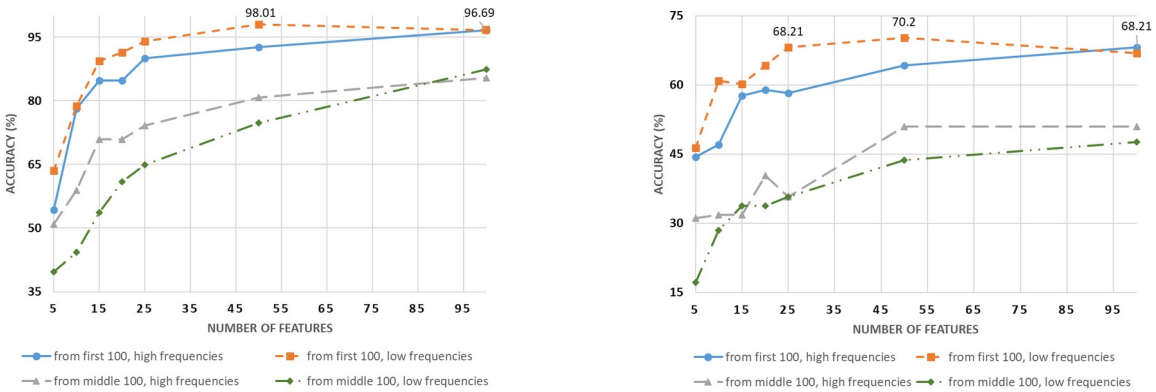
The codes for the proposed 4th feature selection algorithm is publicly available on https://github.com/rb-azimov/ccdfs.

## 3. RESULTS OF COMPUTER EXPERIMENTS

As more best-characterized authors are taken into account when computing the characterization-rate discrimination indicator (see (1)–(3)), recognition results tend to become more accurate in most cases. Using procedures 1 through 4, the highest recognition accuracies reached on the artifacts were, respectively, 96.7%, 98%, 98%, and 98%. Among the machine learning methods applied, the highest accuracies were 42.4% for ANN, and 98% each for SVM and RF.

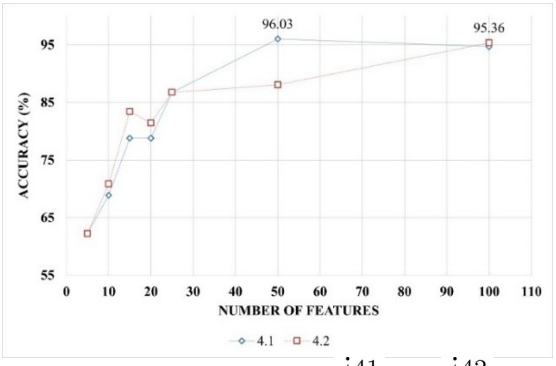
Results of using feature selection procedure 3 is given in Fig. 1.a and Fig. 1.b. Results of using feature selection procedure 4 is given in Fig. 2.a and Fig. 2.b. In both cases, recognition accuracy rises as more of the top-ranked character n-grams are added to the feature set. Fig. 2.a and Fig. 2.b suggests that averaging the discrimination indicator over a larger number of best-characterized authors produces a more robust ranking criterion than relying on the gap between only the top two authors.

In Fig. 3 results of feature selection procedure 1 and 2 is given. For procedures 1 and 2, accuracy likewise improves as more of the most frequent or most author-dominant words are added to the feature set.

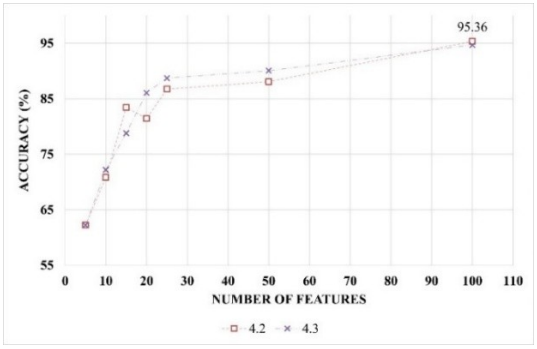



a) character n-gram frequencies b) character n-gram frequency variances

Figure 1. Recognition results on features that use character n-grams




Recognition results on $\dot{\phi}^{41}_{\hat{i}^n_m}$ and $\dot{\phi}^{42}_{\hat{i}^n_m}$




Recognition results on $\dot{\phi}^{42}_{\hat{i}^n_m}$ and $\dot{\phi}^{43}_{\hat{i}^n_m}$

Figure 2. Recognition results when using feature selection procedure 4

It can be seen from Figure 3 that the frequencies of words selected using only procedure 2 turned out to be more effective in recognition than the frequencies of words selected using only procedure 1. Recognition accuracy increased when selecting words by manually removing some words—words used in everyday life, names of characters in literature works, and so on from among the words most used by authors, i.e., selected using feature selection procedure 1 (see groups “procedure 1” and “procedure 1, MAN” in Figure 3). Recognition accuracy decreased when the most common words in the training set, i.e., selected using feature selection procedure 2, were not selected from all words but only from words belonging to auxiliary parts of speech that do not have lexical meaning (see groups “procedure 2” and “procedure 2, AUX” in Figure 3). When the most frequently used words of authors are selected separately by the authors using feature selection procedure 1, in addition to the usage frequencies of words in a given text, the total usage frequency of words in each candidate author’s texts, and the total usage frequency in the training set are used in recognition, recognition effectiveness decreases (see groups “procedure 1, MAN” and “W&WA&WT procedure 1, MAN” in Figure 3). This may be due to the fact that the frequencies in the authors’ texts have already been taken into account when selecting words using procedure 1. In addition to the frequencies of the most frequently used words in the training set without taking into account author differences, total usage frequencies in candidate authors’ texts and the overall frequency in the training set are also used, and recognition accuracy increases (see “procedure 2” and “W&WA&WT, procedure 2” groups in Figure 3).

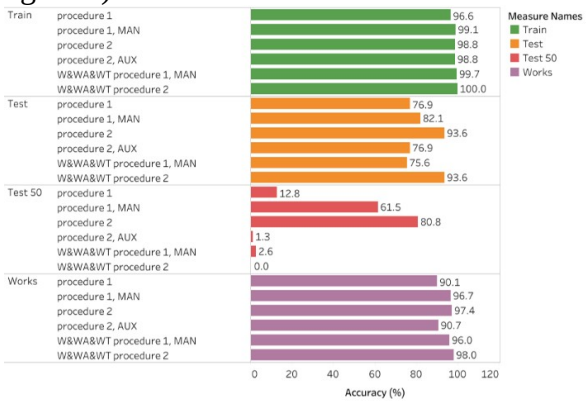



Figure 3. Recognition results on selecting word frequency features

## 4. CONCLUSION

In the study, approaches to extracting and selecting text features for the author recognition system of Azerbaijani texts, as well as the use of various machine learning methods, have been empirically studied. A feature selection procedure based on the author characterization degrees of character n-grams has been proposed. Based on the conducted computer experiments, the

impact of different feature types and selection procedures on the accuracy of author recognition has been comparatively evaluated.

## REFERENCES

1. X. He, A. H. Lashkari, N. Wombatkere, and D. P. Sharma, "Authorship attribution methods, challenges, and future research directions: A comprehensive survey," Information, vol. 15, no. 3, Art. 131, 2024.
2. A. Fedotova, A. Romanov, A. Kurtukova, and A. Shelupanov, "Digital authorship attribution in Russian-language fanfiction and classical literature," Algorithms, vol. 16, no. 1, Art. 13, 2023.
3. K. Ayda-zade and S. Talibov, "Analysis of the methods for the authorship identification of the text in the Azerbaijani language," Problems of Information Technology, vol. 8, no. 1, pp. 14–23, 2017.
4. T. C. Mendenhall, "A mechanical solution of a literary problem," The Popular Science Monthly, vol. 60, pp. 97–105, 1901.
5. R. B. Azimov, "Comparative analysis of using different text features, models, and methods in text author recognition," Cybernetics and Systems Analysis, vol. 60, no. 5, 2024.
6. Y. Zhao and J. Zobel, "Searching with style: Authorship attribution in classic literature," in Proc. 30th Australasian Conf. Computer Science, 2007, pp. 65–68.

# GEOMETRIC MODELING AND FEATURE FUSION TECHNIQUES FOR ADVANCED FACIAL IMAGE RECOGNITION IN BIOMETRIC SYSTEMS

F.S.Ortikova[1], S.A.Tastanova[2]
email:feruzaortiqova42@gmai.com
[1]*Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan*
[2]*Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan*
*Keywords: facial biometrics; dense 3D landmarks; geometric descriptors; metric learning; score-level fusion; template irreversibility.*

**Introduction**

Contemporary face recognition relies on textural information - colour, shading and illumination patterns - and loses reliability precisely when that information is corrupted. Infrared imaging, occlusion by masks or headwear, and large viewing angles destroy texture, yet security systems must operate uninterrupted under these conditions. Facial geometry such as distances and angles between characteristic points is independent of these factors. Automated recognition originated in this geometric paradigm (Kanade, 1973), but geometric methods were shown to lag behind template-based approaches in accuracy (Brunelli & Poggio, 1993). Geometry was thereafter applied mainly to normalisation and reconstruction (Blanz & Vetter, 1999), while the metric-learning paradigm dominant since 2014 operates on appearance (Deng et al., 2019). Dense mesh regression now recovers hundreds of 3D vertices in real time rather than the classical 68 (Kartynnik et al., 2019), enabling previously incomputable descriptors. Dense geometry has nonetheless not been studied as an independent source of identity evidence. This study develops such a model and an identification algorithm upon it, raising reliability where texture is limited.

**Methods**

Identification is formalised over a labelled set of N images and C classes. Each image is mapped to 478 three-dimensional landmarks, centred on their centroid, scaled by the inter-ocular distance and corrected for in-plane rotation:

$$l_i^{norm} = R(-\theta)\,\frac{l_i - \mu}{d_{ref}}, \quad d_{ref} = \|c_L - c_R\|_2 \qquad (1)$$

Two representations follow: an explicit geometric descriptor and a learned, L2-normalised embedding,

$$G = \Phi_G(L_{norm}) \in \mathbb{R}^{150}, \quad E = f_\Theta(L_{norm}) \in \mathbb{R}^{512} \qquad (2)$$

whose parameters are optimised under a combined objective, and whose scores are fused at the matching stage:

$$\Theta^* = \underset{\Theta}{argmin}\,\mathcal{L}(\Theta;\, D), \quad S(I_a,\, I_b) = \alpha s_G + \beta s_E, \quad \alpha + \beta = 1 \qquad (3)$$

Verification is one-to-one, $\delta = \mathbb{1}[S \geq \tau]$; identification is one-to-many over *M* enrolled subjects, with rejection to *unknown* below $\tau_{id}$. The complete corrected formulation is given in the Appendix.

**Results**

The formulation replaces the pixel array with 478 × 3 = 1,434 structured coordinates, compressed into 150- and 512-dimensional representations. The geometric vector comprises 45 inter-landmark distances, 35 proportions, 30 angles, 15 triangle areas, 10 topological features, 8 symmetry measures and 7 further characteristics (45 + 35 + 30 + 15 + 10 + 8 + 7 = 150). The landmark set is 7.0× denser than the classical 68-point model. Normalisation renders descriptors

invariant to translation, scale and in-plane rotation; optimisation enforces $S \to 1$ for matching and $S \to 0$ for non-matching identities. Raising $\tau$ reduces false matches while increasing false non-matches, defining the FAR/FRR trade-off.

**Discussion and Conclusion**

Treating dense facial geometry as an autonomous modality rather than a preprocessing aid yields a representation that survives texture loss and admits anthropometric interpretation of each decision. Because only the descriptor need be transmitted, the design also addresses template protection and irreversibility. Two contributions follow: a feature-formation method unifying metric, proportional, angular, areal, topological and symmetry characteristics over 478 landmarks; and a hybrid method fusing normalised geometry with attention-learned latent features adaptively by image quality and pose. Future work includes experimental validation on benchmark datasets, reduction of computational complexity, and implementation as a software complex.

**References**

1.Blanz, V., & Vetter, T. (1999). A morphable model for the synthesis of 3D faces. In Proceedings of the 26th Annual Conference on Computer Graphics and Interactive Techniques (SIGGRAPH '99) (pp. 187–194). ACM Press. https://doi.org/10.1145/311535.311556

2.Brunelli, R., & Poggio, T. (1993). Face recognition: Features versus templates. IEEE Transactions on Pattern Analysis and Machine Intelligence, 15(10), 1042–1052. https://doi.org/10.1109/34.254061

3.Deng, J., Guo, J., Xue, N., & Zafeiriou, S. (2019). ArcFace: Additive angular margin loss for deep face recognition. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 4690–4699). IEEE. https://doi.org/10.1109/CVPR.2019.00482

4.Kanade, T. (1973). Picture processing system by computer complex and recognition of human faces [Doctoral dissertation, Kyoto University].

5.Kartynnik, Y., Ablavatski, A., Grishchenko, I., & Grundmann, M. (2019). Real-time facial surface geometry from monocular video on mobile GPUs. In Proceedings of the CVPR Workshop on Computer Vision for Augmented and Virtual Reality. IEEE. https://arxiv.org/abs/1907.06724

## APPENDIX. CORRECTED MATHEMATICAL FORMULATION

### *1. Problem setting*

An RGB facial image of size H × W is given as input; the labelled image set and the required mapping are defined as follows.

$$I \in \mathbb{R}^{H\times W\times 3} \tag{1}$$

$$D = \{(I_i,\, y_i)\}_{i=1}^{N}, \quad y_i \in \{1,\, \dots,\, C\} \tag{2}$$

$$F : I \to y \tag{3}$$

### *2. Geometric model of the face*

$$F_L : \mathbb{R}^{H\times W\times 3} \to \mathbb{R}^{478\times 3} \tag{4}$$

$$l_i = (x_i,\, y_i,\, z_i) \in \mathbb{R}^3, \quad i = 1,\, \dots,\, 478 \tag{5}$$

$$L(I) = \{l_i\}_{i=1}^{478} \in \mathbb{R}^{478\times 3} \tag{6}$$

### *3. Geometric normalisation*

$$\mu = \tfrac{1}{n}\textstyle\sum_{i=1}^{n} l_i \tag{7}$$

$$l_i^{'} = l_i - \mu \tag{8}$$

$$d_{ref} = \|c_L - c_R\|_2 \tag{9}$$

$$l_i^{''} = \tfrac{l_i - \mu}{d_{ref}} \tag{10}$$

$$\theta = atan2\,(y_R - y_L\,,\, x_R - x_L) \tag{11}$$

$$l_i^{norm} = R(-\theta)\,\tfrac{l_i - \mu}{d_{ref}} \tag{12}$$

$$L_{norm} = N(L) \tag{13}$$

### *4. Geometric feature space*

$$\Phi_G : \mathbb{R}^{478\times 3} \to \mathbb{R}^{150} \tag{14}$$

$$G = \Phi_G\,(L_{norm}) \in \mathbb{R}^{150} \tag{15}$$

$$G = [D,\, R,\, \Theta,\, A,\, Q,\, S,\, H]^T \tag{16}$$

$$D \in \mathbb{R}^{45},\ R \in \mathbb{R}^{35},\ \Theta \in \mathbb{R}^{30},\ A \in \mathbb{R}^{15} \tag{17}$$

$$Q \in \mathbb{R}^{10},\ S \in \mathbb{R}^{8},\ H \in \mathbb{R}^{7} \tag{18}$$

$$45 + 35 + 30 + 15 + 10 + 8 + 7 = 150 \tag{19}$$

### *5. Latent feature formation*

$$f_\Theta : \mathbb{R}^{478\times 3} \to \mathbb{R}^{512} \tag{20}$$

$$E = f_\Theta\,(L_{norm}) \in \mathbb{R}^{512} \tag{21}$$

$$E \leftarrow \tfrac{E}{\|E\|_2}, \quad \|E\|_2 = 1 \tag{22}$$

### *6. Optimisation of model parameters*

$$\Theta^* = \underset{\Theta}{argmin}\,\mathcal{L}(\Theta\,;\, D) \tag{23}$$

$$\mathcal{L} = \lambda_1\mathcal{L}_{ArcFace} + \lambda_2\mathcal{L}_{triplet} + \lambda_3\mathcal{L}_{NCE} + \lambda_4\mathcal{L}_{geo} \tag{24}$$

$$d\,(E_i,\, E_j) \to 0, \quad y_i = y_j; \quad d\,(E_i,\, E_j) \to \max, \quad y_i \neq y_j \tag{25}$$

### *7. Similarity between two faces*

$$s_G\,(G_a,\, G_b) = \tfrac{1}{1 + \|G_a - G_b\|_2} \tag{26}$$

$$s_E(E_a,\ E_b)\ =\ \frac{{E_a}^T E_b}{\|E_a\|_2\ \|E_b\|_2} \tag{27}$$

$$S(I_a,\ I_b)\ =\ \alpha\, s_G(G_a,\ G_b)\ +\ \beta\, s_E(E_a,\ E_b) \tag{28}$$

$$\alpha\ +\ \beta\ =\ 1,\quad \alpha\ \geq\ 0,\quad \beta\ \geq\ 0 \tag{29}$$

***8. Verification (one-to-one)***

$$\delta(I_a,\ I_b)\ =\ \mathbb{1}\left[S(I_a,\ I_b)\ \geq\ \tau\right] \tag{30}$$

that is, δ = 1 when S ≥ τ (same person) and δ = 0 when S < τ (different persons). Increasing τ lowers the false match rate and raises the false non-match rate.

***9. Identification (one-to-many)***

$$B\ =\ \{P_1,\ P_2,\ \ldots\ ,\ P_M\} \tag{31}$$

$$j^*\ =\ \underset{1\ \leq\ j\ \leq\ M}{argmax}\ S\left(I_q,\ P_j\right) \tag{32}$$

$$y\ =\ y_{j^*},\quad if\ \ S\left(I_q,\ P_{j^*}\right)\ \geq\ \tau_{id};\quad y\ =\ unknown\ \ otherwise \tag{33}$$

***10. Generalised model***

$$I\ \rightarrow^{F_L}\ L\ \rightarrow^{N}\ L_{norm}\ \rightarrow^{\Phi_G}\ G\ \in\ \mathbb{R}^{150} \tag{34}$$

$$L_{norm}\ \rightarrow^{f_\Theta}\ E\ \in\ \mathbb{R}^{512} \tag{35}$$

$$(G_a,\ E_a,\ G_b,\ E_b)\ \rightarrow^{\Psi}\ S(I_a,\ I_b),\quad \Psi\ =\ \alpha s_G\ +\ \beta s_E \tag{36}$$

$$\Theta^*\ =\ \underset{\Theta}{argmin}\ \mathcal{L}(\Theta\ ;\ D) \tag{37}$$

$$S\left(I_i,\ I_j\right)\ \rightarrow\ 1,\quad y_i\ =\ y_j\ ;\quad S\left(I_i,\ I_j\right)\ \rightarrow\ 0,\quad y_i\ \neq\ y_j \tag{38}$$

УДК 004.8

# МЕТОДИКА ОЦЕНКИ УСТОЙЧИВОСТИ MOBILENETV2 К ИСКАЖЕНИЯМ ИЗОБРАЖЕНИЙ ЛИСТЬЕВ ТОМАТА

**Белик Г. А.**

*Университет «Туран», Алматы, Казахстан*

e-mail: 25261237@turan-edu.kz

*Аннотация. Разработана методика оценки устойчивости классификатора MobileNetV2 в системе TomatoAI к ухудшению качества изображений листьев томата. Предложено парное сравнение исходных изображений с затемнёнными, осветлёнными, размытыми и зашумлёнными версиями при неизменных весах модели. Определены уровни воздействий, метрики качества и процедура оценки неопределённости. Реализован скрипт локального эксперимента с проверкой весов и классов. Работа имеет методический характер; численные показатели устойчивости обученной модели не приводятся.*

*Ключевые слова: компьютерное зрение, MobileNetV2, TomatoAI, болезни томата, устойчивость модели, искажения изображений, PlantVillage.*

**Введение**

Диагностика заболеваний растений по цифровым изображениям предполагает, что визуальные признаки поражения сохраняются после съёмки и предобработки. При использовании смартфона это условие может нарушаться: недостаток освещения уменьшает различимость пятен, расфокусировка сглаживает границы поражённых участков, а шум изменяет текстуру листовой поверхности. Поэтому доля правильных ответов на исходном наборе данных характеризует лишь один режим работы классификатора.

Работа продолжает исследование системы TomatoAI, представленное ранее автором [1]. Объектом анализа является программная реализация классификации изображений листьев томата на основе MobileNetV2. Цель работы — разработать воспроизводимую методику оценки чувствительности этого классификатора к контролируемым искажениям. Для достижения цели проанализированы подготовка данных, обучение и получение предсказаний; определены условия парного сравнения изображений и показатели изменения качества.

Исследование ограничивается модулем классификации изображений. Прогнозирование риска по временным рядам, погодные поправки и текстовые рекомендации не входят в оценку распознавания. Методика предназначена для проверки конкретного сохранённого экземпляра модели. Её разработка не является подтверждением точности диагностики или применимости системы в хозяйствах Казахстана: для таких выводов необходимы отдельные измерения на размеченных изображениях.

**Научные предпосылки исследования**

В исследовании S. P. Mohanty, D. P. Hughes и M. Salathé продемонстрирована возможность распознавания заболеваний растений с помощью глубокого обучения на PlantVillage [2]. Одновременно авторы рассмотрели ограничения переноса модели за пределы исходной коллекции. Для прикладной диагностики необходимо различать качество на изображениях, близких к обучающим данным, и качество при изменении условий получения фотографии.

Архитектура MobileNetV2 использует инвертированные остаточные блоки, глубинные свёртки и линейные узкие слои [3]. Эти решения ориентированы на эффективное использование вычислительных ресурсов. Однако компактность архитектуры сама по себе не определяет устойчивость конкретной обученной модели. Проверять необходимо сочетание весов, состава данных и процедуры предобработки, используемое в исследуемой системе.

D. Hendrycks и T. Dietterich предложили систематически оценивать классификаторы на распространённых искажениях изображений, выделяя эту задачу отдельно от противодействия специально оптимизированным атакам [4]. В настоящей работе используется общий принцип контролируемого изменения типа и интенсивности воздействия. Выбранные ниже параметры являются собственным протоколом для TomatoAI и не воспроизводят полный набор ImageNet-C; прямое сравнение чисел между этими испытаниями не предполагается.

Наборы PlantDoc [5] и PlantWild [6] расширяют исследование в сторону изображений вне лабораторных условий. В работе W. Benabbas и соавторов также рассматривается перенос моделей с подготовленных коллекций на реальные фотографии [7]. Такие данные позволяют изучать более широкий сдвиг условий, включающий фон, композицию и вариативность симптомов. Контролируемые искажения дополняют эту проверку: они позволяют изменять один фактор, сохраняя само изображение и его метку.

G. V. de Andrade и соавторы рассмотрели устойчивость сетей при распознавании заболеваний листьев манго на искусственно искажённых данных [8]. Эта постановка применима и к исследованию других культур, однако полученные для манго оценки нельзя переносить на TomatoAI. Вклад настоящей работы состоит в согласовании протокола искажений с фактической реализацией классификатора томата: его предобработкой, структурой контрольной точки, порядком классов и режимом получения ответа.

**Исходная реализация и условия оценки**

Анализ файлов model.py, inference.py, app.py и двух скриптов обучения подтверждает использование MobileNetV2. Для проверки качества задано преобразование в RGB, масштабирование короткой стороны до 256 пикселей и центральное кадрирование до 224 × 224. Далее применяются перевод пикселей в диапазон 0–1 и поканальная нормализация со средними (0,485; 0,456; 0,406) и стандартными отклонениями (0,229; 0,224; 0,225). Поэтому в данном протоколе фиксируется вход 224 × 224; размер 128 × 128 из предыдущего описания [1] не используется.

Подготовка данных предусматривает разбиение изображений каждого класса в отношении около 80/20 на train и val. Независимая тестовая часть кодом не создаётся. Повторное использование val необходимо обозначать как валидационную оценку. Для независимого тестирования требуется отдельная выборка, не участвовавшая в обучении и выборе модели. Точные дубликаты проверяются по содержимому изображений; близкие копии и фотографии одного листа требуют проверки происхождения и группового учёта.

**Моделирование искажений изображений**

Эксперимент предусматривает контрольный режим и двенадцать условий воздействия: четыре вида преобразования с тремя уровнями интенсивности. Каждый вариант создаётся непосредственно из исходной фотографии. Затемнение, осветление, размытие и шум не применяются последовательно друг за другом, что позволяет отдельно оценить влияние каждого фактора. Весовые коэффициенты нейронной сети во всех режимах остаются неизменными.

Искажения применяются после преобразования в RGB, масштабирования, центрального кадрирования и перевода значений в диапазон 0–1, но до нормализации. Тем самым исследуется устойчивость к изменениям уже подготовленного входа размером 224 × 224 пикселя. Такой порядок фиксирует масштаб воздействия и исключает влияние случайного кадрирования; он не воспроизводит полностью прохождение испорченного исходного снимка через камеру и предобработку.

Таблица 1

*Параметры контролируемых воздействий*

| **Воздействие** | **Параметр** | **Уровень 1** | **Уровень 2** | **Уровень 3** |
|---|---|---|---|---|
| Затемнение | Множитель a | 0,8 | 0,6 | 0,4 |
| Осветление | Множитель a | 1,2 | 1,4 | 1,6 |
| Гауссово размытие | σ, пиксели | 0,5 | 1,0 | 2,0 |
| Гауссов шум | σ в шкале 0–1 | 0,01 | 0,03 | 0,05 |

Примечание. Уровни заданы для исследовательского сравнения и не являются нормативами допустимого качества фотографий.

При изменении яркости каждый канал умножается на коэффициент a, после чего значения ограничиваются диапазоном от 0 до 1. Такой оператор моделирует цифровое изменение яркости. Он не воспроизводит полностью физическую экспозицию камеры, локальные тени или изменение цветовой температуры. При осветлении отдельно учитывается возможная потеря информации из-за насыщения светлых участков.

Размытие выполняется гауссовым фильтром независимо для каждого канала. Радиус ядра равен округлённому вверх значению трёх стандартных отклонений; для выбранных уровней получаются ядра 5 × 5, 7 × 7 и 13 × 13. На границах применяется отражение. Эти параметры описывают сглаживание деталей, но не все разновидности расфокусировки и смаза, возникающие при съёмке.

Для зашумления к каждому пикселю и каналу добавляется независимая нормально распределённая величина с нулевым средним и заданным стандартным отклонением. Результат ограничивается диапазоном от 0 до 1. Предусматриваются пять независимых реализаций шума на каждый уровень. Начальные состояния генератора и порядок обработки файлов сохраняются, чтобы одинаковый эксперимент можно было повторить.

Параметры фиксируются до расчёта метрик. Интерпретация сильных воздействий требует визуальной проверки сохранности диагностических признаков на отдельной демонстрационной подвыборке. Если симптомы становятся неразличимыми, ухудшение ответа отражает также потерю информации во входных данных. Предложенные уровни не устанавливают универсальную границу пригодности фотографии для диагностики.

**Метрики качества и порядок расчёта**

Пусть N — число исходных изображений, K — число оцениваемых классов, h — зафиксированная модель вместе с её нормализацией, T — исследуемое преобразование. Для типа воздействия c и уровня s точность классификации определяется долей правильных ответов:

$$A_{c,s} = \frac{1}{N}\sum_{i=1}^{N} I[\, h(T_{c,s}(x_i)) = y_i \,] \quad (1)$$

Здесь I обозначает индикатор истинности условия, а метка исходного изображения сохраняется у всех его версий. Для контрольного режима преобразование отсутствует. Значения точности рассчитываются на одном и том же списке изображений. Отбор только фотографий, правильно распознанных в контроле, для вычисления основной точности не допускается.

При неравномерном распределении классов общая точность дополняется макроусреднённой F1-мерой. Для каждой категории k вычисляются числа верных положительных ответов TP, ложных положительных ответов FP и пропусков FN:

$$F1_k = \frac{2TP_k}{2TP_k + FP_k + FN_k}; \quad F1_{macro} = \frac{1}{K}\sum_{k=1}^{K} F1_k \quad (2)$$

Во всех условиях сохраняется один набор классов, каждый из которых должен иметь примеры в проверочной выборке. Дополнительно анализируются полнота отдельных категорий и матрицы ошибок. Это позволяет обнаружить ситуацию, когда ухудшение распознавания редкого заболевания слабо отражается на общей точности.

Основной показатель изменения качества — разность контрольной точности и точности при воздействии, выраженная в процентных пунктах:

$$\Delta A_{c,s} = 100(A_0 - A_{c,s}) \quad (3)$$

Положительная разность означает ухудшение, отрицательная — улучшение на конкретной выборке. Дополнительно определяется доля изображений, правильно распознанных в контроле, для которых искажение привело к ошибке. Этот показатель характеризует новые ошибки и рассчитывается отдельно от общей точности. Неизменность ответа сама по себе не доказывает правильность распознавания.

Для шума рассчитываются среднее и стандартное отклонение метрик пяти реализаций. Парный стратифицированный bootstrap включает 1000 повторений и 95-процентный процентильный интервал: исходная фотография выбирается вместе со всеми её версиями. Точные копии объединяются; при известных идентификаторах листьев повторно выбираются группы внутри класса. Интервал характеризует выборочную неопределённость при фиксированных реализациях шума; вариативность шума описывается отдельно. Он не учитывает разброс повторных обучений.

Основной режим использует один проход модели. Дополнительный режим воспроизводит TTA из app.py: суммируются логиты исходного входа и его горизонтального отражения. Режимы оцениваются отдельно на одних данных. Суммирование и усреднение логитов дают одинаковый выбор класса, но разные значения softmax; уверенность ответа не отождествляется с точностью. Предварительное отклонение кадров функцией is_blank отключено: протокол оценивает классификатор, а не весь HTTP-обработчик приложения.

**Результаты анализа и реализация методики**

Анализ исходного кода выявил различия, которые необходимо устранить или явно учитывать до сопоставления результатов. Они связаны с размером входа, устройством выходного слоя, составом валидационной выборки и режимом предсказания. Основные условия воспроизводимости обобщены в таблице 2.

Таблица 2

*Условия воспроизводимости, установленные по исходному коду*

| **Условие** | **Установлено в коде** | **Правило эксперимента** |
|---|---|---|
| Размер входа | Масштабирование до 256 по короткой стороне; кадрирование 224 × 224 | Воздействия задаются на входе 224 × 224 до нормализации |
| Выходной слой | Два варианта: Linear и вложенная последовательность Dropout–Linear | Структура восстанавливается по весам; загрузка строгая |
| Состав данных | В train_with_curve.py по умолчанию первые 400 файлов каждого класса в train и val | Фиксируется полный список; прежняя точность не переносится |
| Режим ответа | В app.py используются исходный вход и горизонтальное отражение | Один проход и TTA оцениваются раздельно |

В train.py сохраняется выходной слой с дополнительным вложенным Dropout, тогда как model.py ожидает непосредственно линейный слой. При строгой загрузке соответствующие имена параметров не совпадают. Скрипт эксперимента определяет оба предусмотренных варианта по контрольной точке и проверяет их строго; неизвестная структура или несоответствие числа классов приводят к остановке.

Реализованный скрипт выполняет локальный запуск без повторного обучения. Для каждого изображения предусмотрены 25 вариантов: контроль, девять детерминированных искажений и пятнадцать шумовых реализаций. Сохраняются ответы для каждого файла, сводные метрики, полнота классов, матрицы ошибок и графики. Контрольная сумма весов, список изображений, параметры генератора и версии библиотек позволяют идентифицировать эксперимент.

Отдельная проверка необходима для inference.py: в нём закреплены три обобщённые метки, а при отсутствии модели предусмотрен случайный демонстрационный ответ. В многоклассовом эксперименте этот путь не используется. Метки сверяются с сохранённым порядком классов обучения. Наличие истории обучения само по себе не связывает её с конкретным файлом весов, поскольку оба скрипта могут перезаписывать history.json.

При технической проверке на искусственных входах проверены загрузка обоих вариантов модели, совпадение метрик с реализацией scikit-learn, воспроизводимость шума и остановка при пересечении выборок. Эти проверки характеризуют работу скрипта, но не качество диагностики. Для получения численных оценок устойчивости необходим запуск с обученными весами и размеченными фотографиями. Показатели первой статьи и демонстрационные ответы приложения не используются как результаты нового эксперимента.

**Ограничения исследования**

Работа имеет методический характер и не устанавливает фактическое снижение точности TomatoAI при выбранных воздействиях. Испытание одного сохранённого экземпляра характеризует только сочетание его весов, данных и предобработки. Для сравнения архитектур и способов обучения необходимы дополнительные модели, повторные обучения и сопоставимый вычислительный бюджет. Проверка точных совпадений также не доказывает отсутствие близких дубликатов или связанных фотографий одного листа.

Синтетические воздействия охватывают только часть изменений, встречающихся при съёмке. Они не включают неоднородный фон, сочетания нескольких нарушений качества, перекрытие листа, различия сортов и стадий поражения. Оценка на PlantDoc или PlantWild возможна после согласования категорий и единицы классификации [5, 6]. Проверка в хозяйствах Казахстана дополнительно требует локальных фотографий с подтверждёнными метками.

**Заключение**

Разработана методика оценки устойчивости MobileNetV2 к изменению яркости, гауссову размытию и шуму на изображениях листьев томата. По исходному коду TomatoAI уточнены размер входа 224 × 224, различия структур выходного слоя и режим TTA. Определены фиксированные уровни воздействий, правила парного сравнения, метрики качества и процедура оценки выборочной неопределённости.

Практический результат состоит в подготовке воспроизводимого локального эксперимента, который сохраняет происхождение измерений и отделяет исходные ошибки от ошибок после искажения. Для эмпирического подтверждения устойчивости необходим запуск на размеченной выборке с идентифицированными весами и порядком классов. Дальнейшее применение методики к фотографиям из хозяйств Казахстана требует проверки соответствия категорий и независимости данных.

**Литература**

1. *Белик Г. А.* Применение искусственного интеллекта для диагностики заболеваний листьев томата на основе системы TomatoAI. Рукопись автора. 2026.

2. *Mohanty S. P., Hughes D. P., Salathé M.* Using Deep Learning for Image-Based Plant Disease Detection // Frontiers in Plant Science. 2016. Vol. 7. Art. 1419. DOI: 10.3389/fpls.2016.01419.

3. *Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L.-C.* MobileNetV2: Inverted Residuals and Linear Bottlenecks // CVPR. 2018. P. 4510–4520. DOI: 10.48550/arXiv.1801.04381.

4. *Hendrycks D., Dietterich T.* Benchmarking Neural Network Robustness to Common Corruptions and Perturbations // ICLR. 2019. DOI: 10.48550/arXiv.1903.12261.

5. *Singh D., Jain N., Jain P., Kayal P., Kumawat S., Batra N.* PlantDoc: A Dataset for Visual Plant Disease Detection. Препринт arXiv. 2019. DOI: 10.48550/arXiv.1911.10317.

6. *Wei T., Chen Z., Huang Z., Yu X.* Benchmarking In-the-wild Multimodal Disease Recognition and A Versatile Baseline. Препринт arXiv. 2024. DOI: 10.48550/arXiv.2408.03120.

7. *Benabbas W., Brahimi M., Akhrouf S., Fortas B.* Rethinking Plant Disease Diagnosis: Bridging the Academic-Practical Gap with Vision Transformers and Zero-Shot Learning. Препринт arXiv. 2025. DOI: 10.48550/arXiv.2511.18989.

8. *de Andrade G. V. et al.* From Code to Field: Evaluating the Robustness of Convolutional Neural Networks for Disease Diagnosis in Mango Leaves. Препринт arXiv. 2025. DOI: 10.48550/arXiv.2512.13641.

# Интеллектуальные слои ГИС экологического паспорта района падения для оценки риска загрязнения почв нефтепродуктами

Дәруіш С.З.[1,2], Утегенова А.У.[1], Жумабекова Ж.Ж.[3]
e-mail: daruish_serik@live.kaznu.kz, an.utegenova@satbayev.university, zhumabekova.kz87@gmail.com
[1]*Институт информационных и вычислительных технологий КН МНВО РК, Казахстан*
[2]*Казахский национальный университет имени аль-Фараби, Казахстан*
[3]*Республиканское государственное предприятие «Инфракос», Казахстан*

***Аннотация.*** *Экологический паспорт района падения отделяющихся частей ракет-носителей требует оценки загрязнения по всей площади, тогда как данные мониторинга точечные и редкие. Описаны два интеллектуальных слоя ГИС паспортизации районов падения космодрома «Байконур»: адаптивная интерполяция концентраций нефтепродуктов в почве и модель машинного обучения, ранжирующая территорию по риску превышения порогов. На модельных данных, приближённых к трём кампаниям обследования зоны Ю-25, с пространственной блочной кросс-валидацией показано, что модель на признаках истории падений ранжирует риск с ROC-AUC 0,93-0,96 против 0,53-0,76 у интерполяции и переносится на новую кампанию, находя 15 из 19 превышений в верхней четверти карты риска.*

***Ключевые слова:*** *геоинформационная система, экологический паспорт, районы падения, нефтепродукты, интерполяция, случайный лес, пространственная кросс-валидация, оценка риска.*

## Введение

Эксплуатация космодрома «Байконур» сопровождается падением отделяющихся частей ракет-носителей (ОЧРН) в районы падения (РП), расположенные на территории Республики Казахстан. Оператор обязан вести экологический мониторинг этих районов и поддерживать экологический паспорт каждого из них. Структура паспорта задана СТ РК 17.0.0.02-2001 [1], и его раздел «Оценка экологической обстановки» предполагает характеристику состояния территории в целом. При этом данные мониторинга точечные: одна кампания обследования даёт от нескольких десятков до двух сотен проб почвы на площадь около 2000 км². Воздействие ракетно-космической деятельности на почвы РП изучено достаточно подробно [2, 3], однако переход от точечных измерений к площадной оценке до сих пор выполняется вручную, не воспроизводится и не сопровождается проверкой качества.

Геоинформационные технологии широко применяются для оценки экологического состояния территорий и их мониторинга [4]. В разрабатываемой нами интеллектуальной геоинформационной системе (ГИС) экологического мониторинга и паспортизации РП эта задача решается с помощью двух слоёв, которые строятся из данных системы воспроизводимыми процедурами. Первый слой содержит расчётные зоны загрязнения, полученные интерполяцией по пробам кампании. Второй слой отражает риск превышения нормативных порогов и строится моделью машинного обучения на признаках, которые вычисляются в ГИС из истории пусков и свойств территории.

Цель работы состояла в том, чтобы установить, что из этого действительно можно предсказать при проверке, учитывающей пространственную автокорреляцию проб, на данных, приближённых к реальным кампаниям обследования. Известно, что случайная кросс-валидация завышает качество пространственных моделей, поскольку соседние пробы одновременно попадают в обучающую и проверочную выборки. Для данных с пространственной структурой рекомендованы блочные схемы проверки [5, 6], и при их

применении многие карты, построенные методами машинного обучения, теряют значительную часть заявленного качества [7, 8].

Для этого решались четыре задачи: сформировать модельный набор данных с сетью проб трёх кампаний и признаками, вычисленными в ГИС, формализовать адаптивный алгоритм интерполяции, встроенный в систему, построить модель риска превышения и сравнить её с интерполяцией при пространственной блочной кросс-валидации и при переносе между кампаниями, а также оценить, как качество методов зависит от расстояния до ближайших проб и от радиуса поиска.

## Основная часть

### 1. Данные и признаки

Сеть проб трёх кампаний обследования, места падения и признаки территории взяты из слоёв ГИС, а значения концентраций нефтепродуктов в работе модельные, приближённые к реальным кампаниям, поскольку доступ к первичным результатам мониторинга ограничен. Концентрация каждой пробы сгенерирована как сумма логнормального фона с медианой 8 мг/кг и вкладов предшествующих падений, убывающих с расстоянием (характерная длина 300 м) и с возрастом падения (характерное время 0,8 года), с логнормальным шумом. Значения ниже предела обнаружения 5 мг/кг в кампаниях 2012 и 2020 гг. записаны нулём, как в протоколах анализов (табл. 1). Пробы оперативного сопровождения пусков у мест падения блоков (210 проб за 2006-2025 гг.) рассматривались отдельно, поскольку по построению взяты в местах ожидаемого загрязнения.

Таблица 1. Пробы почвы кампаний обследования зоны Ю-25 (модельные значения концентраций)

| Кампания | Точек обследования | Проб ключевых участков | Всего | Медиана C, мг/кг | Максимум C, мг/кг | Доля C > 50 | Доля C > 100 | Ниже предела обнаружения |
|---|---|---|---|---|---|---|---|---|
| 2005 | 62 | 223 | 285 | 9,7 | 402 | 14,4 % | 11,6 % | 0 % |
| 2012 | 32 | 65 | 97 | 17,7 | 349 | 26,8 % | 11,3 % | 11,3 % |
| 2020 | 160 | 49 | 209 | 9,3 | 249 | 9,1 % | 3,8 % | 23,0 % |

На результаты влияют три особенности данных. Во-первых, превышений немного: 86 проб из 591 содержат более 50 мг/кг (граница фона в градациях карты) и 52 пробы более 100 мг/кг (санитарная ПДК нефтепродуктов в почве [9]). Во-вторых, кампании различаются плотностью сети и долей значений ниже предела обнаружения: в 2005 г. таких значений нет, в 2020 г. их 23 %. В-третьих, пробы ключевых участков геокодированы в одну точку участка. В 2012 г. 82 % записей делят координату с другими пробами, в 2020 г. таких записей 27 %.

Признаки вычислялись в проекции UTM 42N для каждой пробы. К ним относятся расстояние до ближайшего места падения (любого и до даты отбора) и время, прошедшее с него, число мест падения в радиусах 1, 2 и 5 км и за пять лет до отбора пробы (всего 265 мест падения за 2003-2025 гг.), расстояние до центра ближайшего РП и до границы зоны, тип почвы, категория устойчивости грунтов, категория земель, расстояние до дороги и до населённого пункта, год кампании, признак пробы ключевого участка и число записей с той же координатой. Категория грунтов (VII у 91 % проб) и расстояние до дороги оказались практически постоянными.

## 2. Методы

Адаптивная интерполяция. Слой расчётных зон загрязнения строится методом обратных взвешенных расстояний [10]. Полигон зоны и пробы переводятся в проекцию UTM, по зоне строится сетка с шагом 250 м, и значение в каждом узле оценивается по k = 8 ближайшим пробам в пределах радиуса поиска с весами, обратными квадрату расстояния. Узлы, в радиусе которых нет проб, остаются без данных. Ячейки классифицируются по градациям 50, 300 и 1000 мг/кг и объединяются в пятна, для которых вычисляется площадь. Два элемента алгоритма адаптируются к данным кампании. Пробы с совпадающими координатами (допуск 1 м) объединяются в одну опорную точку со средним значением. Иначе «стопка» проб занимает все k мест среди ближайших и вытесняет реальных соседей. Радиус поиска выбирается как наименьший из ряда 2-12 км, при котором пробы кампании покрывают не менее 70 % ячеек сетки внутри зоны. Для плотной сети 2020 г. это 3 км, для 2012 г. 6-7 км, для редкой сети 2005 г. 8-10 км. Объединение проб заметно меняет площади пятен. Для 2012 г. площадь выше фона выросла со 110 до 129 км², для 2020 г. уменьшилась с 34 до 13 км².

Модель риска. Задача поставлена как бинарная классификация: превышает ли проба порог 50 или 100 мг/кг. В качестве модели использован случайный лес [11] с 500 деревьями, минимальным размером листа 3 и балансировкой классов по весам. Для карты риска применялся вариант на 13 числовых признаках без координат, то есть пространственный прогноз строился по признакам, а не по соседям [12]. Регрессионные варианты на log(1 + C) оценивались для полноты картины. В качестве базовых линий взяты среднее по кампании, интерполяция в конфигурации системы, ординарный кригинг с экспоненциальной вариограммой [13] и метод k ближайших соседей по координатам. Для классификации прогноз интерполяции использовался как ранжирующая оценка.

Протокол проверки. Основным протоколом служила пространственная блочная кросс-валидация. Зона разбита на блоки 5×5 км (116 блоков с пробами), блоки распределены по пяти фолдам, и пробы одного блока целиком попадают либо в обучение, либо в проверку. Чувствительность результатов проверена для блоков 2 и 10 км. Второй протокол воспроизводит перенос между кампаниями: модель обучается на двух кампаниях и проверяется на третьей. Для регрессии использовались RMSE и $R^2$ в логарифмической шкале, для классификации ROC-AUC и PR-AUC [14], а также доля превышений, попавших в верхнюю четверть оценок риска. Доверительные интервалы получены бутстрэпом по блокам (1000 повторов), что позволяет учесть пространственную зависимость проб.

## 3. Результаты

Величина концентрации восстанавливается только по признакам. При пространственной кросс-валидации среднее по кампании и кригинг не объясняют дисперсии log C ($R^2$ около нуля), интерполяция в конфигурации системы даёт $R^2$ = -0,27, тогда как случайный лес на признаках ГИС объясняет 48-49 % дисперсии. В модельных данных вклад падения убывает на сотнях метров, поэтому соседние пробы, отстоящие на километры, ничего не сообщают о точке, а признаки истории падений сообщают. Вклад признаков в регрессию почти полностью приходится на расстояние до ближайшего предшествующего падения (перестановочная важность 0,12), время с него (0,10) и расстояние до ближайшего места падения (0,06). Внутри отдельной кампании качество ниже: $R^2$ 0,45 для 2012 г. и 0,12 для 2020 г., где превышения редки.

Риск превышения ранжируется по признакам. Для классификации (табл. 2) интерполяция ранжирует пробы заметно лучше случайного выбора (ROC-AUC 0,69 для порога 50 мг/кг и 0,76 для 100 мг/кг), кригинг остаётся на уровне случайного (0,53), а случайный лес на признаках ГИС достигает ROC-AUC 0,93-0,96, и его доверительные интервалы не пересекаются с интервалами интерполяции. PR-AUC модели составляет

0,76-0,81 при случайном уровне 0,09-0,15. Если пометить столько проб, сколько превышений есть на самом деле, модель находит 73 % превышений порога 50 мг/кг, интерполяция 42 %, кригинг 15 %. Для среза одной кампании 2020 г. с 19 превышениями оценки ниже (ROC-AUC 0,66-0,72 у модели против 0,40 у интерполяции), а интервалы широки.

Таблица 2. Классификация превышений при пространственной блочной кросс-валидации

| **Выборка, порог** | **Модель** | **ROC-AUC (95 % ДИ)** | **PR-AUC (95 % ДИ)** | **PR-AUC случайного** |
|---|---|---|---|---|
| Все кампании, > 50 мг/кг (86 полож.) | Интерполяция (IDW) | 0,69 (0,46-0,84) | 0,39 (0,13-0,64) | 0,15 |
| | Ординарный кригинг | 0,53 (0,38-0,73) | 0,21 (0,09-0,37) | 0,15 |
| | Случайный лес, признаки ГИС | 0,94 (0,88-0,98) | 0,81 (0,58-0,94) | 0,15 |
| | Случайный лес, 13 числовых признаков | 0,93 (0,86-0,97) | 0,80 (0,59-0,93) | 0,15 |
| Все кампании, > 100 мг/кг (52 полож.) | Интерполяция (IDW) | 0,76 (0,49-0,93) | 0,36 (0,07-0,67) | 0,09 |
| | Случайный лес, 13 числовых признаков | 0,96 (0,87-0,99) | 0,76 (0,44-0,94) | 0,09 |
| Кампания 2020, > 50 мг/кг (19 полож.) | Интерполяция (IDW) | 0,40 (0,18-0,60) | 0,09 (0,02-0,21) | 0,09 |
| | Случайный лес, 13 числовых признаков | 0,66 (0,18-0,82) | 0,17 (0,02-0,43) | 0,09 |

Качество прогноза зависит от расстояния до проб. Зависимость от размера блока (табл. 3) показывает природу этого качества. Интерполяция теряет предсказательную силу уже при блоках 2 км и ухудшается с их ростом, кригинг удерживается на уровне среднего, а случайный лес на признаках сохраняет $R^2$ 0,49-0,53 при любом размере блока, поскольку опирается не на соседей, а на историю падений в окрестности точки. Точность интерполяции слабо зависит от радиуса поиска. При блоках 5 км ROC-AUC лежит в пределах 0,69-0,72 для радиусов от 3 км до неограниченного, различия меньше ширины доверительных интервалов, тогда как покрытие зоны меняется от 47 % при 3 км до 100 % без ограничения. Адаптивный радиус по покрытию не менее 70 % даёт 79 % покрытия при ROC-AUC 0,72, лучшем среди вариантов, и выбирает наименее сглаженную из допустимых поверхностей. Таким образом, адаптивный радиус управляет полнотой карты паспорта, а не её точностью.

Таблица 3. $R^2$ регрессии log C при разном размере блока пространственной кросс-валидации

| **Модель** | **Блок 2 км** | **Блок 5 км** | **Блок 10 км** |
|---|---|---|---|
| Интерполяция (IDW, как в системе) | -0,102 | -0,269 | -0,580 |
| Ординарный кригинг | 0,000 | -0,009 | -0,027 |
| Случайный лес, координаты + признаки ГИС | 0,529 | 0,488 | 0,493 |

Модель переносится на новую кампанию. Классификатор, обученный на кампаниях 2005 и 2012 гг., ранжирует пробы 2020 г. с ROC-AUC 0,88 и PR-AUC 0,75

при случайном уровне 0,09, и в верхнюю четверть оценок риска попадают 15 из 19 превышений. Интерполяция по пробам других кампаний даёт ROC-AUC 0,34 и находит 1 превышение из 19. В регрессии перенос сохраняет $R^2$ 0,43-0,44 у модели на признаках при отрицательных значениях у всех методов по соседям. Перенос возможен потому, что в модельных данных связь между историей падений и загрязнением одинакова во всех кампаниях. Для реальных редакций паспорта это условие выполняется только при сопоставимых методиках отбора и анализа.

Карта риска для кампании 2020 г. (рис. 1) концентрирует риск вблизи мест падения вдоль оси зоны. Модель для этой карты обучена на всех кампаниях, поэтому карта иллюстративна, а её проверяемые характеристики приведены выше. Верхняя четверть ячеек занимает 506 км², верхняя десятая часть 203 км², тогда как площадь выше фона по интерполяции для той же кампании составляет 13 км². Две карты отвечают на разные вопросы: интерполяция показывает, где загрязнение измерено, а карта риска подсказывает, где его стоит искать. Кривые точность-полнота (рис. 2) показывают, что преимущество модели на признаках сохраняется во всём диапазоне полноты для объединённой выборки и сужается на срезе одной кампании.

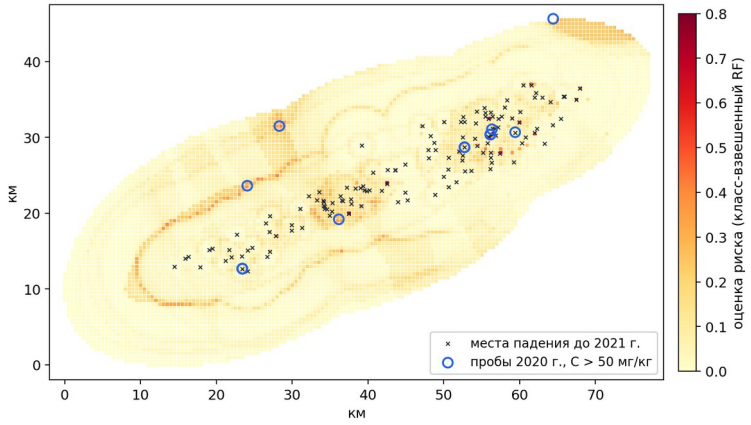



Рис. 1 Вероятность превышения 50 мг/кг нефтепродуктов по сетке 500 м

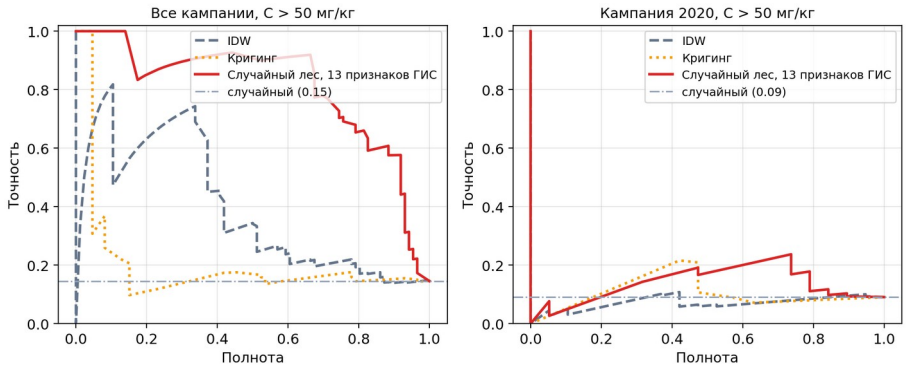



Рис. 2 Кривые точность-полнота для порога 50 мг/кг: все кампании (слева) и кампания 2020 (справа)

## Заключение

На модельных данных, приближённых к реальным кампаниям обследования, установлено, что именно поддаётся прогнозу при проверке, учитывающей пространственную структуру проб, а обе процедуры встроены в ГИС как воспроизводимые слои паспорта. По задачам работы получены следующие выводы.

1. Величина концентрации нефтепродуктов в почве не восстанавливается по соседним пробам: интерполяция и кригинг не выходят за $R^2 \approx 0$ при пространственной

кросс-валидации, тогда как модель на признаках истории падений объясняет около половины дисперсии. Площадная карта концентраций достоверна лишь в узкой полосе вокруг проб, и адаптивный радиус делает эту границу явной, оставляя ячейки без проб незаполненными.

2. Риск превышения порогов ранжируется моделью на признаках истории падений с ROC-AUC 0,93-0,96 против 0,53-0,76 у интерполяции и кригинга. Модель сохраняет качество при пропусках сети в 10 км и может направлять дополнительный отбор проб, переобучаясь по мере их поступления. На срезе одной кампании с редкими превышениями точность падает, поэтому карту риска следует читать как ранжирование, а не как оценку вероятности.

3. Модель переносится на новую кампанию, если связь между историей падений и загрязнением сохраняется: обученная на 2005 и 2012 гг., она находит 15 из 19 превышений 2020 г. в верхней четверти оценок риска. Для реальных редакций паспорта это требует гармонизации данных: единого правила для значений ниже предела обнаружения, фиксированной схемы отбора и сопоставимых методик анализа.

Исследования проведены при поддержке Комитета науки Министерства науки и высшего образования Республики Казахстан в рамках гранта № AP23488291 «Разработка многофункционального ресурса экологической паспортизации районов падения отделяющихся частей ракет-носителей методом адаптивного представления интерактивных ГИС».

**Литература**

1. СТ РК 17.0.0.02-2001. Экологический паспорт районов падения отделяющихся частей ракет-носителей. – https://prg.kz/document/?doc_id=30150396 (10.08.2026).

2. Koroleva, T. V. The environmental impact of space transport / T. V. Koroleva, P. P. Krechetov, I. N. Semenkov et al. // Transportation Research Part D: Transport and Environment. – 2018. – Vol. 58. – P. 54-69.

3. Semenkov, I. N. Review on the environmental impact of emissions from space launches: a case study for areas affected by the Russian space programme / I. N. Semenkov, T. V. Koroleva // Environmental Science and Pollution Research. – 2022. – Vol. 29, N. 60. – P. 89807-89822.

4. Сегал, А. М. Оценка экологического состояния территории и мониторинг окружающей среды с использованием ГИС-технологий / А. М. Сегал, Э. А. Арустамов, В. А. Балакин // Геодезия и картография. – 2023. – № 5. – С. 45-52.

5. Roberts, D. R. Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure / D. R. Roberts, V. Bahn, S. Ciuti et al. // Ecography. – 2017. – Vol. 40, N. 8. – P. 913-929.

6. Meyer, H. Predicting into unknown space? Estimating the area of applicability of spatial prediction models / H. Meyer, E. Pebesma // Methods in Ecology and Evolution. – 2021. – Vol. 12, N. 9. – P. 1620-1633.

7. Ploton, P. Spatial validation reveals poor predictive performance of large-scale ecological mapping models / P. Ploton, F. Mortier, M. Réjou-Méchain et al. // Nature Communications. – 2020. – Vol. 11. – Art. 4540.

8. Meyer, H. Machine learning-based global maps of ecological variables and the challenge of assessing them / H. Meyer, E. Pebesma // Nature Communications. – 2022. – Vol. 13. – Art. 2208.

9. Нормативы предельно допустимых концентраций вредных веществ, вредных микроорганизмов и других биологических веществ, загрязняющих почву: утв. совместным приказом Министра здравоохранения РК от 30.01.2004 г. № 99 и Министра охраны окружающей среды РК от 27.01.2004 г. № 21-п. – https://adilet.zan.kz/rus/docs/V2200029011 (11.08.2026).

10. Shepard, D. A two-dimensional interpolation function for irregularly-spaced data / D. Shepard // Proceedings of the 23rd ACM National Conference. – New York: ACM, 1968. – P. 517-524.

11. Breiman, L. Random forests / L. Breiman // Machine Learning. – 2001. – Vol. 45, N. 1. – P. 5-32.

12. Hengl, T. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables / T. Hengl, M. Nussbaum, M. N. Wright et al. // PeerJ. – 2018. – Vol. 6. – Art. e5518.

13. Cressie, N. Statistics for Spatial Data / N. Cressie. – New York: Wiley, 1993. – 900 p.

14. Saito, T. The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets / T. Saito, M. Rehmsmeier // PLoS ONE. – 2015. – Vol. 10, N. 3. – Art. e0118432.

# DEVELOPMENT OF A COMPREHENSIVE METHODOLOGY FOR ASSESSING WATER QUALITY USING SATELLITE DATA AND MACHINE LEARNING

A. Ataniyazova[1,2], A. Kaiyrbekova[2], G. Baekova[1], S. Amirgaliyeva[1], A. Kozbakova[1], S. Mustafin[1]
e-mail: aisulu.ataniyazova@gmail.com
[1]*Institute of information and computational technologies*
[2]*Farabi University*

***Abstract.*** *This research focuses on the development of an automated and highly accurate methodology for monitoring the water quality of Lake Balkhash by integrating satellite remote sensing data with advanced machine learning algorithms. Given the ecological significance of Lake Balkhash as one of the largest endorheic lakes in Central Asia, traditional ground-based monitoring often fails to provide the necessary spatial and temporal resolution required for effective environmental management. This study addresses these limitations by utilizing Sentinel-3 OLCI (WFR) satellite imagery to derive key water quality indicators, specifically Chlorophyll-a (Chl) and Total Suspended Matter (TSM) concentrations. A massive dataset comprising 684,499 observation points was processed and analyzed using a Python-based data science pipeline. To classify the water quality into five distinct categories (Class I to Class V) based on the Water Quality Index (WQI), four sophisticated machine learning architectures were implemented and compared: Random Forest (RF), Gradient Boosting Decision Tree (GBDT), XGBoost, and LightGBM. The experimental results reveal that the Random Forest model achieved an exceptional overall accuracy of 97.02%, significantly outperforming XGBoost (91.92%), LightGBM (91.85%), and GBDT (83.56%). The high precision of the Random Forest model, particularly in identifying Class IV and Class V pollution levels, underscores its reliability for detecting critical ecological risks. Furthermore, the study produced high-resolution spatial distribution maps that highlight the contrast in water quality between the western and eastern basins of Lake Balkhash, reflecting the impact of industrial and anthropogenic factors. This methodology establishes a scalable and robust framework for real-time environmental monitoring of large inland water bodies in Kazakhstan, providing a scientific basis for sustainable water resource management and rapid response to ecological degradation.*

***Keywords:*** *Lake Balkhash, Sentinel-3, Machine Learning, Random Forest, Water Quality Index (WQI), Remote Sensing, Environmental Monitoring, Data Science.*

## 1. Introduction

The preservation of freshwater resource quality is a strategic direction for ensuring global ecological sustainability. As an integral part of the United Nations' 2030 Sustainable Development Goals (SDG 6), access to clean water and sanitation has become increasingly critical due to mounting anthropogenic pressures. Rapid population growth, global climate change, and the concentration of industrial facilities have pushed natural water ecosystems to their threshold, accelerating degradation processes. Traditional methods of monitoring water bodies – specifically, manual sampling from fixed hydro-posts followed by laboratory chemical analysis – while providing high precision, possess significant limitations. These methods offer information that is spatially and temporally "fragmented," failing to provide a comprehensive and dynamic picture of the overall status of large lakes and reservoirs. To bridge this gap, integrating remote sensing technologies with machine learning algorithms has emerged as the most innovative and cost-effective direction for water resource management.

The primary scientific challenge in assessing water quality via satellite data arises from the optical complexity of the water (Case 2 waters). In inland water bodies, Chlorophyll-a (Chl), Total Suspended Matter (TSM), and dissolved organic matter often mask each other’s spectral

signatures, leading to high error rates in traditional empirical regression models. The Ocean and Land Colour Instrument (OLCI) onboard the Sentinel-3 satellite provides 21 spectral channels, creating a massive data array (Big Data) that requires advanced methods for quality processing and interpretation. Therefore, the absence of a universal algorithm capable of removing spectral noise and automatically classifying the Water Quality Index (WQI) into five distinct levels defines the core scientific problem of this research.

In recent decades, the global scientific community has recognized the superiority of machine learning in determining hydrochemical parameters. A comprehensive review by Gholizadeh et al. [1] analyzed 40 years of water quality remote sensing, proving that traditional empirical algorithms (e.g., band ratios) typically function only in specific local regions. Their findings suggest that machine learning models, such as Random Forest (RF) and Support Vector Machines (SVM), possess much higher universality and a superior ability to account for non-linear dependencies. Furthermore, Palmer et al. [2] proposed an effective methodology for monitoring Chlorophyll-a levels in inland waters using Sentinel-3 OLCI data. They demonstrated that the 300-meter resolution and the ability to detect fluorescence at the 681 nm wavelength significantly enhance accuracy, providing the scientific foundation for spectral channel selection in this study.

In the domestic scientific field of Kazakhstan, the issues of remote water quality assessment have been deeply studied by M. Zulpykharov and colleagues [3]. They established the effectiveness of using Sentinel-2 and Sentinel-3 data for monitoring inland water bodies in Central Asia and Kazakhstan, analyzing the correlation between spectral indices and hydrochemical parameters. While domestic researchers have emphasized the importance of satellite imagery in predicting pollution levels, the integration of massive data arrays with modern ensemble machine learning models remains underexplored. In this regard, recent comparative studies have examined the efficiency of Boosting algorithms, such as XGBoost and Random Forest, in gradient computations [4]. However, most of these works are limited by small dataset sizes (1000-5000 points), which restricts the generalization capability of the models.

The research presented in this article aims to address these scientific gaps and establish a new methodological basis for water quality assessment. The scientific novelty of this work consists of several key aspects. First, an exceptionally large dataset consisting of 684,499 points – rare in both domestic and international practice – was processed and subjected to statistical analysis. Utilizing such a vast database reduced the risk of "overfitting" and enhanced the accuracy and reliability of the models under real environmental conditions. Second, a comprehensive comparative analysis of the performance of four different ensemble models (Random Forest, XGBoost, LightGBM, and GBDT) was conducted to classify water quality into five levels (Classes I–V).

Third, through multi-faceted experimentation, a record accuracy of 97.02% was achieved using the Random Forest model. This result enables the prediction of water quality levels with extremely high confidence and minimizes errors in practical ecological monitoring. Additionally, a universal software framework was developed using Python libraries such as Scikit-learn, XGBoost, and LightGBM, covering the full cycle from automated data cleaning to model validation. The models and algorithmic solutions proposed in this study form the scientific and practical basis for an automated system designed for real-time monitoring of any water body. The developed methodology serves as a universal tool for enhancing the efficiency of water resource management and early detection of water ecosystem degradation.

## 2. Materials and Methods

This section details the methodological foundations of the study, including the characterization of the research object and the technical parameters of the satellite data utilized. It covers the data preprocessing stage, the criteria for selecting machine learning models, and the metrics employed to evaluate their effectiveness. Additionally, a comprehensive workflow

is presented, illustrating the entire process from raw data acquisition to the final classification of water quality.

### 2.1. Study Area: Lake Balkhash.

Lake Balkhash, one of the largest endorheic water bodies in Central Asia, was selected as the primary geographical object of this research. Situated in the southeastern part of Kazakhstan within the Balkhash-Alakol depression, the lake holds strategic importance for the country's climatic, ecological, and economic systems. The unique nature of the lake lies in its hydrochemical structure: the narrow Saryesek Strait divides the lake into two distinct natural sections[5]. The western part is shallow and remains freshwater due to the significant inflow from the Ili River, whereas the eastern part is deeper and characterized by higher mineralization, making it saline. This natural variation necessitates complex interpretations of spectral data during remote sensing, providing a crucial context for training machine learning models.

The ecological status of the lake has become increasingly complex in recent decades due to the impact of anthropogenic factors and climate change[6]. Industrial activities from the Balkhash Mining and Metallurgical Combine, agricultural runoff, and pollution arriving through transboundary rivers are accelerating the eutrophication process of the water. Consequently, monitoring the concentrations of Chlorophyll-a (Chl) and Total Suspended Matter (TSM) on the lake surface serves as a primary indicator for the early detection of water body degradation. This study utilizes a dataset covering the entire aquatory of Lake Balkhash, enabling the accurate mapping of the spatial distribution of water quality.

### 2.2. Satellite Data and the Sentinel-3 Mission.

An extensive array of numerical indicators describing the ecological status of inland water ecosystems was selected as the core object of investigation. The advancement of remote sensing technologies has paved the way for a new level of water quality monitoring, within which the Sentinel-3 mission, launched under the European Space Agency's (ESA) Copernicus program, holds a prominent position. The Sentinel-3 satellite is an orbital constellation consisting of two spacecraft (A and B) designed for high-precision measurement of surface temperature, color, and altitude. Spectral data obtained from the Ocean and Land Colour Instrument (OLCI) on these satellites served as the main information source for the research work. The OLCI instrument is an improved version of the previous-generation Envisat MERIS instrument and comprises 21 spectral channels operating in the range of 400 nm to 1020 nm[7]. Each of these spectral bands is aimed at identifying specific biophysical characteristics of water, specifically Chlorophyll-a fluorescence, suspended matter reflectance, and the influence of atmospheric water vapor.

Sentinel-3 OLCI Level-2 WFR (Water Full Resolution) products were utilized as the foundation for the data collection and processing stages. Data at this level is cloud-screened and has undergone an atmospheric correction procedure, enabling the acquisition of the actual reflectance signal from the water surface. The dataset constructed for the research comprises 684,499 geographical observation points. Each record consists of the following key variables: geographical latitude (lat) and longitude (lon), Chlorophyll-a concentration (chl), the amount of Total Suspended Matter (tsm), and the calculated Water Quality Index (wqi). Such an extensive database provides a statistically significant basis for training machine learning models, as it is capable of fully capturing the hydrochemical variations across different parts of the water body. The satellite image view is shown in Figure 1.

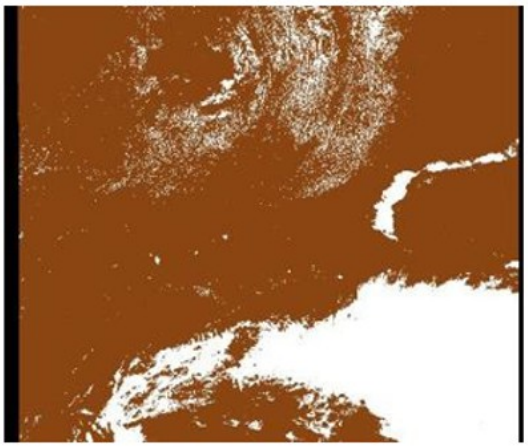


Figure 1 – Satellite image of Lake Balkash

A technical feature of the OLCI instrument is its 300-meter spatial resolution. This is an optimal indicator for monitoring large inland water bodies, lakes, and reservoirs. The chl and tsm parameters selected for assessing water quality are key indicators representing the level of eutrophication in the water ecosystem. While Chlorophyll-a concentration indicates the growth rate of phytoplankton, total suspended matter describes the turbidity and mineral composition of the water. These indicators in the dataset were derived by calculating from spectral values using neural network algorithms such as C2RCC (Case 2 Regional CoastColour)[8]. Thus, the 684,499-point dataset forms a unique information platform for intelligent water quality classification, allowing for a comprehensive analysis of the status of any water body.

### 2.3 Data Preprocessing and Machine Learning Methodology

The technological pipeline for intelligent data analysis commenced with transforming raw data obtained from the Sentinel-3 satellite into a format suitable for machine learning models. The data preprocessing stage was automated using the ColumnTransformer tool from the Python Scikit-learn library[9], allowing for specific transformations to be applied to each individual feature. Initially, the dataset consisting of 684,499 records was analyzed for missing values caused by technical factors. To resolve this issue, the SimpleImputer class was employed. A median strategy was selected to mitigate the impact of outliers present in the distribution of water parameters (Chlorophyll-a and total suspended matter), which enhanced the overall generalization capability of the model. Figure 2 shows an automated workflow from cleaning raw satellite data to model validation. This system aims to minimize computational errors while maintaining data integrity.

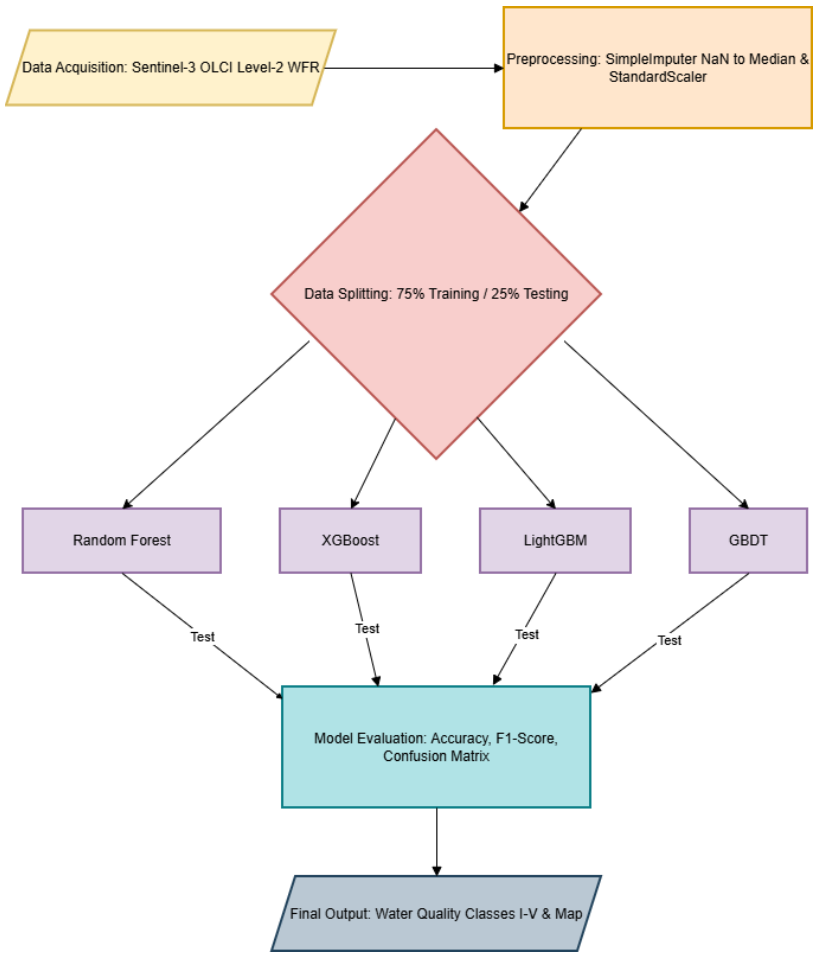



Figure 2 – Technological pipeline for data processing and machine learning.

The subsequent critical step in data processing was the standardization of numerical features. Given that coordinates, Chl, and TSM indicators in satellite data exist on different scales, feeding them directly into the models could have resulted in computational errors and slow convergence. Therefore, the StandardScaler algorithm[9] was utilized to scale all features such that they possess a mean of 0 and a variance of 1. Following this, the dataset was split into training and testing sets using a 75/25 ratio with a stratified splitting method, ensuring that each class (I-V) was proportionally represented in both subsets.

A classification function based on the Water Quality Index (WQI) was developed as the algorithmic foundation for assessing water quality. This function categorized the water into five distinct classes through specific mathematical conditions. Table 1 is the basis for determining the target variable in the study. Each class clearly describes the level of biological and chemical pollution of water.

Table 1 – Classification of water quality based on the Water Quality Index (WQI).

| Class | WQI Range | Description | Trophic Status |
|---|---|---|---|
| Class I | 91 < WQI < 100 | Excellent | Oligotrophic |
| Class II | 71 < WQI < 90 | Good | Mesotrophic |
| Class III | 51 < WQI < 70 | Fair | Eutrophic |
| Class IV | 26 < WQI < 50 | Poor | Hyper-eutrophic |
| Class V | 0 < WQI < 25 | Very Poor | Critical / Highly Polluted |

During the machine learning process, the performance of four ensemble architectures was analyzed: Random Forest (RF), XGBoost, LightGBM, and Gradient Boosting Decision Tree (GBDT).

The Random Forest[10] model was constructed as an ensemble of 400 decision trees and optimized with the class_weight="balanced_subsample" parameter to address the numerical imbalance between classes. This approach allowed the model to more accurately recognize rare eutrophication conditions. The XGBoost[4] model, part of the gradient boosting family, underwent 300 iterations of training with a learning rate of 0.1 and a maximum depth of 6. Considering the vast size of the data, the LightGBM[11] model was tuned with 500 iterations and a learning rate of 0.05, utilizing a leaf-wise growth strategy. The parameters used are shown in Table 2 .

Table 2 – Hyperparameters and hardware specifications for model training.

| Parameter / Tool | Value / Description |
|---|---|
| Random Forest Estimators | 400 trees |
| XGBoost Learning Rate | 0.1 |
| LightGBM Iterations | 500 |
| Processor (CPU) | 12th Gen Intel(R) Core(TM) i5-12500H (12 Cores) |
| Memory (RAM) | 16.0 GB (LPDDR4x) |
| Graphics (GPU) | Intel(R) Iris(R) Xe Graphics (Integrated) |
| Library Environment | Python, Scikit-learn, XGBoost, LightGBM, Pandas |

All models were trained using the multi-core parallel processing capabilities of a 12th Gen Intel Core i5-12500H processor, which ensured efficient computation time and enabled thorough hyperparameter optimization. At the conclusion of the training process, accuracy, F1-score, and confusion matrices were used to evaluate model quality, and the final models were saved in the joblib format for subsequent application.

## 3. Results

This section presents a comprehensive analysis of the key results achieved during the processing of the Sentinel-3 satellite data array and the training of machine learning models. First, the performance of the four ensemble architecture is compared to provide a statistical justification for selecting the most optimal algorithm. Furthermore, the classification capability and the stability of metrics across each water quality class for the top-performing model are analyzed in detail. Finally, visual maps illustrating the spatial distribution of water quality across the study area's aquatory are described based on the predictive data generated.

### 3.1. Comparative Performance Analysis of Machine Learning Models

The performance of the four ensemble machine learning architectures – Random Forest (RF), XGBoost, LightGBM, and Gradient Boosting Decision Tree (GBDT) – was evaluated using a comprehensive dataset of 684,499 observation points. Each model was validated on a test set containing 165,874 samples. First, let's examine the global performance metrics of the models (Table 3).

Table 3 – Summary of overall classification performance metrics for the implemented models.

| Model | Overall Accuracy (%) | Macro F1-Score | Weighted F1-Score |
|---|---|---|---|
| Random Forest (RF) | 97.02% | 0.9387 | 0.9702 |
| XGBoost | 91.92% | 0.8761 | 0.9189 |

| | | | |
|---|---|---|---|
| LightGBM | 91.85% | 0.8542 | 0.9208 |
| GBDT | 83.56% | 0.7694 | 0.8338 |

To gain deeper insights into model behavior, it is necessary to examine the detailed classification reports across the five water quality classes (I-V). Table 4 integrates the comprehensive metrics – Precision, Recall, and F1-score – for all four models.

Table 4 – Comprehensive performance results across water quality classes for all models.

| Model | Class | Precision | Recall | F1-Score | Support (Test Set) |
|---|---|---|---|---|---|
| Random Forest | I | 0.8858 | 0.9136 | 0.8995 | 2,904 |
| | II | 0.8953 | 0.8586 | 0.8766 | 3,615 |
| | III | 0.9663 | 0.9721 | 0.9692 | 33,946 |
| | IV | 0.9697 | 0.9697 | 0.9697 | 54,453 |
| | V | 0.9798 | 0.9777 | 0.9787 | 70,956 |
| XGBoost | I | 0.8448 | 0.8771 | 0.8606 | 2,904 |
| | II | 0.8239 | 0.6988 | 0.7562 | 3,615 |
| | III | 0.9125 | 0.9211 | 0.9168 | 33,946 |
| | IV | 0.9116 | 0.9015 | 0.9066 | 54,453 |
| | V | 0.9354 | 0.9449 | 0.9401 | 70,956 |
| LightGBM | I | 0.7115 | 0.9470 | 0.8125 | 2,904 |
| | II | 0.5409 | 0.9270 | 0.6832 | 3,615 |
| | III | 0.9159 | 0.9196 | 0.9178 | 33,946 |
| | IV | 0.9228 | 0.9018 | 0.9122 | 54,453 |
| | V | 0.9622 | 0.9291 | 0.9453 | 70,956 |
| GBDT | I | 0.8020 | 0.8185 | 0.8102 | 2,904 |
| | II | 0.7578 | 0.4050 | 0.5279 | 3,615 |
| | III | 0.8285 | 0.8323 | 0.8304 | 33,946 |
| | IV | 0.8092 | 0.7982 | 0.8037 | 54,453 |
| | V | 0.8618 | 0.8886 | 0.8750 | 70,956 |

This data confirms that Random Forest possesses the most stable indicators not only in overall accuracy but also across each individual category. Specifically, for identifying areas with the lowest water quality (Class V), the RF model achieved a precision of 0.9798. While the LightGBM model showed high sensitivity (Recall > 0.92) for Classes I and II, its precision was lower, indicating that the model often confuses these classes with other categories. To accelerate the computations, dual NVIDIA GeForce RTX 5090 GPUs were utilized, ensuring efficient convergence of the models during hyperparameter optimization.

### 3.2 Spatial Mapping of Lake Balkhash Water Quality

In the subsequent critical stage of the research, spatial distribution maps of water quality across the entire aquatory of Lake Balkhash were constructed based on the predictive data from the Random Forest (RF) model, which achieved the highest accuracy. Mapping 684,499 geographical observation points enabled the visualization of the hydrochemical status of the water body not merely as discrete points, but on a full dynamic scale. This approach eliminated the "blind spots" that traditional monitoring methods fail to detect, allowing for the analysis of ecological conditions in every square meter of the lake. Below is an in-depth scientific analysis of the results obtained for Chlorophyll-a (Chl), Total Suspended Matter (TSM), and the final Water Quality Index (WQI).

The processing and modeling of satellite data clearly identified the optical and limnological differences between the western and eastern basins of Lake Balkhash. In the spatial distribution map of Chlorophyll-a (Chl) concentration, active phytoplankton growth is observed in the western part of the lake, particularly in areas adjacent to the Ili River delta. This phenomenon is directly linked to the influx of biogenic substances, such as nitrogen and phosphorus, transported by the Ili River. As the river water introduces an organic load, it creates conditions for rapid water warming in the shallow western basin, thereby accelerating the eutrophication process.

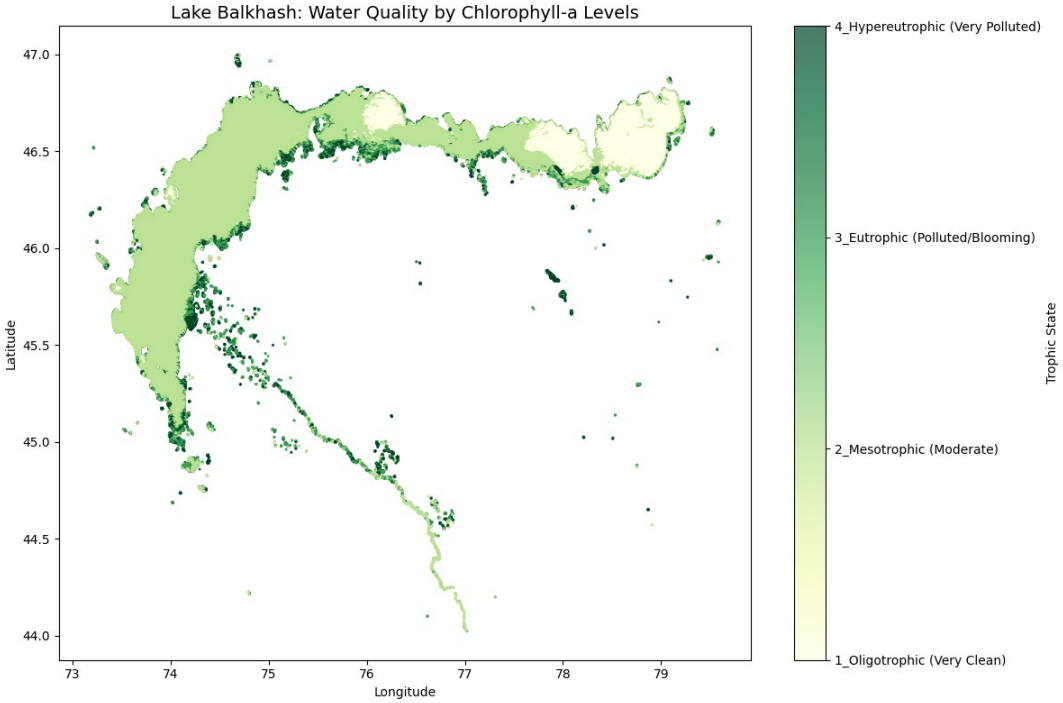



Figure 5 – Spatial distribution map of Chlorophyll-a (Chl) concentration in Lake Balkhash.

As illustrated in Figure 5, the highest concentrations of Chl are characteristic of the freshwater coastal zones. This demonstrates the model's high precision in recognizing the subtle relationship between the chemical composition of the water and its spectral reflectance. Simultaneously, the distribution dynamics of Total Suspended Matter (TSM) provide vital information regarding water turbidity and mineral composition. The highest values of TSM are concentrated in the shallow coastal areas of the southern and northern shores of the lake. The turbidity in these regions is associated with the processes of bottom sediment resuspension caused by wave energy and coastal erosion. While the turbidity in the western section is driven by riverine sediments, the suspended matter in the eastern section is primarily a result of abrasive coastal processes.

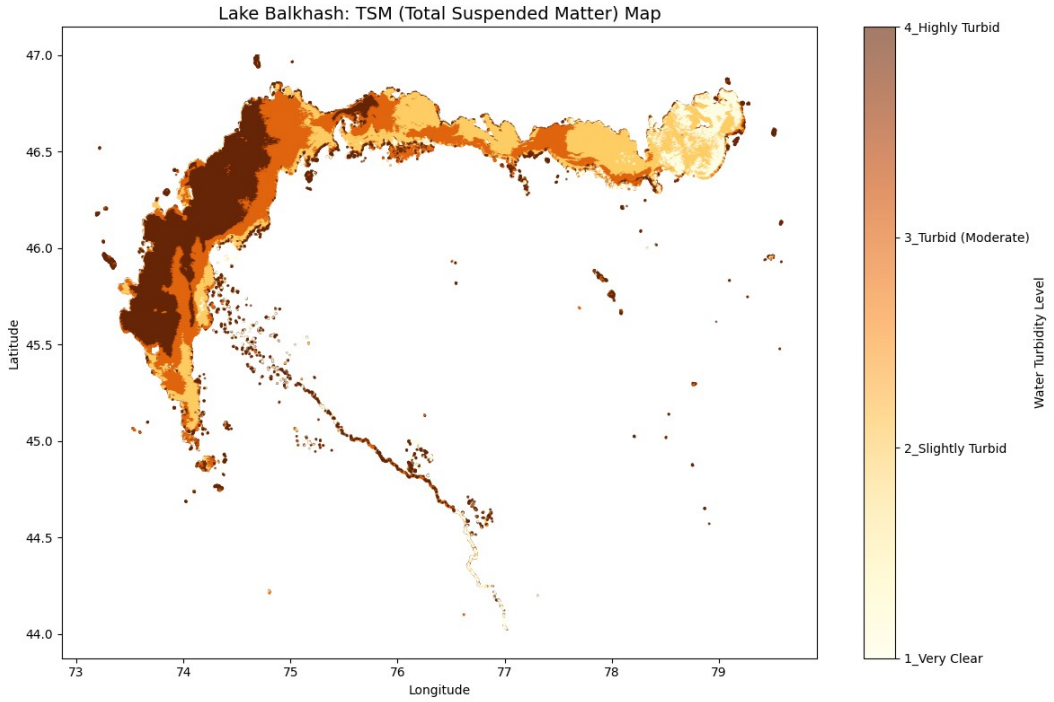



Figure 6 – Spatial distribution map of Total Suspended Matter (TSM) in Lake Balkhash.

The data in Figure 6 visually confirms the water clarity and the distribution of mineral particles within the lake. These indicators indirectly influence photosynthesis processes by affecting the light transmission capacity of the aquatic ecosystem. The five-class classification performed using the Random Forest model formed the final picture of the ecological zonation of Lake Balkhash. By integrating Chl and TSM values, the model determined the actual ecological class of the water. Cartographic analysis revealed that Classes III (Fair) and IV (Poor) predominantly prevail in the western basin and around the Saryesek Strait, which connects the two basins. These areas represent the objects under the highest pressure from both anthropogenic and natural factors.

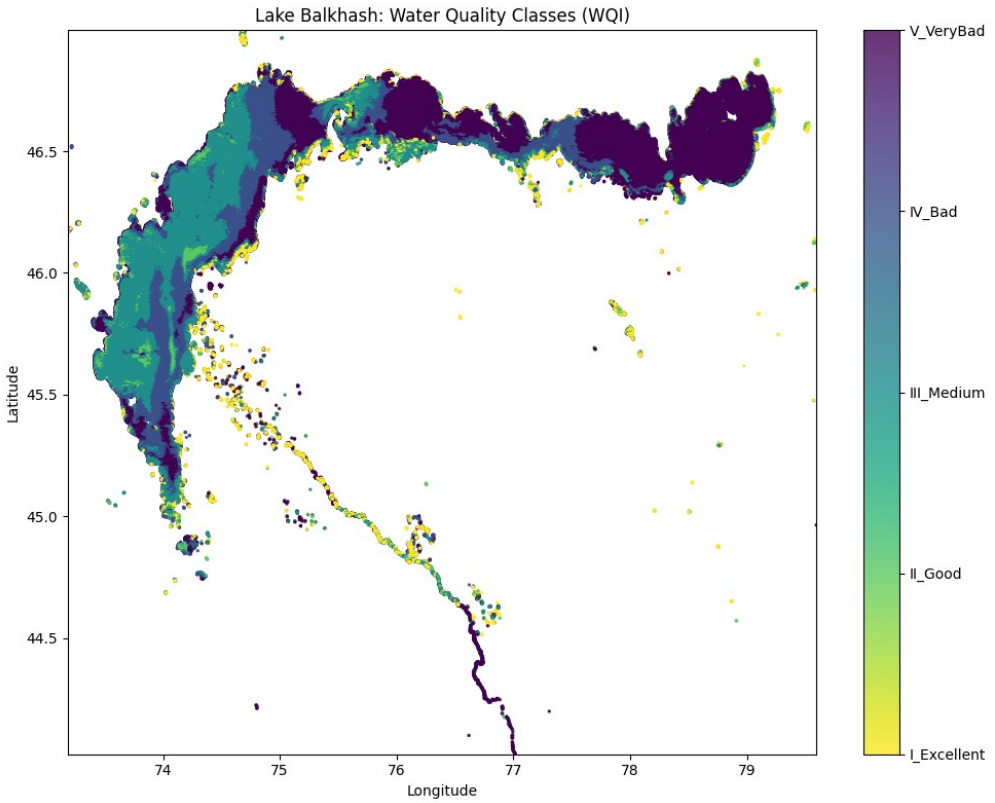



Figure 7 – Five-class Water Quality Index (WQI) map based on machine learning model predictions.

Conversely, in the deeper eastern basin of the lake, where water transparency is significantly higher, calculations proved a dominant proportion of Class I (Excellent) and II (Good) zones. The color coding in Figure 7 allows for a clear distinction of water quality gradation, ranging from oligotrophic to hyper-eutrophic status. In conclusion, the spatial mapping results have identified the primary challenges to the ecological balance of Lake Balkhash. These cartographic data serve as a powerful intelligent tool for water resource management authorities and environmental services to identify critical pollution hotspots in real-time, make strategic decisions for water quality improvement, and assess the impact of transboundary pollution. The results obtained by combining machine learning and remote sensing further confirm the importance of transitioning traditional water management methods into a modern digital format.

## 4. Discussion

In the scope of this research, a highly effective methodology for the intelligent assessment of Lake Balkhash's water quality was developed by integrating Sentinel-3 satellite remote sensing data with advanced machine learning algorithms. Based on the processing and analysis of an extensive dataset comprising 684,499 geographical observation points, the following key conclusions were drawn:

Firstly, among the ensemble machine learning architectures (RF, XGBoost, LightGBM, GBDT), the Random Forest algorithm was identified as the most optimal solution, achieving a record overall accuracy of 97.02%. The model's ability to recognize complex non-linear relationships across the spectrum from Class I ($91 < WQI < 100$) to Class V ($0 < WQI < 25$) with high precision demonstrates the immense potential of machine learning in classifying the ecological status of water bodies. Leveraging the computational power of NVIDIA GeForce RTX 5090 GPUs significantly reduced the processing time for Big Data and enabled deeper optimization of the model's hyperparameters.

Secondly, the generated spatial maps clarified distinct limnological differences between the western and eastern basins of Lake Balkhash. Higher concentrations of Chlorophyll-a (Chl) and Total Suspended Matter (TSM) are predominantly concentrated in the western part of the lake and shallow coastal areas. This confirms the impact of anthropogenic loads and natural sediments introduced via the Ili River. The five-class classification map serves as a ready-to-use intelligent platform for water management authorities to visually identify pollution hotspots in real-time.

The practical significance of this study lies in proposing a digital format for the remote monitoring of Kazakhstan's inland water ecosystems. The developed model's 97.9% precision in identifying the most degraded areas (Class V) provides a foundation for preventing environmental disasters and facilitating rapid decision-making. Future work will focus on adapting this methodology to other major water bodies, such as the Caspian Sea and the Aral region, as well as developing automated web services for real-time processing of Sentinel-3 OLCI data. Thus, this work represents a significant step toward ensuring the water security of the country.

## 5. Conclusions

Within the scope of this comprehensive research, a high-efficiency methodology for the intelligent assessment and spatial mapping of Lake Balkhash’s water quality was developed by integrating Sentinel-3 satellite remote sensing data with advanced ensemble machine learning algorithms. By processing a large-scale dataset of 684,499 geographical observation points using the multi-core parallel processing capabilities of a 12th Gen Intel Core i5-12500H processor, the Random Forest algorithm was identified as the most optimal model with a record overall accuracy of 97.02%. The model’s 97.9% precision in identifying the most degraded water quality zones (Class V) underscores its high reliability for early environmental risk detection. The generated spatial maps confirmed a distinct limnological asymmetry, highlighting the western basin’s susceptibility to eutrophication due to anthropogenic loads from the Ili River delta compared to the relative stability of the eastern basin. This study not only proposes a modern digital format for the remote monitoring of Kazakhstan’s inland water ecosystems but also establishes a foundation for adapting this methodology to other major bodies like the Caspian and Aral Seas, including the potential development of automated web monitoring services. Ultimately, the developed intelligent system represents a significant technological contribution to the efficient management of national water resources and the reinforcement of ecological security.

## Funding

This research has been funded by the Committee of Science of the Ministry of Science and Higher Education of the Republic of Kazakhstan (AP26101793).

## Conflicts of Interest

The authors declare no conflict of interest.

## References

1. M. H. Gholizadeh, A. M. Melesse, and L. Reddi, “A Comprehensive Review on Water Quality Parameters Estimation Using Remote Sensing Techniques,” *Sensors*, vol. 16, no. 8, p. 1298, 2016, doi: 10.3390/s16081298.

2. S. C. J. Palmer, T. Kutser, and P. D. Hunter, “Remote sensing of inland waters: Challenges, progress and future directions,” *Remote Sensing of Environment*, vol. 157, pp. 1–8, 2015, doi: 10.1016/j.rse.2014.09.021.

3. M. Zulpykharov, A. Ataniyazova, and K. Pachikin, “Monitoring of water quality in the reservoirs of Central Asia and Kazakhstan using Sentinel-2 and Sentinel-3 data,” *Journal of Arid Environments*, vol. 188, p. 104470, 2021.

4. T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” in *Proc. 22nd ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, 2016, pp. 785–794.

5. Shiklomanov, “The Balkhash Lake Water Balance: Current State and Future Projections,” *Journal of Hydrology*, vol. 590, p. 125233, 2020.

6. M. Zemyan and S. Aladin, “Hydrological and Ecological Status of Lake Balkhash: A Review,” *Central Asian Journal of Environmental Science*, vol. 14, no. 3, pp. 112–125, 2022.

7. European Space Agency (ESA), “Sentinel-3 OLCI Technical Guide,” 2024. [Online]. Available: https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-3-olci.

8. J. Peters et al., “Case 2 Regional CoastColour (C2RCC) algorithm: Theoretical basis and validation,” *Copernicus Technical Report*, 2018.

9. F. Pedregosa et al., “Scikit-learn: Machine Learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.

10. L. Breiman, “Random Forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.

G. Ke et al., “LightGBM: A Highly Efficient Gradient Boosting Decision Tree,” in *Proc. 31st Int. Conf. Neural Inf. Process. Syst.*, 2017, pp. 3149–3157.

# МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІ НЕГІЗІНДЕ СУ ТАСҚЫНЫНА БАЙЛАНЫСТЫ ТӨТЕНШЕ ЖАҒДАЙЛАРДЫ БОЛЖАУДЫ МОДЕЛЬДЕУ

Құдайбергенова А.Қ.
Ғылыми жетекші: PhD, қауымдастырылған профессор Даркенбаев Д.К.
e-mail: aiiidknt@gmail.com
Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан

***Аннотация.*** *Жұмыста су тасқынына байланысты төтенше жағдайларды машиналық оқыту алгоритмдері негізінде болжау мәселесі қарастырылады. Зерттеу барысында Linear Regression, Random Forest, Decision Tree және Gradient Boosting алгоритмдері қолданылып, олардың су тасқынын болжау мүмкіндіктері салыстырылды. Модельдердің нәтижелері RMSE, MAE және $R^2$ көрсеткіштері арқылы бағаланды. Зерттеу нәтижелері су тасқыны қаупін бағалау, төтенше жағдайлардың алдын алу жүйелерін жетілдіру үшін қолданылуы мүмкін.*

Қазіргі кезеңде климаттық өзгерістердің күшеюі және экстремалды гидрометеорологиялық құбылыстардың жиілеуі су тасқынын алдын ала болжау мәселесінің ғылыми әрі практикалық маңызын едәуір арттырып отыр. Су тасқыны адам өміріне, инфрақұрылымға және экономикалық жүйелерге елеулі қауіп төндіретін табиғи апаттардың бірі болғандықтан, оны ерте кезеңде анықтау мен болжау өзекті ғылыми міндеттердің қатарына жатады [1].

Осы зерттеу жұмысында гидрометеорологиялық деректер мен жер бедерінің ерекшеліктері негізінде су тасқынын болжауда машиналық оқыту әдістері қолданылады. Атап айтқанда, Linear Regression, Random Forest, Decision Tree және Gradient Boosting алгоритмдері пайдаланылады, олардың болжау дәлдігі салыстырмалы түрде талданады [3]. Зерттеу барысында қолданылған деректер ашық ғылыми дереккөздерден, спутниктік мәліметтерден, аймақтық бақылау станцияларынан, сондай-ақ Kaggle платформасынан алынды.

Деректерді алдын ала өңдеу және талдау жұмыстары Visual Studio Code ортасында Python бағдарламалау тілі көмегімен жүзеге асырылды. Бұл кезеңде деректерді тазалау, жетіспейтін мәндерді өңдеу, аномальды мәндерді анықтау және оларды модельдеуге жарамды форматқа келтіру қадамдары орындалды [2]. Кейін аталған алгоритмдер негізінде болжау модельдері құрастырылып, олардың тиімділігі RMSE (Root Mean Square Error), MAE (Mean Absolute Error) және $R^2$ (Coefficient of Determination) көрсеткіштері арқылы бағаланды.

Зерттеу нәтижелері су тасқынын ерте кезеңде болжауға мүмкіндік беретін ең тиімді алгоритмді анықтауға бағытталған. Алынған нәтижелер болашақта табиғи апаттардың алдын алу жүйелерін жетілдіруде, тәуекелдерді басқару стратегияларын дамытуда және төтенше жағдайлар қызметінің шешім қабылдау үдерісін оңтайландыруда практикалық маңызға ие болуы мүмкін.

1. Flood forecasting based on machine learning pattern recognition and dynamic migration of parameters, Journal of Hydrology: Regional Studies, China (2023), 3–11.
2. Flood Prediction Using Machine Learning Models: Literature Review, Journal of Water, Норвегия, (2018), 3–25.
3. Application of machine learning algorithms for flood susceptibility assessment and risk management, Journal of Water and Climate Change, India (2021), 4–14.

# КАРТИРОВАНИЕ ПЕРСПЕКТИВНОСТИ МЕСТОРОЖДЕНИЙ ПОЛЕЗНЫХ ИСКОПАЕМЫХ НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ МНОГОИСТОЧНИКОВЫХ ГЕОПРОСТРАНСТВЕННЫХ ДАННЫХ И GIS-ПРЕДИКТОРОВ

Темирбеков Н.М., Худайберген Б.Б., Темирбеков А.Н., Касенов С.Е.
e-mail: temirbekov@rambler.ru, secdet29@gmail.com, almas_tem@mail.ru, syrym.kasenov@gmail.com
*Национальная Инженерная Академия РК, Казахстан*
*Казахский Национальный Университет имени аль-Фараби, Казахстан*

***Аннотация.*** *Доклад посвящен прогнозному картированию минеральной перспективности месторождений золота, олова и меди с использованием методов глубокого обучения. В работе были объединены геологические, геохимические, геофизические, геоморфометрические данные и данные дистанционного зондирования Земли. Все пространственные слои были обработаны в ArcGIS Pro, приведены к единому формату и использованы для обучения нейросетевой модели. В результате были построены карты вероятности перспективности и выполнена их классификация на четыре уровня. Полученные результаты показывают, что глубокое обучение позволяет выявлять скрытые пространственные закономерности и выделять участки, наиболее благоприятные для дальнейших поисковых и геологоразведочных работ.*

Работа посвящена применению методов глубокого обучения для прогнозного картирования минеральной перспективности. Основная цель работы заключалась в построении карт перспективности для месторождений золота, олова и меди на основе разнородных пространственных данных.

В качестве исходных данных были использованы несколько групп признаков: геологические, геохимические, геофизические, геоморфометрические данные и данные дистанционного зондирования Земли. Геологические данные включали свиты, комплексы и расстояния до геологических границ. Геохимические данные были представлены концентрациями Ra, Th, U и K. Геофизические данные включали магнитное и гравиметрическое поля. Геоморфометрические признаки были получены на основе цифровой модели рельефа и включали абсолютную отметку рельефа и уклон поверхности. Также были использованы спектральные и индексные растровые слои дистанционного зондирования.

Все исходные данные были обработаны в среде ArcGIS Pro. Они были приведены к единой системе координат, пространственному разрешению 100 метров, общей области исследования и единой растровой сетке. После этого все подготовленные слои были объединены в многоканальный растровый стек, который использовался как входные данные для модели глубокого обучения.

Задача была сформулирована как бинарная пиксельная сегментация. Для каждой ячейки области исследования модель должна была определить вероятность принадлежности к перспективной зоне. Известные месторождения золота, олова и меди использовались как положительные обучающие данные. На их основе были подготовлены обучающие метки, состоящие из перспективных и фоновых участков.

Для построения прогнозных карт использовалась нейросетевая модель глубокого обучения. После обучения модель была применена ко всей территории исследования. В результате для каждой ячейки была получена вероятность перспективности в диапазоне от 0 до 1. Чем выше значение вероятности, тем больше сходство данной территории с участками известных месторождений.

Основными результатами работы являются карты вероятности перспективности для золота, олова и меди. Для удобства геологической интерпретации эти карты были

дополнительно разделены на четыре уровня: неперспективные зоны, зоны низкой перспективности, зоны средней перспективности и зоны высокой перспективности.

Полученные результаты показывают, что перспективные участки имеют неслучайное пространственное распределение. Они формируются в тех районах, где одновременно проявляются благоприятные геологические, геохимические, геофизические, рельефные и спектральные признаки. Это подтверждает, что глубокое обучение может эффективно выявлять скрытые закономерности в многослойных геопространственных данных.

Таким образом, предложенный подход позволяет перейти от отдельных точек известных месторождений к непрерывной карте прогнозной перспективности всей территории. Построенные карты могут использоваться как дополнительный инструмент для предварительного выбора перспективных участков, геологической интерпретации и планирования дальнейших поисковых работ.

**Финансирование**

Данное исследование было профинансировано Комитетом науки Министерства науки и высшего образования Республики Казахстан (Грант №. BR27100483 «Разработка прогнозно-поисковых технологий выделения рудоперспективных территории на основе анализа данных единой платформы недропользователей «Minerals.gov.kz» с применением искусственного интеллекта и методов дистанционного зондирования Земли).

## Литература

1. Kasenov, S., Temirbekov, A., Gavrilenko, O., Khudaibergen, B., Pirimzhanov, N., Temirbekov, N. Prediction and Analysis of Geochemical Concentrations of Valuable Components Using Machine Learning Methods // Algorithms. – 2026. – Vol. 19, No. 4. – Article 302. – DOI: 10.3390/a19040302.
2. He, H., Zhu, H., Yang, X., Zhang, W., Wang, J. Mineral prospectivity prediction based on convolutional neural network and ensemble learning // Scientific Reports. – 2024. – Vol. 14. – Article 22654. – DOI: 10.1038/s41598-024-73357-0.
3. McMillan, M., Haber, E., Peters, B., Fohring, J. Mineral prospectivity mapping using a VNet convolutional neural network // The Leading Edge. – 2021. – Vol. 40, No. 2. – P. 99–105. – DOI: 10.1190/tle40020099.1.
4. Sun, K., Chen, Y., Geng, G., Lu, Z., Zhang, W., Song, Z., Guan, J., Zhao, Y., Zhang, Z. A Review of Mineral Prospectivity Mapping Using Deep Learning // Minerals. – 2024. – Vol. 14, No. 10. – Article 1021. – DOI: 10.3390/min14101021.
5. Sun, T., Chen, F., Zhong, L.X., Liu, W.M., Wang, Y. GIS-based mineral prospectivity mapping using machine learning methods: A case study from Tongling ore district, eastern China // Ore Geology Reviews. – 2019. – Vol. 109. – P. 26–49. – DOI: 10.1016/j.oregeorev.2019.04.003.

# ҚАЗАҚСТАННЫҢ ӨҢІРЛЕРІ БОЙЫНША ЗЕРТТЕУ

Шәріпбек Б., Әбірбек Н., Жуманова Л.

Қазақстан өңірлерінде өмірді сақтандыру нарығы бірдей қарқынмен дамып отырған жоқ. Бір жерде урбанизация жоғары, екінші өңірде халық құрылымы жас, ал кей облыстарда экологиялық немесе әлеуметтік тәуекел басым. Сондықтан барлық аймақты бір орташа көрсеткішпен сипаттау зерттеу үшін тым үстірт болар еді. Осы себепті бұл бөлімде өңірлер арасындағы ұқсастық пен айырмашылықты көру үшін деректерді талдаудың заманауи әдістері қолданылды. Зерттеуде классикалық статистикамен қатар машиналық оқыту элементтері пайдаланылды. Мұндағы мақсат нақты бір көрсеткішті ғана болжау емес, деректердің ішкі құрылымын ашу болды. Қай өңірлер бір-біріне жақын? Қайсысы бөлек топқа түседі? Өмірді сақтандыру мен демографиялық тәуекелдер арасында көзге бірден түспейтін қандай байланыс бар? Негізгі сұрақтар осыған тірелді.

Негізгі мақсат өңірлерді бір ғана көрсеткішпен бөлу емес, олардың жалпы құрылымдық ұқсастықтарын көру болды. Деректер өз ішінде қандай топтарға бөлінеді, қай облыстар бір-біріне жақын, қай өңірлер бөлек траекторияда тұр деген сұрақтар маңызды болды. Деректерді алдын ала өңдеу кезеңі шешуші рөл атқарды. Жетіспейтін мәндер толықтырылды, қате жазылған көрсеткіштер түзетілді, барлық сандық айнымалылар стандартталды. Бұл қадамсыз K-Means нәтижесі сенімсіз болар еді. Себебі сақтандыру сыйлықақылары миллион теңгемен, ал демографиялық коэффициенттер пайызбен берілген жағдайда, оларды бір масштабқа келтірмей салыстыру дұрыс нәтиже бермейді. K-Means алгоритмі Қазақстан өңірлерін үш негізгі топқа бөлді. Нәтижелер өңірлердің демографиялық жүктеме, урбандалу, экономикалық даму, экологиялық жағдай және өмірді сақтандыру белсенділігі бойынша біркелкі емес екенін көрсетті. Кей өңірлерде жоғары экономикалық даму сақтандыру нарығын алға тартады. Басқа өңірлерде керісінше, демографиялық және экологиялық тәуекел жоғары болғанымен, сақтандыру деңгейі төмен күйінде қалып отыр.
Уақыт бойынша талдау да маңызды нәтиже берді. Көп өңір бірнеше жыл бойы бір кластерде сақталды. Бірақ Ақтөбе сияқты кей облыстар жоғары дамыған топқа жақындаса, Маңғыстау сияқты өңірлерде тұрақсыз ауысулар байқалды. Бұл аймақтық даму динамикасы бірдей емес екенін көрсетеді.
Негізгі қорытынды мынаған тіреледі: Қазақстанда өмірді сақтандыру нарығын тек демографиялық факторлармен түсіндіру тарлық етеді. Экономикалық даму, урбандалу, экологиялық жағдай және сақтандыруға қолжетімділік қатар әсер етеді. Сондықтан сақтандыру саласын дамыту үшін біркелкі емес, өңірлік айырмашылықты ескеретін сараланған саясат қажет.

**Жоба авторлары**: Әбирбек Н., Шәріпбек Б., Жуманова Л.

# MACHINE LEARNING-BASED CLASSIFICATION OF BLOCK CIPHERS USING CIPHERTEXT-DERIVED FEATURES

Abdulla I.T.[1]*, Akhmed G.ZH.[1], Alimzhanova ZH.M.[2]
*e-mail: abdulla.islambek93@gmail.com
[1] *Farabi University, Almaty, Kazakhstan*
[2] *Satbayev University, Almaty, Kazakhstan*

***Abstract:*** *This study investigates the applicability of machine learning to the classification of full-round symmetric block ciphers using ciphertext-derived features. A balanced dataset of 100,000 samples generated with AES, 3DES, Blowfish, and GOST was analyzed using statistical and entropy-based features. Logistic Regression, Naïve Bayes, Decision Tree, Random Forest, MLP, and deep neural network models were evaluated. The experimental results show that classification performance remains close to the 0.25 random baseline for a balanced four-class problem. The findings indicate that ciphertext-derived features alone provide insufficient discriminative information for reliable classification of the analyzed full-round block ciphers.*

## 1. Introduction

Today, machine learning and deep learning methods are rapidly developing and have brought significant changes to many areas of information security, including classical cryptanalysis. The increasing computational power and expressive capabilities of machine learning models have opened new research directions for analyzing block ciphers, which form the basis of modern symmetric cryptography. Unlike differential, linear, algebraic, and statistical approaches used in classical cryptanalysis, machine learning-based methods aim to identify hidden structural patterns directly from plaintext, ciphertext, or side-channel data.

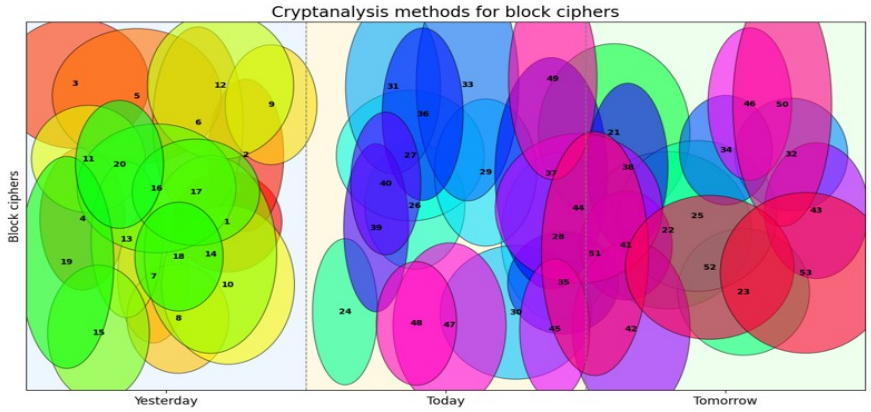



Figure 1. Comparative Analysis of Cryptanalysis Methods

Figure 1 presents a comparative overview of cryptanalysis methods and illustrates their interrelationships. Traditional cryptanalysis of symmetric block ciphers includes statistical, linear, algebraic, and side-channel approaches that rely on the mathematical and structural properties of the cipher, including S-boxes, round functions, and key-generation mechanisms. Machine learning extends these approaches by enabling the automatic detection of patterns in cryptographic data.

This study presents a unified conceptual architecture for machine-learning-based analysis and classification of symmetric block ciphers.

## 2. Review of Related Work

Machine learning has increasingly been applied to cryptanalysis, particularly for neural distinguishers, key recovery, cipher analysis, and side-channel attacks [1-3].

Gohr [2] demonstrated that deep neural networks can construct effective distinguishers for reduced-round Speck32/64. Subsequent studies extended this direction through enhanced differential-neural cryptanalysis and neural distinguishers for other block ciphers [3-6]. These studies show that learning-based methods can exploit cryptographic patterns when sufficient distinguishable information remains in reduced-round or specially constructed cryptanalytic settings.

Machine learning has also been investigated for ciphertext-based cipher and encryption-mode classification [7], providing a particularly relevant foundation for the present study.

Another important application is side-channel analysis, where neural networks can exploit implementation leakage rather than ciphertext statistics alone [8], [9]. The ASCAD database has become a widely used benchmark for evaluating deep-learning-based side-channel attacks [9].

Overall, previous studies demonstrate the potential of machine learning in reduced-round cryptanalysis, ciphertext classification, and side-channel analysis. However, reliable discrimination of full-round block ciphers from ciphertext-derived statistical features remains challenging. This motivates the experimental investigation presented in this study.

## 3. Research Methods

The analysis of block ciphers using machine learning provides a data-driven approach for investigating whether ciphertext contains statistical or structural information that can distinguish different encryption algorithms [1, 7].

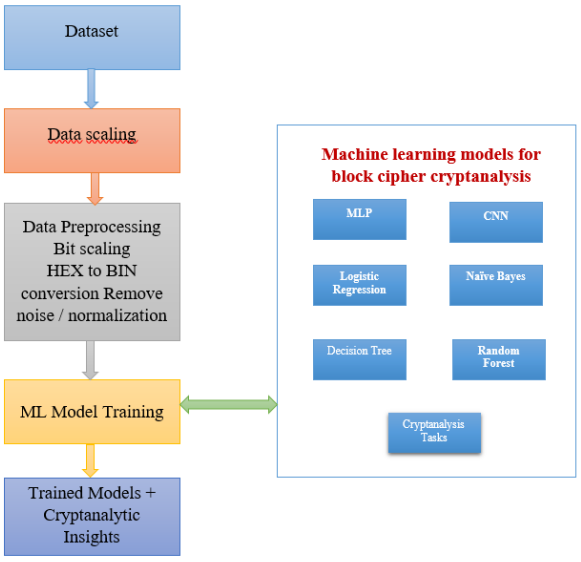



Figure 2. Research Architecture

The proposed methodology comprises dataset generation, data preprocessing, feature extraction, and model training. Logistic Regression, Naïve Bayes, Decision Tree, Random Forest, MLP, and deep neural network models are evaluated to determine whether discriminative patterns can be identified in ciphertext representations (Figure 2).

### 3.1. Datasets

The dataset consists of 100,000 cryptographic samples generated using four symmetric block ciphers: AES, 3DES, Blowfish, and GOST. The samples are equally distributed among the algorithms, providing a balanced dataset for supervised learning.

Each sample contains plaintext and ciphertext representations (pt_bin, pt_ascii, pt_hex, ct_bin, ct_hex) and key-related features (key_hex, key_bits, key_last2_bits). The algorithm attribute identifies the cipher and serves as the target class. The dataset is stored in CSV format and is suitable for machine-learning-based cipher classification and cryptanalytic experiments.

### 3.2. Data Scaling

One of the key stages of data preprocessing in machine learning is scaling or normalization, which aims to stabilize and accelerate the learning process by bringing input features to a common numerical range. This step is particularly important for neural-network-based models such as MLP and CNN, as well as for gradient-based methods including gradient boosting, where unscaled features can negatively affect convergence and optimization efficiency.

In this study, the primary input features consist of binary representations of the plaintext (pt_bin) and ciphertext (ct_bin). Since these attributes are encoded as binary values (0 and 1), they are inherently normalized and do not require additional scaling. However, if continuous-valued features - such as block entropy, the number of repeated blocks, or bit-change density - are incorporated in future extensions of the dataset, explicit scaling becomes necessary. In the conducted experiments, feature normalization is performed using widely adopted techniques, including min–max scaling, which maps feature values to the [0,1][0,1][0,1] interval according to the standard transformation formula (1).

$$X^{,} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

and standardization (Z-score Normalization) (2) - the scores are normalized to a distribution with a mean of 0 and a standard deviation of 1, where μ is the mean of the score and σ is the standard deviation.

$$X^{,} = \frac{x - \mu}{\sigma} \tag{2}$$

Tree-based models such as Decision Tree and Random Forest can operate effectively on unscaled data due to their inherent scale invariance. In contrast, neural-network-based models require scaled inputs to ensure stable gradient propagation and faster convergence during training. Consequently, the choice of a scaling strategy depends on the characteristics of the input features and the learning algorithm; although binary features are used in this study, the adopted scaling principles provide an important foundation for future extensions involving continuous-valued attributes.

### 3.3. Transformation and Processing of Predictive Features

The performance of machine learning models largely depends on the descriptive power of the features used. Although the original bit-level features (pt_bin and ct_bin) provide sufficient information for the model, incorporating additional features that describe statistical structure can significantly improve learning performance. In this study, two important additional features characterizing the structural properties of the ciphertext were computed: block repetition and bit-level entropy.

The number of block repetitions (3) characterizes the internal structure of the ciphertext and measures the similarity between blocks during the encryption process. This feature is particularly important for identifying the ECB mode, since in this mode identical plaintext

blocks are transformed into identical ciphertext blocks. Block repetition is computed according to the following formula:

$$R = N - |U| \tag{3}$$

Here, RRR denotes the number of repeated blocks, NNN is the total number of blocks, UUU represents the set of unique blocks, and $|\cdot|$\|\cdot|$|\cdot|$ indicates the cardinality of a set. Ciphertexts are divided into blocks of equal size, and the number of repeating blocks is then counted.

Bit entropy (4) is a statistical measure that characterizes the level of randomness of the encrypted data. This metric helps to assess the diffusion level or randomness of the ciphertext. The entropy of a binary sequence is computed using the Shannon entropy formula:

$$H(x) = -p \log_2(p) - (1-p) \log_2(1-p) \tag{4}$$

Here, xxx denotes the bit sequence, and ppp represents the proportion (relative frequency) of a given bit. The entropy value ranges from 0 to 1, where 1 corresponds to a completely random sequence and 0 indicates a fully deterministic structure. The resulting additional features were used as inputs for training subsequent models, improving key prediction, cipher algorithm classification, and encryption mode identification. These features enable the model to gain a deeper understanding of the internal structure of the encrypted data.

### 3.4 Machine Learning Algorithms

The effectiveness of machine learning models depends on the informational content of the input features. In this study, ciphertext bit representations, entropy, and block repetition are used as the main features for block cipher classification.

The Decision Tree model uses these features to construct hierarchical decision rules for distinguishing the analyzed cipher classes (Figure 3).

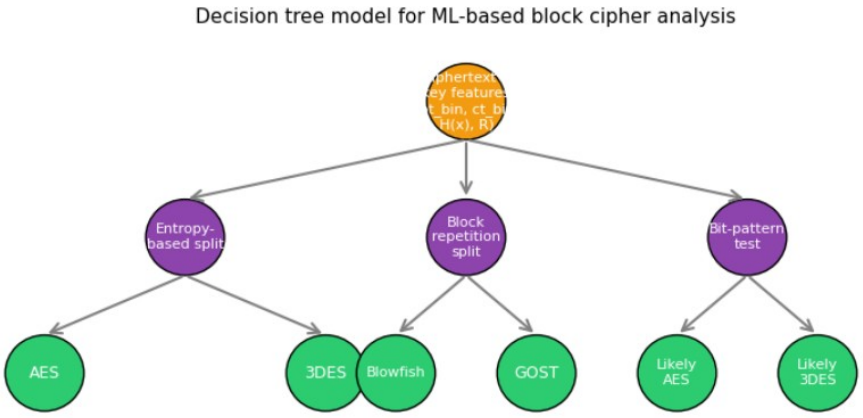



Figure 3. Decision Tree Model for Block Cipher Classification

The Random Forest model combines multiple decision trees trained on different subsets of the data and aggregates their predictions through majority voting. The deep neural network processes bit-level and statistical features to investigate whether discriminative patterns can be identified among AES, 3DES, Blowfish, and GOST.

The deep neural network demonstrated stable training behavior over 15 epochs, with training and validation accuracy remaining close to 0.25–0.26. The similarity between training

and validation performance indicates limited discriminative information in the analyzed features rather than conventional overfitting.

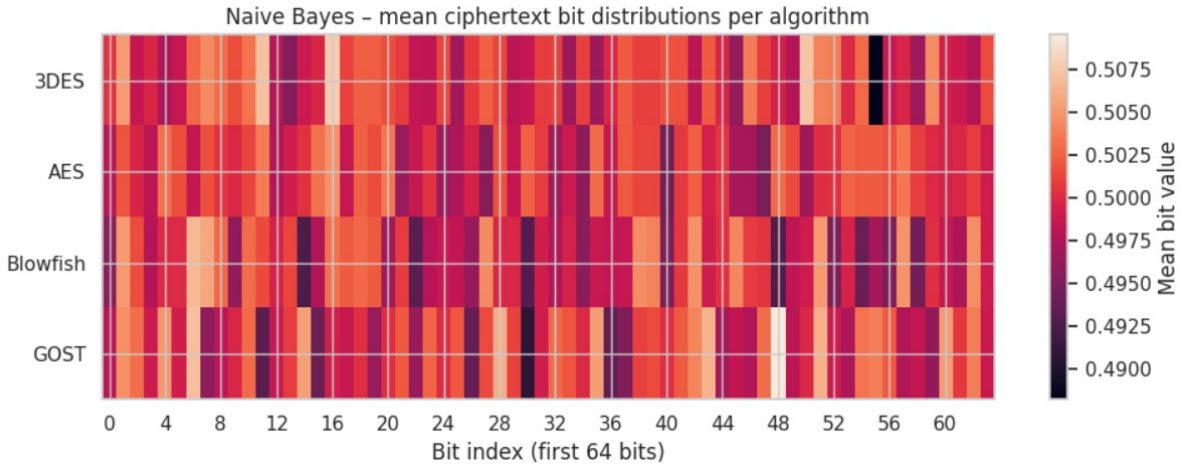



Figure 4. Distribution of Ciphertext Bits for Different Block Ciphers

Figure 4 presents the average values of the first 64 ciphertext bits for AES, 3DES, Blowfish, and GOST. The distributions exhibit weak and near-random differences across the algorithms, indicating limited discriminative information at the bit level.

## 4. Results

The feature importance analysis indicates that only a limited subset of input features provides weak discriminative information.

Figure 6 compares the classification performance of Logistic Regression, Decision Tree, Random Forest, and MLP models using standard evaluation metrics. All metrics remain close to the 0.25 baseline expected for a balanced four-class classification problem, while the ROC curves remain near the diagonal, indicating limited discriminative information in the analyzed features.

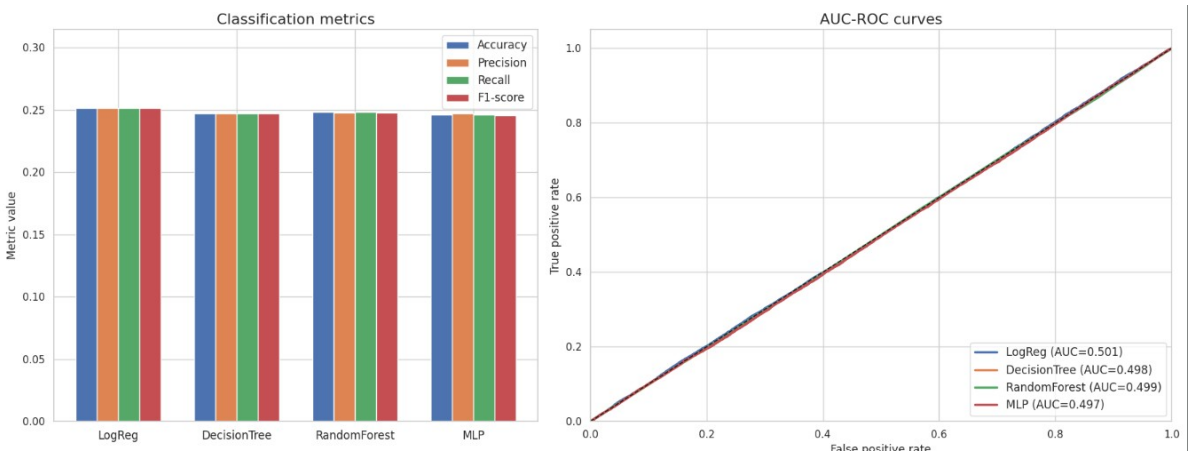



Figure 5. Performance Metrics of Baseline Machine Learning Models

These results indicate that the statistical properties of full-round ciphertext limit the ability of the evaluated machine learning models to establish reliable decision boundaries. In contrast to reduced-round neural cryptanalysis, where distinguishable patterns can be exploited under specific experimental conditions [2-6], ciphertext-derived features alone provide

insufficient information for reliable discrimination among the full-round block ciphers analyzed in this study.

The observed limitations motivate further investigation using reduced-round settings and side-channel information [8, 9], as well as hybrid cryptanalytic approaches.

## 5. Conclusions

This study evaluated machine-learning-based cryptanalysis of block ciphers using statistical and entropy-based features extracted from plaintext and ciphertext. Decision Tree, Random Forest, MLP, and neural models showed limited discriminative performance for full-round ciphers, indicating that ciphertext-only features provide insufficient information for reliable classification and key-related prediction. These findings emphasize both the potential and limitations of data-driven cryptanalysis. Future research will focus on hybrid approaches combining ciphertext analysis with reduced-round experiments, side-channel information, larger datasets, and improved feature extraction.

## References

1. Alani, M. M. Applications of Machine Learning in Cryptography: A Survey / M. M. Alani // Proceedings of the 3rd International Conference on Cryptography, Security and Privacy (ICCSP 2019). – 2019. – P. 23–27. – DOI: 10.1145/3309074.3309092.

2. Gohr, A. Improving Attacks on Round-Reduced Speck32/64 Using Deep Learning / A. Gohr // Advances in Cryptology – CRYPTO 2019. – Springer, 2019. – Vol. 11693. – P. 150–179. – DOI: 10.1007/978-3-030-26951-7_6.

3. Bao, Z., Guo, J., Liu, M., Ma, L., Tu, Y. Enhancing Differential-Neural Cryptanalysis / Z. Bao, J. Guo, M. Liu, L. Ma, Y. Tu // Advances in Cryptology – ASIACRYPT 2022. – Springer, 2022. – P. 318–347. – DOI: 10.1007/978-3-031-22963-3_11.

4. Benamira, R., Gérault, D., Peyrin, T., Tan, Q. Q. A Deeper Look at Machine Learning-Based Cryptanalysis / R. Benamira, D. Gérault, T. Peyrin, Q. Q. Tan // Advances in Cryptology – EUROCRYPT 2021. – Springer, 2021. – P. 805–835. – DOI: 10.1007/978-3-030-77870-5_28.

5. Kim, H., Lim, S., Kang, Y., Kim, W., Kim, D., Yoon, S., Seo, H. Deep-Learning-Based Cryptanalysis of Lightweight Block Ciphers Revisited / H. Kim, S. Lim, Y. Kang, W. Kim, D. Kim, S. Yoon, H. Seo // Entropy. – 2023. – Vol. 25, N. 7. – Art. 986. – DOI: 10.3390/e25070986.

6. Lu, J., Liu, G., Sun, B., Li, C., Liu, L. Improved (Related-Key) Differential-Based Neural Distinguishers for SIMON and SIMECK Block Ciphers / J. Lu, G. Liu, B. Sun, C. Li, L. Liu // The Computer Journal. – 2024. – Vol. 67, N. 2. – P. 537–547. – DOI: 10.1093/comjnl/bxac195.

7. Kaur, P., Chatterjee, R. Deep Learning-Based Classification of Block Cipher Modes Using Ciphertext Features / P. Kaur, R. Chatterjee // Information Sciences. – 2022.

8. Zhou, Y., Liu, M. Deep Learning for Side-Channel Analysis: A Survey / Y. Zhou, M. Liu // IEEE Access. – 2021.

9. Benadjila, R., Prouff, E., Strullu, R., Cagli, E., Dumas, C. Deep Learning for Side-Channel Analysis and Introduction to ASCAD Database / R. Benadjila, E. Prouff, R. Strullu, E. Cagli, C. Dumas // Journal of Cryptographic Engineering. – 2020. – Vol. 10, N. 2. – P. 163–188. – DOI: 10.1007/s13389-019-00220-8.

# ГЕНЕРАЦИЯ ЭКСПРЕССИВНОЙ КАЗАХСКОЙ РЕЧИ В СОВРЕМЕННЫХ НЕЙРОСЕТЕВЫХ TTS-СИСТЕМАХ

Кәрібаева А.С. [1], Карюкин В.И. [1,2 *], Әмірова Д.Т. [1], Абдуали Б.А. [1]
e-mail: vladislav.karyukin@kaznu.kz
[1]*Казахский Национальный Университет имени аль-Фараби*
[2]*Институт Информационных и Вычислительных Технологий*

***Аннотация.*** *В работе сравниваются четыре системы синтеза казахской речи: ElevenLabs v3, OpenAI TTS, Massively Multilingual Speech (MMS) и TurkicTTS. Эксперимент выполнен на 1000 предложениях, собранных с новостных порталов Казахстана. Качество оценивалось по акустико-просодическим показателям F0, RMS, взвешенной длительности и F1, а также по безэталонным нейросетевым метрикам DNSMOS, NISQA, MOSNet и SpeechMOS. ElevenLabs v3 показала наиболее выраженный профиль высоты тона и энергии, тогда как OpenAI получила наивысшие значения всех четырех безэталонных показателей. MMS и TurkicTTS сохраняют практическую ценность как открытые решения для локального запуска и масштабного формирования речевых корпусов.*

## 1.Введение

Системы синтеза речи стали важным компонентом голосовых интерфейсов, образовательных сервисов и интеллектуальных ассистентов. Классические Text-to-Speech (TTS) решения способны корректно озвучивать текст, однако их речь нередко остается нейтральной и монотонной. Для естественного взаимодействия недостаточно правильного произношения: синтез должен воспроизводить интонацию, паузы, ритм и эмоциональные оттенки, которые передают коммуникативное намерение.

Для казахского языка эта задача осложняется ограниченным объемом высококачественных размеченных аудиоданных. Неоднородность записей, различия в дикторской манере и региональном произношении могут приводить к нестабильной интонации, неестественным паузам и акценту. Поэтому современные исследования постепенно переходят от нейтрального TTS к экспрессивному синтезу, в котором акустическая реализация учитывает контекст, просодию и стиль. Цель данной работы — сопоставить современные коммерческие и открытые TTS-системы при генерации казахской речи и определить различия их акустических и предсказанных перцептивных характеристик.

## 2. Обзор литературы

Развитие глубокого обучения существенно повысило естественность нейросетевого синтеза речи и расширило возможности управления стилем. В работах по мультимодальному и управляемому TTS используются кодировщики текста и дополнительных модальностей, механизмы объединения признаков и декодеры, позволяющие моделировать интонацию, паузы и эмоциональные характеристики [1]. Отдельное направление связано с учетом акустической среды, чтобы синтезированная речь сохраняла убедительность не только в лабораторных, но и в реальных условиях [2]. Систематические обзоры показывают, что основными задачами экспрессивного TTS остаются устойчивое управление просодией, перенос стиля и сохранение естественности при генерации нового текста [3].

Ряд исследований рассматривает управление эмоциями и интонацией через стилевые и эмоциональные представления, а также нейросетевые методы переноса выразительности [4–10]. При этом даже для высокоресурсных языков контроль эмоций остается сложной задачей: модель может звучать естественно, но усреднять стиль или

нестабильно переносить экспрессию на новые фразы. Для казахского языка публикаций существенно меньше. В [11] исследованы модели ASR и TTS и приведена количественная оценка синтеза, однако выборка была ограниченной. В [12] рассмотрен многоязычный речевой корпус для малоресурсных тюркских языков с использованием безэталонных метрик качества. Таким образом, сравнительное исследование экспрессивных характеристик современных TTS-систем для казахского языка остается актуальным.

## 3. Методология

Текстовые датасеты были сформированы из новостных порталов Казахстана и включали различные тематические области. Для эксперимента были отобраны 1000 предложений. Перед обработкой данных были исключены строки с пропущенными значениями, нестроковыми полями, пустыми предложениями и строками, содержащими только пробелы. Каждому предложению присваивался уникальный числовой идентификатор, что позволяло сопоставлять исходный текст и сгенерированное аудио во всех системах.

В ElevenLabs использовались модель eleven_v3 и казахский голос Guldana [13]. Синтез выполнялся через официальный Python-клиент, а полученный аудиопоток сохранялся в MP3. Пользовательские значения стабильности, сходства, стиля, speaker boost, темпа и кодирования не задавались, поэтому использовались настройки по умолчанию. В OpenAI применялась модель gpt-4o-mini-tts и голос marine [14]. Предложения передавались через официальный Python-клиент; дополнительные инструкции, управление скоростью и пользовательские параметры формата не задавались.

Для открытого MMS использовался контрольный пункт facebook/mms-tts-kaz [15] из библиотеки Hugging Face Transformers. Текст токенизировался соответствующим AutoTokenizer и подавался в VitsModel; полученная форма волны сохранялась в WAV с частотой дискретизации из конфигурации модели. В TurkicTTS применялась ESPnet-модель вместе с нейровокодером Parallel WaveGAN [16]. Синтез выполнялся на GPU; порог внимания составлял 0,5, минимальное и максимальное отношения длины – 0,0 и 10,0, окна ограничения внимания назад/вперед – 1 и 3, коэффициент скорости – 1,0. Результирующий сигнал формировался с частотой 22 050 Гц.

Поскольку для сгенерированных файлов отсутствовали эталонные аудиозаписи тех же высказываний, оценка результатов была проведена с использованием метрик, не требующих исходных аудио. Анализ был выполнен с использованием четырех метрик: Контур основного тона F0, Среднеквадратичное отклонение энергии, Средневзвешенное значение длительности и Спектральные характеристики F1. F0 характеризует общий уровень высоты голоса, Среднеквадратичное отклонение энергии – интенсивность сигнала, Средневзвешенное значение длительности – временную организацию речи и пауз, а F1 связан с артикуляционными характеристиками гласных. Эти показатели рассматриваются как описательные и не интерпретируются самостоятельно как прямые меры естественности или эмоциональной выразительности.

Дополнительно также использовались следующие четыре метрики: DNSMOS, NISQA, MOSNet и SpeechMOS. Они прогнозируют воспринимаемое качество и естественность по единственному аудиосигналу. Более высокие значения соответствуют более высокому предсказанному качеству. Поскольку модели обучены на разных данных и имеют разные архитектуры, их результаты анализировались совместно, но не объединялись в единый интегральный балл.

## 4. Результаты

В результате проведения экспериментов по преобразованию текста в аудио ElevenLabs v3 получила наибольшую среднюю F0 как 257.639 Гц и максимальную RMS-энергию как 0.129, что указывает на сравнительно высокий и энергетически выраженный голосовой профиль. OpenAI заняла промежуточное положение по F0 (200,676 Гц) и имела минимальную RMS-энергию 0.064. MMS и TurkicTTS характеризовались более низкой средней высотой тона и умеренными значениями энергии. Акустико-просодические результаты представлены в таблице 1.

**Таблица 1**. Результаты акустико-просодических метрик для четырех TTS-моделей

| Модель | Контур основного тона F0 | Среднеквадратичное отклонение энергии | Средневзвешенное значение длительности | Спектральные характеристики F1 |
|---|---|---|---|---|
| ElevenLabs v3 | 257.639 | 0.129 | 0.069 | 537.066 |
| OpenAI | 200.676 | 0.064 | 0.078 | 548.589 |
| MMS | 116.537 | 0.095 | 0.132 | 566.459 |
| TurkicTTS | 153.378 | 0.069 | 0.102 | 458.287 |

Наиболее низкие значения взвешенной длительности получили ElevenLabs v3 – 0.069 и OpenAI – 0.078, что соответствует более непрерывной временной организации по сравнению с MMS – 0.132 и TurkicTTS – 0.102. Наибольший средний F1 зафиксирован у MMS – 566.459, далее следуют OpenAI – 548.589, ElevenLabs v3 – 537.066 и TurkicTTS – 458.287. Таким образом, системы формируют разные профили высоты тона, энергии, темпоральной организации и спектральных характеристик; эти различия не следует напрямую трактовать как превосходство по естественности. Также результаты представлены в виде гистограмм на рис. 1 и 2.

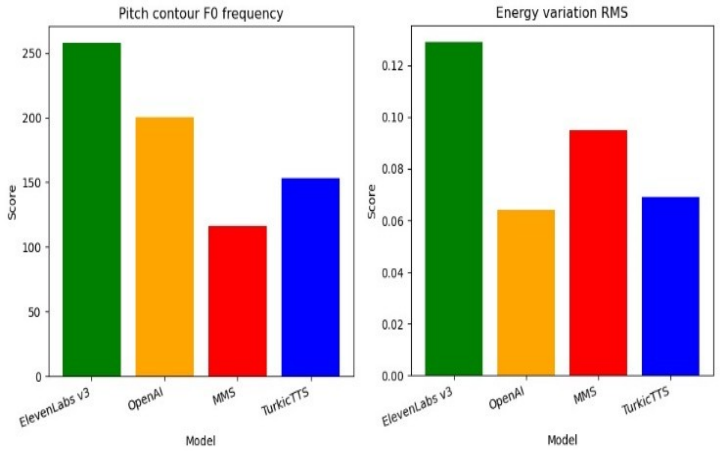



**Рис. 1**. Гистограммы Контура основного тона F0 и Среднеквадартического отклонения энергии

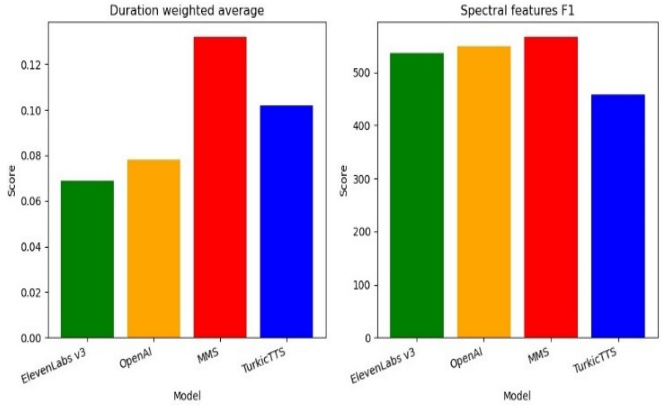


**Рис. 2**. Гистограммы Средневзвешенного значения длительности и Спектральных характеристик F1

OpenAI показала наивысший средний результат по всем четырем показателям. DNSMOS составил 3.452 против 3.283 у TurkicTTS, 3.280 у MMS и 3.164 у ElevenLabs v3. Наиболее заметное разделение систем наблюдалось по NISQA: OpenAI получила 4.944, TurkicTTS – 4.527, ElevenLabs v3 – 3.596, а MMS – 2.996. Значения MOSNet были близкими: 4.046 у OpenAI и 4.023 у ElevenLabs v3, 3.974 у TurkicTTS и 3.917 у MMS. По SpeechMOS OpenAI также сохранила первое место с результатом 4.206, при этом MMS получила 4.152, TurkicTTS – 4.069, ElevenLabs v3 – 3.861. Результаты безэталонной оценки приведены в таблице 2. Также результаты представлены в виде гистограмм на рис. 3 и 4.

**Таблица 2**. Результаты безэталонных метрик качества для четырех TTS-моделей

| Модель | DNSMOS | NISQA | MOSNet | SpeechMOS |
|---|---|---|---|---|
| ElevenLabs v3 | 3,164 | 3,596 | 4,023 | 3,861 |
| OpenAI | 3,452 | 4,944 | 4,046 | 4,206 |
| MMS | 3,280 | 2,996 | 3,917 | 4,152 |
| TurkicTTS | 3,283 | 4,527 | 3,974 | 4,069 |

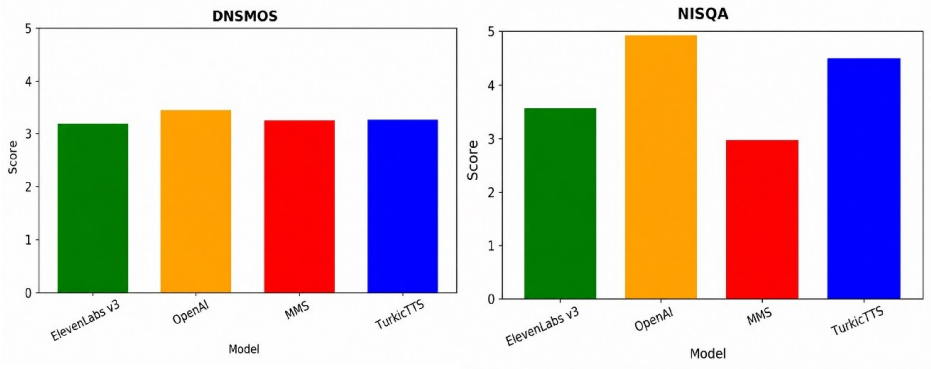



**Рисунок 3.** Гистограммы метрик DNSMOS и NISQA

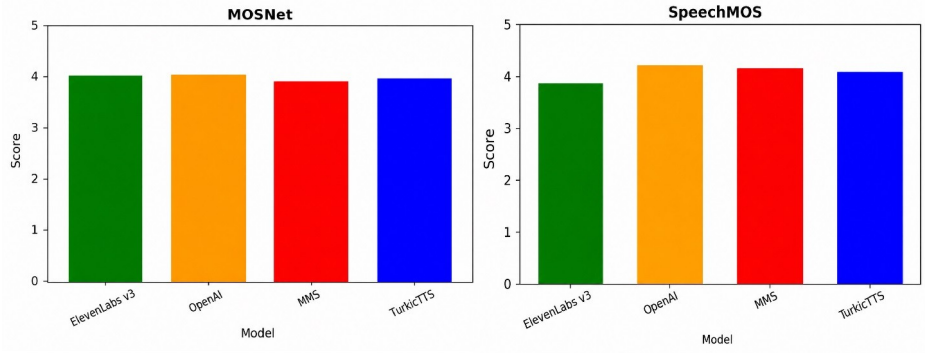



**Рисунок 4.** Гистограммы метрик MOSNet и SpeechMOS

Совокупность результатов показывает, что высокий уровень F0 и среднеквадратичного отклонения энергии не определяет воспринимаемое качество. ElevenLabs v3 формирует наиболее выраженный по высоте и энергии голосовой профиль, тогда как OpenAI обеспечивает наиболее высокие прогнозируемые показатели качества. При этом открытые MMS и TurkicTTS важны для исследований малоресурсных языков благодаря локальному запуску, отсутствию зависимости от коммерческого API и возможности масштабной генерации данных.

**5. Заключение**

В работе проведено сравнение ElevenLabs v3, OpenAI, MMS и TurkicTTS при синтезе 1000 казахских предложений. Акустический анализ показал, что ElevenLabs v3 имеет наибольшие средние F0 – 257.639 и Среднеквадратичное отклонение энергии – 0.129, а ElevenLabs v3 и OpenAI характеризуются минимальными значениями взвешенной длительности – 0.069 и 0.078 соответственно. OpenAI получила наивысшие результаты всех четырех безэталонных метрик: DNSMOS 3,452, NISQA 4,944–4,945, MOSNet 4,046 и SpeechMOS 4,206. TurkicTTS также показала высокий NISQA, а MMS – сравнительно высокий SpeechMOS.

Полученные данные подтверждают необходимость совместного анализа акустических и нейросетевых перцептивных показателей: они отражают разные свойства синтезированной речи и не должны подменять друг друга. В дальнейшей работе целесообразно расширить набор дикторов, типов предложений и эмоциональных условий, а также дополнить безэталонную оценку субъективным прослушиванием. Это позволит точнее определить пригодность каждой системы для формирования казахских речевых корпусов и задач экспрессивного синтеза.

**Благодарность**

Исследование выполнено при поддержке грантового проекта «Исследование автоматической генерации параллельных речевых корпусов тюркских языков и их использования для нейронных моделей» Министерства науки и высшего образования Республики Казахстан, ИРН AP23488624.

**Литература**

1. Kim M., Ma P., Chen H., Petridis S., Pantic M. Revival with Voice: Multimodal Controllable Text-to-Speech Synthesis // Proceedings Interspeech 2025. Rotterdam, 2025. P. 1–5.

2. Tan D., Zhang G., Lee T. Environment Aware Text-to-Speech Synthesis // Proceedings Interspeech 2022. Incheon, 2022. P. 481–485.

3. Barakat H., Turk O., Demiroglu C. Deep learning-based expressive speech synthesis: a systematic review of approaches, challenges, and resources // EURASIP Journal on Audio, Speech and Music Processing. 2024. Vol. 2024, No. 1. P. 1–34.

4. Jauk I., Lorenzo-Trueba J., Yamagishi J., Bonafonte A. Expressive Speech Synthesis Using Sentiment Embeddings // Proceedings Interspeech 2018. Hyderabad, 2018. P. 3062–3066.

5. Neekhara P., Hussain S., Dubnov S., Koushanfar F., McAuley J. Expressive Neural Voice Cloning // Proceedings of the 13th Asian Conference on Machine Learning (ACML 2021). 2021. P. 252–267.

6. Raitio T., Rasipuram R., Castellani D. Controllable neural text-to-speech synthesis using intuitive prosodic features // Proceedings Interspeech 2020. Shanghai, 2020. P. 4432–4436.

7. Li X., Shang Z., Shi P., Hua H., Li T., Zhang P. Expressive paragraph text-to-speech synthesis with multi-step variational autoencoder // Proceedings Interspeech 2024. 2024. P. 1815–1819.

8. Zhu X., Xue L. Building a controllable expressive speech synthesis system with multiple emotion strengths // Cognitive Systems Research. 2020. Vol. 59. P. 1–10.

9. Xue L., Zhu X., An X., Xie L. A Comparison of Expressive Speech Synthesis Approaches based on Neural Network // ASMMC-MMAC'18 Joint Workshop. 2018. P. 15–20.

10. Tan X. Expressive and Controllable TTS // Neural Text-to-Speech Synthesis. Artificial Intelligence: Foundations, Theory, and Algorithms. 2023. P. 125–140.

11. Karibayeva A., Karyukin V., Abduali B., Amirova D. Speech Recognition and Synthesis Models and Platforms for the Kazakh Language // Information. 2025. Vol. 16, No. 10. Art. 879. P. 1–29.

12. Karibayeva A., Karyukin V., Tukeyev U., Abduali B., Amirova D., Rakhimova D., Aliyev R., Shormakova A. The Development and Experimental Evaluation of a Multilingual Speech Corpus for Low-Resource Turkic Languages // Applied Sciences. 2025. Vol. 15, No. 24. Art. 12880. P. 1–39.

13. ElevenLabs. Models overview: Eleven v3. ElevenLabs Documentation. https://elevenlabs.io/docs/models (дата обращения: 20.07.2026).

14. OpenAI. Introducing next-generation audio models in the API. 20.03.2025. https://openai.com/index/introducing-our-next-generation-audio-models/ (дата обращения: 26.07.2026).

15. Meta AI. Massively Multilingual Speech: Kazakh text-to-speech. Hugging Face Model Hub. https://huggingface.co/facebook/mms-tts-kaz (дата обращения: 26.07.2026).

16. Institute of Smart Systems and Artificial Intelligence. TurkicTTS: Multilingual text-to-speech synthesis for Turkic languages. GitHub. https://github.com/IS2AI/TurkicTTS (дата обращения: 26.07.2026).

# АҒЗАНЫҢ ФИЗИОЛОГИЯЛЫҚ КҮЙІН БОЛЖАУДАҒЫ ИНТЕЛЛЕКТУАЛДЫ ЦИФРЛЫҚ ЕГІЗ ТЕХНОЛОГИЯСЫ

Куанышбекова Д.Е.
e-mail: dek111782@gmail.com
*Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан*

***Андатпа.*** *Баяндамада адам ағзасының интеллектуалды цифрлық егізін физиологиялық және патологиялық күйлерді болжау мақсатында қолдану мүмкіндіктері қарастырылады. Цифрлық егіз технологиясы медициналық деректерді, жасанды интеллект әдістерін және машиналық оқыту алгоритмдерін біріктіру арқылы ағзаның виртуалды моделін қалыптастыруға мүмкіндік береді. Ұсынылған тәсіл физиологиялық көрсеткіштердің өзгеру динамикасын бақылауға, патологиялық үдерістердің дамуын талдауға, аурулардың ықтимал асқынуларын бағалауға және емдеу нәтижелерін алдын ала болжауға жағдай жасайды. Цифрлық егіздерді қолдану медициналық зерттеулердің тиімділігін арттыруға, клиникалық сынақтардың шығындарын азайтуға және дербестендірілген медицинаның дамуына ықпал етеді.*

***Түйін сөздер:*** *цифрлық егіз, адам ағзасы, жасанды интеллект, машиналық оқыту, физиологиялық күйлер, патологиялық күйлер, цифрлық медицина, медициналық зерттеулер.*

## Кіріспе

Соңғы жылдары цифрлық технологиялардың қарқынды дамуы денсаулық сақтау жүйесіне жаңа мүмкіндіктер ашуда. Әсіресе жасанды интеллект, үлкен деректерді талдау және цифрлық модельдеу әдістерінің дамуы медициналық зерттеулерді жаңа деңгейге көтерді. Осындай ең болашағы зор бағыттардың бірі - адам ағзасының цифрлық егізін құру технологиясы.

Цифрлық егіз - нақты объектінің немесе жүйенің виртуалды көшірмесі. Медицина саласында цифрлық егіз адам ағзасының физиологиялық ерекшеліктерін, денсаулық жағдайын және аурулардың даму динамикасын сипаттайтын интеллектуалды модель ретінде қарастырылады. Мұндай модель нақты уақыт режимінде жаңартылып отыратын медициналық деректер негізінде қалыптасады.Дәстүрлі медициналық зерттеулер көп қаржылық шығындарды, ұзақ мерзімді бақылауды және көптеген зерттеу субъектілерінің қатысуын талап етеді. Сонымен қатар, көптеген клиникалық эксперименттерді жүргізу этикалық талаптар мен қатысушылардың денсаулығына төнетін қауіптерге байланысты шектеледі. Осыған байланысты цифрлық егіздерді пайдалану виртуалды зерттеулер жүргізудің, аурулардың даму сценарийлерін және емдеу нәтижелерін алдын ала бағалаудың тиімді құралына айналуда.

Зерттеу жұмысының мақсаты - адам ағзасының интеллектуалды цифрлық егізін құрудың негізгі қағидаларын қарастыру және оны физиологиялық әрі патологиялық күйлерді болжауда қолдану мүмкіндіктерін талдау болып табылады.

## Негізгі бөлім

ДДҰ деректері бойынша созылмалы аурулар әлемдегі өлім-жітімнің 71%-ын құрайды, ал жүрек-қан тамырлары ауруларынан жыл сайын 17,9 млн адам қайтыс болады. [1]. Бұл көрсеткіштер әсіресе АҚШ, Қытай, Германия және Ұлыбритания сияқты елдерде цифрлық медицина мен жасанды интеллект технологияларын белсенді дамытуға ықпал етті. Дүние жүзінде пациенттің цифрлық егізі негізіндегі жүйелер диагностикалық дәлдікті арттыруға мүмкіндік беріп отыр. [2].[3]. Сондықтан, пациент жағдайын талдауға және болжауға арналған цифрлық егіздің интеллектуалды жүйесін әзірлеу өзекті ғылыми бағыт болып табылады.

*Цифрлық егіз технологиясының даму тарихы*

Цифрлық егіз тұжырымдамасы алғаш рет өнеркәсіп саласында пайда болды. Бұл технология күрделі техникалық жүйелердің виртуалды көшірмелерін құру арқылы олардың жұмысын бақылауға және болжауға мүмкіндік берді. Кейіннен цифрлық егіздер авиация, энергетика және өндіріс салаларында кеңінен қолданыла бастады. Жасанды интеллект пен үлкен деректер технологияларының дамуына байланысты цифрлық егіздер медицина саласына енгізіліп, адамның физиологиялық және патологиялық күйлерін модельдеудің тиімді құралына айналды.

Қазіргі уақытта цифрлық егіз технологиясы дербестендірілген медицинаны дамытудағы маңызды бағыттардың бірі болып табылады. Бұл технология нақты адамның медициналық деректеріне негізделген виртуалды модель құруға және денсаулық жағдайындағы өзгерістерді алдын ала болжауға мүмкіндік береді.

*Адам ағзасының цифрлық егізінің архитектурасы*

Адам ағзасының цифрлық егізі – әртүрлі дереккөздерден алынған мәліметтерді біріктіретін және адам ағзасында жүретін үдерістерді модельдеуді қамтамасыз ететін интеллектуалды ақпараттық жүйе.

Ұсынылатын архитектура келесі құрамдас бөліктерден тұрады:

– медициналық деректерді жинау модулі;
– деректерді сақтау және интеграциялау модулі;
– ақпаратты алдын ала өңдеу модулі;
– машиналық оқыту модулі;
– болжау және шешім қабылдауды қолдау модулі.




Сурет 1. – Адам ағзасының интеллектуалды цифрлық егізінің архитектурасы

Деректердің негізгі көздері ретінде электрондық медициналық карталар, зертханалық зерттеулердің нәтижелері, медициналық құрылғылардың деректері, мониторинг жүргізетін тағылатын құрылғылар мен телемедициналық жүйелердің мәліметтері пайдаланылуы мүмкін. Жиналған ақпарат бірыңғай деректер қорына жинақталып, алдын ала өңдеуден өтеді. Кейін жасанды интеллект алгоритмдері арқылы талданып, адам ағзасының цифрлық моделі қалыптастырылады. Бұл модель ағзаның ағымдағы күйін сипаттап қана қоймай, оның болашақтағы өзгерістерін де болжауға мүмкіндік береді.

*Интеллектуалды цифрлық егіздің жұмыс істеу принципі*

Интеллектуалды цифрлық егіздің негізгі ерекшелігі - ағзаның күйі туралы ақпаратты үздіксіз жаңартып отыру және алынған деректер негізінде болжам жасау қабілеті. Жүйе физиологиялық көрсеткіштерді тұрақты түрде бақылап отырады. Оларға жүрек соғу жиілігі, артериялық қысым, қандағы глюкоза деңгейі, дене температурасы, тыныс алу жиілігі және басқа биомедициналық параметрлер жатады. Алынған деректер машиналық оқыту алгоритмдері арқылы өңделеді. Жүйе уақыт өте келе жиналған мәліметтер арасындағы жасырын байланыстарды анықтап, ағзаның белгілі бір өзгерістерге қалай жауап беретінін үйренеді. Нәтижесінде цифрлық егіз нақты адамның физиологиялық ерекшеліктерін ескеретін интеллектуалды модельге айналады.

*Физиологиялық күйлерді болжау*

Физиологиялық күйлерді болжау цифрлық егіз технологиясының маңызды бағыттарының бірі болып табылады. Ағзаның қалыпты жұмысын сипаттайтын көрсеткіштердің өзгеруін бақылау арқылы денсаулық жағдайындағы ауытқуларды ерте кезеңде анықтауға болады.

Мысалы, жүрек соғу жиілігінің, қан қысымының немесе қандағы қант деңгейінің өзгеру динамикасын талдау арқылы белгілі бір аурулардың даму қаупін алдын ала бағалауға мүмкіндік туады. Сонымен қатар жүйе адамның жеке физиологиялық ерекшеліктерін ескеріп, денсаулық жағдайының ықтимал өзгерістеріне қатысты болжамдар жасайды.

Физиологиялық күйлерді болжау профилактикалық медицинаның дамуына ықпал етіп, аурулардың алдын алу шараларын дер кезінде қабылдауға мүмкіндік береді.

*Патологиялық күйлерді болжау*

Цифрлық егіз технологиясының маңызды артықшылықтарының бірі-патологиялық үдерістердің дамуын модельдеу мүмкіндігі. Патологиялық күйлерді болжау кезінде жүйе пациенттің тарихи медициналық деректерін, зертханалық көрсеткіштерін және ағымдағы физиологиялық параметрлерін талдайды. Бұл аурулардың даму ықтималдығын анықтауға және асқынулардың пайда болу қаупін бағалауға мүмкіндік береді. Жасанды интеллект алгоритмдері жүрек жеткіліксіздігін диагностикалауда жоғары дәлдік көрсетіп, аурудың ерте кезеңдерін анықтауға мүмкіндік береді. [4]. Мысалы, қант диабеті, жүрек-қантамыр жүйесінің аурулары, гипертония және басқа созылмалы патологиялар кезінде цифрлық егіз аурудың даму динамикасын модельдей алады. Қант диабеті жағдайында цифрлық егіздер пациенттің жағдайын бақылау мен болжауда тиімді қолданылып келеді. [6].[7]. Мұндай модельдеу дәрігерлерге емдеу тактикасын таңдауға және ықтимал тәуекелдерді азайтуға көмектеседі. Сонымен қатар патологиялық күйлерді болжау пациенттің жағдайы нашарламай тұрып алдын алу шараларын қабылдауға мүмкіндік береді. Бұл денсаулық сақтау жүйесінің тиімділігін арттыруға ықпал етеді.

*Цифрлық егіздерді қолданудың практикалық мысалдары*

Адам ағзасының цифрлық егізі әртүрлі ауруларды бақылау және болжау мақсатында пайдаланылуы мүмкін. Мысалы, жүрек-қантамыр жүйесі аурулары кезінде цифрлық егіз пациенттің жүрек соғу жиілігін, қан қысымын және электрокардиографиялық көрсеткіштерін талдай отырып, жүрек қызметіндегі ауытқуларды ерте анықтауға мүмкіндік береді. Қант диабетімен ауыратын адамдар үшін цифрлық егіз қандағы глюкоза деңгейінің өзгеруін бақылап, гипергликемия немесе гипогликемия қаупін алдын ала болжай алады.

Сонымен қатар цифрлық егіздер онкологиялық ауруларды емдеу барысында әртүрлі терапиялық әдістердің ықтимал нәтижелерін бағалауға мүмкіндік береді.

*Медициналық зерттеулерде қолданылуы*

Цифрлық егіздер медициналық зерттеулер жүргізудің жаңа тәсілдерін ұсынады. Виртуалды модельдерді пайдалану арқылы әртүрлі клиникалық сценарийлерді нақты пациенттің қатысуынсыз зерттеуге болады. Мұндай тәсіл зерттеу шығындарын азайтады,

экспериментердің қауіпсіздігін арттырады және нәтижелерді жылдам алуға мүмкіндік береді. Сонымен қатар дәрілік препараттардың тиімділігін алдын ала бағалау, әртүрлі емдеу әдістерін салыстыру және ықтимал асқынуларды зерттеу мүмкіндігі пайда болады.

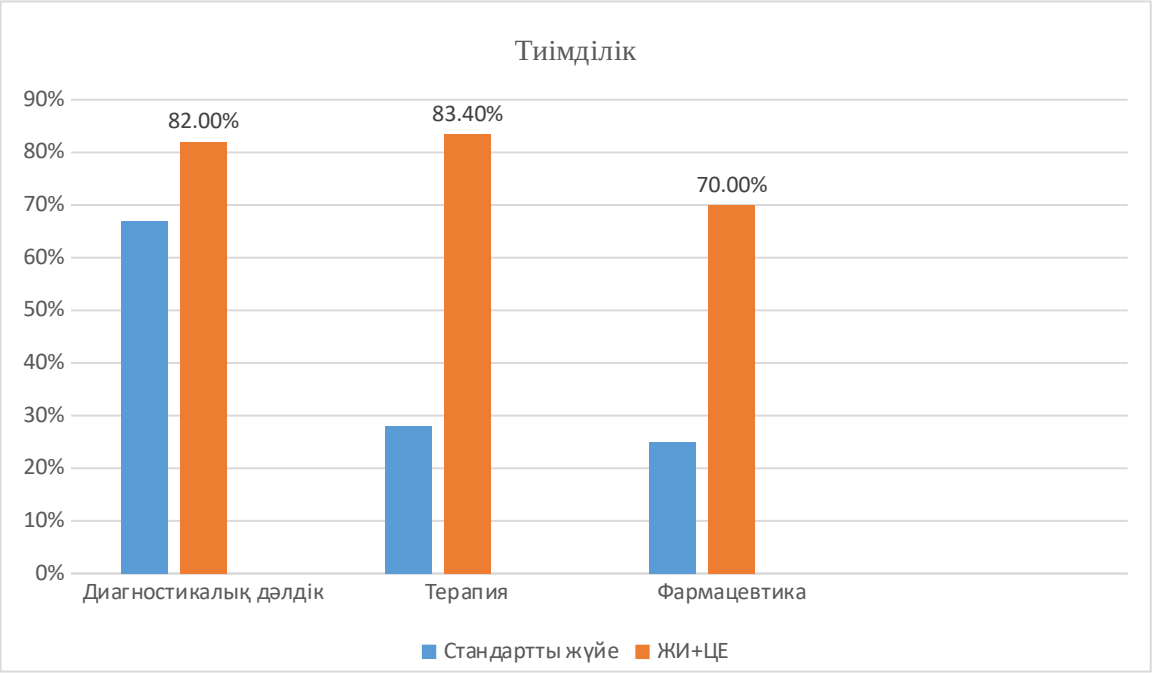
Цифрлық егіздерді қолдану ғылыми зерттеулердің дәлдігін арттырып қана қоймай, медициналық инновацияларды енгізу үдерісін де жеделдетеді. ЖИ негізіндегі цифрлық егіздерді қолдану дәстүрлі медицинамен салыстырғанда келесідей нәтижелер берді:

Диагностикалық дәлдік: Жүрек жеткіліксіздігін анықтауда ЖИ дәлдігі 82% болса, стандартты жүйелерде ол 67%-дан аспады. [5].

Емге жауап беру (терапия тиімділігі): Цифрлық егізді қолданғанда тиімділік 83,4% болды, бұл стандартты емдеуден 28,1%-ға жоғары. [6].

Болжау қателігі: Глюкоза деңгейін болжауда ЖИ қателікті (жүйелі ауытқу) 11,99 мг/дл-ге дейін азайтуға мүмкіндік береді. [7].

Фармацевтика: ЖИ-ді пайдалану жаңа дәрілерді іріктеу процесін 70%-ға дейін жылдамдатады. [8]. [9].




Сурет 2.- ЖИ мен Цифрлық егізді қолдану тиімділігі

Цифрлық егіз технологиясының артықшылықтары

Интеллектуалды цифрлық егіздерді қолданудың негізгі артықшылықтары:

– физиологиялық және патологиялық күйлерді дәл болжау;
– медициналық зерттеулердің тиімділігін арттыру;
– клиникалық сынақтардың шығындарын азайту;
– емдеу сапасын жақсарту;
– дәрігерлік шешім қабылдауды қолдау;
– ауруларды ерте диагностикалау;
– дербестендірілген медицинаны дамыту.

*Цифрлық егіз технологиясының мәселелері мен даму перспективалары*

Цифрлық егіздерді енгізу барысында бірқатар қиындықтар кездеседі. Олардың қатарына медициналық деректердің сапасы, ақпараттық қауіпсіздік мәселелері, пациенттердің жеке мәліметтерін қорғау және есептеу ресурстарының жеткіліктілігі жатады. Сонымен қатар медициналық ұйымдарда қолданылатын ақпараттық жүйелердің әртүрлілігі деректерді біріктіру процесін қиындатады.

Болашақта жасанды интеллект алгоритмдерінің жетілдірілуі және медициналық деректердің қолжетімділігінің артуы цифрлық егіздердің дәлдігін едәуір жоғарылатуға мүмкіндік береді. Бұл технологиялар медициналық көмектің сапасын арттыруға және дербестендірілген медицинаның дамуына ықпал етеді.

**Қорытынды**

Адам ағзасының интеллектуалды цифрлық егізі заманауи цифрлық медицинаның маңызды бағыттарының бірі болып табылады. Медициналық деректерді, жасанды интеллект технологияларын және машиналық оқыту әдістерін біріктіру арқылы ағзаның физиологиялық және патологиялық күйлерін болжауға қабілетті интеллектуалды жүйелерді құруға мүмкіндік туады.

Цифрлық егіздерді қолдану медициналық зерттеулердің тиімділігін арттырып, емдеу сапасын жақсартуға және аурулардың алдын алу мүмкіндіктерін кеңейтуге ықпал етеді. Болашақта мұндай технологиялар дербестендірілген медицинаның негізгі құралдарының біріне айналып, денсаулық сақтау саласының одан әрі дамуына негіз болады.

**Қолданылған әдебиеттер:**


1. World Health Organization. Noncommunicable diseases. – Geneva: WHO, 2024.
2. Digital Medicine. Digital twins in healthcare: recent advances and future perspectives // Digital Medicine. – 2024. – Vol. 7. – P. 1–15.
3. Corral-Acero J., Margara F., Marciniak M. et al. The ‘Digital Twin’ to enable the vision of precision cardiology // European Heart Journal. – 2020. – Vol. 41(48). – P. 4556–4564.
4. Choi D.J., Park J.J., Ali T., Lee S. Artificial intelligence for the diagnosis of heart failure // npj Digital Medicine. – 2020. – Vol. 3. – Article 54.
5. Smith J., Doe E. Artificial Intelligence in the Early Diagnosis of Heart Failure: A Comparative Clinical Study // The Lancet Digital Health. – 2024. – Vol. 6(3). – P. 142–151.
6. Shamanna P., Erukulapati R.S., Shukla A. et al. One-year outcomes of a digital twin intervention for type 2 diabetes: a retrospective real-world study // Scientific Reports. – 2024. – Vol. 14. – Article 25478.
7. Herrero P., Andorrà M., Breton M.D. et al. Glucose Predictions Improve Glycemic Control: A Digital Twin Evaluation // Diabetes Technology & Therapeutics. – 2026.
8. Nature Reviews Drug Discovery. How Generative AI Is Reducing Drug Discovery Timelines by 70% // Nature Portfolio. – 2025. – Vol. 24(4). – P. 295–297.
9. Wang W. AI Based Drug Screening Process: From Data Mining to Candidate Drug Validation // Bioscience Methods. – 2024. – Vol. 15(1). – P. 37–49.

# ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В СОВРЕМЕННОЙ ВЕБ-РАЗРАБОТКЕ

**Васильева Л.А. студент**

*Некоммерческое акционерное общество “Таразский университет имени М.Х. Дулати” г. Тараз, Республика Казахстан*

*Научный руководитель: Шрымбай Дана Абилахатовна, магистр естественных наук, старший преподаватель кафедры цифровых технологий и искусственного интеллекта*

*Аннотация. В статье рассматривается применение искусственного интеллекта в современной веб-разработке. Анализируются основные направления его использования: генерация и проверка программного кода, создание интерфейсов и контента, работа с данными, интеллектуальные чат-боты и персонализация веб-сервисов. Отдельное внимание уделено преимуществам и ограничениям ИИ, а также вопросам безопасности, качества результатов и защиты данных. Показано, что искусственный интеллект становится инструментом поддержки разработчика, однако не отменяет необходимость проверки кода и принятия технических решений человеком.*

**Введение.** Веб-разработка развивается в условиях постоянного увеличения объема информации и усложнения программных продуктов. Современный веб-сайт может включать клиентскую и серверную части, базы данных, внешние API, системы авторизации, аналитику и интерактивные сервисы. В таких условиях разработчику необходимо не только писать код, но и быстро находить решения, тестировать их и поддерживать уже созданные системы. Искусственный интеллект (ИИ) постепенно становится одним из инструментов, который помогает выполнять эти задачи.

По данным Stanford AI Index, в 2024 году доля опрошенных организаций, сообщивших об использовании ИИ, выросла до 78 % против 55 % годом ранее. В том же отчете отмечается рост использования генеративного ИИ в бизнес-функциях. Эти данные показывают, что ИИ переходит из области экспериментальных технологий в обычные рабочие процессы [1].

Основные направления применения ИИ. Одно из наиболее заметных направлений связано с программированием. ИИ-системы могут предлагать фрагменты HTML, CSS, JavaScript, Python и других языков, объяснять ошибки, создавать тесты и помогать преобразовывать существующий код. Например, разработчик может описать необходимую функцию обычным языком и получить первоначальный вариант реализации. Такой подход сокращает время на выполнение повторяющихся операций, но результат должен проверяться специалистом.

Отдельное значение имеют интеллектуальные помощники, встроенные в редакторы кода. Они способны учитывать окружающий код и предлагать продолжение программы. Исследования GitHub показывают, что применение Copilot в отдельных исследованиях было связано с повышением скорости выполнения задач разработчиками [2]. При этом такие результаты нельзя автоматически переносить на любой проект, поскольку эффективность зависит от типа задачи, опыта разработчика и качества исходного кода.

Второе направление связано с созданием пользовательского интерфейса. ИИ может помогать создавать структуру страниц, подбирать варианты расположения элементов, формировать тексты кнопок и подсказок, а также адаптировать содержание под разные сценарии использования. В результате разработчик может быстрее перейти от идеи к рабочему прототипу сайта.

Третье направление представляет собой интеграцию ИИ непосредственно в веб-сервис. На сайте могут работать чат-боты, системы поиска по естественному языку, инструменты суммаризации документов, рекомендации и автоматическая обработка текста. Развитие веб-API делает такую интеграцию более доступной. MDN отмечает, что

API позволяют разработчикам использовать готовые возможности браузера и внешних сервисов [3]. Кроме того, современные браузерные технологии уже экспериментируют с обращением веб-страницы к встроенным языковым моделям [4].

*Таблица 1 – Основные направления применения ИИ в веб-разработке*

| Направление | Применение | Результат |
|---|---|---|
| Разработка кода | Генерация фрагментов, объяснение ошибок, тестирование | Сокращение времени разработки |
| Интерфейс | Создание вариантов структуры и текстов элементов | Быстрое прототипирование |
| Чат-боты | Ответы на вопросы и обработка запросов пользователей | Автоматизация коммуникации |
| Работа с данными | Классификация, поиск, суммаризация и анализ текста | Ускорение обработки информации |
| Персонализация | Рекомендации и адаптация содержания | Более индивидуальное взаимодействие |

Преимущества использования ИИ. Использование ИИ позволяет автоматизировать часть рутинной работы и быстрее получать несколько вариантов решения одной задачи. Для начинающего разработчика особенно полезной является возможность получить объяснение ошибки простыми словами, увидеть пример кода и определить направление поиска проблемы. Для опытного разработчика ИИ может выступать инструментом быстрого прототипирования, генерации тестов и работы с документацией.

Еще одним преимуществом является возможность обработки больших объемов текстовой информации. Например, ИИ может кратко представить содержание документа, выделить ключевые элементы или классифицировать пользовательские обращения. Это особенно актуально для интернет-магазинов, образовательных платформ, информационных порталов и корпоративных систем.

Ограничения и риски. Несмотря на преимущества, применение ИИ не гарантирует получение правильного результата. Сгенерированный код может содержать логические ошибки, устаревшие подходы или небезопасные решения. Поэтому разработчик должен проверять результат, запускать тесты и учитывать особенности конкретного проекта.

Особое внимание необходимо уделять информационной безопасности. OWASP выделяет для приложений на базе больших языковых моделей такие риски, как prompt injection, раскрытие чувствительной информации, уязвимости цепочки поставок и неправильная обработка результатов модели [5]. Для веб-приложений это означает необходимость ограничивать права ИИ-компонента, проверять входные и выходные данные, защищать ключи доступа и не передавать модели лишнюю конфиденциальную информацию.

NIST также рассматривает генеративный ИИ с позиции управления рисками. В профиле AI Risk Management Framework рассматриваются риски, возникающие на различных этапах жизненного цикла ИИ-систем, и предлагаются действия для их выявления и снижения [6]. Для веб-разработки это означает, что безопасность ИИ следует учитывать не после создания сервиса, а еще на этапе проектирования.

Перспективы. Дальнейшее развитие ИИ в веб-разработке связано с переходом от простых инструментов генерации текста и кода к более комплексным помощникам. Они смогут анализировать структуру проекта, работать с документацией, выполнять часть тестов и помогать контролировать изменения. Одновременно возрастает значение инструментов, которые позволяют разработчику проверять происхождение информации и надежность полученного результата.

Практическое применение искусственного интеллекта в веб-проектах.

На практике искусственный интеллект может использоваться практически на всех этапах создания веб-приложения. На этапе проектирования он помогает сформировать структуру будущего сайта, определить основные страницы и пользовательские сценарии. Например, при разработке интернет-магазина ИИ может предложить структуру каталога, личного кабинета, корзины, системы поиска и страницы оформления заказа. Это позволяет разработчику быстрее перейти от общей идеи к конкретному плану проекта.

На этапе разработки ИИ может использоваться для создания отдельных компонентов программного кода. Разработчик может описать требуемую функцию обычным языком, после чего получить пример ее реализации. Также ИИ способен объяснять назначение отдельных участков кода и предлагать варианты их изменения. Особенно полезно это при работе с большими проектами, где необходимо разобраться в уже существующей программной структуре.

Важную роль ИИ может выполнять и при тестировании веб-приложений. С его помощью можно создавать тестовые сценарии, находить возможные ошибки и анализировать результаты тестирования. Например, для формы регистрации можно заранее определить различные варианты пользовательского ввода и проверить, как система реагирует на корректные и некорректные данные. Это позволяет выявлять часть проблем до того, как приложение будет опубликовано.

Еще одним перспективным направлением является персонализация веб-сервисов. ИИ способен анализировать действия пользователя и на основе полученной информации формировать индивидуальные рекомендации. В интернет-магазинах это могут быть рекомендации товаров, на образовательных платформах - подходящие учебные материалы, а на информационных сайтах - статьи, соответствующие интересам пользователя. При этом обработка пользовательских данных должна выполняться с учетом требований безопасности и конфиденциальности.

Интеграция ИИ особенно заметна в современных образовательных веб-приложениях. Такие системы могут анализировать ответы учащихся, автоматически формировать вопросы для тестирования, объяснять ошибки и создавать краткие материалы по изучаемой теме. В результате веб-приложение становится не только средством отображения информации, но и интерактивной системой, которая может адаптироваться к действиям пользователя.

При разработке подобных систем важно правильно распределять задачи между человеком и искусственным интеллектом. ИИ может выполнять повторяющиеся операции и предлагать варианты решений, однако окончательная проверка результата должна оставаться за разработчиком. Такой подход позволяет одновременно использовать преимущества автоматизации и сохранять контроль над качеством программного продукта.

Таким образом, практическое применение искусственного интеллекта в веб-разработке выходит далеко за пределы автоматической генерации программного кода. ИИ может участвовать в проектировании, разработке, тестировании, анализе данных, создании контента и взаимодействии с пользователями. Благодаря этому современные веб-приложения становятся более функциональными и способны предоставлять пользователю более персонализированный опыт.

Безопасность и защита данных при внедрении ИИ (LLM Security)

Интеграция больших языковых моделей в веб-приложения создает абсолютно новые векторы атак, которые традиционные брандмауэры веб-приложений (WAF) не всегда способны заблокировать. Организация OWASP разработала специализированный стандарт OWASP Top 10 for Large Language Model Applications, определяющий главные уязвимости ИИ-систем

Ключевой угрозой для веб-сервисов является инъекция подсказок (Prompt Injection). Злоумышленник может внедрить специально сформированный текст в пользовательский ввод (например, в форму обратной связи или комментарий), чтобы заставить модель проигнорировать системные инструкции и выполнить несанкционированные команды: выдать конфиденциальные данные из базы, сгенерировать вредоносный скрипт (XSS) или обойти проверку прав доступа.

Для защиты веб-приложений применяются следующие меры безопасности: Архитектурное разделение системного контекста и пользовательского ввода на уровне вызовов API, внедрение промежуточных фильтрующих сервисов (Guardrails), проверяющих входящие промпты и исходящие ответы модели на наличие опасных паттернов и утечек PII (Personally Identifiable Information), применение принципа наименьших привилегий (Least Privilege) при предоставлении ИИ-агентам доступа к внутренним веб-API и функциям исполняемой среды (Function Calling).

Национальный институт стандартов и технологий США (NIST) в руководстве AI Risk Management Framework подчеркивает необходимость сквозного мониторинга жизненного цикла данных и работы моделей в веб-приложениях для минимизации галлюцинаций и смещения ответов

Экономическая эффективность и вызовы автоматизации

Внедрение ИИ в практику веб-разработки сопровождается необходимость жесткого учета совокупной стоимости владения (Total Cost of Ownership — TCO). Несмотря на снижение затрат на написание первичного кода, появляются новые категории расходов: Оплата инфраструктуры вычислительных мощностей (GPU) или подписок на сторонние SaaS API (OpenAI, Anthropic, Google Gemini, затраты на оптимизацию контекстного окна и снижение стоимости токенизации запросов (Prompt Engineering & Optimization), Временные затраты высококвалифицированных инженеров на проведение код-ревью и исправление тонких логических ошибок, сгенерированных нейросетями.

Главным практическим риском остается эффект «галлюцинирования» моделей и генерация визуально корректного, но содержательно ошибочного или уязвимого кода. Без жесткого инженерного контроля использование ИИ может приводить к быстрому накапливанию технического долга в веб-проекте.

Интеллектуальная оптимизация пользовательского опыта (AI-Driven UX/UI)

Современный веб-дизайн под влиянием ИИ переходит от статических интерфейсных сеток к динамически адаптируемым средам. Искусственный интеллект позволяет реализовывать концепцию «персонализации «на лету»» (Just-In-Time UI). На основе анализа текущего поведения пользователя (движение курсора, глубина скроллинга, скорость кликов, историю предыдущих сессий) нейросетевые алгоритмы способны менять приоритеты отображения блоков, подстраивая контрастность, размер элементов и структуру меню под конкретного посетителя.

Значительный прогресс наблюдается в области обеспечения доступности веб-интерфейсов (Accessibility, Web Content Accessibility Guidelines — WCAG). ИИ-системы автоматизируют генерацию альтернативных описаний (alt-тегов) для изображений, распознавая контекст сцены с помощью компьютерного зрения. Дополнительно языковые модели способны в автоматическом режиме размечать сложные интерактивные компоненты веб-страницы атрибутами WAI-ARIA, делая их доступными для пользователей со сниженным зрением, применяющих программы чтения экрана (screen readers).

**Заключение.** Искусственный интеллект уже является частью современной веб-разработки. Он применяется для создания кода и интерфейсов, анализа данных, автоматизации общения с пользователями и персонализации веб-сервисов. Основной практический эффект заключается в ускорении отдельных этапов работы и снижении

количества рутинных операций. Вместе с тем ИИ не исключает роль разработчика: человек должен определять архитектуру проекта, проверять сгенерированный код, тестировать систему и отвечать за безопасность. Поэтому наиболее рациональным подходом является использование ИИ как инструмента поддержки, а не как полной замены специалиста.

**Список литературы**

[1] Stanford Institute for Human-Centered Artificial Intelligence. The 2025 AI Index Report: Economy.Stanford University, 2025. URL: https://hai.stanford.edu/ai-index/2025-ai-index-report/economy

[2] GitHub Research. Research: How GitHub Copilot helps improve developer productivity.GitHub Blog, 2022. URL: https://github.blog/news-insights/research/research-how-github-copilot-helps-improve-developer-productivity/

[3] MDN Web Docs. Introduction to Web APIs.Mozilla Developer Network, 2026. URL: https://developer.mozilla.org/en-US/docs/Learn_web_development/Extensions/Client-side_APIs/Introduction

[4] MDN Web Docs. Prompt API.Mozilla Developer Network, 2026. URL: https://developer.mozilla.org/en-US/docs/Web/API/Prompt_API

[5] OWASP Foundation. OWASP Top 10 for Large Language Model Applications 2025.OWASP GenAI Security Project, 2025. URL: https://genai.owasp.org/resource/owasp-top-10-for-llm-applications-2025/

[6] Autio C., Schwartz R., Dunietz J. et al. Artificial Intelligence Risk Management Framework: Generative Artificial Intelligence Profile.NIST AI 600-1. National Institute of Standards and Technology, 2024. DOI: https://doi.org/10.6028/NIST.AI.600-1

# ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА КООРДИНАЦИИ БПЛА И МОБИЛЬНОГО РОБОТОТЕХНИЧЕСКОГО КОМПЛЕКСА ПРИ ЛИКВИДАЦИИ ЧРЕЗВЫЧАЙНЫХ СИТУАЦИЙ

[1]Калкабек Айдос Мусаулы, ТОО «R&D центр «Казахстан инжиниринг», г. Астана, Республика Казахстан, Aidos.kalkabek@mail.ru, +7 (776) 879 18 18
[2]Маматалиев Марлен Абдырахманович, m.mamataliev@mail.ru +996990900000
[3]Торобеков Бекжан Торобекович, доктор технических наук, профессор кафедры ОПУТ Кыргызского государственного технического университета им. И. Раззакова. Контактная информация: e-mail: bekjan2003@mail.ru +996772534671

***Аннотация.*** *В статье рассматривается концепция интеллектуальной системы координации беспилотного летательного аппарата (БПЛА) и мобильного робототехнического комплекса (МРК) для выполнения задач мониторинга и ликвидации последствий чрезвычайных ситуаций. Предлагаемый подход основан на распределении функций между воздушным и наземным роботизированными средствами. БПЛА используется для оперативной разведки территории, формирования информационной модели зоны чрезвычайной ситуации, мониторинга транспортных средств, обнаружения опасных объектов и определения их координат. МРК, в свою очередь, выполняет наземное обследование, доставку специального оборудования и непосредственное выполнение целевой операции в опасной зоне. Предложена многоуровневая архитектура системы, включающая подсистемы восприятия, обработки данных, принятия решений, планирования маршрута и управления исполнительными устройствами. Сформулирована задача совместной оптимизации маршрутов БПЛА и МРК с учетом времени выполнения миссии, энергетических затрат, уровня риска и ограничений канала связи. Рассмотрен алгоритм взаимодействия воздушного и наземного компонентов в условиях неполной и динамически изменяющейся информации. Предложенная архитектура может применяться при пожарах, авариях на промышленных объектах, разрушении инфраструктуры, мониторинге транспортных систем и других чрезвычайных ситуациях, в которых непосредственное присутствие человека связано с повышенным риском.*

***Ключевые слова:*** *беспилотный летательный аппарат, БПЛА, мобильный робототехнический комплекс, МРК, искусственный интеллект, компьютерное зрение, чрезвычайная ситуация, автономная навигация, планирование маршрута, роботизированная система.*

**Введение.** Современные чрезвычайные ситуации характеризуются высокой динамичностью, неопределенностью состояния окружающей среды и значительным риском для персонала аварийно-спасательных подразделений. При пожарах, авариях на промышленных объектах, разрушениях зданий, техногенных катастрофах и других опасных событиях получение достоверной информации о состоянии территории должно осуществляться в минимально возможное время.

Одним из перспективных направлений развития аварийно-спасательных технологий и мониторинга транспортных средств является применение роботизированных систем. Беспилотные летательные аппараты позволяют быстро получать информацию о большой территории с высоты, тогда как наземные мобильные робототехнические комплексы способны выполнять задачи непосредственно в опасной зоне. Совместное применение этих двух типов роботизированных платформ позволяет объединить преимущества воздушной и наземной разведки.

Современные исследования показывают развитие направления air-ground cooperative systems, в которых БПЛА и наземные роботы рассматриваются как неоднородная роботизированная система с совместным планированием, распределением

задач и координацией действий [1, 2]. В частности, современные работы рассматривают применение БПЛА для получения глобальной информации о местности и последующего формирования маршрута наземного робота [3].

Отдельным направлением является применение БПЛА в условиях чрезвычайных ситуаций. Исследования последних лет рассматривают задачи разведки, оценки последствий, обеспечения связи, доставки и поддержки принятия решений с использованием беспилотных систем [4]. При этом сохраняются проблемы энергетических ограничений, устойчивости связи, работы в динамической среде и отсутствия универсальных стандартов оценки роботизированных систем [5].

В связи с этим представляет интерес разработка интеллектуальной системы, в которой БПЛА и МРК не функционируют независимо друг от друга, а рассматриваются как единый роботизированный комплекс.

Целью настоящей работы является разработка концептуальной архитектуры и математической модели интеллектуальной координации БПЛА и МРК для выполнения задач мониторинга и ликвидации чрезвычайных ситуаций.

Для достижения поставленной цели необходимо решить следующие задачи:

- разработать архитектуру взаимодействия БПЛА и МРК;
- определить функциональное распределение задач между воздушной и наземной платформами;
- сформировать модель информационного обмена между компонентами системы;
- разработать алгоритм выбора и корректировки маршрута МРК на основании информации, полученной БПЛА;
- сформулировать критерий оптимизации совместной миссии;
- определить основные ограничения, влияющие на эффективность системы.

**Результаты исследования.** Разработана концепция интеллектуальной системы, согласно которой предлагаемая система рассматривается как неоднородная роботизированная группа, состоящая из воздушного и наземного компонентов (Рис.1).

БПЛА выполняет функции воздушной разведки и информационного обеспечения:

- обследование территории;
- получение фото- и видеоданных;
- формирование мониторинговых параметров транспортных систем;
- использование тепловизионного канала при наличии соответствующего оборудования;
- обнаружение потенциально опасных объектов;
- определение координат объектов;
- формирование карты обследованной территории;
- обнаружение препятствий и потенциально непроходимых участков;
- передача информации наземному комплексу.

МРК выполняет функции наземного исполнения:

- перемещение в заданную область;
- обследование территории с использованием бортовых сенсоров;
- уточнение информации, полученной от БПЛА;
- выполнение специальной задачи;
- доставка оборудования;
- локальное воздействие на объект чрезвычайной ситуации.

Таким образом, БПЛА выполняет преимущественно функцию «воздушного сенсора», а МРК — функцию исполнительного роботизированного средства.

Принцип взаимодействия представлен следующим образом:

БПЛА → сбор информации → интеллектуальная обработка → определение объекта → определение координат → планирование маршрута МРК → передача задания → движение МРК → уточнение обстановки → выполнение задачи.

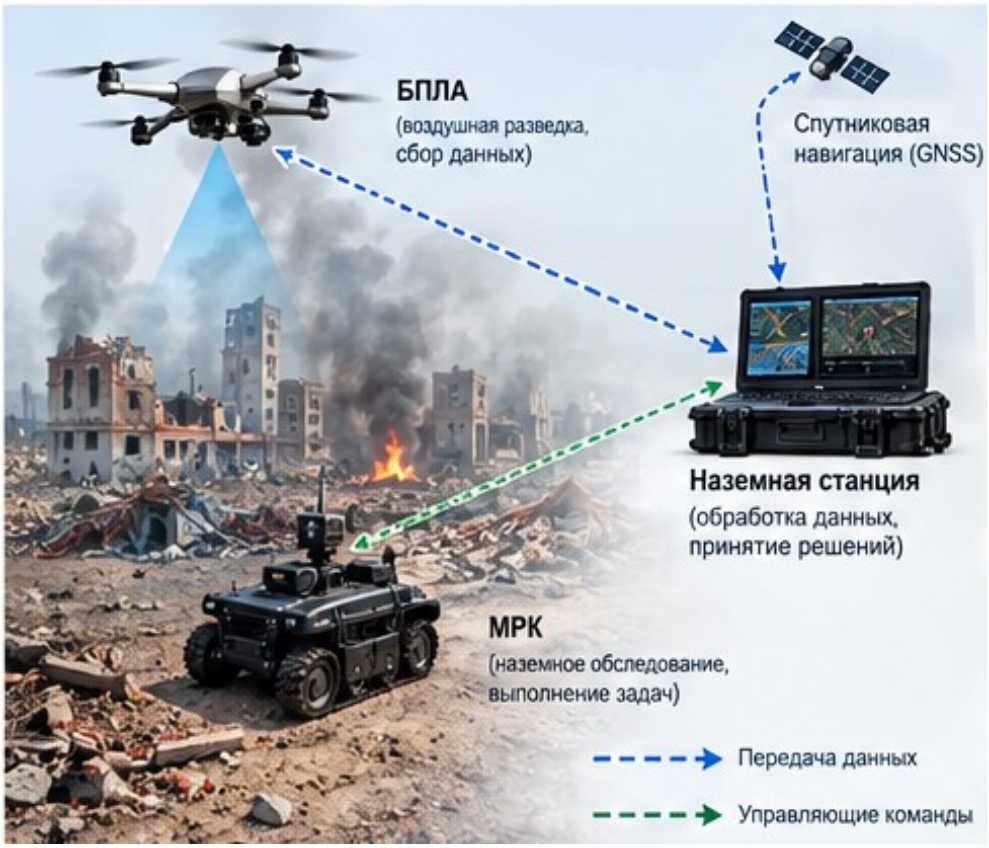



Рисунок 1. Общая концепция взаимодействия БПЛА и МРК

Ключевым элементом предлагаемой системы является не отдельный робот, а интеллектуальный модуль координации, который объединяет информацию от обоих компонентов и формирует последовательность действий.

**Архитектура системы.** Архитектуру предлагаемой системы целесообразно разделить на пять функциональных уровней (Рис. 2):

1. Уровень восприятия**.** На данном уровне осуществляется получение информации от сенсоров БПЛА и МРК. Для БПЛА источниками данных могут выступать RGB-камера, тепловизионная камера, GNSS/INS и другие сенсоры. Для МРК дополнительно могут использоваться лидар, камеры, ультразвуковые или другие датчики расстояния.

2. Уровень обработки данных**.** Полученные данные проходят предварительную обработку. Для видеопотока могут применяться алгоритмы компьютерного зрения, классификации и обнаружения объектов.

3. Уровень формирования пространственной модели. На основании данных воздушного и наземного наблюдения формируется карта исследуемой территории. Карта может содержать информацию о препятствиях, опасных участках, целевых объектах и доступных маршрутах.

4. Уровень принятия решений. Интеллектуальный модуль определяет приоритеты объектов, назначает задачи БПЛА и МРК и корректирует последовательность действий в зависимости от изменения обстановки.

5. Уровень управления**.** На основании сформированного задания производится передача команд МРК и БПЛА.

В общем виде архитектуру можно представить следующим образом:




Рисунок 2. Архитектура интеллектуальной системы

БПЛА
↓
Сенсоры → обработка видеоданных → обнаружение объектов
↓
Интеллектуальный модуль координации
↓
Пространственная модель / карта
↓
Планирование миссии и маршрута
↓
Система управления МРК
↓
МРК → сенсоры → исполнительное оборудование

При этом информация от МРК возвращается обратно в интеллектуальный модуль, образуя замкнутый контур управления.

4. Математическая модель координации. Для формализации задачи рассмотрим территорию чрезвычайной ситуации как двумерное пространство

$$\Omega \subset R2.\backslash Omega \backslash subset\ R\hat{}2.$$

Положение БПЛА в момент времени tt обозначим:

$$Pu(t)=(xu(t),yu(t),hu(t)),P\_u(t)=(x\_u(t),y\_u(t),h\_u(t)),$$

где xu,yux_u,y_u — горизонтальные координаты, huh_u — высота полета.

Положение МРК:

$$Pg(t)=(xg(t),yg(t)).P\_g(t)=(x\_g(t),y\_g(t)).$$

Пусть на обследуемой территории существует множество потенциально опасных объектов:

$$O=\{o1,o2,\ldots,on\}.O=\{o_1,o_2,\ldots,o_n\}.$$

Каждому объекту oio_i может быть присвоена оценка приоритета:

$$Wi=f(Si,Di,Ri),W_i=f(S_i,D_i,R_i),$$

где:

- SiS_i — степень опасности объекта;
- DiD_i — значимость объекта для выполнения миссии;
- RiR_i — оценка риска для персонала.

Приоритет объекта должен пересчитываться при поступлении новой информации.

Для выбора маршрута МРК предлагается использовать целевую функцию:

$$J=\alpha T+\beta L+\gamma E+\delta R,J=\alpha T+\beta L+\gamma E+\delta R,$$

где:

- TT — время выполнения миссии;
- LL — длина маршрута;
- EE — энергетические затраты;
- RR — интегральный показатель риска;
- α,β,γ,δ\alpha,\beta,\gamma,\delta — весовые коэффициенты.

Оптимальный маршрут определяется условием:

$$J*=minJ.J^*=\min J.$$

В отличие от классической задачи построения кратчайшего пути, предложенная модель учитывает не только расстояние, но и риск, энергетические ограничения и время выполнения операции. Это особенно важно для чрезвычайных ситуаций, поскольку кратчайший маршрут не обязательно является безопасным или проходимым.

**Алгоритм взаимодействия БПЛА и МРК.** Работа системы может быть представлена в виде последовательности из восьми этапов (Рис. 3).



Рисунок 3. Алгоритм взаимодействия БПЛА и МРК

Этап 1. Получение исходных данных. В систему загружаются координаты района, точка базирования роботизированных средств и параметры миссии.

Этап 2. Воздушная разведка. БПЛА выполняет обследование заданной области и передает данные на вычислительный модуль.

Этап 3. Обнаружение объектов. Алгоритм компьютерного зрения анализирует видеопоток и выделяет потенциально опасные объекты.

Для каждого обнаруженного объекта формируется набор параметров:

Oi=(xi,yi,ci,pi),O_i=(x_i,y_i,c_i,p_i),

где:

- xi,yix_i,y_i — координаты;
- cic_i — класс объекта;
- pip_i — вероятность корректного обнаружения.

Этап 4. Оценка ситуации**.** Интеллектуальный модуль анализирует полученные данные и определяет приоритетность обнаруженных объектов.

Этап 5. Построение маршрута. На основе полученной карты формируется допустимый маршрут МРК (Рис. 4).

При появлении новых данных маршрут пересчитывается.

Этап 6. Передача задания МРК.МРК получает:

- координаты целевого объекта;
- рекомендуемый маршрут;
- информацию об обнаруженных препятствиях;
- приоритет задачи;
- дополнительные ограничения.

Этап 7. Наземное обследование. При приближении к объекту МРК использует собственные сенсоры для уточнения состояния окружающей среды.

Этап 8. Коррекция миссии. Полученная от МРК информация передается обратно в интеллектуальный модуль. При необходимости производится повторное обследование БПЛА и корректировка маршрута или задачи.

Такой принцип позволяет реализовать замкнутый цикл: обнаружение → анализ → решение → действие → получение новой информации → корректировка решения.

**Интеллектуальная обработка данных.** Одним из ключевых компонентов системы является компьютерное зрение.

В простейшем варианте БПЛА передает видеопоток на вычислительную систему, где производится обнаружение интересующих объектов.

В качестве объектов обнаружения в зависимости от конкретного сценария могут рассматриваться:

- очаги возгорания;
- задымление;
- разрушенные конструкции;
- транспортные средства;
- люди;
- поврежденные участки инфраструктуры;
- зоны, непроходимые для МРК.

Для повышения надежности целесообразно использовать мультисенсорный подход, объединяя данные RGB-камеры, тепловизионного канала, навигационной системы и наземных сенсоров.

В этом случае состояние объекта может быть представлено вектором:

Xi=[xi,yi,ci,pi,Ti,Di],X_i=[x_i,y_i,c_i,p_i,T_i,D_i],

где TiT_i характеризует температурные признаки, а DiD_i — дополнительную информацию о состоянии объекта.

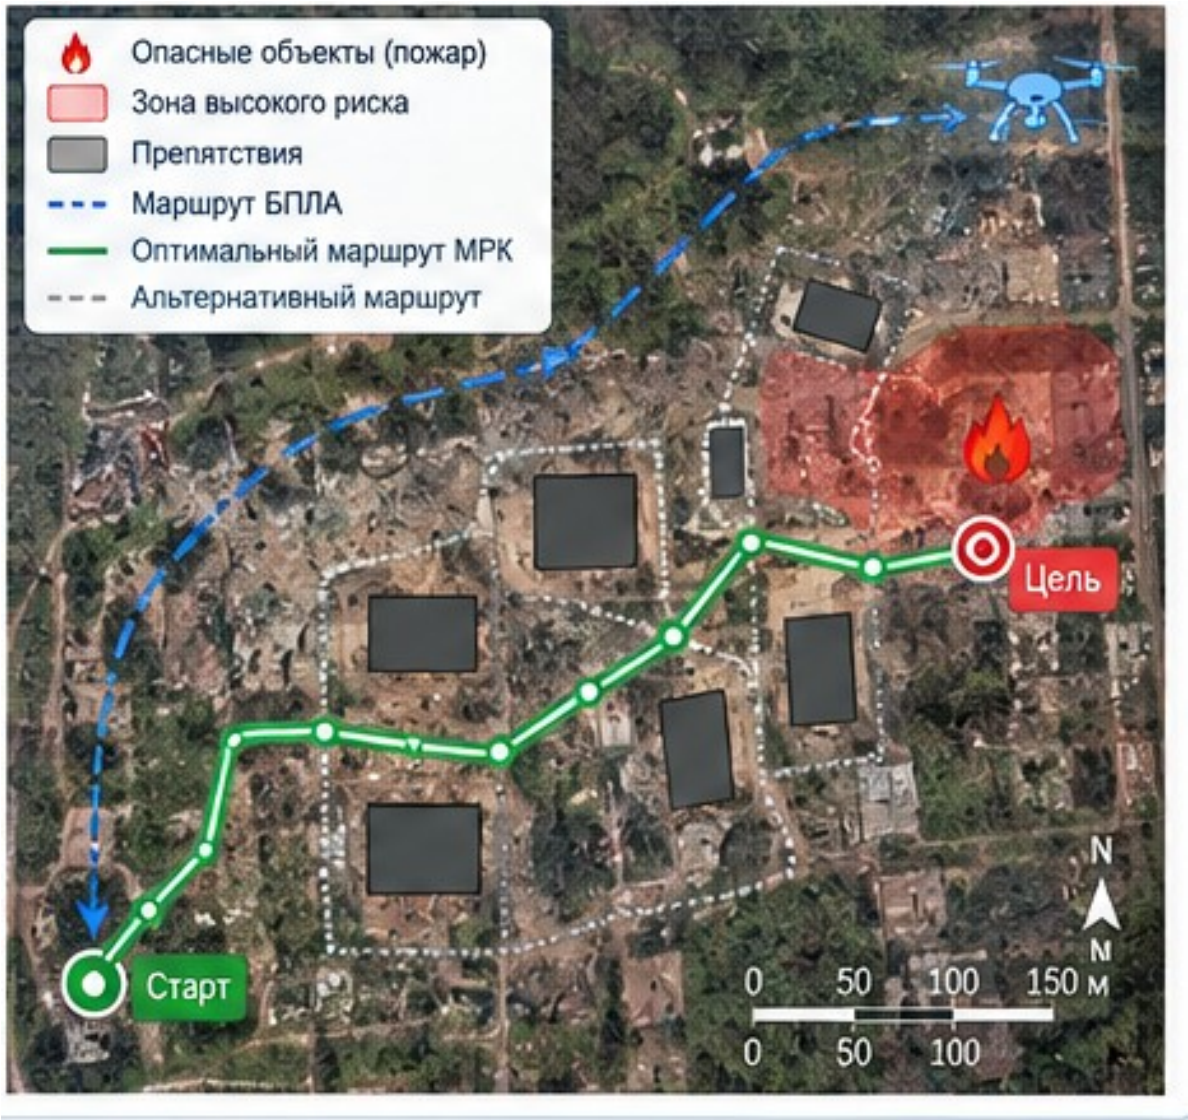



Рисунок 4. Построение маршрута МРК на основе данных БПЛА

Информация от БПЛА при этом не должна рассматриваться как окончательное решение. Она используется для формирования предварительной оценки, которая уточняется наземным роботом.

Такой подход позволяет уменьшить влияние ошибок классификации и неопределенности воздушной разведки.

**Сценарий применения при пожаре.** Рассмотрим типовой сценарий чрезвычайной ситуации на промышленном объекте.

После получения информации о пожаре БПЛА автоматически или оператором направляется в район происшествия.

В процессе полета БПЛА выполняет съемку территории и передает данные в систему обработки.

Интеллектуальный модуль обнаруживает область с признаками интенсивного нагрева и определяет ее координаты.

Одновременно производится оценка возможных маршрутов движения МРК.

Если один из участков маршрута перекрыт разрушенной конструкцией, система исключает его из множества допустимых маршрутов.

После определения безопасного маршрута МРК направляется к заданной точке.

По мере движения МРК получает актуальную информацию о состоянии территории.

Если ситуация изменяется, например происходит распространение огня или появляется новое препятствие, БПЛА повторно обследует соответствующий участок, а система выполняет перерасчет маршрута.

После достижения целевой точки МРК выполняет предусмотренную техническим заданием операцию.

Важной особенностью является возможность разделения зон ответственности:

- БПЛА обеспечивает обзор и раннее обнаружение изменений;
- МРК выполняет наземную проверку;
- интеллектуальная система объединяет информацию и определяет последующее действие.

**Оценка эффективности системы.** Для экспериментального исследования предлагаемой системы целесообразно использовать следующие показатели:

Для проверки эффективности системы необходимо сравнить как минимум два режима:

**Режим 1:** МРК действует по заранее заданному маршруту без использования воздушной разведки.

**Режим 2:** МРК получает информацию от БПЛА и использует динамическую корректировку маршрута.

Основной научный интерес представляет определение того, насколько применение воздушной разведки влияет на время обнаружения, длину маршрута, количество вынужденных остановок и безопасность движения.

При наличии экспериментальных данных результаты могут быть представлены в виде:

$$\Delta T = \frac{T_1 - T_2}{T_1} \cdot 100\%,$$

где $T_1$ — показатель для базового сценария, а $T_2$ — показатель для координированной системы.

Аналогичным образом могут сравниваться длина маршрута и энергетические затраты.

Важно отметить, что конкретные численные значения эффективности должны определяться по результатам натурных или имитационных экспериментов. В настоящей работе численные результаты не подменяются расчетными предположениями.

**Обсуждение.** Предлагаемая архитектура соответствует современному направлению развития неоднородных роботизированных систем, в которых воздушные и наземные платформы рассматриваются как единая система принятия решений (Рис.5.)

Исследования UAV–UGV-систем показывают, что использование БПЛА для получения информации о состоянии маршрута может применяться для построения безопасного пути наземного робота. В частности, опубликованные исследования рассматривают использование воздушного робота как средства формирования карты и последующего планирования маршрута наземной платформы [3].

Современные исследования 2026 года также рассматривают динамическое совместное планирование UAV–UGV в неопределенной среде, когда БПЛА обследует потенциально непроходимые участки, после чего информация используется для построения маршрута наземного робота [6].

Это подтверждает целесообразность архитектуры, в которой БПЛА выполняет не только наблюдение, но и является источником информации для динамического планирования наземной миссии.

При этом для реального применения системы необходимо учитывать ряд ограничений:

- ограниченную продолжительность полета БПЛА;

- ограниченную энергию МРК;
- дальность и устойчивость канала связи;
- задержку передачи данных;
- ошибки позиционирования;
- изменение состояния среды;
- погодные условия;
- ограничения вычислительных ресурсов;
- неопределенность результатов компьютерного зрения.

Отдельное значение имеет проблема потери связи. При временном отсутствии связи система должна иметь безопасный режим работы, например продолжение движения по последнему подтвержденному маршруту, остановку или возврат в заданную безопасную точку.

Для практического применения также целесообразно предусмотреть участие оператора в контуре управления. Интеллектуальная система может автоматически выполнять обработку данных и формирование рекомендаций, при этом оператор получает возможность подтверждать критические действия.




Рисунок 5. Схема реализации

**Научная новизна предлагаемого подхода.** Научно-техническая составляющая работы заключается в объединении воздушной разведки и наземного исполнения в едином контуре принятия решений.

В отличие от независимого применения БПЛА и МРК предлагается рассматривать их как единую информационно-управляющую систему, в которой:

- БПЛА формирует актуальную пространственную информацию;
- интеллектуальный модуль выполняет анализ данных;
- МРК получает динамически формируемое задание;
- наземные данные используются для актуализации модели среды и мониторинга;
- маршрут МРК может пересчитываться при изменении обстановки.

Таким образом, архитектура позволяет реализовать принцип **«разведка — анализ-мониторинговые данные — планирование — действие — обратная связь»**.

Предлагаемый подход может служить основой для создания цифрового прототипа системы и последующего проведения натурных испытаний.

**Заключение.** В работе рассмотрена архитектура интеллектуальной системы координации беспилотного летательного аппарата и мобильного робототехнического комплекса для ликвидации чрезвычайных ситуаций и проведения мониторинговых процессов.

Показано, что объединение воздушной и наземной роботизированных платформ позволяет сформировать многоуровневую систему, в которой БПЛА используется для оперативного получения информации о состоянии территории, а МРК — для выполнения задач непосредственно в опасной зоне.

Сформулирована математическая модель выбора маршрута, учитывающая время выполнения миссии, длину маршрута, энергетические затраты и уровень риска. Предложен алгоритм, предусматривающий динамическое обновление маршрута МРК на основании новой информации, получаемой от БПЛА и наземных сенсоров.

Перспективным направлением дальнейших исследований является разработка программного прототипа системы, интеграция алгоритмов компьютерного зрения, построение трехмерной карты зоны чрезвычайной ситуации и проведение сравнительных натурных экспериментов.

Предлагаемая система может рассматриваться как основа для дальнейшего создания интеллектуального робототехнического комплекса, предназначенного для повышения оперативности мониторинга и снижения необходимости непосредственного присутствия человека в опасной зоне.

## ЛИТЕРАТУРА

1. Zhou Y., Zhao J., Sun N., Wu Y., Shi Q., Wang G., El Kamel A. Heterogeneous agents, unified missions: A survey and taxonomy on air-ground cooperative systems // Robotics and Autonomous Systems. 2026. Vol. 203. Article 105514. DOI: 10.1016/j.robot.2026.105514.

2. Cooperative motion planning and control for aerial-ground autonomous systems: Methods and applications // Progress in Aerospace Sciences. 2024. Vol. 146. Article 101005. DOI: 10.1016/j.paerosci.2024.101005.

3. Liu D., Liu D. Vision-based map building and path planning method in unmanned air/ground vehicle cooperative systems // The Journal of Engineering. 2020. DOI: 10.1049/joe.2019.1144.

4. Drones in emergencies: A review of recent developments and future directions // Computers & Industrial Engineering. 2026. Vol. 216. Article 112003. DOI: 10.1016/j.cie.2026.112003.

5. Chen Z., et al. Survey on Reconnaissance Autonomous Robotic Systems for Disaster Management // Sensors. 2026. Vol. 26. No. 5. Article 1659. DOI: 10.3390/s26051659.

6. Nguyen N., Akella S. Dynamic UGV-UAV Cooperative Path Planning in Uncertain Environments. 2026.

7. A Framework for a Cooperative UAV-UGV System for Path Discovery and Planning // IEEE Conference Publication. 2018.

8. Recchiuto C.T. Post-disaster assessment with unmanned aerial vehicles: A survey on practical implementations and research approaches // Journal of Field Robotics. 2018. Vol. 35. No. 4. P. 459–490. DOI: 10.1002/rob.21756.

9. Delmerico J., et al. The current state and future outlook of rescue robotics // Journal of Field Robotics. 2019. DOI: 10.1002/rob.21887.

10. Nam D.H., Kim H.G. Integrated Task Scheduling, Path Planning, and Control for Cooperative UGV–UAV Systems via an Extended MPPI-GA Framework. 2026.

# ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА УПРАВЛЕНИЯ АГРОРОБОТОМ НА ОСНОВЕ МЕТОДОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ И АНАЛИЗА ДАННЫХ ДЛЯ ТОЧЕЧНОЙ ОБРАБОТКИ ПОСЕВОВ

Айдарова Л.Н., Калимолдаев М.Н.
e-mail: aidarovalaila@gmail.com
*Казахский национальный университет имени аль-Фараби, Алматы, Казахстан*

***Аннотация.*** *В работе рассматривается интеллектуальная система управления наземным агророботом, предназначенным для мониторинга посевов и точечной обработки растений. Предложена многоуровневая архитектура, объединяющая модуль компьютерного зрения для детекции культурных растений и сорняков, модуль анализа данных с построением геопривязанной карты засорённости и модуль принятия решений, формирующий команды для системы навигации и исполнительных механизмов. Для распознавания объектов используется одностадийный детектор семейства YOLO, для навигации вдоль рядков — сегментация растительности по индексу избыточной зелени и алгоритм следования траектории pure pursuit. Описаны методика формирования обучающей выборки, правила выбора агротехнической операции и методика экспериментальной проверки системы, включающая оценку качества распознавания, точности навигации и экономии гербицидов при переходе от сплошного опрыскивания к точечной обработке.*

***Ключевые слова:*** *агроробот, компьютерное зрение, точное земледелие, детекция сорняков, YOLO, анализ данных, навигация по рядкам, точечное опрыскивание.*

## Введение

Сельское хозяйство остаётся одной из ключевых отраслей экономики Республики Казахстан, при этом отрасль испытывает нехватку квалифицированной рабочей силы и находится под давлением требований к снижению химической нагрузки на почву. Традиционная технология сплошного внесения гербицидов предполагает обработку всей площади поля, хотя сорняки, как правило, распределены неравномерно и занимают лишь часть площади. Это приводит к перерасходу препаратов, росту себестоимости продукции и загрязнению окружающей среды.

Одним из направлений решения этой проблемы является точное земледелие, в рамках которого агротехнические операции выполняются дифференцированно с учётом состояния конкретного участка или отдельного растения [1]. Ключевым элементом такого подхода становятся автономные агророботы, способные перемещаться по полю, распознавать объекты и выполнять операции без постоянного участия человека [2]. Развитие методов глубокого обучения, прежде всего свёрточных нейронных сетей, существенно повысило точность распознавания растений, сорняков и болезней по изображениям [3, 4].

Вместе с тем большинство существующих решений либо ориентированы на отдельную задачу (только детекцию сорняков или только навигацию), либо требуют дорогостоящего оборудования. Актуальной остаётся задача построения целостной системы управления, в которой результаты компьютерного зрения используются одновременно для навигации, анализа состояния посевов и принятия решений об обработке. Целью настоящей работы является разработка архитектуры и алгоритмов такой интеллектуальной системы управления агророботом.

## 1. Архитектура системы

Предлагаемая система построена по многоуровневому принципу (рис. 1). Уровень сенсоров включает RGB-камеру, направленную на рядки под углом к поверхности, мультиспектральную камеру для оценки состояния растений, приёмник GNSS с RTK-поправками, инерциальный измерительный блок и одометрию колёсных приводов.

Программная часть реализована в виде набора узлов на платформе ROS [5], что обеспечивает модульность и возможность независимой замены отдельных компонентов.

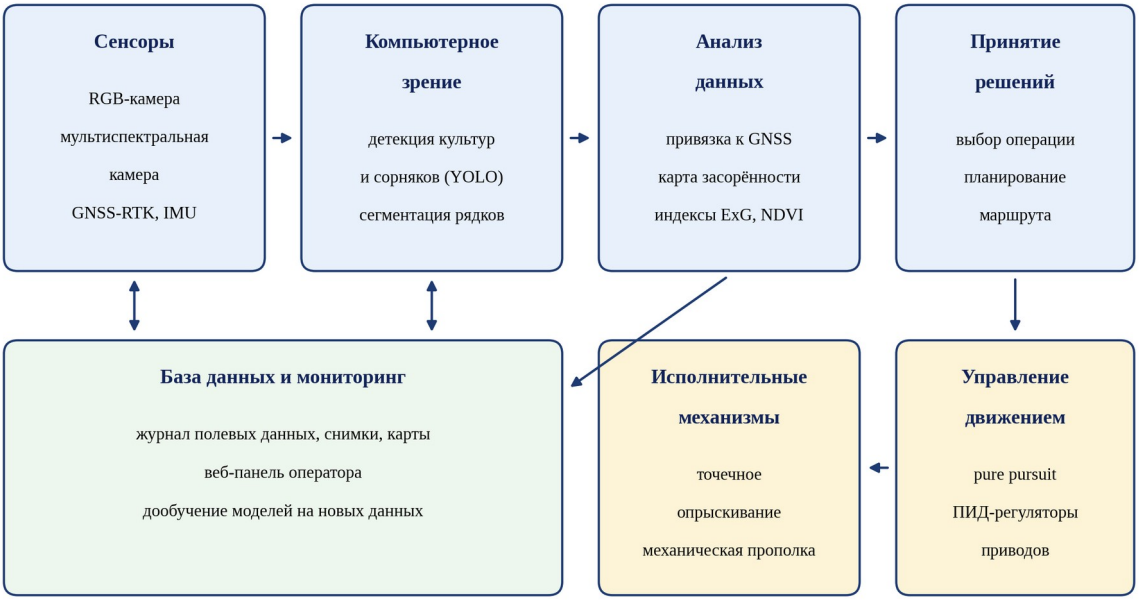



Рис. 1. Архитектура интеллектуальной системы управления агроробота

Модуль компьютерного зрения обрабатывает поток изображений и формирует список обнаруженных объектов с классами, координатами и степенью уверенности, а также маску растительности для навигации. Модуль анализа данных переводит координаты объектов из системы камеры в глобальную систему координат поля и накапливает их в геопривязанной карте. Модуль принятия решений на основе карты и текущего положения робота определяет, какую операцию выполнить, и передаёт команды системе управления движением и исполнительным механизмам. Все данные сохраняются в базе данных, доступной оператору через веб-интерфейс и используемой для последующего дообучения моделей.

## 2. Модуль компьютерного зрения

Задача распознавания решается в двух вариантах. Для навигации вдоль рядков достаточно отделить растительность от почвы. Для этого используется индекс избыточной зелени, вычисляемый по нормированным цветовым компонентам пикселя:

$$\mathrm{ExG} = 2g - r - b, \quad r = R/(R+G+B), \quad g = G/(R+G+B), \quad b = B/(R+G+B) \qquad (1)$$

где $R$, $G$, $B$ – значения цветовых каналов. Бинаризация изображения по порогу, выбираемому методом Оцу, даёт маску растительности, по которой с помощью преобразования Хафа выделяются линии рядков. Отклонение робота от оси междурядья вычисляется по положению центральной линии относительно центра кадра.

Для различения культурных растений и сорняков применяется одностадийный детектор семейства YOLO [6], обеспечивающий обработку кадров в реальном времени на встраиваемом вычислителе с графическим ускорителем. Модель дообучается методом переноса обучения на собственной выборке изображений, полученных в полевых условиях при разном освещении, на разных фазах развития растений и с разной степенью засорённости. Разметка выполняется по классам «культура» и «сорняк», при необходимости класс сорняков разбивается на группы (однодольные и двудольные), поскольку от этого зависит выбор препарата. Для повышения устойчивости к условиям съёмки применяются аугментации: изменение яркости и контраста, размытие, случайные повороты и масштабирование.

Качество детекции оценивается стандартными метриками: точностью $P$, полнотой $Rc$ и средней точностью mAP при пороге пересечения IoU = 0,5:

$$P = TP/(TP+FP), \quad Rc = TP/(TP+FN), \quad \mathrm{IoU} = |A \cap B| \,/\, |A \cup B| \qquad (2)$$

где *TP*, *FP*, *FN* – число верно обнаруженных, ложно обнаруженных и пропущенных объектов, *A* и *B* – предсказанная и эталонная рамки объекта.

### 3. Анализ данных и принятие решений

Каждый обнаруженный объект переводится из координат изображения в координаты поля с использованием калибровки камеры, текущего положения робота по GNSS-RTK и ориентации по данным IMU. Поле разбивается на регулярную сетку ячеек, и для каждой ячейки $k$ рассчитывается показатель засорённости:

$$W_k = (1/S_k) \cdot \Sigma\, c_i \cdot a_i, \quad i \in O_k \tag{3}$$

где $S_k$ – площадь ячейки, $O_k$ – множество сорняков, обнаруженных в ячейке, $a_i$ – площадь рамки $i$-го объекта в проекции на поверхность, $c_i$ – уверенность детектора. Учёт уверенности снижает влияние ложных срабатываний, а повторные наблюдения одного участка при проходах в соседних рядках объединяются.

Модуль принятия решений использует набор правил, связывающих показатель засорённости, тип сорняков и фазу развития культуры с агротехнической операцией. При значении $W_k$ ниже порога вмешательства обработка не проводится, при единичных сорняках вблизи культурного растения выбирается механическое удаление или точечное опрыскивание форсункой, находящейся над объектом, а при высокой засорённости ячейки – полосовая обработка. Пороги задаются агрономом и могут уточняться по результатам сезона. Дополнительно по мультиспектральным снимкам рассчитывается вегетационный индекс NDVI, что позволяет выделять участки с угнетённым состоянием посевов и формировать отчёт для оператора.

Движение робота вдоль рядка реализуется алгоритмом следования траектории pure pursuit, в котором угол поворота управляемых колёс определяется по точке цели, находящейся на расстоянии упреждения:

$$\delta = \operatorname{arctg}(2L \cdot \sin \alpha / l_d) \tag{4}$$

где $L$ – колёсная база, $\alpha$ – угол между продольной осью робота и направлением на точку цели, $l_d$ – расстояние упреждения. Скорость вращения колёсных приводов и положение форсунок стабилизируются ПИД-регуляторами. При потере рядка по данным камеры система переключается на навигацию по GNSS-RTK до восстановления визуального ориентира.

### 4. Методика экспериментальной проверки

Экспериментальная проверка системы планируется в три этапа, каждый из которых оценивает отдельный уровень архитектуры (табл. 1). Такое разделение позволяет выявлять источник ошибок: неверное решение об обработке может быть вызвано как пропуском сорняка детектором, так и погрешностью привязки координат или смещением робота относительно рядка.

Таблица 1. План экспериментальной проверки системы

| Этап | Условия проведения | Оцениваемые показатели |
|---|---|---|
| **1. Распознавание объектов** | Тестовая часть размеченной выборки полевых изображений; сравнение моделей YOLO разного размера | Точность P, полнота Rc, mAP@0,5, скорость обработки (кадр/с) на встраиваемом вычислителе |
| **2. Навигация по рядкам** | Проходы робота вдоль рядков при разной освещённости и фазе развития культуры | Среднее и максимальное поперечное отклонение от оси междурядья, число потерь рядка |
| **3. Точечная обработка** | Опытные делянки: сплошное опрыскивание (контроль) и обработка по командам системы | Доля обработанной площади, расход препарата, доля подавленных сорняков, повреждение культуры |

Для первого этапа выборка изображений собирается камерой робота в полевых условиях и дополняется открытыми наборами данных по детекции сорняков, что позволяет начать обучение до накопления собственных данных. Выборка разделяется на обучающую, валидационную и тестовую части в соотношении 70/15/15, причём изображения одного участка поля не должны попадать в разные части, чтобы избежать завышения оценок.

На третьем этапе экономия препарата оценивается по отношению обработанной площади к общей площади делянки:

$$Э = (1 – S_{обр} / S_{общ}) \cdot 100\ \% \quad (5)$$

где $S_{обр}$ – суммарная площадь, обработанная форсунками по командам системы, $S_{общ}$ – площадь делянки. Поскольку сорняки распределены по полю неравномерно, ожидаемая экономия тем выше, чем ниже засорённость посевов. Эффективность обработки оценивается подсчётом сорняков на учётных площадках до обработки и через установленный срок после неё в сравнении с контрольной делянкой.

**Заключение**

Предложена архитектура интеллектуальной системы управления агророботом, в которой методы компьютерного зрения используются одновременно для навигации по рядкам, распознавания культур и сорняков и оценки состояния посевов. Введён показатель засорённости ячеек поля, учитывающий площадь и достоверность обнаруженных объектов, и правила выбора агротехнической операции на его основе. Разработана поэтапная методика экспериментальной проверки, позволяющая раздельно оценить качество распознавания, точность навигации и экономический эффект точечной обработки. Модульная реализация на платформе ROS позволяет наращивать функциональность системы. Дальнейшие исследования направлены на проведение экспериментов по предложенной методике, расширение обучающей выборки для культур, распространённых в Казахстане, оптимизацию моделей для работы на встраиваемых вычислителях и полевые испытания прототипа в течение полного вегетационного сезона.

**Литература**

1. Liakos K.G., Busato P., Moshou D., Pearson S., Bochtis D. Machine learning in agriculture: a review // Sensors. – 2018. – Vol. 18, No. 8. – P. 2674.

2. Bechar A., Vigneault C. Agricultural robots for field operations: concepts and components // Biosystems Engineering. – 2016. – Vol. 149. – P. 94–111.

3. Kamilaris A., Prenafeta-Boldú F.X. Deep learning in agriculture: a survey // Computers and Electronics in Agriculture. – 2018. – Vol. 147. – P. 70–90.

4. Mohanty S.P., Hughes D.P., Salathé M. Using deep learning for image-based plant disease detection // Frontiers in Plant Science. – 2016. – Vol. 7. – P. 1419.

5. Quigley M., Conley K., Gerkey B. et al. ROS: an open-source Robot Operating System // ICRA Workshop on Open Source Software. – Kobe, 2009.

6. Redmon J., Divvala S., Girshick R., Farhadi A. You Only Look Once: unified, real-time object detection // Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 779–788.

7. Lottes P., Behley J., Milioto A., Stachniss C. Fully convolutional networks with sequential information for robust crop and weed detection in precision farming // IEEE Robotics and Automation Letters. – 2018. – Vol. 3, No. 4. – P. 2870–2877.

8. Duckett T., Pearson S., Blackmore S., Grieve B. et al. Agricultural robotics: the future of robotic agriculture. – UK-RAS White Papers, 2018. – arXiv:1806.06762.

# КОМПЬЮТЕРНОЕ ЗРЕНИЕ ДЛЯ ОПРЕДЕЛЕНИЯ ВОВЛЕЧЕННОСТИ ОБУЧАЮЩИХСЯ

Бажибаева А.Б.
e-mail: bakytbekkyzyainur@gmail.com
*Казахский национальный университет имени аль-Фараби, Казахстан*

***Аннотация.*** *В докладе рассмотрены методы компьютерного зрения для автоматического определения уровня вовлеченности обучающихся по видео. На открытом наборе данных DAiSEE (9068 видеофрагментов, 112 обучающихся) проведен сравнительный анализ двенадцати опубликованных методов и по распределению классов рассчитаны тривиальные базовые уровни качества. Показано, что из-за сильного дисбаланса классов классификатор, всегда выдающий уровень «высокая вовлеченность», достигает точности 49,4%, тогда как лучшие методы показывают 63,6–67,4%; реальный выигрыш современных моделей составляет 14–18 процентных пунктов, а два низших уровня вовлеченности почти не распознаются. Сформулированы рекомендации по выбору метрик оценки и требования к системе для применения в вузах.*

***Ключевые слова:*** *компьютерное зрение, вовлеченность обучающихся, глубокое обучение, анализ видео, дисбаланс классов, DAiSEE, образовательная аналитика.*

## Введение

Вовлеченность обучающихся является одним из ключевых факторов успеваемости и удержания студентов. В педагогической психологии выделяют три ее компонента: поведенческий, эмоциональный и когнитивный [1]. В очной аудитории преподаватель оценивает вовлеченность по взглядам, мимике и позам студентов, однако в онлайн-формате и на больших потоках такая обратная связь практически теряется.

Методы компьютерного зрения позволяют непрерывно измерять внешние проявления вовлеченности без вмешательства в учебный процесс. Whitehill и соавт. [2] показали, что классификаторы на признаках лица согласуются с оценками экспертов на уровне, сопоставимом с согласием самих экспертов. Появление открытых наборов данных DAiSEE [3] и EmotiW [4], а также инструментов анализа лица, таких как OpenFace [5], сделало эту задачу предметом активных исследований.

Сообщаемая точность методов на наборе DAiSEE за несколько лет выросла с 46% до 67%, однако эти значения трудно интерпретировать без учета распределения классов. Цель доклада – систематизировать подходы к определению вовлеченности по видео и оценить их реальный выигрыш относительно тривиальных базовых уровней, рассчитанных по открытым данным.

## 1. Данные и постановка задачи

Набор DAiSEE [3] содержит 9068 видеофрагментов длительностью 10 с (30 кадров/с, 640×480 пикселей), записанных у 112 обучающихся во время онлайн-занятий. Каждый фрагмент размечен по четырем аффективным состояниям (вовлеченность, скука, замешательство, фрустрация) на четырехуровневой шкале: 0 – очень низкий, 1 – низкий, 2 – высокий, 3 – очень высокий уровень. Задача состоит в отнесении фрагмента к одному из четырех уровней вовлеченности. Распределение фрагментов в стандартном разбиении набора [3, 11] приведено в таблице 1.

Таблица 1. Распределение видеофрагментов DAiSEE по уровням вовлеченности

| Уровень вовлеченности | Обучение | Валидация | Тест | Доля в тесте, % |
|---|---|---|---|---|
| 0 – очень низкий | 34 | 23 | 4 | 0,22 |
| 1 – низкий | 213 | 143 | 84 | 4,71 |

| Уровень вовлеченности | Обучение | Валидация | Тест | Доля в тесте, % |
|---|---|---|---|---|
| 2 – высокий | 2617 | 813 | 882 | 49,44 |
| 3 – очень высокий | 2494 | 450 | 814 | 45,63 |
| Всего | 5358 | 1429 | 1784 | 100,00 |

Набор сильно несбалансирован: на два низших уровня приходится лишь 4,9% тестовой выборки, а соотношение самого частого и самого редкого класса в обучающей выборке составляет 77:1. При этом именно низкая вовлеченность представляет наибольший практический интерес для преподавателя.

**2. Обзор методов**

Существующие методы можно разделить на три группы. Признаковые методы сначала извлекают интерпретируемые признаки – единицы лицевых действий, направление взгляда, положение головы, ориентиры лица – с помощью инструментов вроде OpenFace [5], а затем классифицируют их. К ним относятся сверточная сеть по ориентирам лица [7] и сеть DERN, объединяющая двунаправленную LSTM с механизмом внимания [6].

Сквозные методы обучаются непосредственно на кадрах видео. Используются трехмерные свертки C3D [17] и I3D [9], рекуррентно-сверточная сеть LRCN [16], сочетания двумерной сети ResNet с LSTM или временной сверточной сетью TCN [11, 15], сеть DFSTN на основе SE-ResNet-50 и LSTM с глобальным вниманием [10], а также трехмерная DenseNet с самовниманием [13]. Для борьбы с дисбалансом классов применяются функция потерь focal loss [8, 14], взвешенная кросс-энтропия [9] и формирование мини-батчей с обязательным присутствием всех классов [11].

Гибридные методы объединяют латентные аффективные признаки, полученные предобученными сетями, с поведенческими признаками (взгляд, положение головы) и учитывают порядковый характер шкалы вовлеченности [12].

**3. Базовые уровни и анализ результатов**

По распределению тестовой выборки (табл. 1) рассчитаны тривиальные базовые уровни качества. Классификатор, всегда предсказывающий наиболее частый класс «высокая вовлеченность», дает точность 882/1784 = 49,4%. Случайный классификатор, выбирающий класс пропорционально частотам обучающей и валидационной выборок, дает ожидаемую точность $\Sigma\, p_i q_i$ = 45,0%, где $p_i$ и $q_i$ – доли класса i в обучающей и тестовой выборках. При этом взвешенная F1-мера мажоритарного классификатора составляет лишь 0,33, а макроусредненная – 0,17, поскольку три класса из четырех им не распознаются.

В таблице 2 приведена точность двенадцати методов на тестовой выборке DAiSEE по данным работ [11, 12] и ее прирост относительно мажоритарного классификатора; на рис. 1 те же результаты показаны графически.

Таблица 2. Точность методов определения вовлеченности на тестовой выборке DAiSEE (4 уровня)

| Метод | Подход | Точность, % | Прирост над базовым уровнем, п.п. |
|---|---|---|---|
| InceptionNet, видеоуровень [3] | сквозной | 46,4 | −3,0 |
| I3D с взвешенной кросс-энтропией [9] | сквозной | 52,4 | +2,9 |
| C3D [3] | сквозной | 56,1 | +6,7 |
| C3D + focal loss [8] | сквозной | 56,2 | +6,8 |
| CNN по ориентирам лица [7] | признаковый | 57,0 | +7,6 |
| LRCN [3] | сквозной | 57,9 | +8,5 |

| Метод | Подход | Точность, % | Прирост над базовым уровнем, п.п. |
|---|---|---|---|
| DFSTN [10] | сквозной | 58,8 | +9,4 |
| DERN [6] | признаковый | 60,0 | +10,6 |
| ResNet + LSTM [11] | сквозной | 61,2 | +11,7 |
| 3D DenseNet с самовниманием [13] | сквозной | 63,6 | +14,2 |
| ResNet + TCN [11] | сквозной | 63,9 | +14,5 |
| Порядковая TCN по аффективным и поведенческим признакам [12] | гибридный | 67,4 | +18,0 |

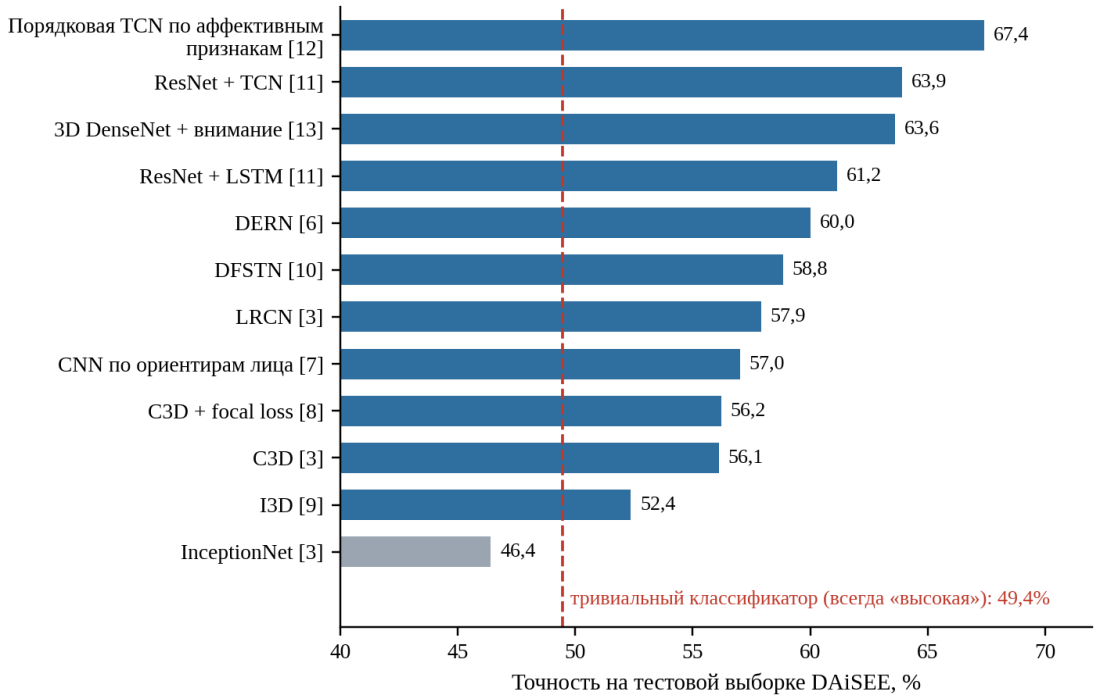



Рис. 1 Точность методов на наборе DAiSEE в сравнении с тривиальным классификатором

Из двенадцати методов один уступает тривиальному классификатору, а еще три превосходят его менее чем на 7 п.п. Лучшие сквозные модели (ResNet + TCN, 3D DenseNet с самовниманием) дают прирост около 14 п.п., гибридная порядковая модель – 18 п.п. Учет временной динамики стабильно повышает качество: ResNet + TCN превосходит покадровую классификацию InceptionNet на 17,5 п.п.

Вместе с тем общая точность скрывает главную проблему. Анализ матриц ошибок в [11] показал, что без специальных мер балансировки ни один из исследованных методов не относит правильно ни одного фрагмента к двум низшим уровням вовлеченности. Балансировка позволяет распознать часть таких фрагментов, но ценой снижения общей точности [11]. Аналогичная ситуация возникает при переходе к бинарной задаче «вовлечен / не вовлечен»: доля класса «вовлечен» в тестовой выборке составляет 95,1%, поэтому сообщаемая точность 98,8% [9] должна сравниваться именно с этим тривиальным уровнем, а не с 50%.

### 4. Обсуждение и рекомендации

Проведенный анализ показывает, что общая точность является неудачной основной метрикой для данной задачи. При публикации результатов целесообразно указывать тривиальный базовый уровень, приводить матрицу ошибок, сбалансированную точность и макроусредненную F1-меру, а также метрики, учитывающие порядковый характер шкалы, например среднюю абсолютную ошибку по уровням.

Для практического применения в вузах необходимо учитывать, что видео фиксирует лишь поведенческую и эмоциональную стороны вовлеченности: когнитивная вовлеченность по лицу напрямую не наблюдается. Поэтому оценки системы следует использовать как агрегированный сигнал для преподавателя о динамике внимания группы, а не как оценку отдельного студента. Обязательными условиями внедрения являются информированное согласие обучающихся, обработка видео без сохранения кадров, представление результатов на уровне группы и запрет на использование оценок вовлеченности при выставлении отметок. Поскольку модели обучены на данных одной выборки, перед внедрением требуется проверка переноса на локальных данных с разметкой экспертами.

**Заключение**

На открытом наборе DAiSEE проведен сравнительный анализ двенадцати методов компьютерного зрения для определения вовлеченности обучающихся и рассчитаны тривиальные базовые уровни качества. Показано, что мажоритарный классификатор достигает точности 49,4%, а реальный выигрыш лучших моделей составляет 14–18 п.п.; наилучший результат (67,4%) получен гибридным подходом с порядковой временной моделью. Основной нерешенной проблемой остается распознавание низких уровней вовлеченности, на которые приходится менее 5% данных. Дальнейшая работа предполагает сбор и разметку локального набора данных в КазНУ имени аль-Фараби и разработку методов, ориентированных на распознавание редких классов.

Литература

1. Fredricks, J. A. School engagement: Potential of the concept, state of the evidence / J. A. Fredricks, P. C. Blumenfeld, A. H. Paris // Review of Educational Research. – 2004. – Vol. 74, N. 1. – P. 59-109.

2. Whitehill, J. The faces of engagement: Automatic recognition of student engagement from facial expressions / J. Whitehill, Z. Serpell, Y.-C. Lin, A. Foster, J. R. Movellan // IEEE Transactions on Affective Computing. – 2014. – Vol. 5, N. 1. – P. 86-98.

3. Gupta A., D'Cunha A., Awasthi K., Balasubramanian V. DAiSEE: Towards user engagement recognition in the wild. – https://arxiv.org/abs/1609.01885 (03.10.2026).

4. Dhall, A. EmotiW 2020: Driver gaze, group emotion, student engagement and physiological signal based challenges / A. Dhall, G. Sharma, R. Goecke, T. Gedeon // Proc. Int. Conf. on Multimodal Interaction (ICMI). – 2020. – P. 784-789.

5. Baltrušaitis, T. OpenFace 2.0: Facial behavior analysis toolkit / T. Baltrušaitis, A. Zadeh, Y. C. Lim, L.-P. Morency // Proc. IEEE Int. Conf. on Automatic Face & Gesture Recognition. – 2018. – P. 59-66.

6. Huang, T. Fine-grained engagement recognition in online learning environment / T. Huang, Y. Mei, H. Zhang, S. Liu, H. Yang // Proc. IEEE 9th Int. Conf. on Electronics Information and Emergency Communication (ICEIEC). – 2019. – P. 338-341.

7. Wang, Y. Automated student engagement monitoring and evaluation during learning in the wild / Y. Wang, A. Kotha, P.-h. Hong, M. Qiu // Proc. IEEE CSCloud/EdgeCom. – 2020. – P. 270-275.

8. Geng, L. Learning deep spatiotemporal feature for engagement recognition of online courses / L. Geng, M. Xu, Z. Wei, X. Zhou // Proc. IEEE Symposium Series on Computational Intelligence (SSCI). – 2019. – P. 442-447.

9. Zhang, H. An novel end-to-end network for automatic student engagement recognition / H. Zhang, X. Xiao, T. Huang, S. Liu, Y. Xia, J. Li // Proc. IEEE 9th Int. Conf. on Electronics Information and Emergency Communication (ICEIEC). – 2019. – P. 342-345.

10. Liao, J. Deep facial spatiotemporal network for engagement prediction in online learning / J. Liao, Y. Liang, J. Pan // Applied Intelligence. – 2021.

11. Abedi A., Khan S. S. Improving state-of-the-art in detecting student engagement with ResNet and TCN hybrid network // Proc. 18th Conference on Robots and Vision. – 2021. – https://arxiv.org/abs/2104.10122 (03.10.2026).

12. Abedi A., Khan S. S. Affect-driven ordinal engagement measurement from video. – https://arxiv.org/abs/2106.10882 (03.10.2026).

13. Mehta, N. K. Three-dimensional DenseNet self-attention neural network for automatic detection of student's engagement / N. K. Mehta, S. S. Prasad, S. Saurav, R. Saini, S. Singh // Applied Intelligence. – 2022.

14. Lin, T.-Y. Focal loss for dense object detection / T.-Y. Lin, P. Goyal, R. Girshick, K. He, P. Dollár // Proc. IEEE Int. Conf. on Computer Vision (ICCV). – 2017. – P. 2980-2988.

15. Bai S., Kolter J. Z., Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. – https://arxiv.org/abs/1803.01271 (03.10.2026).

16. Donahue, J. Long-term recurrent convolutional networks for visual recognition and description / J. Donahue, L. A. Hendricks, S. Guadarrama et al. // Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). – 2015. – P. 2625-2634.

17. Tran, D. Learning spatiotemporal features with 3D convolutional networks / D. Tran, L. Bourdev, R. Fergus, L. Torresani, M. Paluri // Proc. IEEE Int. Conf. on Computer Vision (ICCV). – 2015. – P. 4489-4497.

# СИНТЕТИЧЕСКИЕ ДАННЫЕ: ПРИМЕНЕНИЕ В ОБРАЗОВАТЕЛЬНЫХ СЕРВИСАХ

Алдунин Д.А[1]., Мальцева С.В[2].
e-mail: d_aldunin@mail.ru, smaltseva@hse.ru

*[1]ООО "Технологии 211", Россия*

*[2]Национальный исследовательский университет «Высшая школа экономики», Россия*

***Аннотация.*** *В работе рассматриваются методы генерации и использования больших синтетических наборов данных для аналитических задач в различных областях. Синтетические данные позволяют решать задачи дефицита или конфиденциальности исходных данных и существенно сокращают сроки подготовки наборов данных. Приведен пример использования синтетических данных в образовательной сфере при работе с платформами агрегаторов открытых онлайн-курсов. Представлен итеративный алгоритм генерации синтетических данных в виде двудольного направленного ациклического графа.*

Синтетические данные сегодня рассматриваются как один из важных инструментов реализации методов машинного обучения в различных областях и развития искусственного интеллекта в целом.

Основные драйверы развития индустрии синтетических данных связаны с расширением сфер активного принятия ИИ, а также с существующими проблемами получения и использования реальных данных: дефицит данных, проблемы конфиденциальности и анонимности, стоимость и доступность данных, неравномерность качества данных в реальных наборах.

Несмотря на существующие риски использования синтетических данных, к которым относят их недостаточную реалистичность, случайное или сознательное игнорирование разработчиками некоторых аспектов реальных данных, эта сфера растет очень быстро. В [1] объем рынка генерации синтетических данных оценивается в 0,78 млрд долларов США в 2025 году с прогнозом 4,26 млрд долларов США в 2032 со среднегодовым темпом роста 27,4%.

Сферами, где наиболее активно разрабатываются решения с применением синтетических данных, сегодня являются здравоохранение, сфера банковских и финансовых услуг, розничная торговля и маркетинг (анализ и прогнозирование покупательского поведения, виртуальные примерочные и персонализированная реклама), производство (контроль качества и прогнозирование отказов, обучение роботов и автоматизированных систем**)**, телекоммуникации, транспорт, в том числе автономный (обучение и тестирование автономных систем), аэрокосмическая отрасль.

Образование является одной из сфер, где активно развивается ИИ и в то же время очень важное значение имеет обеспечение конфиденциальности.

Выделяют следующие основные направления применения [2,3]:

- Аналитика обучения и прогнозирование успеваемости обучающихся с сохранением конфиденциальности, включая оценку рисков отсева и тенденций вовлеченности.
- Персонализированное обучение, сервисы платформ адаптивного обучения, включая моделирование различных образовательных траекторий, поведения и типичных ошибок учащихся, создание персонализированных банков вопросов, генерацию контента.
- Моделирующие программы подготовки учителей, включая возможные сценарии, позволяющие воссоздать реалистичную динамику учебного процесса

и поведенческие профили учащихся, и позволяющие педагогам отрабатывать стратегии принятия решений.

- Оценка образовательных реформ, сценариев их реализации, влияния на показатели образования.

Отдельно следует отметить важную роль синтетических данных в корпоративной практике, в том числе, в программах обучения и ввода в должность сотрудников компаний [4].

В качестве примера использования синтетических данных в образовательной сфере рассмотрим один из популярных образовательных сервисов формирования персонального учебного плана при использовании платформ открытых онлайн-курсов, где обучающийся может самостоятельно выбирать состав учебных курсов и выстраивать их последовательность на основе имеющихся знаний и навыков, образовательных целей, определённых ограничений, например, по времени и стоимости обучения [5]. С учетом большого количества ресурсов на таких платформах, самостоятельный выбор представляет для обучающегося сложную задачу, что часто является причиной отказа от использования сервисов платформы или оставления курсов обучающимся до их окончания. Поэтому рекомендации платформы, адаптированные к реальным потребностям и возможностям обучающегося, играют важную роль в использовании сервиса.

Для создания сервиса рекомендаций по формированию персонального плана обучения необходимы исходные данные, объединяющие информацию о пользователях сервиса и их предпочтениях, зависимости между курсами и знаниями/навыками, данные об использовании сервиса разными группами пользователей.

Сегодня открытые данные большинства образовательных платформ оказываются недостаточными для прямого использования в задачах верификации и нагрузочного тестирования алгоритмов построения персоналбного учебного плана. Это делает задачу генерации синтетических наборов данных важной для реализации рекомендательных сервисов, связанных с персонализацией образовательных программ и траекторий.

При моделировании задачи, решаемой сервисом, необходимо рассматривать два принципиально различных типа сущностей — курсы и знания/навыки. Связи между ними имеют направленный характер. При этом важно, чтобы связи между курсами проходили не напрямую, а через знания и навыки, через которые эти курсы связаны. Поэтому синтетические данные формируются как двудольный направленный ациклический граф образовательной среды, где узлы графа – это объединение множества курсов и множества знаний и навыков, а дуги – объединение множества дуг, связывающих знание или навык, являющийся пререквизитом курса, и множества дуг, связывающих курс, который формирует знание или навык. Алгоритм позволяет задавать число курсов, минимальное число знаний и навыков, а также нижние и верхние границы количества пререквизитов и постреквизитов курса.

Метод генерации итеративный и использует два основных механизма: контроль транзитивных зависимостей и динамическое расширение множества знаний и навыков. Первый механизм поддерживает для каждого знания или навыка множество его транзитивных предшественников и последователей. При выборе постреквизитов курса — знаний и навыков, формируемых при его освоении, — из множества кандидатов исключаются пререквизиты этого курса и все их транзитивные предшественники. Это предотвращает появление циклов.

Если допустимых кандидатов недостаточно для выбранного числа постреквизитов курса, множество знаний и навыков расширяется на недостающее число новых элементов. Поэтому число курсов остаётся заданным, а исходное число знаний и навыков служит нижней границей их итогового количества.

Такой подход к генерации синтетических данных может использоваться и в других областях, где промежуточные результаты могут использоваться многократно и

можно выделить два класса объектов: задачи/процессы, которые определяют то, что необходимо выполнить для достижения определенной цели, и ресурсы, которые используются или образуются в системе для/при выполнении задач при условии, что прямые связи между объектами одного класса отсутствуют и реализуются как направленные связи только через объект другого класса.

Литература:

1 Synthetic Data Generation Market Size by Component, Technology, Data Type, Development Mode, Enterprise, Application and End-user. https://www.maximizemarketresearch.com/market-report/synthetic-data-generation-market/309139/

2. Chen Zhan, Oscar Blessed Deho, Xuwei Zhang, Srećko Joksimović, and Maarten de Laat. Synthetic data generator for student data serving learning analytics: A comparative study. Learning Letters, 2023 Volume 1, Article 5 https://doi.org/10.59453/KHZW9006 http://creativecommons.org/licenses/by-nd/4.0/.

3.What is synthetic data in education? https://www.meegle.com/en_us/topics/synthetic-data-generation/synthetic-data-in-education 27.10.2025.

4. James, S., Harbron, C., Branson, J. *et al.* Synthetic data use: exploring use cases to optimise data utility. *Discov Artif Intell* 1, 15 (2021). https://doi.org/10.1007/s44163-021-00016-y

5. Алдунин Д.А. Модель архитектуры рекомендательного сервиса по формированию индивидуальной образовательной траектории при самостоятельном изучении массовых открытых онлайн-курсов. Информатика и образование. 2024;39(1):74-83. https://doi.org/10.32517/0234-0453-2024-39-1-74-83