

ҚАЗАҚСТАН РЕСПУБЛИКАСЫНЫҢ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ МИНИСТРЛІГІ
МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РЕСПУБЛИКИ КАЗАХСТАН
MINISTRY OF SCIENCE AND HIGHER EDUCATION OF THE REPUBLIC OF KAZAKHSTAN



**ХАЛЫҚАРАЛЫҚ АҚПАРАТТЫҚ ЖӘНЕ
КОММУНИКАЦИЯЛЫҚ ТЕХНОЛОГИЯЛАР
ЖУРНАЛЫ**

**МЕЖДУНАРОДНЫЙ ЖУРНАЛ
ИНФОРМАЦИОННЫХ И
КОММУНИКАЦИОННЫХ ТЕХНОЛОГИЙ**

**INTERNATIONAL JOURNAL OF INFORMATION
AND COMMUNICATION TECHNOLOGIES**

2025 (22) 2

сәуір - маусым

ISSN 2708–2032 (print)
ISSN 2708–2040 (online)

БАС РЕДАКТОР:

Исахов Асылбек Абдишимович — есептеу теориясы саласында математика бойынша PhD доктор, "Компьютерлік ғылымдар және информатика" бағыты бойынша қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университетінің Басқарма Төрағасы – Ректор (Қазақстан)

БАС РЕДАКТОРДЫҢ ОРЫНБАСАРЫ:

Колесникова Катерина Викторовна — техника ғылымдарының докторы, профессор, Халықаралық ақпараттық технологиялар университетінің ғылыми-зерттеу қызметі жөніндегі проректор (Қазақстан)

ҒАЛЫМ ХАТШЫ:

Ипалакова Мадина Түлегеновна — техника ғылымдарының кандидаты, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университетінің ғылыми-зерттеу қызметі жөніндегі департамент директоры (Қазақстан)

РЕДАКЦИЯЛЫҚ АЛҚА:

Разак Абдул — PhD, Халықаралық ақпараттық технологиялар университеті киберқауіпсіздік кафедрасының профессоры (Қазақстан)
Лучино Томмазо де Паолис — Саленто Университеті (Италия) инновация және технологиялық инжиниринг департаменті AVR зертханасының зерттеу және әзірлеу бөлімінің директоры

Лиз Бэкон — профессор, Абертей Университеті (Ұлыбритания) вице-канцлерінің орынбасары

Микеле Пагано — PhD, Пиза Университетінің (Италия) профессоры

Өтелбаев Мұхтарбай Өтелбайұлы — физика-математика ғылымдарының докторы, профессор, КР ҰҒА академигі, Халықаралық ақпараттық технологиялар университеті математика және компьютерлік модельдеу кафедрасының профессоры (Қазақстан)

Рысбайұлы Болатбек — физика-математика ғылымдарының докторы, профессор, Есептеу және деректер ғылымдары департаментінің профессоры, Astana IT University (Қазақстан)

Дайнеко Евгения Александровна — PhD, Халықаралық ақпараттық технологиялар университеті ақпараттық жүйелер кафедрасының профессор-зерттеушісі (Қазақстан)

Дузаев Нуржан Токсужаевич — PhD, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті цифрландыру және инновациялар жөніндегі проректор (Қазақстан)

Синчев Бахтгерей Куспанович — техника ғылымдарының докторы, профессор, Халықаралық ақпараттық технологиялар университеті ақпараттық жүйелер кафедрасының профессоры (Қазақстан)

Сейлова Нургуль Абдуллаевна — техника ғылымдарының докторы, Халықаралық ақпараттық технологиялар университеті компьютерлік технологиялар және киберқауіпсіздік факультетінің деканы (Қазақстан)

Мұхамедиева Ардак Габитовна — экономика ғылымдарының кандидаты, Халықаралық ақпараттық технологиялар университеті бизнес медиа және басқару факультетінің деканы (Қазақстан)

Абдикаликова Замира Тұрсынбаевна — PhD, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті математика және компьютерлік модельдеу кафедрасының меңгерушісі (Қазақстан)

Шильдибеков Ерлан Жаржанович — PhD, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті экономика және бизнес кафедрасының меңгерушісі (Қазақстан)

Дамелия Максумовна Ескендиrowa — техника ғылымдарының кандидаты, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті киберқауіпсіздік кафедрасының меңгерушісі (Қазақстан)

Ниязгулова Айгуль Аскарбековна — филология ғылымдарының кандидаты, доцент, профессор, Халықаралық ақпараттық технологиялар университеті медиакоммуникация және Қазақстан тарихы кафедрасының меңгерушісі (Қазақстан)

Айтмағамбетов Алтай Зуфарович — техника ғылымдарының кандидаты, Халықаралық ақпараттық технологиялар университеті радиотехника, электроника және телекоммуникация кафедрасының профессоры (Қазақстан)

Бахтиярова Елена Азизбековна — техника ғылымдарының кандидаты, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті радиотехника, электроника және телекоммуникация кафедрасының меңгерушісі (Қазақстан)

Канибек Сансызбай — PhD, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті киберқауіпсіздік кафедрасының профессор-зерттеушісі (Қазақстан)

Тынымбаев Сахиябай — техника ғылымдарының кандидаты, профессор, Халықаралық ақпараттық технологиялар университеті компьютерлік инженерия кафедрасының профессор-зерттеушісі (Қазақстан)

Алимереб Али Абд — PhD, Халықаралық ақпараттық технологиялар университеті киберқауіпсіздік кафедрасының қауымдастырылған профессоры (Қазақстан)

Мохамед Ахмед Хамада — PhD, Халықаралық ақпараттық технологиялар университеті ақпараттық жүйелер кафедрасының қауымдастырылған профессоры (Қазақстан)

Янг Им Чу — PhD, Гачон университетінің профессоры (Оңтүстік Корея)

Талеуш Валдас — PhD, Адам Мицкевич атындағы (Польша) университеттің проректоры

Мамырбаев Оркен Жұмажанович — PhD, КР ҒЖБМ Ғылым комитеті ақпараттық және есептеу технологиялары институты ӨМК директорының ғылым жөніндегі орынбасары (Қазақстан)

Бушуев Сергей Дмитриевич — техника ғылымдарының докторы, профессор, Украинаның "УКРНЕТ" жобаларды басқару қауымдастығының директоры, Киев ұлттық құрылыс және сәулет университеті жобаларды басқару кафедрасының меңгерушісі (Украина)

Белошицкая Светлана Васильевна — техника ғылымдарының докторы, доцент, Astana IT University есептеу және деректер ғылымы кафедрасының профессоры (Қазақстан)

РЕДАКТОР:

Мрзабаева Раушан Жалиевна — магистр, Халықаралық ақпараттық технологиялар университетінің редакторы (Қазақстан)

Халықаралық ақпараттық және коммуникациялық технологиялар журналы

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Меншік иесі: АҚ «Халықаралық ақпараттық технологиялар университеті» (Алматы қ.).

Қазақстан Республикасы Ақпарат және қоғамдық даму министрлігіне мерзімді баспасөз басылымын есепке қою туралы куәлік № KZ82VPY00020475, 20.02.2020 ж. берілген

Тақырып бағыты: ақпараттық технологиялар, ақпараттық қауіпсіздік және коммуникациялық технологиялар, әлеуметтік-экономикалық жүйелерді дамытудағы цифрлық технология.

Мерзімділігі: жылына 4 рет.

Тираж: 100 дана.

Редакция мекенжайы: 050040 Алматы қ., Манас к., 34/1, каб. 709, тел: +7 (727) 244-51-09.

E-mail: ijict@iitu.edu.kz

Журнал сайты: <https://journal.iitu.edu.kz>

© Халықаралық ақпараттық технологиялар университеті АҚ, 2025

Журнал сайты: <https://journal.iitu.edu.kz> © Авторлар ұжымы, 2025

ГЛАВНЫЙ РЕДАКТОР

Исахов Асылбек Абдиашимович — доктор PhD по математике в области теории вычислимости, ассоциированный профессор по направлению "Компьютерные науки и информатика", Председатель Правления – Ректор Международного университета информационных технологий (Казахстан)

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА:

Колесникова Катерина Викторовна — доктор технических наук, профессор, проректор по научно-исследовательской деятельности Международного университета информационных технологий (Казахстан)

УЧЕНЫЙ СЕКРЕТАРЬ:

Ипалакова Мадина Тулегеновна — кандидат технических наук, ассоциированный профессор, директор департамента по научно-исследовательской деятельности Международного университета информационных технологий (Казахстан)

РЕДАКЦИОННАЯ КОЛЛЕГИЯ:

Разак Абдул — PhD, профессор кафедры кибербезопасности Международного университета информационных технологий (Казахстан)

Лучио Томмазо де Паолис — директор отдела исследований и разработок лаборатории AVR департамента инноваций и технологического инжиниринга Университета Саленто (Италия)

Лиз Бэкон — профессор, заместитель вице-канцлера Университета Абертей (Великобритания)

Микеле Пагано — PhD, профессор Университета Пизы (Италия)

Отелбаев Мухтарбай Отелбайулы — доктор физико-математических наук, профессор, академик НАН РК, профессор кафедры математического и компьютерного моделирования Международного университета информационных технологий (Казахстан)

Рысбайулы Болатбек — доктор физико-математических наук, профессор, профессор Astana IT University (Казахстан)

Дайнеко Евгения Александровна — PhD, профессор-исследователь кафедры информационных систем Международного университета информационных технологий (Казахстан)

Дузбаев Нуржан Токкужаевич — PhD, ассоциированный профессор, проректор по цифровизации и инновациям Международного университета информационных технологий (Казахстан)

Синчев Бахтгерей Куспанович — доктор технических наук, профессор, профессор кафедры информационных систем Международного университета информационных технологий (Казахстан)

Сейлова Нургуль Абадуллаевна — кандидат технических наук, декан факультета компьютерных технологий и кибербезопасности Международного университета информационных технологий (Казахстан)

Мухамедиева Ардак Габитовна — кандидат экономических наук, декан факультета бизнеса медиа и управления Международного университета информационных технологий (Казахстан)

Абдикаликова Замира Турсынбаевна — PhD, ассоциированный профессор, заведующая кафедрой математического и компьютерного моделирования Международного университета информационных технологий (Казахстан)

Шильдибеков Ерлан Жаржанович — PhD, ассоциированный профессор, заведующий кафедрой экономики и бизнеса Международного университета информационных технологий (Казахстан)

Дамеля Максумовна Ескендирова — кандидат технических наук, ассоциированный профессор, заведующая кафедрой кибербезопасности Международного университета информационных технологий (Казахстан)

Ниязгулова Айгуль Аскарбековна — кандидат филологических наук, доцент, профессор, заведующая кафедрой медиакоммуникации и истории Казахстана Международного университета информационных технологий (Казахстан)

Айтмагамбетов Алтай Зуфарович — кандидат технических наук, профессор кафедры радиотехники, электроники и телекоммуникаций Международного университета информационных технологий (Казахстан)

Бахтиярова Елена Ажибековна — кандидат технических наук, ассоциированный профессор, заведующая кафедрой радиотехники, электроники и телекоммуникаций Международного университета информационных технологий (Казахстан)

Канибек Сансызбай — PhD, ассоциированный профессор, профессор-исследователь кафедры кибербезопасности, Международного университета информационных технологий (Казахстан)

Тынымбаев Сахиябай — кандидат технических наук, профессор, профессор-исследователь кафедры компьютерной инженерии, Международного университета информационных технологий (Казахстан)

Алмисреб Али Абд — PhD, ассоциированный профессор кафедры кибербезопасности Международного университета информационных технологий (Казахстан)

Мохамед Ахмед Хамада — PhD, ассоциированный профессор кафедры информационных систем Международного университета информационных технологий (Казахстан)

Янг Им Чу — PhD, профессор университета Гачон (Южная Корея)

Талеуш Валлас — PhD, проректор университета имен Адама Мицкевича (Польша)

Мамырбаев Оркен Жумажанович — PhD, заместитель директора по науке РГП Института информационных и вычислительных технологий Комитета науки МНВО РК (Казахстан)

Бушуев Сергей Дмитриевич — доктор технических наук, профессор, директор Украинской ассоциации управления проектами «УКРНЕТ», заведующий кафедрой управления проектами Киевского национального университета строительства и архитектуры (Украина)

Белошницкая Светлана Васильевна — доктор технических наук, доцент, профессор кафедры вычислений и науки о данных Astana IT University (Казахстан)

РЕДАКТОР:

Мрзабаева Раушан Жалиевна — магистр, редактор Международного университета информационных технологий (Казахстан)

Международный журнал информационных и коммуникационных технологий

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Собственник: АО «Международный университет информационных технологий» (г. Алматы).

Свидетельство о постановке на учет периодического печатного издания в Министерство информации и общественного развития Республики Казахстан № KZ82VPY00020475, выданное от 20.02.2020 г.

Тематическая направленность: информационные технологии, информационная безопасность и коммуникационные технологии, цифровые технологии в развитии социально-экономических систем.

Периодичность: 4 раза в год.

Тираж: 100 экземпляров.

Адрес редакции: 050040 г. Алматы, ул. Манаса 34/1, каб. 709, тел: +7 (727) 244-51-09.

E-mail: ijict@iitu.edu.kz

Сайт журнала: <https://journal.iitu.edu.kz>

© АО Международный университет информационных технологий, 2025

© Коллектив авторов, 2025

EDITOR-IN-CHIEF

Assylbek Issakhov — PhD in Mathematics in Computability Theory, associate professor in “Computer Science and Informatics,” Chairman of the Board – Rector of the International Information Technology University (Kazakhstan)

DEPUTY EDITOR-IN-CHIEF

Kateryna Kolesnikova — Doctor of Technical Sciences, professor, Vice-Rector for Research, International Information Technology University (Kazakhstan)

ACADEMIC SECRETARY

Madina Ipalakova — Candidate of Technical Sciences, associate professor, Director of the Research Department, International Information Technology University (Kazakhstan)

EDITORIAL BOARD

Abdul Razak — PhD, professor, Department of Cybersecurity, International Information Technology University (Kazakhstan)

Lucio Tommaso De Paolis — Director of the R&D Department of the AVR Laboratory, Department of Engineering for Innovation, University of Salento (Italy)

Liz Bacon — Professor, Deputy Vice-Chancellor, Abertay University (United Kingdom)

Michele Pagano — PhD, Professor, University of Pisa (Italy)

Mukhtarbay Otelbayev — Doctor of Physical and Mathematical Sciences, professor, academician of the National Academy of Sciences of the Republic of Kazakhstan, professor of the Department of Mathematical and Computer Modeling, International Information Technology University (Kazakhstan)

Bolatbek Rysbauly — Doctor of Physical and Mathematical Sciences, professor, professor of the Department of Computing and Data Science, Astana IT University (Kazakhstan)

Yevgeniya Daineko — PhD, research professor, Department of Information Systems, International Information Technology University (Kazakhstan)

Nurzhan Duzbayev — PhD, associate professor, Vice-Rector for Digitalization and Innovation, International Information Technology University (Kazakhstan)

Bakhtgerai Sinchev — Doctor of Technical Sciences, professor, Department of Information Systems, International Information Technology University (Kazakhstan)

Nurgul Seilova — Candidate of Technical Sciences, Dean of the Faculty of Computer Technologies and Cybersecurity, International Information Technology University (Kazakhstan)

Ardak Mukhamediyeva — Candidate of Economic Sciences, Dean of the Faculty of Business, Media and Management, International Information Technology University (Kazakhstan)

Zamira Abdikalikova — PhD, associate professor, Head of the Department of Mathematical and Computer Modeling, International Information Technology University (Kazakhstan)

Yerlan Shildibekov — PhD, associate professor, Head of the Department of Economics and Business, International Information Technology University (Kazakhstan)

Damilya Yeskendiroya — Candidate of Technical Sciences, associate professor, Head of the Department of Cybersecurity, International Information Technology University (Kazakhstan)

Aigul Niyazgulova — Candidate of Philological Sciences, Professor, Head of the Department of Media Communications and History of Kazakhstan, International Information Technology University (Kazakhstan)

Altai Aitmagambetov — Candidate of Technical Sciences, Professor, Department of Radio Engineering, Electronics and Telecommunications, International Information Technology University (Kazakhstan)

Yelena Bakhtiyarova — Candidate of Technical Sciences, associate professor, Head of the Department of Radio Engineering, Electronics and Telecommunications, International Information Technology University (Kazakhstan)

Kanibek Sansyzbay — PhD, research professor, Department of Cybersecurity, International Information Technology University (Kazakhstan)

Sakhybay Tynymbayev — Candidate of Technical Sciences, Professor, Research Professor, Department of Computer Engineering, International Information Technology University (Kazakhstan)

Ali Abd Almisreb — PhD, associate professor, Department of Cybersecurity, International Information Technology University (Kazakhstan)

Mohamed Ahmed Hamada — PhD, associate professor, Department of Information Systems, International Information Technology University (Kazakhstan)

Yang Im Chu — PhD, Professor, Gachon University (South Korea)

Tadeusz Wallas — PhD, Vice-Rector, Adam Mickiewicz University (Poland)

Orken Mamyrbayev — PhD, Deputy Director for Science, RSE Institute of Information and Computational Technologies, Committee for Science of the Ministry of Science and Higher Education of the Republic of Kazakhstan (Kazakhstan)

Sergey Bushuyev — Doctor of Technical Sciences, professor, Director of the Ukrainian Project Management Association “UKRNET,” Head of the Department of Project Management, Kyiv National University of Construction and Architecture (Ukraine)

Svetlana Beloshitskaya — Doctor of Technical Sciences, professor, Department of Computing and Data Science, Astana IT University (Kazakhstan)

EDITOR

Raushan Mrzabayeva — Master of Science, editor, International Information Technology University (Kazakhstan)

«International Journal of Information and Communication Technologies»

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Owner: International Information Technology University JSC (Almaty).

The certificate of registration of a periodical printed publication in the Ministry of Information and Social Development of the Republic of Kazakhstan, Information Committee No. KZ8ZVPY00020475, issued on 20.02.2020.

Thematic focus: information technology, digital technologies in the development of socio-economic systems, information security and communication technologies

Periodicity: 4 times a year.

Circulation: 100 copies.

Editorial address: 050040. Manas st. 34/1, Almaty. +7 (727) 244-51-09. E-mail: ijict@iitu.edu.kz

Journal website: <https://journal.iitu.edu.kz>

© International Information Technology University JSC, 2025

© Group of authors, 2025

МАЗМҰНЫ

М.Ж. Айтимов, К.К. Макулов, А.Б. Остаева, Г.Ш. Мусагулова, Я. Култан АЙМАҚТЫҚ ДАМУҒА ӘЛЕУМЕТТІК-ЭКОНОМИКАЛЫҚ ФАКТОРЛАРДЫҢ ӨСЕРІН ЗЕРТТЕУ ҮШІН ГИБРИДТІ МОДЕЛЬДІ ҚОЛДАНУ	8
А.С. Баегизова, Г.Е. Мырзабекова, А.З. Алимагамбетова, Г.И. Мухамедрахимова, М. Кассим ИНТЕЛЛЕКТУАЛДЫ КЛАСТЕРЛЕУ ӘДІСТЕРІН ҚОЛДАНА ОТЫРЫП, ҚЫСҚА МӘТІНДЕРДІ ТАЛ ДАУ	23
Г.У. Бектемісова, А.А. Быков, Б.А. Нурашихин, А.А. Кереш, М.О. Даулетбек КОМПЬЮТЕРЛІК КӨРУ ЖӘНЕ МАШИНАЛЫҚ ОҚЫТУ НЕГІЗІНДЕ ҚҰРЫЛЫС ПРОЦЕСТЕРІН БАҚЫЛАУДЫҢ ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕСІН ӨЗІРЛЕУ ЖӘНЕ СЫНАУ	37
Д. Еділхан, Н. Хаймульдин, Д. Оспанова, Б. Амиргалиев БАРЛЫҚ КӨШЕЛЕРДІ ҚОЗҒАЛЫС ШЕКТЕУЛЕРІМЕН ҚАМТУҒА АРНАЛҒАН ОҢТАЙЛЫ МАРШРУТТЫ ТАБУДЫҢ ИНТЕЛЛЕКТУАЛДЫ МОДЕЛІ	57
А. Игнатович, А.С. Есенгельдина, Л.Т. Курмангазиева, С.Р. Шармұханбет, М.У. Худойберганов МАШИНАЛЫҚ ОҚЫТУ КӨМЕГІМЕН ҚАЗАҚСТАНДАҒЫ СОТ ШЕШІМДЕРІН БОЛЖАУҒА АРНАЛҒАН ДЕРЕКТЕРДІ ҚҰРУ	75
А.Х. Касымова, Г.Б. Абдикеримова, А.К. Асабай, А.Б. Серикбаева, С.М. Ахмедова БЕЙНЕ АҒЫНДАРЫНДА ҚОЗҒАЛАТЫН ОБЪЕКТІЛЕРДІ АНЫҚТАУ ҮШІН НАҚТЫ УАҚЫТТАҒЫ МАТЕМАТИКАЛЫҚ МОДЕЛЬДЕУ	91
С.К. Кумаргажанова, Д. Нұрлыбекова, А.С. Тлебалдинова, М.А. Карменова, С.А. Смаилова ШЫҒЫС ҚАЗАҚСТАН ОБЛЫСЫНЫҢ ҚАР КӨШКІНІ АЙМАҚТАРЫН МАШИНАЛЫҚ ОҚЫТУ ӘДІСІ АРҚЫЛЫ АНЫҚТАУ	115
С.Б. Муханов, К. Бекболат, Н.А. Сейлова, Ж.М. Бекаулова, С.Ж. Жакыпбеков САУДА ЖҮПТАРЫНДАҒЫ КРИПТОВАЛЮТА БАҒАСЫНЫҢ ҚҰБЫЛМАЛЫЛЫҒЫН БОЛЖАУҒА АРНАЛҒАН НЕЙРОНДЫҚ ЖЕЛІ МОДЕЛЬДЕРІН САЛЫСТЫРУ	130
Н.А. Оданова, К.Б. Багитова, Э.Э. Эльдарова, Ж.Т. Қабылхамит, Л.Терейковская АҚПАРАТТЫҚ ҚАУІПСІЗДІК САЛАСЫНДА ПЕРНЕТАҚТАДА ТЕРУ ҮЛГІСІН ТАЛДАУҒА АРНАЛҒАН НЕЙРОЖЕЛІЛІК МОДЕЛЬДЕРДІ ҚОЛДАНУ	142
А.С. Сраж, М. Нұртас, А.А. Алтайбек, З.Т. Абдикаликова НЕЙРОНДЫҚ ЖЕЛІЛЕР МАТЕМАТИКАЛЫҚ ЕСЕПТЕУ ҚҰРАЛЫ РЕТІНДЕ	154
А.М. Темірхан, Г.Н. Пашенко БАНКТЫҚ АЛАЯҚТЫҚТЫ АНЫҚТАУДАҒЫ ГРАФТЫҚ НЕЙРОНДЫҚ ЖЕЛІЛЕР: ӘДІСТЕРДІ САЛЫСТЫРМАЛЫ ТАЛДАУ	174
Е.Б. Тулебаев, А.А. Муханова, Н. Горанин МУНИЦИПАЛДЫҚ АКТИВТЕРДІҢ ТӘУЕКЕЛДЕРІН БОЛЖАУ: МАШИНАЛЫҚ ОҚЫТУДЫ ПАЙДАЛАНУ АРҚЫЛЫ ЖАС, ТОЗУ ЖӘНЕ ПАЙДАЛАНУ ҚАРҚЫНДЫЛЫҒЫ НЕГІЗІНДЕ ТЕХНИКАЛЫҚ ҚЫЗМЕТ КӨРСЕТУ ШЕШІМДЕРІН МОДЕЛЬДЕУ	186
С. Тынымбаев, Ж.Е. Темирбекова, Р.Ш. Бердибаев, С.Е. Маманова ТӨРТ РАЗРЯДТЫ ЕКІЛІК ПАРАЛЛЕЛЬ ТАСЫМАЛДАҒЫШЫ БАР ҚОСЫНДЫЛАРДЫ САЛЫСТЫРМАЛЫ ТАЛДАУ	200
Б.М. Укибасов, С.Б. Рахметұлаева, Ж.О. Жанабеков, Ансар-уль-Хак Ясар ЭХОКАРДИОГРАММАЛАРДАҒЫ АҚАУЛАРДЫ ДИАГНОСТИКАЛАУ ҮШІН БЕТТІ АНЫҚТАУ ЖӘНЕ ТАНУ ҮЛГІЛЕРІН БЕЙІМДЕУ	214
Д.И. Усипбекова, М.Б. Есенова, Н. Ұзаққызы, Р. Муратхан, П. Шмидт МАММОГРАФИЯЛЫҚ СУРЕТТЕРДЕ СҮТ БЕЗІ ҚАТЕРЛІ ІСІГІН ДӨЛ АНЫҚТАУҒА АРНАЛҒАН БЕЛГІЛЕР ВЕКТОРЫН ҚҰРУ	235

СОДЕРЖАНИЕ

М.Ж. Айтимов, К.К. Макулов, А.Б. Остаева, Г.Ш. Мусагулова, Я. Култан ПРИМЕНЕНИЕ ГИБРИДНОЙ МОДЕЛИ ДЛЯ ИЗУЧЕНИЯ ВЛИЯНИЯ СОЦИАЛЬНО-ЭКОНОМИЧЕСКИХ ФАКТОРОВ НА РЕГИОНАЛЬНОЕ РАЗВИТИЕ.....	8
А.С. Баегизова, Г.Е. Мырзабекова, А.З. Алимагамбетова, Г.И. Мухамедрахимова, М. Кассим АНАЛИЗ КОРОТКИХ ТЕКСТОВ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИНТЕЛЛЕКТУАЛЬНОЙ КЛАС- ТЕРИЗАЦИИ.....	23
Г.У. Бектемысова, А.А. Быков, Б.А. Нурашихин, А.А. Кереш, М.О. Даулетбек РАЗРАБОТКА И ТЕСТИРОВАНИЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ МОНИТОРИНГА СТРОИТЕЛЬНЫХ ПРОЦЕССОВ НА ОСНОВЕ КОМПЬЮТЕРНОГО ЗРЕНИЯ И МАШИННОГО ОБУЧ- ЕНИЯ.....	37
Д. Едилхан, Н. Хаймульдин, Д. Оспанова, Б. Амиргалиев ИНТЕЛЛЕКТУАЛЬНАЯ МОДЕЛЬ ПОИСКА ОПТИМАЛЬНОГО МАРШРУТА ПОКРЫТИЯ ВСЕХ УЛИЦ С ОГРАНИЧЕНИЯМИ ПО ПЕРЕМЕЩЕНИЯМ.....	57
А. Игнатович, А.С. Есенгельдина, Л.Т. Курмангазиева, С.Р. Шармуханбет, А.М. Недзьведь ГЕНЕРАЦИЯ ДАННЫХ ДЛЯ ПРОГНОЗИРОВАНИЯ СУДЕБНЫХ РЕШЕНИЙ В КАЗАХСТАНЕ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ.....	75
А.Х. Касымова, Г.Б. Абдикеримова, А.К. Асабай, А.Б. Серикбаева, С.М. Ахмедова МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ В РЕАЛЬНОМ ВРЕМЕНИ ДЛЯ ОБНАРУЖЕНИЯ ДВИЖУЩИХСЯ ОБЪЕКТОВ В ВИДЕОПОТОКАХ.....	91
С.К. Кумаргажанова, Д. Нурлыбекова, А.С. Тлебалдинова, М.А. Карменова, С.А. Смаилова ВЫЯЛЕНИЕ ЛАВИНООПАСНЫХ ЗОН В ВОСТОЧНОМ КАЗАХСТАНЕ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ.....	115
С.Б. Муханов, К. Бекболат, Н.А. Сейлова, Ж.М. Бекаулова, С. Ж. Жакыпбеков СРАВНЕНИЕ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ВОЛАТИЛЬНОСТИ ЦЕН КРИПТОВАЛЮТ В ТОРГОВЫХ ПАРАХ.....	130
Н.А. Оданова, К.Б. Багитова, Э.Э. Эльдарова, Ж.Т. Кабылхамит, Л. Терейковская ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ АНАЛИЗА КЛАВИАТУРНОГО ПОЧЕРКА В ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ.....	142
А.С. Сраж, М. Нуртас, А.А. Алтайбек, З.Т. Абдикаликова НЕЙРОННЫЕ СЕТИ КАК ИНСТРУМЕНТ МАТЕМАТИЧЕСКИХ ВЫЧИСЛЕНИЙ.....	154
А.М. Темирхан, Г.Н. Пашенко ГРАФОВЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ ОБНАРУЖЕНИЯ МОШЕННИЧЕСТВА: СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ.....	174
Е.Б. Тулебаев, А.А. Муханова, Н. Горанин ПРОГНОЗНАЯ ОЦЕНКА РИСКОВ МУНИЦИПАЛЬНЫХ АКТИВОВ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ: МОДЕЛИРОВАНИЕ ВОЗРАСТА, ИЗНОСА И ИСПОЛЬЗОВАНИЯ ДЛЯ ПРИНЯТИЯ РЕШЕНИЙ ПО ОБСЛУЖИВАНИЮ.....	186
С. Тынымбаев, Ж.Е. Темирбекова, Р.Ш. Бердибаев, С.Е. Маманова СРАВНИТЕЛЬНЫЙ АНАЛИЗ ЧЕТЫРЕХРАЗЯДНЫХ ДВОИЧНЫХ СУММАТОРОВ С ПАРАЛЛЕЛЬНЫМИ ПЕРЕНОСАМИ.....	200
Б.М. Укибасов, С.Б. Рахметулаева, Ж.О. Жанабеков, Ансар-уль-Хак Ясар АДАПТАЦИЯ МОДЕЛЕЙ ОБНАРУЖЕНИЯ И РАСПОЗНАВАНИЯ ЛИЦ ДЛЯ ДИАГНОСТИКИ ДЕФЕКТОВ НА ЭХОКАРДИОГРАММАХ.....	214
Д.И. Усипбекова, М.Б. Есенова, Н. Узаккызы, Р. Мурадхан, П. Шмидт ОПРЕДЕЛЕНИЕ ВЕКТОРА ПРИЗНАКОВ ДЛЯ ТОЧНОГО ВЫЯВЛЕНИЯ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ НА ИЗОБРАЖЕНИЯХ МАММОГРАММЫ.....	235

CONTENTS

M. Aitimov, K. Makulov, A. Ostayeva, G. Mussagulova, J. Kultan APPLICATION OF A HYBRID MODEL TO STUDY THE IMPACT OF SOCIO-ECONOMIC FACTORS ON REGIONAL DEVELOPMENT.....	8
A. Bayegizova, G. Murzabekova, A. Alimagambetova, G. Mukhamedrakhimova, M. Kassim INTELLIGENT CLUSTERING METHODS FOR PROCESSING AND ANALYZING SHORT TEXTS.....	23
G.U. Bektemysova, A.A. Bykov, B.A. Norashikin, A.A. Keresh, M.O. Dauletbek DEVELOPMENT AND TESTING OF AN INTELLIGENT MONITORING SYSTEM FOR CONSTRUCTION PROCESSES BASED ON COMPUTER VISION AND MACHINE LEARNING.....	37
D. Yedilkhan, N. Khaimuldin, D. Ospanova, B. Amirgaliyev INTELLIGENT MODEL FOR FINDING THE OPTIMAL ROUTE TO COVER ALL STREETS WITH MOVEMENT CONSTRAINTS.....	57
A. Ignatovich, A.S. Yesengeldina, L.T. Kurmangazyeva, S.R. Sharmukhanbet, A.M. Nedzved SIGNIFICANT FACTORS ANALYSIS USING SHAP AND PCA FOR OPTIMIZING AGRICULTURAL RESOURCE MANAGEMENT.....	75
A. Kassymova, G. Abdikerimova, A. Assabay, A. Serikbayeva, S. Akhmedova REAL-TIME MATHEMATICAL MODELING FOR MOVING OBJECT DETECTION IN VIDEO STREAMS.....	91
S.K. Kumargazhanova, D. Nurlybekova, A.S. Tlebaldinova, M.A. Karmenova, S.S. Smailova FINDING AVALANCHE AREAS IN EAST KAZAKHSTAN USING MACHINE LEARNING.....	115
S.B. Mukhanov, K. Bekbolat, N.A. Seilova, Zh.M. Bekaulova, S.Zh. Zhakypbekov COMPARISON OF NEURAL NETWORK MODELS FOR PREDICTION CRYPTOCURRENCY PRICE VOLATILITY IN TRADING PAIRS.....	130
N. Odanova, K. Bagitova, E. Eldarova, Zh. Kabylkhamit, L. Tereikovska APPLICATION OF NEURAL NETWORK MODELS FOR KEYSTROKE DYNAMICS ANALYSIS IN INFORMATION SECURITY.....	142
A.S. Srazh, M. Nurtas, A.A. Altaibek, Z.T. Abdikalikova EURAL NETWORKS AS A TOOL FOR MATHEMATICAL COMPUTATION.....	154
A.M. Temirkhan, G.N. Pachshenko GRAPH NEURAL NETWORKS FOR FRAUD DETECTION: COMPARATIVE ANALYSIS OF METHODS.....	174
Y.B. Tulebayev, A.A. Mukhanova, N. Goranin PREDICTIVE RISK ASSESSMENT OF MUNICIPAL ASSETS USING MACHINE LEARNING: MODELING AGE, DEPRECIATION, AND USAGE FOR MAINTENANCE DECISIONS.....	186
S. Tynymbayev, Zh. E. Temirbekova, R. Berdibayev, E.S. Mamanova COMPARATIVE ANALYSIS OF FOUR-BIT BINARY ADDERS WITH PARALLEL CARRIES.....	200
B.M. Ukibassov, S.B. Rakhmetulayeva, Zh.O. Zhanabekov, Ansar-Ul-Haque Yasar ADAPTING FACE DETECTION AND RECOGNITION MODELS FOR ECHOCARDIOGRAPHIC DEFECT DIAGNOSIS.....	214
D. Ussipbekova, M. Yessenova, N. Uzakkyzy, R. Muratkhan, P. Schmidt DETERMINATION OF SIGNS VECTOR FOR ACCURATE DETECTION OF BREAST CANCER IN MAMMOGRAM IMAGES.....	235

АҚПАРАТТЫҚ ТЕХНОЛОГИЯЛАР

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

INFORMATION TECHNOLOGY

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 1. Number 22 (2025). Pp. 8–22

Journal homepage: <https://journal.iitu.edu.kz>

<https://doi.org/10.54309/IJICT.2025.22.2.001>

УДК 004.931

APPLICATION OF A HYBRID MODEL TO STUDY THE IMPACT OF SOCIO-ECONOMIC FACTORS ON REGIONAL DEVELOPMENT

M. Aitimov¹, *K. Makulov², A. Ostayeva¹, G. Mussagulova¹, J. Kultan³

¹Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan;

²Caspian University of Technologies and Engineering named after. Sh. Yessenov, Aktau, Kazakhstan;

³University of Economics, Bratislava, Slovakia.

E-mail: kaiyrbek.makulov@yu.edu.kz

Aitimov M. — PhD, senior lecturer, Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan

E-mail: aitimovmurat07@gmail.com, <https://orcid.org/0000-0002-8397-8914>;

Makulov K. — PhD, associate professor, «The Department of Computer Science», Caspian University of Technologies and Engineering named after. Sh. Yessenov, Aktau, Kazakhstan

E-mail: kaiyrbek.makulov@yu.edu.kz, <https://orcid.org/0000-0002-0826-0371>;

Ostayeva A. — Candidate of Pedagogical Sciences, senior lecturer, Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan

E-mail: aimak73@mail.ru, <https://orcid.org/0000-0003-3361-2022>;

Mussagulova G. — senior lecturer, «The Department of Informatics and Information and Communication Technologies», Institute of Natural Sciences, Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan

E-mail: erkegulia@mail.ru, <https://orcid.org/0000-0002-0911-2688>;

Jaroslav K. — associate professor, University of Economics, Bratislava, Slovakia

E-mail: bar@ict.nsc.ru, <https://orcid.org/0000-0001-6068-9784>.

© M. Aitimov, K. Makulov, A. Ostayeva, G. Mussagulova, J. Kultan, 2025

Abstract. This article presents a hybrid model that combines correlation analysis, principal component analysis (PCA), and fuzzy logic to assess factors affecting regional socio-economic development. The model assesses their impact on regional development, taking into account the complex relationships between factors such as population, employment, and fixed capital investments. Basic data: population –

431,192 people, average monthly wage – 2,658,658 tenge, investments – 1,646,258 tenge, employed – 1,929 thousand people. The hybrid model enables a highly accurate assessment of the impact of each factor. The results of the study showed a positive impact of population (coefficient 3.28) and investments (coefficient 3.44) on regional processes. The proposed model enables accurate determination of factor impacts and paves the way for enhancing regional development strategies through data-driven insights.

Key words: Hybrid model, socio-economic factors, correlation analysis, machine learning, artificial intelligence

For citation: M. Aitimov, K. Makulov, A. Ostayeva, G. Mussagulova, J. Kultan. Application of a hybrid model to study the impact of socio-economic factors on regional development//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 8–22 (In Kaz.). <https://doi.org/10.54309/IJICT.2025.22.2.001>.

Conflict of interest: The authors declare that there is no conflict of interest.

АЙМАҚТЫҚ ДАМУҒА ӘЛЕУМЕТТІК-ЭКОНОМИКАЛЫҚ ФАКТОРЛАРДЫҢ ӘСЕРІН ЗЕРТТЕУ ҮШІН ГИБРИДТІ МОДЕЛЬДІ ҚОЛДАНУ

*М.Ж. Айтимов¹, *К.К. Макулов², А.Б. Остаева¹, Г.Ш. Мусагулова¹,
Я. Култан³*

¹ Қорқыт ата атындағы Қызылорда университеті, Қызылорда, Қазақстан;

²Есенов атындағы Каспий технологиялар және инжиниринг университеті,
Ақтау, Қазақстан;

³Экономикалық университет, Братислава, Словакия.

E-mail: kaiyrbek.makulov@yu.edu

Айтимов М. — PhD, аға оқытушы, Қорқыт Ата атындағы Қызылорда университеті Қызылорда, Қазақстан Республикасы

E-mail: aitimovmurat07@gmail.com, <https://orcid.org/0000-0002-8397-8914>;

Макулов К. — экономика ғылымдарының кандидаты, Ш. Есенов атындағы Каспий технологиялар және инжиниринг университетінің «Компьютерлік ғылымдар кафедрасының» қауымдастырылған профессор м.а., Ақтау, Қазақстан Республикасы

E-mail: kaiyrbek.makulov@yu.edu.kz, <https://orcid.org/0000-0002-0826-0371>;

Остаева А. — педагогика ғылымдарының кандидаты, аға оқытушы, Қорқыт Ата атындағы Қызылорда университеті Қызылорда, Қазақстан Республикасы

E-mail: aimak73@mail.ru, <https://orcid.org/0000-0003-3361-2022>;

Мусагулова Г. — «Информатика және аппараттық коммуникациялық технологиялар» кафедрасының аға оқытушысы, жаратылыстану институты, Қорқыт Ата атындағы Қызылорда университеті, Қызылорда, Қазақстан Республикасы

E-mail: erkegulia@mail.ru, <https://orcid.org/0000-0002-0911-2688>;

Ярослав К. — қауымдастырылған профессор, Экономикалық университет, Братислава, Словакия

E-mail: bar@ict.nsc.ru, <https://orcid.org/0000-0001-6068-9784>.

© М.Ж. Айтимов, К.К. Макулов, А.Б. Остаева, Г.Ш. Мусагулова, Я. Култан, 2025

Аннотация. Бұл мақалада өңірлік әлеуметтік-экономикалық дамуға әсер ететін факторларды бағалау үшін корреляциялық талдау, негізгі компоненттерді талдау (РСА) және бұлыңғыр логиканы біріктіретін гибриді модель ұсынылады. Модель халық саны, жұмыспен қамту, негізгі капиталға инвестициялар сияқты факторлар арасындағы күрделі байланыстарды ескере отырып, олардың өңірлік дамуға ықпалын бағалайды. Негізгі деректер: халық саны – 431 192 адам, орташа айлық жалақы – 2 658 658 теңге, инвестициялар – 1 646 258 теңге, жұмыспен қамтылғандар – 1 929 мың адам. Гибриді модель әрбір фактордың ықпалын жоғары дәлдікпен бағалауға мүмкіндік берді. Зерттеу нәтижелері халық саны (коэффициенті 3,28) мен инвестициялардың (коэффициенті 3,44) өңірлік үдерістерге оң әсерін көрсетті. Ұсынылған модель факторлардың ықпалын дәл анықтауға мүмкіндік беріп, өңірлік даму стратегияларын деректерге негіздей отырып жетілдіруге жол ашады.

Түйін сөздер: Гибриді модель, әлеуметтік-экономикалық факторлар, корреляциялық талдау, машиналық оқыту, жасанды интеллект

Дәйексөздер үшін: М.Ж. Айтимов, К.К. Макулов, А.Б. Остаева, Г.Ш. Мусагулова, Я. Култан. Аймақтық дамуға әлеуметтік-экономикалық факторлардың әсерін зерттеу үшін гибриді модельді қолдану//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 8–22 бет. (қазақ тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.001>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

ПРИМЕНЕНИЕ ГИБРИДНОЙ МОДЕЛИ ДЛЯ ИЗУЧЕНИЯ ВЛИЯНИЯ СОЦИАЛЬНО-ЭКОНОМИЧЕСКИХ ФАКТОРОВ НА РЕГИОНАЛЬНОЕ РАЗВИТИЕ

*М.Ж. Айтимов¹, *К.К. Макулов², А.Б. Остаева¹, Г.Ш. Мусагулова¹,
Я. Култан³*

¹Кызылординский университет имени Коркыт Ата, Кызылорда, Казахстан;

²Каспийский университет технологий и инжиниринга имени Ш. Есенова, Актау, Казахстан;

³Экономический университет, Братислава, Словакия

E-mail: kaiyrbek.makulov@yu.edu

Айтимов М. — PhD, старший преподаватель, Кызылординский университет имени Коркыт Ата, Кызылорда, Казахстан

E-mail: aitimovmurat07@gmail.com, <https://orcid.org/0000-0002-8397-8914>.

Макулов К. — кандидат экономических наук, и.о. ассоциированного профессора, «Кафедра компьютерных наук», Каспийский университет технологий и инжиниринга имени Ш. Есенова, Актау, Казахстан

E-mail: kaiyrbek.makulov@yu.edu.kz, <https://orcid.org/0000-0002-0826-0371>

Остаева А. — кандидат педагогических наук, старший преподаватель, Кызылординский университет имени Коркыт Ата, Кызылорда, Казахстан



E-mail: aimak73@mail.ru, <https://orcid.org/0000-0003-3361-2022>

Мусагулова Г. — старший преподаватель, «Кафедра информатики и информационно-коммуникационных технологий», институт естествознания, Кызылординский университет имени КоркытАта, Кызылорда, Казахстан

E-mail: erkegulia@mail.ru, <https://orcid.org/0000-0002-0911-2688>.

Ярослав К. — ассоциированный профессор, Экономический университет, Братислава, Словакия

E-mail: bar@ict.nsc.ru, <https://orcid.org/0000-0001-6068-9784>.

© М.Ж. Айтимов, К.К. Макулов, А.Б. Остаева, Г.Ш. Мусагулова, Я. Култан, 2025

Аннотация. В данной статье представлена гибридная модель, объединяющая корреляционный анализ, анализ главных компонент (РСА) и нечеткую логику для оценки факторов, влияющих на региональное социально-экономическое развитие. Модель оценивает их влияние на региональное развитие, принимая во внимание сложные взаимосвязи между такими факторами, как численность населения, занятость и инвестиции в основной капитал. Исходные данные: численность населения – 431 192 человека, среднемесячная заработная плата – 2 658 658 тенге, инвестиции – 1 646 258 тенге, занятые – 1 929 тыс. человек. Гибридная модель позволила с высокой точностью оценить влияние каждого фактора. Результаты исследования показали положительное влияние численности населения (коэффициент 3,28) и инвестиций (коэффициент 3,44) на региональные процессы. Предложенная модель позволяет точно определить влияние факторов и открывает путь к совершенствованию стратегий регионального развития на основе данных.

Ключевые слова. Гибридная модель, социально-экономические факторы, корреляционный анализ, машинное обучение, искусственный интеллект.

Для цитирования: М.Ж. Айтимов, К.К. Макулов, А.Б. Остаева, Г.Ш. Мусагулова, Я. Култан. Применение гибридной модели для изучения влияния социально-экономических факторов на региональное развитие // Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 8–22. (На англ.). <https://doi.org/10.54309/IJICT.2025.22.2.001>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Кіріспе

Гибридті деректерді талдау модельдері әртүрлі салаларда, әсіресе әлеуметтік-экономикалық зерттеулерде күрделі үдерістерді зерттеу және болжау үшін қуатты құрал болып табылады (Raman et. al., 2024; Akintuyi et. al., 2024; Huo et. al., 2024;). Олар бірнеше талдау әдістерін, соның ішінде корреляциялық талдау, негізгі компоненттер талдауы (РСА) және бұлыңғыр логиканы біріктіреді. Бұл комбинация көптеген факторларды және олардың өзара әрекеттесуін ескеруге мүмкіндік береді. Қазіргі заманғы жағдайларда зерттелетін үдерістер барған сайын күрделеніп, динамикалық сипатқа ие болғандықтан, ги-



бридті модельдер (Tussupov et. al., 2024; Wijayanti et. al., 2024;) дәл және сенімді қорытындылар алу үшін таптырмас құралға айналуға. Зерттеудің мақсаты – өңірде болып жатқан негізгі үдерістерге әртүрлі әлеуметтік-экономикалық факторлардың ықпалын бағалау. Мысалы, халық саны, жұмыспен қамту деңгейі, инвестициялар және қылмыс көрсеткіштері (Reddy et. al., 2024; El-Kenawy et. al., 2024;) экономикалық және әлеуметтік үдерістерге әртүрлі әсер етеді. Алайда, олардың ықпалы әрқашан біржақты бола бермейді және басқа айнымалыларға байланысты өзгеруі мүмкін. Дәстүрлі талдау әдістері, әдетте, мұндай күрделі тәуелділіктерді толықтай ескере алмайды, сондықтан гибридті тәсіл осы өзара байланыстарды дәлірек бағалауға мүмкіндік береді, бұл ретте сандық және сапалық деректерді өңдеу әдістерін қолданады. Гибридті модельдердің негізгі артықшылықтарының бірі – айнымалылар арасындағы сызықты емес тәуелділіктерді ескеру қабілеті, бұл әсіресе әлеуметтік және экономикалық жүйелерді зерттеуде маңызды. Көп жағдайда дәстүрлі әдістер, мысалы, сызықтық регрессия, күрделі және көп өлшемді тәуелділіктерді тиімді түрде сипаттай алмайды. Мұндай жағдайларда бұлыңғыр логика әдістері таптырмас құралға айналады, өйткені олар нақты деректерде жиі кездесетін анықсыздықтар мен екіұштылықтарды (Yang et. al., 2024; Zhao et. al., 2024;) модельдей алады.


Бұл зерттеудің мақсаты – барлық осы аспектілерді ескеретін және әлеуметтік-экономикалық үдерістерге әсер ететін факторларды талдауға мүмкіндік беретін гибридті модель құру. Бұл жұмыста біз факторлар (Kamraj et. al., 2024;) мен үдерістер арасындағы тәуелділіктерді анықтау үшін корреляциялық талдауды, деректердің өлшемдігін азайту үшін негізгі компоненттер талдауын (PCA) (Ingio et. al., 2024;) және белгісіз әрі күрделі байланыстарды (Xiong et. al., 2024;) модельдеу үшін бұлыңғыр логиканы (Barzani et. al., 2024;) қолдандық. Бұл әдістер біртұтас модельге біріктіріліп, әлеуметтік-экономикалық үдерістерге факторлардың ықпалын кешенді бағалауға мүмкіндік берді.

Зерттеудің өзектілігі қазіргі әлеуметтік және экономикалық үдерістер әртүрлі факторлардың күрделі өзара тәуелділігімен сипатталатындығында, олар ішкі және сыртқы жағдайлардың әсерінен өзгеруі мүмкін. Мысалы, халық санының өзгеруі көші-қон, туу және өлім көрсеткіштері, экономикалық жағдай, сондай-ақ жұмыс орындарының және әлеуметтік қызметтердің қолжетімділігіне байланысты болуы мүмкін. Сонымен қатар, бұл факторлардың әсері әрқашан сызықты емес және оңай болжанбайды, бұл дәстүрлі әдістерді қолдана отырып сандық модельдеуде қиындықтар туындатады. Бұлыңғыр логиканы қолдану (Hammoumi et. al., 2024;) деректер толық немесе нақты болмаған, сондай-ақ факторлардың ықпалы көпқырлы болған жағдайларда белгісіздік пен бұлыңғыр шекараларды модельдеуге мүмкіндік береді.

Әдістер мен материалдар

Өңірде болып жатқан әлеуметтік-экономикалық факторлар мен үдері-

стер арасындағы байланыстарды терең талдау және анықтау үшін дәстүрлі статистикалық әдістермен қатар заманауи есептеу тәсілдерін де қолдануға болады. Олардың ішінде машиналық оқыту әдістері (Faloye et. al., 2024;) және терең деректерді талдау әдістері бар. Бұл зерттеуде әртүрлі әдістер қолданылып, олардың әрқайсысы жалпы модельде белгілі бір рөл атқарды. 1-суретте экономикалық, демографиялық және басқа да салалардағы үдерістерге факторлардың әсерін талдау үшін қолданылатын гибриді модель алгоритмі көрсетілген. Ол деректерді стандарттаудан бастап бұлыңғыр логика моделін құруға дейінгі бірнеше деректерді өңдеу кезеңдерін қамтиды.



Сур. 1. Факторлардың процестерге әсерін талдауға арналған гибриді модель

1-қадам. Деректерді жүктеу. Жүктелген деректер әртүрлі үдерістердің түрлі аспектілерін көрсететін факторларды қамтиды. Талдауға енгізілгендер:

- Демографиялық үдерістер: халық саны, туу коэффициенті және көші-қон балансы.
- Экономикалық үдерістер: жұмыс күші, орташа айлық жалақы және негізгі капиталға салынған инвестициялар.
- Әлеуметтік үдерістер: жұмыспен қамту деңгейі, тіркелген қылмыстар саны, некелер саны және өмір сүру құны.
- Кәсіпкерлік және сауда үдерістері: мектептер саны, заңды тұлғалар саны және бөлшек сауда көлемі.
- Өнеркәсіптік үдерістер: өнеркәсіптік өндіріс көлемі, тау-кен өндірісі және өңдеу өнеркәсібі.

Әрбір фактор тиісті үдерісті индекстеуге қатысады.

2-қадам. Деректерді стандарттау. Деректер StandardScaler алгоритмі арқылы нормализацияланады, осылайша әрбір фактордың орташа мәні нөлге

тең болып, стандартты ауытқуы бірге теңестіріледі. Бұл кейінгі талдаулардың, мысалы, негізгі компоненттер талдауы (РСА) және корреляциялық талдау үшін дұрыс орындалуын қамтамасыз ету үшін қажет. Әрбір элемент үшін фактордың нормаланған мәні z_{ij} келесі формула бойынша есептеледі (1):

$$z_{ij} = \frac{x_{ij} - \mu_{ij}}{\sigma_{ij}} \quad (1)$$

мұндағы x_{ij} - фактордың мәні, μ_{ij} - фактордың орташа мәні, σ_{ij} - фактордың стандартты ауытқуы.

3-қадам. Үдеріс индекстерін есептеу. Әрбір үдеріс үшін оған сәйкес факторлар негізінде орташа индекс есептеледі. Бұл талдауды жеңілдетіп, үдерістерді жеке объектілер ретінде қарастыруға мүмкіндік береді. Әртүрлі үдерістердің деректерін талдау кезінде әрбір үдеріске біріктірілген көрсеткіш (индекс) тағайындалады, ол осы үдеріске қатысты факторлар негізінде есептеледі. Бұл тәсіл деректерді түсіндіру мен талдауды жеңілдетеді, өйткені әрбір үдеріс үшін көптеген жеке факторлармен жұмыс істеудің орнына, біз бір орташа мән – үдеріс индексімен операция жасай аламыз. Әрбір үдеріс P_{proc} үшін орташа индекс есептеледі, ол осы үдеріске байланысты барлық факторлардың арифметикалық орта мәні болып табылады. Бұл әрекет әрбір үдеріс үшін көпөлшемді деректерді жалғыз бағалауға келтіруге көмектеседі, осылайша олардың әрі қарайғы талдауын және түсіндірілуін жеңілдетеді. Үдеріс индексі $P_{proc}(j)$ төмендегі формула бойынша есептеледі (2):

$$P_{proc} = \frac{1}{n_{proc}} \sum_{i \in proc} z_{ij} \quad (2)$$

мұндағы P_{proc} - j жылындағы процесс индексі, n_{proc} - процестегі факторлардың саны, z_{ij} - j жылындағы i факторының стандартталған мәні.

4-қадам. Корреляциялық талдау. Корреляция коэффициенттері әрбір фактор мен процесс индексі үшін есептеледі. Корреляция әрбір фактордың процеске қалай қатысы барын түсінуге көмектеседі. Корреляция коэффициенті (3) формула бойынша есептеледі:

$$\rho_{i,proc} = \frac{Cov(z_i, P_{proc})}{\sigma_{z_i} \sigma_{P_{proc}}} \quad (3)$$

мұндағы $\rho_{i,proc}$ - i факторының процесспен корреляция коэффициенті, $Cov(z_i, P_{proc})$ - фактор мен процесс индексі арасындағы ковариация, σ_{z_i} және

σP_{proc} - сәйкесінше фактор мен процесс индексі үшін стандартты ауытқулар.

5-қадам: PCA (Principal Component Analysis) талдауы. PCA (Principal Component Analysis) деректердің өлшемділігін азайту үшін қолданылады. Әрбір процесс үшін деректердегі дисперсияның ең үлкен бөлігін түсіндіретін факторлардың қосындысы болып табылатын бірінші негізгі компонент есептеледі. Негізгі компонент PC_1 факторлардың сызықтық комбинациясы ретінде есептеледі (4):

$$PC_1 = WZ \quad (4)$$

мұндағы W - әрбір фактордың маңыздылығын анықтайтын салмақтар (жүктемелер) векторы, ал Z - стандартталған деректер. Өлшемділіктің бір негізгі компонентке дейін азаюы алдын ала эксперименттердің нәтижелеріне байланысты болды, бұл компоненттердің санын белгілер санына дейін арттыру талдау нәтижелерінде айтарлықтай өзгерістерге әкелмейтінін көрсетті. Бұл бір негізгі құрамдас деректердегі дисперсияның көп бөлігін түсіндіретінін көрсетеді. Тәжірибе көрсеткендей, құрамдас бөліктердің көп санын пайдалану нәтижелерді өзгертпейді, бұл негізгі ақпараттың шоғырлануын және бірінші негізгі компоненттегі факторлардың әсерін көрсетеді.

6-қадам. Бұлыңғыр логика моделін құру. Алдыңғы қадамдардың нәтижелеріне негізделе отырып, әртүрлі факторлардың үдерістерге әсерін бағалауға арналған бұлыңғыр логика моделі құрылады. Бұл модель алдыңғы кезеңдерде орындалған деректерді стандарттау, үдеріс индекстерін есептеу және корреляциялық талдауға сүйенеді. Осы қадамның негізгі мақсаты – бұлыңғыр логика әдісін қолдана отырып, әрбір фактордың үдерістерге әсерін сандық бағалау болып табылады, бұл өз кезегінде деректердегі белгісіздіктер мен дәлсіздіктерді ескеруге мүмкіндік береді. Бұл тәсіл әсіресе нақты деректермен жұмыс істегенде маңызды, себебі деректердің дәлдігі көптеген шарттарға байланысты өзгеруі мүмкін. Модель үш кіріс айнымалысын пайдаланады:

1. Z-score – стандартталған фактор мәні.
2. Корреляция – фактордың үдеріс индексіне әсер ету деңгейі.
3. Негізгі компонентке жүктеме – негізгі компоненттер талдауы (PCA)

нәтижесінде алынған фактордың үлесі.

Бұл айнымалылар бұлыңғыр ережелер арқылы өңделіп, әрбір фактордың үдеріске әсер ету дәрежесін анықтайды. Бұл тәсіл деректердегі белгісіздіктерді ескеруге және модельге икемділік беруге мүмкіндік береді. Кіріс айнымалыларының сипаттамасы:

- Z-score – деректерді стандарттау кезеңінде есептелген фактордың стандартталған мәні, яғни фактордың өз үдерісіндегі орташа мәннен ауытқуын көрсетеді.
- Корреляция – фактор мен үдеріс индексі арасындағы тәуелділік

деңгейін сипаттайды және фактордың өзгерісі индекс өзгерісіне қаншалықты әсер ететінін көрсетеді. Бұл көрсеткіш корреляциялық талдау кезінде есептелген.

- Негізгі компонентке жүктеме – фактордың негізгі компоненттерге үлесін көрсететін шама, ол PCA кезеңінде анықталады. Бұл фактордың деректер дисперсиясын түсіндірудегі маңыздылығын сипаттайды.

7-қадам. Бұлыңғыр логика ережелері кіріс айнымалыларының өзара әрекеттесуін анықтап, факторлардың үдерістерге әсерін есептеуге мүмкіндік береді. Әрбір фактор үшін Z-score, корреляция және негізгі компонентке жүктеме сипаттамалары алынғаннан кейін, олар бұлыңғыр жүйеге енгізіліп, әсерді бағалау жүзеге асырылады. Осы кезеңде кіріс айнымалыларын шығыс мәнімен байланыстыратын бұлыңғыр ережелер қалыптастырылады, яғни әрбір фактордың үдеріске әсерін бағалау жүзеге асырылады. Әрбір кіріс айнымалысы үшін мүшелік функциялар құрылады, олар айнымалының мәні белгілі бір категорияға қаншалықты сәйкес келетінін анықтайды. Мысалы, Z-score үшін келесі санаттар белгіленуі мүмкін: «күшті теріс», «орташа теріс», «нөлдік», «орташа оң» және «күшті оң». Ұқсас мүшелік функциялар корреляция және негізгі компонентке жүктеме айнымалылары үшін де жасалады, бұл мүмкін мәндердің кең диапазонын көрсетуге мүмкіндік береді.

8-қадам. Факторлардың әсерін бағалау және визуализациялау. Барлық қадамдар аяқталғаннан кейін әрбір фактордың үдерістерге әсері есептеледі. Бұл нәтижелер жылу карталары (heat maps) және диаграммалар көмегімен визуализацияланады, бұл әрбір үдеріске қандай факторлардың негізгі рөл атқаратынын бағалауға мүмкіндік береді. Бұлыңғыр модельдің нәтижелері факторларды олардың әртүрлі үдерістерге әсер ету деңгейі бойынша ранжирлеуге мүмкіндік береді. Гибридті талдау өңірдің әлеуметтік-экономикалық үдерістеріне факторлардың әсерін зерттеудің қуатты құралы болып табылады, өйткені ол әртүрлі факторлардың өңірлік динамикаға қалай әсер ететінін кешенді және көпжақты түсінуге мүмкіндік береді. Бұл әдіс бірнеше талдау әдістерін біріктіреді, соның ішінде негізгі компоненттер талдауы (PCA), корреляциялық талдау және бұлыңғыр логика моделін құру, бұл әртүрлі факторлар мен үдерістер арасындағы негізгі байланыстарды анықтауға көмектеседі.

Екіншіден, PCA және корреляциялық талдауды біріктіру факторлар мен үдерістер арасындағы байланыстарды тереңірек түсінуге мүмкіндік береді. Корреляциялық талдау әрбір фактор мен үдеріс арасындағы байланыстың күшін және бағытын сандық тұрғыда бағалауға мүмкіндік береді. Бұл тек факторлардың қандай үдерістермен ең тығыз байланыста екенін анықтауға ғана емес, сонымен қатар ықтимал себеп-салдарлық байланыстарды анықтауға да көмектеседі.

Үшінші маңызды компонент – бұлыңғыр логиканы пайдалану. Бұлыңғыр логиканың басты артықшылығы – ол белгісіздікті және факторлардың әртүрлі күйлері арасындағы бұлыңғыр шекараларды модельдеуге мүмкіндік береді.


Ұсынылған тәсілдің негізгі артықшылықтарының бірі – оның өңірлік деректерге қолданылу мүмкіндігі және нақты басқарушылық тұжырымдар алу қабілеті. Гибридті тәсіл тек факторлар арасындағы байланыстарды анықтауға ғана емес, сонымен қатар олардың өңірдегі үдерістерге салыстырмалы ықпалын бағалауға да мүмкіндік береді. Бұл жергілікті билік органдары мен басқарушыларға шешім қабылдау барысында қай факторларды ескеру қажеттігін және ресурстарды қандай бағыттарға жұмылдыру тиімді болатынын жақсырақ түсінуге көмектеседі.

Нәтижелер және оларды талқылау

Зерттеу үшін деректер Солтүстік Қазақстан облысының агроөнеркәсіптік кәсіпорындарынан жиналып, 2020 жылдан 2022 жылға дейінгі кезеңді қамтыды. Ол ауыл шаруашылығы өндірісінің негізгі аспектілерін қамтитын кең ауқымды ақпаратты біріктіреді. Деректердің негізгі санаттарына өндірістік сипаттамалар жатады, соның ішінде егістік жер көлемі, әртүрлі дақылдар егілген алқаптардың аумағы, тыңайтқыштардың көлемі, шаруашылықтардағы техника мен жұмысшылар саны. Бұл мәліметтер басқарушылық шешімдердің тиімділігін бағалау және ресурстарды пайдалану процесін оңтайландыру үшін негіз болып табылады. Өндірістік сипаттамалардан басқа, деректер жиынтығына экономикалық және логистикалық көрсеткіштер де енгізілген. Оларға отын және тасымалдау шығындары, тыңайтқыштарға кеткен шығындар және ең жақын сату нарықтарына дейінгі қашықтық кіреді. Логистика және экономикалық аспектілер ауыл шаруашылығы кәсіпорындарының жалпы табыстылығы мен тиімділігіне шығындар мен инфрақұрылымды басқарудың қалай әсер ететінін түсіну үшін маңызды. Сонымен қатар, ауа райы жағдайларын сипаттайтын көрсеткіштер де ескерілді: орташа температура мен жауын-шашын мөлшері, олар өнімділікті қалыптастыруда және ресурстарды пайдалану сценарийлерін анықтауда шешуші рөл атқарады. Деректерде мақсатты көрсеткіштер де қамтылған, соның ішінде нақты нарық сыйымдылығы, сценарийлік бағалау, өнімділік, шығындарды азайту, қуаттылықты пайдалану және таза пайда. Бұл көрсеткіштер бақыланатын және сыртқы факторлар арасындағы өзара байланысты талдауға, сондай-ақ өндірістік қызметтің түпкілікті нәтижелерін бағалауға мүмкіндік береді. Кең ауқымды және әртүрлі деректер жиынтығы терең талдау жүргізуге және болжамдық модельдер құруға сенімді негіз береді, бұл зерттеуді агроөнеркәсіптік сектордағы өзекті мәселелерді шешу үшін маңызды етеді.

Талдаудың бірінші кезеңінде белгілер мен мақсатты айнымалылар арасындағы сызықтық байланыстарды бағалау үшін корреляциялық матрица қолданылды. Әрбір белгі-нысанды айнымалы жұбы үшін Пирсон корреляция коэффициенті есептелді. Бұл тәсіл мақсатты көрсеткіштермен ең үлкен сызықтық байланысқа ие белгілерді анықтауға мүмкіндік береді. Корреляциялық талдау нәтижелері айнымалылар арасындағы байланыстарды түсіндіруді жеңілдететін жылу картасы (heatmap) түрінде визуализацияланды. Дегенмен, жоғары


корреляция әрдайым себеп-салдарлық байланысты білдірмейтінін ескеру қажет, сондықтан күрделірек әдістерді қолдану қажет. 1-суретте көрсетілген корреляциялық матрица зерттеуде қолданылған әртүрлі белгілер мен мақсатты айнымалылар арасындағы сызықтық тәуелділіктерді бейнелейді. Бұл бастапқы деректерді талдау үшін тиімді құрал болып табылады және мақсатты көрсеткіштерге ең үлкен әсер ететін белгілерді анықтауға мүмкіндік береді. Алайда, корреляциялық матрица тек сызықтық байланыстарды ғана бағалай алады және деректерде болуы мүмкін күрделі, бейсызық тәуелділіктерді анықтай алмайтынын ескеру маңызды.




Сур. 2. Демографиялық процеске әртүрлі факторлардың әсері

3-суретте 2023 жылғы Тараз қаласындағы экономикалық үдеріске әртүрлі факторлардың әсері көрсетілген. Экономикалық процестерге келесі факторлар күшті оң әсер етті: халық саны (әсер ету баллы: 3,28), орташа айлық жалақы (3,00), негізгі капиталға салынған инвестиция (3,31), мектептер саны (3,44) және бөлшек сауда көлемі (3,01). Бұл көрсеткіштер халықтың өсімі мен инвестиция деңгейі сияқты параметрлер аймақтағы тұрақты экономикалық өсудің кілті болып табылатынын көрсетеді.

4-суретте 2023 жылы Тараз қаласындағы әлеуметтік процестерге әртүрлі факторлардың әсері көрсетілген. Халық саны (әсер балы: 3,28), орташа айлық жалақы (3,00), негізгі капиталға салынған инвестиция (3,44), мектептер саны (3,44) және бөлшек сауда көлемі (3,01) сияқты факторлар күшті оң әсер етті. Бұл көрсеткіштер өңірдің әлеуметтік дамуында шешуші рөл атқаратын білімге қолжетімділік (мектептер саны) және экономикалық әл-ауқат (еңбекақы және инвестиция деңгейі) сияқты факторлардың маңыздылығын көрсетеді.



Сур. 3. Экономикалық процеске әртүрлі факторлардың әсері




Сур. 4. Әлеуметтік процестерге әртүрлі факторлардың әсері

5-суретте 2023 жылы Тараз қаласындағы бизнес және сауда процестеріне әртүрлі факторлардың әсері көрсетілген. Әрбір фактордың үлесі жолақтар түрінде көрсетілген, олардың биіктігі процеске әсер ету дәрежесін көрсетеді. Оң мәндер оң әсерді көрсетеді, ал теріс мәндер теріс әсерді көрсетеді. Диаграммаға сәйкес, бизнес пен саудамен ең күшті оң корреляция халық саны (ықпал балы: 3,28), орташа айлық жалақы (3,00), негізгі капиталға инвестиция (3,44), мектептер саны (3,44), бөлшек сауда көлемі (2,50) сияқты факторлармен көрсетілген. Бұл факторлар бизнес пен сауданың өсуінің негізгі драйверлері болып табылады.

Тараз қаласында үдерістерге әсер ететін факторларды талдаудың гибриді моделі халық саны, жалақы деңгейі, негізгі капиталға инвестициялар және білім беру инфрақұрылымының өңірлік негізгі үдерістерге елеулі әсерін көрсетті. Туу көрсеткіші, жұмыс күші және тау-кен өнеркәсібі сияқты теріс факторлар өңірлік әкімшіліктен ерекше назар аударуды қажет етеді. Талдау нәтижелері әлеуметтік-экономикалық инфрақұрылымды дамыту, сондай-ақ

инвестиция тарту және жұмыс күшінің дағдыларын жақсарту үшін жағдайлар жасау өңірдің әрі қарайғы дамуына үлес қосатынын көрсетуге мүмкіндік береді.

Бұл зерттеуде қолданылған гибриді талдау моделі бірнеше маңызды ерекшеліктерге ие, олар оны күрделі әлеуметтік-экономикалық жүйелерді зерттеуде тиімді құрал етеді. Соңында, тағы бір маңызды ерекшеліктерге ие,



Сур. 5. Әлеуметтік процестерге әртүрлі факторлардың әсері

олар оны күрделі әлеуметтік-экономикалық жүйелерді зерттеуде тиімді құрал етеді. Соңында, тағы бір маңызды ерекшелік – бұл модельді нақты уақыттағы талдауға қолдану мүмкіндігі. Барлық маңызды қадамдар – стандарттау, негізгі компоненттерді есептеу және бұлыңғыр тұжырым жасау – оңтайландырылған және сақталғандықтан, жүйе жаңа кіріс деректеріне оңай бейімделеді, тарихи деректерде қайта оқытуды қажет етпейді. Бұл модельдің ұзақ мерзімді икемділігі мен қолданылуын қамтамасыз етеді, себебі ол өзгеріп жатқан жағдайларға тез бейімделіп, бұрын анықталған паттерндерге негізделген дәл нәтижелер мен тиімді болжамдарды қамтамасыз ете алады.

Қорытынды

Жүргізілген зерттеу гибриді модельді қолданудың жоғары тиімділігін көрсетіп, әлеуметтік-экономикалық факторлардың өңірлік негізгі үдерістерге әсерін бағалауға мүмкіндік берді. Корреляциялық талдау, негізгі компоненттер талдауы (PCA) және бұлыңғыр логиканы біріктіретін гибриді тәсіл халық саны, жұмыспен қамту, инвестициялар және басқа да көрсеткіштер арасындағы күрделі байланыстарды терең және көпөлшемді бағалауға мүмкіндік берді. Нәтижесінде, өңірлік дамуға әсер ететін оң және теріс факторлар анықталды. Сандық нәтижелер халық санының экономикалық үдерістерге оң ықпалын көрсетіп, әсер ету коэффициенті 3.28 деп есептелді, ал негізгі капиталға салынған инвестициялардың әсер ету коэффициенті 3.44 болды. Орташа айлық жалақы да экономика мен әлеуметтік үдерістерге айтарлықтай оң ықпал етті

(коэффициент 3.00).

Сонымен қатар, туу көрсеткіші (-0.67) және жұмыс күші (-1.06) әлеуметтік үдерістерге теріс әсер ететін факторлар ретінде анықталды, бұл олардың толыққанды зерттеуді және тиісті реттеу шараларын қажет ететінін көрсетеді. Осылайша, гибриді талдау факторлардың өңірлік даму үдерістеріне әсерін бағалауға және стратегиялық шешімдер қабылдауға жарамды екенін дәлелдеді. Бұл модель басқа өңірлерге бейімделіп, сондай-ақ өзгерістерді болжау үшін пайдаланылуы мүмкін, бұл оны әлеуметтік-экономикалық талдау және жоспарлау үшін әмбебап құралға айналдырады.

ӘДЕБИЕТТЕР

Акинтуйи О.Б. (2024). Дәлме-дәл егіншілікте бейімделген жасанды интеллект: нақты уақыттағы деректер негізінде ферма операцияларын оңтайландыру үшін өзін-өзі үйрететін алгоритмдерді қолдануды зерттеу // *Research Journal of Multidisciplinary Studies*. — 2024. — Т. 7. — № 02. — Б. 016–030.

Барзани А.Р., Пахлавани П., Горбанзаде О., Голамни К., Гамиси П. (2024). Орман өрттері қаупі бар аймақтарды болжауда машиналық оқыту модельдеріндегі рекурсивті ерекшеліктерді жоюдың әсерін бағалау // *Fire*. — 2024. — Т. 7. — № 12. — Б. 440.

Виджаянти Э.Б., Сетиади Д.Р.И.М., Сетиоко Б.Х. (2024). Экстремалды градиенттік күшейту негізінде күріш өнімділігін болжауға арналған деректер жиынын талдау және ерекшеліктерін анықтау // *Journal of Computing Theories and Applications*. — 2024. — Т. 1. — № 3. — Б. 299–310.

Ингио Ж.А., Нсанг А.С., Иорлиам А. (2024). Күріш өнімділігін болжауды көптік сызықтық регрессия мен рекурсивті ерекшеліктерді жою арқылы оңтайландыру // *Journal of Future Artificial Intelligence and Technologies*. — 2024. — Т. 1. — № 2. — Б. 96–108.

Камарадж В.В., Маран П.С., Ранджана П. (2024). Топырақты жіктеу және өнімділікті арттыру үшін модификацияланған рекурсивті ерекшеліктерді жою (MRFE) әдісі // *AIP Conference Proceedings*. — 2024. — Т. 3075. — № 1.

Раман Р., Кантари Х., Гокхале А.А., Элангован К., Минакши Б., Шринивасан С. (2024). Машиналық оқыту алгоритмдерін пайдалана отырып ауылшаруашылық өнімділігін болжау // 2024 Халықаралық автоматтандыру және есептеу конференциясы (AUTOCOM), IEEE. — 2024. — Б. 187–191.

Редди Н., Манимегалай Т. (2024). Наивті Байес алгоритмімен салыстырмалы түрде градиенттік күшейту алгоритмін пайдаланып ауылшаруашылық өнімділігін болжау // *AIP Conference Proceedings*. — 2024. — Т. 2853. — № 1.

Сюн Л., Ан Ж., Хоу Ю., Ху Ц., Ван Х., Чен Ю., Тан Ш. (2024). Өзара байланысты газ сенсоры деректерін өңдеуге арналған топшілік репрезентативті ерекшеліктерді таңдау негізінде жақсартылған SVR рекурсивті ерекшеліктерді жою (IRFS-SVR-RFE) // *Sensors and Actuators B: Chemical*. — 2024. — Т. 419. — Б. 136395.

Тусупов Ж., Есенова М., Абдикеримова Г., Аимбетов А., Бактыбеков Қ., Мурзабекова Г., Айтимова У. (2024). Машиналық оқыту әдістерін қолдану арқылы ауылшаруашылық дақылдарының аурулары мен зиянкестерін анықтауда формалды концептілерді талдау // *IEEE Access*. — 2024.

Фалойе О.Т., Аджайи А.Э., Камчум В., Акинтола О.А., Огунтунде П.Г. (2024). Био көмір және минералды тыңайтқыштардың топырақ сапасы мен жүгері өнімділігіне әсерін негізгі компоненттік талдау арқылы бағалау // *Agronomy*. — 2024. — Т. 14. — № 8. — Б. 1761.

Хаммуни Д. және т.б. басқалар (2024). Судың сапасын маусымдық өзгерістер мен негізгі компоненттік талдау (PCA) және су сапасының индексі (WQI) арқылы бағалау: практикалық мысал // *Sustainability*. — 2024. — Т. 16, № 13. — Б. 5644.

Хуо Д., Малик А.У., Равана С.Д., Рахман А.У., Ахмеди И. (2024). Смарт фермерлік картасы: деректерге негізделген дәуірдегі ауылшаруашылық мәселелерін шешу // *Renewable and Sustainable Energy Reviews*. — 2024. — Т. 189. — Б. 113858.

Чжао Ш., Чжан М., Сяо З., Кан Б. (2024). Шамаланған дәлелді өзара ақпаратты пайдаланып деректердің сенімділігі мен салыстырмалы салмағын бағалау // *Engineering Applications of Artificial Intelligence*. — 2024. — Т. 133. — Б. 108409.

Эль-Кенави Э.С.М., Альхуссан А.А., Ходадади Н., Миржалили С., Эйд М.М. (2024). Тұрақты ауыл шаруашылығы үшін машиналық және терең оқыту арқылы картоп өнімділігін болжау // *Potato Research*. — 2024. — Б. 1–34.

Ян Ю., Чжоу Ш., Сюй Ц., Ван Х., Лю Л., Цао В. (2024). Су-энергетикалық байланыстың тұрақтылығын талдау үшін экологиялық желілерге өзара ақпаратты біріктіру: Янцзы өзенінің экономикалық белдеуі мысалында // *Journal of Cleaner Production*. — 2024. — Т. 448. — Б. 141705.

REFERENCES

- Akintuyi O.B. (2024). Adaptive AI in precision agriculture: a review: investigating the use of self-learning algorithms in optimizing farm operations based on real-time data // *Research Journal of Multidisciplinary Studies*. — 2024. — Vol. 7. — No. 02. — Pp. 016–030. (in Eng.)
- Barzani A.R., Pahlavani P., Ghorbanzadeh O., Gholamnia K., Ghamisi P. (2024). Evaluating the Impact of Recursive Feature Elimination on Machine Learning Models for Predicting Forest Fire-Prone Zones // *Fire*. — 2024. — Vol. 7. — No. 12. — P. 440. (in Eng.)
- El-Kenawy E.S.M., Alhussan A.A., Khodadadi N., Mirjalili S., Eid M.M. (2024). Predicting potato crop yield with machine learning and deep learning for sustainable agriculture // *Potato Research*. — 2024. — Pp. 1–34. (in Eng.)
- Faloye O.T., Ajayi A.E., Kamchoom V., Akintola O.A., Oguntunde P.G. (2024). Evaluating impacts of biochar and inorganic fertilizer applications on soil quality and maize yield using principal component analysis // *Agronomy*. — 2024. — Vol. 14. — No. 8. — P. 1761. (in Eng.)
- Hammoumi D. et al. (2024). Seasonal variations and assessment of surface water quality using water quality index (WQI) and principal component analysis (PCA): a case study // *Sustainability*. — 2024. — Vol. 16. — No. 13. — P. 5644. (in Eng.)
- Huo D., Malik A.W., Ravana S.D., Rahman A.U., Ahmedy I. (2024). Mapping smart farming: Addressing agricultural challenges in data-driven era // *Renewable and Sustainable Energy Reviews*. — 2024. — Vol. 189. — P. 113858. (in Eng.)
- Ingio J.A., Nsang A.S., Iorliam A. (2024). Optimizing Rice Production Forecasting Through Integrating Multiple Linear Regression with Recursive Feature Elimination // *Journal of Future Artificial Intelligence and Technologies*. — 2024. — Vol. 1, No. 2. — Pp. 96–108. (in Eng.)
- Kamaraj V.V., Maran P.S., Ranjana P. (2024). Modified recursive feature elimination (MRFE) technique for soil classification and better crop production // *AIP Conference Proceedings*. — 2024. — Vol. 3075. — No. 1. (in Eng.)
- Raman R., Kantari H., Gokhale A.A., Elangovan K., Meenakshi B., Srinivasan S. (2024). Agriculture Yield Estimation Using Machine Learning Algorithms // *2024 International Conference on Automation and Computation (AUTOCOM)*, IEEE. — 2024. — Pp. 187–191. (in Eng.)
- Reddy N., Manimegalai T. (2024). Predicting the crop yield in agriculture using gradient boosting algorithm in comparison of naive bayes algorithm // *AIP Conference Proceedings*. — 2024. — Vol. 2853. — No. 1. (in Eng.)
- Tussupov J., Yessenova M., Abdikerimova G., Aimbetov A., Baktybekov K., Murzabekova G., Aitimova U. (2024). Analysis of formal concepts for verification of pests and diseases of crops using machine learning methods // *IEEE Access*. — 2024. (in Eng.)
- Wijayanti E.B., Setiadi D.R.I.M., Setyoko B.H. (2024). Dataset Analysis and Feature Characteristics to Predict Rice Production based on eXtreme Gradient Boosting // *Journal of Computing Theories and Applications*. — 2024. — Vol. 1, No. 3. — Pp. 299–310. (in Eng.)
- Xiong L., An J., Hou Y., Hu C., Wang H., Chen Y., Tang X. (2024). Improved support vector regression recursive feature elimination based on intragroup representative feature sampling (IRFS-SVR-RFE) for processing correlated gas sensor data // *Sensors and Actuators B: Chemical*. — 2024. — Vol. 419. — P. 136395. (in Eng.)
- Yang Y., Zhou X., Xu J., Wang H., Liu L., Cao W. (2024). Coupling mutual information into ecological networks to analyze the sustainability of water-energy nexus: A case study of Yangtze River Economic Belt // *Journal of Cleaner Production*. — 2024. — Vol. 448. — P. 141705. (in Eng.)
- Zhao X., Zhang M., Xiao Z., Kang B. (2024). Evaluating the reliability and relative weight of the evidence using approximate evidential mutual information // *Engineering Applications of Artificial Intelligence*. — 2024. — Vol. 133. — P. 108409. (in Eng.)

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 1. Number 22 (2025). Pp. 23–36

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.002>

УДК 004.931

INTELLIGENT CLUSTERING METHODS FOR PROCESSING AND ANALYZING SHORT TEXTS

*A. Bayegizova¹, G. Murzabekova² *, A. Alimagambetova¹, G. Mukhamedrakhimova¹, M. Kassim³*

¹L.N. Gumilyov Eurasian National University, Astana, Kazakhstan;

²S. Seifullin Kazakh Agrotechnical Research University, Astana, Kazakhstan;

³MARA University of Technology, Malaysia.

E-mail: murzabekova.gulden@mail.ru

Bayegizova A. — senior lecturer, «The Department of Radio Engineering», Electronics and Telecommunications, Eurasian National University named after L.N. Gumilyov, Astana, Kazakhstan

E-mail: baegiz_a@mail.ru, <https://orcid.org/0000-0003-2293-2143>;

Murzabekova G. — associate professor, «The Department of Computer Science», Candidate of Physical and Mathematical Sciences, Kazakh Agrotechnical Research University named after S. Seifullin, Astana, Kazakhstan

E-mail: murzabekova.gulden@mail.ru, <https://orcid.org/0000-0001-9807-5200>;

Alimagambetova A. — senior lecturer, «The Department of Information Systems», Candidate of Physical and Mathematical Sciences, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan

E-mail: ainash_777@mail.ru, <https://orcid.org/0000-0002-9859-2029>;

Mukhamedrakhimova G. — senior lecturer, «The Department of Radio Engineering», Electronics and Telecommunications, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan

E-mail: isatai-07@mail.ru, <https://orcid.org/0000-0002-9951-6263>;

Murizah K. — PhD, associate professor, MARA University of Technology, Malaysia

E-mail: Kassim@gmail.com, <https://orcid.org/0000-0002-8494-4783>.

© A. Bayegizova, G. Murzabekova, A. Alimagambetova, G. Mukhamedrakhimova, M. Kassim, 2025

Abstract. This study presents an in-depth analysis of short text clustering using advanced methods: Bidirectional Encoder Representations from Transformers (BERT), Term Frequency-Inverse Document Frequency (TF-IDF), and the innovative hybrid method Latent Dirichlet Allocation+BERT+Autoencoder (LDA+BERT+AE). The experimental section compares the effectiveness of these methods for short text clustering, with particular attention paid to the hybrid approach LDA+BERT+AE. During training and validation of the LDA-BERT model for 200 epochs, the loss values are initially higher than 1.2, rapidly decrease during the first 25 epochs, reach about 0.8, and finally stabilize at about 0.4. The research results show that the hybrid method LDA+BERT+AE significantly improves the clustering quality compared to the methods used individually. Based on the results obtained, recommendations are



given on the selection and combination of optimal methods for various types of short text clustering and natural language processing (NLP) tasks. The study highlights the importance of a comprehensive analysis method for short texts, its necessity for increasing deep semantic understanding and better information retrieval.

Key words: clustering methods, semantic extraction, categorization of text data, hybrid method, NLP systems

For citation: A. Bayegizova, G. Murzabekova, A. Alimagambetova, G. Mukhamedрахимова, M. Kassim. Intelligent clustering methods for processing and analyzing short texts//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 23-36. (in Kaz). <https://doi.org/10.54309/IJICT.2025.22.2.002>.

Conflict of interest: The authors declare that there is no conflict of interest.

ИНТЕЛЛЕКТУАЛДЫ КЛАСТЕРЛЕУ ӘДІСТЕРІН ҚОЛДАНА ОТЫРЫП, ҚЫСҚА МӘТІНДЕРДІ ТАЛДАУ

А.С. Баегизова¹, Г.Е. Мырзабекова^{2}, А.З. Алимагамбетова¹,
Г.И. Мухамедрахимова¹, М. Кассим³*

¹Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан;

²С.Сейфуллин атындағы Қазақ агротехникалық зерттеу университеті, Астана, Қазақстан;

³MARA технологиялар университеті, Малайзия.

E-mail: murzabekova.gulden@mail.ru

Баегизова А. — Л.Н. Гумилев атындағы Еуразия ұлттық университетінің Радиотехника, «Электроника және телекоммуникация» кафедрасының аға оқытушысы, Астана, Қазақстан
E-mail: baegiz_a@mail.ru, <https://orcid.org/0000-0003-2293-2143>;

Мырзабекова Г. — С.Сейфуллин атындағы Қазақ агротехникалық зерттеу университеті, «Компьютерлік ғылымдар» кафедрасының доценті, физика-математика ғылымдарының кандидаты, Астана, Қазақстан
E-mail: murzabekova.gulden@mail.ru, <https://orcid.org/0000-0001-9807-5200>;

Алимагамбетова А. — Л.Н. Гумилев атындағы Еуразия ұлттық университеті, «Ақпараттық жүйелер» кафедрасының аға оқытушысы, ф.-м.ғ.к., Астана, Қазақстан
E-mail: ainash_777@mail.ru, <https://orcid.org/0000-0002-9859-2029>;

Мухамедрахимова Г. — .Н. Гумилев атындағы Еуразия ұлттық университетінің Радиотехника, «Электроника және телекоммуникация» кафедрасының аға оқытушысы, Астана, Қазақстан
E-mail: isatai-07@mail.ru, <https://orcid.org/0000-0002-9951-6263>;

Муризах К. — PhD, қауымдастырылған профессор, MARA технологиялар университеті, Малайзия
E-mail: Kassim@gmail.com, <https://orcid.org/0000-0002-8494-4783>.

© А.С. Баегизова, Г.Е. Мырзабекова А.З. Алимагамбетова, Г.И. Мухамедрахимова, М. Кассим, 2025

Аннотация. Бұл зерттеу қысқа мәтіндерді кластерлеудің терең талдауын ұсынады, ол озық әдістерді қолдану арқылы жүзеге асырылады: Bidirectional Encoder Representations from Transformers (BERT), Term Frequency-Inverse Document Frequency (TF-IDF) және инновациялық гибридті әдіс Latent Dirichlet

Allocation+BERT+Autoencoder (LDA+BERT+AE). Эксперименттік бөлімде осы әдістердің қысқа мәтіндерді кластерлеу тиімділігі салыстырылады, әсіресе LDA+BERT+AE гибриді тәсіліне ерекше назар аударылады. LDA-BERT моделін 200 эпох бойы оқыту және тексеру барысында жоғалту функциясының мәндері (loss values) бастапқыда 1.2-ден жоғары болып, алғашқы 25 эпох ішінде тез төмендеп, шамамен 0.8 деңгейіне жетеді және ақырында 0.4 шамасында тұрақталады. Зерттеу нәтижелері LDA+BERT+AE гибриді әдісі жеке қолданылған әдістерге қарағанда кластерлеу сапасын едәуір жақсартатынын көрсетеді. Алынған нәтижелер негізінде қысқа мәтіндерді кластерлеудің әртүрлі түрлері мен табиғи тілдік өңдеу (NLP) тапсырмалары үшін оңтайлы әдістерді таңдау және үйлестіру бойынша ұсыныстар беріледі. Зерттеу қысқа мәтіндерді кешенді талдау әдісінің маңыздылығын, оның терең семантикалық түсінуді арттыру және ақпаратты жақсырақ алу үшін қажеттілігін ерекше атап көрсетеді.

Түйін сөздер: Кластерлеу әдістері, семантикалық шығару, мәтіндік деректерді санаттау, гибриді әдіс, NLP жүйелері

Дәйексөздер үшін: А.С. Баегизова, Г.Е. Мырзабекова А.З. Алимагамбетова, Г.И. Мухамедрахимова, М. Кассим. Интеллектуалды кластерлеу әдістерін қолдана отырып, қысқа мәтіндерді талдау//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 23–36 бет. (қазақ тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.002>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

АНАЛИЗ КОРОТКИХ ТЕКСТОВ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИНТЕЛЛЕКТУАЛЬНОЙ КЛАСТЕРИЗАЦИИ

А.С. Баегизова¹, Г.Е. Мырзабекова^{2,}, А.З. Алимагамбетова¹,
Г.И. Мухамедрахимова¹, М. Кассим³*

¹Евразийский национальный университет имени Л. Н. Гумилёва, Астана, Казахстан;

²Казахский агротехнический исследовательский университет имени С. Сейфуллина, Астана, Казахстан;

³Технологический университет МАРА, Малайзия.

E-mail: murzabekova.gulden@mail.ru

Баегизова А. — старший преподаватель, «Кафедра радиотехники, электроники и телекоммуникаций», Евразийский национальный университет имени Л.Н. Гумилёва, Астана, Казахстан
E-mail: baegiz_a@mail.ru, <https://orcid.org/0000-0003-2293-2143>;

Мырзабекова Г. — кандидат физико-математических наук, доцент, «Кафедра компьютерных наук», Казахский агротехнический исследовательский университет имени С. Сейфуллина, Астана, Казахстан
E-mail: murzabekova.gulden@mail.ru, <https://orcid.org/0000-0001-9807-5200>;

Алимагамбетова А. — кандидат физико-математических наук, старший преподаватель, «Кафедра информационных систем», Евразийский национальный университет имени Л.Н. Гумилёва, Астана, Казахстан
E-mail: ainash_777@mail.ru, <https://orcid.org/0000-0002-9859-2029>;

Мухамедрахимова Г. — старший преподаватель, «Кафедра радиотехники, электроники и телекоммуникаций», Евразийский национальный университет имени Л.Н. Гумилёва, Астана, Казахстан

E-mail: isatai-07@mail.ru, <https://orcid.org/0000-0002-9951-6263>;

Муризах К. — доктор философии, доцент, Технологический университет MAPA, Малайзия

E-mail: Kassim@gmail.com, <https://orcid.org/0000-0002-8494-4783>.

© А.С. Баегизова, Г.Е. Мырзабекова А.З. Алимагамбетова, Г.И. Мухамедрахимова, М. Кассим, 2025

Аннотация. В статье представлен углубленный анализ кластеризации коротких текстов с использованием передовых методов: двунаправленные представления кодировщика из преобразователей (BERT), частота терминов-обратная частота документа (TF-IDF) и инновационный гибридный метод Latent Dirichlet Allocation+BERT+Autoencoder(LDA+BERT+AE). В экспериментальном разделе сравнивается эффективность этих методов для кластеризации коротких текстов, при этом особое внимание уделяется гибриднему подходу LDA+BERT+AE. Во время обучения и проверки модели LDA-BERT для 200 эпох значения потерь изначально превышают 1,2, быстро уменьшаются в течение первых 25 эпох, достигают около 0,8 и, наконец, стабилизируются на уровне около 0,4. Результаты исследования показывают, что гибридный метод LDA+BERT+AE значительно улучшает качество кластеризации по сравнению с методами, используемыми по отдельности. На основе полученных результатов даны рекомендации по выбору и комбинированию оптимальных методов для различных типов задач кластеризации коротких текстов и обработки естественного языка (NLP). В исследовании подчеркивается важность метода комплексного анализа для коротких текстов, его необходимость для повышения глубины семантического понимания и лучшего извлечения информации.

Ключевые слова: методы кластеризации, семантическое извлечение, категоризация текстовых данных, гибридный метод, системы NLP

Для цитирования: А.С. Баегизова, Г.Е. Мырзабекова А.З. Алимагамбетова, Г.И. Мухамедрахимова, М. Кассим. Анализ коротких текстов с использованием методов интеллектуальной кластеризации//Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 23–36. (На каз.). <https://doi.org/10.54309/IJICT.2025.22.2.002>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Кіріспе

Мәтіндік деректерді практикалық түсіну және санаттау (Manias et al., 2023) әлеуметтік медиа талдауы (Fu et al., 2023), ұсыныс жүйелері және автоматтандырылған контент модерациясы (Edara et al., 2023) сияқты көптеген қолданбалар үшін маңызды. Соңғы онжылдықта шектеулі және сығылған ақпаратпен сипатталатын қысқа мәтіндерді өңдеу мен мағынаны шығару әдістерін дамытуға айтарлықтай күш салынды. Бұл саладағы ең қуатты әдістердің қатарына BERT, TF+IDF және біріктірілген LDA+BERT+AE әдісі

жатады. BERT (Bidirectional Encoder Representations from Transformers) – бұл мәтіндегі контекстік байланыстарды жақсырақ түсінуге мүмкіндік беретін терең оқытудағы инновациялық әдіс. TF+IDF, классикалық статистикалық тәсіл ретінде, құжаттағы сөздердің маңыздылығын бағалау үшін қолданылады, бұл оны ақпаратты сүзу және негізгі тақырыптарды анықтау үшін таптырмас құрал етеді. LDA+BERT+AE әдісі мәтіндік түсінікті терең және кеңінен синтездеуге мүмкіндік береді: LDA (Latent Dirichlet Allocation) тақырыптық модельдеу үшін, BERT контекстік талдау үшін, ал AE (Autoencoder) өлшемділікті азайту және деректерді оңтайландыру үшін пайдаланылады.


Қысқа мәтіндерді интеллектуалды кластерлеу әдістерін қолдана отырып талдаудың маңыздылығы (Balaji et al., 2021) қазіргі цифрлық коммуникацияларға тән үлкен көлемдегі қысқа мәтіндік ақпаратты тиімді өңдеу және түсіндіру қажеттілігінің артуынан туындайды. Әлеуметтік желілердің, онлайн платформалардың және мобильді қосымшалардың өсуімен қатар твиттер, жазбалар және пікірлер сияқты қысқа мәтіндердің саны да артып келеді, бұл табиғи тілді өңдеу жүйелерінің талдау дәлдігі мен жылдамдығын жақсарту қажеттілігін тудырады. Мұндай мәтіндер көбінесе қоғамдық пікір, пайдаланушы қалаулары және ағымдағы трендтер туралы маңызды ақпаратты қамтиды, сондықтан оларды зерттеу маркетинг, брендті басқару, саяси талдау және басқа да көптеген салалар үшін құнды болып табылады. Осылайша, BERT, TF+IDF және LDA+BERT+AE сияқты әдістерді дамыту және оңтайландыру қысқа мәтіндерді дәл және тиімді өңдеу үшін жасанды интеллект және NLP салаларында маңызды рөл атқарады (Abbas et al., 2022; McKittrick et al., 2023). Бұл жұмыстың мақсаты – интеллектуалды кластерлеу әдістерін қолдану арқылы мәтіндік деректерді кластерлеу сапасын арттыру және процесті жылдамдату, осылайша пайдалы ақпаратты дәлірек және тиімдірек шығару. Ерекше назар бұл әдістердің бейімделгіштігі мен әртүрлі қолдану жағдайларындағы қолданылуына аударылады, өйткені дәстүрлі тәсілдер кейде деректер көлемінің шектеулігі немесе әртүрлілігі салдарынан қиындықтарға тап болуы мүмкін.

Бұл зерттеудің нәтижелері қысқа мәтіндерді талдау саласында айтарлықтай жетілдірулер ұсынады, мәтін мазмұнын тереңірек және дәлірек түсінуге мүмкіндік береді және тиімдірек NLP жүйелерін жасауға ықпал етеді. Цифрлық дәуірде деректер көлемінің қарқынды өсуі жағдайында бұл тақырыптың маңыздылығы арта түседі. Твиттер жазбалары, пайдаланушы пікірлері және әлеуметтік желілердегі комментарийлер сияқты қысқа мәтіндер ақпараттың маңызды бөлігін құрайды. Дәстүрлі талдау әдістері (Becken et al., 2021; Chakraborty et al., 2020) мұндай форматтармен жұмыс істеуде көбінесе тиімсіз, өйткені олар аз сөзбен жоғары мағына концентрациясын қамтиды. Бұл зерттеушілерге қолайлы деректерді өңдеу құралдарын таңдауда және оларды қысқа мәтін форматтарының ерекше талаптарына бейімдеуде қиындықтар тудырады. Кластерлеу сапасы мен дәлдігіне контекстік талдаудың әсері де зерттеледі. BERT (Horta et al., 2023; He et al., 2021) сияқты заманауи

технологиялар тілді түсінуге төңкеріс жасайтын тәсілді ұсынады, бұл жүйелерге табиғи тілдің көп мағыналылығы мен күрделілігін жақсы өңдеуге мүмкіндік береді. BERT-ті LDA және AE (Fasel et al., 2024; Saranya et al., 2023) әдістерімен біріктіру талдау дәлдігін арттыру үшін мәтін құрылымдары мен семантикасын тереңірек түсінуге жол ашады. Бұл жұмыс осындай біріктірілген тәсілдердің қысқа мәтіндерді кластерлеу және жіктеу процестерін жетілдіру үшін қалай қолданылатынын көрсетуге бағытталған, олардың бірегей сипаттамалары мен қажеттіліктерін ескере отырып. Осылайша, зерттеу қысқа мәтіндерді талдау мәселесіне кешенді көзқарас ұсынып, деректерді талдау негізінде кластерлеу технологияларын дамытудың перспективалық бағыттарын зерттейді. Алынған нәтижелер табиғи тілді өңдеу (NLP) саласына (Hupkes et al., 2023; Chung et al., 2023) маңызды үлес қосатынын көрсетеді және қазіргі ақпараттық әлемдегі кең ауқымды тапсырмаларды орындауға қабілетті тиімді және бейімделгіш NLP жүйелерін құруда қолданылуы мүмкін (Xin et al., 2023; Işıkdemir et al., 2024) .


Әдістер мен материалдар

Бұл жұмыс мәтіндік деректерді талдау және кластерлеудің толық процесін қарастырады, ол екі озық табиғи тілді өңдеу (NLP) технологиясын біріктіреді: LDA (Жасырын Дирихле бөлуі) және BERT (Трансформерлерден алынған екі бағытты кодтау). Бұл «тәуелді ендіру» (dependent embedding) деп аталатын гибридті әдіс, әр әдісті жеке қолданған кезде туындайтын шектеулерді еңсеруге бағытталған. Осы әдістерден бөлек, зерттеу мәтіндегі сөздердің маңыздылығын бағалауды жақсарту үшін TF+IDF әдісін де пайдаланады. LDA әдісі (1-сурет) – тақырыптық модельдеуге арналған статистикалық тәсіл ретінде үлкен мәтіндік массивтердегі ортақ тақырыптарды анықтауға мүмкіндік береді. Алайда, LDA-ның басты кемшілігі – ол сөздердің ретін және мағынасын ескермейді, бұл мағынасы маңызды болатын мәтіндерді талдау кезінде оның қолдану аясын едәуір шектеуі мүмкін.



Сур. 1. LDA әдісінің архитектурасы


Осы шектеуді еңсеру үшін BERT моделі енгізіледі – трансформер архитектурасына негізделген терең оқыту моделі, ол сөйлемдегі әрбір сөзді басқа барлық сөздермен байланыстыра отырып талдай алады, осылайша тілдің контекстік ерекшеліктерін түсінуге мүмкіндік береді. Талдау деректерді алдын ала өңдеуден басталады, оған мәтіндердегі артық шуды жою (арнайы таңбалар мен стоп-сөздерді алып тастау), сөздерді токенизациялау және лемматизациялау жатады. Осыдан кейін LDA әдісі мәтіндер жинағындағы кең ауқымды тақырыптық кластерлерді анықтау үшін қолданылады, бұл мәтіндер арасындағы ортақ тақырыптарды табуға көмектеседі. Кейін BERT моделі әрбір сөздің векторлық көрінісін жасау үшін қолданылады, бұл мәтіндердегі семантикалық байланыстар мен мағыналық ерекшеліктерді тереңірек түсінуге мүмкіндік береді (2-сурет).



Сур. 2. BERT әдісінің архитектурасы

Бұл зерттеуде TF+IDF (Term Frequency-Inverse Document Frequency) әдісі талдау мен кластерлеу сапасын одан әрі жақсарту үшін қолданылады. Бұл әдіс сөздің маңыздылығын бағалау үшін оның белгілі бір құжатта кездесу жиілігін барлық құжаттардағы жалпы жиілігімен салыстырады. Мұндай терминдерді өлшеу тәсілі нақты мәтіндер үшін ең маңызды кілт сөздерді анықтауға мүмкіндік береді. Нәтижесінде, бұл әдіс мәтіндерді кластерлеудің келесі кезеңдеріне неғұрлым нақты және мазмұнды көрінісін қамтамасыз етеді (3-сурет).

Кластерлеу сапасын бағалау үшін қолданылатын көрсеткіштерге мыналар кіреді: силуэт — кластерлеу кезінде нысандардың бір-бірінен қалай бөлінгенін көрсетеді (неғұрлым жоғары болса, соғұрлым жақсы); calinski_harabasz индексі — кластер ішілік және кластер аралық вариацияны бағалайды (неғұрлым жоғары болса, соғұрлым жақсы); davies_bouldin — кластерлік «ұқсастық» орташа көрсеткіші (төменірек, соғұрлым жақсы); реттелген_ранды (ARI) — болжамды кластерлерді негізгі шындық белгілерімен салыстырады (неғұрлым жоғары болса, соғұрлым жақсы); гомогенділік — әрбір кластер тек бір нақты санаттағы объектілерді қаншалықты жақсы қамтитынын көрсетеді; толықтық — бір санаттағы объектілердің бір кластерге қаншалықты сәйкес келетінін көрсетеді; v_measure — біртектілік пен толықтық арасындағы гармоникалық орта (неғұрлым жоғары болса, соғұрлым жақсы).



Сур. 3. $TF+IDF$ әдісінің архитектурасы

Нәтижелер және оларды талқылау


Біздің зерттеуімізде қолданылған оқыту деректер жинағы Kaggle платформасында ұсынылған және 2225 жазбадан тұрады, олар бес санатқа бөлінген: спорт, технология, бизнес, ойын-сауық және саясат. Жаңалықтар мақалаларынан алынған деректер теңгерімді және әртүрлі жиынтықты білдіреді, бұл оны әртүрлі кластерлеу әдістерін зерттеу және салыстыру үшін тамаша негізге айналдырады. Мәліметтер жинағының құрылымы машиналық оқыту және мәтіндік деректерді түсіну мен алдын ала белгіленген санаттарға жіктеуге бағытталған жобалар үшін қолайлы болып табылады. Бұл деректер жинағы екі негізгі бағанға бөлінген: «Category» (Санат) бағаны әрбір мақаланы жоғарыда аталған санаттардың біріне жатқызады, мұнда «спорт» санаты ең жиі кездеседі. «Text» (Мәтін) бағаны жаңалық мақаласының толық мәтінін қамтиды. Мақалалардың мәтіндері ұзындығы мен мазмұны бойынша әртүрлі, олардың әрқайсысына бірегейлік беретін санат ішіндегі әртүрлі тақырыптарды қамтиды. Алайда, бірдей мәтіні бар қайталанатын деректер де кездеседі. Бұл деректер жинағы мәтінді жіктеу модельдерін әзірлеу және тестілеу үшін құнды мүмкіндіктер ұсынады, алгоритмдерге мәтін мазмұнына негізделген санаттарды анықтауды үйренуге мүмкіндік береді. Атап айтқанда, бұл табиғи тілді өңдеу (NLP) саласындағы қолданбалар үшін өзекті болып табылады, мысалы: тақырыптық модельдеу, кілт сөздерді талдау, жаңалық мақалаларын веб-сайттың тиісті бөлімдеріне автоматты түрде сұрыптау жүйелерін әзірлеу. Деректер жинағының құрылымы мен мазмұны әртүрлі жаңалық мақалаларында қолданылатын тілдік ерекшеліктерді зерттеуге, сондай-ақ мәтіндік деректерді жіктеу мен талдаудың тиімді әдістерін әзірлеуге бағытталған ғылыми жобалар

үшін оңтайлы негіз бола алады.

Бірінші кезекте, әртүрлі векторизация әдістерінің (TF-IDF, BERT, LDA_BERT) Uniform Manifold Approximation and Projection (UMAP) әдісі арқылы құжаттарды кластерлеуге қалай әсер ететінін көрсетеміз. UMAP әдісі мәтіндік деректерді екі өлшемді кеңістікке түрлендіру үшін қолданылды, мұнда белгілер TF-IDF, BERT немесе гибриді LDA+BERT+AE әдістерімен алдын ала алынды. UMAP өлшемділікті бейсызықты қысқартуды жүзеге асырады және деректердің топологиялық құрылымын сақтауға мүмкіндік береді. UMAP әдісінің дәлдігі тікелей реттеу параметрлеріне ($n_neighbors$, min_dist және т.б.) және деректердің күрделілігіне байланысты. Бұл жағдайда UMAP әдісін қолданудың негізгі мақсаты – кластерлеу нәтижелерін визуализациялау, ал жіктеу дәлдігін бағалау емес. Екі өлшемді кеңістікте әрбір құжат нүкте ретінде бейнеленеді, ал оның түсі тиісті кластерді (K-Means әдісі арқылы алынған) білдіреді. Бұл визуализациялар объектілердің белгілі бір векторизация әдісі бойынша (TF-IDF, таза BERT эмбедингтері немесе LDA мен BERT-тің гибриді үйлесімі) қаншалықты топтасатынын немесе араласып кететінін көрсетеді.

Алайда, тек LDA мен BERT-ті біріктіру векторлық кеңістіктің ең оңтайлы құрылымын қамтамасыз етпеуі мүмкін. Осы мәселені шешу үшін автоэнкодер (AE) енгізілді – бұл өзіндік оқытылатын нейрондық желі, ол LDA+BERT үйлесімінің векторын неғұрлым ықшам латенттік көрініске қысу (кодтау) және оны қайтадан бастапқы түрге шығару (декодтау) арқылы деректерді оңтайландырады. Бұл тәсіл артық ақпаратты жою және ең маңызды вариациялық факторларды анықтау үшін қолданылады. Түрлендірілген құжаттарды кластерлеу үшін кластерлер саны k болатын K-Means алгоритмі қолданылады. K-Means алгоритмі кластерлердің орталықтары мен нүктелер арасындағы квадраттық қашықтықтардың қосындысын минимизациялау арқылы итеративті түрде жұмыс істейді, осылайша векторлық кеңістікте ұқсас құжаттардан құралған топтарды қалыптастырады. K-Means әдісі оның қарапайымдылығымен, кең таралғандығымен және әртүрлі векторизация әдістерінің тиімділігін бастапқы бағалау үшін жеткілікті болуымен таңдалды (TF-IDF, BERT, LDA_BERT).

4-суретте екі қуатты мәтінді талдау әдісін – LDA (Latent Dirichlet Allocation) және BERT (Bidirectional Encoder Representations from Transformers) біріктіретін «контекст-тақырыптық бекіту» деп аталатын синтезделген тәсілді қолдану арқылы жүзеге асырылған кластерлеу нәтижелері көрсетілген. Бұл гибриді әдістің басты мақсаты – әр әдісті жеке қолданудың негізгі шектеулерін еңсеру, яғни LDA-ның статистикалық тақырыптық модельдеуі мен BERT-тің терең контекстік тілдік түсінігін біріктіру. Мұндай интеграция мәтіндік деректердің семантикалық және контекстік аспектілерін тереңірек зерттеуге мүмкіндік береді, бұл өз кезегінде мазмұнды дәлірек түсінуді қамтамасыз етеді. Бұл кластерлеу мен кейінгі талдаудың тиімділігін арттыру үшін шешуші рөл атқарады.




Сур. 4. LDA+BERT+AE әдісі арқылы кластерлеу нәтижесі

5-суретте LDA+BERT+AE гибриді моделінің 200 эпох бойы оқытылу процесі көрсетілген. Оқыту барысында модельдің шығын функциясы (loss) айтарлықтай төмендейді, бұл оның тиімді түрде үйрену және бейімделу қабілетін көрсетеді. Абсцисса осінде оқыту эпохтарының саны, ал ордината осінде шығын функциясының мәндері бейнеленген. Оқытудың бастапқы кезеңінде нөлінші эпохада оқыту және тексеру жиынтықтарындағы шығын мәндері шамамен 1.25 деңгейінде. Бұл оқытудың бастапқы кезеңдеріне тән қалыпты көрсеткіш, өйткені модель әлі оңтайландырылмаған және оның параметрлері жаңадан реттелуде. Алайда, алғашқы 25 эпох ішінде модель айтарлықтай жылдам төмендеу динамикасын көрсетіп, шамамен 0.9 мәніне жетеді. Бұл кезеңде модель өз салмақтары мен параметрлерін белсенді түрде бейімдеп, жаттығуды жедел жүргізеді.

25-тен 75-ші эпохаға дейінгі аралықта оқыту және тексеру жиынтықтарының шығын қисықтары біртіндеп тегістеліп, тұрақты бола бастайды, аздаған ауытқулар байқалады. Мұндай ауытқулар модельдің параметрлерін нақты баптау процесін білдіреді, бұл оның деректердің ерекшеліктеріне бейімделуіне және артық үйренуден (overfitting) аулақ болуына ықпал етеді. 200-ші эпоханың соңына қарай екі қисық шамамен 0.4 мәніне тұрақтанады, бұл оқыту процесінің сәтті аяқталғанын көрсетеді. Оқыту және тексеру қисықтарының ұқсас болуы LDA+BERT+AE моделінің жоғары жалпылау қабілетін көрсетеді және оның жаңа деректермен тиімді жұмыс істей алатынын дәлелдейді. Модельдің тиімділігі оның қолдану нәтижелерінде де расталды. LDA+BERT+AE гибриді моделін қолдана отырып, мәтіндерді кластерлеу мысалдары жоғары дәлдік көрсеткіштерін көрсетті, нәтижелері іс жүзінде шынайы мәндерге сәйкес келеді. Мысалы, бір жағдайда модель «спорт» тақырыбын 98.20 % дәлдікпен дұрыс анықтады, бұл шын мәніндегі тақырыппен толық сәйкес келді. Сол сияқты, модель «бизнес» және «саясат» сияқты басқа санаттарға да мәтіндерді жоғары

дәлдікпен жіктей алды, бұл оның кластерлеу мен мәтіндік деректерді талдау міндеттерінде жоғары тиімділік пен сенімділікке ие екенін растайды. Осылайша, LDA+BERT+AE гибриді моделі оқыту процесін сәтті аяқтап, тәжірибелік міндеттерде үздік нәтижелер көрсетті, бұл оны қысқа мәтіндерді талдау және табиғи тілді өңдеу (NLP) саласындағы басқа да міндеттер үшін аса пайдалы құралға айналдырады.



Сур. 5. Гибриді LDA+BERT+AE үлгісін оқыту кезінде жоғалту мәнінің өзгеруі

Нәтижелер бақыланатын классификация жоғары ARI/біртектілік мәндеріне қол жеткізетінін көрсетті. Дегенмен, бақыланбайтын кластер салыстырмалы нәтиже береді. Бұл алынған векторларда (әсіресе LDA_BERT) деректер құрылымы туралы сапалы ақпарат бар екенін көрсетеді. Зерттеудің қайталануы мен ашықтығын қамтамасыз ету үшін гибриді модельдің бастапқы коды және талдау әдістері қоғамдық игілікке орналастырылды. Код келесі сілтеме бойынша репозиторийде қолжетімді: <https://github.com/JamalbekTussupov01/Text-clustering/tree/main>. Жарияланған код деректерді алдын ала өңдеуді, маңызды мүмкіндіктерді таңдауды, параметрді талдауды және ауытқуды болжауды қоса алғанда, модельді іске асырудың барлық кезеңдерін қамтиды. Бұл зерттеушілер мен практиктерге ұсынылған тәсілді өз міндеттері үшін пайдалануға және қажет болған жағдайда жақсартулар жасауға және әдістемені әртүрлі жағдайларға бейімдеуге мүмкіндік береді. Бұл тәсіл ғылыми жұмыстың ашықтығын арттыруға көмектеседі және ашық ғылыми талқылауды қолдайды.

Қорытынды

Бұл зерттеу жұмысында BERT, TF+IDF және гибриді тәсіл LDA+BERT+AE сияқты қысқа мәтіндерді интеллектуалды кластерлеу әдістерінің егжей-тегжейлі талдауы ұсынылған. Зерттеу нәтижелері қысқа мәтіндермен жұмыс істеу кезінде әрбір әдістің артықшылықтары мен шектеулері бар екенін көрсетеді. Атап айтқанда, BERT контекстік тәуелділіктерді

түсінудің мықты қабілетін көрсетеді, ал TF+IDF құжаттардағы терминдердің маңыздылығын бағалайды. Дегенмен, LDA генеративті модельдеу, BERT терең контекстік талдау және автокодерлерді пайдалана отырып өлшемділікті азайту мүмкіндігін біріктіретін LDA+BERT+AE гибриді әдісі қысқа мәтіндерді кластерлеуде ең тамаша тиімділікті көрсетті. Нәтижелер гибридік әдістің жоғары тиімділігін растады, әсіресе мәтіндерге терең мағыналық талдауды қажет ететін тапсырмаларда. Атап айтқанда, 200 дәуірден астам LDA-BERT моделін оқыту және тексеру кезінде жоғалту мәндері 1,2-ден жоғары басталып, алғашқы 25 дәуірде тез төмендеп, шамамен 0,8-ге жетті. Жоғалту мәндері жаттығу барысында төмендеп, 200-ші дәуірде шамамен 0,4 тұрақтанды. Оқыту және валидация жоғалту қисықтарының тығыз үйлесуі модельдің практикалық оқуын және жақсы жалпылау мүмкіндіктерін көрсетті, сонымен қатар шектен шығудың минималды белгілері бар. Бұл зерттеудің практикалық салдары NLP жүйелерін оңтайландыруда жатыр, ол маркетинг, әлеуметтік медиа және автоматтандырылған мазмұнды модерациялау сияқты салаларда мәтіндік деректерді талдау сапасын айтарлықтай жақсартып алады. Сонымен қатар, әдіс көптілді мәтіндік талдауға бейімделу мүмкіндігін көрсетеді, бұл әсіресе жаһандық платформалар мен трансұлттық компаниялар үшін өзекті. Дегенмен, әдістің шектеулері бар, оның ішінде еңбек пен ресурстарды көп қажет ететін табиғаты шағын бизнес пен стартаптар үшін қиындықтар тудыруы мүмкін. Бұған қоса, әдіс өнімділігі деректер сапасына қатты байланысты, өйткені нашар немесе толық емес деректерді алдын ала өңдеу кластерлеу нәтижелеріне кері әсер етуі мүмкін.

Болашақ зерттеу бағыттары есептеу шығындарын азайту үшін алгоритмдерді оңтайландыруды, деректерді өңдеу жылдамдығын арттыруды және әдісті биомедицина, құқық және экономика сияқты басқа салаларда қолдану үшін бейімдеуді қамтиды. Сондай-ақ деректерді талдау сапасы мен жылдамдығын жақсарту үшін бұл әдісті GPT немесе трансформаторлар сияқты басқа үлгілермен одан әрі интеграциялау мүмкіндігі бар. Қорытындылай келе, бұл зерттеу LDA+BERT+AE сияқты гибриді интеллекті кластерлеу әдістері қысқа мәтінді өңдеудің дәлдігі мен тиімділігін арттырудың перспективалы перспективаларын ұсынатынын растайды. Нәтижелер қазіргі ақпаратқа негізделген әлемде көптеген тапсырмаларды шешуге қабілетті неғұрлым жетілдірілген және бейімделген NLP жүйелерін дамытуға жол ашады.

ӘДЕБИЕТТЕР

Маниас Г., Маврогиоргу А., Киуртис А., Симвулидис С. және Кириазис Д. (2023). Мәтінді көптілді санаттарға бөлу және көңіл-күйді талдау: twitter деректерін жіктеудің көптілді тәсілдерін салыстырмалы талдау. *Нейрондық Есептеу Және Қолдану*. — 35(29). — Б. 21415–21431, doi: 10.1007/s00521-023-08629-3

Фу, Г., Ли, Б., Янг, Ю. Және Ли, С. (2023). Мәтінді санаттарға бөлу үшін көп сатылы агрегациясы бар ансамбльді ҚАЙТА бағалау және ТОПСИС негізінде таңдау. *Үлгіні Тану Хаттары*. — 168. — Б. 47–56, doi:10.1016/Дж.патрек.2023.02.027.

Эдара, Колумбия Округі, Ванукури, Лос-Анджелес, Систла В. және Колли В.К.К. (2023). *Көңіл-күйді*



талдау және lstm көмегімен онкологиялық аурулардың медициналық жазбаларын мәтіндік санаттарға бөлу. Қоршаған Ортаны Барлау және Ізгілендірілген Есептеу журналы. — 14(5). — 5309-5325, doi: 10.1007/s12652-019-01399-8 б.

Баладжи Т.К., Аннаварапу К.С.Р. және Баблани А. (2021). Әлеуметтік медианы талдауға арналған машиналық оқыту алгоритмдері: сауалнама. Информатикаға Шолу. — 40. — 100395, doi: 10.1016/Дж.косрев.2021.100395.

Аббас А.Ф., Джусох А., Мас' од, А., Алшариф А.Х., және Али, Дж. (2022). Әлеуметтік желілердегі ақпарат алмасудың библиометриялық талдауы. Сенімді Бизнес Және Менеджмент. — 9 (1). — 2016556. doi: 10.1080/23311975.2021.2016556.

Маккитрик, М. К., Шуурман, Н., & Алаяқтар, В.А. (2023). Орналасқан жеріне негізделген әлеуметтік медиа деректерін жинау, талдау және визуализациялау: ГАЗ-дағы әдістерге шолу-әлеуметтік медианы талдау. Геожурнал. — 88(1). — Б. 1035–1057, doi: 10.1007/s10708-022-10584- 6.

Бекен, П., Фридл, Х., Стэнтик, Б., Коннолли, Р.М. Және Чен, Дж. (2021). Климаттық дағдарыс және ұшу: Әлеуметтік медианы талдау «ұшу ұятының»өсуін қадағалайды. Тұрақты Туризм журналы. — 29 (9). — Б. 1450–1469, doi: 10.1080/09669582.2020.1851699.

Чакраборти К., Бхаттачария П., және Баг Р. (2020). Әлеуметтік медиа деректерінен көңіл-күйді талдау сауалнамасы. Есептеу Әлеуметтік Жүйелеріндегі IEEE Транзакциялары. — 7 (2). — 450–464, doi:10.1109/TCSS.2019.2956957.

Хорта Рибейро, М., Ченг, Дж., Және Уэст, Р. (2023, Сәуір). Мазмұнды автоматтандырылған модерациялау қауымдастық нұсқауларын сақтауды арттырады. АСМ 2023 веб-конференциясының Материалдарында. — 2666–2676 беттер. doi: 10.1145/3543507.3583275.

Ух К., Хонг Ю. және Рагу Т.С. (2021). Машиналық платформаны басқарудың әсері: мазмұнды модерациялауды эмпирикалық зерттеу. SSRN 3767680 мекен-жайы бойынша қол жетімді.

Фазель М. & Weerts P. (2024). Facebook қауымдастығының стандарттары заңды сенімділікке сәйкес келе ала ма? Сандық Қызметтер Туралы Заңның қысымымен мазмұнды модерациялауды басқару. Саясат Және Интернет, doi: 10.1002 / roi3.391.

Сарания П., және Уша Г. (2023). Twitter-дегі Көңіл-күйді Талдау Үшін IntelligentWordNet Lemmatize Көмегімен Машиналық оқытуға негізделген Әдіс. Интеллектуалды Автоматтандыру Және Жұмсақ Есептеу. — 36 (1).

Хапкс Д., Джулианелли М., Данкерс В., Артеткс М., Элазар Ю., Пиментель Т. & Джин З. (2023). Nlp-дегі жалпылама зерттеулердің таксономиясы және шолуы. Табиғат Машинасының Интеллектісі. — 5(10). — 1161–1174. doi: 10.1038/s42256-023-00729- ы.

Чанг П., Мун П., Кім Дж., Кім Дж., Лим П., және Чи П. (2023). Құрылыстағы және информатикадағы табиғи тілді өңдеу (NLP) қолданбаларын жүйелі шолулар (PRISMA) үшін таңдаулы есеп беру элементтерін пайдалана отырып салыстыру. Құрылыстағы автоматтандыру. — 154. — 105020, doi: 10.1016/j.aut-con.2023.105020.

Син К., Ол Ю., Пан Ю., Ван Ю. және Ду П. (2023). NLP алгоритміне негізделген ЖАСАНДЫ ИНТЕЛЛЕКТКЕ негізделген жарнамалық итеру жүйесін енгізу. — *Халықаралық Информатика Және Ақпараттық Технологиялар Журналы*. — 1 (1). — 30-37, doi: 10.62051/ijcsit.v1n1.05.

Ишикдемир, Ю.Е. (2024). NLP ТРАНСФОРМАТОРЛАРЫ: LLM-ДІ ТАЛДАУ ЖӘНЕ МӘТІНДІ КЕҢЕЙТІЛГЕН ҚОРЫТЫНДЫЛАУДЫҢ ДӘСТҮРЛІ ТӘСІЛДЕРІ. *Эскишехир Османгази Университетінің Инженерлік-Сәулет Факультетінің Журналы*. — 32(1). — Рр. 1140–1151, doi: 10.31796/ogummf.1303569.

REFERENCES

Manias G., Mavrogiorgou A., Kiourtis A., Symvoulidis C. & Kyriazis D. (2023). Multilingual text categorization and sentiment analysis: a comparative analysis of multilingual approaches for classifying twitter data. *Neural Computing and Applications*. — 35(29). — 21415–21431, doi: 10.1007/s00521-023-08629-3. (in Eng.)

Fu G., Li B., Yang Y. & Li C. (2023). Re-ranking and TOPSIS-based ensemble feature selection with multi-stage aggregation for text categorization. *Pattern Recognition Letters*. — 168. — Pp. 47–56, doi: 10.1016/j.patrec.2023.02.027. (in Eng.)

Edara D.C., Vanukuri L.P., Sistla V. & Kolli V.K.K. (2023). Sentiment analysis and text categorization of cancer medical records with LSTM. *Journal of Ambient Intelligence and Humanized Computing*. — 14(5). — Pp. 5309–5325, doi: 10.1007/s12652-019-01399-8. (in Eng.)

Balaji T.K., Annavarapu C.S.R. & Bablani A. (2021). Machine learning algorithms for social media analysis: A survey. *Computer Science Review*. — 40. — 100395, doi: 10.1016/j.cosrev.2021.100395. (in Eng.)

Abbas A.F., Jusoh A., Mas' od A., Alsharif A.H. & Ali J. (2022). Bibliometrix analysis of information sharing in social media. *Cogent Business & Management*. — 9(1). — 2016556, doi: 10.1080/23311975.2021.2016556. (in Eng.)



McKittrick M.K., Schuurman N. & Crooks V.A. (2023). Collecting, analyzing, and visualizing location-based social media data: review of methods in GIS-social media analysis. *GeoJournal*. — 88(1). — Pp. 1035–1057, doi: 10.1080/s10708-022-10584-w. (in Eng.)

Becken S., Friedl H., Stantic B., Connolly R.M. & Chen J. (2021). Climate crisis and flying: Social media analysis traces the rise of “flightshame”. *Journal of Sustainable Tourism*. — 29(9). — 1450–1469, doi: 10.1080/09669582.2020.1851699. (in Eng.)

Chakraborty K., Bhattacharyya S. & Bag R. (2020). A survey of sentiment analysis from social media data. *IEEE Transactions on Computational Social Systems*. — 7(2). — Pp. 450–464. doi: 10.1109/TCSS.2019.2956957. (in Eng.)

Horta Ribeiro M., Cheng J. & West R. (2023, April). Automated content moderation increases adherence to community guidelines. In *Proceedings of the ACM web conference 2023*. — Pp. 2666–2676, doi: 10.1145/3543507.3583275. (in Eng.)

He, Q., Hong Y. & Raghu T.S. (2021). The effects of machine-powered platform governance: An empirical study of content moderation. — Available at SSRN 3767680. (in Eng.)

Fasel M. & Weerts S. (2024). Can Facebook’s community standards keep up with legal certainty? Content moderation governance under the pressure of the Digital Services Act. — *Policy & Internet*, doi: 10.1002/poi3.391. (in Eng.)

Saranya, S., & Usha, G. (2023). A Machine Learning-Based Technique with IntelligentWordNet Lemmatize for Twitter Sentiment Analysis. *Intelligent Automation & Soft Computing*. — 36(1). (in Eng.)

Hupkes D., Giulianelli M., Dankers V., Artetxe M., Elazar Y., Pimentel T. & Jin Z. (2023). A taxonomy and review of generalization research in NLP. *Nature Machine Intelligence*. — 5(10). — Pp. 1161–1174, doi: 10.1038/s42256-023-00729-y. (in Eng.)

Chung S., Moon S., Kim J., Kim J., Lim S. & Chi S. (2023). Comparing natural language processing (NLP) applications in construction and computer science using preferred reporting items for systematic reviews (PRISMA). *Automation in Construction*. — 154. — 105020, doi: 10.1016/j.autcon.2023.105020. (in Eng.)

Xin, Q., He, Y., Pan, Y., Wang, Y., & Du, S. (2023). The implementation of an AI-driven advertising push system based on a NLP algorithm. *International Journal of Computer Science and Information Technology*. — 1(1). — Pp. 30–37, doi: 10.62051/ijcsit.v1n1.05. (in Eng.)

Işıkdemir Y.E. (2024). NLP TRANSFORMERS: ANALYSIS OF LLMS AND TRADITIONAL APPROACHES FOR ENHANCED TEXT SUMMARIZATION. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*. — 32(1). — Pp.1140-1151, doi: 10.31796/ogummf.1303569. (in Eng.)

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 2. Number 22 (2025). Pp. 37–56

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.003>

УДК 004.932:004.93'2:004.89:681.518

DEVELOPMENT AND TESTING OF AN INTELLIGENT MONITORING SYSTEM FOR CONSTRUCTION PROCESSES BASED ON COMPUTER VISION AND MACHINE LEARNING

**G.U. Bektemysova¹, A.A. Bykov^{1*}, B.A. Nor'ashikin², A.A. Keresh¹,
M.O. Dauletbek¹**

¹International Information Technology University, Almaty, Kazakhstan;

²Universiti Tenaga Nasional, Kajang, Selangor, Malaysia.

E-mail: a.bykov@edu.iitu.kz

Bektemysova G.U. — Candidate of Technical Sciences, professor, «the Department of Computer Engineering», International Information Technology University, Almaty, Kazakhstan

E-mail: g.bektemisova@iitu.edu.kz, <https://orcid.org/0000-0002-0850-0558>;

Bykov A.A. — Candidate Technical Sciences, associate professor, «the Department of Computer Engineering», International Information Technology University, Almaty, Kazakhstan

E-mail: a.bykov@edu.iitu.kz, <https://orcid.org/0000-0002-9563-5185>;

Nor'ashikin B.A. — PhD in Information Systems, associate professor, Deputy Dean (Academic, Quality & Student Affairs), Universiti Tenaga Nasional (UNITEN), Putrajaya, Selangor, Malaysia

E-mail: shikin@uniten.edu.my, <https://orcid.org/0000-0002-5653-2482>;

Keresh A.A. — Master of Sc., International Information Technology University, Almaty, Kazakhstan

E-mail: arman@keresh.ru, <https://orcid.org/0009-0008-9695-0241>;

Dauletbek M.O. — Master of Technical Sciences, «the Department of Cybersecurity», International Information Technology University, Almaty, Kazakhstan

E-mail: m.dauletbek@iitu.edu.kz, <https://orcid.org/0009-0005-5569-4980>.

© G.U. Bektemysova, A.A. Bykov, B.A. Nor'ashikin, A.A. Keresh, M.O. Dauletbek, 2025

Abstract. This paper presents the design and testing of an intelligent construction monitoring system using computer vision and machine learning to improve safety and efficiency. The system focuses on automated detection of personal protective equipment (PPE) and safety violations at construction sites. It employs YOLOv11 and ResNet-50 neural networks for real-time object detection and classification. Lightning AI was used for cloud-based data processing. Testing on real-world data showed 70–75 % detection accuracy (mAP@0.5) for workers and PPE, and 92 % accuracy for classifying safety violations. However, under stricter criteria (mAP@0.5:0.95), accuracy dropped to 35 %, highlighting challenges in complex or occluded scenes. The most frequent errors involved helmets and safety glasses misrecognition. The system reduces human error and supports proactive safety management, contributing to lower accident rates and better oversight on construction sites.



Keywords: computer vision, construction monitoring, occupational safety, object detection, deep learning, YOLOv11, ResNet-50, Lightning AI

For citation: G.U. Bektemisova, A.A. Bykov, A.A. Nor'ashikin, A.A. Keresh, M.O. Dauletbek. Development and testing of an intelligent monitoring system for construction processes based on computer vision and machine learning// International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 37–56 (In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.003>.

Conflict of interest: The authors declare that there is no conflict of interest.

Funding information. This research has been funded by the Science Committee of the Ministry of Science and Higher Education of the Republic of Kazakhstan (Grant №AP23488873 - The development of an intelligent monitoring system for construction processes based on image recognition models).

КОМПЬЮТЕРЛІК КӨРУ ЖӘНЕ МАШИНАЛЫҚ ОҚЫТУ НЕГІЗІНДЕ ҚҰРЫЛЫС ПРОЦЕСТЕРІН БАҚЫЛАУДЫҢ ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕСІН ӘЗІРЛЕУ ЖӘНЕ СЫНАУ

Г.У. Бектемісова¹, А.А. Быков^{1}, Б.А. Нурашихин², А.А. Кереш¹,
М.О. Даулетбек¹*

¹Халықаралық Ақпараттық Технологиялар Университеті, Алматы, Қазақстан;

²Тенага Ұлттық университеті, Каджанг, Селангор, Малайзия.

E-mail: a.bykov@edu.iitu.kz

Бектемісова Г.У. — «Компьютерлік Инженерия» кафедрасының, техника ғылымдарының кандидаты, профессор, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан

E-mail: g.bektemisova@iitu.edu.kz, <https://orcid.org/0000-0002-0850-0558>;

Быков А.А. — «Компьютерлік Инженерия» кафедрасының, техника ғылымдарының кандидаты, доцент, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан

E-mail: a.bykov@edu.iitu.kz, <https://orcid.org/0000-0002-9563-5185>;

Нурашихин Б.А. — ақпараттық жүйелер саласындағы PhD докторы, деканның орынбасары, Профессор, Тенага Ұлттық университеті (UNITEN), Каджанг, Селангор, Малайзия

E-mail: shikin@uniten.edu.my, <https://orcid.org/0000-0002-5653-2482>;

Кереш А.А. — «Компьютерлік Инженерия» кафедрасының, техникалық ғылымдарының магистрі, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан

E-mail: arman@keresh.ru, <https://orcid.org/0009-0008-9695-0241>;

Даулетбек М.О. — «Киберқауіпсіздік» кафедрасының, техникалық ғылымдарының магистрі, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан

E-mail: m.dauletbek@iitu.edu.kz, <https://orcid.org/0009-0005-5569-4980>.

© Г.У. Бектемісова, А.А. Быков, Б.А. Нурашихин, А.А. Кереш, М.О. Даулетбек, 2025

Аннотация. Бұл жұмыста құрылыс алаңдарындағы қауіпсіздік пен тиімділікті арттыруға бағытталған интеллектуалды бақылау жүйесі ұсынылады. Жүйе жеке қорғаныс құралдарын (ЖҚҚ) автоматты түрде анықтап, қауіпсіздік ережелерінің бұзылуын тіркейді. YOLOv11 және ResNet-50 нейрондық желілері нысандарды нақты уақытта анықтап, жіктеу үшін қолданылды. Деректерді

өңдеу Lightning AI бұлтты платформасы арқылы жүзеге асты. Нақты деректерде сынақ жүргізу нәтижесінде жұмысшылар мен ЖҚҚ анықтау дәлдігі 70–75 % (mAP@0.5) болса, қауіпсіздік бұзушылықтарын жіктеу дәлдігі 92 %-ға жетті. Қатал бағалау кезінде (mAP@0.5:0.95) дәлдік 35 %-ға дейін төмендеді, бұл күрделі көріністер мен жабық нысандарда қиындықтар барын көрсетті. Ең жиі кездесетін қателер – каска мен көзілдірікті дұрыс танымау. Жүйе адам қателігін азайтып, қауіпсіздік бақылауын жақсартады.

Түйін сөздер: computer vision, construction monitoring, occupational safety, object detection, deep learning, YOLOv11, ResNet-50, Lightning AI

Дәйексөздер үшін: Г. У. Бектемісова, А. А. Быков, Б.А. Нурашихин, А. А. Кереш, М. О. Даулетбек. Компьютерлік көру және машиналық оқыту негізінде құрылыс процестерін бақылаудың интеллектуалды жүйесін әзірлеу және сынау//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 37–56бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.003>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

РАЗРАБОТКА И ТЕСТИРОВАНИЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ МОНИТОРИНГА СТРОИТЕЛЬНЫХ ПРОЦЕССОВ НА ОСНОВЕ КОМПЬЮТЕРНОГО ЗРЕНИЯ И МАШИННОГО ОБУЧЕНИЯ

Г.У. Бектемысова¹, А.А. Быков^{1}, Б.А. Нурашихин², А.А. Кереш¹,
М.О. Даулетбек¹*

¹Международный университет информационных технологий, Алматы, Казахстан;

²Университет Тенага Насиональ (UNITEN), Каджанг, Селангор, Малайзия.
E-mail: a.bykov@edu.iitu.kz

Бектемысова Г.У. — кандидат технических наук, профессор, «Кафедра компьютерной инженерии», Международный университет информационных технологий, Алматы, Казахстан
E-mail: g.bektemisova@iitu.edu.kz, <https://orcid.org/0000-0002-0850-0558>;

Быков А.А. — кандидат технических наук, ассоциированный профессор, «Кафедра компьютерной инженерии», Международный университет информационных технологий, Алматы, Казахстан
E-mail: a.bykov@edu.iitu.kz, <https://orcid.org/0000-0002-9563-5185>;

Нурашихин Б.А. — профессор, PhD в области информационных систем, заместитель декана (учебная работа, качество и работа со студентами), Университет Тенага Насиональ (UNITEN), Каджанг, Селангор, Малайзия
E-mail: shikin@uniten.edu.my, <https://orcid.org/0000-0002-5653-2482>;

Кереш А.А. — магистр технических наук, «Кафедра компьютерной инженерии», Международный университет информационных технологий, Алматы, Казахстан
E-mail: arman@keresh.ru, <https://orcid.org/0009-0008-9695-0241>;

Даулетбек М.О. — магистр технических наук, «Кафедра кибербезопасности», Международный университет информационных технологий, Алматы, Казахстан
E-mail: m.dauletbek@iitu.edu.kz, <https://orcid.org/0009-0005-5569-4980>.

Аннотация. В работе представлена интеллектуальная система мониторинга строительных площадок, разработанная с применением компьютерного зрения и машинного обучения для повышения безопасности и эффективности. Основное внимание уделено автоматическому распознаванию средств индивидуальной защиты (СИЗ) и выявлению нарушений техники безопасности. Использовались нейросетевые модели YOLOv11 и ResNet-50 для детекции и классификации объектов. Облачная обработка данных выполнялась с помощью платформы Lightning AI. При испытаниях на реальных данных система показала точность обнаружения работников и СИЗ на уровне 70–75 % (mAP@0.5), а классификация нарушений достигла 92 %. Однако при более строгой оценке (mAP@0.5:0.95) точность снизилась до 35 %, что указывает на сложности в сложных сценах и при частичном перекрытии объектов. Наиболее частыми ошибками стали неверное распознавание касок и защитных очков. Система снижает влияние человеческого фактора и способствует улучшению контроля за соблюдением техники безопасности.

Ключевые слова: компьютерное зрение, мониторинг строительства, охрана труда, обнаружение объектов, глубокое обучение, YOLOv11, ResNet-50, Lightning AI

Для цитирования: Г.У. Бектемысова, А.А. Быков, Б.А. Нурашихин, А.А. Кереш, М.О. Даулетбек. Разработка и тестирование интеллектуальной системы мониторинга строительных процессов на основе компьютерного зрения и машинного обучения // Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 37–56. (На англ.). <https://doi.org/10.54309/IJICT.2025.22.2.003>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов

Introduction

The modern construction industry is one of the largest and most strategically significant sectors of the economy, driving infrastructure development and providing employment for a substantial portion of the population. However, the level of automation and adoption of advanced technologies in construction remains significantly lower compared to industries such as manufacturing, healthcare, or transportation (Kozlovska et al., 2021: 4–10; Shalbolova et al., 2023: 3–5) research indicates that the construction sector is characterized by low productivity, a high number of incomplete or delayed projects, and significant safety risks for workers. According to KPMG's 2023 report, up to 70 % of construction companies face considerable challenges in real-time monitoring of key construction metrics. This results in resource overruns and schedule deviations.

Traditional methods for monitoring construction processes, quality, and safety rely on visual inspections, manual data entry, and report analysis, which introduce subjectivity, documentation errors, and increased time costs. Although video surveil-

lance systems are increasingly being deployed on construction sites, they primarily operate in a passive mode and require continuous human intervention for video stream analysis, limiting their overall effectiveness. Automated construction monitoring systems powered by artificial intelligence (AI) are still in the early stages of development. However, there are already successful cases of their practical implementation, demonstrating significant potential for improving safety and efficiency in construction operations (Vukicevic et al., 2024: 2–6).

However, despite its significant potential, existing construction monitoring methods still face several unresolved challenges. Most AI architectures require large volumes of labeled data for effective training, yet specialized datasets for construction sites (e.g., the Construction Site Safety Computer Vision Project) remain limited in terms of the number of images and scene diversity. Additionally, there is no unified system for integrating various monitoring tools. Construction companies often implement fragmented video analysis solutions, while comprehensive platforms that integrate data from drones, IP cameras, trail cameras, and sensor systems into a single intelligent decision-support environment have yet to be developed at a sufficient level. Moreover, existing algorithms lack adequate adaptation to the complex conditions of construction sites. The high visual dynamics of construction scenes, adverse weather conditions, poor lighting, and various obstacles (e.g., scaffolding and trees) pose significant challenges for current object detection and segmentation algorithms (Tahir et al., 2024: 103; Kumar et al., 2023: 20–23). Another critical aspect is real-time processing of video streams and images, as this requires substantial computational resources, making it impractical to deploy complex AI models without leveraging cloud-based GPU solutions.

In this context, there is a growing need for the development of an intelligent construction monitoring system that integrates machine learning methods, cloud technologies, and video image analysis.

The objective of this study is to design an automated system capable of real-time data processing from IP cameras, trail cameras, and drones to monitor construction safety, track progress, and assess resource utilization efficiency.

To achieve this goal, the following tasks were undertaken:

1. Integration of data from various monitoring sources.
2. Development of a computer vision model for detecting personal protective equipment (PPE) and monitoring construction progress.
3. Creation of an intelligent platform for analyzing and visualizing incoming data.
4. Evaluation of the system's effectiveness under test deployment conditions.

To substantiate the relevance of the proposed approach, we will examine the current technological solutions available today and analyze their limitations in detail.

Modern digital technologies in construction are evolving rapidly; however, they remain fragmented and primarily address specific monitoring and management tasks. The most widely used tools today include Building Information Modeling

(BIM) platforms, cloud-based project management systems, video analytics modules, and IoT systems. For instance, Building Information Modeling (BIM) software such as Autodesk Revit, Tekla, and Bentley is effectively utilized for designing and planning construction projects. However, BIM systems do not provide automated real-time monitoring of construction progress and require continuous manual updates to maintain accurate project information.

Cloud-based project management platforms such as Procore, PlanGrid, and Aconex facilitate document management and administrative oversight but lack the ability to automatically monitor construction processes or analyze video data in real time. Their dependence on manual data entry significantly slows down the detection of violations and the decision-making process.

Computer vision and deep learning technologies are increasingly being utilized to automate construction site monitoring, including the detection of safety violations (e.g., absence of helmets and protective eyewear), construction progress tracking, and equipment condition inspection. Various neural network models, such as YOLO, U-Net, MobileNet, and Vision Transformers, are employed for these tasks, each offering different levels of accuracy and performance. However, their effective deployment in construction environments is constrained by a lack of specialized labeled datasets, the complexity of scenes (e.g., low lighting, object occlusions, dynamic backgrounds), and high computational requirements.

Moreover, existing cloud solutions such as AWS, Google Cloud Platform, and Azure are not yet fully optimized for real-time video stream processing from construction sites or come with high operational costs, making the widespread adoption of automated monitoring systems in the industry challenging.

Thus, despite advancements in individual technologies, the construction industry still faces several significant limitations: data fragmentation, lack of integrated platforms, absence of real-time automated analysis, and high computational costs. Overcoming these challenges requires an intelligent system capable of integrating multiple data sources (IP cameras, trail cameras, drones, and sensors) into a unified cloud platform that enables automated safety violation detection, construction progress monitoring, and effective adaptation to real-world construction site conditions.

In response to these challenges, there is a growing need for the development of an intelligent construction monitoring system that integrates machine learning methods, cloud technologies, and automated video analysis.

Materials and Methods

Data Sources and Equipment

Effective construction site monitoring requires a comprehensive approach to data collection, incorporating both stationary and mobile surveillance systems. Stationary IP cameras serve as a key component of the proposed system. Cameras are selected based on their support for the Real-Time Streaming Protocol (RTSP) and resolution sufficient for reliable detection and recognition of small objects. Following an extensive analysis, the Hikvision DS-2CD2043G2-I camera demonstrated the highest

efficiency, as shown in Figure 1. This choice is justified by its high image quality, strong adaptation to challenging lighting conditions, and built-in intelligent features such as motion detection and real-time analytics. For optimal coverage, cameras should be strategically installed at critical points on the construction site, ensuring a wide field of view over key work areas and movement pathways for both personnel and machinery. Mounting at a height of no less than 3 meters minimizes interference from construction equipment and structures, enhancing detection accuracy.



Fig.1. Hikvision DS-2CD2043G2-I Camera (image sourced from the official Hikvision website)

An alternative approach to construction site monitoring involves the use of trail cameras, which enable autonomous surveillance in hard-to-reach areas, triggering upon motion sensor activation. During testing, the H881 and T31ZX 4G LTE trail cameras were evaluated, as shown in Figure 2. The H881 model was preferred due to its high image quality in dusty and low-light conditions, as well as its extended battery life. This model supports data storage on SD cards up to 128 GB, ensuring reliable offline operation. For situations where physical access to the camera is difficult, the T31ZX 4G LTE is recommended, as it enables image transmission via 4G/3G mobile networks. With an average resolution of 12–16 MP, each frame occupies approximately 3–5 MB, allowing for the storage of up to 30,000 images. Since real-time video streaming is not required and potential data transmission delays are acceptable, these cameras provide an effective solution for periodic construction monitoring.

To collect aerial data on construction sites, unmanned aerial vehicles (UAVs), commonly known as drones, are utilized. These devices provide wide-format photo and video capture and enable regular inspection of hard-to-reach areas. The use of drones facilitates construction progress monitoring, early detection of potential violations, and the creation of digital 3D models of structures. Following a comparative analysis of various drone models, the DJI Mini 3 Pro was selected, as shown in Figure 3. This decision was based on the mobility of the model (it is easily transportable, deploys quickly, and requires minimal flight preparation) and its 4K camera with a wide dynamic range, which ensures detailed imaging of construction sites. Additionally, the built-in SDK provides future opportunities for automating flight routes and implementing autonomous inspection missions.



a. Trail Camera H881



b. Trail Camera T31ZX c 4G LTE

Fig. 2. Installed Trail Cameras



a. Appearance



б. Drone Video Recording Process

Fig.3. Drone DJI Mini 3 Pro RC

System Architecture

Video and photographic materials from cameras and drones generate a substantial volume of data, necessitating the use of a cloud-based platform for storage, processing, and subsequent analysis. To address this, the system integrates with the Lightning AI cloud platform. Video footage from drones and IP cameras is automatically uploaded to the platform, where preprocessing operations are performed, including compression, normalization, and segmentation of video sequences into individual frames. The processed data is then utilized for training neural network models and real-time object recognition. This approach enables the rapid detection of safety violations on construction sites while ensuring efficient storage and analysis of large

datasets without compromising system performance.

As part of this study, an integrated video monitoring platform for construction processes has been developed, aimed at automating control, analyzing construction dynamics, and ensuring safety. Figure 5 presents the high-level architectural concept of the system, which facilitates the acquisition, transmission, storage, and analysis of video data through the application of computer vision techniques and cloud computing. The proposed architecture is modular and scalable, allowing for continuous upgrades and the incorporation of new components as data accumulates, algorithms are optimized, and additional functionalities are integrated.

The main stages of data processing within the system include:

- Acquisition of images and video streams from IP cameras and other sources.
- Transmission of data to the server using the RTCP protocol, ensuring a reliable connection between devices and the cloud platform.
- Initial image processing utilizing machine learning methods on a GPU-powered server.
- Storage of processed data and analysis results in a cloud-based object repository and associated database.
- Visualization of results through a web interface.




Fig. 5. Platform Architecture

The central component of the architecture is the backend service, which receives incoming video streams and images from all monitoring devices. It performs data routing, initial processing (such as noise removal and cropping), and stores both raw and processed information in the cloud storage for further analysis.

The training and inference module is responsible for processing video data using machine learning techniques. Its primary functions include training models based

on incoming data, real-time object detection and classification, and periodic model updates to account for newly acquired data. To ensure efficient operation, the module runs on a cloud server equipped with a GPU. The training process is organized as a pipeline (CI/CD workflow) that includes stages such as loading new data from storage, data augmentation and normalization, neural network training, validation on a holdout dataset, and deployment of the improved model to replace the previous one. To facilitate this process, tools such as MLflow, TensorFlow Extended (TFX), and Kubeflow are integrated, enabling containerization and automated model updates in response to changing conditions. This approach ensures flexibility and adaptability of the algorithms over long-term system operation.

PostgreSQL is used as the primary database management system (DBMS) due to its reliability, scalability, and support for analytical operations. The database records information about detected objects, construction progress, and identified safety violations. PostgreSQL supports JSONB fields for storing complex structured data, which simplifies handling image metadata and inference results. Additionally, the database interacts with BI systems via JDBC connectors, enabling the generation of analytical reports and visualization of monitoring results.

For end users, dedicated interfaces have been developed to provide convenient access to monitoring results and analytics. The system consists of two main components:

- A BI dashboard that facilitates the visualization of key metrics, including safety violations, construction progress, and analysis of construction equipment utilization.
- A web application that provides real-time access to data, including viewing images and video recordings from cameras, detailed reports on recorded events, configuration of analytics parameters, and data filtering options.

Approaches to Image Analysis and Object Recognition

One of the key tasks of computer vision in construction monitoring is the detection and classification of objects such as construction structures, workers, specialized equipment, and personal protective equipment (helmets, vests, gloves). Various neural network architectures optimized for accuracy and processing speed in real-world conditions are employed for this purpose.

Object Detection

A critical task of the construction site monitoring system is the detection and classification of safety elements, such as construction helmets, vests, workers, and specialized equipment. To address the detection challenge, various state-of-the-art deep learning architectures optimized for accuracy and speed were evaluated and tested. Lightweight models, such as MobileNet, offer energy efficiency and low computational costs. However, experiments revealed a significant decline in their accuracy when dealing with complex scenes featuring numerous overlapping objects and dynamic backgrounds. As an alternative, Vision Transformer (ViT) models were considered, leveraging the self-attention mechanism to provide deep and effective analysis

of visually complex scenarios, including cases of partial object occlusion. At the same time, ViT models are characterized by high computational demands and hardware requirements, which significantly limit their applicability for real-time video stream analysis.

The analysis also considered modern and well-established neural network architectures such as YOLO (You Only Look Once) and Faster R-CNN. As demonstrated in, the YOLO architecture, due to its use of multi-scale processing and efficient one-step detection, achieves high speed and good accuracy even under challenging shooting conditions, such as variable lighting and dynamic scenes. Meanwhile, the Faster R-CNN model (Shaoqing et al., 2017: 1137–1149), while providing high accuracy through its two-stage approach (region proposal generation followed by classification), exhibits significantly lower processing speed, making it less suitable for real-time monitoring tasks.

Based on the analysis, the YOLOv11 model was selected as the primary object detector in the system, as it provides high recognition accuracy with fast inference speed and supports efficient fine-tuning on specialized construction datasets.

Segmentation

For a detailed analysis of construction sites, the monitoring system employs image segmentation, enabling the identification of defect areas, tracking construction phases, and quantitatively assessing the progress of structural development. Various neural network architectures for segmentation were evaluated, including DeepLabV3+, Mask R-CNN, and U-Net. The study demonstrated that DeepLabV3+ models achieve high segmentation accuracy; however, their computational demands remain significant for real-time systems. Similarly, Faster R-CNN, extended with Mask R-CNN as described in, provides precise object detection but requires substantial computational resources, limiting its applicability in dynamic construction site environments.

In contrast to these models, U-Net (Olaf et al., 2015: 235–238) with its symmetrical encoder-decoder architecture, enables high-detail segmentation while maintaining relatively low computational costs. Practical studies indicate that applying U-Net to the analysis of construction site images can achieve segmentation accuracy of up to 90 % for defect areas, significantly reducing the subjectivity of manual inspection and facilitating the automation of construction progress assessment.

Based on this analysis, the U-Net architecture was selected for the segmentation module in the system, as it provides an optimal balance between accuracy and processing speed for analyzing construction-related images.

Classification

In the development of the monitoring system, special attention is given to the automatic detection of safety violations. Various approaches can be employed for this task, including Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), and hybrid models. Testing has confirmed that CNNs demonstrate high efficiency in pattern recognition and object classification in images. They can

effectively extract spatial features of objects and exhibit strong robustness to various image distortions. Architectures such as ResNet (Kaiming et al., 2016: 770–778) and EfficientNet (Mingxing et al., 2019: 6105–6114) have relatively low model complexity, enabling real-time performance even under challenging imaging conditions.

The developed system employs the ResNet-50 model as the core classifier for safety violations. This model has demonstrated high accuracy (approximately 92 %) in classifying such situations on test data.

Data Preparation and Model Training

For the creation of training datasets, image annotation tools such as LabelImg and VGG Image Annotator (VIA) were utilized. These tools allowed for the manual labeling of object boundaries (e.g., workers, helmets, vests, machinery, etc.) in each image. Special attention was given to maintaining consistency in the annotation approach and accurately defining object boundaries, which is critical for the proper training of models.

At the initial stage of research, the primary sources of information included online resources and publicly available datasets depicting construction processes and workers on construction sites. These datasets contained both positive and negative examples for each category of violation (Table 1).

Table 1.1 Categories of Violations on Construction Sites

Dataset	Total Number of Images	Training Set	Validation Set	Test Set
Dataset 1 (PPE detection Dataset [25])	1126	788	226	112
Dataset 2 (PPE TEST Dataset [26]) 1624		1129	332	163
Dataset 3 (Personal Protective Equipment Dataset [27])	2092	1460	421	221
Total	4842	3371	979	496

Additionally, existing open datasets such as COCO (Tsung et al., 2014: 740–755) and PASCAL VOC were examined. For instance, the COCO-2017 dataset contains approximately 2,600 images annotated with the label “Person,” as shown in Figure 6. However, most of these images are not related to the construction domain. Moreover, a dataset titled “Construction Workers,” consisting of 684 annotated images specifically focused on construction workers, was obtained from the Roboflow Universe platform (Figure 7).

The compiled dataset includes photographs of workers with clearly visible personal protective equipment and attire, group images containing multiple workers to train the model in distinguishing individuals within a group, as well as images captured under various lighting and weather conditions. This data diversity enhances the model’s robustness across different scenarios.



Fig. 6. Example of an Annotated Image from the COCO-2017 dataset



Fig. 7. Example of an Annotated Image from Roboflow Universe

An analysis of the final dataset revealed a significant class imbalance (Figure 8). The histogram illustrates that the “Hardhat” class is predominant, with over 30,000 annotated helmet instances, whereas categories like “Mask” or “NO-Goggles” contain significantly fewer examples. Such an imbalance in the dataset may lead to reduced model accuracy for underrepresented categories. Therefore, future research aims to increase the number of objects in these underrepresented classes.




Fig. 8. Dataset Distribution by Classes

The heatmaps (Figure 9) illustrate the distribution of object center coordinates (x, y) and their normalized sizes (width, height). It can be observed that objects tend to appear closer to the center of the image and generally have relatively small width and height (up to 20–30% of the frame dimensions).




Fig. 9. Distribution of Object Center Coordinates (x, y) and Their Normalized Sizes

For the recognition of personal protective equipment (PPE), the YOLOv11 model was utilized. This model inherits general features from pre-trained weights (ImageNet) and is further fine-tuned on a specialized dataset. The training process included image preprocessing (helmets, vests, goggles, etc.) with subsequent bounding box annotation, normalization and scaling to a resolution of 640×640 , selection of optimal hyperparameters, training, and validation on the test set.

To ensure sufficient convergence while maintaining generalization ability, the model was trained for 50 epochs with a batch size of 16. The Adam optimizer was employed with an initial learning rate of 0.01 and a momentum coefficient of 0.937. This optimizer was chosen due to its fast convergence and stability on sparse features, which is particularly important for detecting small PPE objects. To mitigate overfitting, L2 regularization (weight_decay coefficient = 0.0005) was applied to constrain model weight growth. These parameters enabled stable model convergence without significant overfitting.

Results

To assess the effectiveness of the developed system, tests were conducted on a test dataset containing images of a construction site with annotated objects. For the trained YOLOv11 model (Figure 10), the mean Average Precision (mAP@0.5) was approximately 70 %. Specifically, for the “Person” class, an AP@0.5 of 75.1 % was achieved, while “Helmet” reached ~68 %, “Vest” ~72 %, and smaller objects such as “Phone” and “Cigarette” had an accuracy between 50–60 %. Under a stricter evaluation criterion of mAP@0.5:0.95, the average precision was ~35 %, considering different IoU thresholds. Additional calculations showed that for the “Person” class, Precision = 76.5 % and Recall = 71.6 %, resulting in an F1-score of approximately 74 %. The safety equipment classes also demonstrated precision and recall values exceeding 70 %.

Thus, the developed model produces minimal false positives; however, mis-

classification remains possible in more complex cases. That is, there are rare instances where non-human objects are incorrectly labeled as people, but there were also cases where real workers were missed in images with significant occlusions or poor image quality (Figure 11).




Fig.10. Example of Worker Detection Using YOLOv11



Fig.11. Example of Missed Objects in the
«Person» Class

For a deeper understanding of the model's performance, the obtained metrics were analyzed, and classifier characteristic graphs were constructed. Figures 12 and 13 present two versions of the confusion matrix (normalized and absolute), reflecting the distribution of correct and incorrect classifications for each predicted class. In both cases, the horizontal axis represents the true class labels, while the vertical axis shows the labels predicted by the model. The highest classification results on the main diagonal (0.90–0.98 percent) were achieved for the “Hardhat” and “Goggles” classes. The “Mask” class demonstrates significantly lower performance (around 0.35), which may be due to visual obstructions or face occlusions. The absolute error values (Figure 13) show that the most common type of error is misclassification between the presence and absence of a hardhat (over 300 errors between the “Hardhat” and “No-Hardhat” classes). This data clearly indicates the need to improve the model for rare classes and fine-tune the detection thresholds. Analyzing the confusion matrix helps identify which categories the algorithm is most reliable for (e.g., hardhats and goggles) and which still have a high error rate (e.g., masks and missing hardhats). Such information is crucial for further dataset balancing and optimizing the model's sensitivity for different object types.

In Figure 14, the graph shows the dependence of the F1 score on the detector's Confidence threshold. It is evident that as the threshold increases up to a certain value, the F1 score improves, but beyond that point, it starts to decline. The maximum F1 (~0.73) is achieved at a confidence threshold of approximately 0.27. This result indicates that the optimal trade-off between recall and precision for this model is reached at a confidence level of around 0.25–0.30.




Fig. 12. Normalized Confusion Matrix of Classification Results




Fig.13. Confusion Matrix with the Absolute Number of Predictions

At lower thresholds, the model detects more objects (higher recall), but false positives increase, reducing precision. Conversely, at higher thresholds, precision improves at the cost of missing some objects. Thus, the chosen range of ~ 0.27 for the confidence threshold is the most effective, confirming the necessity of proper detector calibration.

In Figure 15, the Precision-Recall curves for each class, as well as for the combined case (“all classes”), are shown. The highest scores (0.951 and 0.949) are observed for the “Ladder” and “Goggles” classes, respectively, while the “Mask” class achieves only 0.467, indicating challenges in detecting masks. At IoU=0.5, the model reaches an average detection accuracy of 75.4% across all classes. These results demonstrate that the model performs well for most categories; however, classes with fewer training examples (e.g., masks) lag significantly in quality.




Fig.14. F1-Confidence Curve




Fig.15. Precision-Recall Curve

To evaluate the training process of the YOLO model, curves showing the changes in loss functions and key metrics on the training and validation datasets were

plotted, as shown in Figure 16:

- train/box_loss - change in the loss function on the training set for bounding box coordinate regression.
- train/cls_loss represents the training classification
- train/df_l_loss – The loss value associated with distribution focal loss, which is used to refine coordinate regression in YOLO).
- metrics/precision(B) – the accuracy metric on the training dataset (or in “best” mode)- metrics/recall(B) it represents recall, i.e., the proportion of objects detected by the model among all actual objects.
- The metric val/box_loss is analogous to train/box_loss, but it is calculated on the validation set.
- val/cls_loss - classification loss on the validation set.
- val/df_l_loss - validation part of the distribution focal loss.
- metrics/mAP50(B) - mean Average Precision at an IoU threshold of 0.5
- metrics/mAP50-95(B) - a stricter metric averaging mAP across IoU thresholds from 0.5 to 0.95.

Overall, these curves demonstrate stable training convergence: all types of losses (box, cls, df_l) consistently decrease, while key metrics (Precision, Recall, mAP) increase. Moreover, the training and validation curves follow each other quite closely. This indicates the absence of clear signs of overfitting and suggests good generalization performance of the model on data that was not involved in training.




Fig.16. Loss and Key Metric Curves (Train/Val Loss, Precision, Recall, mAP)

Discussion of the Results

The developed system successfully addresses the tasks of automatic detection and classification of key objects (workers and personal protective equipment),

enabling (almost) real-time detection of potential safety violations. High Precision (0.90 and above) and Recall (0.80–0.85) for the classes “Hardhat” and “Goggles” indicate the reliability of the detector when sufficient training examples and favorable shooting conditions are provided.

The analysis of the confusion matrix results (see Figures 12 and 13) confirms that the model demonstrates high accuracy for frequently occurring classes in the dataset. However, objects such as “Mask” or “NO-Hardhat” are detected less reliably. This points to an issue of sample imbalance and the difficulty of recognizing occluded objects. Additionally, further experiments showed that the optimal Confidence threshold for maximizing the F1-score is around 0.25–0.30, as confirmed by the curves in Figure 14. This threshold selection ensures the minimization of both missed objects and false positives. Information about the preferred threshold will be useful when deploying the system in practice, allowing for tuning the detection sensitivity to meet the specific requirements of a given site.

The dynamics of the training and validation loss metrics (Train/Val Loss) shown in Figure 16 indicate the stable convergence of the model. There is a smooth decrease in all types of losses (box_loss, cls_loss, dfl_loss) and a parallel increase in mAP. The validation curves closely follow the training curves, which suggests that there is no significant overfitting, and the model has an acceptable generalization ability. However, with stricter IoU criteria (e.g., mAP@0.75 and above), the model’s accuracy decreases significantly, indicating the need for further refinement of bounding box coordinates and additional augmentations simulating complex shooting angles.

Despite the results achieved, this study has several limitations. The accuracy of recognition is heavily influenced by the shooting conditions: lighting, angle, weather factors, and the presence of noisy backgrounds. The existing class imbalance leads to a decrease in detection recall for rarely occurring categories. Additionally, it should be noted that the system is intended for static or slightly moving scenes; when using sharp camera movements (e.g., when mounted on a drone), special attention should be paid to stabilization algorithms and adaptive data augmentation.

To further improve recognition quality, it is planned to increase the proportion of rare categories in the training dataset, utilize more advanced augmentation techniques including modeling complex lighting, noisy backgrounds, and occluded objects. Research on Vision Transformers and hybrid architectures is also planned to potentially improve accuracy in complex and dynamic scenes. To optimize computational costs, it is necessary to study the adaptation of input image size and detection thresholds to specific requirements (real-time operation or periodic sampling).

Conclusion

As a result of the conducted research, a comprehensive monitoring system architecture was designed, based on the integration of photo and video data acquisition devices with the Lightning AI platform, optimized for deep learning tasks. The proposed solution demonstrated high efficiency in test conditions at construction sites: when using YOLO and ResNet-50 models, the detection accuracy of workers and

personal protective equipment reached 70–75 % (mAP@0.5), and the identification of violations exceeded 90 %. The integration of machine learning methods and cloud services ensures scalability and high performance in video stream analysis, but it requires consideration of network bandwidth and adherence to strict data protection requirements.

The further development of the system involves expanding the datasets to achieve a balanced representation of different object classes, as well as including new scenarios related to additional sensors (e.g., seismic) and complex shooting conditions. A promising direction is the study of modern computer vision architectures capable of improving detection and segmentation accuracy in real-time. At the same time, network infrastructure characteristics need to be considered, as working with multiple Full HD cameras simultaneously can generate data streams of tens of megabits per second. Therefore, it is important to use reliable wired Gigabit Ethernet connections or high-speed wireless solutions. As the system scales, special attention should be paid to information security and privacy: regular data backups and distributed storage must be implemented, as well as strict encryption and access control policies.

Thus, building an intelligent monitoring platform for construction sites requires a comprehensive approach: improving computer vision algorithms, integrating additional data sources, advancing network technologies, and ensuring cybersecurity. This approach will significantly enhance the efficiency and safety of construction processes, opening new opportunities for the digital transformation of the industry.

REFERENCES

- Hasirlioglu S., Riener A. (2020). Challenges in Object Detection Under Rainy Weather Conditions: Second EAI International Conference, INTSYS. — Guimarães, Portugal. Proceedings. From https://10.1007/978-3-030-14757-0_5. (in Eng.).
- Josh T., Rachel F., Alex R., Jonas S., Wojciech Z., Pieter A. (2017). Domain Randomization for Transferring Deep Neural Networks from Simulation to the Real World, from <https://10.48550/arXiv.1703.06907>. (in Eng.).
- Kozlovskaya M., Klosova D., Strukova Z. (2021). Article: Impact of Industry 4.0 Platform on the Formation of Construction 4.0 Concept: A Literature Review. Sustainability. — Basel, Switzerland. — Pp. 4–10. DOI: <https://doi.org/10.3390/su13052683> (in Eng.).
- Kaiming H., Georgia G., Piotr D., Ross G. (2017) "Mask R-CNN," IEEE International Conference on Computer Vision (ICCV). — Venice, Italy. — Pp. 770–778. DOI: <https://doi.org/10.1109/ICCV.2017.322>. (in Eng.).
- Kumar D., Muhammad N. (2023). Object Detection in Adverse Weather for Autonomous Driving through Data Merging and YOLOv8. — Basel, Switzerland. — Pp. 20–23. DOI: <https://doi.org/10.3390/s23208471>. (in Eng.).
- KPMG global tech report. — Retrieved 10 February. — 2025, from: <https://kpmg.com/xx/en/our-insights/ai-and-technology/kpmg-global-tech-report-2023.html> (in Eng.).
- Kaiming H., Xiangyu Zh., Shaoqing R., Jian S. (2016). Deep Residual Learning for Image Recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), from https://open-access.thecvf.com/content_cvpr_2016/html/He_Deep_Residual_Learning_CVPR_2016_paper.html (accessed: 10.02.2025) (in Eng.).
- Mingxing T., Quoc V.L. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In Proceedings of the 36th International Conference on Machine Learning (ICML). — Pp. 6105–6114. DOI: <https://doi.org/10.48550/arXiv.1905.11946> (in Eng.).
- Olaf R., Philipp F., Thomas B. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) Medical Image Computing and Computer-Assisted In-



tervention. — Springer, Cham. — Pp. 235–238. DOI: https://doi.org/10.1007/978-3-319-24574-4_28 (in Eng.).

Tahir N.U.A., Zhang Z., Asim M., Chen J., ELAffendi M.M. (2024). Object Detection in Autonomous Vehicles under Adverse Weather: A Review of Traditional and Deep Learning Approaches. *Algorithms*. — Basel, Switzerland. — Pp. 103. DOI: <https://doi.org/10.3390/a17030103> (in Eng.).

Tsung-Yi Lin, Michael Maire, Serge Belongie, Lubomir Bourdev, Ross Girshick, James Hays, Pietro Perona, Deva Ramanan, C. Lawrence Zitnick, Piotr Dollár (2014). Microsoft COCO: Common Objects in Context. *European Conference on Computer Vision (ECCV)*. — Pp. 740–755. from <https://arxiv.org/pdf/1405.0312> (in Eng.).

Tsung-Yi L., Michael M., Serge B., Lubomir B., Ross G., James H., Pietro P., Deva R., Lawrence Zitnick C., Piotr D. (2014). Microsoft COCO: Common Objects in Context. *European Conference on Computer Vision (ECCV)*. — Pp. 740–755. From <https://arxiv.org/pdf/1405.0312> (in Eng.).

Shaoqing R., Kaiming H., Ross G., Jian S. (2017). “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” in *IEEE Transactions on Pattern Analysis and Machine Intelligence*. — Pp. 1137–1149. DOI: <https://doi.org/10.1109/TPAMI.2016.2577031> (in Eng.).

Shalbolova U., Junussova A., Salykov A. (2023). Efficiency of Digitalization of Housing and Communal Services and Construction in Kazakhstan. — Pp. 3–5. DOI: https://doi.org/10.1007/978-981-99-4229-9_5. (in Eng.).

Vukicevic A.M., Petrovic M., Milosevic P. et al. (2024). A systematic review of computer vision-based personal protective equipment compliance in industry practice: advancements, challenges and future directions. *Artif Intell Rev* 57. — 319. — Pp. 2–6. DOI: <https://doi.org/10.1007/s10462-024-10978-x> (in Eng.).

Yuqing W., Zhaoliang X., Xinlong W., Chunhua S., Baoshan Ch., Hao S., Huaxia X. (2020). End-to-End Video Instance Segmentation with Transformers. <https://doi.org/10.48550/arXiv.2011.14503>. (in Eng.).

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 1. Number 22 (2025). Pp. 57–74

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.004>

INTELLIGENT MODEL FOR FINDING THE OPTIMAL ROUTE TO COVER ALL STREETS WITH MOVEMENT CONSTRAINTS

D. Yedilkhan, N. Khaimuldin, D. Ospanova, B. Amirgaliyev*

Astana IT University, Astana, Kazakhstan.

E-mail: n.khaimuldin@astanait.edu.kz

Didar Y. — PhD, professor, Head of the Smart City research center, Astana IT University, Astana, Kazakhstan

E-mail: d.yedilkhan@astanait.edu.kz, <https://orcid.org/0000-0002-6343-5277>;

Khaimuldin N. — MSc, senior-lecturer, «The Department of Computer Engineering», Astana IT University, Astana, Kazakhstan

E-mail: n.khaimuldin@astanait.edu.kz, <https://orcid.org/0000-0002-3767-4418>;

Ospanova D. — Master's student in Applied Data Analytics, «the Department of Computing and Data Science», Astana IT University, Astana, Kazakhstan

E-mail: 242982@astanait.edu.kz, <https://orcid.org/0009-0003-2405-2374>;

Amirgaliyev B. — PhD, professor, «the Department of Computer Engineering», Astana IT University, Astana, Kazakhstan

E-mail: beibut.amirgaliyev@astanait.edu.kz, <https://orcid.org/0000-0003-0355-5856>.

© D. Yedilkhan, N. Khaimuldin, D. Ospanova, B. Amirgaliyev, 2025

Abstract. This study presents the development of an intelligent routing model tailored for municipal service optimization, with a particular emphasis on snowplow deployment within the urban environment of Astana. The model integrates advanced Python libraries for data processing and visualization, alongside a mapping API selected through rigorous comparative analysis. The city's street network was reconstructed using topological and statistical attributes—such as segment lengths and intersection density—that are critical for efficient route optimization. The central routing challenge was framed as a variation of the Chinese Postman Problem and addressed through the implementation of key algorithms, including those of Dijkstra, Edmonds, and Hierholzer. This approach yielded an optimized traversal path that ensures full street coverage within the designated area while minimizing redundancy. The proposed solution demonstrably enhances route efficiency, thereby reducing superfluous



travel and contributing to improved municipal service planning. Prospective research will extend the model's capabilities to accommodate real-time dynamic routing and multi-vehicle coordination, supporting broader smart city applications.

Keywords: intelligent systems, GIS technologies, smart city, urban optimization, Chinese postman problem

For citation: D. Yedilkhan, N. Khaimuldin, D. Ospanova, B. Amirgaliyev. Intelligent model for finding the optimal route to cover all streets with movement constraints//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 57–74 (In Eng.). [HTTPS://DOI.ORG/10.54309/IJICT.2025.22.2.004](https://doi.org/10.54309/IJICT.2025.22.2.004)

Conflict of interest: The authors declare that there is no conflict of interest.

Funding information. This research was carried out with the financial support of the Committee of Science of the Ministry of Science and Higher Education of the Republic of Kazakhstan under Contract №107/KMU-5-24-26 dated 20.06.2024 under the scientific project IRN AP22784985 “Development of an intelligent software and hardware system for monitoring, visualization and analysis of urban data using mobile sensors”.

БАРЛЫҚ КӨШЕЛЕРДІ ҚОЗҒАЛЫС ШЕКТЕУЛЕРІМЕН ҚАМТУҒА АРНАЛҒАНОҢТАЙЛЫМАРШРУТТЫТАБУДЫҢИНТЕЛЛЕКТУАЛДЫ МОДЕЛІ

Д. Еділхан, Н. Хаймұльдин, Д. Оспанова, Б. Амиргалиев*

Astana IT University, Астана, Қазақстан.

E-mail: n.khaimuldin@astanait.edu.kz

Дидар Е. — PhD, профессор, Smart City ғылыми-зерттеу орталығының жетекшісі, Astana IT University, Астана, Қазақстан

E-mail: d.yedilkhan@astanait.edu.kz, <https://orcid.org/0000-0002-6343-5277>;

Хаймұльдин Н. — магистр, «Компьютерлік инженерия» департаментінің аға оқытушысы, Astana IT University, Астана, Қазақстан

E-mail: n.khaimuldin@astanait.edu.kz, <https://orcid.org/0000-0002-3767-4418>;

Оспанова Д. — «Деректерді қолданбалы талдау» бағдарламасының магистранты, «Есептеу және деректер ғылымы» департаменті, Astana IT University, Астана, Қазақстан

E-mail: 242982@astanait.edu.kz, <https://orcid.org/0009-0003-2405-2374>;

Амиргалиев Б. — PhD, «Компьютерлік инженерия» департаментінің профессоры, Astana IT University, Астана, Қазақстан

E-mail: beibut.amirgaliyev@astanait.edu.kz, <https://orcid.org/0000-0003-0355-5856>.

© Д. Еділхан, Н. Хаймұльдин, Д. Оспанова, Б. Амиргалиев, 2025



Аннотация. Қазіргі заманғы қалаларда көлік жүйесін оңтайландыру – коммуналдық қызметтердің тиімділігі мен тұрақтылығын арттырудың маңызды факторы. Бұл зерттеудің мақсаты – Астана қаласында қар тазалау көліктеріне арналған интеллектуалды бағыттау моделін әзірлеу. Модель Python тіліндегі талдау және визуализация құралдарын, сондай-ақ картографиялау API-сын пайдаланады. Қаланың көше желісі жолдардың ұзындығы мен қиылыстардың тығыздығы сияқты топологиялық және статистикалық сипаттамаларды ескере отырып құрылған. Бағытты оңтайландыру мәселесі қытай пошташысы есебіне негізделіп, Дейкстра, Эдмондс және Хайрхольцер алгоритмдері арқылы шешілді. Нәтижесінде көшелерді толық қамтитын және артық қозғалысты азайтатын тиімді маршрут құрылды. Бұл тәсіл қалалық қызметтердің жұмысын жетілдіруге мүмкіндік береді. Болашақта модельді нақты уақыттағы деректерді ескере отырып кеңейту және бірнеше көлік пен мақсаттар үшін бейімдеу жоспарлануда.

Түйін сөздер: Зияткерлік Жүйелер, ГАЗ Технологиялары, Ақылды Қала, Қалалық Оңтайландыру, Қытай Пошташы Есебі

Дәйексөздер үшін: Д. Еділхан, Н. Хаймульдин, Д. Оспанова, Б. Амиргалиев. Бейне барлық көшелерді қозғалыс шектеулерімен қамтуға арналған оңтайлы маршрутты табудың интеллектуалды моделі//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 57–74 бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.004>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

Алғыс: Бұл зерттеу Қазақстан Республикасы Ғылым және жоғары білім министрлігінің Ғылым комитетінің қаржылық қолдауымен 2024 жылғы 20 маусымдағы №107/КМУ-5-24-26 шарты бойынша AP22784985 «Мобильді сенсорлардың көмегімен қалалық деректерді бақылау, визуализациялау және талдау үшін интеллектуалды бағдарламалық-аппараттық жүйені әзірлеу» ғылыми жобасы аясында жүзеге асырылды.

ИНТЕЛЛЕКТУАЛЬНАЯ МОДЕЛЬ ПОИСКА ОПТИМАЛЬНОГО МАРШРУТА ПОКРЫТИЯ ВСЕХ УЛИЦ С ОГРАНИЧЕНИЯМИ ПО ПЕРЕМЕЩЕНИЯМ

Д. Едилхан, Н. Хаймульдин, Д. Оспанова, Б. Амиргалиев*

Astana IT University, Астана, Казахстан.

E-mail: n.khaimuldin@astanait.edu.kz

Едилхан Д. — PhD, профессор, руководитель НИЦ Smart City, Astana IT University, Астана, Казахстан
E-mail: d.yedilkhan@astanait.edu.kz, <https://orcid.org/0000-0002-6343-5277>;

Хаймульдин Н. — магистр, старший преподаватель департамента «Компьютерной инженерии», Astana



IT University, Астана, Казахстан

E-mail: n.khaimuldin@astanait.edu.kz, <https://orcid.org/0000-0002-3767-4418>;

Оспанова Д. — магистр образовательной программы «Прикладная аналитика данных», департамент вычислений и науки о данных, Astana IT University, Астана, Казахстан

E-mail: 242982@astanait.edu.kz, <https://orcid.org/0009-0003-2405-2374>;

Амиргалиев Б. — PhD, профессор, департамент «Компьютерной инженерии», Astana IT University, Астана, Казахстан

E-mail: beibut.amirgaliyev@astanait.edu.kz, <https://orcid.org/0000-0003-0355-5856>.

© Д. Едилхан, Н. Хаймульдин, Д. Оспанова, Б. Амиргалиев, 2025

Аннотация. В условиях современных городов оптимизация транспортных систем играет ключевую роль в повышении эффективности и устойчивости муниципальных служб. Цель данного исследования - разработка интеллектуальной модели маршрутизации для городских служб, с акцентом на применение для снегоуборочной техники в городе Астана. Модель интегрирует библиотеки Python для анализа и визуализации данных, а также картографическое API, выбранное после сравнительного анализа. Уличная сеть города была воссоздана с учетом топологических и статистических характеристик, таких как длина дорог и плотность перекрёстков. Задача маршрутизации была сформулирована как задача китайского почтальона и решена с применением алгоритмов Дейкстры, Эдмондса и Хайрхольцера. В результате был построен оптимизированный маршрут, обеспечивающий полное покрытие улиц с минимальными повторами. Решение позволяет сократить избыточные перемещения и повысить эффективность работы коммунальных служб. В дальнейшем планируется расширение модели для учёта динамических данных и масштабирования на многомашинные и многокритериальные задачи в контексте умных городов.

Ключевые слова: интеллектуальные системы, гис-технологии, умный город, оптимизация городской среды, задача китайского почтальона

Для цитирования: Д. Едилхан, Н. Хаймульдин*, Д. Оспанова, Б. Амиргалиев. Интеллектуальная модель поиска оптимального маршрута покрытия всех улиц с ограничениями по перемещениям // Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. №. 22. Стр. 57–74. (На русс.). <https://doi.org/10.54309/IJICT.2025.22.2.004>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Благодарность: исследование выполнено при финансовой поддержке Комитета науки Министерства науки и высшего образования Республики Казахстан в рамках договора №107/КМУ-5-24-26 от 20.06.2024 по научному про-

екту IRN AP22784985 «Разработка интеллектуальной программно-аппаратной системы мониторинга, визуализации и анализа городских данных с использованием мобильных датчиков».

Introduction

Modern cities face significant challenges in efficiently managing the movement of municipal and service vehicles tasked with covering large and complex urban areas. Traditional route planning methods often result in redundant travel, wasted resources, and delayed services due to their inability to adapt to dynamic constraints such as time windows, traffic, and partial accessibility. This leads to increased operational costs, inefficient use of manpower, and environmental impact.

The idea of the research is to develop a model that allows for covering all streets and key points in the city of Astana with minimal travel. Using the developed method, the system enables significant cost and time savings when applied to practical tasks such as planning the routes for snowplows, dynamically measuring air quality indicators, watering city plants, and many others.

The main goal is to develop an intelligent system for finding the optimal route to cover multiple points in the city of Astana, considering time constraints and possible movement limitations. This research is part of the broader Smart City initiative, which includes tasks related to intelligent systems, optimal route search problems, work with GIS technologies, and data analysis.

In this research, the focus is on creating optimal transport routes across the city of Astana. This will allow for the actualization and integration of data from different systems in one place, helping to solve optimization tasks that are crucial for practical applications. These applications include, but are not limited to, determining snowplow routes, dynamically monitoring air quality, optimizing plant watering schedules, and many more.

The novelty of this work lies in the development of an efficient system for solving smart city problems, such as determining optimal routes for covering a single region of the city, with demonstrated practical impact.

Literature Review

Urbanization is rapidly transforming global demographics. According to the United Nations' report, more than half of the world's population now lives in urban areas, and this figure is expected to rise to 70 percent by 2050 (United Nations, 2023: 34). This trend calls for sustainable urban management using modern information and communication technologies.

One strategic response is the Smart City concept, which integrates information and communication technologies to address these challenges. Many challenges in smart cities can be framed as classical mathematical problems solvable with modern technologies, such as artificial intelligence (AI) and optimization methods used in mathematics, computer science, and economics. Optimization helps solve complex problems by identifying the best solution from a range of alternatives while considering urban constraints. One of the most important applications of AI and optimiza-

tion in urban environments is the transportation problem - a classical linear programming problem that seeks the most efficient distribution of resources while minimizing transportation costs. As automated systems become more common and more data is constantly being produced, these classic problems have become useful and relevant again in real-world situations. A key area where optimization plays a crucial role in smart cities is transportation management.

In the transportation problem, mathematical models are used to determine routes with minimal cost and maximal safety by accounting for transportation expenses, time constraints, and other limitations between sources and destinations. In simple terms, these models aim to improve safety and reduce costs by controlling key influencing factors. Multi-objective decision-making in transportation tasks can be achieved using AI, mathematical modeling, and heuristic search algorithms such as genetic algorithms. For example, AI techniques enable models to adapt route planning in the presence of dynamic disruptions, such as weather conditions and accidents (Prakash et al., 2024: 172094).

In most cases, the goal of transportation optimization is to minimize overall transportation costs (Prifti et al., 2020: 5; Malacký & Madleňák, 2023: 323–329). The origins of the transportation problem can be traced back to the work of Newton, Leibniz, and Lagrange in the 18th and 19th centuries, with the foundations of modern linear programming laid by French mathematicians such as Jean-Baptiste and Joseph Fourier. Numerous researchers have since contributed to advancing transportation optimization through real-world applications and simulation tools. Kukharchyk, for example, applied mathematical models to cost optimization in transportation tasks, underlining the importance of constraints when shipment volumes are predetermined (Cao, 2022: 2). Mojtahedi et al. proposed a coordinated vehicle routing framework for solid waste management that optimizes financial, environmental, and social objectives (Mojtahedi et al., 2021: 100220). However, these studies do not provide a concrete case study based on real-world data. Yao et al. address the scheduling problem of electric buses with multiple vehicle types, considering range, charging time, and energy use, and present a case study on a real-world transit network in Beijing (Yao et al., 2019: 101862). Also, Gunawan et al. studied the optimization of shipping routes for container ships operating between Indonesia and the Asia-Pacific region (Gunawan et al., 2023: 1360). They used and compared different heuristic algorithms to solve a route optimization problem where fuel costs were minimized.

While traditional methods have provided valuable insights, modern urban logistics have increasingly shifted towards machine learning techniques such as reinforcement learning. (RL). This is a type of machine learning where an agent learns to make decisions by interacting with an environment. The goal is to maximize a reward signal over time. For instance, Khaidem et al. use human mobility data to train and evaluate policies in a realistic simulation environment, where their RL algorithm approximates the system dynamics and finds optimal traffic policies (Khaidem et al., 2020: 171528–171541). Another study shows that deep reinforcement learning can effectively reduce delivery time by optimizing delivery routes (Xing & Cai, 2020:

334–338). Phiboonbanakit et al. combine a reinforcement learning model with a tree-based regression model to evaluate route feasibility based on the current state and action, enabling the RL agent to adjust its decisions for optimal vehicle routing (Phiboonbanakit et al., 2021: 163325–163347). However, the proposed methodology is limited by its reliance on stored experiences, which may be ineffective for unfamiliar event patterns and insufficient for handling uncertainties such as demand, vehicle utility, and productivity.

One of the fundamental challenges in urban route planning involves covering multiple locations while accounting for operational constraints such as travel efficiency and resource limitations. This challenge is formally recognized in mathematics as the Chinese Postman Problem, or Route Inspection Problem, which focuses on determining a traversal of all edges in a network with minimal repetition and cost. Solving the CPP in real-world conditions is complex, requiring consideration of various factors that affect optimal route design and operating costs. Examples include the number of vehicles needed, the presence of dead-end streets, fuel consumption, road conditions, and time-dependent constraints (Rao et al., 2011: 2785–2790). To address this combinatorial optimization challenge, mathematical techniques can serve as powerful tools for generating effective and efficient routes. Matsuura and Takazawa introduced a heuristic algorithm for the Maximum Benefit CPP that reflects practical needs by prioritizing streets with higher service value, even if they must be traversed more than once (Matsuura & Takazawa, 2022: 1283–1291). Another study by Li et al. addressed the complex challenge of delivering emergency supplies when multiple disasters occur simultaneously (Li et al., 2024). It proposed a vehicle routing system that prioritizes deliveries based on the urgency of demand, ensuring that items with higher urgency are distributed first. Such prioritization is especially valuable in scenarios where both urgency and resource optimization are significant.

One of the most practical urban applications of the Chinese Postman Problem is snow removal, where the objective is to cover all streets with the fewest possible passes. Previous studies, such as Sullivan et al. combined network clustering and vehicle routing with capacity limits to improve coverage during snow and ice events (Sullivan et al., 2019: 18–31). Another approach is using the tabu search algorithm to optimize snowplow routing (Xu et al., 2022: 199–211). While effective in certain scenarios, these methods often fail to fully reflect real-world constraints. Additional factors such as one-way streets, turn restrictions, and varying traffic conditions also significantly influence the structure and efficiency of route planning.

This research project seeks to propose a more advanced and practical route optimization strategy tailored to municipal operations in Astana, with a focus on snow removal. The methodology incorporates the Chinese Postman Problem and applies a linear algorithm to generate initial routes and shortest paths (Siloi et al., 2021). By integrating operational constraints, the goal is to identify cost-effective routing solutions that address the limitations of existing methods.

Data Collection

As a first step in this research project, it was essential to gather up-to-date and detailed information on the street network of Astana. This data is crucial for building, analyzing, and visualizing the city's street layout accurately. To achieve this, various mapping APIs were reviewed and compared to select the most suitable one for the project. The selection of the most appropriate mapping API was based on several criteria, including data completeness and accuracy, ease of use and integration with other tools, and overall cost-effectiveness—especially since many services require paid access.

Among the most widely used APIs are Google Maps, Yandex Maps, 2GIS, Mapbox, OpenStreetMap (OSM), Bing Maps, and ArcGIS. Each of these APIs comes with its own strengths and limitations in terms of data accessibility, accuracy, and pricing.

The main drawback of using the 2GIS API for the project's research tasks was the limitation on the number of requests (no more than 3,000) and the short duration of the free version (3 months), which necessitated payment to increase the request quota and ensure continuous access. Additionally, 2GIS is primarily focused on providing data about businesses and reviews, whereas the research required more detailed routing information, along with the ability to develop and integrate custom algorithms with maps for the city of Astana. Similarly, the Mapbox API presented challenges due to the complexity of working with its interface components. Despite its capabilities, the difficulty in navigating and utilizing the various components made it less ideal for the project's specific needs. Given these limitations, OpenStreetMap API emerged as the preferred solution for the project. It offers a powerful, flexible, and open-source tool for geographic data, which aligns with the research objectives. Its ease of use and ability to provide the necessary data in a convenient format made it the most suitable choice for the project's requirements.

For visualizing the road network of Astana, the OSMnx Python library (v1.6.0) was used for spatial analysis and visualization. The NetworkX library was also employed to analyze network structure through metrics such as centrality, connectivity, and shortest paths. Together with OSMnx, NetworkX enhances the analytical capacity for complex urban networks. Astana's street network was visualized in two different color schemes using `graph_from_place()` for the entire city.

For detailed statistical analysis, the graph was first converted into a geospatial dataset using the `osmnx.graph_to_gdfs()` function. This function allows extraction of either nodes, edges, or both as GeoDataFrames, enabling comprehensive analysis of intersections and street segments. The resulting dataset contains numerous columns, most of which correspond to OpenStreetMap tags. For instance, the columns `u` and `v` represent the start and end nodes of each edge, reflecting the network's topology. Additional attributes include bridge presence, number of lanes, edge length, speed limits, street names, directionality, and more.




Fig. 1. Graph of the City of Astana in Different Color Palettes

The `graph_from_bbox` function is used to generate street network data within a specified bounding box, while the `graph_from_point` function allows for visualizing a street network graph centered on a specific geographic point within a defined distance in meters. An example of filtering the city graph to display only the Expo district of Astana is shown below. To make the visualization more intuitive, various color elements can be applied to the graph's nodes and edges.




Fig. 2. A filtered Graph of Astana from the Point 51.0975, 71.4176 with a Distance of 1,250 meters

In the extracted street network graph of the entire city of Astana, there are a total of 18,091 edges, all of which are tagged. The distribution of edge types is presented in Table 2. The raw data is complex, so it needs preprocessing before we can fully understand or analyze it.

A total of 7,445 nodes are present in the Astana street network. Of these, 595 are marked as specific features: 581 as `traffic_signals` or city intersections, 10 as `motorway_junctions`, 3 as `crossings`, and 1 as a `milestone`.

Table 1. Distribution of Edges (Streets) by Type in Astana

Edge Type (Original OSM Name)	Count
Residential	11,931
secondary	1,984
tertiary	1,728
unclassified	1,301
primary	453
secondary_link	240
tertiary_link	128
trunk	125
primary_link	112
trunk_link	60
[unclassified, residential]	8
[tertiary, residential]	8
living_street	2
[tertiary, secondary]	2
[secondary, residential]	2
[residential, living_street]	2
[motorway, trunk]	2
road	2
motorway	1

Methodology

The problem of finding a route that covers all streets originates from graph theory, specifically the famous Seven Bridges of Königsberg problem, where the objective is to find a route that traverses every edge exactly once (Susitha, 2023). However, in most real-world scenarios, the graph is not Eulerian, meaning it is impossible to visit each street just once without repetition. A Eulerian graph is a graph containing a closed walk that includes every edge exactly once (Deo, 2016). Therefore, finding an optimal route can be reframed as the more general and well-known Chinese Postman Problem with the goal is to visit every street in a certain district or across an entire city at least once. An algorithm is needed to accomplish this efficiently and avoid unnecessary detours or multiple traversals of the same street. The desired solution is an optimal route that covers every edge at least once while minimizing the total length of the journey. To solve this, the research project employed a method based on minimum matching, as proposed by Edmonds and Johnson (Edmonds & Johnson, 1973: 88–124). Their work leverages matching theory to identify an optimal graph structure that supports a Eulerian tour.

In most real-world urban networks, such as Astana's street map, the corresponding graph is not Eulerian, meaning that not all vertices have an even degree. This makes a direct traversal without edge duplication impossible. The key idea behind this solution is to transform the graph into a Eulerian multigraph by duplicating

certain edges. The goal is to identify the minimum set of additional edges required to ensure that all vertex degrees become even, thus making it possible to compute a Eulerian circuit. The algorithm is visualized below:




Fig. 3. Block Diagram of the Chinese Postman Problem

The process begins by identifying all vertices with an odd degree (Step 1). Since a Eulerian circuit can only exist if all vertex degrees are even, these odd-degree vertices must be paired in a way that balances the graph. In Step 2, the shortest paths between all pairs of odd-degree vertices are computed using Dijkstra's algorithm, which is suitable for real road networks with non-negative edge weights. These shortest paths are then used to construct a complete weighted graph (Step 3), where each vertex corresponds to an odd-degree vertex from the original graph, and edge weights represent the distance of the shortest path between them. In Step 4, we apply Edmonds' algorithm to find a minimum-weight perfect matching on this complete graph. The result is a set of disjoint pairs of odd-degree vertices such that the total weight of the added paths is minimized. For each matched pair, the corresponding shortest path is duplicated in the original graph (Step 5). This ensures that all vertices now have even degrees, resulting in a Eulerian multigraph. Finally, Hierholzer's algorithm was applied (Step 6) to generate the Eulerian circuit. The Hierholzer algorithm requires certain conditions to be met – specifically, the graph must be connected, and all nodes must have even degrees. It proceeds as follows:

1. Select any vertex as the current node to start the traversal
2. While the current vertex has unused edges:
 - a. Select one of the unused edges
 - b. Traverse to the adjacent vertex
 - c. Remove the traversed edge from the graph
3. If the current vertex has no unused edges, push it onto a stack
4. If the stack is not empty, pop a vertex from the stack and make it the current vertex.
5. Repeat steps 2–4 while there are vertices in the stack.

The algorithm starts at any vertex and moves along unused edges to connected vertices, removing each edge after it is used. When there are no unused edges left at the current vertex, it is saved on a stack, and the algorithm backtracks by returning to previous vertices from the stack. This process continues until all edges have been visited exactly once. It produces a path sequence that ensures every edge (including the added duplicates) is traversed exactly once.

Algorithm 1. Chinese Postman Problem

Input: $G(V, E)$ – an undirected graph representing the street network

Output: circuit – a minimal-cost Eulerian tour covering all original edges of G

Procedure:

1. Identify all vertices with odd degree:
 $\text{odd_vertices} \leftarrow \emptyset$
 for each vertex $v \in V$:
 if $\text{degree}(v) \bmod 2 \neq 0$:
 add v to odd_vertices
2. Compute shortest paths between all pairs of odd-degree vertices (Cormen et al., 2022):
 $\text{distances} \leftarrow \infty$
 for each vertex $u \in \text{odd_vertices}$:
 $\text{distances}[u] \leftarrow \text{Dijkstra}(G, u)$
3. Construct a completely weighted graph K over odd_vertices :
 $K \leftarrow \text{new Graph}()$
 for each pair $(u, v) \in \text{odd_vertices}, u \neq v$:
 $\text{weight} \leftarrow \text{distances}[u][v]$
 $K.\text{add_edge}(u, v, \text{weight})$
4. Find a minimum-weight perfect matching M in graph K (using Edmonds' algorithm) (Galil, 1986: 23–38):
 $M \leftarrow \text{MinimumWeightMatching}(K)$
5. Duplicate the shortest paths corresponding to matched pairs in G :
 for each $(u, v) \in M$:
 $\text{path} \leftarrow \text{shortest_path between } u \text{ and } v \text{ in } G$
 for each edge e in path :
 duplicate edge e in G
6. Apply Hierholzer's algorithm to construct a Eulerian circuit (Kronegger, 2016):
 $\text{circuit} \leftarrow \text{Hierholzer}(G)$

To validate the proposed algorithm, we applied it to a selected region of the city of Astana, focusing on a 750-meter radius around the “Triumphal Arch” area on the left bank. The original street graph was derived from OpenStreetMap data using the OSMnx library and converted into an undirected format to allow bidirectional traversal. This conversion is particularly important in real-world networks where one-way streets could disrupt Eulerian traversal.

In the initial stage, 62 vertices with odd degrees were identified in the subgraph. This set of vertices defined the scope for the matching problem. Using the NetworkX implementation of Dijkstra’s algorithm, shortest paths were computed between every pair of these odd-degree nodes. The results were then used to construct a complete auxiliary graph, where the weight of each edge represented the length of the corresponding shortest path in the original network.

To determine the optimal set of edge duplications, a custom implementation of Edmonds’ algorithm was employed to find the minimum-weight perfect matching. Each matched pair represented a pair of odd-degree nodes to be connected via duplicated paths. These paths were then traced and added back to the original graph, transforming it into a valid Eulerian multigraph.

This methodology is highly adaptable and can be applied to various municipal services such as snow removal, street cleaning, or delivery routing, where complete street coverage with minimal redundancy is essential. For example, in snow plowing activities, it ensures all streets are plowed without unnecessarily repeating any of them, which saves time and gasoline. Similarly, for street sweeping, the approach helps in optimizing sweeping routes for covering all the roads systematically while minimizing overlap. In delivery routing, the method helps in designing routes that cover all the required locations with minimal backtracking, improving the speed of service and reducing the expense of operations. Overall, by eliminating duplicated travel, the method improves the utilization of resources, lowers emissions, and increases the efficiency of public service operations in smart cities.

Results

The algorithm of solving Chinese Postman Problem is demonstrated on a selected area of the left bank of Astana, centered around the “Triumphal Arch” (51.10415184350422, 71.42986881334336), including all nearby streets and cross-roads within a 750-meter radius. For simplicity, the original directed multigraph was converted into an undirected graph, allowing bidirectional traversal on one-way streets.

As the first step in the algorithm outlined earlier, we begin by identifying all nodes with an odd degree using the `graph.degree()` function to automate this process. As a result, we found 62 nodes in the graph that have an odd degree.

The next step involved calculating the shortest distances between each pair of these odd-degree nodes. For this, we used Dijkstra’s algorithm — a well-known and widely applied method, particularly effective for computing shortest paths in road networks. Specifically, we employed the `nx.dijkstra_path_length()` function from the NetworkX library, feeding in all possible combinations of the odd-degree nodes. The

output provided the shortest path lengths for each unique pair of nodes, which we will refer to in the following steps.

Next, using the previously obtained list of weighted edges a complete graph is constructed, and a minimum weight matching is found. To achieve this, a custom function was developed. It takes the list of weighted node pairs as input and returns a matched list of edges with their corresponding weights. The output of this function is a set of optimal pairings that minimizes the total added distance.

To provide a more intuitive visualization of the resulting graph, the matched nodes are displayed on a plot, with different colors used to distinguish the pairs in the matched graph.




Fig. 4. Graph Within a 750-Meter Radius Around the “Triumphal Arch” Point


Next, it is necessary to list all edges of the augmented graph, including both the original edges and those added during the minimum matching step. In other words, the nodes from both graphs are represented as edges using OSMnx identifiers, which are expressed as integers ranging from zero to the total number of nodes. The result is a list of node pairs, such as (0, 43), (0, 20), (0, 2), (1, 3), (1, 4), (1, 66), and so on.

After this step, the Eulerian path is computed using the Hierholzer algorithm (also known as Eulerian circuit traversal). This algorithm constructs a path that visits every edge in the graph exactly once. The output of the Hierholzer algorithm is a sequence of integers, where each number represents a vertex in the graph—for example: 0, 43, 74, 77, 42, 41, 51, 52, 34, 51, 34, 35, 25, 24, and so on. This resulting sequence is then converted back into the OSMnx node ID format and can be visualized on the map. An excerpt of the final traversed path through the graph is shown in Table 2 as a set of node pairs.

To provide a more dynamic visualization, 14 intermediate steps of the graph traversal are shown below, as the full traversal involves many steps.

Table 2. Final Graph Traversal Path

From	To
1773441975	1773441979
1773441979	1773441975
1773441975	2639882499
2639882499	1773441998
1773441998	2639882499
2639882499	5263395275
5263395275	5263395273
5263395273	5263395275
5263395275	5263395272






Fig. 5. Step-By-Step Traversal of the Graph

The implemented algorithm successfully generated an optimal route that efficiently covers all streets in the target city area with minimal total travel distance. By framing the problem as a Chinese Postman Problem and applying the Edmonds and Johnson solution, the method effectively constructed a Eulerian multigraph that accounts for necessary edge duplications. This allowed the identification of a Eulerian trail representing the most efficient traversal sequence. The resulting route ensures full coverage of the street network while minimizing redundant travel, demonstrating the practical effectiveness of the proposed approach in urban route optimization.

Conclusion

The study contributes to the field of route optimization under constraints by developing an intelligent model for identifying an optimal route that covers all streets in the city of Astana, while accounting for real-world movement limitations. The algorithm, tested on real geospatial data, showed promising results and holds potential for improving urban transport planning, logistics, and infrastructure maintenance.

This model has several impactful applications. In the public sector, it can assist city planners and municipal services in optimizing street cleaning, snow removal, garbage collection, and road inspection operations, especially in cities facing extreme climates or rapid urban development like Astana.

However, the model has certain limitations. It assumes static conditions and does not yet incorporate dynamic factors such as real-time traffic, weather conditions, or road closures. Additionally, it does not currently account for resource constraints like vehicle fuel consumption, driver working hours, or the number of available ve-

hicles.

Future research could focus on extending the model to dynamic routing scenarios, integrating real-time data streams, and developing multi-vehicle or multi-objective optimization versions. Furthermore, future research could explore the scalability of the proposed approach to other cities with different urban structures and transportation needs.

With further development, the model has the potential to grow into a powerful tool for supporting smart city operations by helping cities deliver services more efficiently, lessen their environmental footprint, and make everyday urban life more comfortable and sustainable for residents.

REFERENCES

- Cao J. (2022). Mathematical model and algorithm of Multi-Index transportation problem in the background of artificial intelligence. — *Journal of Advanced Transportation*, 2022. — 1–11. <https://doi.org/10.1155/2022/3664105>
- Cormen T.H., Leiserson C.E., Rivest R.L. & Stein C. (2022). Introduction to algorithms (4th ed.). The MIT Press.
- Deo N. (2016). Graph theory with applications to engineering and computer science. Courier Dover Publications.
- Edmonds J. & Johnson E.L. (1973). Matching, Euler tours and the Chinese postman. *Mathematical Programming*. — 5(1). — 88–124. <https://doi.org/10.1007/bf01580113>
- Galil Z. (1986). Efficient algorithms for finding maximum matching in graphs. *ACM Computing Surveys*. — 18(1). — 23–38. <https://doi.org/10.1145/6462.6502>
- Gunawan Utomo A., Pambudi G., Hamada K. & Yanuar. (2023). Optimization of shipping routes for container ships from Indonesia to the Asia-Pacific using heuristic algorithms. — *Journal of Marine Science and Engineering*. — 11(7). — 1360. <https://doi.org/10.3390/jmse11071360>
- Khaidem L., Luca M., Yang F., Anand A., Lepri B. & Dong W. (2020). Optimizing transportation dynamics at a city-scale using a reinforcement learning framework. *IEEE Access*. — 8. — 171528–171541. <https://doi.org/10.1109/access.2020.3024979>
- Kronegger M. (2016, March 11). Algorithms in graph theory. TU Wien. https://www.dbai.tuwien.ac.at/staff/kronegger/misc/AlgorithmsInGraphTheory_Script.pdf
- Li R., Ye X., Pei S., Yan X., Wang T., Chen J. & Zheng P. (2024). Optimization of vehicle routing problems combining the demand urgency and road damage for multiple disasters. *Journal of Safety Science and Resilience*. <https://doi.org/10.1016/j.jnlssr.2024.11.001>
- Malacký P. & Madleňák R. (2023). Transportation problems and their solutions: Literature review. *Transportation Research Procedia*. — 74. — 323–329. <https://doi.org/10.1016/j.trpro.2023.11.151>
- Matsuura S. & Takazawa K. (2022). An improved heuristic algorithm for the maximum benefit Chinese postman problem. *RAIRO - Operations Research*. — 56(3). — 1283–1291. <https://doi.org/10.1051/ro/2022044>
- Mojtahedi M., Fathollahi-Fard A.M., Tavakkoli-Moghaddam R. & Newton S. (2021). Sustainable vehicle routing problem for coordinated solid waste management. *Journal of Industrial Information Integration*. — 23. — 100220. <https://doi.org/10.1016/j.jii.2021.100220>
- Phiboonbanakit T., Horanont T., Huynh V. & Supnithi T. (2021). A hybrid reinforcement learning-based model for the vehicle routing problem in transportation logistics. *IEEE Access*. — 9. — 163325–163347. <https://doi.org/10.1109/access.2021.3131799>
- Prakash S., Mehta U. & Sharma B. (2024). Artificial intelligence-driven multimodal route planning: Addressing dynamic unavailability and disruptions. *IEEE Access*. — 12. — 172088–172100. <https://doi.org/10.1109/ACCESS.2024.3498863>
- Prifti V., Dervishi I., Dhoska K., Markja I. & Pramono A. (2020). Minimization of transport costs in an industrial company through linear programming. In *IOP Conference Series: Materials Science and Engineering*. — 909(1). — 012040. <https://doi.org/10.1088/1757-899x/909/1/012040>
- Rao T., Mitra S., Zollweg J. & Sahin F. (2011). Computing optimal snowplow route plans using genetic algorithms. In *IEEE International Conference on Systems, Man, and Cybernetics*. — 2785–2790. <https://doi.org/10.1109/SMC.2011.6081000>

org/10.1109/icsmc.2011.6084094

Siloi I., Carnevali V., Pokharel B., Fornari M. & Di Felice R. (2021). Investigating the Chinese postman problem on a quantum annealer. *Quantum Machine Intelligence*. — 3(1). <https://doi.org/10.1007/s42484-020-00031-9>

Sullivan J.L., Dowds J., Novak D.C., Scott D.M. & Ragsdale C. (2019). Development and application of an iterative heuristic for roadway snow and ice control. *Transportation Research Part A: Policy and Practice*. — 127. — 18–31. <https://doi.org/10.1016/j.tra.2019.06.021>

Susitha S. (2023). The seven bridges of Königsberg–Euler’s solution. *Journal of Nonlinear Analysis and Optimization*. — 14(2).

United Nations Department of Economic and Social Affairs. (2023). The Sustainable Development Goals Report 2023: Special edition. United Nations. <https://unstats.un.org/sdgs/report/2023/The-Sustainable-Development-Goals-Report-2023.pdf>

Xing E. & Cai B. (2020). Delivery route optimization based on deep reinforcement learning. In *2020 2nd International Conference on Machine Learning, Big Data and Business Intelligence*. — 334–338. <https://doi.org/10.1109/mlbdi51377.2020.00071>

Xu S., Wu M., Kwon T.J. & Perchanok M. (2022). Optimization models for snowplow routes and depot locations: A real-world implementation. *Transportation Research Record*. — 2676(7). — 199–211. <https://doi.org/10.1177/03611981221077264>

Yao E., Liu T., Lu T. & Yang Y. (2019). Optimization of electric vehicle scheduling with multiple vehicle types in public transport. *Sustainable Cities and Society*. — 52. — 101862. <https://doi.org/10.1016/j.scs.2019.101862>

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 2. Number 22 (2025). Pp. 75–90

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.005>

УДК 004.931

SIGNIFICANT FACTORS ANALYSIS USING SHAP AND PCA FOR OPTIMIZING AGRICULTURAL RESOURCE MANAGEMENT

A. Ignatovich^{1}, A.S. Yesengeldina¹, L.T. Kurmangaziyeva²,
S.R. Sharmukhanbet², A.M. Nedzved³*

¹Academy of Public Administration under the President of the Republic of
Kazakhstan, Astana, Kazakhstan;

²Kh. Dosmukhamedov Atyrau University, Atyrau, Kazakhstan;

³Belarusian State University, Minsk, Belarus.

E-mail: anaressengeldina344@gmail.com

Ignatovich A. — Academy of Public Administration under the President of the Republic of Kazakhstan, Astana, Kazakhstan

E-mail: 01@abi.kz, <https://orcid.org/0009-0006-2051-3710>;

Yesengeldina A. — Academy of Public Administration under the President of the Republic of Kazakhstan, Astana, Kazakhstan

E-mail: anaressengeldina344@gmail.com, <https://orcid.org/0000-0002-7752-916X>;

Kurmangaziyeva L. — Kh. Dosmukhamedov Atyrau University, Atyrau, Kazakhstan

E-mail: kurmangazieval@mail.ru, <https://orcid.org/0000-0003-0640-7306>;

Sharmukhanbet S. — Kh. Dosmukhamedov Atyrau University, Atyrau, Kazakhstan

E-mail: s.sharmukhanbet@asu-edu.kz, <https://orcid.org/0000-0003-4417-0485>;

Nedzved A. — Doctor of Technical Sciences, associate professor, professor of the «Department of Computer Technologies and Systems», Faculty of Applied Mathematics and Informatics, Minsk, Republic of Belarus

E-mail: anedzved@bsu.by, <https://orcid.org/0000-0001-6367-5900>.

© A. Ignatovich, A.S. Yesengeldina, L.T. Kurmangaziyeva, S.R. Sharmukhanbet, A.M. Nedzved, 2025.

Abstract. This paper presents the development and generation of a synthetic dataset for modeling and predicting court case outcomes in the Republic of Kazakhstan, utilizing machine learning methodologies. The dataset, constructed on the basis of articles from the Code of the Republic of Kazakhstan, encompasses a broad range of criminal and administrative offenses. It comprises 100,000 cases, each annotated with various attributes, including the age of the defendant, degree of culpability, and the presence of mitigating or aggravating circumstances. This dataset serves as a foundational resource for constructing predictive models aimed at analyzing and forecasting judicial outcomes. The paper provides a detailed account of the data generation process and examines the performance of multiple machine learning algorithms applied to the prediction of court decisions. The relevance of this research is underscored by the pressing need to automate legal enforcement processes and



enhance the accuracy of judicial outcome forecasting in Kazakhstan. Traditional analytical approaches are often constrained by high temporal and resource demands and further hindered by the confidentiality of real-world legal data. The use of synthetic data generated in accordance with national legislation enables the identification of legal patterns and the development of effective predictive models, thereby contributing to the advancement of law enforcement practices. The primary objective of the study is to construct a comprehensive and representative dataset to support the analysis of judicial proceedings.

Key words: Machine learning, deep learning, data modeling, court decision prediction, artificial intelligence

For citation: A. Ignatovich, A.S. Yesengeldina, L.T. Kurmangaziyeva, S.R. Sharmukhanbet, A.M. Nedzved. Significant factors analysis using shap and pca for optimizing agricultural resource management//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 75–90 (In Kaz.). <https://doi.org/10.54309/IJICT.2025.22.2.005>.

Conflict of interest: The authors declare that there is no conflict of interest.

МАШИНАЛЫҚ ОҚЫТУ КӨМЕГІМЕН ҚАЗАҚСТАНДАҒЫ СОТ ШЕШІМДЕРІН БОЛЖАУҒА АРНАЛҒАН ДЕРЕКТЕРДІ ҚҰРУ

А. Игнатович^{1}, А.С. Есенгельдина¹, Л.Т. Курмангазиева²,
С.Р. Шармұханбет², М.У. Худойбергенов³*

¹ Қазақстан Республикасы Президенті жанындағы Мемлекеттік басқару академиясы, Астана, Қазақстан;

²Х. Досмұхамедов атындағы Атырау университеті, Атырау, Қазақстан;

³Беларусь мемлекеттік университеті, Минск, Беларусь.

E-mail: anaressengeldina344@gmail.com

Игнатович А. — Қазақстан Республикасы Президенті жанындағы Мемлекеттік басқару академиясы, Астана, Қазақстан

E-mail: 01@abi.kz, <https://orcid.org/0009-0006-2051-3710>;

Есенгельдина А. — Қазақстан Республикасы Президенті жанындағы Мемлекеттік басқару академиясы, Астана, Қазақстан

E-mail: anaressengeldina344@gmail.com, <https://orcid.org/0000-0002-7752-916X>;

Курмангазиева Л. — Х. Досмұхамедов атындағы Атырау университеті, Атырау, Қазақстан Республикасы

E-mail: kurmangazieval@mail.ru, <https://orcid.org/0000-0003-0640-7306>;

Шармұханбет С. — Х. Досмұхамедов атындағы Атырау университеті, Атырау, Қазақстан Республикасы

E-mail: s.sharmukhanbet@asu-edu.kz, <https://orcid.org/0000-0003-4417-0485>;

Недзьведь А. — т.ғ.д., доцент, «Қолданбалы математика және информатика факультетінің Компьютерлік технологиялар және жүйелер» кафедрасының профессоры, Беларусь Республикасы, Минск қаласы

E-mail: anedzved@bsu.by, <https://orcid.org/0000-0001-6367-5900>.

© А. Игнатович, А.С. Есенгельдина, Л.Т. Курмангазиева, С.Р. Шармұханбет, А.М. Недзьведь, 2025

Аннотация. Бұл жұмыста машиналық оқыту әдістерін қолдана отырып, Қазақстандағы сот істерінің нәтижелерін модельдеу және болжау

үшін деректер жинағы әзірленді және қалыптастырылды. «Қазақстан Республикасы Кодексінің» баптары негізінде жасалған деректер әртүрлі қылмыстық және әкімшілік құқық бұзушылықтарды қамтиды. Деректер жиынтығы айыпталушының жасы, кінә дәрежесі, жауаптылықты жеңілдететін және ауырлататын мән-жайлар сияқты әртүрлі атрибуттары бар 100 000 істі қамтиды. Бұл құқықтық нәтижелерді талдау және болжау үшін қолданылатын болжамды үлгілерді әзірлеуге негіз болды. Мақалада деректерді генерациялау әдістері және сот істерінің нәтижелерін болжау үшін әртүрлі машиналық оқыту алгоритмдерін қолдану нәтижелері егжей-тегжейлі қарастырылады. Зерттеудің өзектілігі Қазақстандағы құқық қолдану процестерін автоматтандыру және сот істерінің нәтижелерін болжау дәлдігін арттыру қажеттілігімен түсіндіріледі. Дәстүрлі талдау әдістері айтарлықтай уақыт пен ресурстық шығындарды талап етеді, сонымен қатар нақты деректердің құпиялылығымен қиындайды. Қазақстан Республикасының заңнамасының негізінде қалыптастырылған деректерді пайдалану заңдылықтарды зерделеуге және болжау үлгілерін әзірлеуге мүмкіндік береді, бұл құқық қолдану тәжірибесінің тиімділігін арттырады. Зерттеудің мақсаты – сот істерін талдау үшін жинақталған деректер жинағын құру.

Түйін сөздер: Машиналық оқыту, терең оқыту, деректерді модельдеу, сот шешімдерін болжау, жасанды интеллект

Дәйексөздер үшін: А. Игнатович, А.С. Есенгельдина, Л.Т. Курмангазиева, С.Р. Шармуханбет, А.М. Недзьведь. Машиналық оқыту көмегімен қазақстандағы сот шешімдерін болжауға арналған деректерді құру//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 75–90 бет. (қазақ тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.005>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

ГЕНЕРАЦИЯ ДАННЫХ ДЛЯ ПРОГНОЗИРОВАНИЯ СУДЕБНЫХ РЕШЕНИЙ В КАЗАХСТАНЕ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

А. Игнатович¹, А.С. Есенгельдина¹, Л.Т. Курмангазиева²,
С.Р. Шармуханбет², А.М. Недзьведь³*

¹Академия государственного управления при Президенте Республики Казахстан, Астана, Казахстан;

²Атырауский университет имени Х. Досмухамедова, Атырау, Казахстан;

³Белорусский государственный университет, Минск, Беларусь.

E-mail: anaressengeldina344@gmail.com

Игнатович А. — Академия государственного управления при Президенте Республики Казахстан, Астана, Казахстан

E-mail: 01@abi.kz, <https://orcid.org/0009-0006-2051-3710>;



Есенгельдина А. — Академия государственного управления при Президенте Республики Казахстан, Астана, Казахстан

E-mail: anaressengeldina344@gmail.com, <https://orcid.org/0000-0002-7752-916X>;

Курмангазиева Л. — Атырауский университет имени Х. Досмухамедова, Атырау, Казахстан

E-mail: kurmangazieval@mail.ru, <https://orcid.org/0000-0003-0640-7306>;

Шармуханбет С. — Атырауский университет имени Х. Досмухамедова, Атырау, Казахстан

E-mail: s.sharmukhanbet@asu-edu.kz, <https://orcid.org/0000-0003-4417-0485>;

Недзьведь А. — доктор технических наук, доцент, профессор, «Кафедра компьютерных технологий и систем», факультет прикладной математики и информатики, Минск, Беларусь

E-mail: anedzved@bsu.by, <https://orcid.org/0000-0001-6367-5900>.

© А. Игнатович, А.С. Есенгельдина, Л.Т. Курмангазиева, С.Р. Шармуханбет, А.М. Недзьведь, 2025

Аннотация. В данной работе представлен разработанный и сформированный набор данных, предназначенный для моделирования и прогнозирования исходов судебных дел в Республике Казахстан с применением методов машинного обучения. Основу данных составили статьи Кодекса Республики Казахстан, охватывающие широкий спектр уголовных и административных правонарушений. Сформированный корпус включает 100 000 судебных дел с различными атрибутами, такими как возраст обвиняемого, степень вины, а также наличие смягчающих и отягчающих обстоятельств. Указанный набор данных послужил основой для построения прогностических моделей, ориентированных на анализ и предсказание юридических исходов. В статье подробно рассмотрены методы формирования датасета и представлены результаты применения различных алгоритмов машинного обучения для решения задачи прогнозирования судебных решений. Актуальность исследования определяется необходимостью автоматизации правоприменительных процессов в Казахстане и повышением точности прогнозирования судебных исходов. Традиционные аналитические подходы требуют значительных временных и ресурсных затрат, а также ограничены конфиденциальностью реальных данных. Использование синтетических данных, сгенерированных на основе действующего законодательства, позволяет выявлять закономерности и разрабатывать эффективные прогнозные модели, способствующие совершенствованию правоприменительной практики. Целью настоящего исследования является создание комплексного и репрезентативного набора данных для анализа судебных дел с использованием современных методов интеллектуального анализа данных.

Ключевые слова: машинное обучение, прогнозирование судебных решений, генерация данных, регрессия, классификация

Для цитирования: А. Игнатович, А.С. Есенгельдина, Л.Т. Курмангазиева, С.Р. Шармуханбет, А.М. Недзьведь. Генерация данных для прогнозирования судебных решений в казахстане с использованием машинного обучения//Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 75–90. (На каз.). <https://doi.org/10.54309/IJICT.2025.22.2.005>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Кіріспе

Құқықтық процестерді автоматтандыру және цифрландыру (Karpenko et. al., 2023; Parysek et. al., 2023) көптеген елдерде, соның ішінде Қазақстанда да, сот жүйесін модернизациялаудың маңызды бөлігіне айналууда. Машиналық оқыту сияқты заманауи технологиялар құқық қолдану тәжірибесінің тиімділігін айтарлықтай арттыруға мүмкіндік береді, әсіресе нақты мәліметтерге шектеулі қолжетімділік жағдайында (Ruslan et. al., 2023; Said et. al., 2023). Сот шешімдерінің нәтижелерін деректер негізінде болжау сот процестерінде бар заңдылықтарды жақсырақ түсінуге, сондай-ақ уақыт пен ресурстарды барынша үнемдей отырып, негізделген шешімдер қабылдауға көмектеседі. Алайда, Қазақстанда сот істеріне қатысты нақты деректерге қолжетімділік құпиялылыққа байланысты шектеулі, бұл ғылыми талдау жүргізуге және олардың негізінде болжам жасау модельдерін әзірлеуге айтарлықтай кедергілер туғызады (Bianchini et. al., 2024; Setiawan et. al., 2024). Осы мәселені шешу үшін «Қазақстан Республикасының Кодексі» негізінде жасалған деректер жиынтығы құрылды (Sadykov et. al., 2024; Bolatbek et. al., 2024). Бұл жиынтық әкімшілік және қылмыстық құқық бұзушылықтардың кең ауқымын қамтитын 100 000 істі қамтиды, бұл машиналық оқыту алгоритмдерін қолдану арқылы сот шешімдерін модельдеуге негіз береді. Жасалған деректер көптеген атрибуттардан тұрады, мысалы, айыпталушының жасы, қылмыстың ауырлығы, кінәнің деңгейі, сондай-ақ жеңілдететін және ауырлататын жағдайлардың болуы. Машиналық оқытуды деректерді талдау үшін (Yelegen et. al., 2024) және сот шешімдерін болжау үшін пайдалану (Abdrasulov et. al., 2024) жоғары әлеуетке ие. Ол жасырын заңдылықтар мен үрдістерді анықтауға, істердің нәтижелерін болжау дәлдігін арттыруға, сондай-ақ құқық қорғау органдарына сот шешімдерінің ашықтығы мен әділдігін арттыру үшін жаңа құралдарды ұсынуға мүмкіндік береді (Akhmetov et. al., 2024; Orynbayeva et. al., 2023). Нақты деректерді алу мүмкін болмаған жағдайда, жасалған деректер сценарийлерді модельдеуге және гипотезаларды тексеруге пайдалы балама ретінде қызмет етеді, бұл нақты ақпарат қолжетімді болған кезде шынайы процестерді жақсартуға алып келуі мүмкін (Aitimova et. al., 2024).

Зерттеудің өзектілігі Қазақстанның құқық қолдану жүйесінің тиімділігін арттыру қажеттілігімен негізделеді, әсіресе талдауды қажет ететін істер көлемінің артуына байланысты. Сот процестерінің нәтижелерін қолмен талдау және болжау едәуір ресурстар мен уақытты талап етеді, бұл сот органдарына ауыртпалық түсіреді. Сонымен қатар, адами фактор қателіктерге немесе шешімдердің бірізділігінің болмауына әкелуі мүмкін, бұл сот жүйесінің әділдігіне әсер етеді. Жасанды интеллект технологияларын, соның ішінде машиналық оқытуды енгізу бұл процестерді автоматтандыруға ғана емес,

қабылданатын шешімдердің объективтілігін арттыруға да мүмкіндік береді. Сот жүйесін цифрландыру сонымен қатар әділеттілікке қол жеткізуді жақсарту бойынша ғаламдық бастамалардың маңызды аспектісі болып табылады. Осы контексте машиналық оқытуды сот шешімдерін талдау және болжау үшін пайдалану сот процестерінің қолжетімділігі мен ашықтығын едәуір арттыруы мүмкін. Сонымен қатар, мұндай технологиялар құқық бұзушылықтардың алдын алуға немесе олардың қайталануын азайтуға көмектесетін ерте ескерту жүйелерін әзірлеу үшін пайдаланылуы мүмкін.


Осы зерттеудің мақсаты – Қазақстандағы сот істерінің нәтижелерін талдау және болжау үшін жасалған деректерді қолдану және заңнамалық және басқа да деректер негізінде сот процестерінің нәтижелерін болжай алатын тиімді машиналық оқыту модельдерін әзірлеу. Жұмыс құқық бұзушылық түрін, оның ауырлығын, сондай-ақ белгілі бір жазаның тағайындалу ықтималдығын болжау үшін қолданылатын классификация және регрессия модельдерін әзірлеуге бағытталған. Осылайша, бұл зерттеу тек Қазақстандағы құқық қолдану тәжірибесін дамыту үшін ғана емес, сонымен қатар сот процестерін ғаламдық цифрландыру үшін де маңызды. Алынған нәтижелер құқықтық жүйеде жасанды интеллектті қолдану саласындағы болашақ әзірлемелерге негіз бола алады, бұл әділеттілікті жақсартуға жаңа мүмкіндіктер ашады.

Әдістер мен материалдар

Машиналық оқыту алгоритмдері классификация және регрессия сияқты әртүрлі міндеттерді шешу үшін кеңінен қолданылады (Hiremath et. al., 2023). Осы жұмыста бұл алгоритмдер көптеген белгілер негізінде нәтижелерді болжауға көмектеседі, олар істің әртүрлі атрибуттарын көрсетеді. Модельдерді оқыту процесіндегі негізгі қадамдардың бірі – деректерді дайындау, бұл категориялық айнымалыларды өңдеуді, жоқ деректерді толтыруды және оқыту үшін маңызды белгілерді таңдауды қамтиды. Содан кейін бұл белгілер екі типтегі модельдерді оқыту үшін қолданылады: сандық мәндерді болжауға арналған регрессиялық модельдер, мысалы, құқық бұзушылықтың ауырлығы немесе айыпталушының кінәсі, және санаттарды болжауға арналған классификациялық модельдер, мысалы, айыпталушыға қатысты бап немесе заң тарауының нөмірі. Суреттерде көрсетілген визуализациялар деректерді өңдеу, модельді оқыту және регрессия мен классификация үшін болжам жасау процесін көрсетеді (Medvedeva et. al., 2023).

Зерттеу барысында машиналық оқытудың екі түрі қолданылды: регрессиялық және классификациялық модельдер. 1-суретте регрессиялық модельді оқыту процесі көрсетілген. Бұл жағдайда оқыту моделі бірнеше мақсатты айнымалылармен жұмыс істейді, мысалы, құқық бұзушылықтың ауырлығы, кінә деңгейі, сондай-ақ жеңілдететін және ауырлататын факторлар. Бұл мақсатты мәндер айыпталушының кінәсінің деңгейін және жасалған құқық бұзушылықтың ауырлығын анықтау үшін маңызды. Модельді оқыту үшін пайдаланылатын деректер құқық бұзушылықтың күні, сот күні, айыпталушының жасы, оның


бұрынғы құқық бұзушылықтары, пара сомасы, қандағы алкоголь деңгейі, құқық бұзушылықтың орны және басқа да көптеген белгілерді қамтиды.



Сур. 1. Регрессиялық модельді оқыту процесі

Осы модельдің маңызды аспектісі – ол көптеген белгілерді ескеру мүмкіндігі, бұл болжамдардың дәлдігін арттыруға мүмкіндік береді. Бұл белгілердің барлығы түпкілікті бағалаулармен тығыз байланысты болғандықтан, модельге неғұрлым дәл болжам жасауға мүмкіндік береді. Нәтижесінде, регрессиялық модель мақсатты айнымалылардың мәндерін болжайды, оларды әрі қарай талдау немесе келесі өңдеу қадамдары үшін классификациялық модельге беру үшін пайдалануға болады. 2-суретте классификациялық модельдің жұмыс процесі көрсетілген. Бұл модель құқық түрі, бап нөмірі және тармақ сияқты мақсатты айнымалыларды оқыту арқылы істерді заңнаманың баптары мен тарауларына сәйкес жіктеуге мүмкіндік береді.

Классификациялау үшін қолданылатын белгілерге істің әртүрлі белгілері жатады: қылмыс жасалған күн, баптың атауы, қылмыстың орналасқан жері, айыпталушының жасы, бұрын жасалған қылмыстардың болуы және басқа да көрсеткіштер. Мәліметтердің бұл әртүрлілігі модельге істі заңның тиісті бабы бойынша жіктеуге әсер ететін әртүрлі аспектілерді есепке алуға мүмкіндік береді. Мысалы, егер іс жол қозғалысы ережесін бұзуға қатысты болса, есірткінің түрі немесе жаяу жүргіншілер ережесін бұзу сияқты факторлар елеусіз қалдырылуы мүмкін, себебі олар іс түріне қатысы жоқ.




Сур. 2. Классификация моделінің жұмыс процесі

Нәтижелер және талқылау

Бұл зерттеу 100 000 құқық бұзушылық істерінің жинақталған деректер жинағын жасады және пайдаланды, оның негізінде Қазақстандағы сот істерінің нәтижелерін болжау үшін машиналық оқыту үлгілері құрастырылды және сынақтан өтті. Деректер жинағы «Қазақстан Республикасының Кодексінде» қамтылған заңнамалық нормаларды пайдалана отырып әзірленді және қылмыстық және әкімшілік құқық бұзушылықтардың кең ауқымын қамтыды. Деректер атрибуттары айыпталушының жасы, құқық бұзушылықтың ауырлығы, жеңілдететін және ауырлататын факторлардың болуы сияқты параметрлерді қамтыды, бұл оларды модельдерді үйрету және нақты болжамдар алу үшін пайдалануға мүмкіндік берді. Жасалған деректер жинағын әзірлеу мұндай деректердің құпиялылығы мен қауіпсіздігіне байланысты сот істері бойынша нақты деректердің ашық көздерінің болмауы проблемасын еңсеруге мүмкіндік берді. Жасалу нәтижесінде 100 000 жазба жасалды, олардың әрқайсысында құқық бұзушылықтар туралы мәліметтер, соның ішінде жасы, қылмыс түрі, айыпталушының ауырлығы мен кінәсі сияқты атрибуттар бар, бұл деректерді талдау үшін пайдалануға мүмкіндік береді. Жүйелі түрде таңдалған және құрылымдалған деректер машиналық оқыту үлгілерін құру және сынау


мүмкіндігін берді. Әрбір деректер жазбасында құқық бұзушылықтың жасалған күні, сот талқылауының күні, заң түрі (қылмыстық немесе әкімшілік), бап нөмірі, тармақ, мақала тақырыбы, айыпталушының жасы, құқық бұзушылықтың ауырлығы, кінәсі, жауаптылығын жеңілдететін және ауырлататын факторлар, бұрын жасалған қылмыстардың болуы және басқа да маңызды параметрлер. 3-суретте Қазақстан Республикасы Кодексінің әртүрлі баптары бойынша бұзушылықтардың жиілігін талдау, әкімшілік және қылмыстық құқық бұзушылықтар арасында ең жиі бұзылатын 10 бапты көрсетеді. Графиктегі әрбір баған белгілі бір мақалаға қатысты бұзушылықтар санын көрсетеді, көлденең ось мақала нөмірлерін және тік ось хабарланған бұзушылықтардың санын көрсетеді. Графикте көлік құралын лицензиясыз пайдалану (441–1-бап), қоғамдық орындарға мас күйінде шығу (440-бап), жол қозғалысы ережелерін бұзу (441-бап), тасымалдау ережелерін бұзу сияқты әкімшілік құқық бұзушылықтар бар баптар көрсетілген. жолаушылар (448-бап) және ұсақ бұзақылық (449-бап). Бұл талдау құқық қорғау саласында шешім қабылдау үшін маңызды ақпарат бола алатын қай баптар жиі бұзылатынын анықтауға мүмкіндік береді.



Сур. 3. Әртүрлі баптар бойынша бұзушылықтарды жиілікті талдау

4-сурет - барлық құқық бұзушылықтар арасындағы құқық түрлерінің бөлінуін көрсететін дөңгелек диаграмма, қаралып жатқан деректер жиынтығында қылмыстық және әкімшілік істердің саны бірдей екенін анық көрсетеді, әрбір санат құқық бұзушылықтардың жалпы санының 50% құрайды. Қылмыстық құқыққа адам өлтіру, ұрлық, алаяқтық, бопсалау сияқты аса ауыр қылмыстарға және Қазақстан Республикасының Қылмыстық кодексінде көзделген басқа да қылмыстарға байланысты істер жатады. Қылмыстық санатқа жатқызылған бұзушылықтар бас бостандығынан айыру, қоғамдық жұмыстарға тарту немесе елеулі айыппұлдар сияқты неғұрлым қатаң жазаларды қамтиды.

Модельдерді құру үшін регрессиялық және классификациялық машиналық оқыту алгоритмдері пайдаланылды. Тәжірибелер кезінде деректер 80 % және 20 % қатынасында оқу және сынақ үлгілеріне бөлінді.




Сур. 4. Барлық құқық бұзушылықтар арасында құқық түрлерінің бөлінуі

Бұл тәсіл модельдердің ақпаратты жаңа деректерге жалпылау мүмкіндігін бағалауға және артық сәйкестендірмеуге мүмкіндік берді. Нәтижелер көрсеткендей, регрессиялық модельдер қылмыстардың ауырлығы мен айыпталушының кінәсі сияқты сандық көрсеткіштерді жоғары дәлдікпен болжауға қабілетті. Жіктеу үлгілері құқық бұзушылықтың түрін, заңнаманың баптары мен пункттерін тиімді жіктеді, бұл деректерді жіктеудегі үлгілердің жоғары дәлдігін растайды. Зерттеу барысында деректердің әртүрлі визуализациялық талдаулары да жүргізілді. Мәселен, құқық бұзушылықтардың жиілігін талдау көрсеткендей, әкімшілік құқық бұзушылықтар арасында көлік құралын рұқсатсыз пайдалану және жол қозғалысы ережелерін бұзу жиі кездесетін баптар болып табылады.


Бұл зерттеу нақты криминалистикалық деректер болмаған кезде жасалған деректердің болжамды модельдерді құру мүмкіндігін қамтамасыз ететін пайдалы болуы мүмкін екенін көрсетті. Нақты деректерге қол жетімді болғаннан кейін, бұл модельдерді нақты әлем жағдайында олардың дәлдігі мен қолдану мүмкіндігін арттыра отырып, қосымша оқытуға болады. 5-сурет - зерттелетін деректер үлгісінде айыпталушының жасын бөлу гистограммасы. Көлденең ось 18 жастан 80 жасқа дейінгі сотталушылардың жасын, ал тік ось әрбір жас диапазонындағы жауапкерлердің санын көрсетеді. Ең көп ұсынылған жас тобы – 20 мен 30 жас аралығындағы адамдар, олардың ең жоғары деңгейі 25 жас шамасында, мұнда айыпталушылардың ең көп саны байқалады (шамамен 80 мың).

6-суретте құқық бұзушылықтың ауырлық дәрежесін бөлу гистограммасы көрсетілген, мұнда Х осі 0-ден 100-ге дейінгі аралықтағы құқық бұзушылықтың ауырлық деңгейін көрсетеді, ал Y осі әрбір деңгей үшін істердің санын көрсетеді. Құқық бұзушылықтардың ең көп саны 30-дан 40-қа дейін және 80-ден 90-ға дейінгі диапазонда шоғырланған, бұл қылмыстардың салыстырмалы түрде жеңіл қылмыстардан аса ауыр қылмыстарға дейін болатынын көрсетеді. Сондай-

ақ, құқық бұзушылықтардың белгілі бір санының ауырлық деңгейі төмен, 0-ге жақын екенін атап өтуге болады, бірақ мұндай жағдайлар аз. Ең жоғары шыңы шамамен 40 ауырлық деңгейінде орын алады, бұл құқық бұзушылықтардың көпшілігі орташа ауырлық аймағында екенін көрсетеді.




Сур. 5. Зерттелетін деректер үлгісінде айыпталушылардың жасының бөлінуі




Сур. 6. Құқық бұзушылықтың ауырлық дәрежесін бөлу гистограммасы

7-суретте бірінші 10 мақала бойынша орташа кінә деңгейінің гистограммасы көрсетілген, X осі мақала тақырыптарын және Y осі әрбір бұзушылыққа байланысты орташа кінә деңгейін (пайызбен) көрсетеді. Заңсыз автотұраққа, жолды бұзуға және жылдамдықты арттыруға қатысты мақалалар 70 %-ға жуық кінәнің жоғары орташа деңгейін көрсетеді, бұл бұзушылық туралы хабардар болу деңгейін де, құқық бұзушылықтардың ауырлығын да көрсетуі мүмкін.

8-суретте әр түрлі жаза түрлерінің бөліну гистограммасы көрсетілген, мұнда X осі «Ескерту», «Айыппұл», «Өмір бойына бас бостандығынан айыру», «Бостандығын шектеу», «Бас бостандығынан айыру» сияқты жазалардың түрлерін көрсетеді. », «Түзеу жұмыстары» және «Әкімшілік қамауға алу», ал y осі әрбір жаза түрі бойынша істердің санын көрсетеді. Ескерту және айыппұл жазаның ең жиі қолданылатын түрлері болып табылады, ол әкімшілік құқық бұзушылықтарға сәйкес келеді, онда жеңілдетілген шаралар жиі қолданылады.



Сур. 7. Құқық бұзушылықтың ауырлық дәрежесін бөлу гистограммасы



Сур. 8. Әр түрлі жаза түрлерін бөлу


9-суретте «Асқындататын факторлар» мақсатты мүмкіндігі үшін RMSE өзгерісі көрсетілген. Жаттығу деректеріне арналған RMSE (Train RMSE) итерациялар бойынша төмендейтінін көруге болады, бұл модель сәтті оқытылғанын және оқу деректер жиынына жақсырақ сәйкес келетінін көрсетеді. Дегенмен, RMSE Validation сызығы итерациялар артқан сайын шамалы өсуді көрсетеді.

10-суретте «Қауіптілік» мүмкіндігі үшін үлгіні оқыту процесі көрсетілген. Бұл график алдыңғыға мүлдем қарама-қайшы. Бұл жағдайда валидациядағы RMSE сызығы, әсіресе алғашқы 10 итерациядан кейін оқу деректеріндегі RMSE жолымен дерлік бірдей. Бұл модель оқыту және тексеру деректерін жақсы меңгеретінін білдіреді, бұл модельдің білімін жалпылау және жаңа деректер үшін дұрыс мәндерді болжау қабілетінің жоғарылығын көрсетеді.


11-суретте «Жеңілдететін факторлар» мүмкіндігіне арналған оқу үдерісі көрсетілген. Бұл график оқу деректеріндегі RMSE (Train RMSE) үнемі төмендейтінін көрсетеді, бұл модель үйренуді жалғастыратынын және оқу жиынына болжам жасауда дәлірек болатынын көрсетеді. Дегенмен, бірінші графиктегідей, Validation RMSE әрбір итерацияда баяу өсе бастайды, бұл қайтадан шама-

дан тыс орнату мәселесін көрсетеді. Бұл жерде бірінші графиктегідей шамадан тыс фитинг байқалмайды, бірақ валидация қателерінің көбею тенденциясы қатысты. Бұл модельдің оқу деректеріне тым «бапталған» және жаңа деректер бойынша тиімді болжау мүмкін еместігін көрсетеді. Бұл жағдайда модельдің жалпылау қабілетін жақсарту үшін ерте тоқтату немесе реттеу әдістерін енгізу де пайдалы болуы мүмкін.


Тұтастай алғанда, бұл графиктер әртүрлі мақсатты мүмкіндіктер үшін оқыту және валидация деректері бойынша модельді оқыту процесінің нақты бейнесін береді. «Қауіптілігі» ең табысты оқуды көрсетеді, ал «Ауырлайтын факторлар» және «Жеңілдететін факторлар» шамадан тыс жаттығулардың ықтимал проблемаларын көрсетеді. Модельді одан әрі жетілдіру үшін реттеу немесе деректерді көбейту сияқты шамадан тыс орнатудың алдын алу әдістерін зерттеу және модельдің гиперпараметрлерін егжей-тегжейлі талдау маңызды.



Сур. 9. «Асқындататын факторлар» мақсатты мүмкіндігі үшін RMSE



Сур. 10. «Асқындататын факторлар» мақсатты мүмкіндігі үшін RMSE



Сур. 11. «Жеңілдететін факторлар» мүмкіндігіне арналған оқу процесі

Қорытынды

Бұл зерттеу машиналық оқыту әдістерін пайдалана отырып, Қазақстандағы сот істерінің нәтижелерін модельдеу және болжау үшін деректерді генерациялау әдістемесін әзірледі және енгізді. «Қазақстан Республикасы Кодексінің» баптары негізінде жасалған құқық бұзушылықтың 100 000 ісін қамтитын құрылған деректер жиынтығы нақты сот деректеріне қол жеткізудің болмауы проблемасын еңсеруге мүмкіндік берді. Жасалған деректер сотталушының жасы, кінәсінің дәрежесі, жеңілдететін және ауырлататын факторлардың болуы сияқты негізгі атрибуттарды қамтыды, бұл сот істерінің нәтижелерін талдау мен болжаудың нақты үлгілерін құруға мүмкіндік берді. Регрессия да, классификация да машиналық оқыту алгоритмдерін пайдалану жоғары тиімділікті көрсетті. Регрессиялық модельдер RMSE төмен мәндеріне қол жеткізді, мысалы, «құқық бұзушылықтың ауырлығы» көрсеткіші үшін RMSE 0,12, ал «жеңілдететін факторлар» үшін 0,15 болды, бұл болжамдардың жоғары дәлдігін көрсетеді. Жіктеу үлгілері құқық бұзушылық түрін жіктеуде 92 % және заңнаманың баптары мен тарауларын жіктеуде 89% дәлдік көрсетті. Бұл нәтижелер модельдердің жасалған деректер негізінде нәтижелерді тиімді болжауға қабілетті екенін көрсетеді. Деректерді визуализациялау және модельдік талдау құрылған жүйені сот істерін талдау және құқық қолдану тәжірибесіне көмек көрсету үшін пайдалануға болатынын растады. Жасалған деректер қылмыстың негізгі тенденцияларын анықтауға мүмкіндік берді, мысалы, қылмыстардың ең көп санын 20 мен 30 жас аралығындағы адамдар жасайды, ал қылмыстардың көпшілігі орташа ауырлық дәрежесіне ие (30–40 балл).

ӘДЕБИЕТТЕР

Карпенко О., Айгумов Т., Золкин А., Гурева А. және Поскряков И. (2023). «Заңды қолданудағы автоматтандыру және цифрландырудың заманауи тенденциясы», АІР конференциясының

материалдарында. — Т. 2910. — Жок. 1. — AIP Publishing, қазан 2023 ж.

Парычек П., Шмид В. және Новак А.С. (2023). «Әкімшілік процедуралардағы жасанды интеллект (AI) және автоматтандыру: әлеуеттер, шектеулер және құрылымдық шарттар, білім экономикасы журналы. — 1–26 беттер, 2023 ж.

Руслан С. (2023). «Кибердәуірдегі заңгерлік тәжірибе мен заңгерлік кәсіптің қиындықтары мен мүмкіндіктері», Халықаралық құқық және саясат журналы. — Т. 1. — жок. 4. 2023 ж.

Сайд Г., Азамат К., Равшан С. және Бохадир А. (2023). «Құқықтық жүйелерді жасанды интеллектті дамытуға бейімдеу: сот процестеріндегі AI жаһандық мәселесін шешу», Халықаралық кибер құқық журналы. — Том. 1. — Жок. 4. 2023 ж.

Bianchini D., Bono C., Campi A., Cappiello C., Ceri S., De Luzi F. et al. (2024). «Итальяндық сот жүйесіндегі AI қолдайтын процесті талдаудағы қиындықтар: цифрландырудан кейін ше?» Цифрлық үкімет: зерттеулер және тәжірибе. — Т. 5. — Жок. 1. — 1–10 беттер, 2024 ж.

Сетияван Х., Хандаяни I.G.A.K.R., Хамза М.Г. және Тегнан Х. (2024). «Конституциялық сотта сотты қарау бойынша құқықтық трансформацияны цифрландыру», Адам құқықтары, мәдениет және құқықтық жүйе журналы. — Том. 4. — Жок. 2. — 263–298 беттер, 2024 ж.

Садықов М., Карим М.Е., Тынышбаева А. және Бахтеев Д. (2023). «Жасанды интеллект жүйелерінің қасиеттері, оларды заңдық қызметте пайдалану контекстінде», 12-ші UUM халықаралық заң конференциясында 2023 (UUMILC 2023), Atlantis Press. — 26–14 қаңтар, 2012 ж.

Болатбек М., Байспай Г., Мүсірәлиева С. және Усманова А. (2024). «Қазақстандағы университеттік желілерді пайдалана отырып, киберқылмыстық әрекеттерді анықтау және жеңілдету негіздері», Радиоэлектрондық және компьютерлік жүйелер. — Т. 2024. — №. 2. — 186–202 б., 2024 ж.

Елеген А.Ю. және Сәрсембаев М.А. (2024). «Қазақстанның жасанды интеллект технологиялары бар медициналық электрлік көліктерді өндіру және пайдалану бойынша БРИКС елдерімен құқықтық ынтымақтастығы», BRICS LJ. — Том. 11. — Б. 131. 2024 ж.

Абдрасулов Е., Ахметов Ю., Абдрасулова А., Тапакова В. және Муталыпова А. (2024). «Қазақстан Республикасының әкімшілік сот ісін жүргізу жүйесінде заңдылық пен әділеттілік принциптерін қолданудың құқықтық негіздері», Статут заңына шолу. — Т. 45. — Жок. 2. — Б. hmae026. 2024 ж.

Ахметов Ы., Абдрасулов Ы., Имамбаева Г., Ахметова А. және Аликулова Г. (2024). «Қазақстан Республикасының әкімшілік сот ісін жүргізудегі заңдылық пен әділеттілік принциптерін талдау», Халықаралық қоғамдық құқық және саясат журналы. — Т. 10. — Жок. 5. — 1–11 беттер. 2024 ж.

Орынбаева А., Шындалиев Н. және Арипбаева А. (2023). «Машиналық оқытуды қолдану арқылы медициналық университеттерде деректерді өңдеудің статистикалық әдістерін жетілдіру». World Transactions on Engineering and Technology Education. — Т. 21. — Жок. 1. — 58–63 б. 2023 ж.

Әйтимова У., Әйтимов М., Мұхаметжанова Б., Исақұлова З., Қасымова А., Исмаилова А. т.б. (2024). «Деректердің көлемін ұлғайту үшін генеративті қарсылас желілерді пайдалана отырып деректерді генерациялау». — *International Journal of Electrical & Computer Engineering*. — Т. 14. — Жок. 2. 2024 ж.

Хиремат С., Шетти Э., Пракаш А.Дж., Саху С.П., Патро К.К., Раджеш К.Н. және Плавияк П. (2023). «Киберқауіпсіздік үшін машиналық оқытуды пайдалана отырып, деректерді талдауға жаңа көзқарас», Үлкен деректер және когнитивтік есептеулер. — Том. 7. — Жок. 4. — б. 176. 2023 ж.

Медведева М., Wieling M. және Vols M. (2023). «Сот шешімдерін автоматты түрде болжау саласын қайта қарау», Жасанды интеллект және құқық. — Т. 31. — Жок. 1. — 195–212 б., 2023 ж.

REFERENCES

Karpenko O., Aygumov T., Zolkin A., Gureva A. and Poskryakov I. (2023). “Modern trend of automation and digitalization in law application,” in AIP Conference Proceedings. — Vol. 2910. — No. 1. — AIP Publishing. — Oct. 2023. (in Eng.)

Parycek P., Schmid V. and Novak A.S. (2023). “Artificial Intelligence (AI) and automation in administrative procedures: Potentials, limitations, and framework conditions”. — *Journal of the Knowledge Economy*. — Pp. 1–26, 2023. (in Eng.)

Ruslan S. (2023). “Challenges and Opportunities for Legal Practice and the Legal Profession in the Cyber Age,” *International Journal of Law and Policy*. — Vol. 1. — No. 4. 2023. (in Eng.)

Said G., Azamat K., Ravshan S. and Bokhadir A. (2023). “Adapting legal systems to the development of artificial intelligence: solving the global problem of AI in judicial processes,” *International Journal of Cyber Law*. — Vol. 1. — No. 4. 2023. (in Eng.)

Bianchini D., Bono C., Campi A., Cappiello C., Ceri S., De Luzi F. et al. (2024). “Challenges in AI-supported process analysis in the Italian judicial system: what after digitalization?” *Digital Government: Research and Practice*. — Vol. 5. — No. 1. — Pp. 1–10. 2024. (in Eng.)

Setiawan H., Handayani I.G.A.K.R., Hamzah M.G. and Tegnan H. (2024). “Digitalization of Legal Transformation on Judicial Review in the Constitutional Court,” *Journal of Human Rights, Culture and Legal System*. — Vol. 4. — No. 2. — Pp. 263–298. 2024. (in Eng.)

Sadykov M., Karim M.E., Tynyshbayeva A. and Bakhteev D. (2023). “Properties of artificial intelligence systems in the context of their use in legal activities,” in 12th UUM International Legal Conference 2023 (UUMILC 2023), Atlantis Press, Jan. 2024. — Pp. 156–169. (in Eng.)

Boлатбек М., Байспай Г., Мусирәлиева С. және Усманова А. (2024). «А framework for detection and mitigation of cyber criminal activities using university network in Kazakhstan», *Radioelectronic and Computer Systems*. — Vol. 2024. — No. 2. — Pp. 186–202. 2024. (in Eng.)



Yelegen A.Y. and Sarsembayev M.A. (2024). “Legal Cooperation of Kazakhstan with the BRICS Countries on the Production and Operation of Medical Electric Vehicles with Artificial Intelligence Technologies,” *BRICS LJ*. — Vol. 11. — P. 131. 2024. (in English)

Abdrasulov E., Akhmetov Y., Abdrasulova A., Tapakova V. and Mutalyapova A. (2024). “Legal Basis for the Application of the Principles of Legality and Justice in the System of Administrative Proceedings of the Republic of Kazakhstan,” *Statute Law Review*. — Vol. 45. — No. 2. — P. hmae026. 2024. (in Eng.)

Akhmetov Y., Abdrassulov Y., Imambayeva G., Akhmetova A. and Alikulova G. (2024). “Analyses of the principles of legality and justice in administrative proceedings of the Republic of Kazakhstan”. — *International Journal of Public Law and Policy*. — Vol. 10. — No. 5. — Pp. 1–11. 2024. (in Eng.)

Orynbayeva A., Shyndaliyev N. and Aripbayeva A. (2023). “Improving statistical methods of data processing in medical universities using machine learning”. *World Transactions on Engineering and Technology Education*. — Vol. 21. — No. 1. — Pp. 58–63. 2023. (in Eng.)

Aitimova U., Aitimov M., Mukhametzhanova B., Issakulova Z., Kassymova A., Ismailova A. et al. (2024). “Data generation using generative adversarial networks to increase data volume”. — *International Journal of Electrical & Computer Engineering*. — Vol. 14. — No. 2. 2024. (in Eng.)

Hiremath S., Shetty E., Prakash A.J., Sahoo S.P., Patro K.K., Rajesh K.N. and Pławiak P. (2023). “A new approach to data analysis using machine learning for cybersecurity”. *Big Data and Cognitive Computing*. — Vol. 7. — No. 4. — P. 176. 2023. (in Eng.)

Medvedeva M., Wieling M. and Vols M. (2023). “Rethinking the field of automatic prediction of court decisions”. *Artificial Intelligence and Law*. — Vol. 31. — No. 1. — Pp. 195-212. 2023. (in Eng.)

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 2. Number 22 (2025). Pp. 91–114

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.006>

УДК 004.931

REAL-TIME MATHEMATICAL MODELING FOR MOVING OBJECT DETECTION IN VIDEO STREAMS

A. Kassymova¹, G. Abdikerimova^{2*}, A. Assabay¹, A. Serikbayeva³, S. Akhmedova⁴

¹Zhangir Khan West Kazakhstan Agrarian Technical University, Uralsk, Kazakhstan;

²L.N. Gumilyov Eurasian National University, Astana, Kazakhstan;

³Kazakh Agrotechnical Research University named after S. Seifullin, Astana,
Kazakhstan;

⁴Sumgait State University, Sumgait, Azerbaidzhan.

E-mail: gulzira1981@mail.ru

Kassymova A. — Candidate of Pedagogical Sciences, associate professor, Zhangir Khan West Kazakhstan Agrarian Technical University, Uralsk, Kazakhstan

E-mail: kasimova_ah@mail.ru, <https://orcid.org/0000-0002-4614-4021>;

Abdikerimova G. — PhD, associate professor, «Department of Information Systems», Eurasian National University named after L.N. Gumilyov, Astana, Kazakhstan

E-mail: gulzira1981@mail.ru, <https://orcid.org/0000-0002-4953-0737>;

Assabay A. — Master's student in Information Technology, Zhangir Khan West Kazakhstan Agrarian Technical University, Uralsk, Kazakhstan

E-mail: 02assabayazamat@gmail.com, <https://orcid.org/0009-0008-9542-348>;

Serikbayeva A. — Master of Sc., Senior Lecturer, «the Department of Higher Mathematics, Kazakh Agrotechnical Research University named after S. Seifullin, Astana, Kazakhstan

E-mail: ser_assem@mail.ru;

Akhmedova S. — senior lecturer, «the Department of Information Technology and Programming», Sumgait State University, Sumgait, Azerbaidzhan

E-mail: axmedova60@mail.ru.

© A. Kassymova, G. Abdikerimova, A. Assabay, A. Serikbayeva, S. Akhmedova, 2025

Abstract. The development of mathematical models for real-time detection of moving objects in video streams is crucial, particularly in response to the increasing need for security and automation. This study presents a detection system based on the Faster Region-Based Convolutional Neural Network (Faster R-CNN) framework, integrating multiple backbone architectures such as Residual Network-50 (ResNet-50), Feature Pyramid Network (FPN), MobileNet Version 3 Large, and Efficient Network-B0 (EfficientNetB0) enhanced with a Self-Attention mechanism. The model leverages deep neural networks combined with scaling techniques to extract object features effectively, ensuring adaptability across various operational conditions. Experimental findings reveal outstanding accuracy, with the MobileNet



Version 3 Large model achieving 95.70 % accuracy and the Residual Network-50 model attaining 100 % accuracy within the first three epochs. The Faster R-CNN model using EfficientNetB0 with a Self-Attention mechanism also achieves 100 % accuracy by the third epoch, maintaining consistent performance in subsequent training cycles. The model with the ResNet-50 and FPN backbone demonstrates a reduction in average loss from 0.0922 during the first epoch to 0.0102 by the 15th epoch, highlighting its robustness and efficiency. Future investigations may focus on enhancing the proposed system to manage more complex and dynamic video scenarios, as well as optimizing data processing to lower computational costs and improve processing speed.

Key words: Real-time object detection, video stream processing, face embeddings, multi-threaded recognition, machine learning, object classification

For citation: A. Kassymova, G. Abdikerimova, A. Assabay, A. Serikbayeva, S. Akhmedova. Real-time mathematical modeling for moving object detection in video streams//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 91–114 (In Kaz.). [HTTPS://DOI.ORG/10.54309/IJICT.2025.22.2.006](https://doi.org/10.54309/IJICT.2025.22.2.006)

Conflict of interest: The authors declare that there is no conflict of interest.

БЕЙНЕ АҒЫНДАРЫНДА ҚОЗҒАЛАТЫН ОБЪЕКТИЛЕРДІ АНЫҚТАУ ҮШІН НАҚТЫ УАҚЫТТАҒЫ МАТЕМАТИКАЛЫҚ МОДЕЛЬДЕУ

А.Х. Касымова¹, Г.Б. Абдикеримова^{2}, А.Қ. Асабай¹, А.Б. Серикбаева³,
С.М. Ахмедова⁴*

¹Жәңгір хан атындағы Батыс Қазақстан аграрлық-техникалық университеті,
Орал, Қазақстан;

²Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан;

³С. Сейфуллин атындағы Қазақ агротехникалық зерттеу университеті, Астана,
Қазақстан;

⁴Сумгаит мемлекеттік университеті, Сумгаит, Әзірбайжан.

E-mail: gulzira1981@mail.ru

Касымова А. — қауымдастырылған профессор, педагогика ғылымдарының кандидаты, Жәңгір хан атындағы Батыс Қазақстан аграрлық-техникалық университеті, Орал Қазақстан
E-mail: kasimova_ah@mail.ru, <https://orcid.org/0000-0002-4614-4021>;

Абдикеримова Г. — Л.Н. Гумилев атындағы Еуразия ұлттық университетінің «Ақпараттық жүйелер» кафедрасының м.а. доценты, PhD, Астана, Қазақстан, Сатпаев к., 2, 010000
E-mail: gulzira1981@mail.ru, <https://orcid.org/0000-0002-4953-0737>;

Асабай А. — Жәңгір хан атындағы Батыс Қазақстан аграрлық-техникалық университеті, «Ақпараттық технологиялар» мамандығының магистранты, Орал, Қазақстан
E-mail: 02assabayazamat@gmail.com, <https://orcid.org/0009-0008-9542-348>;

Серикбаева А. — С. Сейфуллин атындағы Қазақ агротехникалық зерттеу университеті, “Жоғары математика” кафедрасының аға оқытушысы, магистр, Астана, Қазақстан
e-mail: ser_assem@mail.ru;

Ахмедова С. — Сумгаит мемлекеттік университетінің «Ақпараттық технологиялар және бағдарламалау» кафедрасының аға оқытушысы, Сумгаит, Әзірбайжан қ.

E-mail: axmedova60@mail.ru.

© А.Х. Касымова, Г.Б. Абдикеримова, А.Қ. Асабай, А.Б. Серикбаева, С.М. Ахмедова, 2025

Аннотация. Қозғалыстағы объектілерді нақты уақытта бейне ағындарында анықтауға арналған математикалық модельдерді әзірлеу қауіпсіздік пен процестерді автоматтандыру қажеттілігінің артуына байланысты маңызды міндет болып табылады. Бұл зерттеуде Faster Region-Based Convolutional Neural Network (Faster R-CNN) моделіне негізделген анықтау жүйесі ұсынылады. Жүйе Residual Network-50 (ResNet-50), Feature Pyramid Network (FPN), MobileNet Version 3 Large және Efficient Network-B0 (EfficientNetB0) сияқты әртүрлі архитектураларды пайдаланады және Self-Attention механизмімен күшейтілген. Модель объектілердің белгілерін тиімді түрде бөліп алып, терең нейрондық желілер мен масштабтау әдістерін пайдалану арқылы әртүрлі операциялық жағдайларға бейімделуді қамтамасыз етеді. Эксперименттік нәтижелер жоғары дәлдікті көрсетеді: MobileNet Version 3 Large моделі 95,70 % дәлдікке, ал Residual Network-50 моделі алғашқы үш оқу кезеңінде 100 % дәлдікке жетті. EfficientNetB0 архитектурасы мен Self-Attention механизмі қолданылған Faster R-CNN моделі де үшінші кезеңге дейін 100% дәлдікке жетіп, кейінгі оқу циклыдарында тұрақты нәтижелер көрсетті. ResNet-50 және FPN архитектурасы қолданылған модель бірінші оқу кезеңіндегі орташа шығын мәнін 0,0922-ден он бесінші кезеңге дейін 0,0102-ге дейін төмендетуді көрсетті, бұл оның сенімділігі мен тиімділігін растайды. Болашақ зерттеулер ұсынылған жүйені күрделірек және динамикалық бейне сценарийлерін өңдеуге бейімдеуге, сондай-ақ есептеу шығындарын азайтып, өңдеу жылдамдығын арттыру үшін деректерді өңдеуді оңтайландыруға бағытталуы мүмкін.

Түйін сөздер: Нақты уақыттағы нысанды анықтау, бейне ағынын өңдеу, бетті ендіру, көп ағынды тану, машиналық оқыту, нысанды жіктеу

Дәйексөздер үшін: А.Х. Касымова, Г.Б. Абдикеримова, А.Қ. Асабай, А.Б. Серикбаева, С.М. Ахмедова. Бейне ағындарында қозғалатын объектілерді анықтау үшін нақты уақыттағы математикалық модельдеу // Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 91–114 бет. (қазақ тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.006>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ В РЕАЛЬНОМ ВРЕМЕНИ ДЛЯ ОБНАРУЖЕНИЯ ДВИЖУЩИХСЯ ОБЪЕКТОВ В ВИДЕОПОТОКАХ

А.Х. Касымова¹, Г.Б. Абдикеримова^{2}, А.К. Асабай¹, А.Б. Серикбаева³,
С.М. Ахмедова⁴*

¹Западно-Казахстанского аграрно-технический университет имени Жангир



хана, Уральск, Казахстан;

²Евразийский национальный университет имени Л.Н. Гумилева,
Астана, Казахстан;

³Казахский агротехнический исследовательский университет имени С.
Сейфуллина, Астана, Казахстан;

⁴Сумгаитский государственный университет, Сумгаит, Азербайджан.
E-mail: gulzira1981@mail.ru

Касымова А. — кандидат педагогических наук, доцент, Западно-Казахстанский аграрно-технический университет имени Жангир хана, Уральск, Казахстан

E-mail: kasimova_ah@mail.ru, <https://orcid.org/0000-0002-4614-4021>;

Абдикеримова Г. — PhD, исполняющая обязанности доцента кафедры «Информационных систем» Л.Н. Гумилева Евразийского национального университета, Астана, Казахстан

E-mail: gulzira1981@mail.ru, <https://orcid.org/0000-0002-4953-0737>;

Асабай А. — магистрант по специальности «Информационные технологии», Западно-Казахстанский аграрно-технический университет имени Жангир хана, Уральск, Казахстан

E-mail: 02assabayazamat@gmail.com, <https://orcid.org/0009-0008-9542-348>;

Серикбаева А. — магистр, старший преподаватель, «Кафедра высшей математики», Казахский агротехнический исследовательский университет имени С. Сейфуллина, Астана, Казахстан

E-mail: ser_assem@mail.ru;

Ахмедова С. — старший преподаватель, «Кафедра информационных технологий и программирования», Сумгаитский государственный университет, Сумгаит, Азербайджан

E-mail: axmedova60@mail.ru.

© А.Х. Касымова, Г.Б. Абдикеримова, А.К. Асабай, А.Б. Серикбаева, С.М. Ахмедова, 2025

Аннотация. В статье рассматривается использование гибридной модели при изучении влияния социально-экономических факторов на региональное развитие. Этот подход объединяет корреляционный анализ, анализ главных компонент (РСА) и нечеткую логику. Целью исследования является разработка модели, учитывающей многомерные и нелинейные связи между такими факторами, как численность населения, занятость и инвестиции в основной капитал, и оценка их влияния на региональные социально-экономические процессы. В качестве основных данных использовались численность населения (431 192 человека), среднемесячная заработная плата (2 658 658 тенге), инвестиции в основной капитал (1 646 258 тенге), занятое население (1 929 тыс. человек). Результаты исследования показали, что численность населения оказывает положительное влияние на экономические процессы, коэффициент влияния составляет 3,28, а коэффициент влияния инвестиций в основной капитал — 3,44. Гибридная модель позволила нам с высокой точностью оценить влияние каждого фактора. Использование этого метода поможет улучшить стратегии регионального экономического развития и принимать управленческие решения на основе данных. Результаты исследования демонстрируют важность гибридных методов для политики регионального развития, поскольку они позволяют проводить комплексный анализ региональных социально-экономических тенденций и повышают достоверность результатов.

Ключевые слова: гибридная модель, социально-экономические факторы, корреляционный анализ, машинное обучение, искусственный интеллект

Для цитирования: А.Х. Касымова, Г.Б. Абдикеримова, А.К. Асабай, А.Б. Серикбаева, С.М. Ахмедова. Математическое моделирование в реальном времени для обнаружения движущихся объектов в видеопотоках//Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 91–114. (На каз.). <https://doi.org/10.54309/IJICT.2025.22.2.006>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Кіріспе

Терең оқытуды нақты әлемдік мәселелерге қолданудағы негізгі қиындықтардың бірі – мәліметтердің жеткіліксіздігі. Қазіргі зерттеулер көрсеткендей, нейрондық желілерді тиімді оқыту үшін үлкен көлемдегі деректер қажет, алайда нақты жағдайларда деректер көбінесе шектеулі болады. Бұл әсіресе мультимодальды деректерге қатысты, онда ең жақсы нәтижеге қол жеткізу үшін әртүрлі көздерден алынған деректерді (мысалы, кескіндер, мәтіндер, уақыттық мәліметтер) біріктіру қажет. Бұл мәселені шешу үшін деректерді толықтыру әдістері, трансферлік оқыту, сондай-ақ генеративті бәсекелес желілерді (GANs) пайдалана отырып синтетикалық деректерді жасау әдістері кеңінен қолданылады. Мысалы, TriChronoNet электр энергиясы бағаларын болжауға арналған мультимодальды деректерді біріктіру әдісін ұсынып, шектеулі дереккөздер жағдайында жоғары тиімділігін көрсетеді.

Бет-әлпетті тану жүйелерін әзірлеу – компьютерлік көру және жасанды интеллект саласындағы маңызды міндеттердің бірі, әсіресе қазіргі уақытта қауіпсіздік және жеке тұлғаны сәйкестендіру талаптары күшейіп жатқан кезде. Бет-әлпетті тану жүйелері әртүрлі салаларда кеңінен қолданылады: кіруді басқарудан және қоғамдық орындарды бақылаудан бастап, жеке қосымшалар мен қызметтерге дейін. Сондықтан қолданыстағы бет-әлпетті тану әдістерін жетілдіру өзекті міндет болып қалып отыр, бұл үшін терең оқыту (Waelen et. al., 2023; Dang et. al., 2023) және бет-әлпет ендіргіштері (Opanasenko et. al., 2024; Carragher et. al., 2023) сияқты озық технологияларды енгізу қажет.

Бет-әлпет ендіргіштері – бұл адамның бетінің ерекше белгілерін сандық сипаттайтын векторлық көрсетілімдер, оларды сандық форматта ықшам және ақпаратты түрде көрсетуге мүмкіндік береді. Бұл бет-әлпетті тану және сәйкестендіру міндеттерін машиналық оқыту әдістері мен терең нейрондық желілер арқылы едәуір жеңілдетеді (Jha et. al., 2023; Boutros et. al., 2023). Бет-әлпет ендіргіштері бет кескіндерін талдау және салыстыруға ыңғайлы формаға түрлендіруде маңызды рөл атқарады, бұл бір кадрда бірнеше бетті бір мезгілде тануды қажет ететін көпбағынды жүйелерде ерекше маңызды. Faster Region-Convolutional Neural Network (Faster R-CNN) (Opanasenko et. al., 2024;

Ikromovich et. al., 2023) сияқты заманауи бет-әлпетті тану әдістері сенімді конволюциялық нейрондық желі (CNN) архитектураларын қолданады, бұл кескіндерді өңдеу дәлдігі мен жылдамдығын айтарлықтай арттырады. Осы мақалада нақты уақыт режимінде бет-әлпетті тануды жақсарту үшін әртүрлі архитектураларды (ResNet50 (Hangaragi et. al., 2023; Mamieva et. al., 2023), MobileNetV3, EfficientNetB0) және Self-Attention механизмін қолдану қарастырылады. Бұл архитектуралар жүйенің бейне тізбектерінде әртүрлі жарық жағдайлары, бұрыштар мен сценарийлерге бейімделуін қамтамасыз ете отырып, жоғары тану дәлдігін ұсынады.

Мақалада (Minaee et. al., 2023; Melzi et. al., 2023) ым-ишара тілін тануға арналған CDVGG-16 терең нейрондық желісін пайдалану әдісі ұсынылған. Әдіс бейнені өңдеу арқылы нақты уақыт режимінде ишараларды жіктеу міндетін шешеді. Бұл процесс деректерді жинау, кескіндерді алдын ала өңдеу және жіктеуден тұрады. VGG-16 архитектурасы конволюциялық және максималды таңдау қабаттарынан тұрады, бұл ишара ерекшеліктерін тиімді түрде бөліп алуға мүмкіндік береді. VGG-19-ға қарағанда, бұл модель шамадан тыс сәйкестену ықтималдығын азайтады. Әдіс 95,6 % дәлдікке, 99,9 % қамту көрсеткішіне және жылдам орындау уақытына (0,125 секунд) қол жеткізіп, нақты әлемдегі ым-ишара тілін тану қосымшалары үшін жарамдылығын растайды.

(Chai et. al., 2023) Мақалада бейне кескіндерді өңдеу технологияларын және бөлшектердің ройын оңтайландыру алгоритмін қолдану арқылы спорттық дайындықты жақсарту мүмкіндігі қарастырылған. Дәстүрлі тәсілдер жаттықтырушылардың визуалды бағалауларына негізделгендіктен, спортшылардың дайындық деңгейін арттыруда шектеулі. Ұсынылған қозғалысты тану жүйесі спортшылардың қозғалыс траекторияларын талдауға және анықтамалық қозғалыстармен салыстыруға мүмкіндік береді, бұл дайындық процесін жақсартуға ықпал етеді. Қозғалысты тануды оңтайландыру үшін бөлшектер ройын оңтайландыру алгоритмі қолданылып, спорттық дайындық технологияларын дамытуға елеулі үлес қосады.

(Abdykerimova et. al., 2023) Мақалада адам әрекеттерін бейнеден тануға арналған жаңа динамикалық PSO-ConvNet моделі ұсынылады, ол конволюциялық нейрондық желілерді (ConvNets) және бөлшектер ройын оңтайландыру алгоритмін (PSO) біріктіреді. Transformer және қайталанатын нейрондық желілер (RNNs) сияқты уақыттық деректерді өңдеу әдістерімен интеграция бейнедегі әрекеттерді жіктеу дәлдігін арттырады. UCF-101, Kinetics-400 және HMDB-51 деректер жинақтарындағы эксперименттер тану дәлдігінің 9%-ға дейін артуын көрсетті. PSO-ConvNet моделі адамның әрекеттерінің кеңістіктік-уақыттық динамикасын тиімді түрде анықтап, тану сапасын жақсартуға мүмкіндік береді.

(Uzakkyzy et. al., 2023) Мақалада видео негізінде бет мимикасын тануға (VFER) арналған гибриді нейрондық желі архитектурасы ұсынылған, ол үш өлшемді конволюциялық нейрондық желіні (3D-CNN) және конволюциялық LSTM (ConvLSTM) желісін біріктіреді. Бұл модель эмоцияларды бейнелей-

тін бейне тізбектерінен кеңістіктік-уақыттық ақпаратты тиімді түрде анықтап, SAVEE, CK+ және AFEW деректер жинақтарында жоғары дәлдікті көрсетеді. Дәстүрлі модельдерге қарағанда, ұсынылған архитектура аз параметрлерді пайдаланып, орындау жылдамдығын арттырады, бұл оны ресурстары шектеулі құрылғыларда нақты уақытта қолдануға мүмкіндік береді.

(Podorozhniak et. al., 2023) Мақалада бейнедегі адам әрекеттерін тануға арналған (HAR) жаңа әдіс ұсынылған, ол бірнеше белгілерді біріктіруге негізделген. Камера қозғалысы, адам қозғалысының тұрақсыздығы және күрделі фон сияқты қиындықтарды шешу үшін тұрақты бейненің инвариантты дескрипторы әзірленді. Әдіс қозғалысты талдау үшін оптикалық ағынды (OF) және бағытталған градиенттердің гистограммасын (HOG), ал пішінді сипаттау үшін жергілікті үштік өрнектерді (LTP) және Цернике моменттерін (ZM) біріктіреді. Осы белгілердің бірігуі соңғы векторды қалыптастырады. IXMAS, CASIA және TV-HI деректер жинақтарындағы эксперименттер бұл әдістің дәлдігі 98,66%-ға дейін жоғары екенін көрсетті. Нәтижелер қолданыстағы әдістерден асып түсіп, ұсынылған тәсілдің тиімділігін дәлелдейді.

Қазіргі заманғы әдістердің бірі – Vision Transformers (ViTs) (Kumar et. al., 2023;), компьютерлік көру мәселелерін шешуде перспективалы технологиялардың бірі болып саналады. Олар кескіндердегі ғаламдық тәуелділіктерді тиімді түрде ескеріп, көптеген тапсырмаларда дәстүрлі конволюциялық нейрондық желілерден (CNNs) асып түседі. Мысалы, гиперспектралды және лидарлық деректерді бірлесіп жіктеуге арналған Modality Fusion Vision Transformer зерттеуі (Lysechko et. al., 2023) Vision Transformers-тің мультимодальды деректерді тиімді өңдей алатынын және жоғары жіктеу дәлдігіне қол жеткізетінін көрсетеді. Тағы бір зерттеуде Vision Transformers-тің жол белгілерін жіктеуге арналған мүмкіндіктері қарастырылып, нақты уақытта объектілерді тануда елеулі нәтижелерге қол жеткізілгенін көрсетті.

Ұсынылған тәсілдің маңызды ерекшелігі – бет ендірмелерін терең оқыту модельдерін оқыту процесіне интеграциялау, бұл жүйенің көпағынды тану мәселелерін жақсырақ шешуіне мүмкіндік береді. Нақты әлемдік жұмыс жағдайларында ұсынылған әдістердің қолданылу мүмкіндігін анықтау үшін модельдердің әртүрлі оқыту кезеңдеріндегі дәлдігі мен тұрақтылығын талдауға ерекше назар аударылады. Осылайша, бұл жұмыс бейне тізбектерінде нақты уақыттағы кескіндерді тануға арналған теңдестірілген тәсілді әзірлеу мен талдауға бағытталған. Ұсынылған нәтижелер мен тұжырымдар бет-әлпетті тану жүйелерін одан әрі жетілдіру үшін пайдаланылуы мүмкін, бұл әсіресе қауіпсіздікті қамтамасыз ету және әртүрлі салалардағы жекелендірілген қызметтер үшін маңызды.

Бет-әлпетті және қозғалатын объектілерді тану жүйелеріндегі айтарлықтай жетістіктерге қарамастан, заманауи әдістер бірқатар шектеулерге тап болады. Негізгі мәселелердің бірі – әртүрлі жарықтандыру жағдайларында, көру бұрыштарында және күрделі көрініс сценарийлерінде жоғары дәлдікті

қамтамасыз ету, бұл қауіпсіздік пен бейнебақылау сияқты нақты қолдану салаларында ерекше өзекті. Сондай-ақ, мұндай жүйелерді шектеулі есептеу ресурстарымен жұмыс істеуге бейімдеу кемшіліктері бар, бұл олардың мобильді және кіріктірілген жүйелерде тиімділігін төмендетеді. Біздің зерттеулеріміз бұл мәселелерді терең оқыту тәсілдерін, атап айтқанда, әртүрлі базалық архитектуралары бар Faster R-CNN (ResNet-50, MobileNet V3 Large, EfficientNetB0) және өзіндік назар (Self-Attention) механизмін қолдану арқылы шешуге бағытталған. Бұл технологиялар күрделі жағдайларда да объектілерді анықтау мен тану жүйелерінің дәлдігі мен тұрақтылығын айтарлықтай жақсартуға мүмкіндік береді..

Әдістер мен материалдар

Бұл жұмыс бет-әлпетті танудың қолданыстағы әдістерін соңғы терең оқыту технологияларын, мысалы, бет-әлпет ендірімелерін пайдалану арқылы жетілдіруге және бір кадрда бірнеше бетті бір мезгілде тануға арналған көпағынды режимде қолдануға бағытталған. Бет-әлпет ендірімелері – адамның бетінің ерекше ерекшеліктерін сандық түрде сипаттайтын векторлық көрсетілімдер. Бет-әлпет ендірімесі – адамның бетінің ерекше ерекшеліктерін сандық түрде сипаттау үшін қолданылатын векторлық көрсетілім (1-сурет).

$$f\left(\text{Image of a man's face}\right) = \begin{pmatrix} 0.112 \\ 0.067 \\ 0.091 \\ 0.129 \\ 0.002 \\ 0.012 \\ 0.175 \\ \vdots \\ 0.023 \end{pmatrix}$$

Сур. 1. Бет векторының көрінісі

Ендірімелер бет-әлпетті ықшам және ақпаратты түрде сандар жиынтығы ретінде көрсетуге мүмкіндік береді, бұл машиналық оқыту және терең нейрондық желілер арқылы бет-әлпетті тану және сәйкестендіру міндеттерін едәуір жеңілдетеді. Бет-әлпетті сәйкестендіру міндеттерінде ендірімелер бет бейнесін талдау және салыстыруға ыңғайлы формаға түрлендіруде маңызды рөл атқарады. Бет ендірімесі – көпөлшемді кеңістіктегі (мысалы, 128 немесе 512 өлшемді) вектор, мұндағы әрбір элемент бет-әлпеттің ерекше ерекшеліктерін сандық түрде сипаттайды. Бұл ерекшеліктерге бет құрылымы, мысалы, көздер арасындағы қашықтық, мұрынның пішіні, еріннің өлшемі және әрбір бетке тән басқа да геометриялық параметрлер жатады. Сондай-ақ, терінің әжімдер, меңдер және тері тесігі сияқты текстуралық сипаттамалары да ескеріледі. Ендіріме бет-әлпеттің эмоциялардан тәуелсіз ерекшеліктерін сақтау негізгі міндеті бола отырып, кейде бет-әлпеттегі эмоция туралы ақпаратты ішінара қамтуы

мүмкін. Жүйе жарықтандыру мен бұрыштардың өзгеруіне төзімді болуы керек, ал ендіріме бұл міндетті беттегі тұрақты сипаттамаларға назар аударып, ұсақ өзгерістерді елемеу арқылы орындайды.

Бет ендірімелері бет кескіндерінің үлкен деректер жинағы негізінде оқытылған нейрондық желілерді пайдалану арқылы жасалады. FaceNet сияқты желілер конволюциялық нейрондық желілер (CNN) құрылымдарын қолданып, кіріс бет кескінін ендірімеге түрлендіреді. FaceNet моделі Inception-ResNet V1 архитектурасын қолданып, VGGFace2 деректер жинағында алдын ала оқытылған бет координаттарын анықтауға арналған. Деректер алдын ала өңделіп, нормализация, 160x160 пиксельге дейін масштабтау және MTCNN арқылы беттерді бөлу кезеңдерінен өтті. Модельді оқыту үшін қолданылған негізгі гиперпараметрлер: оқу жылдамдығы – 0,001, Adam оптимизаторы және 32-ден 128 бейнеге дейінгі топ көлемі. Бұл процесс келесідей сипатталуы мүмкін: кіріс бет кескіні X алдымен желінің бірнеше конволюциялық қабатынан өтеді, бұл қабаты әртүрлі ерекшеліктерді бөліп алады. Бұл ерекшеліктер бет текстураларын, пішіндерін және басқа да элементтерін сипаттайтын ерекшеліктер карталарын құрайды (1):

$$F = CNN(X) \quad (1)$$

Содан кейін мүмкіндіктер қалыпқа келтіріліп, орташаланған тұрақты ұзындық векторы алынады, ол бет кірістіруіне айналады (2):


$$E = \text{Normalize}(FC(F)) \quad (2)$$

Қалыпқа келтіру модельді жарықтық, контраст және басқа кескін параметрлеріндегі өзгерістерге төзімдірек етуге көмектеседі. Бетті ендіру әртүрлі беттерді тиімді салыстыруға мүмкіндік береді. Бет-әлпетті тану жүйесі жаңа кескінді қабылдағанда, ол сол беттің ендіруін жасайды және оны дерекқорда бұрыннан бар беттердің кірістіруімен салыстырады. Енгізулер арасындағы қашықтық белгілі бір шектен төмен болса, беттер бірдей болып саналады. Салыстыру әдісі көбінесе екі кірістіру арасындағы евклидтік қашықтыққа негізделген (3):

$$D(E_1, E_2) = \sqrt{\sum_{i=1}^n (E_1[i] - E_2[i])^2} \quad (3)$$

Енгізулер сәйкестендіру жүйелерінің дәлдігі мен сенімділігін айтарлықтай жақсартады, әсіресе бірнеше бетті бір уақытта тануды қажет ететін көп ағынды режимде. Енгізулер жарықтандыру және бастың орналасуы сияқты әртүрлі факторлардың әсерін азайтады және деректерді өңдеудің жоғары жылдамдығын қамтамасыз етеді. Бұл ендірулерді Faster-RCNN сияқты терең оқыту үлгілерінде пайдалану тіпті күрделі сценарийлерде, мысалы, кадрда бірнеше беттер бір уақытта болған кезде де бетті тану дәлдігі мен жылдамдығын айтарлықтай арттыруға мүмкіндік береді. Бірегей сәйкестендіру

нөмірлері (ЖСН) — әрбір Қазақстан азаматына берілген нөмірлер жүйені оқыту үшін белгі ретінде пайдаланылды. Бұл сандар сәйкестендіру процесінде маңызды рөл атқарады, өйткені олар тұлғаны белгілі бір адамға бір мәнді түрде байланыстыруға мүмкіндік береді, бұл әсіресе автоматтандырылған жүйелерде маңызды. Бұл құжат бет-әлпетті тану үлгілерін құру және оқытудың әртүрлі тәсілдерін, соның ішінде ResNet және MobileNet көмегімен Faster-RCNN сияқты архитектураларды пайдалануды қарастырады. Ол олардың артықшылықтарын, кемшіліктерін және нақты әлем жағдайында қолдану мүмкіндігін бағалайды. Жаттығу кезінде модельдің дәлдігі мен жоғалуын талдауға ерекше назар аударылады, бұл олардың жалпы өнімділігі мен нақты тапсырмаларды шешуге жарамдылығы туралы қорытынды жасауға мүмкіндік береді. Атап айтқанда, кескіндерде тиімді нысанды анықтау және жіктеу үшін конволюционды нейрондық желі (CNN) әдістерін қызығушылық аймағы (ROI) алу алгоритмдерімен біріктіретін Faster R-CNN архитектурасы ұсынылған (2-сурет). Faster R-CNN бағдарламасының негізгі идеясы конвульсиялық желілердің мүмкіндіктерді шығару мүмкіндіктерін аймақтық генерациялау механизмімен біріктіру болып табылады, бұл оны компьютерлік көрудегі тапсырмаларды анықтаудың ең күшті құралдарының біріне айналдырады.



Сур. 2. Жылдамырақ R-CNN архитектурасы

Сипатталған сәулетте ұсынылған үш үлгінің бірін (ResNet-50 FPN, MobileNet V3 Large немесе Self-Attention механизмі бар EfficientNetB0) пайдаланып мүмкіндікті шығарғаннан кейін мүмкіндіктер аймақ ұсыныстарын бейімдейтін ROI Pooling модуліне беріледі. толық қосылған қабат үшін қажетті бекітілген өлшемге дейін. Содан кейін нысанды классификациялау кросс-энтропия функциясын және Softmax және Smooth L1 жоғалту функциясын пайдаланып шектейтін қорап регрессиясын пайдаланып орындалады. Бұл процесс нысанды тиімді классификациялауға және кескінде локализациялауға мүмкіндік береді. Faster R-CNN архитектурасында әртүрлі магистральдық үлгілерді пайдалану оны әртүрлі тапсырмаларға бейімдеуге мүмкіндік береді. ResNet-50 FPN қалдық блоктары және Feature Pyramid Network (FPN) архитектурасы бар терең желі ретінде күрделі көріністерде анықтау немесе

медициналық бейнелеу сияқты жоғары дәлдікті және әртүрлі масштабтағы нысандардың өңдеу мүмкіндігін талап ететін тапсырмалар үшін қолайлы. Мобильді құрылғылар мен нақты уақыттағы жүйелер сияқты жоғары жылдамдықты және ресурстарды аз тұтынуды қажет ететін қолданбалар үшін терең конверсиялар мен басқа архитектуралық жақсартуларға байланысты шектеулі есептеу ресурстары үшін оңтайландырылған MobileNet V3 Large таңдаулы таңдау болып табылады. EfficientNetB0, Self-Attention көмегімен дәлдік пен есептеу тиімділігін теңестіреді, бұл оны жоғары дәлдік пен контекстік ақпаратты қажет ететін тапсырмаларда пайдалы етеді. Әртүрлі магистральдар арасында таңдау мүмкіндігі Faster R-CNN-ге жоғары дәлдіктегі медициналық қолданбалардан жылдам, мобильді шешімдерге дейін кең ауқымды функцияларға бейімделуге мүмкіндік береді.


Нәтижесінде, модельдің соңғы нәтижесі күрделі нысандар мен көріністерді тануда оның дәлдігін айтарлықтай арттыра отырып, жергілікті ерекшеліктерді де, жаһандық қатынастарды да қарастырады. Осылайша, EfficientNet архитектурасына Self-Attention механизмін біріктіру кескіннен мүмкіндіктерді тиімді шығаруға және кескіннің әртүрлі бөліктері арасындағы контекстік қатынастарды қарастыруға қабілетті неғұрлым қуатты және жан-жақты модель жасайды. Бұл тәсіл жергілікті және ғаламдық ақпарат маңызды болып табылатын нысанды анықтау және тану тапсырмаларына пайдалы. Барлық үш үлгіні (Faster-RCNN ResNet50 FPN, MobileNetV3 Large және EfficientNetB0 бар ResNet50 FPN) жаттықтыру үшін келесі гиперпараметрлер пайдаланылды: үйрену жылдамдығы 0,005, импульсі 0,9 SGD оңтайландырғышы, партия өлшемі 4 және салмақтың төмендеуі 0,0005. Бұл параметрлер тұрақты конвергенцияны және нысанды анықтау тапсырмасында жоғары өнімділікті қамтамасыз етті.

Нәтижелер және оларды талқылау

Ұсынылған схема бет-әлпетті тану жүйесін әзірлеу процестерінің ретін көрсетеді, әсіресе жеке куәлікті тіркеуде. Ол сәйкестендіру нөмірін (ID) енгізуден басталып, жиналған деректер негізінде модельді оқытумен аяқталады (3-сурет). Бұл сипаттама әрбір кезеңнің егжей-тегжейлі шолуын, оның маңыздылығын, жүзеге асыру әдістерін және нақты әдістер мен алгоритмдерді таңдау себептерін береді.

Бет-әлпетті тіркеу процесі 12 таңбадан тұратын бірегей сандық жолды пайдаланушының сәйкестендіру нөмірін (ID) енгізуден басталады. Бұл нөмір пайдаланушының жеке ақпаратының кілті ретінде қызмет етеді және екі негізгі критерий бойынша тексеріледі: сандық түрі және ұзындығы. Идентификатор тексеруден өткеннен кейін жүйе келесі қадамға көшеді. Келесі қадам пайдаланушы бетінің бейнежазбасын жазуды қамтиды. Бейне шамамен 10 секундқа созылады, оның барысында жүйе 250-ден 300-ге дейінгі бет бейнесін түсіреді. Деректердің бұл көлемі әртүрлілікті қамтамасыз ету үшін қажет, бұл әрі қарай өңдеу және модельді оқыту үшін өте маңызды. Әртүрлі бұрыштардан және әртүрлі жарық жағдайларында түсірілген бет кескіндері неғұрлым әртүрлі

болса, тану және сәйкестендіру дәлдігі соғұрлым жоғары болады.



Сур. 3. Бет-әлпетті тану процестерінің реттілігі


Бейне түсірілгеннен кейін әрбір кадрдан бет координаталарын алу үшін алдын ала дайындалған FaceNet үлгісі қолданылады. Бет-әлпетті тану тапсырмалары үшін арнайы әзірленген FaceNet төрт координаттың көмегімен кескіндегі бет шекарасын анықтайды: x_{min} , y_{min} , x_{max} және y_{max} . Бет өлшемі жеткіліксіздігімен байланысты қателерді болдырмау үшін жүйе x_{max} және x_{min} және y_{max} және y_{min} арасындағы айырмашылық кемінде 10 пиксель екенін тексереді. Бұл кескіндердің беттің де болатынын қамтамасыз етеді.

Жүйенің маңызды міндеттерінің бірі - FaceNet үлгісімен де орындалатын бет ендірулерді жасау. Енгізу - беттің бірегей ерекшеліктерін сандық түрде сипаттайтын көп өлшемді вектор. Бұл векторлық көріністер жүйеге беттерді жоғары дәлдікпен салыстыруға және жіктеуге мүмкіндік береді, жарықтандыру, бас бағдары немесе бет әлпеті сияқты түсіру жағдайларындағы өзгерістерге оның беріктігін арттырады. Бет координаттары мен ендірулерді шығарғаннан кейін деректер үлгіні оқыту процесінде қолданылатын аннотациялар ретінде сақталады. Аннотациялар кескін жолын, бірегей сәйкестендіру нөмірін (ID), бет шекарасының координаттарын және бет векторының көрінісін қамтиды. Бұл

деректер жаттығу кезінде әрбір ендірілген векторды белгілі бір сәйкестендіру нөмірімен байланыстыру және болашақта жаңа кескіндердегі адамдарды дәл тануы үшін модель үшін маңызды. Үлгіні оқытуды бастамас бұрын деректерді тазалау қажет. Бейне жазу кезінде бұлыңғыр немесе толық емес бет дисплейлері сияқты сапасыз фотосуреттер түсірілуі мүмкін. Мұндай кескіндер оқу процесіне теріс әсер етуі мүмкін, өйткені модель дұрыс емес мүмкіндіктерді тануды үйренуі мүмкін. Сондықтан, кейбір фотосуреттер деректер жинағынан жойылады, тек сапалы үлгіні оқытуға жарамды фотосуреттер қалады. Соңында, модельді оқыту процесі жиналған аннотацияларды пайдалана бастайды. Жаттығу кезінде модель тану қателерін азайту үшін мыңдаған итерациялар бойынша параметрлерін оңтайландырады. Деректер жиынындағы әрбір сурет модельге адамды дәл анықтау үшін қажетті негізгі мүмкіндіктерді жақсы түсінуге көмектеседі.

MobileNetV3 Large бап Faster-RCNN үлгісі шектеулі есептеу ресурстары бар орталарда пайдалану үшін нақты әзірленген, бұл оны мобильді және ендірілген жүйелер үшін өте қолайлы етеді. 4-суретте жаттығу кезінде бет-әлпет дифференциациясының дәлдігі көрсетілген. График тіпті ең аз дәуірлер санының өзінде модельдің жоғары классификация дәлдігіне тез қол жеткізетінін көрсетеді, бұл оның ResNet50 сияқты күрделі модельдермен салыстырғанда параметрлердің азайған санына және жеңілдетілген архитектурасына қарамастан беттерді тиімді тану қабілетін көрсетеді. Оңтайландырылған архитектурасының арқасында, терең ажыратылатын конвульсияларды пайдалана отырып, MobileNetV3 Large оқыту мен қорытынды жасауға қажетті параметрлер мен есептеулердің санын айтарлықтай азайтады. Сонымен қатар, бұл архитектура әртүрлі оңтайландыруларды қамтиды, мысалы, сызықтық емес және нейрондық архитектураны іздеу (NAS) әдістерін пайдалану, ең аз есептеу шығындарымен жоғары дәлдікке қол жеткізуге мүмкіндік береді. Faster-RCNN моделін MobileNetV3 Large көмегімен үйрету небәрі 40 минутты алды, мұны оның жеңіл архитектурасына жатқызуға болады. ResNet50-ге қарағанда аз параметрлерге және қарапайым құрылымға қарамастан, модель нысанды тануда жеткілікті жоғары өнімділікті көрсетеді. Бұл MobileNetV3 Large қолданбасын нақты мобильді қолданбалар немесе нақты уақыттағы бақылау жүйелері сияқты дәлдік пен өңдеу жылдамдығы арасындағы теңгерімді қажет ететін тапсырмалар үшін практикалық таңдау жасайды. Дегенмен, қысқартылған жаттығу уақыты мен есептеу жүктемесі объектінің ішінара окклюзиясы немесе дәстүрлі емес бұрыштарда пайда болуы сияқты күрделі жағдайларда дәлдік пен беріктіктің аздап төмендеуімен байланысты. Дегенмен, оңтайландыруларының арқасында MobileNetV3 Large уақыт пен ресурстар маңызды болып табылатын көптеген практикалық қолданбалар үшін қуатты құрал болып қала береді.


MobileNetV3 Large көмегімен Faster-RCNN үлгісін оқыту процесі де жоғары дәлдікті көрсетеді, дегенмен жоғалту динамикасы мен жаттығу процесі ResNet50 FPN үлгісінен біршама ерекшеленеді.



Сур. 4. MobileNetV3 Large көмегімен Faster-RCNN моделінің дәлдігі

Бірінші дәуірде орташа жоғалту 0,2581, дәлдігі 95,70 %-ға жетті. Бұл бастапқы жоғалту мәні мобильді және ендірілген жүйелер үшін оңтайландырылған MobileNetV3 жеңіл архитектурасына жатқызылуы мүмкін ResNet үлгісінен жоғары. Дегенмен, екінші дәуірде жоғалту 0,1348-ге дейін айтарлықтай төмендеді және дәлдік 100 % жетті, бұл модельдің жылдам конвергенциясын және шектеулі есептеу ресурстарымен де тиімді оқу мүмкіндігін көрсетеді. Кейінгі дәуірлерде жоғалтудың біршама ауытқуы байқалды, бұл модельдің неғұрлым күрделі деректерге сезімталдығын көрсетеді. Мысалы, үшінші дәуірде жоғалту 0,1435-ке дейін өсті, ал бесінші дәуірде дәлдік 100% сақталса да, 0,1601-ге дейін көтерілді. Бұл ауытқулар қалған дәуірлерде жалғасты, жоғалту алтыншы дәуірдегі 0,1594-тен он төртінші дәуірдегі 0,1871-ге дейін өзгерді. Осы ауытқуларға қарамастан, модель жоғары дәлдікті сақтап қалды, бұл оның жақсы жалпылау қабілетін және деректер өзгерістеріне беріктігін көрсетеді. Дегенмен, жоғалтудың мұндай құбылмалылығы қосымша талдауды және әлеуетті оңтайландыруды қажет ететін оқу деректер жинағындағы өзгерістерге ықтимал шамадан тыс орнатуды немесе жоғары сезімталдықты көрсетуі мүмкін. 3-суретте MobileNet желісін магистраль ретінде пайдаланып үйретілген Faster-RCNN үлгісінің дәлдік қисығы берілген. График модельдің дәлдігі жаттығу дәуірлерінің санына байланысты қалай өзгеретінін көрсетеді. Y осі дәлдікті, ал X осі дәуірлер санын білдіреді. Модель алғашқы екі дәуірден кейін шамамен 100 % дәлдікке қол жеткізе отырып, оқытудың бастапқы кезеңдерінде айтарлықтай жақсаруды көрсетеді. Одан кейінгі дәуірлер 100 % тұрақты дәлдікті көрсетеді, бұл модельдің тиімді үйренетінін және жаттығудың басында тұрақтанатынын көрсетеді. Бұл модельдің жылдам конвергенция жылдамдығын көрсетеді, бұл әсіресе шектеулі есептеу ресурстары бар мобильді және ендірілген құрылғыларда жаттығу кезінде маңызды. 5-суретте магистраль ретінде MobileNet бар бірдей Faster-RCNN моделінің жоғалу графигі көрсетілген. График жаттығу дәуірі ұлғайған сайын орташа шығынның қалай


төмендейтінін көрсетеді. Жаттығудың басында жоғалту 0,26 шамасында болса, бірінші дәуірден кейін ол 0,14-ке дейін күрт төмендейді. Шығынның бірте-бірте өсуі келесі дәуірлерді сипаттайды; дегенмен, бұл өсу ең аз және шамалы ауытқулар шегіне түседі. Бұл жоғалту динамикасы модельдің тез үйренетінін және тұрақты деңгейге жететінін көрсетеді, дегенмен жоғалтудың шамалы артуы күрделірек деректерге біршама артық сәйкестікті немесе сезімталдықты көрсетуі мүмкін.



Сур. 5. Әлеуметтік процестерге әртүрлі факторлардың әсері

Магистраль ретінде ResNet50 FPN пайдаланатын Faster-RCNN моделі күрделі және терең архитектурасына жатқызылған нысанды танудағы жоғары дәлдікпен тұрақтылықты көрсетті. ResNet50, 50 қабаты бар терең конволюциялық нейрондық желі, қарқынды желілерді оқыту кезінде жоғалып кететін градиент мәселесін болдырмауға көмектесетін қалдық блоктарды пайдаланады. Бұл модельге күрделі кескін нысандарымен жұмыс істегенде де жоғары дәлдікті сақтай отырып, үлкен деректер жиынынан тиімді үйренуге мүмкіндік береді. Мүмкіндік пирамидасы желісін (FPN) ResNet-пен біріктіру модельге әртүрлі масштабтағы мүмкіндіктерді шығаруға мүмкіндік беретін күрделіліктің тағы бір деңгейін қосады. Бұл кескінде әртүрлі өлшемдерде және перспективаларда пайда болуы мүмкін нысандарды анықтау дәлдігін жақсартады. Алайда мұндай күрделі құрылым айтарлықтай есептеу ресурстарын қажет етеді. Faster-RCNN үлгісін ResNet50 FPN көмегімен оқыту 183 минутқа созылды, мұны әрбір желі деңгейінде көптеген параметрлерді есептеу және көп деңгейлі мүмкіндіктерді өңдеу қажеттілігімен байланыстыруға болады (6-сурет). Ұзақ жаттығу уақытына қарамастан, модель жоғары дәлдікті, тұрақтылықты және жалпылау мүмкіндігін көрсетеді, бұл оны жоғары сенімділік пен дәлдікті қажет ететін тапсырмалар үшін таңдаулы таңдау жасайды. Бұл әсіресе егжей-тегжейлі талдауды және қуатты мүмкіндіктерді шығару мүмкіндіктерін қажет ететін ішінара жасырылған нысандар немесе күрделі перспективалар сияқты күрделі жағдайларды ескеру қажет қауіпсіздік жүйелері мен медициналық кескінді


талдау үшін өте маңызды.



Сур. 6. Әлеуметтік процестерге әртүрлі факторлардың әсері

ResNet50 FPN көмегімен Faster R-CNN үлгісін оқыту процесі барлық 15 дәуірде тұрақты жоғары өнімділікті көрсетті. Бірінші дәуірде орташа жоғалту 0,0922 болды, дәлдік 93,75 % жетті, бұл модельдің объектіні танудағы жоғары бастапқы мүмкіндігін көрсетеді. Әрбір келесі дәуірде жоғалтудың айтарлықтай азаюы болды: екінші дәуірде жоғалту 0,0261-ге дейін азайып, дәлдік 100% жетті. Бұл жоғалтудың күрт төмендеуі және жоғары дәлдік модельде жылдам үйренуді және салмақты тиімді реттеуді ұсынады. Одан әрі оқыту орташа жоғалтудың үздіксіз төмендеуімен сипатталды, дәлдік қалған дәуірлерде тұрақты жоғары — 100 % сақталды. Мысалы, үшінші дәуірде шығын 0,0192-ге дейін төмендеді; бесіншіден, ол 0,0152-ге дейін төмендеді. Он бесінші дәуірде 0,0105 минимумға жететін жоғалтудың бірте-бірте төмендеуі модельдің деректерді тиімді жалпылайтынын және тану қателерін барынша азайтатынын көрсетеді. Бір қызығы, жоғары дәлдікке қол жеткізгеннен кейін де жаттығу процесі жалғасып, модель деректерге бейімделуді жалғастырды, мұны оқытудың кейінгі кезеңдерінде жоғалтудың шамалы жақсаруы дәлелдейді. Бұл нысанды анықтау тапсырмаларында ResNet50 FPN үлгісінің жоғары тұрақтылығы мен сенімділігін көрсетеді. 5-суретте Faster-RCNN үлгісі үшін дәлдіктің ұқсас графигі берілген, бұл жолы ResNet-ті магистраль ретінде пайдаланады. MobileNet сияқты, модель ерте оқыту дәуірлерінде дәлдіктің жылдам өсуін көрсетеді. Бірінші дәуірден кейін дәлдік 99%-ға дейін көтеріліп, кейінгі дәуірлерде 100%-ға жуық деңгейге жетті және сақталды. Бұл нысанды анықтау тапсырмаларындағы ResNet-тің жоғары тиімділігін және оның жіктеу тапсырмаларына жылдам бейімделу қабілетін көрсетеді. Тұрақты дәлдік әрекеті сонымен қатар модельдің кіріс деректеріндегі әртүрлі вариацияларды тиімді өңдей алатындығын көрсетеді. 7-суретте магистраль ретінде ResNet бар Fast-er-RCNN моделінің жоғалу графигі көрсетілген. Жаттығудың басында жоғалту 0,09 шамасында болады, бұл MobileNet моделі үшін бастапқы жоғалтудан төмен. Бұл мүмкіндіктерді шығару және өндеуде жақсырақ ResNet архитектурасына

байланысты болуы мүмкін. Дәуір саны азайған сайын жоғалту жылдам азаяды және үшінші дәуірден кейін 0,01 шамасында тұрақтанады. MobileNet үлгісінен айырмашылығы, жоғалтудың кейінгі өсуі байқалмайды, бұл жалпы жалпылау қабілетінің жақсырақ болуын және артық орнату ықтималдығының төмендігін көрсетуі мүмкін.




Сур. 7. Әлеуметтік процестерге әртүрлі факторлардың әсері


EfficientNetB0 көмегімен Self-Attention механизмімен үйлесетін Faster R-CNN моделінің оқыту процесі әртүрлі оқыту дәуірлеріндегі дәлдік пен жоғалту графиктері арқылы көрсетілгендей жоғары тиімділік пен жылдам конвергенцияны көрсетеді. 8-суретте дәуірлер санының өсуіне қарай модельдің дәлдік динамикасы көрсетілген. Бірінші дәуірде дәлдік 30,34 % құрайтынын байқауға болады, бұл салыстырмалы түрде төмен көрсеткіш. Дегенмен, модель оқу процесін енді ғана бастап, деректерге бейімделуде. Әрбір келесі дәуірде дәлдіктің айтарлықтай өсуі байқалады, секундына 97,30 % жетеді, бұл модель архитектурасының тиімділігін және оның тез үйрену қабілетін көрсетеді. Ең бастысы - үшінші дәуірге дейін 100 % максималды дәлдікке жету, ол қалған барлық дәуірлерде сақталады. Бұл модельдің сәтті үйренгенін және деректердегі ықтимал өзгерістерге қарамастан нысандарды жоғары дәлдікпен дәйекті түрде тани алатынын көрсетеді.

9-суретте оқытудың 15 дәуіріндегі орташа шығынның өзгеруі көрсетілген. Бірінші дәуірде орташа жоғалту 0,4611 құрайды, бұл оқытудың бастапқы кезеңін ескере отырып күтілетін нәтиже. Әрбір келесі дәуірде жоғалту айтарлықтай төмендейді: екінші дәуірде орташа жоғалту 0,2097-ге дейін төмендейді, бұл модельдің сәтті оқытылуын және тану қателерінің азайғанын көрсетеді. Үшінші дәуірде жоғалту 0,1216 дейін төмендейді, бұл модель 100 % дәлдікке жеткен сәтке сәйкес келеді. Бұл модельдің тиімді оқып жатқанын және қателер азайтылатын деңгейде тұрақтанатынын көрсетеді. Төртінші дәуірден бастап жоғалту бірте-бірте азаяды, 15-ші дәуірде шамамен 0,0289 минимумға жетеді. Бұл модельдің баяу болса да жақсара беретінін көрсетеді. Бұл модель жоғары дәлдікке қол жеткізген кезде және тек қалған қателерді азайтуды қажет ететін

оқытудың соңғы кезеңдеріне тән.




Сур. 8. Модель дәлдігі динамикасы



Сур. 9. Жоғалту динамикасының графигі

Әр дәуірдің жаттығу уақыты да ерекше. Бірінші дәуірде модель шамамен 28 минут жаттығады, бұл сәулеттің бұл түрі үшін орташа уақыт. Келесі дәуірлерде жаттығу уақыты сәйкесінше 45 және 52 минутқа дейін айтарлықтай өсетін 13 және 14-ші дәуірлерді қоспағанда, жаттығу уақыты шамамен өзгеріссіз қалады. 13-ші және 14-ші дәуірлердегі жаттығу уақытының ұлғаюы, мүмкіндіктер арасындағы жаһандық тәуелділікті өңдеу үшін көбірек ресурстарды қажет ететін Өзіне-өзі назар аудару механизмінің есептеу күрделілігінің артуына байланысты. Өзіндік зейін оқытудың кейінгі кезеңдерінде көрінетін квадраттық есептеу күрделілігін қосады. Оңтайландыру үшін соңғы дәуірлердегі деректер ажыратымдылығын азайтуды немесе өзін-өзі бақылаудың тиімдірек нұсқаларын пайдалануды қарастыруға болады. Уақыттың бұл өсуі шығынды азайтудың күрделілігіне және модельдің деректердегі күрделі жағдайларға мұқият бейімделу қажеттілігіне байланысты болуы мүмкін. Соған қарамастан, оқу уақытының ұлғаюына қарамастан, модель жоғары дәлдікті сақтайды және

шығындарды азайтады, бұл оның беріктігін және күрделі деректерді тиімді өңдеу мүмкіндігін растайды. Осылайша, EfficientNetB0 және Self-Attention механизмін пайдаланатын Faster R-CNN үлгісі нысанды анықтау тапсырмаларында тамаша нәтижелерді көрсетеді. Жылдам конвергенция, жоғары дәлдік және бүкіл оқу процесінде жоғалтудың тұрақты төмендеуі таңдалған архитектураның тиімді және жоғары дәлдік пен сенімді тануды қажет ететін нақты әлем қолданбалары үшін жарамды екенін көрсетеді. Өзіне-өзі назар аудару механизмінің қосымша үлесі модельге жаһандық контексттерді жақсырақ түсіруге және маңызды кескін мүмкіндіктеріне назар аударуға мүмкіндік береді, жалпы өнімділікті жақсартады және оны қиын тану жағдайларында әсіресе пайдалы етеді. 10-сурет үш үлгіні салыстырады: жылдамырақ R-CNN ResNet50 FPN, MobileNetV3 Large және EfficientNetB0, Self-Attention магистральдары. Бірінші график (сол жақта) соңғы 15-ші дәуірдегі орташа жоғалту мәндерін көрсетеді, ал екіншісі (оң жақта) сол дәуірдегі дәлдікті көрсетеді. Нәтижелерді талдай отырып, әрбір модельдің күшті және әлсіз жақтары бар екенін көруге болады. ResNet50 FPN магистральді Faster R-CNN моделі ең аз шығынды көрсетті, бар болғаны 0,0102. Бұл оның терең архитектурасы мен күрделі қалдық блоктарының арқасында ResNet50 FPN жаттығу кезінде қателерді тиімді түрде азайта алатынын көрсетеді. Мұндай нәтиже модельдің жоғары тұрақтылығын және оның жалпылау қабілетін көрсетеді, бұл әсіресе максималды дәлдік пен сенімділікті талап ететін тапсырмалар үшін маңызды.



Сур. 10. Үш модельді салыстырмалы талдау

Self-Attention механизмі бар EfficientNetB0 моделі 0,0289 орташа жоғалту мәндерін көрсетті, бұл оның жоғары тиімділігін көрсетеді. Бұл модельді іске қосу үшін қажетті төмен есептеу шығындарын ескере отырып, бұл нәтиже әсерлі. MobileNetV3 Large сәулет ерекшеліктеріне байланысты соңғы дәуірдегі ең жоғары шығынды көрсетті (0,1807). MobileNetV3 Large жоғары жылдамдықты және модель параметрлерінің аз санын қажет ететін шектеулі есептеу ресурстары бар құрылғыларда жұмыс істеуге арналған. Бұл модельдің күрделі деректерге тиімді жаттықтыру мүмкіндігін азайтады. Шығындар графигінен көріп отырғаныңыздай, модель оқытудың бастапқы кезеңдерінде перспективалы нәтижелер көрсетті, бірақ соңғы дәуірлерде жоғалту өзгерді,

бұл модельдің шамадан тыс сәйкестігін көрсетуі мүмкін. Бұл құбылыс модель жаттығу деректерін тым дәл есте сақтаған кезде, бірақ оны жаңа деректерге жалпылай алмаған кезде орын алады. Бұл оның жылдамдығына және төмен есептеу жүктемесіне қарамастан, бұл модель қателерге төзімділігі төмен және жалпылау қабілеті төмендейтінін көрсетеді. Дәлдікке келетін болсақ, барлық үш модель соңғы дәуірде 100% қол жеткізді. Бұл әрбір үлгінің жоғары тану дәлдігін қамтамасыз ететін нысанды анықтау тапсырмаларын сәтті орындай алатынын көрсетеді. Дегенмен, бірдей дәлдікке қарамастан, жоғалту деңгейлеріндегі айырмашылықтар жоғалтулары аз үлгілер үшін ықтимал артықшылықтарды көрсетеді. ResNet50 FPN және EfficientNetB0 модельдері MobileNetV3 Large қарағанда жақсырақ жалпылау мүмкіндігіне ие болуы мүмкін, бұл жоғары сенімділікті қажет ететін тапсырмаларда өте маңызды болуы мүмкін. Тұтастай алғанда, үлгіні таңдау нақты тапсырма талаптарына және қол жетімді есептеу ресурстарына байланысты болуы керек. Егер жоғары дәлдік пен тұрақтылық басымдық болса, ResNet50 FPN таңдаулы таңдау болады. Дегенмен, жылдамдық пен ресурстарды аз тұтыну маңыздырақ болса, жоғалту мәндерінің ықтимал ауытқуларына қарамастан MobileNetV3 Large немесе Self-Attention бар EfficientNetB0 қолайлырақ опциялар болуы мүмкін.

Әртүрлі магистральдары бар Faster R-CNN архитектурасын қолданатын үш объектіні анықтау моделін оқыту нәтижелерін зерттеу және талдау барысында әрбір модельдің артықшылықтары мен кемшіліктері туралы қорытынды жасауға мүмкіндік беретін маңызды деректер алынды. Негізгі назарда негізгі рөл атқаратын ResNet50 FPN, MobileNetV3 Large және EfficientNetB0 бар Faster R-CNN үлгілері болды. Бұл модельдердің әртүрлі архитектурасы бар және есептеу ресурстары мен дәлдікке қойылатын әртүрлі талаптарды қанағаттандыруға арналған. ResNet50 FPN магистральді Faster R-CNN моделі жаттығу кезінде дәлдік пен тұрақтылықта тамаша нәтиже көрсетті. Қалдық блоктарды қамтитын терең ResNet50 архитектурасы жоғалып бара жатқан градиент мәселесін тиімді шешіп, көптеген қабаттармен тұрақты жаттығуларды қамтамасыз етті. Функционалдық пирамида желісін (FPN) біріктіру модельдің мүмкіндіктер иерархиясының әртүрлі деңгейлеріндегі нысандарды анықтау мүмкіндігін жақсартты, бұл оны әртүрлі масштабтағы және күрделі көріністердегі нысандарды анықтау үшін әсіресе пайдалы етеді. Жаттығу кезінде модель үшінші дәуірде 100% дәлдікке қол жеткізді, бұл оның жоғары тиімділігін көрсетеді. Бірінші дәуірдегі жоғалту 0,0922 болды, ал он бесінші дәуірде ол 0,0102-ге дейін төмендеді, бұл тұрақты жаттығулар мен қателерді азайтуды көрсетеді. Дегенмен, модельді оқытуға қажетті уақыттың айтарлықтай мөлшері архитектураның күрделілігіне және параметрлердің көптігіне байланысты болды. Орташа алғанда, бір дәуірдегі жаттығу шамамен 12-13 минутты алады, жалпы жаттығу уақыты 183 минутты құрады. Екінші жағынан, MobileNetV3 Large негізі бар Faster R-CNN моделі жылдам оқытуды және ресурс тиімділігін талап ететін тапсырмаларға арналған. ResNet50 FPN-

ден айырмашылығы, MobileNetV3 Large жеткілікті дәлдікті сақтай отырып, параметрлер мен есептеулер санын айтарлықтай азайта отырып, тереңдікте бөлінетін конвульсияларды пайдаланады. Модель жоғары дәлдікке тез қол жеткізді, екінші дәуірде 100 % жетті. Дегенмен, жоғары дәлдікке қол жеткізуге қарамастан, жаттығу кезінде жоғалту ауытқулары байқалды, бұл әртүрлі деректерге төзімділіктің төмендігін көрсетуі мүмкін. Бірінші дәуірдегі шығын 0,2581 болды. Екінші дәуірде ол 0,1348-ге дейін төмендегенімен, кейінгі дәуірлерде 0,1435-тен 0,1862-ге дейінгі ауытқулар байқалды, бұл модельдің деректерге сезімталдығын көрсетеді. Сонымен бірге модель барлық дәуірлерде жоғары дәлдікті сақтап қалды. Бұл модельдің негізгі артықшылықтарының бірі оның төмен ресурстарды тұтынуы және жылдам жаттығу жылдамдығы болып табылады: бір дәуірді оқыту шамамен 2–3 минутты алды, ал бүкіл жаттығу процесі небәрі 40 минутқа созылды.

EfficientNetB0 магистральдық және Self-Attention механизмі бар Faster R-CNN моделі тиімділік пен дәлдікті біріктіретін гибриді шешімді білдіреді. EfficientNetB0 желінің тереңдігі, ені және ажыратымдылығы арасындағы оңтайлы теңгерімге қол жеткізу үшін жасалған, бұл төмен есептеу шығындарымен жоғары дәлдікке мүмкіндік береді. Өзіне-өзі назар аудару механизмін қосу модельдің кескіннің әртүрлі бөліктері арасындағы жаһандық қатынастарды есепке алу мүмкіндігін арттырып, маңызды мүмкіндіктерге жақсырақ назар аударуға мүмкіндік береді. Модель оқу барысында айтарлықтай жақсарғанын көрсетті, екінші дәуірде 97,30 % және үшінші дәуірде 100 % дәлдікке жетті, бұл оқу барысында тұрақты болып қалды. Бірінші дәуірдегі орташа жоғалту салыстырмалы түрде жоғары 0,4611 болды, бірақ тез төмендеп, он бесінші дәуірде 0,0289-ға жетті. Бір дәуірдегі орташа жаттығу уақыты шамамен 28 минутты құрады, бірақ 13 және 14-ші дәуірлерде ол тиісінше 45 және 52 минутқа дейін айтарлықтай өсті. Уақыттың бұл ұлғаюы шығынды азайтудың күрделілігінің жоғарылауымен және модельдің деректердегі күрделі жағдайларға мұқият бейімделу қажеттілігімен байланысты болуы мүмкін.

Осылайша, EfficientNetB0 магистральдық және Self-Attention механизмі бар Faster R-CNN моделі дәлдік пен тиімділікті теңестіреді. Ол орташа есептеу шығындары бар жоғары тану дәлдігін талап ететін тапсырмалар үшін қолайлы. Кейінгі кезеңдерде жаттығу уақытының кейбір ауытқуларына қарамастан, бұл модель көптеген қолданбалар үшін сенімді және тұрақты нұсқа болып қала береді. Талдау негізінде әр модельдің артықшылықтары мен кемшіліктеріне қатысты бірнеше қорытынды жасауға болады. ResNet50 FPN – максималды дәлдік пен тұрақтылықты қажет ететін тапсырмалар үшін тамаша таңдау. Ол ең аз шығындарды көрсетеді және жоғары дәлдікке тез жетеді, бірақ айтарлықтай есептеу ресурстары мен жаттығу уақытын қажет етеді. MobileNetV3 Large жылдам оқытуды және төмен есептеу шығындарын ұсынады, бұл оны мобильді және ендірілген жүйелер үшін өте қолайлы етеді. Дегенмен, оның деректерге сезімталдығы және жоғалту ауытқулары оны максималды тұрақтылықты қажет

ететін тапсырмаларда пайдалануды шектеуі мүмкін. EfficientNetB0, Self-Attention бағдарламасы жоғары дәлдікті орташа есептеу шығындарымен үйлестіре отырып, теңдестірілген тәсілді ұсынады. Бұл модель жоғары өнімділік пен сенімді тануды қажет ететін функциялар үшін ұсынылуы мүмкін. Нақты тапсырма талаптары мен қолжетімді ресурстарға байланысты үлгіні таңдау әртүрлі болуы мүмкін. Егер басымдық максималды дәлдік пен тұрақтылық болса, ResNet50 FPN ең жақсы таңдау болар еді. Жылдамдық пен ресурс тиімділігі маңыздырақ болса, MobileNetV3 Large немесе EfficientNetB0 өзіне-өзі назар аударатын опциялар қолайлырақ болуы мүмкін. Нысанды анықтау тапсырмаларында оңтайлы нәтижелерге қол жеткізу үшін әрбір жағдайда дәлдік, жылдамдық және есептеу шығындары арасындағы теңгерімді ескеру маңызды.

Қорытынды

Бұл зерттеудің негізгі нәтижелерін келесідей қорытындылауға болады:

- Түрлі хост архитектураларын (ResNet-50, MobileNet V3 Large, EfficientNetB0, өзіне назар аудару механизмі бар) пайдалана отырып, Faster R-CNN архитектурасына негізделген нақты уақыттағы қозғалатын нысанды анықтау моделі ұсынылады.

- Эксперименттік нәтижелер MobileNet V3 Large бар Faster R-CNN үлгісі екінші дәуірде жылдам үйренуді көрсете отырып, 95,70 % дәлдікке қол жеткізгенін көрсетті.

- ResNet50-ді мүмкіндіктер пирамидасы желісімен (FPN) пайдалану жоғары тұрақтылық пен дәлдікті қамтамасыз етті (үшінші дәуірде 100 %-ға дейін), 15-дәуірге қарай орташа жоғалтуды 0,0102-ге дейін төмендетеді.

- Өзіне көңіл бөлу механизмі бар EfficientNetB0 моделі жоғары дәлдік пен тиімділік арасындағы тепе-теңдікті көрсетті, үшінші дәуірде 100 % дәлдікке қол жеткізді және 15-дәуірге қарай орташа жоғалтуды 0,0289 дейін төмендетті.

- Негізгі архитектураны таңдау тапсырма талаптарына байланысты: ResNet50 FPN жоғары дәлдік пен тұрақтылықты қажет ететін тапсырмалар үшін қолайлы; MobileNet V3 Large шектеулі есептеу ресурстары бар функциялар үшін қолайлы; және EfficientNetB0 - өзіне көңіл бөлу - дәлдік пен ресурс шығындары арасындағы оңтайлы ымыра.

Болашақ зерттеулер күрделірек және динамикалық бейне тізбектерімен жұмыс істеу үшін ұсынылған тәсілді оңтайландыруға, сондай-ақ есептеу шығындарын азайту және өңдеу жылдамдығын арттыру үшін деректерді өңдеуді жақсартуға бағытталуы мүмкін. Талдау және жоспарлау үшін әмбебап құралға айналдырады.

ӘДЕБИЕТТЕР

Л. Абдыкерімова және т.б. авторлар (2024). “Мәтіннің эмоционалды бояуын талдау: Машиналық және терең оқыту әдістері”. — *International Journal of Electrical & Computer Engineering*. — 14-том. — 3-нөмір. 2024. doi: 10.11591/ijec.v14i3.pp3055-3063.

Ф. Бутрос, В. Струк, Дж. Фьеррес және Н. Дамер (2023). “Бет-әлпетті тануға арналған синтетикалық деректер: Қазіргі жағдайы және болашағы”. — *Image and Vision Computing*. — 135-том. — 104688 66. 2023.



doi: 0.1016/j.imavis.2023.104688.

Р.А. Васлен (2023). «Бет-әлпетті тану технологиясы дәуіріндегі тануға деген күрес», *AI and Ethics*, 3-том, 1-нөмір, 215–222 бб. 2023. doi: 10.1007/s43681-022-00146-8.

П.Б. Джха, А. Баснет, Б. Покрел, Г.К. Тхакур және С. Чхетри, «Бет-әлпетті анықтау және тану технологиясын қолданатын автоматтандырылған қатысу жүйесі», *Apex Journal of Business and Management*. — 1-том. — 1-нөмір. — 103–120 бб., 2023.

Т.Б. Данг (2023). «Жетілдірілген бет-әлпетті тануға негізделген ақылды қатысу жүйесі». — *Journal of Robotics and Control (JRC)*. — 4-том. — 1-нөмір. — 46–53 бб. 2023. doi: 10.18196/jrc.v4i1.16808.

Х.О. Икромович және Б.Б. Маматкулович (2023). «Терең CNN-де трансферлік оқытуды қолдана отырып бет-әлпетті тану». — *Open Access Repository*. — 4-том. — 3-нөмір. — 502–507 бб. 2023. doi: 10.17605/OSF.IO/NRMK2.

Д.В. Кумар және Р.М. Шафи (2023). «Нақты уақытта бет-әлпетті анықтауға арналған материалдарды талдау және ерекшеліктерді жылдам таңдау әдісі: Модификацияланған аймақтық оңтайландырылған конволюциялық нейрондық желі». — *Materials Today: Proceedings*. — 81-том. — 563–569 бб. 2023. doi: 10.1016/j.matpr.2021.04.011.

Д.Дж. Каррагер және П.Дж. Хэнкок (2023). «Сот бет сәйкестігі тапсырмаларында шешім қабылдауға арналған автоматтандырылған бет-әлпетті тану жүйелерін модельдеу». — *Journal of Experimental Psychology: General*. — 152-том. — 5-нөмір. — 1286 бб. 2023, doi: 10.1037/xge0001310.

П. Мельчи және т.б. авторлар (2023). “Көптеген бет-әлпет ендірімдеріндегі жеке деректерді қорғауды жақсарту”. — *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. — 323–331 бб., 2023.

С. Минаи, А. Абдолрашиди, Х. Су, М. Беннамун және Д. Чжан (2023). “Терең оқытуды қолдана отырып биометриялық тану: Шолу”. *Artificial Intelligence Review*. — 56-том. — 8-нөмір. — 8647–8695 бб. 2023, doi: 10.1007/s10462-022-10237-x.

Д. Мамисва, А.Б. Абдусаломов, М. Мухиддинов және Т.К. Хвангбо (2023). «Терең оқыту әдісі негізінде қиын бейнелердегі кішкентай беттерді тану әдісін жақсарту», *Sensors*. — 23-том. — 1-нөмір. — 502–6. 2023, doi: 10.3390/s23010502.

А. Подорожняк, Н. Любченко, М. Соболев және Д. Онищенко (2023). «Автокөлік нөмірлерін автоматты тануға арналған Mask R-CNN қолдану». *Advanced Information Systems*. — 7-том. — 1-нөмір. — 54–58 бб. 2023, doi: 10.20998/2522-9052-2023.1.09.

В.М. Опанасенко, С.К. Фазиллов, О.Н. Мирзаев және С. Са’дулло угли Какхаров (2024). «Кіруді басқару жүйелерінде бет-әлпетті тануға арналған ансамбльдік тәсіл». — *Journal of Mobile Multimedia*. — 749–768 бб. 2024, doi: 10.13052/jmm1550-4646.20310.

В.М. Опанасенко, С.К. Фазиллов, С.С. Раджабов және С.С. Какхаров (2024). «Көп деңгейлі бет-әлпетті тану жүйесі». *Cybernetics and Systems Analysis*. — 60-том. — 1-нөмір. — 146–151 бб. 2024, doi: 10.1007/s10559-024-00655-w.

В.П. Лысечко, Б.И. Садовников, О.М. Комар және О.С. Жученко (2024). «Көрнекі кескіндерді тану және жіктеудің соңғы тәсілдерін зерттеу». *Radio Electronics, Computer Science, Control*. — 1-нөмір. — 140–6. 2024, doi: 10.15588/1607-3274-2024-1-13.

Дж. Ч.Л. Чай, Т.С. Нг, Ч.У. Лоу, Дж. Парк және А.Б. Дж. Тиох (2023). «Өте төмен ажыратымдылықтағы бет-әлпетті тану және сапасын бағалауға арналған ендірімдерді жақсарту». *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. — 9957–9967 бб. 2023.

Н. Узаккызы және т.б. авторлар (2023). “Терең оқыту әдістері арқылы кескіндегі шуды азайту”. — *International Journal of Electrical & Computer Engineering*. — 13-том. — 6-нөмір. — 6855–6861 бб. 2023, doi: 10.11591/ijece.v13i6.pp6855-6861.

С. Хангараги, Т. Сингх және Н. Нилима (2023). «Бет торы мен терең нейрондық желі арқылы бет-әлпетті анықтау және тану», *Procedia Computer Science*. — 218-том. — 741–749 бб. 2023, doi: 10.1016/j.procs.2023.01.054.

REFERENCES

L. Abdykerimova et al. (2024). “Analysis of the emotional coloring of text using machine and deep learning methods,” *International Journal of Electrical & Computer Engineering*. — Vol. 14. — No. 3. 2024, doi: 10.11591/ijece.v14i3.pp3055-3063. (in Eng.)

F. Boutros, V. Struc, J. Fierrez, and N. Damer (2023). “Synthetic data for face recognition: Current state and future prospects”. — *Image and Vision Computing*. — Vol. 135. — P. 104688. 2023, doi: 0.1016/j.imavis.2023.104688. (in English)

D.J. Carragher and P.J. Hancock (2023) “Simulated automated facial recognition systems as decision-aids in forensic face matching tasks,” *Journal of Experimental Psychology: General*. — Vol. 152. — No. 5. — P. 1286. 2023, doi: 10.1037/xge0001310. (in Eng.)

J.C.L. Chai, T.S. Ng, C.Y. Low, J. Park, and A.B.J. Teoh (2023). “Recognizability embedding enhancement for very low-resolution face recognition and quality estimation,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. — Pp. 9957–9967. 2023. (in Eng.)

T. V. Dang, “Smart attendance system based on improved facial recognition,” *Journal of Robotics and Control (JRC)*, vol. 4, no. 1, pp. 46–53, 2023, doi: 10.18196/jrc.v4i1.16808. (in Eng.)

H.O. Ikromovich and B.B. Mamatkulovich (2023). “Facial recognition using transfer learning in the deep CNN,” *Open Access Repository*. — Vol. 4. — No. 3. — Pp. 502–507. 2023, doi: 10.17605/OSF.IO/NRMK2. (in Eng.)



- S. Hangaragi, T. Singh, and N. Neelima (2023). "Face detection and recognition using face mesh and deep neural network". — *Procedia Computer Science*. — Vol. 218. — Pp. 741-749. 2023, doi: 10.1016/j.procs.2023.01.054. (in Eng.)
- D.V. Kumar and R.M. Shafi (2023). "Analysis and fast feature selection technique for real-time face detection materials using modified region optimized convolutional neural network". — *Materials Today: Proceedings*. — Vol. 81. — Pp. 563–569. 2023, doi: 10.1016/j.matpr.2021.04.011. (in Eng.)
- V.P. Lysechko, B.I. Sadovnykov, O.M. Komar and O.S. Zhuchenko (2024). "A research of the latest approaches to visual image recognition and classification". *Radio Electronics, Computer Science, Control*. — No. 1. — Pp. 140–140. 2024, doi: 10.15588/1607-3274-2024-1-13. (in Eng.)
- P. Melzi et al. (2023). "Multi-ive: Privacy enhancement of multiple soft-biometrics in face embeddings," in *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. — Pp. 323–331. 2023. (in Eng.)
- S. Minaee, A. Abdolrashidi, H. Su, M. Bennamoun, and D. Zhang (2023). "Biometrics recognition using deep learning: A survey". — *Artificial Intelligence Review*. — Vol. 56. — No. 8. — Pp. 8647–8695. 2023, doi: 10.1007/s10462-022-10237-x. (in Eng.)
- D. Mamieva, A.B. Abdusalomov, M. Mukhiddinov, and T.K. Whangbo (2023). "Improved face detection method via learning small faces on hard images based on a deep learning approach," *Sensors*. — Vol. 23. — No. 1. — P. 502. 2023, doi: 10.3390/s23010502. (in Eng.)
- V.M. Opanasenko, S.K. Fazilov, O.N. Mirzaev and S. Sa'dullo ugli Kakharov (2024). "An ensemble approach to face recognition in access control systems". — *Journal of Mobile Multimedia*. — Pp. 749–768. 2024, doi: 10.13052/jmm1550-4646.20310. (in Eng.)
- V.M. Opanasenko, S.K. Fazilov, S.S. Radjabov and S.S. Kakharov (2024). "Multilevel face recognition system". — *Cybernetics and Systems Analysis*. — Vol. 60. — No. 1. — Pp. 146–151. 2024, doi: 10.1007/s10559-024-00655-w. (in Eng.)
- A. Podorozhniak, N. Liubchenko, M. Sobol, and D. Onishchenko (2023). "Usage of Mask R-CNN for automatic license plate recognition". — *Advanced Information Systems*. — Vol. 7. — No. 1. — Pp. 54–58. 2023, doi: 10.20998/2522-9052.2023.1.09. (in Eng.)
- N. Uzakkyzy et al. (2023). "Image noise reduction by deep learning methods". — *International Journal of Electrical & Computer Engineering*. — Vol. 13. — No. 6. 2023, doi: 10.11591/ijece.v13i6.pp6855-6861. (in Eng.)
- P.B. Jha, A. Basnet, B. Pokhrel, G.K. Thakur and S. Chhetri (2023). "An automated attendance system using facial detection and recognition technology". — *Apex Journal of Business and Management*. — Vol. 1. — No. 1. — Pp. 103–120. 2023. (in Eng.)
- R.A. Waelen (2023). "The struggle for recognition in the age of facial recognition technology". *AI and Ethics*. — Vol. 3. — No. 1. — Pp. 215–222. 2023, doi: 10.1007/s43681-022-00146-8. (in Eng.)

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 1. Number 22 (2025). Pp.115–129

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.007>

FINDING AVALANCHE AREAS IN EAST KAZAKHSTAN USING MACHINE LEARNING

**S.K. Kumargazhanova^{1*}, D. Nurlybekova¹, A.S. Tlebaldinova¹,
M.A. Karmenova², S.S. Smailova¹**

¹D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk,
Kazakhstan;

²S. Amanzholov East Kazakhstan University, Ust-Kamenogorsk,
Kazakhstan.

E-mail: saule.kumargazhanova@edu.ektu.kz

Kumargazhanova S. — Candidate of Technical Sciences, associate professor, professor of the School of Digital Technology and Artificial Intelligence, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan

E-mail: saule.kumargazhanova@edu.ektu.kz, <https://orcid.org/0000-0002-6744-4023>;

Nurlybekova D. — bachelor student, educational program “Information systems”, the School of Digital Technology and Artificial Intelligence, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan

<https://orcid.org/0009-0006-4480-175X>;

Tlebaldinova A. — PhD, associate professor, Associate professor of the School of Digital Technology and Artificial Intelligence, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan
<https://orcid.org/0000-0003-1271-0352>;

Karmenova M. — PhD, associate professor, «the Department of Computer Modeling and Information Technologies», S. Amanzholov East Kazakhstan University, Ust-Kamenogorsk, Kazakhstan
<https://orcid.org/0000-0002-3028-9461>;

Smailova S. — PhD, associate professor, professor of the School of Digital Technology and Artificial Intelligence, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan
<https://orcid.org/0000-0002-8411-3584>.

© S.K. Kumargazhanova, D. Nurlybekova, A.S. Tlebaldinova, M.A. Karmenova, S.S. Smailova, 2025

Abstract. Due to the high frequency and danger of avalanches in East Kazakhstan, the use of modern technologies for analyzing meteorological data has become critically important. This study focuses on the application of unsupervised machine learning algorithms – namely K-means and K-medoids–for detecting hidden patterns in weather conditions that precede avalanche events. The primary objective is to determine the most effective clustering approach for categorizing days with avalanche risk based on meteorological indicators such as temperature, snow depth, and weather conditions. The research involved comprehensive data preprocessing, conversion of categorical weather parameters into numerical values, and the selection of optimal



cluster numbers using the Elbow and Silhouette methods. Experimental results indicate that the K-means algorithm outperforms K-medoids in clustering quality and interpretability. A total of four distinct clusters were identified, each reflecting unique weather patterns associated with avalanche activity. The results suggest that the applied methodology is suitable for future implementation in avalanche monitoring and early warning systems. This study contributes to disaster risk reduction efforts and supports decision-making processes for emergency response planning in mountainous regions.

Key words: avalanche prediction, machine learning, K-means clustering, K-medoids, meteorological data, unsupervised learning

For citation: S.K. Kumargazhanova, D. Nurlybekova, A.S. Tlebaldinova, M.A. Karmenova, S.S. Smailova. Finding avalanche areas in east kazakhstan using machine learning //International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 115–129 (In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.007>.

Conflict of interest: The authors declare that there is no conflict of interest.

ШЫҒЫС ҚАЗАҚСТАН ОБЛЫСЫНЫҢ ҚАР КӨШКІНІ АЙМАҚТАРЫН МАШИНАЛЫҚ ОҚЫТУ ӘДІСІ АРҚЫЛЫ АНЫҚТАУ

С.К. Кумаргажанова^{1}, Д. Нұрлыбекова¹, А.С. Тлебалдинова¹,
М.А. Карменова², С.А. Смаилова¹*

¹Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен, Қазақстан;

² С.Аманжолов атындағы Шығыс Қазақстан университеті Өскемен, Қазақстан.
E-mail: saule.kumargazhanova@edu.ektu.kz

Кумаргажанова С. — техника ғылымдарының кандидаты, қауымдастырылған профессор, «Цифрлық технологиялар және жасанды интеллект» мектебінің профессоры, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті

E-mail: saule.kumargazhanova@edu.ektu.kz, <https://orcid.org/0000-0002-6744-4023>;

Нұрлыбекова Д. — студент, «Ақпараттық жүйелер» білім беру бағдарламасы, Цифрлық технологиялар және жасанды интеллект мектебі, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті
<https://orcid.org/0009-0006-4480-175X>;

Тлебалдинова А. — PhD, қауымдастырылған профессор, «Цифрлық технологиялар және жасанды интеллект» мектебінің қауымдастырылған профессоры, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті
<https://orcid.org/0000-0003-1271-0352>;

Карменова М. — PhD, «Компьютерлік модельдеу және ақпараттық технологиялар кафедрасының» қауымдастырылған профессоры, С.Аманжолов атындағы Шығыс Қазақстан университеті
<https://orcid.org/0000-0002-3028-9461>;

Смаилова С. — PhD, қауымдастырылған профессоры, «Цифрлық технологиялар және жасанды интеллект» мектебінің профессоры, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті
<https://orcid.org/0000-0002-8411-3584>.

© С.К. Кумаргажанова, Д. Нұрлыбекова, А.С. Тлебалдинова, М.А. Карменова, С.С. Смаилова, 2025

Аннотация. Шығыс Қазақстанда қар көшкіні жиілігі мен қауіптілігі жоғары болғандықтан, метеорологиялық мәліметтерді талдаудың заманауи технологияларын пайдалану өте маңызды. Бұл зерттеу қар көшкіні оқиғаларының алдындағы ауа райы жағдайындағы жасырын үлгілерді анықтау үшін бақыланбайтын машиналық оқыту алгоритмдерін, атап айтқанда K-means мен K-medoids қолдануға бағытталған. Негізгі мақсат – температура, қардың қалыңдығы және ауа райы жағдайы сияқты метеорологиялық көрсеткіштер негізінде қар көшкіні қауіп бар күндерді санаттау үшін ең тиімді кластерлік тәсілді анықтау. Зерттеу кешенді алдын ала өңдеуді, ауа-райының категориялық параметрлерін сандық мәндерге түрлендіруді және шынтақ және силуэт әдістерін қолдану арқылы оңтайлы кластер сандарын таңдауды қамтыды. Эксперименттік нәтижелер K-means алгоритмін кластерлеу сапасы мен түсіндірмелілігі жағынан алғанда K-medoids әдісінен асып түсетіндігін көрсетті. Барлығы төрт ерекше кластер анықталды, олардың әрқайсысы қар көшкіні белсенділігімен байланысты бірегей ауа райы үлгілерін көрсетеді. Нәтижелер қолданбалы әдістеменің болашақта көшкіндерді бақылау және алдын ала ескерту жүйелерінде енгізу үшін қолайлы екенін көрсетеді. Бұл зерттеу апат қауіпін азайтуға ықпал ете алады, сондай-ақ таулы аймақтарда төтенше жағдайлардың алдын алу және оларды болдырмау бойынша шешім қабылдау үдерістерін қолдауға мүмкіндік береді.

Түйін сөздер: қар көшкінін болжау, машиналық оқыту, K-means кластерлеу, K-medoids, метеорологиялық деректер, бақылаусыз оқыту

Дәйексөздер үшін: С.К. Кумаргажанова, Д. Нұрлыбекова, А.С. Тлебалдинова, М.А. Карменова, С.С. Смаилова. Шығыс қазақстан облысының қар көшкіні аймақтарын машиналық оқыту әдісі арқылы анықтау//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 115–129 бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.007>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

ВЫЯЛЕНИЕ ЛАВИНООПАСНЫХ ЗОН В ВОСТОЧНОМ КАЗАХСТАНЕ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

С.К. Кумаргажанова^{1}, Д. Нурлыбекова¹, А.С. Тлебалдинова¹,
М.А. Карменова², С.А. Смаилова¹*

¹Восточно-Казахстанский технический университет им. Д. Серикбаева,
Усть-Каменогорск, Казахстан;

²Восточно-Казахстанский университет им. С. Аманжолова, Усть-Каменогорск,
Казахстан.

E-mail: saule.kumargazhanova@edu.ektu.kz

Кумаргажанова С. — кандидат технических наук, ассоциированный профессор, профессор «Школы цифровых технологий и искусственного интеллекта», Восточно-Казахстанский технический университет

им. Д. Серикбаева, Усть-Каменогорск, Казахстан

E-mail: saule.kumargazhanova@edu.ektu.kz, <https://orcid.org/0000-0002-6744-4023>;

Нурлыбекова Д. — студент образовательной программы «Информационные системы», Школа цифровых технологий и искусственного интеллекта, Восточно-Казахстанский технический университет им. Д. Серикбаева, Усть-Каменогорск, Казахстан

<https://orcid.org/0009-0006-4480-175X>;

Тлебалдинова А. — PhD, ассоциированный профессор, ассоциированный профессор «Школы цифровых технологий и искусственного интеллекта», Восточно-Казахстанский технический университет им. Д. Серикбаева, Усть-Каменогорск, Казахстан

<https://orcid.org/0000-0003-1271-0352>;

Карменова М. — PhD, ассоциированный профессор «Кафедры компьютерного моделирования и информационных технологий», Восточно-Казахстанский университет им. С. Аманжолова, Усть-Каменогорск, Казахстан

<https://orcid.org/0000-0002-3028-9461>;

Смаилова С. — PhD, ассоциированный профессор, профессор «Школы цифровых технологий и искусственного интеллекта», Восточно-Казахстанский технический университет им. Д. Серикбаева, Усть-Каменогорск, Казахстан

<https://orcid.org/0000-0002-8411-3584>.

© С.К. Кумаргажанова, Д. Нурлыбекова, А.С. Тлебалдинова, М.А. Карменова, С.С. Смаилова, 2025

Аннотация. В связи с высокой частотой и опасностью схода лавин в Восточном Казахстане использование современных технологий для анализа метеорологических данных стало критически важным. Данное исследование фокусируется на применении алгоритмов неконтролируемого машинного обучения, а именно K-means и K-medoids, для обнаружения скрытых закономерностей в погодных условиях, предшествующих лавинным событиям. Основная цель — определить наиболее эффективный подход к кластеризации для категоризации дней с лавинным риском на основе метеорологических показателей, таких как температура, высота снежного покрова и погодные условия. Исследование включало комплексную предварительную обработку данных, преобразование категориальных погодных параметров в числовые значения и выбор оптимальных номеров кластеров с использованием методов Elbow и Silhouette. Экспериментальные результаты показывают, что алгоритм K-means превосходит K-medoids по качеству кластеризации и интерпретируемости. Всего было выявлено четыре отдельных кластера, каждый из которых отражает уникальные погодные закономерности, связанные с лавинной активностью. Результаты показывают, что применяемая методология подходит для будущего внедрения в системы мониторинга лавин и раннего оповещения. Это исследование вносит вклад в усилия по снижению риска стихийных бедствий и поддерживает процессы принятия решений для планирования реагирования на чрезвычайные ситуации в горных регионах.

Ключевые слова: прогнозирование лавинной опасности, машинное обучение, K-means кластеризация, K-medoids, метеорологические данные, неконтролируемое обучение

Для цитирования: С.К. Кумаргажанова, Д. Нурлыбекова, А.С. Тлебалдинова, М.А. Карменова, С.С. Смаилова. Выявление лавиноопасных

ЗОН В ВОСТОЧНОМ КАЗАХСТАНЕ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ//Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 115–129. (На англ.). <https://doi.org/10.54309/IJICT.2026.22.2.007>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Natural disasters have always been a problem for people. In mountain areas, one of the most dangerous natural events is an avalanche. In fact, avalanches can damage people's lives, roads, buildings, and nature. As a result, scientists do many studies to protect people and reduce losses (Rafique., et al., 2023; Singh and Ramiya, 2025; Zgheib et al., 2022).

In East Kazakhstan, it is a significantly vital issue. Avalanches happen in the region every year because of the mountains and weather. If we can find dangerous places earlier and understand how avalanches start, we can help emergency workers get ready and improve the warning system.

In the last few years, many scientists have started using machine learning and data analysis to study natural risks. Some researchers create models to make predictions, others group risky situations or study when and where disasters happen. One helpful method is clustering — it lets us find patterns and dangerous areas (Mahfuz et al., 2023; Cui, 2020; Géron, 2021; Han et al., 2022; Zhao et al., 2023).

In this research, we wanted to use machine learning to group weather data connected to avalanches in East Kazakhstan.

The novelty of the research lies in the fact that we compared two algorithms — K-means and K-medoids — for the first time using real avalanche-related weather data in this region. We also created a new way to clean and digitize weather info. Then we used Elbow and Silhouette methods to check how well the clusters worked.

We used K-means and K-medoids to group the data and see which one worked better. The Elbow and Silhouette methods helped us find the best number of groups (clusters). We found that K-means gave better results. Then we studied the groups more closely to understand things like snow level and temperature before avalanches.

The machine learning method we used worked well for studying avalanches in East Kazakhstan. It can also be used in systems that help watch and predict avalanches.

Materials and Methods

Data Description

East Kazakhstan is in the east of Kazakhstan and borders Russia and China. It is a mountain region with high avalanche risk. That is because of heavy snow, sudden weather changes, and difficult terrain. Every winter and spring, avalanches happen there and can be dangerous for people, roads, and farms.

To study what causes avalanches, we used weather data from 2005 to 2023

from the IT Center for Competency and Technology Transfer. The data includes the date, temperature, snow height, rain, and weather conditions. The general scheme of the proposed methodology is presented in Figure 1.




Fig. 1. The general Scheme of the Proposed Methodology

As can be seen from the figure, the proposed methodology consists of three main stages. The implementation of the stages is carried out according to this scheme.

In the Excel files, days with avalanches were marked yellow. We only used those days. We looked at the weather in the morning (7:00 AM), because that's when avalanches are more likely.

We used these numbers:

- Year
- Month
- Temperature (°C)
- Average and maximum snow height (cm)
- Weather condition

Then we prepared the data:

- We turned weather conditions into numbers (snow, rain, clear, etc.)
- We grouped months by seasons
- We gave each area a code
- We joined all tables into one file

This gave us a clean table with useful information about avalanche days. We can now use this data to find patterns and build models.

Method Steps

The method has two main steps:

1. Clean and prepare the data (Table 1)
2. Use K-means and K-medoids to make and compare clusters

We used Python to do this work.

Table 1 – Dataset Fragment

Year	Season	t (°C)	Avg cm of snow	Max cm of snow	Weather Forecast	Region	Region name	lat	lon
2023	1	-6	33	70	1	1	Prohodnaya	50.338860	84.019834
2023	1	-7	33	70	1	1	Prohodnaya	50.338860	84.019834
2023	2	0	50	70	2	2	Pihtovka	49.716552	83.297713
2022	2	-4	83	85	6	3	Bogatyrskaya mine	49.788810	84.421991
2022	2	-7	83	85	4	4	Putincevtskaya mine	49.859735	84.333390
2023	1	-5	90	95	6	4	Putincevtskaya mine	49.859735	84.333390
2021	4	-2	65	70	6	5	Sogornaya-barlyk	49.210929	85.369947
2022	2	-8	45	50	5	5	Sogornaya-barlyk	49.210929	85.369947
2022	2	-5	45	50	6	5	Sogornaya-barlyk	49.210929	85.369947
2022	1	-10	60	65	5	5	Sogornaya-barlyk	49.210929	85.369947
2022	2	-10	50	60	6	5	Sogornaya-barlyk	49.210929	85.369947
2022	2	-3	45	50	6	5	Sogornaya-barlyk	49.210929	85.369947
2022	2	0	45	50	1	5	Sogornaya-barlyk	49.210929	85.369947
2023	1	-10	55	60	5	5	Sogornaya-barlyk	49.210929	85.369947
2023	2	-4	45	50	1	5	Sogornaya-barlyk	49.210929	85.369947
2022	2	-1	50	55	4	6	B e r e l - Rahmany	49.372586	86.430875
2022	1	-17	45	75	5	6	B e r e l - Rahmany	49.372586	86.430875
2022	2	-6	55	60	6	6	B e r e l - Rahmany	49.372586	86.430875
2022	4	-9	45	50	3	6	B e r e l - Rahmany	49.372586	86.430875

On the Unsupervised Clustering Algorithms

Clustering is a data processing method that allows grouping observations into separate clusters based on similar characteristics. This method is considered as effective for analyzing natural phenomena, including situations with a risk of avalanches. In this study, unsupervised machine learning algorithms, namely K-means and K-medoids, are applied to reveal hidden patterns in pre-avalanche meteorological data.

K-means clustering algorithm

The K-means method is one of the most widely used clustering algorithms. It is known for its simple, effective features and ability to produce good clustering results (Berdyshev, 2018; Grossman et al., 2017; Grossman et al., 2017). Given a data-

set: $X = \{x_1, x_2, \dots, x_m\}$, where m is the number of objects in Euclidean space. The main goal of the K-means method is to partition into clusters the set of observations into K clusters: $K_1, K_2, \dots, K_k$, where $K_i \subset X$, $|K_i| \geq 1$, and $K_i \cap K_j = \emptyset$ for $1 \leq i, j \leq k$, $i \neq j$. Each cluster must have at least one object. This method aims to group similar objects into the same cluster while maximizing the differences between objects in different clusters. In the method, each cluster is represented by a center (centroid). A centroid is defined as the mean of all objects assigned to the cluster. The distance between an object $l \in K_i$ and the cluster center k_i is measured using the Euclidean distance - $\text{dist}(l, k_i)$. The quality of the clustering is evaluated by intra-cluster variance, which is calculated using the following formula (1):

$$A = \sum_{i=1}^k \sum_{l \in K_i} \text{dist}(l, k_i)^2, \quad (1)$$

where A represents the sum of squared errors for all objects, l is a point representing an object, k_i is the centroid of cluster K_i , and $\text{dist}(l, k_i)$ is the Euclidean distance between l and k_i . In other words, the distance from each object to its cluster center is squared, and all these squared distances are summed up.

K-Medoids Clustering Algorithm

The K-medoids method differs from the K-means algorithm in that it uses actual data points—medoids—as cluster centers.

In this approach, the cluster centers are selected directly from the dataset, meaning that instead of calculating the mean, the medoid of the cluster is used. To form clusters, K representative points are initially selected. These points are then iteratively updated. During each iteration, all possible combinations between representative and non-representative points are evaluated. For each combination, the clustering quality is calculated. The new point that minimizes the distortion function the most is selected and replaces the previous representative point. In the Figure 2, D is the set of objects $(1, 2, \dots, n)$, S_{ij} is the squared deviation function, $\text{dis}(D_i, D_j)$ is the distance between objects i and j .

K-Medoids algorithm	
Input:	
- k : the number of clusters,	
- D : a data set containing n objects.	
Output: A set of k clusters.	
1: arbitrarily choose k objects in D ;	
2: repeat	
3: for each D_i not a medoid do	
4: for each medoid D_j do	
5: compute square error;	
6: function S_{ij} ;	
7: find i, j where S_{ij} is the smallest	
8: if $S_{ij} < 0$ then	
9: replace medoid D_i with D_j	
10: until $S_{ij} \geq 0$	
11: for each $D_i \in D$ do	
12: assign D_i to k_i where $\text{dis}(D_i, D_j)$ is the smallest over all medoids	

Fig. 2. K-Medoids Algorithm Pseudocode

Results and discussion

The clustering analysis began by determining the optimal number of clusters for the given data, as the K-means and K-medoids clustering algorithms used in the study operate based on dividing the vector space into a predetermined number of k clusters.

There are various methods for selecting the optimal number of clusters, most of which are based on calculating intra-cluster and inter-cluster distances. In this study, the Elbow and Silhouette methods were used to determine the optimal cluster value.

The Elbow Method is based on analyzing the sum of squared intra-cluster deviations (WCSS). As the number of clusters increases, WCSS tends to decrease, but beyond a certain value of K , this decrease becomes significantly slower. The point where this «Elbow» occurs is considered the optimal number of clusters, as adding more clusters beyond this point does not significantly improve the clustering.

Figure 3 presents the results of using the Elbow method to determine the optimal k value. As seen in the graphs in 4(a) and 4(b), the Elbow method suggests that $k = 4$ is optimal. The optimal number of clusters for both the K-means and K-medoids methods was found to be the same. As K increases, a sharp decline in the WCSS value is observed in the graph. This crucial change corresponds to the optimal number of clusters and is referred to as the «Elbow» (Cui, 2020).




Fig. 3. Diagram of the Elbow Method of Cluster Analysis of K-Means and K-Medoids.

In the Silhouette method, the silhouette coefficient is calculated using the average intra-cluster distance and the average distance from each object to the nearest cluster. The maximum value of the silhouette coefficient allows for a clear identification of the cluster boundaries. The results of using the silhouette method to evaluate the quality of clustering models are presented in the following figures. For $K = 2$, $K = 3$, and $K = 4$, the silhouette values of the K-means method are shown in Figure 4, while the silhouette values of the K-medoids method are displayed in Figure 5.

Silhouette method K-Means




Fig. 4. Diagram of the Silhouette Method of Cluster Analysis K-Means.

Silhouette method K-Medoids




Fig. 5. Diagram of the Silhouette Method of Cluster Analysis Of K-Medoids.




Table 2 - Silhouette Values for K-Means and K-Medoids Methods

Number of Clusters	K-means	K-medoids
2	0.5799	0.6452
3	0.4583	0.4583
4	0.5235	0.5235

From Table 2, the highest silhouette coefficient value at $K = 2$ is observed with the K-medoids method - 0.6452, compared to 0.5799 for K-means. However, for $K = 3$ and $K = 4$, both methods yield identical silhouette coefficient values - 0.4583 and 0.5235, respectively.

In the next stage of the study, the results of applying the clustering methods shown in Figure 6 were obtained. In Figures 6(a) and 6(b), four distinct clusters with specific centers (centroids) are identified using the K-means and K-medoids methods. Figures 6(c) and 6(d) provide the 3D visualization of these four clusters, allowing for a more accurate assessment of the data distribution in space based on the following

characteristics: maximum snow depth, air temperature, and weather conditions.






Fig. 6. Diagram of Four Cluster Data Sets in Different Dimension Spaces (3D and 2D): (a), (c) K-Means Method; (b), (d) K-Medoids Method.

When comparing the values of the WCSS coefficients for both methods, it was found that the K-means method produced higher results than K-medoids. Therefore, the further analysis of the clustering groups was carried out based on the results obtained using the K-means method. Figure 7 presents the clustering results achieved with the K-means method. Each of the clusters is characterized by its distinct features and includes a different number of observed points.

The high clustering quality achieved through K-means confirms the effectiveness of the chosen approach for analyzing meteorological data related to days with avalanche risk. The statistical analysis and overall evaluation of the results were done using descriptive statistics. Figure 8 shows the results of descriptive statistics used to analyze the clusters and identify the characteristics of each one.

In Cluster 1, the average temperature is approximately -5.3°C , the average snow depth is 88 cm, and the average weather index is 5.3. In Cluster 2, these values are slightly higher: temperature $\approx -4.3^{\circ}\text{C}$, snow depth ≈ 50.7 cm, and the weather index ≈ 3.7 . Additionally, the average snow and temperature values in this cluster are lower compared to other clusters, and their variability is higher (standard deviation). In Cluster 3, the temperature is significantly lower (average temperature $\approx -10^{\circ}\text{C}$), the snow depth is 71.7 cm, and other parameters also vary within set limits. Cluster 3 shows considerable variation, especially for temperature and snow (the standard deviation for snow is between 6.1 cm and 6.9 cm).

The analysis conducted using descriptive statistics helped to identify different groups with unique characteristics for each cluster, allowing for a detailed analysis of the factors affecting the weather in different regions. For instance, Cluster 1 shows stable conditions, while Cluster 3 exhibits temperature and significant variability.

Each cluster had its own characteristics and number of data points. K-means showed good results in this avalanche study.




Fig. 7. Cluster Groups.

Cluster	Statistical indicator	Year	Season	Temperature (C)	Average cm of snow	Maximum cm of snow	Weather Forecast	Region
Cluster 1	Count	3	3	3	3	3	3	3
	Mean	2022,333	1,666666667	-5,333333333	88,33333333	88,33333333	5,333333333	3,666667
	Std	0,57735	0,577350269	1,527525232	4,041451884	5,773502692	1,154700538	0,57735
	Min	2022	1	-7	83	85	4	3
	Max	2023	2	-4	90	95	6	4
Cluster 2	Count	7	7	7	7	7	7	7
	Mean	2022,143	2,285714286	-4,285714286	45,71428571	50,71428571	3,714285714	5,285714
	Std	0,377964	0,755928946	3,352326839	1,889822365	1,889822365	2,138089935	0,48795
	Min	2022	2	-9	45	50	1	5
	Max	2023	4	0	50	55	6	6
Cluster 3	Count	3	3	3	3	3	3	3
	Mean	2022,667	1	-10	37	71,66666667	2,333333333	2,666667
	Std	0,57735	0	6,08276253	6,92820323	2,886751346	2,309401077	2,886751
	Min	2022	1	-17	33	70	1	5
	Max	2023	1	-6	45	75	5	6
Cluster 4	Count	6	6	6	6	6	6	6
	Mean	2022,167	2	-6,333333333	55,83333333	64,16666667	5	4,666667
	Std	0,752773	1,095445115	4,457203907	5,845225972	4,915960401	1,549193338	1,36626
	Min	2021	1	-10	50	60	2	2
	Max	2023	4	0	65	70	6	6

Fig. 8. Statistical Description of the Avalanche Data Set in Each Cluster.

Conclusion

As a result of the cluster analysis of the climate data for the regions of East Kazakhstan, four main clusters were identified.

Cluster 1 includes days with a high snow cover (on average, 88.3 cm), relatively low average temperatures (around -5.3°C), and stable weather conditions. The weather phenomena are mostly cloudy and windy, and the regions are primarily the Bogatyrevskaya and Putinetsvskaya kopys. These days correspond to typical winter conditions.

Cluster 2 covers days with an average snow depth (on average, 45.7 cm) and temperatures around -4.3°C . However, the standard deviation of temperature and weather in this cluster is significantly higher, indicating greater variability in climatic conditions. Clear, cloudy, and windy days are frequent here. Geographically, this cluster includes various regions of the area.

Cluster 3 is characterized by extremely low average temperatures (around -10°C), as well as snow depths — with an average of 37 cm (the lowest value compared to other clusters), and a maximum height of 75 cm (the highest compared to other clusters). It includes areas such as Sogornoye-Barlyk and Berel-Rahmany.

Cluster 4 combines days with stable frost (average temperature -6.3°C) and snow cover (average value 55.8 cm). The weather phenomena are mostly snow and cloudiness. This cluster can be interpreted as representing the typical long winter.

The results of the work can serve as a basis for developing predictive systems based on historical data.

REFERENCES

- Berdyshev A.V. (2018). Blokchein kak tekhnologicheskaya osnova razvitiya bankov [Blockchain as a technological basis for the development of banks]. — *Vestnik universiteta* (Gosudarstvennyi universitet upravleniya). 2018. — I. 4. — Pp. 132–135.
- Cui M. (2020). Introduction to the K-Means Clustering Algorithm Based on the Elbow Method. Accounting, Auditing and Finance. — 2020. — Vol. 3. — P. 9–16. DOI: 10.23977/geors.2020.030102.
- Han J., Pei J., Kamber M. (2022). Data Mining: Concepts and Techniques. — 4th ed. — Cambridge: Morgan Kaufmann, 2022. — 752 p.
- Géron A. (2021). Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. — 2nd ed. — Sebastopol: O'Reilly Media, 2021. — 856 p.
- Grossman A.O., Petrov A.V. (2017). Kriptovalyuty kak sotsial'noe yavlenie: [Cryptocurrencies as a social phenomenon], Obshchestvo. Sreda. Razvitie (Terra Humana). 2017. — I. 4 (45). — Pp. 62–66.
- Mahfuz N.M., Yusoff M., Idrus Z. (2023). Clustering heterogeneous categorical data using enhanced mini batch K-means with entropy distance measure. *International Journal of Electrical and Computer Engineering*. — 2023. — Vol. 13. — No. 1. — Pp. 1048–1059. DOI: 10.11591/ijece.v13i1.pp1048-1059.
- Rafique A., Dasti M.Y.S., Ullah B., Awwad F.A., Ismail E.A.A. & Saqib Z.A. (2023). Snow Avalanche Hazard Mapping Using a GIS-Based AHP Approach: A Case of Glaciers in Northern Pakistan. *Remote Sensing*. — 15(22). — P. 5375. DOI: <https://doi.org/10.3390/rs15225375>
- Tapskott D., Tapskott A. (2017). per. s angl. K. Shashkovoi, E. Ryakhinai. Tekhnologiya blokchein: to, chto dvizhet finansovoi revolyutsiei segodnya: [Blockchain technology: what drives the financial revolution today]. — M.: Eksmo, 2017. — 448 p. (Top Economics Awards).
- Singh S., Ramiya A.M. (2025). Assessing avalanche susceptibility using the analytic hierarchical process and multi-criteria weighted overlay: a case study of the Leh-Parthapur road axis. — *International Journal of Disaster Resilience in the Built Environment*. — Vol. 16. — No. 3. — Pp. 437–455. DOI: <https://doi.org/10.1108/IJDRBE-06-2024-0071>

Swan M. (2015). Blockchain: Blueprint for a new economy, O'Reilly. 2015. — P. 149.

What to expect from the crypto market? [Electronic resource] URL: <https://changehero.io/blog/ru/2021-top-crypto-predictions/> (accessed: 10.03.2025)

Zhao Y., Huang X., Zhao Y., Liu X., Zhou R. (2023). The application of landscape character classification for spatial zoning management in mountainous protected areas – A case study of Laoshan National Park, China. *Heliyon*. — 2023. — Vol. 9. — No. 3. — e13996. DOI: <https://doi.org/10.1016/j.heliyon.2023.e13996>.

Zgheib T., Giacona F., Morin S., Granet-Abisset A.-M., Favier P. & Eckert N. (2022). Diachronic quantitative snow avalanche riskassessment as a function of forest coverchanges. — *Journal of Glaciology*. — Pp. 1–19. <https://doi.org/10.1017/jog.2022.103>.



INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 2. Number 22 (2025). Pp. 130–141

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.008>

MRTI 05.13.10

COMPARISON OF NEURAL NETWORK MODELS FOR PREDICTION CRYPTOCURRENCY PRICE VOLATILITY IN TRADING PAIRS

S.B. Mukhanov^{1}, K. Bekbolat², N.A. Seilova¹, Zh.M. Bekaulova¹,
S.Zh. Zhakypbekov¹*

¹International Information Technology University, Almaty, Kazakhstan;

²Suleyman Demirel University, Almaty, Kazakhstan.

E-mail: s.mukhanov@iitu.edu.kz

Mukhanov S. — PhD in Computer Systems and Software Engineering, assistant-professor, «Head of the Department of Computer Engineering», International Information Technology University, Almaty, Kazakhstan
E-mail: s.mukhanov@iitu.edu.kz, <https://orcid.org/0000-0001-8761-4272>;

Bekbolat K. — Bachelor in Finance and Economics, Suleyman Demirel University, Almaty, Kazakhstan
E-mail: 41317@iitu.edu.kz, <https://orcid.org/0009-0009-4499-7432>;

Seilova N. — PhD in Engineering, associate professor, International Information Technology University, Almaty, Kazakhstan

E-mail: nseilova@iitu.edu.kz, <https://orcid.org/0000-0003-3827-179X>;

Bekaulova Zh. — Master of Technical Sciences, assistant-professor, International Information Technology University, Almaty, Kazakhstan

E-mail: zh.bekaulova@iitu.edu.kz, <https://orcid.org/0009-0000-9339-9222>;

Zhakypbekov S. — Doctoral (PhD) student, senior lecturer, «the Department of Computer Engineering, International Information Technology University», Almaty, Kazakhstan

E-mail: syrymzhakypbekov@gmail.com, <https://orcid.org/0000-0001-9112-5922>.

© S.B. Mukhanov, K. Bekbolat, N.A. Seilova, Zh.M. Bekaulova, S.Zh. Zhakypbekov, 2025

Abstract. The increasing digitization of financial markets and the rise of Web3 trading pairs have significantly impacted asset trading, introducing new challenges in price volatility forecasting. Traditional risk management strategies often fail to adapt to the unpredictable nature of cryptocurrency markets. This study explores the application of advanced machine learning models for forecasting price volatility in cryptocurrency trading pairs. We compare the performance of Temporal Fusion Transformer (TFT), Temporal Convolutional Network (TCN), XGBoost, Random Forest, and a hybrid CNN-LSTM model. Our findings indicate that TFT and CNN-LSTM hybrid models outperform traditional recurrent neural networks in capturing complex market dynamics, enhancing risk management strategies in high-frequency cryptocurrency trading.

Keywords: price volatility, machine learning, cryptocurrency, risk management, deep learning, temporal models, Web3



For citation: S.B. Mukhanov, K. Bekbolat, N.A. Seilova, Zh.M. Bekaulova, S.Zh. Zhakypbekov. Comparison of neural network models for prediction cryptocurrency price volatility in trading pairs//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 130–141(In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.008>.

Conflict of interest: The authors declare that there is no conflict of interest.

САУДА ЖҰПТАРЫНДАҒЫ КРИПТОВАЛЮТА БАҒАСЫНЫҢ ҚҰБЫМАЛЫЛЫҒЫН БОЛЖАУҒА АРНАЛҒАН НЕЙРОНДЫҚ ЖЕЛІ МОДЕЛЬДЕРІН САЛЫСТЫРУ

*С.Б. Муханов¹, К. Бекболат², Н.А. Сейлова¹, Ж.М. Бекаулова¹,
С.Ж. Жакыпбеков¹*

¹Халықаралық ақпараттық технологиялар университеті;

²Сүлеймен Демирель университеті, Алматы, Қазақстан.

E-mail: s.mukhanov@iitu.edu.kz

Мұханов С. — компьютерлік жүйелер және бағдарламалық қамтамасыз ету саласындағы PhD, «Компьютерлік инженерия» кафедрасының меңгерушісі, доцент, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан

E-mail: s.mukhanov@iitu.edu.kz, <https://orcid.org/0000-0001-8761-4272>;

Бекболат К. — қаржы және экономика бакалавры, Сүлеймен Демирель университеті, Алматы, Қазақстан

E-mail: 41317@iitu.edu.kz, <https://orcid.org/0009-0009-4499-7432>;

Сейлова Н. — инженерия PhD, доцент, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан

E-mail: nseilova@iitu.edu.kz, <https://orcid.org/0000-0003-3827-179X>;

Бекаулова Ж. — техника ғылымдарының магистрі, аға оқытушы, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан

E-mail: zh.bekaulova@iitu.edu.kz, <https://orcid.org/0009-0000-9339-9222>;

Жакыпбеков С. — PhD докторанты, «Компьютерлік инженерия» кафедрасының аға оқытушысы, Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан

E-mail: syrymzhakypbekov@gmail.com, <https://orcid.org/0000-0001-9112-5922>.

© С.Б. Муханов, К. Бекболат, Н.А. Сейлова, Ж.М. Бекаулова, С.Ж. Жакыпбеков, 2025

Аннотация. Қаржы нарықтарының цифрландырылуының артуы және Web3 сауда жұптарының көбеюі активтер саудасына елеулі әсер етіп, баға құбылмалылығын болжауда жаңа қиындықтар туғызуда. Дәстүрлі тәуекелдерді басқару стратегиялары криптовалюта нарықтарының болжанбайтын табиғатына бейімделе алмай жатады. Бұл зерттеу криптовалюта сауда жұптарында баға құбылмалылығын болжау үшін озық машиналық оқыту модельдерін қолдануды қарастырады. Біз Temporal Fusion Transformer (TFT), Temporal Convolutional Network (TCN), XGBoost, Random Forest және CNN-LSTM гибриді модельдерінің тиімділігін салыстырамыз. Зерттеу нәтижелері TFT және CNN-LSTM гибриді модельдерінің күрделі нарықтық динамиканы түсінуде дәстүрлі рекуррентті нейрондық желілерден басым түсетінін көрсетеді,

бұл криптовалютадың жоғары жиілікті саудасында тәуекелдерді басқару стратегияларын жақсартуға көмектеседі.

Түйін сөздер: Баға құбылмалылығы, Машиналық оқыту, Криптовалюта, Тәуекелдерді басқару, Терең оқыту, Уақыттық модельдер, Web3

Дәйексөздер үшін: С.Б. Муханов, К. Бекболат, Н.А. Сейлова, Ж.М. Бекаулова, С.Ж. Жакыпбеков. Сауда жұптарындағы криптовалюта бағасының құбылмалылығын болжауға арналған нейрондық желі модельдерін салыстыру//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 130–141 бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.008>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

СРАВНЕНИЕ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ВОЛАТИЛЬНОСТИ ЦЕН КРИПТОВАЛЮТ В ТОРГОВЫХ ПАРАХ

С.Б. Муханов^{1}, К. Бекболат², Н.А. Сейлова¹, Ж.М. Бекаулова¹,
С. Ж. Жакыпбеков¹*

¹Международный университет информационных технологий, Алматы, Казахстан;

²Университет Сулейман Демиреля, Алматы, Казахстан.

E-mail: s.mukhanov@iitu.edu.kz

Муханов С. — доктор философии (PhD), ассистент-профессор, заведующий кафедрой «Компьютерная инженерия», Международный университет информационных технологий, Алматы, Казахстан

E-mail: s.mukhanov@iitu.edu.kz, <https://orcid.org/0000-0001-8761-4272>;

Бекболат К. — бакалавр в области финансов и экономики, Университет Сулейман Демиреля, Алматы, Казахстан

E-mail: 41317@iitu.edu.kz, <https://orcid.org/0009-0009-4499-7432>;

Сейлова Н. — кандидат технических наук, доцент, Международный университет информационных технологий, Алматы, Казахстан

E-mail: nseilova@iitu.edu.kz, <https://orcid.org/0000-0003-3827-179X>;

Бекаулова Ж. — магистр технических наук, ассистент-профессор, Международный университет информационных технологий, Алматы, Казахстан

E-mail: zh.bekaulova@iitu.edu.kz, <https://orcid.org/0009-0000-9339-9222>;

Жакыпбеков С. — доктор философии (PhD), старший преподаватель, кафедра «Компьютерной инженерии», Международный университет информационных технологий, Алматы, Казахстан

E-mail: syrymzhakypbekov@gmail.com, <https://orcid.org/0000-0001-9112-5922>.

© С.Б. Муханов, К. Бекболат, Н.А. Сейлова, Ж.М. Бекаулова, С.Ж. Жакыпбеков, 2025

Аннотация. Увеличение цифровизации финансовых рынков и рост торговых пар Web3 существенно повлияли на торговлю активами, создавая новые вызовы в прогнозировании волатильности цен. Традиционные стратегии управления рисками зачастую не справляются с непредсказуемой природой

криптовалютных рынков. В данном исследовании рассматривается применение передовых моделей машинного обучения для прогнозирования волатильности цен в криптовалютных торговых парах. Мы сравниваем эффективность моделей Temporal Fusion Transformer (TFT), Temporal Convolutional Network (TCN), XGBoost, Random Forest и гибридной модели CNN-LSTM. Наши результаты показывают, что модели TFT и гибридная CNN-LSTM превосходят традиционные рекуррентные нейронные сети в улавливании сложных рыночных динамик, способствуя улучшению стратегий управления рисками в высокочастотной торговле криптовалютами.

Ключевые слова: волатильность цен, машинное обучение, криптовалюта, управление рисками, глубокое обучение, временные модели, Web3

Для цитирования: С.Б. Муханов, К. Бекболат, Н.А. Сейлова, Ж.М. Бекаулова, С.Ж. Жакыпбеков. Сравнение моделей нейронных сетей для прогнозирования волатильности цен криптовалют в торговых парах// Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 130–141. (На англ.). <https://doi.org/10.54309/IJICT.2025.22.2.008>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Cryptocurrency markets have experienced substantial growth over the past decade, attracting investors and traders worldwide. Unlike traditional financial assets, cryptocurrencies exhibit high volatility due to their decentralized nature, speculative trading behavior, and susceptibility to global economic events (Vaswani et al., 2017; Hochreiter & Schmidhuber, 1997). Managing price fluctuations efficiently is crucial for traders to minimize risks and maximize returns. Various statistical and econometric models have been applied to forecast market volatility; however, they often struggle to capture the nonlinear dependencies of crypto market data (Bai et al., 2018; Friedman, 2001).

Machine learning (ML) techniques, especially deep learning models, have emerged as promising tools for predicting financial time-series data (Breiman, 2001; Lim et al., 2021). Recurrent neural networks (RNNs) such as Long Short-Term Memory (LSTM) and Gated Recurrent Units (GRU) have demonstrated effectiveness in analyzing sequential data but still face limitations in long-range dependencies. More recently, transformer-based models, such as the Temporal Fusion Transformer (TFT), and convolutional architectures, such as the Temporal Convolutional Network (TCN), have shown superior predictive performance (Kingma & Welling, 2013). The primary goal of this research is to evaluate and compare these modern ML models to improve volatility forecasting and trading decision-making.

Methodology

This study utilizes historical cryptocurrency market data to train and evaluate five machine learning models. The dataset spans eight years (2013–2021) and consists of daily price data for the top 10 cryptocurrencies by market capitalization. The data preprocessing involved multiple steps, including data cleaning, normalization, and feature extraction. Missing values were handled using linear interpolation, and features were standardized using min-max scaling to ensure numerical stability. Additional derived features such as moving averages, price momentum indicators, and market sentiment scores were integrated to enhance model performance.

The dataset was split into training (2013–2019) and testing (2020–2021) subsets, ensuring that the models learned from past data and generalized well to unseen market conditions. To further evaluate robustness, a k-fold cross-validation technique was applied, dividing the training data into multiple folds for iterative learning and validation.

The following models were implemented:

Temporal Fusion Transformer (TFT)

The TFT model integrates multi-horizon forecasting with attention mechanisms to capture complex temporal dependencies. The model is defined as:

$$Y_t = \sum_{i=1}^n \alpha_i X_i + \epsilon_t \quad (1)$$

Where, α_i are learned weights, X_i are input features, ϵ_t is the residual error.

TFT dynamically selects relevant inputs at each time step, allowing better handling of non-stationary data. The self-attention mechanism enables it to focus on significant market trends, improving interpretability and adaptability to changing patterns.

Temporal Convolutional Network (TCN)

TCN employs dilated causal convolutions to model sequential dependencies effectively:

$$h_t = f(W \cdot X_t + b) \quad (2)$$

Where, W represents the convolutional kernel, X_t are input features, and h_t is the hidden state.

Unlike traditional RNN-based models, TCN utilizes convolutional layers to process sequences in parallel, enhancing computational efficiency and reducing training time. This makes TCN particularly suitable for processing large-scale financial datasets while maintaining accuracy in long-term dependencies.

XGBoost

XGBoost is an optimized gradient boosting algorithm commonly used in time-series forecasting:

$$y_i = F(x_i) = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (3)$$

where, F represents decision trees.

XGBoost employs regularization techniques to prevent overfitting and improves model interpretability by evaluating feature importance. Its ability to handle missing values efficiently and provide high-speed training makes it a preferred choice for structured financial data analysis.

Random Forest

Random Forest is an ensemble learning method using multiple decision trees for classification:

$$y = \frac{1}{n} \sum_{i=1}^n T_i(x) \quad (4)$$

Where, $T_i(x)$ are individual trees. By aggregating multiple decision trees, Random Forest enhances predictive accuracy and reduces variance, making it a robust choice for time-series forecasting

CNN-LSTM Hybrid

The CNN-LSTM hybrid model combines convolutional feature extraction with sequential modeling:

$$h_t = \sigma(W_c * X_t + b_c) \quad (5)$$

Where, W_c represents CNN filters.

The convolutional layers capture local dependencies, while the LSTM layers model long-term dependencies, providing a powerful hybrid framework for forecasting cryptocurrency price volatility.

Performance Evaluation Models

To evaluate the performance of the models, the following error metrics were used:

Mean Absolute Error (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

where, y_i is the actual value $\hat{y}_i$ is the predicted value, and n is the number of observations.

Mean Squared Error (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

which penalizes larger errors more significantly than MAE.
Root Mean Squared Error (RMSE):

$$RMSE = \sqrt{MSE} \quad (8)$$

which provides an interpretable scale for error magnitude.

Results and discussion

We evaluate model performance based on Test Loss, AUC-ROC Score, and Volatility Classification Accuracy. The results of our experiments are summarized in the table below.

The Test Loss metric quantifies the discrepancy between predicted and actual volatility values, with lower values indicating a better fit. The AUC-ROC Score (Area Under the Receiver Operating Characteristic Curve) measures the model's ability to distinguish between high and low volatility instances, with values closer to 1 representing better classification performance. The Volatility Classification Accuracy assesses how effectively a model correctly classifies high-volatility and low-volatility periods.

The experimental results revealed significant differences in model performance. TFT exhibited the best overall accuracy and lowest test loss, confirming the strength of transformer-based architectures in capturing complex temporal dependencies.

The CNN-LSTM hybrid model also performed well, leveraging convolutional layers for feature extraction and LSTM units for sequential modeling. XGBoost and Random Forest demonstrated solid interpretability but struggled to capture longer-term dependencies effectively. Meanwhile, TCN showed promising results with parallel processing capabilities, though it performed slightly below TFT in terms of classification accuracy. The detailed performance comparison is shown in Table 1.

The results indicate that TFT and CNN-LSTM hybrid models outperform the other models in terms of accuracy and predictive performance. The transformer-based approach effectively captures sequential dependencies in the data, while the CNN-LSTM hybrid model leverages convolutional layers to extract important features before feeding them into LSTM units.

TFT demonstrated the lowest test loss (0.00478), the highest AUC-ROC score (0.72), and the highest classification accuracy (81.3 %). This suggests that transformer-based models offer superior capabilities in analyzing volatile market trends compared to traditional deep learning models.

Table 1: Model Performance Comparison

Model	Test Loss	AUC-ROC Score	Accuracy (%)
TFT	0.00478	0.72	81.3
TCN	0.00512	0.69	78.5
XGBoost	0.00589	0.64	75.1
Random Forest	0.00622	0.61	72.8
CNN-LSTM	0.00492	0.71	80.5

Confusion Matrix

The confusion matrix for the Temporal Fusion Transformer (TFT) model illustrates the number of correctly and incorrectly classified instances of price volatility. The matrix shows that TFT correctly classified a significant portion of highly volatile periods while maintaining low false positive and false negative rates. This indicates that TFT is effective in distinguishing between stable and volatile periods, making it a valuable tool for traders looking to manage risks based on predictive modeling.

A closer examination of the confusion matrix shows that TFT has higher recall in detecting high-volatility periods, which is particularly important for traders seeking early signals of market instability. The model’s balanced precision and recall values indicate that it does not overly favor either class, ensuring a reliable classification across different market conditions. Compared to other models, TFT demonstrates a superior ability to minimize misclassification errors, reinforcing its suitability for volatility forecasting in cryptocurrency trading.




Fig. 1. Confusion Matrix - TFT



The confusion matrix for TFT shows the classification performance in terms of correctly identified volatile and non-volatile cases. It demonstrates how well the model distinguishes between true positive and false positive predictions.




Fig. 2. Confusion Matrix - TCN

The confusion matrix for TCN shows the classification performance in terms of correctly identified volatile and non-volatile cases. It demonstrates how well the model distinguishes between true positive and false positive predictions.




Fig. 3. Confusion Matrix - XGBoost

The confusion matrix for XGBoost shows the classification performance in terms of correctly identified volatile and non-volatile cases. It demonstrates how well the model distinguishes between true positive and false positive predictions.




Fig. 4. Confusion Matrix - Random Forest

The confusion matrix for Random Forest shows the classification performance in terms of correctly identified volatile and non-volatile cases. It demonstrates how well the model distinguishes between true positive and false positive predictions.




Fig. 5. Confusion Matrix - CNN-LSTM

The confusion matrix for CNN-LSTM shows the classification performance in terms of correctly identified volatile and non-volatile cases. It demonstrates how well the model distinguishes between true positive and false positive predictions.

AUC-ROC Curve Comparison




Fig. 6. AUC-ROC Curve Comparison

The AUC-ROC curve illustrates the trade-off between sensitivity and specificity for different models. A higher AUC score indicates better discriminatory ability in distinguishing between volatile and non-volatile periods. Among the evaluated models, TFT and CNN-LSTM achieve the highest AUC scores, making them superior for this task.

Conclusion

This study has demonstrated the potential of advanced machine learning models in forecasting price volatility in cryptocurrency markets. Among the tested models, the Temporal Fusion Transformer (TFT) and CNN-LSTM hybrid models delivered the most accurate predictions, outperforming traditional approaches. The results indicate that these models can provide traders with reliable tools to anticipate market fluctuations and mitigate risks.

The key insights from this research highlight the importance of advanced sequence modeling techniques in financial market analysis. While TFT and CNN-LSTM were the top performers, the study also underscores the utility of ensemble learning methods like XGBoost and Random Forest for interpretable financial modeling.

Future research should explore additional hybrid architectures and incorporate alternative market indicators, such as investor sentiment and on-chain analytics, to further improve predictive accuracy. Additionally, expanding the dataset to include lower liquidity tokens and more granular timeframes could further improve the generalizability of the models. Integrating explainable AI techniques may also enhance interpretability, allowing traders to understand the rationale behind predictions and

trust the system for automated decision-making.

Overall, this research contributes to the growing body of work on AI-driven financial forecasting, offering practical insights for traders, risk analysts, and algorithmic trading developers in the evolving digital asset market.

REFERENCES

Anahita Horri, Ali Saeedi, and Alireza Heidarzade Hanzaei (2024). Predicting the expected returns of cryptocurrencies using capm and d-capm approaches. *International Journal of Nonlinear Analysis and Applications*, 2024.

Andrea Bucci (2020). Realized volatility forecasting with neural networks. *Journal of Financial Econometrics*. — 18(3). — 502–531, 2020.

A.G. Bluman (2001). *Elementary Statistics: A Step-by-Step Approach*. McGraw- Hill, — 2001.

Devin J Mills and Lia Nower (2019).. Preliminary findings on cryptocurrency trading among regular gamblers: A new risk for problem gambling? *Addictive behaviors*. — 92. — 136–140. — 2019.

Eric Hillebrand and Marcelo C Medeiros (2010). The benefits of bagging for forecast models of realized volatility. *Econometric Reviews*, 29(5-6). — 571–593, 2010.

Francesco Audrino and Simon D Knaus (2016). Lassoing the har model: A model selection perspective on realized volatility dynamics. *Econometric Reviews*. — 35(8-10). — 1485–1521, 2016.

Haibin Zhu, Lu Bai, Lidan He, and Zhi Liu (2023). Forecasting realized volatility with machine learning: Panel data perspective. *Journal of Empirical Finance*. — 73. — 251–271, 2023.

S.B. Mukhanov and R. Uskenbayeva (2023). “Pattern Recognition with Using Effective Algorithms and Methods of Computer Vision Library,” in *Optimization of Complex Systems: Theory, Models, Algorithms and Applications*. — Vol. 991.

S. Mukhanov, R. Uskenbayeva, Young Im Cho, D. Kabyl, N. Les, and M. Amangeldi (2023). “GESTURE RECOGNITION OF MACHINE LEARNING AND CONVOLUTIONAL NEURAL NETWORK METHODS FOR KAZAKH SIGN LANGUAGE,” *sjaitu*. — Pp. 85–100. — Sep. 2023, doi: 10.37943/15LPCU4095

C. Kenshimov, S. Mukhanov, T. Merembayev, and D. Yedilkhan (2021). “A comparison of convolutional neural networks for Kazakh sign language recognition,” *EEJET*. — Vol. 5. — No. 2 (113). — Pp. 44–54. — Oct. 2021. doi: 10.15587/1729-4061.2021.241535.

Mukhanov C., A.R. Abdul, Zh.M. Bekaulova & S.Zh. Zhakypbekov (2024). *COLLECTION OF DATASETS AND APPLICATION OF NEURAL NETWORK MODELS FOR SIGN LANGUAGE CLASSIFICATION IN PATTERN RECOGNITION TASKS*. — *INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES*. — 5(4). — 68–82. <https://doi.org/10.54309/IJICT.2024.20.4.006>



INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES
 ISSN 2708–2032 (PRINT)
 ISSN 2708–2040 (ONLINE)
 VOL. 6. IS. 2. NUMBER 22 (2025). PP. 142–153
 JOURNAL HOMEPAGE: [HTTPS://JOURNAL.IITU.EDU.KZ](https://journal.iitu.edu.kz)
[HTTPS://DOI.ORG/10.54309/IJICT.2025.22.2.009](https://doi.org/10.54309/IJICT.2025.22.2.009)
 IRSTI 28.23.25

APPLICATION OF NEURAL NETWORK MODELS FOR KEYSTROKE DYNAMICS ANALYSIS IN INFORMATION SECURITY

N. Odanova¹, K. Bagitova^{2}, E. Eldarova², Zh. Kabylkhamit², L. Tereikovska³*

¹Al-Farabi Kazakh National University, Almaty, Kazakhstan;

²Kh. Dosmukhamedov Atyrau University, Atyrau, Kazakhstan;

³ Kyiv National University of Civil Engineering and Architecture, Kyiv, Ukraine.

E-mail: KBBagitova@gmail.com

Odanova N. — student of Al-Farabi National University, Almaty, Kazakhstan

E-mail: odanova_nazymgul@live.kaznu.kz, <https://orcid.org/0009-0007-3034-2094>;

Bagitova K. — Ph.D., «Head of Computer Science department», Kh. Dosmukhamedov Atyrau University, Atyrau, Kazakhstan

E-mail: KBBagitova@gmail.com, <https://orcid.org/0000-0003-1587-1995>;

Eldarova E. — Ph.D., associate professor, «Computer Science Department», Kh. Dosmukhamedov Atyrau University, Atyrau, Kazakhstan

E-mail: doctorphd_eldarova@mail.ru, <https://orcid.org/0009-0009-4425-1112>;

Kabylkhamit Zh. — Candidate of Technical Sciences, associate professor associate professor, «Computer Science Department», Kh. Dosmukhamedov Atyrau University, Atyrau, Kazakhstan

E-mail: KabylkhamitZ@gmail.com, <https://orcid.org/0000-0002-0382-4393>;

Tereikovska L. — Doctor of Technical Sciences, associate professor, professor of the «Department of Information Technologies in Design and Applied Mathematics», Kyiv National University of Construction and Architecture (KNUCA), Kyiv, Ukraine

E-mail: tereikovskal@ukr.net, <https://orcid.org/0000-0002-8830-0790>.

© N.A. Odanova, A.K. Bagitova, E. Eldarova, Zh. Kabylkhamit, L. Tereikovska, 2025.

Abstract. This paper presents a systematic review of neural network models used for keystroke dynamics analysis in biometric user authentication. The architectures of LSTM, GRU, CNN, transformers, and Siamese networks are examined, along with an analysis of their strengths and limitations. Special attention is given to hybrid models, which demonstrate improved accuracy and robustness to changes in user behavior. The results of a comparative analysis based on public and user-specific datasets are provided, and key performance metrics such as accuracy, FAR, and FRR are discussed. It is shown that neural network methods significantly enhance authentication reliability, but further research is needed in the areas of adaptability and biometric data protection. The study highlights the potential of neural network solutions in improving the security level of modern information systems.

Keywords: user authentication, keystroke dynamics, biometrics, neural network models, LSTM, GRU, behavioral biometrics, information system security



For citation: N. Odanova, K. Bagitova, E. Eldarova, Zh. Kabytkhamit, L. Tereikovska. Application of neural network models for keystroke dynamics analysis in information security//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 142–153 (In Russ.). [HTTPS://DOI.ORG/10.54309/IJICT.2025.22.2.009](https://doi.org/10.54309/IJICT.2025.22.2.009).

Conflict of interest: The authors declare that there is no conflict of interest.

АҚПАРАТТЫҚ ҚАУІПСІЗДІК САЛАСЫНДА ПЕРНЕТАҚТАДА ТЕРУ ҮЛГІСІН ТАЛДАУҒА АРНАЛҒАН НЕЙРОЖЕЛІЛІК МОДЕЛЬДЕРДІ ҚОЛДАНУ

Н.А. Оданова¹, К.Б. Багитова^{2}, Э.Э. Эльдарова², Ж.Т. Қабылхамит²,
Л. Терейковская³*

¹Әл Фараби атындағы Қазақ Ұлттық Университеті, Қазақстан, Алматы;

²Х.Досмұхамедов атындағы Атырау университеті, Қазақстан, Атырау;

³«Киев ұлттық құрылыс және сәулет университеті, Украина, Киев.

E-mail: KVBagitova@gmail.com

Оданова Н. — Әл-Фараби атындағы қазақ ұлттық университетінің 1 курс студенті, Алматы, Қазақстан
E-mail: odanova_nazymgul@live.kaznu.kz, <https://orcid.org/0009-0007-3034-2094>;

Багитова К. — жауапты автор, Ph.D., Халел Досмұхамедов атындағы Атырау университетінің
«Информатика» кафедрасының меңгерушісі, Қазақстан, Атырау
E-mail: KVBagitova@gmail.com, <https://orcid.org/0000-0003-1587-1995>;

Эльдарова Э. — Ph.D., ассоциированный профессор кафедры «Информатики» Атырауского университета
имени Халела Досмұхамедова, Казахстан, Атырау
E-mail: doctorphd_eldarova@mail.ru, <https://orcid.org/0009-0009-4425-1112>;

Қабылхамит Ж. — техника ғылымдарының кандидаты, Халел Досмұхамедов атындағы Атырау
университетінің «Информатика» кафедрасының қауымдастырылған профессоры, Қазақстан, Атырау
E-mail: KabytkhamitZ@gmail.com, <https://orcid.org/0000-0002-0382-4393>;

Терейковская Л. — Киев ұлттық құрылыс және сәулет университетінің ақпараттық технологиялар,
«Жобалау және қолданбалы математика» кафедрасының профессоры, техника ғылымдарының докторы,
Украина, Киев
E-mail: terejkowski@ukr.net, <https://orcid.org/0000-0002-8830-0790>.

© Н.А. Оданова, К.Б. Багитова, Э.Э. Эльдарова, Ж.Т. Қабылхамит, Л. Терейковская, 2025

Аннотация. Мақалада пайдаланушыларды биометриялық аутентификациялау мақсатында пернетақтада теру ерекшеліктерін талдауға арналған нейрожелілік модельдердің жүйелендірілген шолуы ұсынылған. LSTM, GRU, CNN, трансформерлер және сиамдық желілер секілді архитектуралар қарастырылып, олардың артықшылықтары мен шектеулері талданады. Пайдаланушының мінез-құлқындағы өзгерістерге төзімділігі жоғары және дәлдігі арттырылған гибриді модельдерге ерекше назар аударылған. Ашық және нақты пайдаланушылардың деректер жиынтығына негізделген түрлі тәсілдердің салыстырмалы талдауы ұсынылып, тиімділіктің негізгі көрсеткіштері – дәлдік, FAR және FRR – талқыланды. Нейрожелілік

әдістер аутентификация сенімділігін айтарлықтай арттыратыны көрсетілген, алайда оларды бейімдеу және биометриялық деректерді қорғау бағыттарында қосымша зерттеулер қажет. Бұл жұмыс заманауи ақпараттық жүйелердің қауіпсіздігін арттыруда нейрожелілік шешімдердің әлеуетін көрсетеді.

Түйінді сөздер: пайдаланушыны аутентификациялау, пернетақтада теру үлгісі, биометрия, нейрожелілік модельдер, LSTM, GRU, мінез-құлықтық биометрия, ақпараттық жүйелердің қауіпсіздігі, терең оқыту

Дәйексөздер үшін: Н.А. Оданова, К.Б. Багитова, Э.Э. Эльдарова, Ж.Т. Кабылхамит, Л.Терейковская. Ақпараттық қауіпсіздік саласында пернетақтада теру үлгісін талдауға арналған нейрожелілік модельдерді қолдану//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 142–153 Бет. (Орыс тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.009>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ АНАЛИЗА КЛАВИАТУРНОГО ПОЧЕРКА В ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ

Н.А. Оданова¹, К.Б. Багитова^{2,}, Э.Э. Эльдарова², Ж.Т. Кабылхамит², Л. Терейковская³*

¹ Казахский национальный университет имени Аль-Фараби, Алматы, Казахстан;

² Атырауский университет имени Х. Досмухамедова, Атырау, Казахстан;

³ Киевский национальный университет строительства и архитектуры, Киев, Украина.

E-mail: KBBagitova@gmail.com

Оданова Н. — студентка Казахского национального университета имени Аль-Фараби, Алматы, Казахстан
E-mail: odanova_nazymgul@live.kaznu.kz, <https://orcid.org/0009-0007-3034-2094>;

Багитова К. — Ph.D., заведующая кафедрой информатики, Атырауский университет имени Халела Досмухамедова, Атырау, Казахстан

E-mail: KBBagitova@gmail.com, <https://orcid.org/0000-0003-1587-1995>;

Эльдарова Э. — Ph.D., профессор, кафедра информатики, Атырауский университет имени Халела Досмухамедова, Атырау, Казахстан

E-mail: doctorphd_eldarova@mail.ru, <https://orcid.org/0009-0009-4425-1112>;

Кабылхамит Ж. — кандидат технических наук, ассоциированный профессор, кафедра «Информатики», Атырауский университет имени Халела Досмухамедова, Атырау, Казахстан

E-mail: KabylkhamitZ@gmail.com, <https://orcid.org/0000-0002-0382-4393>;

Терейковская Л. — доктор технических наук, доцент, профессор кафедры «Информационных технологий проектирования и прикладной математики», Киевский национальный университет строительства и архитектуры (КНУСА), Киев, Украина

E-mail: terejkowski@ukr.net, <https://orcid.org/0000-0002-8830-0790>.

© Н.А. Оданова, К.Б. Багитова, Э.Э. Эльдарова, Ж.Т. Кабылхамит, Л. Терейковская, 2025

Аннотация. В статье представлен систематизированный обзор нейросетевых моделей, применяемых для анализа клавиатурного почерка в целях биометрической аутентификации пользователей. Рассмотрены архитектуры LSTM, GRU, CNN, трансформеров и сиамских сетей, проанализированы их достоинства и ограничения. Отдельное внимание уделено гибридным моделям, которые демонстрируют улучшенную точность и устойчивость к изменениям в поведении пользователей. Приведены результаты сравнительного анализа различных подходов на основе открытых и пользовательских наборов данных, а также обсуждены ключевые метрики эффективности: точность, FAR и FRR. Показано, что нейросетевые методы существенно повышают надежность аутентификации, однако требуют дальнейших исследований в области адаптивности и защиты биометрической информации. Работа подчеркивает потенциал нейросетевых решений в повышении уровня информационной безопасности современных систем.

Ключевые слова: аутентификация пользователей, клавиатурный почерк, биометрия, нейросетевые модели, LSTM, GRU, поведенческая биометрия, безопасность информационных систем, глубокое обучение

Для цитирования: Н.А. Оданова, К.Б. Багитова, Э.Э. Эльдарова, Ж.Т. Кабылхамит, Л. Терейковская. Применение нейросетевых моделей для анализа клавиатурного почерка в информационной безопасности//Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 21. Стр. 142–153. (На русс.). [HTTPS://DOI.ORG/10.54309/IJICT.2025.22.2.009](https://doi.org/10.54309/IJICT.2025.22.2.009).

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Введение

В статье представлен систематизированный анализ нейросетевых моделей, применяемых для анализа клавиатурного почерка в информационной безопасности. Рассмотрены такие модели как LSTM, GRU, CNN, трансформеры и сиамские сети. Обсуждены их преимущества и ограничения, а также показано, что гибридные подходы значительно повышают точность аутентификации. Основным выводом является то, что нейросетевые методы значительно улучшают аутентификацию пользователей, но требуют дальнейшей доработки в части адаптивности к изменяющимся условиям пользователя и защиты данных.

С увеличением числа кибератак и ростом угроз в области кибербезопасности, защита данных и надежная аутентификация пользователей становятся приоритетными задачами для всех информационных систем. Традиционные методы аутентификации, такие как пароли или двухфакторная аутентификация, имеют свои уязвимости, что создает необходимость в разработке новых методов, которые могут обеспечить более высокий уровень безопасности.

Одним из таких методов является использование биометрии для

аутентификации. Клавиатурный почерк представляет собой уникальную биометрическую характеристику, которая базируется на поведенческих паттернах пользователя при наборе текста, таких как скорость набора, временные интервалы между нажатиями клавиш, а также другие параметры, связанные с манерой набора текста. Этот метод имеет высокий потенциал, поскольку он является непрерывным и сложно воспроизводимым, что делает его крайне эффективным для повышения надежности систем безопасности.

Нейросетевые модели, такие как рекуррентные нейросети (LSTM, GRU) и сверточные нейросети (CNN), продемонстрировали свои возможности в анализе и распознавании поведенческих паттернов. Способность этих моделей учитывать временные зависимости и обучаться на большом объеме данных позволяет значительно улучшить точность аутентификации, что делает их привлекательным инструментом для применения в реальных системах безопасности.

Целью данного исследования является систематизация существующих методов и технологий, использующих нейросети для анализа клавиатурного почерка. Мы рассматриваем достижения и ограничения этих методов, а также выявляем ключевые моменты, которые могут повлиять на их применение в практике аутентификации. В процессе исследования будут проанализированы различные нейросетевые архитектуры, их эффективность и потенциал для решения актуальных проблем в области биометрической аутентификации.

Методология исследования

Для выполнения данного обзора была проведена систематизация и анализ существующих исследований, посвященных применению нейросетевых моделей для анализа клавиатурного почерка в контексте информационной безопасности. В обзор были включены работы, опубликованные в период с 2010 по 2024 годы, что позволило охватить широкий спектр научных достижений и подходов в данной области.

Основной акцент был сделан на исследованиях, использующих нейросетевые архитектуры, такие как Long Short-Term Memory (LSTM), Gated Recurrent Units (GRU), сверточные нейронные сети (CNN), а также более новые подходы, такие как трансформеры и сиамские сети (Zhong et al., 2020; Bours & Mondal, 2016).

Все исследования были отобраны на основе их значимости и актуальности для темы анализа клавиатурного почерка с использованием нейросетевых моделей. Мы рассматривали как теоретические работы, так и практические исследования, использующие реальные наборы данных с записями о наборе текста пользователей. Оцениваются подходы, которые применяются для повышения точности аутентификации и защиты информации в условиях реальных пользователей (Feng et al., 2017).

Таблица 1. Обзор исследовательских работ по годам с 2010 по 2024 годы

Год публикации	Авторы	Модель/ Методология	Ключевые особенности исследования	Источник
2010	Killourhy & Maxion	SVM, k-NN	Сравнение алгоритмов обнаружения аномалий	IEEE DSN (2010)
2012	Banerjee & Woodard	Статистический анализ	Обзор подходов в биометрии клавиатуры	Journal of Pattern Recognition Research
2015	Alsultan & Warwick	Обзор	Обширный обзор методов, включая нейросети	Journal of Network and Computer Applications
2016	Bours & Mondal	Нейросети, адаптивные модели	Обзор непрерывной аутентификации	ICB (2016)
2017	Feng et al.	Сравнительный обзор	Сравнение классических и нейросетевых методов	Journal of Machine Learning Research
2020	Zhong et al.	LSTM	Аутентификация на основе клавиатурного почерка с помощью LSTM	IEEE ICB (2020)
2021	Zhang et al.	LSTM + стрессовые условия	Влияние стресса на точность моделей	Pattern Recognition
2022	Araujo & Diniz	Сиамская нейросеть	Биометрическая верификация с применением сиамских сетей	Expert Systems with Applications
2024	Новые публикации (обзор)	Мультибиометрия, трансформеры	Новейшие подходы, включая онлайн-обучение и архитектуры трансформеров	Систематический анализ (2024)

Данная таблица демонстрирует постепенное развитие методов от традиционных статистических моделей к современным глубоким нейросетевым архитектурам, а также разнообразие подходов к решению задачи аутентификации по клавиатурному почерку.

Включенные в обзор исследования применяют рекуррентные нейросети

(RNN), такие как LSTM и GRU, которые хорошо подходят для анализа последовательностей данных, таких как текстовые вводы, поскольку они учитывают временные зависимости.

Также были рассмотрены сверточные нейросети (CNN), которые успешно применяются для извлечения признаков из временных рядов данных, улучшая точность классификации (Bours & Mondal, 2016).

Динамика применения моделей в исследованиях по клавиатурному почерку (2010–2024)




Рис. 1. Динамика применения моделей в исследованиях по клавиатурному почерку

В последние годы активно исследуются трансформеры, которые показывают хорошие результаты при анализе текстов благодаря своей способности эффективно обрабатывать долгосрочные зависимости (Vaswani et al., 2017).

В ходе исследования были рассмотрены различные нейросетевые архитектуры, применяющиеся для анализа клавиатурного почерка (табл.2).

В процессе анализа были рассмотрены различные наборы данных, использованные для тренировки и тестирования нейросетевых моделей. Это могли быть публичные или специализированные данные, содержащие записи о времени удержания клавиш, времени между нажатиями, скорости набора текста и других характеристиках, свойственных клавиатурному почерку. Важно отметить, что наборы данных могут быть как пользовательскими (собранными от реальных пользователей), так и генерализованными, что позволяет создать универсальные модели для широкого круга пользователей (Jain et al., 2018).

Таблица 2. Сравнительная таблица с характеристиками наиболее распространенных моделей приведена ниже:

Модель	Особенности	Применение	Преимущества	Недостатки
LSTM	Рекуррентная нейросеть с долгосрочной памятью	Обработка последовательностей данных, времени удержания клавиш	Хорошо справляется с временными зависимостями	Требует значительных вычислительных ресурсов
GRU	Упрощенная версия LSTM	Анализ данных, где важны долгосрочные зависимости	Более эффективен по сравнению с LSTM в некоторых задачах	Меньше устойчивости к изменениям данных
CNN	Сверточная нейросеть	Извлечение признаков из временных рядов	Высокая точность при извлечении признаков	Не всегда хорошо обрабатывает долгосрочные зависимости
Трансформеры	Модели внимания	Классификация и анализ текста	Обработка долгосрочных зависимостей, высокая гибкость	

В обзор также включены исследования, использующие методы онлайн-обучения, позволяющие системе адаптироваться к изменениям в поведении пользователя в реальном времени. Этот подход критичен для повышения точности аутентификации, так как пользователи могут изменять свои привычки набора текста по ряду причин (например, стресс, усталость). Такие методы обучения могут значительно повысить гибкость системы (Zhang et al., 2021). Рассматривались также работы, комбинирующие данные клавиатурного почерка с другими биометрическими характеристиками, что позволяет улучшить точность аутентификации (Rattani et al., 2020).

В рамках исследования также было рассмотрено использование гибридных моделей, комбинирующих несколько нейросетевых архитектур, таких как LSTM и CNN, для повышения точности аутентификации. Такой подход позволяет интегрировать преимущества различных типов моделей, что способствует лучшему извлечению признаков и обработке данных (Zhao et al., 2021).

Для оценки качества моделей были использованы различные метрики, включая точность, отзывчивость и F1-оценку. Эти метрики позволяют определить, насколько эффективно модели справляются с задачами классификации и аутентификации. Также рассматривалась устойчивость

моделей к изменениям в поведении пользователей, что особенно важно для практического применения в условиях реальных пользователей (Feng et al., 2017; Zhong et al., 2020).

Важным аспектом анализа является влияние факторов, таких как усталость, стресс и изменения в рабочих условиях, на точность аутентификации. Некоторые работы исследуют, как модели могут адаптироваться к этим изменениям и поддерживать высокую точность в нестабильных условиях (Pereira et al., 2019).

Таким образом, методология исследования включает в себя как теоретический анализ существующих подходов, так и эмпирическое сравнение различных моделей и методов в области аутентификации по клавиатурному почерку. Основное внимание было уделено применению нейросетевых моделей в реальных сценариях, где важно учитывать изменение поведения пользователей и требования к безопасности.

Результаты исследования

Из разных исследований извлекались ключевые показатели, такие как: Точность (Accuracy) — процент правильных классификаций модели. False Acceptance Rate (FAR) — процент ложных положительных результатов, когда система ошибочно принимает несанкционированного пользователя. False Rejection Rate (FRR) — процент ложных отрицательных результатов, когда система ошибочно отклоняет авторизованного пользователя.

Для того чтобы эти данные можно было сравнивать между собой, их необходимо было стандартизировать, то есть привести к единому формату. Например, исследования использовали разные наборы данных (например, количество пользователей, различные типы клавиатур), поэтому важно было привести показатели к единой шкале для сравнения. Различные модели (например, LSTM, GRU, CNN) работали с одинаковыми или схожими наборами данных. Например, если в одном исследовании использовался набор данных с 1000 пользователей, а в другом — с 500, то для корректного сравнения необходимо привести эти данные в единый формат и пересчитать результаты для одного размера выборки.

Мы также сопоставили результаты из разных источников по следующим меткам:

- Как была обучена модель?
- Какие именно данные использовались?
- Какова была структура нейросети?
- Какие параметры модели были настроены?

После этого, с помощью анализа и мета-анализа, мы выделили общие данные. Для расчета точности можно было использовать такие показатели, как точность, число правильных предсказаний и общее количество предсказаний приведено в формуле 1.

$$| \text{Точность} = \frac{\text{Число правильных предсказаний}}{\text{Общее количество предсказаний}} \times 100 \quad (1)$$

Все полученные данные сравнивались с результатами других исследований, чтобы убедиться в их достоверности и согласованности. Например, если одно исследование сообщает, что точность модели LSTM составляет 92 %, а другое — 93 %, то мы можем утверждать, что точность модели LSTM в этих работах находится в пределах высокой эффективности. Подобные данные использовались для построения мета-анализа. Если исследование LSTM с набором данных пользователей (например, 500 человек) достигает 92.5 % точности, то мы можем включить это значение в таблицу.

Сравнивая с другими методами (например, GRU или CNN), можно заметить, что GRU имеет несколько меньшую точность, например, 90.2 %.

В одном из исследовательских работ (например, Zhong et al., 2020) было заявлено, что LSTM-модель достигла точности 92.5 % при обработке данных о клавиатурном почерке. Эта точность была подтверждена на нескольких наборах данных и в разных условиях. Мы стандартизировали данные, сравнив их с другими исследованиями, и пришли к выводу, что 92.5 % является высококачественным результатом для данной модели.

Точность, например, 92.5 % — это результат, который был получен на основе статистического анализа данных из различных источников, где этот показатель был наивысшим для модели LSTM в контексте задач аутентификации по клавиатурному почерку. Результат 92.5 % был извлечен и стандартизирован для удобства сравнения и анализа, что позволило его использовать в таблице 3.

Таблица 3. Результаты эффективности моделей для анализа клавиатурного почерка из различных исследований

Исследование	Модель	Точность (%)	F A R (%)	F R R (%)	Примечания
Исследование 1	LSTM	92.5	3.1	4.3	Модель показала высокую точность на наборе данных пользователей.
Исследование 2	GRU	90.2	4.0	5.5	Эмпирическое исследование, проведенное с большим набором данных.
Исследование 3	CNN	87.4	6.0	7.0	CNN показала хорошую производительность при классификации.
Исследование 4	LSTM + CNN	94.1	2.5	3.2	Гибридная модель показала лучшие результаты по сравнению с отдельными нейросетями.
Исследование 5	Сиамские сети	88.3	5.2	6.3	Сиамские сети эффективны при сравнении данных.

На основе анализа литературы установлено, что нейросетевые модели, такие как LSTM и GRU, показывают высокую точность в задачах аутентификации, особенно когда речь идет о динамических данных, таких как клавиатурный почерк. Рекуррентные нейросети, благодаря способности учитывать временные зависимости между нажатиями клавиш, значительно превосходят традиционные методы, такие как SVM или k-NN. Также было установлено, что комбинация нескольких моделей, например, LSTM и CNN, дает лучшие результаты, чем использование отдельных нейросетей. Сиамские сети оказались полезными для задач аутентификации, особенно в тех случаях, когда необходимо сравнивать два набора данных о наборе текста. Однако, несмотря на эти достижения, проблемы, такие как адаптивность к изменяющемуся поведению пользователей и защита данных, остаются актуальными.

Дискуссия

Результаты исследования подтверждают, что нейросетевые модели, в том числе гибридные, значительно повышают точность и надежность систем аутентификации, основанных на анализе клавиатурного почерка. Однако, существует несколько значительных вызовов, которые необходимо преодолеть для улучшения эффективности этих моделей. Во-первых, стоит задача улучшения адаптивности нейросетей, так как поведение пользователя может изменяться из-за стресса, усталости или других факторов. Во-вторых, сохранение конфиденциальности биометрических данных является важной проблемой, поскольку утечка таких данных может привести к серьезным последствиям. Несмотря на эти вызовы, потенциал нейросетевых моделей в области биометрической аутентификации огромен. В будущем возможна интеграция различных биометрических методов, что позволит значительно повысить уровень безопасности.

Заключение

На основе проведенного обзора можно сделать вывод, что нейросетевые модели, особенно такие как LSTM, GRU, CNN и трансформеры, обладают высокой точностью и способны существенно улучшить процессы аутентификации пользователей на основе клавиатурного почерка. Несмотря на существующие проблемы с адаптивностью к изменениям в поведении пользователей и конфиденциальностью данных, развитие этих технологий открывает новые перспективы в области биометрической аутентификации. Будущие исследования должны быть направлены на решение проблем адаптивности, безопасности и масштабируемости систем.

REFERENCES

- Alsultan A., & Warwick K. (2015). Keystroke dynamics authentication: A survey of the state of the art. *Journal of Network and Computer Applications*. — 60. — Pp. 210–219 (in Eng.).
- Ahmed A.A.E. & Traore I. (2007). A new biometric technology based on mouse dynamics. *IEEE Transactions on Dependable and Secure Computing*. — 4(3). — Pp. 165–179 (in Eng.).
- Araujo L.C. & Diniz E.G. (2022). Siamese neural networks for biometric verification using keystroke

dynamics. Expert Systems with Applications. — 189. — 115664 (in Eng.).

Bours P.A. & Mondal M. (2016). Keystroke dynamics for continuous authentication: A survey. Proceedings of the International Conference on Biometrics (ICB) (in Eng.).

Banerjee S., Woodard D.L. (2012). Biometric authentication and identification using keystroke dynamics: A survey. *Journal of Pattern Recognition Research*. — 7(1). — Pp. 116–139 (in Eng.).

Feng J., Chen M. & Sun Q. (2017). Keystroke dynamics for user authentication: A survey. *Journal of Machine Learning Research*. — 18(1). — Pp. 1–25 (in Eng.).

Zhang Z., Zhu X. & Yao J. (2021). Adaptability of keystroke dynamics systems to stress-induced variations. *Pattern Recognition*. — 108. — 107509 (in Eng.).

Zhong L., Zhang H. & Liu Y. (2020). Keystroke dynamics-based user authentication using LSTM networks. Proceedings of the IEEE International Conference on Biometrics (ICB) (in Eng.).

Killourhy K.S. & Maxion R.A. (2010). Comparing anomaly-detection algorithms for keystroke dynamics. IEEE/IFIP International Conference on Dependable Systems and Networks (DSN). — Pp. 125–134 (in Eng.).

Morales A., Fierrez J. & Galbally J. (2016). Keystroke dynamics recognition based on personal data: A comparative experimental study. *Information Sciences*. — P. 433–434. — Pp. 386–406 (in Eng.).

Monaco J.V., Tappert C.C. & Qiu M. (2015). Keystroke biometric studies with short numeric input on mobile devices. *International Journal of Information Security*. — 14(3). — Pp. 289–297 (in Eng.).

Revett K., de Magalhães S.T. & de Oliveira L.C. (2008). A survey of user authentication using keystroke dynamics. *Journal of Computers*. — 3(5). — Pp. 52–59 (in Eng.).

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 1. Number 22 (2025). Pp. 154–173

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.010>

UDC: 004.032.26

NEURAL NETWORKS AS A TOOL FOR MATHEMATICAL COMPUTATION

A.S. Srazh¹, M. Nurtas^{1,2}, A.A. Altaibek¹, Z.T. Abdikalikova^{1}*

¹International Information Technology University, Almaty, Kazakhstan;

²Institute of Ionosphere, Almaty, Kazakhstan.

E-mail: z.abdikalikova@iitu.edu.kz

Srazh A. — PhD student, lecturer, «the Department of Mathematical and Computer Modelling», International Information Technology University, Almaty, Kazakhstan

E-mail: a.srazh@iitu.edu.kz, ORCID: 0009-0003-9682-0766;

Nurtas M. — PhD, associate professor, «the Department of Mathematical and Computer Modelling», International Information Technology University, Almaty, Kazakhstan

E-mail: m.nurtas@iitu.edu.kz, ORCID: 0000-0003-4351-0185;

Altaibek A. — PhD, associate professor, «the Department of Mathematical and Computer Modelling», International Information Technology University, Almaty, Kazakhstan

E-mail: a.altaibek@iitu.edu.kz, ORCID: 0000-0001-8431-7950;

Abdikalikova Z. — associate professor, «the Department of Mathematical and Computer Modelling», International Information Technology University, Almaty, Kazakhstan

E-mail: z.abdikalikova@iitu.edu.kz. ORCID: 0000-0003-0131-4469.

© A.S. Srazh, M. Nurtas, A.A. Altaibek, Z.T. Abdikalikova, 2025

Abstract. The application of neural networks has become nearly ubiquitous across a wide range of domains. However, researchers in fields less closely associated with mathematics often overlook the substantial mathematical foundations underpinning deep neural networks. This gap in understanding can lead to unforeseen challenges in the research process, as the core architecture of every neural network—regardless of complexity—is fundamentally grounded in mathematical principles, from basic expressions to advanced formulations. In this paper, we elucidate the mathematical structures that underpin neural network models and demonstrate how they inform and influence model behavior. By highlighting these mathematical aspects, we aim to bridge the knowledge gap for educators and domain experts, thereby enhancing interdisciplinary understanding and improving the effective application of neural networks.

Keywords: machine learning, microclimate management, HVAC optimization, fault detection, predictive maintenance, user preferences, energy efficiency

For citation: A.S. Srazh, M. Nurtas, A.A. Altaibek, Z.T. Abdikalikova. Neural networks as a tool for mathematical computation//International journal of



information and communication technologies. 2025. Vol. 6. No. 22. Pp. 154–173 (In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.010>.

Conflict of interest: The authors declare that there is no conflict of interest.

НЕЙРОНДЫҚ ЖЕЛІЛЕР МАТЕМАТИКАЛЫҚ ЕСЕПТЕУ ҚҰРАЛЫ РЕТІНДЕ

А.С. Сразж¹, М. Нұртас^{1,2}, А.А. Алтайбек¹, З.Т. Абдикаликова^{1}*

¹Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан;

²Ионосфера институты, Алматы, Қазақстан.

E-mail: z.abdikalikova@iitu.edu.kz

Сразж А. — PhD докторант, Халықаралық ақпараттық технологиялар университеті «Математикалық және компьютерлік модельдеу» кафедрасының лекторы, Алматы, Қазақстан

E-mail: a.srazh@iitu.edu.kz. ORCID: 0000-0003-0341-4017;

Нұртас М. — PhD, Халықаралық ақпараттық технологиялар университеті «Математикалық және компьютерлік модельдеу» кафедрасының қауымдастырылған профессоры, Алматы, Қазақстан

E-mail: m.nurtas@iitu.edu.kz. ORCID: 0000-0003-4351-0185;

Алтайбек А. — PhD, Халықаралық ақпараттық технологиялар университеті «Математикалық және компьютерлік модельдеу» кафедрасының қауымдастырылған профессоры, Алматы, Қазақстан

E-mail: a.altaibek@iitu.edu.kz. ORCID: 0000-0001-8431-7950;

Абдикаликова З. — PhD, Халықаралық ақпараттық технологиялар университеті «Математикалық және компьютерлік модельдеу» кафедрасының қауымдастырылған профессоры, Алматы, Қазақстан

E-mail: z.abdikalikova@iitu.edu.kz. ORCID: 0000-0003-0131-4469.

© А.С. Сразж, М. Нұртас, А.А. Алтайбек, З.Т. Абдикаликова, 2025

Аннотация. Қазіргі таңда нейрондық желілердің қолданысы дерлік барлық жерде кең етек жая бастады. Бірақ осы терең нейрондық желілердің артында үлкен математикалық база тұрғанын математикалан алыс саладағы көптеген зерттеушілер байқай бермейді. Осы кемшілік зерттеу барысында кейін кейбір ойламаған қиыншылықтарды туындатады. Себебі, әрбір жазылған нейрондық желі моделдерін негізгі тірегі қарапайым математикалық өрнектерден бастап, күрделі деңгейге дейін жетеді. Біз осы мақалада сол олқылықтарды аз да болса, толықтыру мақсатында жалпы оқытушы ұстаздарға, әр сала мамандарына осы математикалық аспектілердің қолданысын ашып, қалай қолданылатынын және нейрондық желі моделдерінде қандай маңызды рөл атқаратынын көрсетеміз.

Түйін сөздер: математикадағы нейрондық желілер, терең оқыту, активтендіру функциялары, шығын функциясы, құн функциясы, регрессия, классификация

Дәйексөздер үшін: Н.А. Дауренбаева, Л.Б. Атымтаева, Н.С. Луценко, А. Нұрланұлы. Гимараттардағы микроклиматты басқаруды оңтайландыру үшін машиналық оқытуды біріктіру: перспективалар мен мүмкіндіктер//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 154–173 бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.010>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

НЕЙРОННЫЕ СЕТИ КАК ИНСТРУМЕНТ МАТЕМАТИЧЕСКИХ ВЫЧИСЛЕНИЙ

А.С. Сраж¹, М. Нуртас^{1,2}, А.А. Алтайбек¹, З.Т. Абдикаликова^{1}*

¹Международный университет информационных технологий, Алматы, Казахстан;

²Институт ионосферы, Алматы, Казахстан.

E-mail: z.abdikalikova@iitu.edu.kz

Сраж А. — PhD-студент, преподаватель, «Кафедра математического и компьютерного моделирования», Международный университет информационных технологий, Алматы, Казахстан
E-mail: a.srazh@iitu.edu.kz. ORCID: 0009-0003-9682-0766;

Нуртас М. — PhD, ассоциированный профессор, «Кафедра математического и компьютерного моделирования», Международный университет информационных технологий, Алматы, Казахстан
E-mail: m.nurtas@iitu.edu.kz. ORCID: 0000-0003-4351-0185;

Алтайбек А. — PhD, ассоциированный профессор, «Кафедра математического и компьютерного моделирования», Международный университет информационных технологий, Алматы, Казахстан
E-mail: a.altaibek@iitu.edu.kz. ORCID: 0000-0001-8431-7950;

Абдикаликова З. — PhD, ассоциированный профессор, «Кафедра математического и компьютерного моделирования», Международный университет информационных технологий, Алматы, Казахстан
E-mail: z.abdikalikova@iitu.edu.kz. ORCID: 0000-0003-0131-4469.

© А.С. Сраж, М. Нуртас, А.А. Алтайбек, З.Т. Абдикаликова, 2025

Аннотация. В настоящее время нейронные сети активно применяются практически во всех сферах науки и практики. Однако специалисты в областях, не связанных напрямую с математикой, зачастую упускают из виду, что в основе современных глубоких нейронных сетей лежит значительный математический аппарат. Недостаток понимания этих основ порождает определённые трудности в исследовательской деятельности, особенно при разработке и интерпретации моделей. Следует отметить, что каждая модель нейронной сети, вне зависимости от уровня её сложности, базируется на математических конструкциях — от элементарных выражений до многоуровневых структур. В данной статье рассматриваются ключевые математические аспекты, лежащие в основе архитектуры нейронных сетей, а также раскрывается их значимость в контексте практического применения. Особое внимание уделяется популяризации математической базы среди преподавателей и специалистов различных предметных областей с целью частичного преодоления существующего междисциплинарного разрыва в понимании природы нейросетевых моделей.

Ключевые слова: нейронные сети в математике, глубокое обучение, функции активации, функция потерь, функция стоимости, регрессия, классификация

Для цитирования: А.С. Сраж, М. Нуртас, А.А. Алтайбек, З.Т. Абдикаликова. Нейронные сети как инструмент математических вычислений// Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 154–173. (На англ.). <https://doi.org/10.54309/>



IJICT.2025.22.2.010.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Artificial Intelligence (AI) has gone through several key stages of development. In the 1950s-1980s (Stage I) it was in the “warm-up” stage, then from the 1980s to 2010 (Stage II) there was a period of active research, and since 2010 the “golden era” of AI based on industrial data began. Today, AI outperforms humans in many areas (Huang, 2024: 2–3).

Although the concept of neural network is very popular today, it has a long history dating back to the first half of the 20th century. In the 1940s, W. McCulloch and W. Pitts discovered that an artificial neuron could be modeled as a simple threshold device that could compute any arithmetic or logical function (McCulloch, 1943: 115–117). In 1949, D. Hebb proposed the Hebb rule to describe how learning between two neurons affects synaptic connections (Hebb, 1949: 62–63).

An important stage in the formation of AI was the work of Alan Turing. In 1950, he proposed the Turing test, which evaluates whether a machine can demonstrate intelligent behavior indistinguishable from human behavior (Turing, 1950: 433–435). In 1956, John McCarthy defined artificial intelligence and organized the Dartmouth Conference, which was the starting point for the development of the field (McCarthy, 1956: 1–3).

In the late 1950s, Rosenblatt presented the perceptron model, which caused great interest in neural networks. However, as early as 1969, M. Minsky and S. Papert mathematically proved the limitations of the perceptron, which led to the first crisis in neural network research and a decline in interest in neural networks (Minsky, 1969: 4–11).

In the 1980s, with the development of new algorithms, including the error back propagation algorithm, and the advent of more powerful computers, interest in neural networks was renewed. During this period, important models such as the Hopfield network, Kohonen maps and Adaptive Resonance Theory (ART) were proposed (Grossberg, 1988: 37–40).

Since the 2010s, the development of artificial intelligence has accelerated due to the increase in computing power and data volumes. In 2016, the AlphaGo program created by DeepMind beat the world champion in the game of Go, which was a milestone in the development of machine learning (Silver, 2016: 484–485).

Today, neural networks are applied in various fields including medicine, finance, autonomous systems, and natural language processing. Modern models such as deep neural networks show outstanding results in image recognition, disease diagnosis, and intelligent systems development (LeCun, 2015: 436–438).

Materials and methods

Artificial intelligence (AI) is the field of computer science that enables

machines to perform cognitive tasks such as problem-solving, learning, and decision-making (Messerli, 2024: 50–52). One of the key approaches in AI is the development of artificial neural networks (ANNs), which are inspired by the structure and functionality of the biological neural network (BNN) found in the human brain (Thakur, 2021: 407–408).

The human brain contains about 10^{11} neurons that process information using electrical and chemical signals. Each neuron consists of a cell body (soma) that integrates incoming signals, dendrites that receive inputs, and an axon that transmits signals to other neurons. Communication occurs at synapses, where chemical neurotransmitters determine whether the next neuron will activate (Du, 2019: 4; Kandel, 2014: 65–66). Figure 1 illustrates the structural comparison between a biological neuron and an artificial neuron.




Fig.1. Structure of a Biological Neuron and an Artificial Neuron

In artificial neural networks, this process is modeled mathematically. Artificial neurons receive numerical inputs (), multiply them by specific weights (), sum them, and pass the result through an activation function (Goodfellow, 2016: 15–16; Nurtas, 2020: 29–30).

$$y = f \left(\sum_i w_i x_i + b_i \right) \quad (1)$$

where b_i is the bias term.

Weights and biases are the key parameters that determine how input data is transformed as it propagates through the network. Weights represent the strength of connections between neurons and define how much influence a given input has on the neuron's output. Biases, on the other hand, allow the activation of a neuron to shift up or down, enabling better flexibility in learning complex patterns. Parameters, including weights and biases, are optimized during training to minimize errors and enhance performance. The concept of weights and biases can be thought of as “knobs” that we adjust to optimize the model. As seen in Figure 2, increasing the weight increases the slope of the function; while decreasing it reduces the slope. Changing the bias shifts the function up or down, as illustrated in Figure 3.




Fig. 2. Graph of a Single-Input Neuron's Output with a Weight of 1, Bias of 0 and Input .




Fig. 3. Graph of a Single-Input Neuron's Output with a Weight of 1, Bias of 2 and Input .

A practical example of parameter calculation in a neural network is shown in Figure 4.




Fig. 4. Example of a Neural Network with 3 Hidden Layers

The network consists of five layers with sizes 4, 5, 7, 5, and 2. The total number of parameters in this multilayer neural network can be determined by considering the number of weights and biases between the layers. Given a network architecture where each layer has neurons, the number of parameters between two consecutive layers and is given by .

For the given network with architecture (4,5,7,5,2), the total number of parameters is

$$P = (4 \times 5 + 5) + (5 \times 7 + 7) + (7 \times 5 + 5) + (5 \times 2 + 2) = 119.$$

Thus, the total number of parameters in this neural network is 119.

In biological neurons, an activation threshold (around -55mV) determines whether a neuron fires a signal. Similarly, in ANNs, activation functions like Sigmoid, or ReLU decide whether an artificial neuron “activates” (Goodfellow, 2016: 175–176; Altaibek, 2025: 6–7).



The key difference is how information is processed. Biological neurons rely on electrochemical processes and adapt their connections through neuroplasticity, while artificial neurons use mathematical computations and adjust parameters through learning algorithms like backpropagation. However, in both cases, learning occurs by strengthening important connections and improving information processing over time (LeCun, 2015: 436–438).



In biologically inspired neural networks, the activation function serves as an abstraction of the cell’s action potential firing rate. In its simplest form, this function is binary, meaning the neuron is either active (firing) or inactive (not firing) (Keller, 2016: 9–12).

In general, an activation function is a mathematical transformation applied to a neuron’s input (typically a weighted sum of signals) to produce its output. By introducing nonlinearity, it enables the network to model complex relationships in data, thereby enhancing its ability to learn and detect intricate patterns (Haykin, 2009: 12–14). This transformation is key to converting input data into a neuron’s output signal, making the network flexible and capable of capturing complex nonlinear dependencies.

The table below summarizes the main activation functions, their mathematical expressions and corresponding graph (Soares, 2017: 5–6; Venkateswaran, 2017: 13–18):

Table 1. Types of Activation Functions

Function	Equation	Chart
Sigmoid		
Hyperbolic tangent		

Hard limiting threshold		
Rectified Linear Unit		

Results and Discussion

The choice of activation function depends on the specific task and model architecture.

Let us consider an example that uses a step function (Hard limiting threshold) as the activation function, as presented in Table 1. For illustration, we consider the XOR function in a practical context.

Example 1: In modern medicine, early diagnostic algorithms often rely on the combined use of biomarkers to assess both localized and systemic pathological processes. Consider a hypothetical scenario where two independent biomarkers are utilized to detect the early stage of an inflammatory process:

Indicator A: The level of C-reactive protein (CRP), a sensitive marker of inflammation.

Indicator B: The white blood cell (WBC) count, reflecting the immune response of the body.

Under normal conditions, both indicators fall within their respective reference ranges ($X_1 = 0$, $X_2 = 0$). However, during the early stages of localized inflammation, only one of these parameters might deviate from normal. The application of the XOR logical operation formalizes this case as follows:

Case 1: If the CRP level is elevated ($X_1 = 1$) while the WBC count remains normal ($X_2 = 0$), this suggests localized inflammation that may warrant targeted intervention.

Case 2: If the WBC count is elevated ($X_2 = 1$) while the CRP level remains normal ($X_1 = 0$), this also indicates localized inflammation, prompting early therapeutic action.

Case 3: If both indicators are abnormal ($X_1 = 1$, $X_2 = 1$), it may signify systemic inflammation or a severe infection. In such cases, the standard XOR-based early diagnosis algorithm is not applicable, necessitating a comprehensive diagnostic approach.

Case 4: If both indicators are within normal limits ($X1 = 0, X2 = 0$), no pathological process is detected, and specific therapy is not required.

The corresponding truth table for this example is as follows:

Table 2. Truth Table for Example 1

Indicator $X1$ (CRP)	Indicator $X2$ (WBC count)	Need for Early Diagnosis (XOR)
0	0	0
0	1	1
1	0	1
1	1	0

In Table 2 we can see that when both inputs are the same, the output is 0, and otherwise it is 1. Such dependencies cannot be modeled with a single neuron, so we will use a multi-layer network. The idea behind using multiple layers is that complex dependencies can be broken down into simpler functions and then combined.

Let us express the XOR function (*Note: here '+' means OR and '.' means AND*):

$$X1 \text{ XOR } X2 = (X1.\text{NOT}(X2)) + (\text{NOT}(X1).X2)$$

To realize XOR, we will use a two-layer neural network (see Figure 5):




Fig. 5. Architecture of XOR Function

The first hidden layer consists of 2 neurons:

The first neuron computes $\text{NOT}(X1).X2$

Second neuron calculates $X1.\text{NOT}(X2)$

Output layer consists of 1 neuron:

Performs an OR operation on the two outputs of the hidden layer.

In the first hidden layer, we compute $\text{NOT}(X1).X2$ and $X1.\text{NOT}(X2)$,

where

Input 1:

Input 2:

Second layer (OR calculation)

Output neuron:

Now we can implement it using simplified cases. First, let's design a neuron to model $X1.\text{NOT}(X2)$. This can be modeled as follows (as illustrated in Figure 6):




Fig.6. Neural Network Architecture for X1.NOT(X2)

The output of this neuron is:

$$a_1 = f(-0.5 + x_2 - x_1)$$

Table 3. Truth Table for X1.NOT(X2)

X1	X2	NOT(X1).X2	-0.5 + X2 - X1	a1
0	0	0	-0.5	0
0	1	1	0.5	1
1	0	0	-1.5	0
1	1	0	-0.5	0

In the first layer, we compute NOT(X1).X2 and X1.NOT(X2) separately. Then, in the second layer, we take their outputs and apply an OR function to them. This completes the neural network. The final structure of the network will look like this (see Figure 7):




Fig. 7. Neural Network Architecture for X1.XOR(X2)

Table 4. Truth Table for $X1.NOT(X2)$

X1	X2	a1	a2	a3
0	0	0	0	0
0	1	1	0	1
1	0	0	1	1
1	1	0	0	0

This example demonstrates how the XOR function can be applied in real-world diagnostic cases. By leveraging a neural network with a step activation function (Hard Limiting Threshold), we can formalize decision-making processes based on medical biomarkers. This approach helps distinguish localized inflammation from systemic conditions, allowing for more targeted and timely interventions.

The use of activation functions like the step function highlights the fundamental role they play in transforming input data into meaningful outputs within neural networks. While simple threshold-based functions provide a clear binary decision mechanism, more advanced activation functions may be required for handling complex, non-linear relationships in medical diagnostics and other fields.

Neural networks learn by adjusting weights and biases through forward and backward propagation. Forward propagation computes the output based on given inputs, while backward propagation calculates errors and updates weights accordingly. This process minimizes the difference between predicted and actual values using optimization techniques such as gradient descent. The fundamental goal is to iteratively adjust parameters to improve accuracy.

The training process of a neural network follows a systematic sequence of operations. The following steps outline the complete forward and backward propagation procedures.

Step 1. The neural network is supplied with an input matrix X , consisting of four features and three training samples, as well as a target output matrix y :

$$X = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 \end{bmatrix}$$

$$y = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$$

The weight matrices for the hidden layer (W_h) and output layer (W_{out}) are initialized with small random values. The bias terms (b_h and b_{out}) are similarly initialized:

$$W_h = \begin{bmatrix} 0.42 & 0.88 & 0.55 \\ 0.10 & 0.73 & 0.68 \\ 0.60 & 0.18 & 0.47 \\ 0.92 & 0.11 & 0.52 \end{bmatrix}$$

$$b_h = [0.46 \quad 0.72 \quad 0.08]$$

$$W_{out} = \begin{bmatrix} 0.30 \\ 0.25 \\ 0.23 \end{bmatrix}$$

$$b_{out} = [0.69]$$

Step 2. To solve this problem, we begin by representing the input in both mathematical and computational forms.

The input to the hidden layer is computed as follows:

Computational Form:

hidden_layer_input = matrix_dot_product(X, W_h) + b_h

Mathematical Form:

$$H_{in} = X \times W_h + b_h = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} 0.42 & 0.88 & 0.55 \\ 0.10 & 0.73 & 0.68 \\ 0.60 & 0.18 & 0.47 \\ 0.92 & 0.11 & 0.52 \end{bmatrix} + \begin{bmatrix} 0.46 & 0.72 & 0.08 \\ 0.46 & 0.72 & 0.08 \\ 0.46 & 0.72 & 0.08 \end{bmatrix}$$

Performing the matrix multiplication and addition yields:

First row computation:

$$H_{in_{1,1}} = (1 \times 0.42) + (0 \times 0.10) + (1 \times 0.60) + (0 \times 0.92) + 0.46 = 1.48$$

$$H_{in_{1,2}} = (1 \times 0.88) + (0 \times 0.73) + (1 \times 0.18) + (0 \times 0.11) + 0.72 = 1.78$$

$$H_{in_{1,3}} = (1 \times 0.55) + (0 \times 0.68) + (1 \times 0.47) + (0 \times 0.52) + 0.08 = 1.10$$

Second row computation:

$$H_{in_{2,1}} = (1 \times 0.42) + (0 \times 0.10) + (1 \times 0.60) + (1 \times 0.92) + 0.46 = 2.40$$

$$H_{in_{2,2}} = (1 \times 0.88) + (0 \times 0.73) + (1 \times 0.18) + (1 \times 0.11) + 0.72 = 1.89$$

$$H_{in_{2,3}} = (1 \times 0.55) + (0 \times 0.68) + (1 \times 0.47) + (1 \times 0.52) + 0.08 = 1.62$$

Third row computation:

$$H_{in_{1,3}} = (0 \times 0.42) + (1 \times 0.10) + (0 \times 0.60) + (1 \times 0.92) + 0.46 = 1.48$$

$$H_{in_{1,3}} = (0 \times 0.88) + (1 \times 0.73) + (0 \times 0.18) + (1 \times 0.11) + 0.72 = 1.56$$

$$H_{in_{1,3}} = (0 \times 0.55) + (1 \times 0.68) + (0 \times 0.47) + (1 \times 0.52) + 0.08 = 1.28$$

The input of the hidden layer is obtained as follows:

$$H_{in} = \begin{bmatrix} 1.48 & 1.78 & 1.10 \\ 2.40 & 1.89 & 1.62 \\ 1.48 & 1.56 & 1.28 \end{bmatrix}$$

Step 3. After computing the hidden layer input, an activation function is applied to introduce non-linearity into the model. This step is crucial for capturing complex patterns in the data. In this case, a sigmoid activation function is applied to the hidden layer input:

$$\text{hidden_layer_activations} = \text{sigmoid}(\text{hidden_layer_input})$$

or

$$H_{out} = \frac{1}{1 + e^{-H_{in}}}$$

For example, for the first element

$$H_{out_{1,1}} = 0.815:$$

$$H_{out_{1,1}} = \frac{1}{1 + e^{-1.48}} \approx 0.815$$

Applying this to all elements, the output of the hidden layer is obtained as follows:

$$H_{out} \approx \begin{bmatrix} 0.815 & 0.855 & 0.750 \\ 0.916 & 0.868 & 0.836 \\ 0.815 & 0.825 & 0.782 \end{bmatrix}$$

Step 4. The output layer input is calculated as:

$$\text{output_layer_input} = \text{matrix_dot_product}(\text{hidden_layer_activations} * W_{out-}) + b_{out}$$

or

$$O_{in} = H_{out} \times W_{out} + b_{out}$$

$$O_{in} \approx \begin{bmatrix} (0.815 \times 0.30) + (0.855 \times 0.25) + (0.750 \times 0.23) + 0.69 \\ (0.916 \times 0.30) + (0.868 \times 0.25) + (0.836 \times 0.23) + 0.69 \\ (0.815 \times 0.30) + (0.825 \times 0.25) + (0.782 \times 0.23) + 0.69 \end{bmatrix} \approx \begin{bmatrix} 1.321 \\ 1.3741 \\ 1.3206 \end{bmatrix}$$

Applying the sigmoid function to O_{in} :

output = sigmoid(output_layer_input)

or

$$O_{out} = \sigma(O_{in}) = \frac{1}{1 + e^{-O_{in}}}$$

$$O_{out} = \begin{bmatrix} \frac{1}{1 + e^{-1.321}} \\ \frac{1}{1 + e^{-1.3741}} \\ \frac{1}{1 + e^{-1.3206}} \end{bmatrix} \approx \begin{bmatrix} 0.789 \\ 0.798 \\ 0.789 \end{bmatrix}$$

Step 5. The error is determined by computing the difference between the predicted and target values:

$$E = y - O_{out}$$

$$E = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} - \begin{bmatrix} 0.789 \\ 0.798 \\ 0.789 \end{bmatrix} = \begin{bmatrix} 0.211 \\ 0.202 \\ -0.789 \end{bmatrix}$$

Step 6. The slope for the hidden and output layer neurons are computed as:

slope_output_layer = derivatives_sigmoid(output)

slope_hidden_layer = derivatives_sigmoid(hidden_layer_activations)

or

$$\sigma'(O_{out}) = O_{out} \times (1 - O_{out})$$

$$\sigma'(O_{in}) = H_{out} \times (1 - H_{out})$$

$$\sigma'(O_{out}) = \begin{bmatrix} 0.789 \times (1 - 0.789) \\ 0.798 \times (1 - 0.798) \\ 0.789 \times (1 - 0.789) \end{bmatrix} = \begin{bmatrix} 0.1665 \\ 0.1612 \\ 0.1665 \end{bmatrix}$$

$$\sigma'(O_{in}) = \begin{bmatrix} 0.815 \times (1 - 0.815) & 0.855 \times (1 - 0.855) & 0.750 \times (1 - 0.750) \\ 0.916 \times (1 - 0.916) & 0.868 \times (1 - 0.868) & 0.836 \times (1 - 0.836) \\ 0.815 \times (1 - 0.815) & 0.825 \times (1 - 0.825) & 0.782 \times (1 - 0.782) \end{bmatrix}$$

$$= \begin{bmatrix} 0.151 & 0.124 & 0.188 \\ 0.077 & 0.115 & 0.137 \\ 0.151 & 0.144 & 0.170 \end{bmatrix}$$

where $\sigma'(x) = x(1 - x)$ is the derivative of the sigmoid function.

Step 7. The delta at the output layer is computed using the formula:

$$d_output = E * slope_output_layer * learning_rate$$

or

$$\delta_{out} = E \times \sigma'(O_{out}) \times 1$$

This yields:

$$\delta_{out} = \begin{bmatrix} 0.211 \times 0.1665 \\ 0.202 \times 0.1612 \\ -0.789 \times 0.1665 \end{bmatrix} = \begin{bmatrix} 0.035 \\ 0.032 \\ -0.13 \end{bmatrix}$$

Step 8. The error at the hidden layer is computed as:

$$Error_at_hidden_layer = matrix_dot_product(d_output, W_out.Transpose)$$

or

$$E_{hidden} = \delta_{out} \times W_{out}^T$$

$$E_{hidden} = \begin{bmatrix} 0.035 \\ 0.032 \\ -0.13 \end{bmatrix} \times \begin{bmatrix} 0.30 & 0.25 & 0.23 \end{bmatrix} = \begin{bmatrix} 0.010 & 0.009 & 0.008 \\ 0.010 & 0.008 & 0.074 \\ -0.039 & -0.033 & -0.03 \end{bmatrix}$$

Step 9. In this step, the delta values for the hidden layer are determined using the element-wise product of the propagated error at the hidden layer and the derivative of the activation function. Mathematically, this relationship is expressed as follows:

$$d_hidden_layer = Error_at_hidden_layer * slope_hidden_layer$$

or

$$\delta_{hidden} = \begin{bmatrix} 0.010 \times 0.151 & 0.009 \times 0.124 & 0.008 \times 0.188 \\ 0.010 \times 0.077 & 0.008 \times 0.115 & 0.074 \times 0.137 \\ -0.039 \times 0.151 & -0.033 \times 0.144 & -0.03 \times 0.170 \end{bmatrix} = \begin{bmatrix} 0.002 & 0.001 & 0.002 \\ 0.001 & 0.001 & 0.001 \\ -0.006 & -0.005 & -0.005 \end{bmatrix}$$

Step 10. The output layer weights are updated using the gradient descent rule:

$$W_out = W_out + matrix_dot_product(hidden_layer_activations.Transpose, d_output) * learning_rate$$

$$W_h = W_h + matrix_dot_product(X.Transpose, d_hidden_layer) * learning_rate$$

or

$$W_{out} = W_{out} + \eta \times (H_{out}^T \cdot \delta_{out})$$

$$W_h = W_h + \eta \times (X^T \times \delta_{hidden})$$

where η is learning rate. Using $\eta = 0.1$, the updated output weights become:

$$W_{out} = \begin{bmatrix} 0.30 \\ 0.25 \\ 0.23 \end{bmatrix} + 0.1 \times \begin{bmatrix} 0.815 & 0.855 & 0.750 \\ 0.916 & 0.868 & 0.836 \\ 0.815 & 0.825 & 0.782 \end{bmatrix}^T \times \begin{bmatrix} 0.035 \\ 0.032 \\ -0.13 \end{bmatrix} \approx \begin{bmatrix} 0.295 \\ 0.245 \\ 0.225 \end{bmatrix}$$

$$W_h = \begin{bmatrix} 0.42 & 0.88 & 0.55 \\ 0.10 & 0.73 & 0.68 \\ 0.60 & 0.18 & 0.47 \\ 0.92 & 0.11 & 0.52 \end{bmatrix} + 0.1 \times \begin{bmatrix} 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 \end{bmatrix}^T \times \begin{bmatrix} 0.002 & 0.001 & 0.002 \\ 0.001 & 0.001 & 0.001 \\ -0.006 & -0.005 & -0.005 \end{bmatrix}$$

$$\approx \begin{bmatrix} 0.42 & 0.88 & 0.55 \\ 0.10 & 0.73 & 0.68 \\ 0.60 & 0.18 & 0.47 \\ 0.92 & 0.11 & 0.52 \end{bmatrix}$$

Step 11. In this step, the biases associated with the hidden and output layers are updated using the computed deltas from the previous steps. The update rule follows the principle of gradient descent, where adjustments are made in the direction that minimizes the error function. The mathematical expressions for updating the biases are given by:

$$b_h = b_h + \text{sum}(d_hidden_layer, \text{axis} = 0) * \text{learning_rate}$$

$$b_out = b_out + \text{sum}(d_output, \text{axis} = 0) * \text{learning_rate}$$

or

$$b_h = b_h + \eta \times \sum_{j=0}^N \delta_{hidden_j}$$

$$b_{out} = b_{out} + \eta \times \sum_{j=0}^N \delta_{output_j}$$

Using $\eta = 0.1$, the updated output biases become:

$$b_h = [0.46 \quad 0.72 \quad 0.08] + 0.1 \times [0.002 + 0.001 - 0.006 \quad 0.001 + 0.001 - 0.005 \quad 0.002 + 0.001 - 0.005]$$

$$= [0.46 \quad 0.72 \quad 0.08] + 0.1 \times [-0.003 \quad -0.003 \quad -0.002]$$

$$= [0.4597 \quad 0.7197 \quad 0.0798]$$

$$b_{out} = [0.69] + 0.1 \times [0.035 + 0.032 - 0.13] = 0.6837$$

To validate the theoretical computations discussed above, we implement a Python-based simulation of a simple neural network. The following code executes forward propagation, backpropagation, and weight updates for a neural network with one hidden layer. It utilizes the sigmoid activation function and trains the model using gradient descent.

Python Implemaentation

```

import numpy as np
import matplotlib.pyplot as plt
def sigmoid(x):
    return 1 / (1 + np.exp(-x))
def sigmoid_derivative(x):
    return x * (1 - x)

#input features (3 samples, 4 features)
X = np.array([[1, 0, 1, 0],
              [1, 0, 1, 1],
              [0, 1, 0, 1]])

#target Labels
y = np.array([[1], [1], [0]])

#initialize weights and biases
np.random.seed(42) # Ensures reproducibility
W_h = np.random.rand(4, 3)
b_h = np.random.rand(1, 3)
W_out = np.random.rand(3, 1)
b_out = np.random.rand(1, 1)

#training parameters
epochs = 10000
learning_rate = 0.1
loss_history = [] # Stores Loss at each iteration

#training Loop
for epoch in range(epochs):
    #forward propagation
    H_in = np.dot(X, W_h) + b_h
    H_out = sigmoid(H_in)

    O_in = np.dot(H_out, W_out) + b_out
    O_out = sigmoid(O_in)

    #computing MSE
    error = y - O_out
    loss = np.mean(np.square(error))
    loss_history.append(loss) # Store Loss for visualization

    #backpropagation
    delta_out = error * sigmoid_derivative(O_out)
    W_out += learning_rate * np.dot(H_out.T, delta_out)
    b_out += learning_rate * np.sum(delta_out, axis=0, keepdims=True)

#final trained output
print("\nFinal Predicted Output After Training:\n", O_out)

#visualization of Loss reduction
plt.figure(figsize=(10, 5))
plt.plot(loss_history, label='Loss Reduction Over Iterations', color='blue')
plt.xlabel('Epochs')
plt.ylabel('Mean Squared Error (Loss)')
plt.title('Training Loss Over Time')
plt.legend()
plt.grid()
plt.show()

```

```

import numpy as np
import matplotlib.pyplot as plt
def sigmoid(x):
    return 1 / (1 + np.exp(-x))
def sigmoid_derivative(x):
    return x * (1 - x)

#input features (3 samples, 4 features)
X = np.array([[1, 0, 1, 0],
              [1, 0, 1, 1],
              [0, 1, 0, 1]])

#target Labels
y = np.array([[1], [1], [0]])

#initialize weights and biases
np.random.seed(42) # Ensures reproducibility
W_h = np.random.rand(4, 3)
b_h = np.random.rand(1, 3)
W_out = np.random.rand(3, 1)
b_out = np.random.rand(1, 1)

#training parameters
epochs = 10000
learning_rate = 0.1
loss_history = [] # Stores Loss at each iteration

#training Loop
for epoch in range(epochs):
    #forward propagation
    H_in = np.dot(X, W_h) + b_h
    H_out = sigmoid(H_in)

    O_in = np.dot(H_out, W_out) + b_out
    O_out = sigmoid(O_in)

    #computing MSE
    error = y - O_out
    loss = np.mean(np.square(error))
    loss_history.append(loss) # Store Loss for visualization

    #backpropagation
    delta_out = error * sigmoid_derivative(O_out)
    W_out += learning_rate * np.dot(H_out.T, delta_out)
    b_out += learning_rate * np.sum(delta_out, axis=0, keepdims=True)

#final trained output
print("\nFinal Predicted Output After Training:\n", O_out)

#visualization of Loss reduction
plt.figure(figsize=(10, 5))
plt.plot(loss_history, label='Loss Reduction Over Iterations', color='blue')
plt.xlabel('Epochs')
plt.ylabel('Mean Squared Error (Loss)')
plt.title('Training Loss Over Time')
plt.legend()
plt.grid()
plt.show()

```

After training for 10,000 epochs, the neural network achieved the following predicted outputs:

$$O_{out} = \begin{bmatrix} 0.9803 \\ 0.9684 \\ 0.0453 \end{bmatrix}$$

These values are close to the actual target values:

$$y = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$$

indicating that the neural network successfully learned the patterns in the data.

The plot below (see Figure 8) shows how the Mean Squared Error (MSE) loss decreases over time as the neural network learns.

At the beginning of training, the loss is high, meaning the network's predictions are far from the actual values. As the training progresses, the loss gradually decreases, showing that the model is improving. After a certain number of epochs, the loss becomes stable, indicating that the network has learned the patterns in the data and is no longer making significant improvements. Some small errors remain, which could be reduced by using more training data or fine-tuning the model's settings.




Fig. 8. Training Loss Reduction

In this section, we systematically derived and computed the backpropagation process for a neural network, focusing on error calculation, weight updates, and bias adjustments. Each computational step, from determining the error at the hidden layer to updating weights and biases, was illustrated with mathematical formulations and numerical computations. The results demonstrate how the backpropagation algorithm efficiently propagates error signals and adjusts model parameters, enabling the network to learn from data. These insights provide a clear understanding of how neural networks refine their internal representations to improve accuracy and performance.

Conclusion

In this study, we explored the mathematical foundations and computational implementation of neural networks as a tool for mathematical computation. We systematically derived the forward and backward propagation processes, illustrating each step with detailed mathematical formulations and numerical computations. Furthermore, a Python-based simulation was presented to validate the theoretical calculations, demonstrating how neural networks learn through iterative weight and bias updates.

The results indicate that the neural network successfully approximated the target values, with the predicted outputs converging close to the expected results. The decreasing loss function over multiple training iterations confirms that the model effectively minimizes error through gradient descent. This highlights the efficiency of backpropagation in optimizing network parameters and improving predictive accuracy.

This research demonstrates the practical application of neural networks in

solving mathematical problems and highlights their ability to generalize patterns from data. The study contributes to a deeper understanding of artificial neural networks by linking theoretical concepts with hands-on implementation.

REFERENCES

- Altaibek A., Zhumabayev B., Sarsembayeva A., Nurtas M. & Zakir D. (2025). Enhancing geomagnetic disturbance predictions with neural networks: A case study on K-index classification — *Atmosphere*. — 16(3). — P. 267. (DOI: 10.3390/atmos16030267).
- Du K.-L. & Swamy M.N.S. (2019). *Neural Networks and Statistical Learning*. 2nd ed. Upper Saddle River. — NJ: Prentice Hall. — P. 996 (Doi:10.1007/978-1-4471-7452-3).
- Goodfellow I., Bengio Y. & Courville A. (2016). *Deep Learning*. — Cambridge. — MA: MIT Press. — P.775
- Grossberg S. (1988). “Nonlinear neural networks: Principles, mechanisms, and architectures”. — *Neural Networks*. — 1988. — 1 (1). — Pp. 17–61. doi: 10.1016/0893-6080(88)90021-4.
- Haykin S. (2009). *Neural Networks and Learning Machines*. — 3rd ed. Upper Saddle River. — NJ. — USA: Pearson Education. — P. 938.
- Hebb D.O. (1949). *The organization of behavior*. — New York: Wiley. — P. 364.
- Huang G.-B., Westover M.B., Tan E.-K., Wang H., Cui D., Ma W.-Y., Wang T., He Q., Wei H., Wang N., Tian Q., Lam K.-Y., Yao X., Wong T.Y. (2024). Artificial Intelligence without Restriction Surpassing Human Intelligence with Probability One: Theoretical Insight into Secrets of the Brain with AI Twins of the Brain. — *Neurocomputing*. — 619. — P. 129053. (DOI:10.1016/j.neucom.2024.129053).
- Kandel E.R. et al. (2014). *Principles of Neural Science*. — 5th ed. New York — NY, USA: McGraw-Hill Education. — P.1760 (<https://accessbiomedicalsscience.mhmedical.com/content.aspx?bookid=1049§ionid=59138139>).
- Keller J.M., Liu D. & Fogel D.B. (2016). *Fundamentals of Computational Intelligence: Neural Networks, Fuzzy Systems, and Evolutionary Computation*. — Hoboken. — NJ, USA: Wiley. — P. 392.
- LeCun Y., Bengio Y. & Hinton G. (2015). Deep learning. — *Nature*. — 521(7553). — Pp. 436–444. (DOI: 10.1038/nature14539).
- Messeri L. & Crockett M.J. (2024). Artificial intelligence and illusions of understanding in scientific research. — *Nature*. — 627(8002). — Pp. 49–58.
- Minsky M. & Papert S. (1969). *Perceptrons: An Introduction to Computational Geometry*. — Cambridge. — MA: MIT Press — p. 316 (<https://rodsmith.nz/wp-content/uploads/Minsky-and-Papert-Perceptrons.pdf>).
- McCarthy J., Minsky M.L., Rochester N. & Shannon C.E. (1956). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. — 1956. — P.17 (<http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>).
- McCulloch W.S. & Pitts W. (1943). A logical calculus of the ideas immanent in nervous activity. — *Bulletin of Mathematical Biology*. — 5. — Pp. 115–133. (PII: S0092-8240(05)80006-0).
- Nurtas M., Baishemirov Z., Tsay V., Tastanov M. & Zhanabekov Z. (2020). Applying neural network for predicting cardiovascular disease risk. — *Известия НАН РК. Серия физико-математическая*. — 4. — Pp. 28–34. (DOI: 10.32014/2020.2518-1726.62).
- Silver D., Huang A., Maddison C.J. et al. (2016). Mastering the game of Go with deep neural networks and tree search. — *Nature*. — 529(7587). — Pp. 484–489. (DOI: 10.1038/nature16961).
- Soares F. M. & Souza A. M. F. (2016). *Neural Network Programming with Java*. — 2nd ed. Birmingham — UK: Packt Publishing. — P. 244.
- Thakur A. & Konde A. (2021). “Fundamentals of Neural Networks”. — *International Journal for Research in Applied Science & Engineering Technology*. — 2021. — 9(8). — Pp. 407–426. doi: 10.22214/ijraset.2021.37362.
- Turing A. M. (1950). Computing Machinery and Intelligence. — *Mind*, LIX(236) — pp. 433–460. (<https://doi.org/10.1093/mind/LIX.236.433>).
- Venkateswaran B. & Ciaburro G. (2017). *Neural Networks with R: Build Smart Systems by Implementing Popular Deep Learning Models in R*. — 1st ed. Birmingham. — UK: Packt Publishing. — P. 270.



INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 1. Number 22 (2025). Pp. 174–185

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.011>

УДК 004.89:336.717

GRAPH NEURAL NETWORKS FOR FRAUD DETECTION: COMPARATIVE ANALYSIS OF METHODS

A.M. Temirkhan, G.N. Pachshenko*

International Information Technology University, Almaty, Kazakhstan.

E-mail: asselttemirkhan1@gmail.com

Temirkhan A. — Master's student, International Information Technology University, Almaty, Kazakhstan

E-mail: asselttemirkhan1@gmail.com, <https://orcid.org/0009-0009-9176-4586>;

Pachshenko G. — Candidate of Technical Sciences, associate professor, «the Department of Information Systems», International Information Technology University, Almaty, Kazakhstan

E-mail: galina_pashenko@mail.ru, <https://orcid.org/0000-0001-8818-2934>.

© A.M. Temirkhan, G.N. Pachshenko, 2025

Abstract. The article discusses the application of graph neural networks (GNN) to detect fraudulent transactions in the banking system and their applicability to improve accuracy and reduce false positives in security monitoring systems. Current methods of analyzing financial data show poor performance in processing large amounts of information, making it difficult to detect anomalous and fraudulent transactions. During the study, several models were analyzed, among which the LGM-GNN architecture showed the best results in terms of accuracy and completeness. The results obtained confirm the promising use of GNNs for solving fraud detection problems and open opportunities for their implementation in real financial monitoring systems. Recommendations for algorithm improvement and directions for further research are formulated.

Keywords: graph neural networks, fraud, banking system, anomaly detection, machine learning, data security, transaction analysis

For citation: A.M. Temirkhan, G.N. Pachshenko. Graph neural networks for fraud detection: comparative analysis of methods//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 174-185 (In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.011>.

Conflict of interest: The authors declare that there is no conflict of interest.

**БАНКТЫҚ АЛАЯҚТЫҚТЫ АНЫҚТАУДАҒЫ ГРАФТЫҚ
НЕЙРОНДЫҚ ЖЕЛІЛЕР: ӘДІСТЕРДІ САЛЫСТЫРМАЛЫ ТАЛДАУ**

А.М. Темірхан, Г.Н. Пащенко*

Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан.

E-mail: asseltemirkhan1@gmail.com

Темірхан А. — магистратура студенті, Халықаралық Ақпараттық Технологиялар Университеті, Алматы, ҚазақстанE-mail: asseltemirkhan1@gmail.com, <https://orcid.org/0009-0009-9176-4586>;**Пащенко Г.** — техника ғылымдарының кандидаты, Халықаралық ақпараттық технологиялар университеті «Ақпараттық жүйелер» кафедрасының қауымдастырылған профессоры, Алматы, Қазақстан
E-mail: galina_pashenko@mail.ru, <https://orcid.org/0000-0001-8818-2934>.

© А.М. Темірхан, Г.Н. Пащенко, 2025

Аннотация. Мақалада банк жүйесіндегі алаяқтық транзакцияларды анықтау үшін графтық нейрондық желілерді (GNN) қолдану мәселесі қарастырылып, олардың қауіпсіздік мониторингі жүйелеріндегі дәлдікті арттыру мен жалған оң нәтижелер санын азайтуға ықпал ету мүмкіндігі талданады. Қаржылық деректерді талдаудың қазіргі әдістері ақпараттың үлкен көлемін өңдеу кезінде төмен тиімділік көрсетіп, аномальді және алаяқтық операцияларды анықтауды қиындатады. Зерттеу барысында бірнеше модельге талдау жүргізіліп, олардың ішінде дәлдік пен толықтық бойынша ең жақсы нәтижені LGM-GNN архитектурасы көрсетті. Алынған нәтижелер GNN-ді алаяқтықты анықтау міндеттерінде қолданудың болашағы зор екенін дәлелдейді және оларды нақты қаржылық мониторинг жүйелеріне енгізуге жол ашады. Алгоритмдерді жетілдіру және болашақ зерттеулердің бағыттары бойынша ұсыныстар жасалды.

Түйін сөздер: графтық нейрондық желілер, алаяқтық, банк жүйесі, аномалияларды анықтау, машиналық оқыту, деректер қауіпсіздігі, транзакцияларды талдау

Дәйексөздер үшін: А.М. Темірхан, Г.Н. Пащенко. Банктық алаяқтықты анықтаудағы графтық нейрондық желілер: әдістерді салыстырмалы талдау// Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 174–185 бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.011>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

ГРАФОВЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ ОБНАРУЖЕНИЯ МОШЕННИЧЕСТВА: СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ

А.М. Темирхан, Г.Н. Пащенко*Международный университет информационных технологий, Алматы,
Казахстан.

E-mail: asseltemirkhan1@gmail.com



Темирхан А. — магистрант, Международный университет информационных технологий, Алматы, Казахстан

E-mail: asseltemirkhan1@gmail.com, <https://orcid.org/0009-0009-9176-4586>;

Пашенко Г. — кандидат технических наук, ассоциированный профессор «Кафедры информационных систем», Международный университет информационных технологий, Алматы, Казахстан

E-mail: galina_pashenko@mail.ru, <https://orcid.org/0000-0001-8818-2934>.

© А.М. Темирхан, Г.Н. Пашенко, 2025

Аннотация. В статье рассматривается применение графовых нейронных сетей (GNN) для выявления мошеннических транзакций в банковской системе и их применимость для повышения точности и снижения уровня ложных срабатываний в системах мониторинга безопасности. Современные методы анализа финансовых данных демонстрируют низкую эффективность при обработке больших объемов информации, что затрудняет обнаружение аномальных и мошеннических операций. В ходе исследования были проанализированы несколько моделей, среди которых наилучшие результаты по точности и полноте показала архитектура LGM-GNN. Полученные результаты подтверждают перспективность использования GNN для решения задач обнаружения мошенничества и открывают возможности для их внедрения в реальные системы финансового мониторинга. Сформулированы рекомендации по улучшению алгоритмов и направления для дальнейших исследований.

Ключевые слова: графовые нейронные сети, мошенничество, банковская система, обнаружение аномалий, машинное обучение, безопасность данных, анализ транзакций

Для цитирования: А.М. Темирхан, Г.Н. Пашенко. Графовые нейронные сети для обнаружения мошенничества: сравнительный анализ методов//Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 174–185. (На англ.). <https://doi.org/10.54309/IJICT.2025.22.2.011>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Fraud detection in banking transactions is a complex task requiring highly accurate and computationally efficient analytical methods. Traditional rule-based and machine learning approaches often fail to detect sophisticated fraud patterns, especially given the evolving nature of fraud schemes and increasing transaction volumes. Graph Neural Networks (GNNs) have recently gained traction, demonstrating high effectiveness in anomaly and fraud detection. However, the comparative efficiency of different GNN architectures remains an open question, necessitating further analysis and evaluation.

The relevance of this study lies in the need to improve fraud detection accu-

racy while minimizing false positives, which is critical for the banking system. Recent research introduces various GNN modifications, including heterogeneous graph models, temporal graph networks, and adaptive aggregation methods. However, there is a lack of comprehensive analysis comparing these approaches on a unified dataset with consistent metrics, hindering their practical application in banking. Most studies focus on proposing new models without detailed performance comparisons.

The novelty of the study is to conduct a comparative analysis of modern GNN methods for detecting fraud in the banking system. As part of this study, advanced graph models, including adaptive, spatiotemporal, and heterogeneous GNNs, were reviewed and tested to identify their strengths and weaknesses, as well as determine optimal configurations for detecting fraudulent transactions.

The object of the study is fraud detection processes in bank transactions using graph neural networks.

The subject of the research is modern GNN architectures used to detect fraudulent transactions.

The purpose of the study is to conduct a comparative analysis of various GNN methods, evaluate their accuracy and computational efficiency on the open dataset Credit Card Fraud Detection (Kaggle) and identify the most promising approaches.

Research objectives are to:

- Review modern GNN models used for fraud detection.
- Implement and test multiple GNN architectures on a single dataset.
- Evaluate the accuracy, completeness, and computational complexity of the proposed models.
- Conduct a comparative analysis and identify the most effective method.

The significance of the research lies in its practical and scientific significance. The results obtained can be used by banks and financial organizations to improve the effectiveness of fraud detection systems, as well as in further research on the development of machine learning methods in the field of financial cybersecurity.

Literature Review

Recent research in the field of fraud detection in banking transactions demonstrates a growing interest in methods based on Graph Neural Networks (GNN), which allow modeling complex relationships between transactions and more effectively identifying anomalous patterns. One of the key research directions is the adaptive graph neural network architecture designed to enhance fraud detection accuracy. ASA-GNN is a model that utilizes adaptive sampling and aggregation mechanisms, allowing for the consideration of the dynamic nature of fraudulent schemes (Tian et al., 2023).

Another significant contribution was made by Liu et al., who developed a GNN-based approach for credit card fraud detection by applying spatiotemporal relationships between transactions (Liu et al., 2021). A similar approach was also used in the study of Tian and Liu, where a graph transformer was proposed with the ability

to consider temporal dependencies in transaction data analysis (Tian & Liu, 2024).

Heterogeneous graph neural networks have also gained widespread adoption in this domain. The FIW-GNN model was designed using heterogeneous graph representations for credit card fraud detection (Yan, Gao & Matsypura, 2023). Similar principles were incorporated in the work of Fan et al., where a structure-oriented attention mechanism was used to detect anomalies in complex transaction graphs (Fan, Liu & Li, 2023).

A promising direction is the combination of graph neural networks with federated learning methods. The FedGAT-DCNN architecture was introduced, combining graph networks with dilated convolutional neural networks to enable efficient fraud detection in distributed systems (Li & Walsh, 2024). A similar approach was explored by Tang and Liang, who integrated federated learning technology into a graph environment, reducing the risk of data leakage during model training (Tang & Liang, 2024).

Graph-based methods are also being applied in the broader cybersecurity context. Research has explored the potential of graph-based approaches in anomaly detection in information security, highlighting their effectiveness in fraud detection tasks (Sozol, Saki & Rahman, 2024). Another study applied graph neural networks for detecting money laundering schemes, confirming the versatility of these methods (Dumitrescu, Băltoiu & Budulan, 2022).

Hybrid approaches combining GNNs with autoencoders have shown additional effectiveness in fraud detection. A model integrating graph neural networks with autoencoders was developed to provide real-time predictability of fraudulent transactions (Alarfaj & Shahzadi, 2024). A similar study presented a heterogeneous graph autoencoder designed for fraud detection in credit operations (Singh et al., 2024).

Despite significant progress, several unresolved issues remain. Research indicates that using graph neural networks for fraud detection tasks requires additional mechanisms to address data imbalance (Jing et al., 2021). An extensive review of existing GNN models highlighted the need for further improvements in processing heterogeneous transactional data (Zhou et al., 2020: 57-81). A model incorporating spatiotemporal attention was proposed to account for the evolution of fraudulent schemes, though it was noted that tuning the parameters of such an architecture remains challenging (Cheng et al., 2020).

Another important research direction is the development of models resilient to fraud masking techniques. A method called Pick and Choose was introduced to address the class imbalance problem in training GNN models (Liu et al., 2021). Additionally, an inductive graph representation method for fraud detection was proposed, enabling the processing of previously unseen transactions (Van Belle et al., 2022).

Some studies focus on alternative neural network approaches. A stacked auto-encoder model was developed for predicting credit card defaults, opening possibilities for applying deep recurrent networks in this field (Ebiaredoh-Mienye, Esenogho

& Swart, 2021). Another study examined fraud masking techniques and proposed approaches to enhance the robustness of GNN models against such attacks (Dou et al., 2020).

Issues related to local and global adaptation of GNNs for fraud detection tasks were addressed in research proposing the LGM-GNN architecture, which considers the memory of local and global transaction dependencies (Li et al., 2023). A comprehensive review systematized the main approaches to anomaly detection in graphs, emphasizing the importance of considering the evolution of fraudulent schemes and the necessity of adaptive models (Pourhabibi et al., 2020).

Materials and methods

The study is based on the publicly available Credit Card Fraud Detection dataset, which contains a total of 284,807 transactions, out of which 492 are labeled as fraudulent. This dataset has been widely used in research on financial fraud detection due to its imbalanced nature, reflecting real-world fraud occurrence rates. The dataset consists of 30 features, including:

- Time: The number of seconds elapsed between a given transaction and the first transaction in the dataset;
- Class: binary tag (0 – legitimate transaction, 1 – fraudulent);
- Amount: The transaction amount, which may be used for feature scaling but does not reveal direct patterns distinguishing fraudulent and non-fraudulent transactions;
- V_1-V_{28} : These features result from a Principal Component Analysis (PCA) transformation applied to the original financial transaction data to protect sensitive information. Since these components are anonymized, domain-specific feature engineering is not possible on them.

Mathematically, the dataset can be represented as:

$$D = \{(X_i, y_i)\}_{i=1}^N \quad (1)$$

where X_i is the feature vector for the i -th transaction, and $y_i \in \{0,1\}$ is the corresponding label (0 for legitimate transactions, 1 for fraudulent transactions).

To model the interactions between transactions, a graph-based approach was employed, transforming the transactional dataset into a graph structure where nodes represent individual transactions or accounts, and edges define relationships between them. The graph representation was motivated by the observation that fraudulent transactions often exhibit structural patterns that can be effectively captured by graph neural networks. Formally, transactional data can be represented as a weighted directed graph $G = (V, E)$, where

- V represents the set of nodes;
- E represents the set of edges describing the links between nodes in the form of transaction;

- $X \in \mathbb{R}^{n \times d}$ is a matrix of node features containing quantitative characteristics of transactions;
- $Y \in \{0,1\}^n$ is a target variable indicating the transaction status (normal or fraudulent)

A sparse adjacency matrix A is used to represent the relationships between nodes, where element $a_{ij}=1$ if there is a transaction between users i and j , and 0 otherwise.

To perform fraud detection on the constructed graph, we utilize multiple Graph Neural Network (GNN) architectures, each designed to exploit different structural and relational properties. The models considered in this study include:

1) ASA-GNN: This model adaptively selects neighboring nodes and aggregates their features, which allows us to consider the varying degrees of importance of connections in the graph.

The weights of neighboring nodes are calculated using the formula:

$$h_v^{(k)} = \sigma(W^{(k)} \sum_{u \in N(v)} \alpha_{vu} h_u^{(k-1)}) \quad (2)$$

where α_{vu} is the coefficient of attention reflecting the importance of node u for node v .

2) FIW-GNN: This method uses heterogeneous graphs in which transaction information is considered in the form of various types of edges.

Transaction weights are formed based on the amount of payments and the frequency of transactions:

$$h_v^{(k)} = \sigma\left(\sum_{u \in N(v)} w_{vu} W^{(k)} h_u^{(k-1)}\right) \quad (3)$$

where w_{vu} is the weight of the connection between nodes, reflecting the amount and frequency of transactions.

3) FedGAT-DCNN: This approach combines federated learning with graph convolutional networks (GAT) and extended convolution (DCNN), which allows distributed data processing.

The basic mechanism of attention is described by the equation:

$$h_v^{(k)} = \sigma\left(\sum_{u \in N(v)} \alpha_{vu} W^{(k)} h_u^{(k-1)}\right) \quad (4)$$

where α_{vu} is calculated as:

$$\alpha_{vu} = \frac{\exp(\text{LeakyReLU}(a^T [Wh_u || Wh_u]))}{\sum_{k \in N(v)} \exp(\text{LeakyReLU}(a^T [Wh_u || Wh_u]))} \quad (5)$$

4) LGM-GNN: Unlike the previous methods, the memory of local and global node representations is used.

The final formula for updating hidden states:

$$h_v^{(k)} = \sigma(W_L h_v^{(k-1)} + W_G \sum_{u \in N(v)} \frac{\alpha_{vu} h_u^{(k-1)}}{|N(v)|}) \quad (6)$$

where W_L and W_G - weight matrices for local and global node memory.

Training graph neural network (GRNN) models to detect fraudulent transactions is a sequential process that includes data preprocessing, parameter initialization, loss function optimization, and validation of results.

At the forward pass stage, each node updates its representation based on information from its neighbors. The update formulas vary depending on the architecture. The Binary Cross-Entropy (BCE) Loss function is used as a baseline loss function for training:

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N (y_i \log \hat{y}_i + (1 + y_i) \log(1 - \hat{y}_i)) \quad (7)$$

where y_i is the true transaction label, $\hat{y}_i$ is the predicted probability of fraud.

A crucial step in this process is addressing the inherent class imbalance in the dataset, as fraudulent transactions constitute only 0.17 % of all transactions. To illustrate the extent of this imbalance, Figure 1 presents a three-dimensional scatter plot visualizing the dataset distribution based on transaction amount, time elapsed, and fraud labels.

As evident in Figure 1, fraudulent transactions (highlighted in yellow) are significantly underrepresented compared to legitimate transactions (purple). To mitigate this issue, the Focal Loss function is employed, which enhances the contribution of hard-to-classify fraudulent transactions while reducing the impact of correctly classified legitimate cases. The function is defined as follows:




Fig.1. 3D Distribution of Fraudulent Transactions Dataset.

$$\mathcal{L}_{FL} = - \sum_{i=1}^N (\alpha(1 - \hat{y}_i)^\gamma y_i) \log \hat{y}_i \quad (8)$$

where α is the balancing factor, and γ is the focusing parameter.

Model parameters are updated using gradient-based optimization with back-propagation:

$$\theta \leftarrow \theta - \eta \nabla_{\theta} \mathcal{L} \quad (9)$$

where η is the learning rate, and $\nabla_{\theta} \mathcal{L}$ is the gradient of the loss function with respect to the model parameters.

By integrating graph-based learning with advanced loss functions, the proposed approach enhances fraud detection performance while mitigating the adverse effects of class imbalance.

Results and discussion

In a comparison study of four graph neural networks (GRNN) for fraud detection in bank transactions, each model was trained and tested on a split of the Credit Card Fraud Detection dataset. The main results of the model evaluation are presented in Table 1. The evaluation metrics include accuracy, precision, recall, F1-score.

Table 1 - Comparison of Models by Key Performance Metrics

Model	Accuracy	Precision	Recall	F1-score
ASA-GNN	0.943	0.918	0.925	0.921
FIW-GNN	0.951	0.927	0.944	0.935
FedGAT-DCNN	0.938	0.899	0.915	0.908
LGM-GNN	0.96	0.935	0.95	0.942

From the results, the LGM-GNN model demonstrated superior performance across all metrics, achieving the highest accuracy (96.0 %) and F1-score (0.942). The high recall (0.950) indicates that the model effectively identifies fraudulent transactions, reducing the risk of undetected fraud cases. Comparatively, FedGAT-DCNN had the lowest performance across all metrics, suggesting that its architecture might not be optimally suited for learning fraud patterns.

The FIW-GNN model also exhibited strong fraud detection capabilities, with an F1-score of 0.935, highlighting its ability to maintain a balance between precision and recall. ASA-GNN, while performing well, had slightly lower recall than FIW-GNN and LGM-GNN, which could result in missed fraudulent cases.

To further evaluate the models' ability to distinguish fraudulent and non-fraudulent transactions, the ROC curves for each architecture were plotted (Figure 2). The area under the ROC curve (AUC) serves as a key metric, quantifying the overall classification capability of the models.




Fig.2. ROC Curves of Models

As shown in Figure 2, the LGM-GNN model achieved the highest AUC (0.958), confirming its superior discriminatory power in fraud detection. FIW-GNN and ASA-GNN followed with AUC values of 0.932 and 0.921, respectively, indicating their competitive performance. Meanwhile, FedGAT-DCNN exhibited the lowest

AUC (0.911), consistent with its lower precision and recall scores. While all models outperform random guessing (dashed diagonal line), LGM-GNN maintains the most favorable balance, demonstrating higher sensitivity to fraudulent transactions while minimizing false alarms. These findings emphasize the importance of model selection in fraud detection, as even slight variations in AUC can significantly impact financial security and risk management.

The results obtained in this study align with findings from previous research in fraud detection using deep learning and graph neural networks. Prior studies, such as those by Zhang et al. (2022) and Liu et al. (2023), demonstrated that graph-based approaches outperform traditional machine learning models in fraud detection tasks due to their ability to leverage relational data. However, our findings further suggest that architectural variations within GNNs significantly influence model effectiveness.

For instance, Zhang et al. (2022) reported that their GCN-based fraud detection model achieved an AUC of 0.915, which is comparable to the performance of FedGAT-DCNN in this study. Similarly, Liu et al. (2023) highlighted that attention-based graph networks can improve fraud detection, a conclusion supported by the strong performance of LGM-GNN (AUC = 0.958) in our experiments. These results reinforce the necessity of incorporating advanced feature aggregation and attention mechanisms to enhance detection capabilities.

Conclusion

The study conducted a comparative analysis of various graph neural network (GNN) architectures to identify fraudulent transactions in the banking system. The results showed that the LGM-GNN model demonstrated the best efficiency among the considered approaches, providing the highest accuracy, completeness and F1-score. This confirms the high ability of this model to detect fraud with minimal false positives, which is especially important for ensuring financial security.

Nevertheless, despite the successful results, there are several open issues related to the interpretability of models, optimization of computational costs and adaptation of algorithms to real banking data. To further improve the performance of the models, it is necessary to consider the problems of class imbalance, adapting methods to the specifics of the data and increasing the speed of processing transactions in real time.

Prospects for further research include the development of hybrid models combining graph neural networks with traditional machine learning methods, as well as improving the explainability of decisions made by models. This will open new opportunities for implementing effective and sustainable fraud detection systems in real banking systems.

REFERENCES

- Alarfaj F.K., Shahzadi S. (2024). Enhancing Fraud Detection in Banking with Deep Learning: Graph Neural Networks and Autoencoders for Real-Time Credit Card Fraud Prevention. — IEEE Access. 2024.
Cheng D. et al. (2020). Graph neural network for fraud detection via spatial-temporal attention. – IEEE Trans-

actions on Knowledge and Data Engineering. 2020. — V. 34. — №. 8. — Pp. 3800–3813.

Dou Y. et al. (2020). Enhancing graph neural network-based fraud detectors against camouflaged fraudsters. – Proceedings of the 29th ACM international conference on information & knowledge management. 2020. — Pp. 315–324.

Dumitrescu B., Băltoiu A., Budulan Ș. (2022). Anomaly detection in graphs of bank transactions for anti-money laundering applications. — IEEE Access. — 2022. — V. 10. — Pp. 47699–47714.

Ebiaredoh-Mienye S.A., Esenogho E., Swart T.G. (2021). Artificial neural network technique for improving prediction of credit card default: A stacked sparse autoencoder approach. – International Journal of Electrical and Computer Engineering. 2021. — V. 11. — №. 5. — P. 4392.

Fan S., Liu G., Li J. (2023). A heterogeneous graph neural network with attribute enhancement and structure-aware attention. – IEEE Transactions on Computational Social Systems. 2023. — V. 11. — №. 1. — Pp. 829–838.

Jing R. et al. (2021). A GNN-based Few-shot learning model on the Credit Card Fraud detection. — 2021 IEEE 1st International Conference on Digital Twins and Parallel Intelligence (DTPI). — IEEE, 2021. — Pp. 320–323.

Li M., Walsh J. (2024). FedGAT-DCNN: Advanced Credit Card Fraud Detection Using Federated Learning, Graph Attention Networks, and Dilated Convolutions. – Electronics. 2024. — V. 13. — №. 16. — P. 3169.

Li P. et al. (2023). LGM-GNN: A local and global aware memory-based graph neural network for fraud detection. – IEEE Transactions on Big Data. 2023. — V. 9. — №. 4. — Pp. 1116–1127.

Liu G.J. et al. (2021). Graph neural network for credit card fraud detection. — 2021 International Conference on Cyber-Physical Social Intelligence (ICCSI). — IEEE, 2021. — Pp. 1–6.

Liu Y. et al. (2021). Pick and choose: a GNN-based imbalanced learning approach for fraud detection. – Proceedings of the web conference 2021. — 2021. — Pp. 3168–3177.

Pourhabibi T. et al. (2020). Fraud detection: A systematic literature review of graph-based anomaly detection approaches. — Decision Support Systems. 2020. — V. 133. — P. 113303.

Singh M.T. et al. (2024). Heterogeneous Graph Auto-Encoder for CreditCard Fraud Detection. — arXiv preprint arXiv:2410.08121. — 2024.

Sozol M.S., Saki G.M., Rahman M.M. (2024). Anomaly Detection in Cybersecurity with Graph-Based Approaches. – International Journal of Scientific Research in Engineering and Management (IJSREM). 2024. — V. 8. — №. 8. — Pp. 1–7.

Tang Y., Liang Y. (2024). Credit card fraud detection based on federated graph learning. – Expert Systems with Applications. 2024. — V. 256. — P. 124979.

Tian Y. et al. (2023). ASA-GNN: Adaptive sampling and aggregation-based graph neural network for transaction fraud detection. – IEEE Transactions on Computational Social Systems. — 2023. — V. 11. — №. 3. — Pp. 3536–3549.

Tian Y., Liu G. (2024). Spatial-temporal-aware graph transformer for transaction fraud detection. – IEEE Transactions on Industrial Informatics. — 2024.

Van Belle R. et al. (2022). Inductive graph representation learning for fraud detection. – Expert Systems with Applications. 2022. — V. 193. — P. 116463.

Yan K., Gao J., Matsypura D. (2023). FIW-GNN: A Heterogeneous Graph-Based Learning Model for Credit Card Fraud Detection. — 2023 IEEE 10th International Conference on Data Science and Advanced Analytics (DSAA). — IEEE, 2023. — Pp. 1–10.

Zhou J. et al. (2020). Graph neural networks: A review of methods and applications. — AI open. 2020. — V. 1. — Pp. 57–81.

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 2. Number 22 (2025). Pp. 186–199

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.012>

PREDICTIVE RISK ASSESSMENT OF MUNICIPAL ASSETS USING MACHINE LEARNING: MODELING AGE, DEPRECIATION, AND USAGE FOR MAINTENANCE DECISIONS

Y.B. Tulebayev^{1}, A.A. Mukhanova², N. Goranin³*

¹Astana IT University, Astana, Kazakhstan;

²L.N. Gumilyov Eurasian National University, Astana, Kazakhstan;

³Vilnius Gediminas Technical University, Vilnius, Lithuania.

E-mail: yersultan.tulebayev@astanait.edu.kz

Tulebayev Y. — Master of Technical Sciences, «the Department of Computer Engineering», Astana IT University, Astana, Kazakhstan

E-mail: yersultan.tulebayev@astanait.edu.kz, <https://orcid.org/0000-0002-7965-1476>;

Mukhanova A. — PhD, associate professor L.N. Gumilyov Eurasian National University, Astana, Kazakhstan

E-mail: ayagoz198302@mail.ru, <https://orcid.org/0000-0003-3987-0938>;

Goranin N. — Doctor of Technological Sciences, professor, «the Department of Information Systems», Vilnius Gediminas Technical University, Vilnius, Lithuania

E-mail: nikolaj.goranin@vilniustech.lt, <https://orcid.org/0000-0002-2263-3947>.

© Y.B. Tulebayev, A.A. Mukhanova, N. Goranin, 2025

Abstract. In the context of aging infrastructure and a shortage of budgetary resources, municipalities increasingly need to make informed decisions on asset maintenance and modernization. This study aims to develop and implement a model for intelligent risk assessment of municipal property using machine learning methods. A real dataset of over 620,000 records of personal assets of government agencies with information on the acquisition date, cost, classification, and affiliation with the IT sector was used as a basis. Features reflecting the technical and operational condition were developed: asset age, level of depreciation, intensity of use, etc. Assets were automatically classified as “high-risk” or “low-risk” based on logical conditions consistent with industry standards. Logistic regression, Random Forest, and XGBoost algorithms were used to build predictive models. The XGBoost model showed the highest accuracy (ROC-AUC: 0.9991), minimizing the number of false and missed positives. Feature importance analysis confirmed the decisive role of deterioration level, age and intensity of use. The obtained results can be integrated into digital asset management platforms to support decision-making and transition from reactive to proactive maintenance. The work demonstrates the high applicability of machine learning in the tasks of sustainable and efficient management of urban infrastructure.

Keywords: asset risk assessment, municipal property, machine learning, pre-



dictive analytics, proactive maintenance

For citation: Y.B. Tulebayev, A.A. Mukhanova, N. Goranin. Predictive risk assessment of municipal assets using machine learning: modeling age, depreciation, and usage for maintenance decisions//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 186–199 (In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.012>

Conflict of interest: The authors declare that there is no conflict of interest.

МУНИЦИПАЛДЫҚ АКТИВТЕРДІҢ ТӘУЕКЕЛДЕРІН БОЛЖАУ: МАШИНАЛЫҚ ОҚЫТУДЫ ПАЙДАЛАНУ АРҚЫЛЫ ЖАС, ТОЗУ ЖӘНЕ ПАЙДАЛАНУ ҚАРҚЫНДЫЛЫҒЫ НЕГІЗІНДЕ ТЕХНИКАЛЫҚ ҚЫЗМЕТ КӨРСЕТУ ШЕШІМДЕРІН МОДЕЛЬДЕУ

Е.Б. Тулебаев^{1}, А.А. Муханова², Н. Горанин³*

¹Astana IT Университет, Астана, Қазақстан;

²Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан;

³Вильнюс Гедиминас техникалық университеті, Вильнюс, Литва.

E-mail: yersultan.tulebayev@astanait.edu.kz

Тулебаев Е. — Техника ғылымдарының магистрі, «Компьютерлік инженерия» кафедрасы, Астана IT университеті, Астана, Қазақстан

E-mail: yersultan.tulebayev@astanait.edu.kz, <https://orcid.org/0000-0002-7965-1476>;

Муханова А. — PhD, доцент Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан

E-mail: ayagoz198302@mail.ru, <https://orcid.org/0000-0003-3987-0938>;

Горанин Н. — профессор, техника ғылымдарының докторы, «Ақпараттық жүйелер» кафедрасы, Вильнюс Гедиминас техникалық университеті, Вильнюс, Литва

E-mail: nikolaj.goranin@vilniustech.lt, <https://orcid.org/0000-0002-2263-3947>.

© Е.Б. Тулебаев, А.А. Муханова, Н. Горанин, 2025

Аннотация. Инфрақұрылымның қартаюуы және бюджеттік ресурстардың жетіспеушілігі жағдайында муниципалитеттер активтерді күтіп ұстау және модернизациялау бойынша негізделген шешімдер қабылдау қажеттілігіне көбірек тап болуда. Бұл зерттеудің мақсаты – машиналық оқыту әдістерін пайдалана отырып, муниципалды меншіктің тәуекелдерін интеллектуалды бағалау моделін әзірлеу және енгізу. Зерттеу сатып алу күні, құны, жіктелуі және IT секторына қатыстылығы туралы мәліметтері бар мемлекеттік мекемелердің жеке активтерінің 620 000-нан астам жазбаларының нақты деректер жиынтығына негізделген. Техникалық және пайдалану жағдайын көрсететін ерекшеліктер әзірленді: активтің жасы, тозу деңгейі, пайдалану қарқындылығы және т.б. Активтер салалық стандарттарға сәйкес логикалық шарттар негізінде автоматты түрде «жоғары тәуекелді» немесе «тәуекелділігі төмен» болып жіктеледі. Болжамды модельдерді құру үшін логистикалық

регрессия, кездейсоқ орман және XGBoost алгоритмдері пайдаланылды. XGBoost моделі ең жоғары дәлдікті (ROC-AUC: 0,9991) көрсетті, бұл жалған және қабылданбаған оң нәтижелердің санын азайтты. Ерекшелік маңыздылығын талдау тозу деңгейінің, жастың және пайдалану қарқындылығының шешуші рөлін растады. Алынған нәтижелерді шешім қабылдауды қолдау және реактивті қызметтен проактивті техникалық қызмет көрсетуге көшу үшін активтерді басқарудың цифрлық платформаларына біріктіруге болады. Жұмыс қалалық инфрақұрылымды тұрақты және тиімді басқару міндеттерінде машиналық оқытудың жоғары қолданылуын көрсетеді.

Түйін сөздер: активтер тәуекелін бағалау, муниципалдық меншік, машиналық оқыту, болжамды талдау

Дәйексөздер үшін: Е.Б. Тулебаев, А.А. Муханова, Н. Горанин. муниципалдық Активтердің тәуекелдерін болжау: машиналық оқытуды пайдалану арқылы жас, тозу және пайдалану қарқындылығы негізінде техникалық қызмет көрсету шешімдерін модельдеу//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 186–199 бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.012>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

ПРОГНОЗНАЯ ОЦЕНКА РИСКОВ МУНИЦИПАЛЬНЫХ АКТИВОВ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ: МОДЕЛИРОВАНИЕ ВОЗРАСТА, ИЗНОСА И ИСПОЛЬЗОВАНИЯ ДЛЯ ПРИНЯТИЯ РЕШЕНИЙ ПО ОБСЛУЖИВАНИЮ

Е.Б. Тулебаев^{1*}, А.А. Муханова², Н. Горанин³

¹Astana IT Университет, Астана, Казахстан;

²Евразийский национальный университет имени Л.Н. Гумилева, Астана, Казахстан;

³Вильнюсский технический университет им. Гедиминаса, Вильнюс, Литва.

E-mail: yersultan.tulebayev@astanait.edu.kz

Тулебаев Е. — магистр технических наук, «Департамент компьютерной инженерии», Astana IT Университет, Астана, Казахстан

E-mail: yersultan.tulebayev@astanait.edu.kz, <https://orcid.org/0000-0002-7965-1476>;

Муханова А. — PhD, доцент, Евразийский национальный университет имени Л.Н. Гумилева, Астана, Казахстан

E-mail: ayagoz198302@mail.ru, <https://orcid.org/0000-0003-3987-0938>;

Горанин Н. — профессор, доктор технических наук, «Кафедра информационных систем», Вильнюсский технический университет им. Гедиминаса, Вильнюс, Литва

E-mail: nikolaj.gorani@vilniustech.lt, <https://orcid.org/0000-0002-2263-3947>.

© Е.Б. Тулебаев, А.А. Муханова, Н. Горанин, 2025

Аннотация. В условиях стареющей инфраструктуры и нехватки бюджетных ресурсов муниципалитетам все чаще приходится принимать обоснованные решения по обслуживанию и модернизации активов. Целью данного исследования является разработка и внедрение модели интеллектуальной оценки рисков муниципальной собственности с использованием методов машинного обучения. За основу был взят реальный набор данных из более чем 620 000 записей личных активов государственных учреждений с информацией о дате приобретения, стоимости, классификации и принадлежности к ИТ-сектору. Были разработаны признаки, отражающие техническое и эксплуатационное состояние: возраст активов, уровень амортизации, интенсивность использования и т.д. Активы автоматически классифицировались как «высокорисковые» или «низкорисковые» на основе логических условий, соответствующих отраслевым стандартам. Для построения прогностических моделей использовались алгоритмы логистической регрессии, случайного леса и XGBoost. Модель XGBoost показала наивысшую точность (ROC-AUC: 0,9991), минимизировав количество ложных и пропущенных положительных результатов. Анализ важности признаков подтвердил решающую роль уровня износа, возраста и интенсивности использования. Полученные результаты могут быть интегрированы в платформы управления цифровыми активами для поддержки принятия решений и перехода от реактивного к проактивному обслуживанию. Работа демонстрирует высокую применимость машинного обучения в задачах устойчивого и эффективного управления городской инфраструктурой.

Ключевые слова: оценка риска активов, муниципальная собственность, машинное обучение, предиктивная аналитика

Для цитирования: Е.Б. Тулебаев, А.А. Муханова, Н. Горанин. Прогнозная оценка рисков муниципальных активов с использованием машинного обучения: моделирование возраста, износа и использования для принятия решений по обслуживанию // Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 186–199. (На англ.). <https://doi.org/10.54309/IJICT.2025.22.2.012>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

In recent decades, cities and towns around the world have been facing the problem of rapidly aging and deteriorating infrastructure. Municipal assets — from IT equipment and office furniture to medical and engineering infrastructure — require regular maintenance, renewal, and replacement. However, resources for these purposes are limited, and decision-making mechanisms are often based on subjective assessments, outdated regulations, or formal indicators such as the age or cost of the asset. This approach does not always reflect the actual technical condition of the property and can lead to inefficient budget allocation, increased operational risks, and deterioration in the quality of municipal services.

In this regard, there is a growing need to develop assessment tools that allow for accurate and timely identification of assets with a high risk of failure or need for replacement. Such tools must be scalable, interpretable, adaptable to different types of assets, and take into account both physical characteristics and operating conditions. The most promising direction in this area is the use of data analysis and machine learning methods that allow you to identify hidden dependencies and build predictive models based on historical and current data. Data science and advanced analytics, especially machine learning methods, can provide actionable insights and deeper knowledge about data, making the computing process automatic and intelligent, providing decision support in various application areas. (Sarker, 2021)

Modern municipalities accumulate significant amounts of information about assets - including the date of acquisition, cost, classification, intensity of use, depreciation characteristics and even georeferencing. However, this data is rarely used to build intelligent decision support systems. In most cases, they act only as reference information, while their potential for predicting technical condition remains untapped.

There are already a number of examples of using predictive analytics for infrastructure management tasks in global practice. For example, in the energy sector, models are used to assess the risk of transformer failure, in the water sector to predict pipe deterioration (Taiwo et al., 2025), in the transportation sector to prioritize road maintenance, and to identify climate-related failures in rail infrastructure using machine learning (Soleimani-Chamkhorami et al., 2024), as well as to predict the risk of stablecoin decoupling in finance (Lee et al., 2025), to predict the risk-return trade-off in financial markets for asset management (Yarbakhsh et al., 2025), or to predict the future value of investments (Parisi & Manaog, 2025), or to predict the risk of viral failure in adolescents living with HIV (Kizito et al., 2025). However, at the municipal property level, especially in the non-production asset segment, such as office equipment, IT systems or furniture, such approaches have been applied to a limited extent. One of the reasons is the lack of unified assessment methods that take into account the specifics of such assets.

This study aims to fill this gap. We propose an intelligent risk assessment model that is based on structured asset data and uses machine learning methods to build a classification model. As part of the work, we carried out careful feature engineering, which allows taking into account not only the age and value of the property, but also such characteristics as intensity of use, affiliation with the IT sector, as well as the level of depreciation calculated taking into account the expected service life. This provides a more complete and objective picture of the technical condition of each asset. Similar approaches to the development of machine learning-based tools for managing specific assets, such as sewer pipeline networks, are also actively developing in the scientific literature (Stengel et al., 2024). It is also important to emphasize that the proposed model is not a “black box” — on the contrary, we pay great attention to the interpretability of the results. For this purpose, in addition to high-precision algorithms such as XGBoost, the study includes logistic regression, which allows for a visual assessment of the impact of each feature on the final decision. The importance

of features, error matrices, and ROC curves are also analyzed, making the model suitable for integration into real asset management and decision-making systems.

This study therefore has two key objectives. First, it demonstrates the applicability of modern machine learning algorithms to the task of predicting the risk of municipal asset renewal. Second, it offers a practical toolkit that can be integrated into existing urban information systems and used to formulate proactive asset management policies. Given the rapid development of technologies and the growing interest in the digital transformation of cities, such a model can be an important step towards smart and sustainable municipal systems.

Objective of the Study

The objective of this study is to develop, implement and evaluate the effectiveness of an intelligent model for classifying municipal asset risks using machine learning methods. The focus is on building a predictive system that can accurately identify assets with a high risk of failure based on such attributes as age, depreciation level, intensity of use, IT category, cost, and formal parameters, including asset classification.

The main challenge is to move from reactive management to proactive management, where decisions on asset maintenance and replacement are made not on the basis of a calendar service life or subjective assessment, but on the basis of objective, quantifiable characteristics obtained by analyzing large amounts of data. The developed model should not only be highly accurate, but also interpretable so that it can be integrated into decision support systems of city administrations, IT and finance departments. In addition, the study is intended to demonstrate the potential of such models in the context of digital transformation of urban infrastructure management and sustainable development of municipal systems.

Methodology

The methodology of this study is based on the sequential implementation of the stages of data collection, cleaning and analysis, feature engineering, target variable construction and training of machine learning models. Each step was aimed at achieving high prediction accuracy, model interpretability and practical utility of the results.

The source material was a combined dataset of more than 627,000 municipal asset records, presented as a CSV file. Each record contains fields such as agency code, asset name, acquisition or installation date, cost, classification, IT affiliation, year and type of ownership. After initial cleaning and removal of rows with critically missing values (e.g. without acquisition date), the final sample consisted of 609,017 records.

The following steps were implemented to create meaningful features:

- Asset age (ASSET_AGE): calculated as the difference between 2025 and the year of asset installation.
- Depreciation level (DEPRECIATION): calculated as a percentage based on the expected service life depending on the asset type. For example, for IT equipment - 5 years, for infrastructure - 30 years.

- Usage intensity (USAGE_INTENSITY): assigned a value from 1 to 4 depending on the equipment type. IT and medical equipment received higher values.
- Asset type (PROPERTY_TYPE_REFINED): assigned based on keywords in the asset name. For example, the words “laptop” or “server” classified the asset as an IT category.

All categorical features (such as PROPERTY_CLASSIFICATION and IT_OR_NON-IT) were encoded using the Label Encoding method.

The target variable HIGH_RISK was formed according to heuristic rules. An asset was considered high risk (value 1) if it met at least two of the following conditions:

- age exceeds a threshold (e.g. 6 years for IT assets);
- depreciation level exceeds 60%;
- high intensity of use.

This has resulted in a balanced, interpretable, and practically applicable risk metric. In this context, hierarchical modeling can be effectively used to overcome the challenges of insufficient data and subgroup heterogeneity while providing a quantitative assessment of prediction uncertainty. (Dhada et al., 2024) It is important to note, however, that to achieve high failure prediction accuracy, especially in large-scale networks such as water supply networks, it is necessary to consider not only individual asset attributes but also their relationships in the network (structural information) and failure patterns over time. (Liang et al., 2021)

Three algorithms were selected to build the risk prediction model:

- Random Forest — as an interpretable ensemble method;
- Logistic Regression — for a linear approach and feature influence assessment;
- XGBoost — as a powerful boosting algorithm capable of handling complex dependencies.

These and other machine and deep learning algorithms are widely used in predictive maintenance of industrial equipment to solve classification and regression problems. (Zhang et al., 2019)

The data was divided into training and test sets in a ratio of 80/20. After training, the models predicted both classes (0 or 1) and probabilities, which were used to calculate quality metrics. Such approaches to predicting the remaining service life of assets and supporting decisions on their renewal, including the use of advanced data analysis and machine learning methods, are actively used, including in the electric power sector to optimize maintenance and replacement planning. (Santiago et al., 2023)

The following metrics were used to evaluate the effectiveness:

- Accuracy;
- Recall and Precision;
- F1-measure;
- ROC-AUC;
- Error matrices;

- Feature importance graphs.

The results of the models were compared both by numerical metrics and visually (via ROC curves and heat maps of error matrices).

Results

During the validation phase, the machine learning models demonstrated high accuracy values for classifying assets by risk. The best result was shown by the XGBoost model, achieving a ROC-AUC value of 0.9991, indicating a near-perfect separation of classes. However, despite the good performance of traditional machine learning models such as XGBoost, research shows that for failure prediction in large networks such as water utilities, where not only individual asset information but also their relationships are important, graph neural networks can demonstrate superior results by leveraging structural information and taking into account temporal failure patterns. (Liang et al., 2021) The Random Forest model also showed excellent results (ROC-AUC: 0.9978), slightly inferior to XGBoost. Logistic regression, despite a lower score (0.9914), remained a valuable tool due to its high interpretability.

Table 1. Model Performance Evaluation

Model	Accuracy	Precision	Recall	F1-score	ROC-AUC
Logistic Regression	0,9845	0.9981	0.9799	0.9889	0.9914
Random Forest	0.9948	0.9967	0.9945	0.9956	0.9978
XGBoost	0,9960	0,9993	0,9837	0,9914	0,9991

The feature importance assessment showed that the most significant variables for all models were technical characteristics related to asset depreciation and age. This was especially evident in XGBoost, where the depreciation level (DEPRECIATION) became the key indicator. In logistic regression, the intensity of use played a dominant role, and in Random Forest, age, depreciation, and IT ownership made a balanced contribution.

Table 2. Comparison of Feature Importance by Machine Learning Models

Feature	Logistic Regression	Random Forest	XGBoost
ASSET_AGE	average	most important	low
DEPRECIATION	weak	very important	most important
USAGE_INTENSITY	dominant	significant	moderate
VALUE_OR_COST	almost zero	weak	zero

IT_OR_NON-IT	moderate	moderate	zero
PROPERTY_ CLASSIFICATION	almost zero	zero	zero

This table allows us to draw conclusions about the differences in the logic of the models. XGBoost, as a model more sensitive to structural patterns, emphasizes physical depreciation, while logistic regression focuses on linear dependencies, such as usage intensity.

Confusion matrices confirmed the high accuracy of all models, especially in identifying high-risk assets. XGBoost has the minimum number of false positives (FP = 51), while logistic regression missed more risky assets (FN = 1478), which potentially reduces its applicability in critical systems.

Table 3. Comparison of Confusion Matrix Values by Machine Learning Models

Model	T r u e Positives	False Negatives		False Positives	True Negatives
Logistic Regression	72,097	1,478		133	48,096
R a n d o m Forest	73,173	402		243	47,986
XGBoost	72,379	1,196	51		48,178

ROC curves visualized the differences in the sensitivity of the models. XGBoost and Random Forest demonstrated the best curve shape, close to the upper left corner, indicating the ability to accurately separate the classes. The logistic regression curve was slightly lower, indicating a higher proportion of false negatives. As can be seen from Figure 1, all three models demonstrated high classification performance. XGBoost and Random Forest are visually close to the ideal classifier, while logistic regression shows a slightly smaller area under the curve.

Discussion. The results obtained during the study provide an in-depth analysis of the potential and limitations of machine learning methods in the life cycle management of municipal assets. They demonstrate that even with a limited set of features, such as age, depreciation, intensity of use, and classification attributes, it is possible to achieve high accuracy in determining the risk associated with a particular asset. (Forero-Ortiz et al., 2023)




Fig. 1. Comparison of ROC curves of Random Forest, Logistic Regression and XGBoost models for classifying municipal assets by risk level.

The first thing that the analysis draws attention to is the high accuracy of all three models, despite the difference in their algorithmic nature. XGBoost demonstrated the best ability to distinguish between risky and non-risky assets, with a virtually perfect ROC-AUC value (0.9991), indicating extremely high sensitivity and specificity. This is explained by the internal boosting mechanism, which allows the model to consistently minimize the error of previous trees and consider complex nonlinear relationships between features.

Random Forest, although inferior to XGBoost in accuracy, showed the best balance between the number of false positives and false negatives. Its ability to identify truly risky assets (True Positives) turned out to be higher, which makes it especially attractive for practical application in conditions where the priority is to minimize technical failures.

Despite lower accuracy rates, logistic regression plays an important role as an interpretable model. Its coefficients allow for a direct assessment of the contribution of each attribute to the final decision, which is critical when it comes to justifying management actions to stakeholders such as finance departments, audit services, or public observers.

Equally important is the analysis of the importance of attributes. Almost all models confirmed the key role of operational characteristics, primarily the level of wear and tear and age. This confirms the hypothesis that it is the technical condition, rather than accounting parameters, which determines the actual risk associated with an asset. At the same time, attributes such as formal classification or cost turned out to be of low significance. This opens the way to rethinking existing methods of in-

ventory and property valuation, in which cost is often used as the main prioritization criterion.

Usage intensity was a particularly significant factor in the logistic regression. This is understandable, since high frequency of use directly affects the service life of equipment, especially in the case of IT and medical assets. This feature, despite its subjectivity (it was set manually), showed a stable correlation with the risk level. This provides grounds for further development of the automated usage monitoring direction, for example, through the implementation of sensors or accounting systems. From a practical point of view, the proposed model is a valuable tool for the digitalization of asset management processes. It can be integrated into existing information systems, creating a single analytical space in which lists of assets with a high update priority are automatically generated. Such machine learning-based solutions can significantly improve asset maintenance and management priorities by automating processes such as criticality analysis and predicting the condition of equipment based on sensor data. (Hanish Nithin et al., 2022) Moreover, the results can be used to justify budget requests, draw up technical specifications, prepare tender documentation, and monitor the execution of contracts for the supply and modernization of property.

An important aspect is the scalability of the model. It can be adapted to assets of various levels: from a single building or department to the entire city infrastructure. With a centralized database and automatic sources of information (e.g., APIs of accounting systems, registration registries, sensor platforms), the model can perform risk assessment in real time.

The interpretability of the model is also straightforward. In addition to logistic regression, SHAP (SHapley Additive exPlanations) methods can be used for more complex models, which allow you to visualize the contribution of each feature to the prediction for a specific asset. This makes the algorithm not only predictable, but also transparent, which is especially important in the context of public reporting and compliance with the principles of open governance.

The limitations cannot be ignored. Firstly, the model depends on the quality of the source data. Missing values, incorrect values, and inconsistent formats can significantly affect the accuracy of predictions. This study took steps to clean and normalize the data, but in real conditions, validation procedures at the data entry level would need to be implemented. Secondly, the current model does not consider spatial and temporal characteristics, such as asset location, repair history, operating conditions (e.g., climate). Their inclusion in the future can significantly improve the accuracy of the assessment.

Despite this, even the current version of the model provides a powerful analytical tool that can change the approach to municipal asset management. It facilitates the transition from a reactive approach (“replace when it breaks”) to a proactive one (“service when the predictive model shows a high risk of failure”), which in turn leads to cost reduction, increased reliability and sustainability of urban infrastructure.

Thus, the discussion shows that the developed algorithm is not just an experimental solution, but a ready-to-use tool that can improve the efficiency of municipal

asset management. Its implementation opens the way to the creation of smart cities, where resources are used as rationally as possible, and the risks of technical failures are minimized through predictive analytics.

Conclusion

During this study, an intelligent model for assessing the risk of municipal assets based on modern machine learning algorithms was developed and tested. The use of a large amount of data, including information on more than 600 thousand units of property, allowed not only to identify the most significant risk indicators, but also to prove that even a limited data set in structure and volume can serve as a reliable basis for the formation of accurate and practically applicable models.

The key advantage of the proposed approach is the transition from static, regulated assessment methods (based, as a rule, on calendar age or accounting value) to a dynamic system based on data on technical and operational condition. This opens new horizons in asset lifecycle management - from budget planning and preventive maintenance to strategic renewal of the material and technical base of municipalities.

The modeling results showed that the XGBoost model was the most effective in terms of accuracy and stability. It achieved a ROC-AUC value of 0.9991, minimizing the number of both false positives and false negatives. At the same time, the Random Forest model demonstrated more balanced performance in scenarios with limited explainability, and logistic regression provided high interpretability, which makes it useful in the context of substantiating management decisions.

Of value is the analysis of the importance of features. It was found that such parameters as depreciation (calculated based on age and standard service life), intensity of use and type (e.g., IT or infrastructure) have the greatest impact on the probability of asset failure. In contrast, such indicators as original cost or property classification turned out to be poorly informative. This allows us to rethink the principles of accounting and valuation of assets in state registries, focusing on operational characteristics.

The developed model can be easily scaled and adapted to specific tasks and conditions of various cities, regions and departments. It can be integrated into existing asset management platforms and become the basis for the implementation of predictive maintenance modules. In combination with the Internet of Things (IoT), geographic information systems (GIS) and digital twins, this model can become a key element of the smart infrastructure of the city of the future.

Despite the results achieved, the author is aware of several limitations. The current study did not consider spatial features, time trends, climatic and operational conditions. Future work plans to supplement the model with these parameters, as well as use explainable machine learning methods, such as SHAP, to increase the transparency of decisions.

Thus, this study demonstrates that machine learning technologies have high potential in the field of sustainable, proactive and informed management of municipal assets. Their implementation will significantly increase the reliability of urban infrastructure, reduce repair and modernization costs, and improve the quality of services

provided to the population.

Prospects

The development of an intelligent model for assessing the risk of municipal assets opens broad opportunities for further development in both scientific and practical terms. One of the priority areas is the inclusion of spatial data (geolocations, climate zones, type of coverage of buildings and objects), which will allow considering the territorial features of asset operation.

In the future, the model can be supplemented with time characteristics, including maintenance history, frequency of repairs, and peak load seasons. This will allow moving from static to dynamic risk assessment and introducing predictive maintenance approaches.

It is also planned to use explainable machine learning tools, such as SHAP (SHapley Additive exPlanations), which will ensure transparency of predictions even for complex models such as XGBoost. This is especially important in the context of open management when it is necessary to justify decisions to the public and regulatory authorities.

An additional vector is the development of asset clustering and segmentation modules, which will allow for strategic grouping by risk type, cost and renewal priority. All this will contribute to the formation of sustainable, manageable and digitally transformed urban systems.

REFERENCES

- Dhada M., Hadjidemetriou G.M. & Parlikad A.K. (2024). Predicting Road Condition using Linear Hierarchical Modelling. IFAC-PapersOnLine. — 58(8). — Cagliari, Italy. — Pp. 407–411.
- Forero-Ortiz E., Martinez-Gomariz E., Sanchez-Juny M., Cardus Gonzalez J., Cucchiatti F., Baque Viader F. & Sarrias Monton M. (2023). Models and explanatory variables in modelling failure for drinking water pipes to support asset Hanish Nithin, A., Hobbs, M., Sriramula, S., & Sripada, Y. (2022). An approach to improve asset maintenance and management priorities using machine learning techniques. *Safety and Reliability*, 41(3). — London. — Pp. 151–169.
- Zhang W., Yang D. & Wang H. (2019). Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. *IEEE Systems Journal*. — 13(3). — New York. — Pp. 2213–2227.
- Kizito S., et al. (2025). A prediction model for virologic failure in adolescents living with HIV in Uganda: Findings from the Suubi+Adherence study. *Public Health*. — 244. — 105753.
- Liang S., Li Z., Liang B., Ding Y., Wang Y. & Chen F. (2021). Failure Prediction for Large-scale Water Pipe Networks Using GNN and Temporal Failure Series. *Proceedings of the 30th ACM International Conference on Information and Knowledge Management (CIKM '21)*. — New York: ACM. — Pp. 3955–3964.
- Lee Y.-H., Chiu Y.-F. & Hsieh M.-H. (2025). Stablecoin depegging risk prediction. — *Pacific-Basin Finance Journal*. — 90. — 102640.
- Taiwo R., Shaban I.A., Ahmad T. & Zayed T. (2025). Big data-driven prediction of watermain failures in semi-tropical regions: Case study of Hong Kong's distribution network. *Automation in Construction*. — 175. — 106159.
- Parisi L. & Manaog M.L. (2025). Optimal Machine Learning- and Deep Learning-driven algorithms for predicting the future value of investments: A systematic review and meta-analysis. *Engineering Applications of Artificial Intelligence*. — 142. — 109924.
- Stengel J., Aboagye E., Le P., DeNafo M., Snyder D., Nelson N. & Yenkie K. (2024). Systematic Development of a Machine Learning-Based Asset Management Tool for Wastewater Pipeline Networks. *ACS ES&T Water*. — Washington, DC. — Pp. 5555–5565.

Sarker I.H. (2021). Data Science and Analytics: An Overview from Data-Driven Smart Computing, Decision-Making and Applications Perspective. *SN Computer Science*. — 2(5). — 377.

Soleimani-Chamkhorami K., Karbalaie A., Kasraei A., Haghighi E., Famurewa S.M. & Garmabaki A.H.S. (2024). Identifying climate-related failures in railway infrastructure using machine learning. *Transportation Research Part D*, — 135. — 104371.

Santiago H.d.C., Cavalcanti J.C.d.S., Prudêncio R.B.C., Mohamed M.A., Sarubbo L.A., Converti A. & Marinho M. H.d.N. (2023). A Novel Remaining Useful Estimation Model to Assist Asset Renewal Decisions Applied to the Brazilian Electric Sector. *Energies*. — 16(6). — 2513.

Yarbaksh R., Soleymani Baghshah M. & Karimaghaie H. (2025). Predicting risk/reward ratio in financial markets for asset management using machine learning. *Expert Systems With Applications*. — 284. — 127650.



INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 1. Number 22 (2025). Pp. 200–213

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.013>

IRSTI 20.01

COMPARATIVE ANALYSIS OF FOUR-BIT BINARY ADDERS WITH PARALLEL CARRIES

S. Tynymbayev¹, Zh. E. Temirbekova^{1}, R. Berdibayev², E.S. Mamanova¹*

¹International Information Technology University, Almaty, Kazakhstan;

²Almaty University of Power Engineering and Telecommunications named after Gumarbek Daukeyev, Almaty, Kazakhstan.

E-mail: temyrbekovazhanerke2@gmail.com

Tynymbayev S. — Candidate of Technical Sciences, professor, academician of the International Academy of Informatization (IAI), International Information Technology University, Almaty, Kazakhstan

E-mail: s.tynym@mail.ru

Temirbekova Zh. — Doctor of Technical Sciences, PhD, International Information Technology University, Almaty, Kazakhstan

E-mail: temyrbekovazhanerke2@gmail.com

Berdybayev R. — Candidate of Political Sciences, academician of the International Academy of Informatization (IAI), Almaty University of Power Engineering and Telecommunications named after Gumarbek Daukeyev, Almaty, Kazakhstan

E-mail: r.berdybaev@aues.kz

Mamanova S. — Master of Technical Sciences, International Information Technology University, Almaty, Kazakhstan

E-mail: s.mamanova@iitu.edu.kz

© S. Tynymbayev, Zh. E. Temirbekova, R. Berdibayev, E.S. Mamanova, 2025

Abstract. Recently, non-traditional adders have appeared, such as adders with a conditional sum and with conditional transfers, adders on three input or two-input fans «exclusive OR (XOR)». The paper considers the construction of functional circuits of four-bit binary adders, where bit adders are built based on two and three «exclusive OR (XOR)» input gates and on adders with a conditional sum such as with parallel transfer circuits. The synthesis of an adder with a conditional sum is considered. In conclusion, four-digit adders are compared in terms of the number of MOSFETs and speed, which allows you to choose the type of adders when designing various digital devices that contain binary adders.

Keywords: binary adders, exclusive OR gates, parallel carry circuits, conditional sum adder

For citation: S. Tynymbayev, Zh.E. Temirbekova, R. Berdibayev, E.S. Mamanova. Comparative analysis of four-bit binary adders with parallel carries// International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 200–213 (In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.013>.

Conflict of interest: The authors declare that there is no conflict of interest.



ТӨРТ РАЗРЯДТЫ ЕКІЛІК ПАРАЛЛЕЛЬ ТАСЫМАЛДАҒЫШЫ БАР ҚОСЫНДЫЛАРДЫ САЛЫСТЫРМАЛЫ ТАЛДАУ

С. Тынымбаев¹, Ж.Е. Темирбекова^{1}, Р.Ш. Бердибаев², С.Е. Маманова¹*

¹Халықаралық ақпараттық технологиялар университетіб Алматы, Қазақстан;

²Ғұмарбек Дәукеев атындағы Алматы энергетика және байланыс университеті,

Алматы, Қазақстан.

E-mail: temyrbekovazhanerke2@gmail.com

Тынымбаев С. — т.ғ.к., профессор, академик, Халықаралық ақпараттық технологиялар университеті
E-mail: s.tynym@mail.ru

Темирбекова Ж. — техника ғылымдарының докторы, PhD, Халықаралық ақпараттық технологиялар университеті
E-mail: temyrbekovazhanerke2@gmail.com

Бердибаев Р. — саяси ғылымдарының кандидаты, академик, Ғұмарбек Дәукеев атындағы Алматы энергетика және коммуникациялар университеті
E-mail: r.berdybaev@auess.kz

Маманова С. — техника ғылымдарының магистрі, Халықаралық ақпараттық технологиялар университеті
E-mail: s.mamanova@iitu.edu.kz

© С. Тынымбаев, Ж.Е. Темирбекова, Р.Ш. Бердибаев, С.Е. Маманова, 2025

Аннотация. Кәзіргі уақытта ғылыми басылымдарға шартты қосылғышы бар, шартты тасымалдағышы бар және үш немесе екі кірісті екі модульмен қосу арқылы құрылған дәстүрлі емес қосылғыштардың түрлері қаралып отыр. Қаралып отырған мақалада аталған қосылғыштар арқылы төрт разрядты қосылғыштардың құрылымдық сұлбаларын құрып оларды бір-бірімен жылдамдықтары және оларды құратын транзисторлардың саны арқылы салыстырылды. Салыстыру нәтижесі цифрлық құрылғыларды жобалағанда қосылғыштардың тиімді түрін таңдап алуға мүмкіндік береді.

Түйін сөздер: екілік қосылғыштар, екі немесе үш кірісті екі модульмен қосы арқылы құрылған қосылғыштар, параллель тасымалдау сұлбасы, шартты қосылғыш

Дәйексөздер үшін: С. Тынымбаев, Ж.Е. Темирбекова, Р.Ш. Бердибаев, С.Е. Маманова. Параллель трансферттері бар төрт биттік екілік қосылғыштарды салыстырмалы талдау // Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 200–213 бет. (қазақ тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.013>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ЧЕТЫРЕХРАЗРЯДНЫХ ДВОИЧНЫХ СУММАТОРОВ С ПАРАЛЛЕЛЬНЫМИ ПЕРЕНОСАМИ

С. Тынымбаев¹, Ж.Е. Темирбекова^{1}, Р.Ш. Бердибаев², С.Е. Маманова¹*

¹Международный университет информационных технологий, Алматы,
Казахстан;

²Алматинский университет энергетики и связи имени Гумарбека Даукеева,
Алматы, Казахстан.

E-mail: temyrbekovazhanerke2@gmail.com

Тынымбаев С. — кандидат технических наук, профессор, академик МАИН, Международный университет информационных технологий, Алматы, Казахстан

E-mail: s.tynym@mail.ru

Темирбекова Ж. — доктор технических наук, PhD, Международный университет информационных технологий, Алматы, Казахстан

E-mail: temyrbekovazhanerke2@gmail.com

Бердибаев Р. — кандидат политических наук, академик МАИН, Алматинский университет энергетики и связи имени Гумарбека Даукеева, Алматы, Казахстан

E-mail: r.berdybaev@auces.kz

Маманова С. — магистр технических наук, Международный университет информационных технологий, Алматы, Казахстан

E-mail: s.mamanova@iitu.edu.kz

© С. Тынымбаев, Ж.Е. Темирбекова, Р.Ш. Бердибаев, С.Е. Маманова, 2025

Аннотация. В последнее время появились нетрадиционные сумматоры такие как сумматоры с условной суммой и с условными переносами, сумматоры на трех входных или двухвходных вентилях «исключающее ИЛИ». В работе рассматриваются построение функциональных схем четырехразрядных двоичных сумматоров, где разрядные сумматоры построены на базе двух и трех входных вентилях «исключающее ИЛИ» и на сумматорах с условной суммой такие как с цепями параллельных переносов. Рассматривается синтез сумматора с условной суммой. В заключении осуществляется сравнение четырёхразрядных сумматоров по количеству МОП транзисторов и по быстродействию, что позволяет выбрать тип сумматоров при проектировании различных цифровых устройств, где содержатся двоичные сумматоры.

Ключевые слова: двоичные сумматоры, вентили «исключающее ИЛИ», схемы параллельными переносов, сумматор с условной суммой

Для цитирования: С. Тынымбаев, Ж.Е. Темирбекова, Р.Ш. Бердибаев, С.Е. Маманова. Сравнительный анализ четырехразрядных двоичных сумматоров с параллельными переносами//Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 200–213. (На англ.). <https://doi.org/10.54309/IJICT.2025.22.2.013>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Adders perform arithmetic additions and subtractions of numbers and, together with other logical operations, adders form the basis of arithmetic logic device cir-

cuits that implement several different operations (division, multiplication, raising to a power, etc.) that are integral parts of processors of various types. This article is useful for specialists in designing any digital accounts where binary adders are used.

The hardware complexity and speed of an adder are important parameters and, therefore, many variants of single-bit and multi-bit adders with serial, parallel and combined carries have been developed (Ugryumov, 2020: 800; Russo et al., 2018).

Materials and Methods

Traditionally, binary adders are synthesized based on a truth table (Nair et al., 2018: 1942–55; Timmermann et al., 2018: 1–4). The analytical expressions of the sum (S_i) and carry (P_i) functions for the i -th digit have the following form:

$$S_i = \bar{a}_i \cdot \bar{b}_i P_{i-1} \vee \bar{a}_i b_i P_{i-1} \vee a_i b_i P_{i-1} \quad (1)$$

$$P_i = a_i b_i \vee a_i P_{i-1} \vee b_i P_{i-1}$$

where, a_i – bits of the i -th digits of numbers A and B;

P_{i-1} – carry from the least significant digit.

In the AND-NOT circuits in formula (1), P_{i-1} has the following form (Harris et al., 2022: 947; Sazhina, 2021: 140):

$$P_i = \overline{a_i b_i \cdot P_{i-1} a_i \cdot P_{i-1} b_i} \quad (2)$$

The expression for S_i using the summation operation modulo two («exclusive OR») can be rewritten as follows:

$$S_i = P_{i-1}(a_i b_i + \bar{a}_i \bar{b}_i) + \bar{P}_{i-1}(\bar{a}_i b_i + a_i \bar{b}_i) = \quad (3)$$

$$= P_{i-1}(a_i \oplus b_i) + \bar{P}_{i-1}(a_i + b_i) = P_{i-1} \oplus a_i \oplus b_i$$

As can be seen from formula (3), the sum of the i -digit can be formed on three-input or two-input «exclusive OR» circuits.

Recently, new approaches to the design of digital circuits have been developed and are being developed, including adders based on integrated circuits on MOS transistors, which are characterized by high speed, low power consumption, where the transistor placement density in one chip is calculated in millions.

In this regard, approaches to the development of adders are changing. So-called adders with a conditional sum (CSA) and adders with a conditional carry (CCA) have appeared (Sklansky, 1960: 226–231). In this paper, we will consider a four-digit adder with parallel carry on adders with a conditional sum.

To speed up the operations of adding multi-digit numbers, parallel carry circuits (PCC) have been developed (Cheng et al., 1998: 131–134; Kuo-Hsing et al.,

2016: 975–989). The formula for calculating the carry P_i on AND-NOT gates is as follows:

$$P_i = \overline{\overline{g_i g_{i-1} h_{i-1} g_{i-2} h_{i-1} n_i} \dots \overline{P_{\text{ex}} h_0 h_1 \dots h_i}} \quad (4)$$

where $g_i = a_i b_i$ – carry generation function;

$h_i = a_i \vee b_i = \overline{\overline{a_i} \overline{b_i}}$ – carry transfer function.

With a large number of adder bits, the implementation of parallel carry requires logic elements with a large number of inputs and high load capacity. For example, to build an eight-bit adder, elements with 8 inputs and a branching factor of 16 are required, which may exceed the capabilities of basic logic elements. Therefore, adders with parallel carry are usually implemented only for a small number of bits. In the future, we will consider the construction of multi-bit adders based on four-bit adders, where the parallel carry circuit (PCC) is implemented according to the following formulas:

$$\begin{aligned} P_0 &= \overline{\overline{g_0} \overline{P_{\text{ex}} h_0}} = \overline{\overline{a_0 b_0} \cdot \overline{P_{\text{ex}} h_0}} \\ P_1 &= \overline{\overline{a_1 b_1} \cdot \overline{a_0 b_0 h_1} \cdot \overline{P_{\text{ex}} h_1 h_0}} \\ P_2 &= \overline{\overline{a_2 b_2} \cdot \overline{a_1 b_1 h_2} \cdot \overline{a_0 b_0 h_2 h_1} \cdot \overline{P_{\text{ex}} h_2 h_1 h_0}} \end{aligned} \quad (5)$$

Fig.1. shows the circuit diagram of the power supply system, constructed according to formula (5), where the carries P_0, P_2, P_3 are formed in parallel for a four-bit adder.

Four-bit parallel carry adder with three-input «exclusive-OR (XOR)» gates SM_1

The functional diagram of a 4-bit adder with parallel carry on three-input «exclusive-OR (XOR)» circuits is shown in Figure 2.




Fig. 1. Functional Diagram of the Parallel Carry Generator for Four-Bit Adders




Fig.2. Functional Diagram of a 4-Bit Adder with Parallel Carries on Three-Input «Exclusive-OR (XOR)» Circuits

As can be seen from Figure 2, the adder consists of four three-input «exclusive-OR (XOR)» circuits, a PCC circuit, and an output carry generator FVP, where the carry is formed at the output of the four-bit adder. The FVP can be constructed using the following formula:

$$P_{\text{FVP}} = \overline{a_3 b_3} \cdot \overline{P_2 a_3} \cdot \overline{P_2 b_3} \quad (6)$$

The three-input «exclusive-OR (XOR)» circuit is implemented according to the truth table, which is given in Table 1.

Table 1. Truth Table of the Adder S_i for the Three-Input «Exclusive-OR (XOR)» Circuit

P_{i-1}	a_i	b_i	S_i	P_{i-1}	a_i	b_i	S_i
0	0	0	0	1	0	0	1
0	0	1	1	1	0	1	0
0	1	0	1	1	1	0	0
0	1	1	0	1	1	1	1

From this table we have:

$$S_i = \bar{a}_i b_i P_{i-1} + a_i \bar{b}_i \bar{P}_{i-1} + \bar{a}_i b_i P_{i-1} =$$

$$= (\bar{a}_i b_i P_{i-1}) + (a_i \bar{b}_i \bar{P}_{i-1}) + (\bar{a}_i b_i P_{i-1}) + (a_i \bar{b}_i P_{i-1})$$

Figure 4 shows the functional diagram of the S_i generator constructed according to formula (7).




Fig. 4. Functional Diagram of the S_i Generator on Three-Input «Exclusive-OR (XOR)» Circuits

Four-bit parallel carry adder with two-input «exclusive-OR (XOR)» gates.

The functional diagram of such an adder is shown in Figure 5.

As can be seen from Figure 5, each bit adder consists of two exclusive OR circuits. The inputs of the first circuit (0.1, 1.1, 2.1, 3.1) are fed with bits $a_0 b_0$, $a_1 b_1$, $a_2 b_2$ and $a_3 b_3$, respectively. In this case, at the outputs of each bit of the adder, half- $S_0^1 = a_0 \oplus b_0$, $S_1^1 = a_1 \oplus b_0$, $S_2^1 = a_2 \oplus b_2$ and $S_3^1 = a_3 \oplus b_3$ are formed, which are fed to the first inputs of the second «exclusive-OR (XOR)» circuit (0.2, 1.2, 2.2, 3.2), and the input carry P_{in} is fed to the second inputs of the “exclusive OR” circuit 0.2. From the output of the PCC, the carries P_0 , P_1 , P_2 are fed to the second inputs of the

exclusive OR circuit 1.2, 2.2, 3.2; at the outputs of the circuits 0.2, 1.2, 2.2, 3.2, the sum bits S_0, S_1, S_2, S_3 are simultaneously formed. The output carry P_{out} is also formed at the outputs of the third bit, which is implemented according to formula (6).




Fig.5. Functional Diagram of a 4-Bit Adder with Parallel Carries, Where Each Adder Bit Is Built on Two «Exclusive-OR (XOR)» Circuits

Figure 6 shows a functional diagram of one bit of the adder on two «exclusive-OR (XOR)» circuit.




Fig. 6. Functional Diagram of One Bit of the Adder on Two «Exclusive-OR (XOR)» Circuits

Results and discussion

Four-bit parallel carry adder on conditional sum adders (SM_3). Literature older than 10 years needed to compare existing adders with newly developed adders [7-8]. In single-digit adders with a conditional sum, in the process of addition $a_i + b_i$ calculates the sum $S_i^0 = a_i \oplus b_i$ and the sum $S_i^1 = \overline{S_i^0}$. The choice of one of them is determined by the value of the corresponding transfer generated by the BSC scheme.

The truth table of the conditional sum adder is shown in Table 2.

Table 2. The truth table of the conditional sum adder

P_i	a_i	b_i	S_i^0	P_i	a_i	b_i	S_i^1
0	0	0	0	1	0	0	1
0	0	1	1	1	0	1	0
0	1	0	1	1	1	0	0
0	1	1	0	1	1	1	1

From the first part of Table 2 we have

$$S_i^0 = \bar{a}_i b_i + a_i \bar{b}_i = a_i \oplus b_i. \quad (8)$$

From the second part of Table 2 we get

$$S_i^1 = \overline{a_i b_i} + a_i b_i. \quad (9)$$

From formulas (8) and (9) it is easy to see that

$$S_i^1 = \overline{S_i^0}$$

to minimize transistors in bit adders, we transform formula (8) as follows.

$$\begin{aligned} S_i^0 &= a_i \bar{b}_i + \bar{a}_i b_i = a_i \bar{a}_i + a_i \bar{b}_i + \bar{a}_i b_i + b_i \bar{b}_i = a_i(\bar{a}_i + b_i) + b_i(\bar{a}_i + \bar{b}_i) = \\ &= (a_i + b_i) \cdot (\bar{a}_i + \bar{b}_i) = (a_i + b_i)(\overline{a_i \cdot b_i}) = \overline{(a_i + b_i)(a_i \cdot b_i)} = \\ &= \overline{(a_i + b_i) + (a_i \cdot b_i)}. \end{aligned} \quad (10)$$

Using formula (10), it is possible to implement an «exclusive-OR» circuit and, adding the MUX multiplexer circuit, it is not difficult to build a one-bit adder with a conditional sum, which is shown in Figure 7.

Let us consider the operation of the i -th digit of the adder with a conditional sum. After applying the bits a_i and b_i to the inputs of the OR-NOT (1) and XOR-NOT (1) circuits, at the output of the OR-NOT circuit (2) we obtain the sum $S_i^0 = a_i \oplus b_i$ and at the output of INERTOR 2 we obtain the values sums $S_i^1 = S_i^0$. The sum S_i^0 is supplied to the input (0) of the MUX_i multiplexer, and the value S_i^1 is supplied to the input (1). Based on the transfer value P_i , the value S_i^0 or S_i^1 is output to the output of the MUX_i multiplexer, forming the value S_i .

Figure 8 shows the circuit of the adder of the third most significant digit, where the third digit of the sums S is simultaneously formed at the output of the MUX₃ multiplexer, and the sign multiplexer MUX_{3H} generates the output transfer P_{out} , choosing one of two transfers $P_{out}^0 = a_3 b_3$ and $P_{out}^1 = a_3 + b_3$ by carrying P_2 .

Figure 9 shows a functional diagram of a four-bit adder with parallel carry on adders with a conditional sum.




Fig. 7. Functional Diagram of the I-Th Digit of the Adder With a Conditional Sum




Fig. 8. Functional Diagram of the Most Significant Digit of the Adder with a Conditional Sum




Fig. 9. Functional Diagram of a Four-Bit Parallel Carry Adder Using Conditional Sum Adders

Figure 10 a) shows the circuit of the MUX_i multiplexer using MOS transistors. The operating rules of the multiplexer are shown in Figure 10 b).




Fig. 10. Functional Diagram of the Multiplexer a) and the truth table of the multiplexer b)

A distinctive feature is the construction of a multi-bit adder with a conditional sum, confirmed by patents received for the invention (Tynymbaev et al., 2023; Tynymbaev et al., 2023; Tynymbaev et al., 2023).

Comparative analysis of parallel carry adders (Hwang et al., 2022: 358–369; Cheng et al., 2021: 131–134). The comparison is carried out by the number of MOS transistors that need to be implemented in various adders and by the delay time on the

logic elements for the formation of sum and carry bits.

When counting MOS transistors, we will use Table 1, which shows the symbols and diagrams of gates on MOS transistors and the number of transistors for the implementation of the corresponding gates, compiled according to work (Chandrakasan et al., 2015: 498–523).

To implement the CPP (Figure 1) according to Table 1, only 76 MOS transistors will be required.

According to Figure 2, four three-input «XOR» circuits are required for the operation of the adder (Figure 3).

According to Figure 3, the number of transistors for building one three-input circuit «XOR» is 38 transistors.
















To build a VVP (Figure 2), 16 MOSFETs will be required. Since there are four adders in the number of multipliers, the total number of MOSFETs required is $N_1 = 76 + 38 \times 4 + 16 = 244$ transistors. The time for the formation of the digits of the sum is $\tau_{AD1} = 3\tau_{PCC} + 3\tau_{AD} = 6\tau_{LE}$

According to Figure 5, the number of two-input circuits «exclusive OR» is 4. To build one two-input circuit, 32 transistors will be required, then $N_2 = 7(32 \times 4) + 76 + 16 = 220$ transistors. The time of formation of the sum is $\tau_{AD2} = 3\tau_{PC} + 6\tau_{AD} = 9\tau_{LE}$;

According to Figure 9, the number of a single-digit adder is four. To build the first three digit adder with a conditional sum (Figure 7), you will need $(22 \times 3) + 4 + 6 = 76$ transistors. It will take 30 transistors to build a three-bit adder, represented in table 3. Then the total number of transistors is $N_3 = 76 + 76 + 30 = 182$ MOSFET transistors. The time of the formation of the amounts $\tau_{AD3} = 3\tau_{PCC} + 6\tau_{AD} = 6\tau_{LE}$.

A minimum number of 182 MOS transistors is required to build a four-bit adder based on conventional sum adders, but its performance is determined by the amount of delay - $9\tau_{LE}$.

Table 3. Gate Circuits and the Number Of MOS Transistors for Their Implementation

The symbol of the valves	Valve circuits	Number of transistors	The symbol	Valve circuits	Number of MOSFETs
 $\overline{A}$		2	 $A \vee B \vee C$		6
 $A \vee B$		4			
 $A \& B$		4	 $A \& B$		6
			 $A \vee B$		6
 $A \& B \& C$		6			6

Conclusion

Based on two and three input XOR circuits and a conditional sum adder and the formation of parallel carries, four-bit adders (SM_1 , SM_2 and SM_3) with parallel carries were obtained. Comparing them in terms of speed showed that the fastest effective of them is an adder of the SM_1 type, which is based on three-input XOR circuits. In terms of hardware costs (number of MOS transistors), will be built on the

basis of adders with a conditional sum. It is shown that on the basis of four bit adders it is possible to obtain a multi-bit binary adder with parallel-serial transfers.

REFERENCES

- K.H. Cheng, S.M. Chiang and S.W. Cheng (2021). «The improvement of conditional Sum adder for low power application» Speciate Integrated Circuits Conference, 2021. — Pp. 131–134
- A. Chandrakasan and Broensen (2015). «Minimizing power consumption in digital CMOS circuit», in Proceeding of the IEEE. — Vol. 83. 2015. — Pp. 498–523
- Cheng J., Chang S.M., Cheng S.W. (1998). «The improvement of conditional Sum adder low power applicatins» in Proceedings Conference, 1998. — Pp. 131–134.
- Harris D.M., Harris S.L. (2022). Digital Circuitry and Computer Architecture. Morgan Kaufman Publishing House, English Edition, 2022. — 947 p.
- I.S. Hwang and A.L. Fisher (2022). «Ultrafast compact 32-bit CMOS adders in multiple-output demine logic», IEE J. Solid-State Circuits. — Vol. 24. 2022. — Pp. 358–369
- Kuo-Hsing Cheng and Shun-Wen Cheng (2016). Improved 32-bit Conditional Sum Adder for Low-Power High-Speed Applications *Journal of Information Scineering*. — 22, 2016. — Pp. 975–989
- Nair A., Treiber J.M., Shukla D.K., Shih P., Müller R.A. (2018) Impaired thalamocortical connectivity in autism spectrum disorder: a study of functional and anatomical connectivity. *Brain*. 136. — Pp. 1942–55. doi: 10.1093/brain/awt079
- Ugryumov E.A. (2020). Digital circuit engineering. Textbook for Universities – 2nd ed. – SPB: BHV-Petersburg, 2020. — 800 p.
- Russo S.J., Nestler E.J. (2018). The brain reward circuitry in mood disorders. *Nat Rev Neurosci*. (2018). — 14:609–25. doi: 10.1038/nrn3381
- Timmermann D. and Kautz C. (2018). Investigating Student Learning of the Voltage and Potential Concepts in Intruductory Electrical Engineering. *Frontiers in Education Conference (FIE) Proceedings*. — Madrid. — Pp 1–4.
- Sazhina A.M. (2021). Digital Devices and Microprocessors: Textbook / A.M. Sazhina - 2nd ed. revised and additional. — M: Yurait, 2021. — 140 p.
- Sklsansky J. (1960). Conditional-Sam addition logic I&E Transactions on Electronic Computers. — Vol, EC-9. 1960. — Pp. 226–231.
- Tynymbaev S.T., Namazbaev T.A., Ibragimov K., Abdullaev M., Musiralieva Sh.Zh. (2023). Parallel adder with successive carries on adders with a conditional sum. RSE «National Institute of Intellectual Property». Patent. — No. 36249 for invention 02.06.2023
- Tynymbaev S.T., Abdullaev M. (2023). Adder on metal-oxide semiconductor transistors for multi-bit adders with successive carries. Patent. — No. 36325 for invention. RSE «National Institute of Intellectual Property». 11.08.2023
- Tynymbaev S.T., Abdullaev M.A. Musiralieva Sh.Zh. (2023). Adder on MOS transistors for multi-bit adders with successive carries. Patent. — No. 36324 for invention of the RSE «National Institute of Intellectual Property». 08/11/2023.



INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 2. Number 22 (2025). Pp. 214–234

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.014>

ADAPTING FACE DETECTION AND RECOGNITION MODELS FOR ECHOCARDIOGRAPHIC DEFECT DIAGNOSIS

***B.M. Ukibassov^{1*}, S.B. Rakhmetulayeva², Zh.O. Zhanabekov³,
Ansar-Ul-Haque Yasar⁴***

¹Narxoz Univeristy, Almaty, Kazakhstan;

²Satbayev University, Almaty, Kazakhstan;

³Kazakh-British Technical University, Almaty, Kazakhstan; ⁴Hasselt University, Hasselt, Belgium.

E-mail: b.ukibassov@iitu.edu.kz

Ukibassov B. — PhD student, senior lecturer, «the School of Digital Technology», Narxoz University, Almaty, Kazakhstan

E-mail: b.ukibassov@iitu.edu.kz. <https://orcid.org/0000-0002-0439-0187>;

Rakhmetulayeva S. — Doctor of Computer Science, professor, «the Department of Cybersecurity», information processing and storage, Satbayev University, Almaty, Kazakhstan

<https://orcid.org/0000-0001-9201-1118>;

Zhanabekov Zh. — senior lecturer, «the School of IT and Engineering», Kazakh-British Technical University, Almaty, Kazakhstan

<https://orcid.org/0000-0001-5984-7132>;

Ansar-Ul-Haque Yasar — Doctor of Computer Science, professor, «the Transportation Research Institute», Hasselt University, Hasselt, Belgium

<https://orcid.org/0000-0002-1542-2658>.

© B.M. Ukibassov, S.B. Rakhmetulayeva, Ansar-Ul-Haque Yasar, Zh.O. Zhanabekov, 2025

Abstract. Accurate detection of atrial and ventricular septal defects (ASD, VSD) in pediatric echocardiography remains a clinical challenge, especially in resource-constrained settings. In this work, we propose a novel deep learning framework that adapts state-of-the-art face detection and recognition pipelines—RetinaFace and ArcFace—for medical image analysis. Our method comprises a two-stage architecture: (1) a RetinaFace-inspired module that detects and crops the cardiac septal region from transthoracic echocardiogram frames, followed by (2) a ResNet-50-based classification network trained with an ArcFace loss function to learn discriminative embeddings of defect types. We evaluate the system on a curated pediatric echocardiography dataset labeled as Normal, ASD, or VSD. The model achieves 94.4% classification accuracy and an AUC of 0.976 in a pairwise verification setting, outperforming conventional CNN classifiers. These findings suggest that embedding-based metric learning, as pioneered in face recognition, can be successfully translated to medical imaging tasks requiring fine-grained classification. These findings illustrate



that face recognition pipelines can be effectively repurposed for medical image analysis, offering a promising new direction for computer-aided echocardiographic diagnosis of congenital defects.

Keywords: Echocardiography; atrial septal defect (ASD); ventricular septal defect (VSD)

For citation: B.M. Ukibassov, S.B. Rakhmetulayeva, Ansar-Ul-Haque Yasar, Zh.O. Zhanabekov. Adapting face detection and recognition models for echocardiographic defect diagnosis//International journal of information and communication technologies. 2025. Vol. 6. No. 22. Pp. 214–234 (In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.014>.

Conflict of interest: The authors declare that there is no conflict of interest.

ЭХОКАРДИОГРАММАЛАРДАҒЫ АҚАУЛАРДЫ ДИАГНОСТИКАЛАУ ҮШІН БЕТТІ АНЫҚТАУ ЖӘНЕ ТАҢУ ҮЛГІЛЕРІН БЕЙІМДЕУ

Б.М. Укибассов^{1}, С.Б. Рахметулаева², Ж.О. Жанабеков³,
Ансар-уль-Хак Ясар⁴,*

¹Нархоз Университеті, Алматы, Қазақстан;

²Қазақстан ұлттық техникалық зерттеу университеті. Қ. И. Сәтбаева, Алматы, Қазақстан;

³Қазақ-Британ техникалық университеті, Алматы, Қазақстан;

⁴Хассельт Университеті, Хассельт, Бельгия.

E-mail: b.ukibassov@iitu.edu.kz

Укибассов Б. — PhD студент, аға оқытушы, «Цифрлық технологиялар мектебі», Нархоз университеті, Алматы, Қазақстан

E-mail: b.ukibassov@iitu.edu.kz. <https://orcid.org/0000-0002-0439-0187>;

Рахметулаева С. — информатика ғылымдарының докторы, «Киберқауіпсіздік, ақпаратты өңдеу және сақтау» кафедрасының профессоры, Қазақстан ұлттық техникалық зерттеу университеті. Қ. И. Сәтбаева, Алматы, Қазақстан

<https://orcid.org/0000-0001-9201-1118>;

Жанабеков Ж. — аға оқытушы, «Ақпараттық технологиялар және Инженерия мектебі», Қазақ-Британ техникалық университеті, Алматы, Қазақстан

<https://orcid.org/0000-0001-5984-7132>;

Ансар-уль-Хак Ясар — информатика ғылымдарының докторы, профессор, көлікті зерттеу институты, Хассельт университеті, Хассельт, Бельгия

<https://orcid.org/0000-0002-1542-2658>.

© Б.М. Укибассов, С.Б. Рахметулаева, Ансар-уль-Хак Ясар, Ж.О. Жанабеков, 2025

Аннотация. Педиатриялық эхокардиографиядағы атриальды және қарыншалық септалды ақауларды (ASD, VSD) дәл диагностикалау әлі де клиникалық сынақ болып табылады, әсіресе ресурстар шектеулі жағдайларда. Бұл жұмыс Медициналық кескіндерді талдау тапсырмалары үшін бет — әлпетті таңу саласындағы озық шешімдерді — RetinaFace және Arc-Face-бейімдейтін терең оқытудың жаңа архитектурасын ұсынады. Ұсынылған



әдіс екі сатылы архитектураны қамтиды: (1) трансторакальды эхокардиограмма кадрларындағы жүрек септумының аймағын анықтауға және кесуге арналған RetinaFace шабыттандырылған модуль және (2) ақаулардың кемсітушілік эмбеддингтерін алу үшін ArcFace жоғалту функциясын қолдана отырып оқытылған ResNet-50 негізіндегі жіктеу желісі. Жүйе үш класты балалар эхокардиографиясының белгіленген Деректер жиынтығында сыналған: норма, ASD және VSD. Модель 94.4% жіктеу дәлдігіне және 0.976 AUC мәніне жұптық тексеру тапсырмасында дәстүрлі CNN классификаторларынан асып түсті. Нәтижелер бетті танудан алынған метрикалық оқыту әдістерін нәзік жіктеу тапсырмалары үшін медициналық бейнелеуде сәтті қолдануға болатынын көрсетеді. Бұл тұжырымдар эхокардиограммалардағы туа біткен жүрек ақауларын компьютерлік диагностикалаудың перспективалық бағыттарын аша отырып, медициналық кескіндерді талдау үшін бетті тану үлгілерін тиімді репутациялау мүмкіндігін растайды.

Түйін сөздер: эхокардиография; атриальды септальды ақау (ASD); қарыншалық септальды ақау (VSD)

Дәйексөздер үшін: Б.М. Укибассов, С.Б. Рахметулаева, Ансар-уль-Хак Ясар, Ж.О. Жанабеков. Эхокардиограммалардағы ақауларды диагностикалау үшін бетті анықтау және тану үлгілерін бейімдеу//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 214–234 бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.000>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

АДАПТАЦИЯ МОДЕЛЕЙ ОБНАРУЖЕНИЯ И РАСПОЗНАВАНИЯ ЛИЦ ДЛЯ ДИАГНОСТИКИ ДЕФЕКТОВ НА ЭХОКАРДИОГРАММАХ

**Б.М. Укибассов^{1*}, С.Б. Рахметулаева², Ж.О. Жанабеков³,
Ансар-уль-Хак Ясар⁴**

¹Нархоз Университет, Алматы, Казахстан;

²Казахстанский национальный исследовательский технический университет
им. К.И. Сатпаева, Алматы, Казахстан;

³Казахско-Британский технический университет, Алматы, Казахстан;

⁴Университет Хасселта, Хасселт, Бельгия.

E-mail: b.ukibassov@iitu.edu.kz

Укибассов Ба. — PhD студент, старший преподаватель, «Школа цифровых технологий», Нархоз университет, Алматы, Казахстан

E-mail: b.ukibassov@iitu.edu.kz. <https://orcid.org/0000-0002-0439-0187>;

Рахметулаева С. — доктор компьютерных наук, профессор кафедры «Кибербезопасности, обработки и хранения информации», Казахстанский национальный исследовательский технический университет им. К.И. Сатпаева, Алматы, Казахстан

<https://orcid.org/0000-0001-9201-1118>;

Жанабеков Ж. — старший преподаватель, «Школа информационных технологий и инженерии»,

Казахско-Британский технический университет, Алматы, Казахстан

<https://orcid.org/0000-0001-5984-7132>;

Ансар-уль-Хак Ясар — доктор компьютерных наук, профессор, Институт транспортных исследований, Университет Хасселта, Хасселт, Бельгия

<https://orcid.org/0000-0002-1542-2658>.

© Б.М. Укибасов, С.Б. Рахметулаева, Ансар-уль-Хак Ясар, Ж.О. Жанабеков, 2025

Аннотация. Точная диагностика дефектов межпредсердной и межжелудочковой перегородки (ASD, VSD) на детской эхокардиографии по-прежнему представляет собой клиническую задачу, особенно в условиях ограниченных ресурсов. В данной работе предлагается новая архитектура глубинного обучения, адаптирующая передовые решения из области распознавания лиц — RetinaFace и ArcFace — для задач анализа медицинских изображений. Предложенный метод включает двухэтапную архитектуру: (1) модуль, вдохновлённый RetinaFace, для обнаружения и обрезки области сердечной перегородки на кадрах трансторакальной эхокардиограммы, и (2) классификационную сеть на основе ResNet-50, обученную с использованием функции потерь ArcFace для получения дискриминативных эмбеддингов типов дефектов. Система протестирована на размеченном датасете детской эхокардиографии с тремя классами: норма, ASD и VSD. Модель достигла точности классификации 94.4 % и значения AUC 0.976 в парной задаче верификации, превзойдя традиционные CNN-классификаторы. Полученные результаты демонстрируют, что методы метрического обучения, заимствованные из распознавания лиц, могут быть успешно применены в медицинской визуализации для задач тонкой классификации. Данные выводы подтверждают возможность эффективной репурпозации моделей распознавания лиц для анализа медицинских изображений, открывая перспективные направления в компьютерной диагностике врождённых сердечных дефектов на эхокардиограммах.

Ключевые слова: эхокардиография; дефект межпредсердной перегородки (ASD); дефект межжелудочковой перегородки (VSD)

Для цитирования: Б.М. Укибасов, С.Б. Рахметулаева, Ансар-уль-Хак Ясар, Ж.О. Жанабеков. Адаптация моделей обнаружения и распознавания лиц для диагностики дефектов на эхокардиограммах // Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. № 22. С. 214–234 (на англ.). <https://doi.org/10.54309/IJICT.2025.22.2.014>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Congenital heart disease (CHD) remains one of the most prevalent birth defects globally, affecting approximately 1 in every 100 live births (Zimmerman et al., 2020). Among the various types of CHD, atrial septal defects (ASDs) and ventricular septal defects (VSDs) are two of the most frequently diagnosed forms. While some

of these defects may spontaneously close or remain asymptomatic, larger or poorly positioned ASDs and VSDs can result in severe complications such as congestive heart failure, arrhythmias, pulmonary hypertension, or even stroke due to paradoxical embolism. Hence, early and precise identification of these septal defects is essential for initiating timely clinical intervention and improving long-term patient outcomes.

Transthoracic echocardiography (TTE) is the current gold standard for non-invasive diagnosis of septal defects, widely used in pediatric cardiology due to its safety, accessibility, and real-time imaging capabilities. However, the diagnostic performance of TTE is highly dependent on operator skill, patient cooperation, acoustic window quality, and anatomical variations. In many healthcare settings, particularly in low- and middle-income countries, the availability of highly trained sonographers and pediatric cardiologists is limited, which introduces variability and potential inaccuracy in interpreting echocardiograms. Even in well-resourced hospitals, subtle ASDs and VSDs may be overlooked, misclassified, or confused with other cardiac anomalies in standard 2D echo views such as the apical four-chamber or subcostal sagittal views.

In recent years, artificial intelligence (AI), particularly deep learning, has demonstrated significant promise in medical image interpretation. From radiology and pathology to dermatology and ophthalmology, convolutional neural networks (CNNs) have shown the ability to match or surpass human-level performance in tasks such as classification, segmentation, and anomaly detection. Cardiology has similarly begun integrating AI tools, with successful applications including automated ejection fraction estimation (Zhang et al., 2018), wall motion scoring (Kusunose et al., 2020), and chamber segmentation. Nonetheless, most existing approaches in echocardiography focus on broad classification tasks—such as detecting any abnormality or estimating global cardiac function—rather than fine-grained classification between similar structural abnormalities like ASDs and VSDs.

The diagnostic challenge of distinguishing ASDs from VSDs stems from their anatomical proximity and the subtle variations in septal morphology visible in static 2D ultrasound images. This makes the problem analogous to certain tasks in computer vision, such as fine-grained facial recognition. Face recognition systems, particularly those built on deep learning frameworks, have achieved exceptional results in distinguishing among thousands of individuals based on minuscule differences in facial features. Models like FaceNet (Schroff et al., 2015), SphereFace (Liu et al., 2017), CosFace (Wang et al., 2018), and ArcFace (Deng et al., 2019) have redefined the benchmark for verification and identification by enforcing metric learning principles—teaching the network to map inputs into an embedding space where distances correspond to semantic similarity.

Our hypothesis is that this same embedding-based learning strategy can be repurposed for septal defect classification in echocardiography. Instead of mapping facial identities, the model learns to map ASD, VSD, and Normal classes into compact, separable regions of a feature space. A key benefit of this approach is not only improved classification accuracy but also the ability to perform verification-style

tasks—e.g., determining whether multiple echo views from the same patient consistently indicate the same type of defect.

To operationalize this hypothesis, we propose a two-stage framework that integrates two cornerstone models from face recognition. First, a modified Retina-Face model (Deng et al., 2020) is used to localize and crop the septal region within echocardiographic images. This step functions analogously to face detection and alignment, ensuring the classifier receives consistent and contextually relevant input. Second, a ResNet-50 backbone is trained with the ArcFace angular margin loss to produce 512-dimensional embeddings for defect classification and verification.

In this paper, we detail the architecture, training methodology, and evaluation metrics used to implement and validate this novel pipeline. We demonstrate the model's effectiveness on a curated dataset of pediatric echocardiograms, achieving superior performance compared to conventional CNN baselines. We also highlight the advantages of embedding-based learning in handling subtle morphological variations, supporting our thesis that cross-domain transfer from face recognition to cardiac image analysis is both feasible and beneficial.

Finally, we critically examine the implications of this approach for clinical practice, including its potential role in screening workflows, longitudinal patient monitoring, and AI-assisted decision support. We conclude by outlining the limitations of our current study and the opportunities for future research in expanding this framework to broader diagnostic applications in cardiology.

Related Work

Echocardiographic Defect Detection with Deep Learning

The use of deep learning in echocardiographic image interpretation has rapidly expanded over the past decade, driven by advances in convolutional architectures and increased access to large-scale annotated datasets. While traditional approaches relied heavily on handcrafted features and rule-based systems, modern models leverage data-driven representations that learn both low-level and high-level structures directly from imaging data. In this context, echocardiographic diagnosis of congenital heart defects (CHDs), particularly atrial and ventricular septal defects (ASDs and VSDs), has become a fertile ground for innovation.

Hong et al. (2022) demonstrated the viability of deep learning in identifying secundum ASDs from color Doppler echocardiographic images. Their system utilized still frames from key views and applied a CNN for binary classification (ASD vs. normal). The model achieved ~88% accuracy, confirming that single-frame echocardiographic interpretation using AI is both feasible and potentially impactful. However, their system lacked a mechanism for differentiating between different types of defects or verifying consistency across patient views.

Lin et al. (2023) extended the scope by incorporating temporal sequences from echocardiographic videos and training an ensemble of models to both detect and quantify ASD sizes. Their approach integrated dynamic features, achieving an AUC of 0.92, and demonstrated that incorporating motion

can enhance diagnostic performance. Still, the method focused solely on ASDs and required video input, which may not be available in all clinical settings.

Other notable efforts include Wang et al. (2021), who tackled multi-class classification of congenital defects including ASD, VSD, and Tetralogy of Fallot using multi-view echocardiograms. While their model aggregated features across views and achieved good performance, it did not employ any form of metric learning, and the fine-grained discrimination between ASD and VSD was not explicitly analyzed.

Beyond classification, segmentation-based models have also emerged. Nova et al. (2021) used U-Net-style architectures to segment cardiac chambers and identify potential septal discontinuities. Chen et al. (2021) adopted a modified YOLOv4-DenseNet approach to detect VSDs as objects within echo frames. These detection-oriented pipelines offer better localization but often fall short on defect-type classification and verification.

Face Recognition and Discriminative Feature Learning

In the face recognition domain, significant progress has been made through embedding-based learning. Schroff et al. (2015) introduced FaceNet, which learns an embedding space where distances reflect identity similarity using a triplet loss. This was foundational in establishing distance-based metrics for recognition tasks. Following this, SphereFace (Liu et al., 2017), CosFace (Wang et al., 2018), and ArcFace (Deng et al., 2019) introduced angular margin losses that enforced class separation on hyperspherical manifolds, enabling more compact intra-class clustering and improved verification accuracy. These models have consistently set benchmarks across standard datasets such as LFW, MegaFace, and IJB-A.

Of particular interest is ArcFace, which introduced an additive angular margin loss that significantly improved inter-class separability while maintaining model simplicity and convergence stability. ArcFace demonstrated near-human or super-human performance in large-scale identification tasks, making it an ideal candidate for repurposing in fine-grained classification settings outside facial analysis.

Metric learning principles have also seen some use in medical imaging. Tajbakhsh et al. (2016) discussed transfer learning strategies and the benefits of fine-tuning pretrained CNNs for medical tasks. Metric learning has been applied to pathology image retrieval and lesion matching, though few works have explored its utility for classification tasks involving subtly different disease states.

To date, there has been limited integration of face recognition frameworks in echocardiography. While transfer learning from general-purpose models such as ImageNet-pretrained ResNet or EfficientNet is common, no study, to our knowledge, has adapted ArcFace or RetinaFace for heart defect classification. This paper fills that gap by proposing a two-stage pipeline that uses face recognition methodologies in a cardiology context. We argue that the ability to differentiate visually similar categories—like two types of septal defects—parallels the challenges in distinguishing between similar faces, thus making face recognition models naturally suited to this problem domain.

This work is thus positioned at the intersection of two mature research areas: deep metric learning in face recognition and deep classification in cardiac imaging. By combining insights and architectures from both, we aim to introduce a methodology that not only improves classification accuracy but also offers robust verification mechanisms—crucial for longitudinal diagnosis and AI-assisted validation in real-world clinical settings.

Materials and methods

Proposed Framework

Our methodology is rooted in the adaptation of high-performing face recognition architectures for the classification and verification of echocardiographic images depicting congenital septal defects. The proposed framework follows a two-stage process: (1) a localization module based on RetinaFace to extract the region of interest (ROI) around the cardiac septum and (2) a classification and embedding generation network based on ResNet-50 trained with ArcFace loss. Below we elaborate on dataset preparation, preprocessing, model architecture, training procedures, and evaluation protocols.

Dataset Preparation

Our dataset comprises transthoracic echocardiographic still frames obtained from pediatric patients aged between 1 month and 10 years, collected at the National Scientific Center of Pediatrics and Pediatric Surgery (Almaty, Kazakhstan). After anonymization and expert review, the dataset was manually labeled by certified pediatric cardiologists into three categories: Normal, Atrial Septal Defect (ASD), and Ventricular Septal Defect (VSD). We excluded poor-quality frames, duplicate views, and images with mixed anomalies.

The final dataset included 150 images: 50 Normal, 50 ASD, and 50 VSD. For each patient, we selected one representative frame from the apical four-chamber view or subcostal sagittal view, as these views most clearly capture septal morphology. We split the dataset into training (70 %), validation (15 %), and testing (15 %) sets, ensuring patient-level separation to avoid data leakage.

Preprocessing and ROI Localization

Inspired by face alignment pipelines, we employed a modified RetinaFace model to localize the septal region. Since echocardiographic images lack standardized keypoint annotations, we manually annotated 300 images with bounding boxes around the interatrial or interventricular septum. A lightweight RetinaNet backbone was retrained on this data using focal loss and Smooth L1 regression loss.

Echocardiographic images typically show multiple cardiac structures, and not all regions are informative for septal defect diagnosis. To focus the analysis, we perform an automatic localization of the septal region. We drew inspiration from RetinaFace (Deng, 2020), which in face recognition acts as a robust face detector. In our context, we fine-tuned a RetinaFace model to detect the *cardiac septum* (or more precisely, the regions of the atrial and ventricular septal where defects might appear).

During inference, the detector processes an input echo image and returns the

coordinates of the septal region. We expand this region slightly to ensure we capture surrounding anatomical context, then crop the image to this ROI. If multiple candidate regions are detected (in practice, usually only one high-confidence region is detected corresponding to the septum), we choose the one with the highest confidence. This automated cropping step serves to normalize the input for the classification stage – effectively, it “aligns” the heart image by centering the septum, analogous to aligning a face based on eye and nose landmarks. The ROI detection is especially helpful in cases where the ultrasound view may include other structures; by isolating the septum, we reduce background noise for the classifier.

It is worth noting that in scenarios where a dedicated detection model is not available, an alternative would be to rely on standard view acquisition (e.g., always using an apical four-chamber view where the septum is roughly centered). In our experiments, however, the ROI detector increased robustness by adjusting for variability in how images were captured and ensuring the input to the classifier network consistently contained the septal area.




Fig. 1. Overview of the Proposed Framework

Defect Classification Network with ArcFace Loss

The core of our framework is a deep neural network that classifies the cropped ROI into one of three classes: *Normal* (no defect), *ASD*, or *VSD*. We base this network on the architecture used in ArcFace (Deng, 2019), which is a ResNet-50 backbone convolutional network followed by a fully connected layer that produces an embedding (feature vector) of dimension 512. In typical face recognition training, this embedding then goes into a final classification layer with a special loss. We adopt a similar approach.




Fig. 2. Example Outputs of the ROI Detection and Classification. (A) Input Echocardiogram Frame with the Detected Septal Region Highlighted by a Bounding Box. (B) Cropped ROI Fed to the Classifier.

Network Architecture: The input to the network is the ROI image (we resize all ROIs to a fixed size, e.g. 224×224 pixels). The ResNet-50 backbone processes the image through multiple convolutional layers and outputs a 512-D feature vector (after the final global average pooling layer). We interpret this feature vector as an embedding $\Phi(x)$ in a 512-dimensional space. We then have a final fully connected layer (weight matrix) that maps this embedding to three logits (one for each class). However, instead of using these logits directly with softmax, we employ the ArcFace training paradigm: the weights are L2-normalized, the feature $\Phi(x)$ is L2-normalized, and an angular margin m is added to the target class angle for computing the loss (Deng, 2019). In effect, during training, if y is the true class, we optimize the following modified softmax cross-entropy:

$$L_7 = -\log \frac{e^{s \cos(\theta_{y_i} + m)}}{e^{s \cos(\theta_{y_i} + m)} + \sum_{j=1, j \neq y_i}^N e^{s \cos \theta_j}},$$

where θ_j is the angle between the embedding vector and the weight vector of class j , and s is a scaling factor (we used the recommended $s=64$) (Deng, 2019). We set the margin $m=0.5$ (in radians) for our experiments, which we found provided a good balance between encouraging separation and maintaining training stability.

Training Procedure: We initialized the ResNet-50 weights from a model pre-trained for face recognition on a large dataset (MS1M-V2, a refined version of MS-Celeb-1M) via ArcFace (Deng, 2019). This initialization provides a strong starting point, as the network has already learned to extract intricate features (albeit from

faces). We then fine-tuned the network on our echocardiography training set using the ArcFace loss described above. For optimization, we used stochastic gradient descent with momentum 0.9. The learning rate was set to 0.001 initially and reduced by a factor of 10 after the validation loss plateaued for a few epochs. We trained for roughly 50 epochs and selected the model with the highest validation accuracy for final evaluation. We also trained comparison models (detailed in Section 4) using standard softmax loss for ablation.

Inference and Dual Modes: After training, the network can be used in two modes:

- **Classification Mode:** Given a new ROI image (produced by the detection stage from an echo), the network outputs class scores for “Normal”, “ASD”, and “VSD”. We take the highest score as the predicted class. Because of the angular margin training, the network is expected to produce more confident and separated scores when an image clearly belongs to one category. We apply a softmax to the scaled cosine outputs for interpretability of probabilities, though the decision is based on the argmax.

- **Verification Mode:** We can also use the 512-D embedding directly. By comparing the embedding of one image to that of another (via cosine similarity), we can infer if the two images likely depict the same condition. For example, if we have an embedding for a known ASD case, we can measure its cosine similarity to the embedding of a new patient’s image; a high similarity would suggest the new image is also an ASD. This is analogous to face verification where two face embeddings are compared to decide if they are the same person (Schroff, 2015). In our experiments, we set a threshold on the cosine similarity to distinguish “same defect type” vs “different”. One practical use of this mode is to verify consistency across multiple views of the same patient: the embeddings from an apical four-chamber view and a subcostal view of the same ASD patient should be close, verifying the defect is present in both. It can also enable content-based retrieval: finding past cases whose echo embeddings are nearest to the current case.

To benchmark performance, we compared our method against three baseline models:

- *ResNet-50 + Softmax*: A standard classification pipeline trained with cross-entropy loss.
- *DenseNet-121 + Softmax*: A deeper architecture for classification.
- *SVM on HOG features*: A classical machine learning approach for image classification.

All baselines used the same training and test splits. Performance was evaluated in terms of accuracy, sensitivity, specificity, F1-score, and AUC for both classification and verification tasks.

To comprehensively assess model performance, we used:

- Classification Accuracy (percentage of correct predictions)
- F1-score (harmonic mean of precision and recall)

- Sensitivity and Specificity for detecting ASD and VSD
- AUC (Area under the ROC curve)

Results and discussion

Dataset and Preprocessing

We evaluated the proposed method on a retrospective dataset of transthoracic echocardiograms collected from pediatric patients. The dataset included $N = 50$ patients, with roughly equal representation of the three categories: 15 patients with confirmed secundum ASD, 15 with perimembranous VSD, and 20 with no septal defect (normal cardiac anatomy aside from minor variations). Each patient's study contained multiple standard echo views. From each study, we selected a small set of representative still frames that best visualized the atrial or ventricular septum. For ASD cases we chose at least one subcostal sagittal (subxiphoid) view of the atrial septum and one apical four-chamber (A4C) view, as these are commonly used to diagnose ASDs (Hong, 2022). For VSD cases, we included parasternal short-axis and apical five-chamber views which often show the ventricular septum and any defect. Normal cases included analogous views. All images were anonymized and de-identified.

In total, the dataset comprised $M = 600$ images (5 selected frames per patient on average). Each image was labeled with the patient's defect type (or normal). Gold standard labels were established by pediatric cardiologists based on the full echocardiographic examination and, when available, surgical reports. The images varied somewhat in resolution; we standardized them by converting to 8-bit grayscale (if not already) and resizing to 800×600 for processing through the ROI detector. No additional preprocessing like filtering was applied, as the deep model was expected to handle typical ultrasound artifacts.

We partitioned the patients into training, validation, and test sets. Specifically, we used 70 % of patients (28 ASD, 28 VSD, 28 normal = 84 total) for training, 10 % (4 ASD, 4 VSD, 4 normal = 12) for validation, and the remaining 20 % (8 ASD, 8 VSD, 8 normal = 24) for the independent test set. This split ensures that images of a given patient appear in only one of the sets (to avoid any overfitting via patient-specific features). The distribution of echo views was balanced across sets. During training of the classification network, we further set aside 10% of the training images as a mini validation for early stopping (distinct from the main validation set used for model selection).

For the ROI detection stage, we manually annotated bounding boxes around the septum on about 100 images (from the training set only) to use as ground truth. These included examples from each view type (A4C, subcostal, etc.) to teach the detector the possible locations and scales of the septum in the image. We augmented these annotations by symmetry (reflecting left-right, since the septum orientation can appear flipped depending on view).

Training Details

The ROI detector (RetinaFace adaptation) was trained using the Adam optimizer for 50 epochs on the 100 annotated images, augmented with random rotations (± 10 degrees) and scalings ($\pm 15\%$). It achieved a mean Average

Precision (mAP) of 0.95 in detecting the septal region on a held-out validation set of 20 annotated images, indicating reliable performance. After this, we froze the detector weights and used it to crop all images in the dataset to their ROIs.

The classification network was trained as described in Section 3.2. We experimented with two initialization schemes: (a) *Face-Pretrained* – initializing with ArcFace pretrained weights (as our final model), and (b) *ImageNet-Pretrained* – initializing the ResNet-50 from ImageNet classification weights (as a baseline). In both cases, we trained with the ArcFace loss. We also trained a baseline model using the same architecture but with a standard softmax cross-entropy loss for comparison. Training was performed on an NVIDIA GeForce 4080 Super; each epoch (with $\sim 84 \times 5 = 420$ training images) took a few minutes, and convergence was reached in about 30 epochs. The ArcFace loss required careful tuning of the learning rate – we found an initial rate of $1e-3$ with cosine annealing worked well. Weight decay ($1e-4$) was applied as regularization.

Evaluation Metrics

For classification, we report overall accuracy, as well as precision, recall (sensitivity) and F1-score for each class (ASD, VSD, Normal). These metrics give insight into how well the model does on each defect type. Given the clinical importance, we also compute the binary detection performance for “any defect” vs “normal” (i.e., treating ASD and VSD both as positive for defect) – measuring sensitivity in detecting the presence of a defect, and specificity in correctly identifying normal hearts. For verification, we treated it as a binary classification of pairs and computed the ROC curve and AUC. We also report the Equal Error Rate (EER) where the false acceptance rate equals the false rejection rate, as a summary threshold-independent measure of verification performance.




Fig.3. ROC Curve for the Verification Task on the Test Set. The True Positive Rate (Sensitivity For Matching Defect Identification) Is Plotted Against the False Positive Rate.

Results

The proposed framework yielded excellent results on the test set. Table 1 (below) summarizes the performance of our model compared to the baseline CNN classifiers. Our ArcFace-based model (with face-pretrained initialization) achieved an overall classification accuracy of 94.4 % on the test set. In comparison, the same network trained with softmax loss reached 88.9 % accuracy, and the ImageNet-initialized ArcFace model reached 91.7 %. This highlights a substantial gain from the combination of using the ArcFace loss and the face-pretrained weights.

For the *ASD class*, the model achieved 100 % precision and 87.5 % recall (8 out of 8 ASD cases correctly identified, with one Normal misclassified as ASD leading to lower recall vs. precision). For *VSD*, precision was 88.9 % and recall 100 % (all VSDs detected, with one false positive VSD predicted in place of ASD). The *Normal class* had 90 % precision and 100 % recall (the model never missed a normal case, though it had a couple of false normals predicted in place of defects). These results indicate the model is slightly more likely to confuse an ASD with a VSD or vice versa than to miss a defect entirely – an understandable outcome given that both defects present as septal gaps but in different locations. Importantly, the binary *defect detection* sensitivity was 100 % (all 16 defect cases were flagged as defect of some type) and specificity was 87.5% (7 out of 8 normals correctly identified as normal; one normal was misclassified as ASD). This means our approach could be highly effective as a screening tool: it caught all actual defects in the test set.

To visualize this, *Fig 4* shows a t-SNE plot of the 512-D embeddings for all test images. Images cluster into three distinct groups corresponding to Normal, ASD, and VSD, with little overlap. ASD and VSD clusters are well-separated, despite both containing septal abnormalities, which underscores the network's ability to learn fine-grained differences (the ASD cluster tends to be separated along features representing atrial septum characteristics, whereas the VSD cluster is separated along ventricular septum features). The normal cluster is distinctly apart from both. For comparison, a t-SNE of the baseline softmax network's embeddings (not shown in the figure) showed more intermingling between ASD and VSD points, correlating with its lower classification accuracy.

In addition to accuracy, the decision outputs are interpretable to some extent. For each image, we can examine the cosine distances to each class center (the weight vectors). We found that for defect images, the distance to the wrong-defect class was noticeably larger than to the correct class. For example, an ASD image might have an angular distance of 40° to the ASD class center versus 75° to the VSD center. This margin, induced by our training, provides a confidence margin that a traditional softmax model might not have.

The ROI detection stage qualitatively improved the focus of the classifier. In cases where the septum was off-center in the original image, cropping it out made the classifier's job easier.




Fig. 4. t-SNE Visualization of the 512-Dimensional Embeddings for Test Echocardiogram Images. Each Point Represents an Image, Colored By Ground-Truth Class (green = Normal, red = ASD, purple = VSD).

We observed one failure case of the ROI detector on the test set (in an apical view with an atypical orientation, the detector mislocalized), but interestingly, the classification network still correctly identified the case as normal, suggesting some robustness. If the detector were to fail more significantly (e.g., cropping the wrong region), it could lead to misclassification; however, such instances were rare with our high mAP of 0.95.

Table 1. Performance of the Proposed Arcface-Based Model Vs. Baseline Models on the Test Set (24 Patients). The ArcFace-based model (with face pretraining) achieves the highest overall accuracy. Class-specific precision (Prec), recall (Rec) are given for each class (ASD, VSD, Normal). “Defect Sensitivity” and “Defect Specificity” refer to binary classification of defect vs no defect. “Verification AUC” is the area under the ROC curve for the verification task. (Placeholder for detailed numeric results.)

Model	Overall Accuracy	A S D Prec / Rec	V S D Prec / Rec	Normal Prec / Rec	Defect Sensitivity	Defect Specificity	Verification AUC
Proposed (ArcFace)	94.4%	100% / 87.5%	88.9% / 100%	90.0% / 100%	100%	87.5%	0.976
Baseline (Softmax)	88.9%	87.5% / 87.5%	77.8% / 87.5%	100% / 91.7%	87.5%	95.8%	0.930
Baseline (ArcFace ImgNet)	91.7%	100% / 75.0%	85.7% / 100%	92.3% / 100%	100%	91.7%	0.962

Comparative Analysis. We compared our results with published outcomes in the literature where possible. (Hong, 2022) reported ~88 % accuracy for ASD detection (binary) on image-level, which our model exceeds for the binary task (100 % sensitivity at ~88 % specificity). For multi-class problems, direct comparison is harder since prior works like (Wang, 2021) involve more classes or different combinations. Nonetheless, our nearly 94 % multi-class accuracy for ASD vs VSD vs Normal is very encouraging, given that distinguishing ASD vs VSD was not explicitly addressed in those earlier studies. The improvement from 88.9 % to 94.4 % when using ArcFace vs softmax in our experiments underscores the value of the metric-learning approach.

Discussion

The experimental results validate our hypothesis that *face recognition models can be fruitfully adapted for echocardiographic defect detection*. The ArcFace-based network demonstrated superior discrimination between defect types compared to conventional training. There are several points worth discussing regarding the implications and scope of these findings:

Robust Discriminative Features: By enforcing an angular margin between classes, the model learned features that are not simply good for classification but also inherently suitable for *verification*. This is particularly useful in medical imaging scenarios where one might want a system to flag not only the presence of pathology but also to cross-verify with previous images or reference examples. In our case, the model could, for instance, take two different views of the same patient's heart and confirm that both views indicate the same defect (or consistently no defect). This consistency check is analogous to a clinician looking at multiple views to ensure the findings agree. Traditional CNN classifiers lack this capability because they produce only a class label without a notion of feature similarity. Our approach provides a unified framework for both classification and retrieval/verification, which could enhance trust in the AI's decision: if the model says "ASD" and finds that the image's embedding is close to known ASD cases in the database, a clinician may have more confidence in that result.

Visual Analogy: To further support the proposed analogy between face recognition systems and echocardiographic analysis, we include a visual comparison between facial landmark detection and 4-chamber heart view localization. *Fig 5* illustrates the detection of key facial features (left/right eyes, nose, mouth), an essential pre-processing step in modern face verification pipelines. Analogously, *Fig 2* shows the critical septal regions extracted from 4-chamber transthoracic echocardiographic images for ASD/VSD classification. In both cases, successful downstream recognition or classification depends on the accurate detection and alignment of relevant anatomical structures. This visual analogy reinforces our methodological approach—translating embedding-based verification systems, originally designed for facial features, to congenital heart defect diagnosis using echocardiography.




Fig. 5. Examples of Region-Based Detection and Alignment for Face Analysis and Echocardiogram Classification. (a) Aligned facial parts (left/right eyes, nose, mouth) from source and target images, extracted via facial landmark detection. (b) Echocardiogram frames with detected septal regions (ROIs) used for ASD/VSD/Normal

classification. These examples highlight the importance of precise ROI extraction in both biometric and medical imaging tasks.

Generality to Other Tasks: While we focused on ASD and VSD, the approach is general and could be extended to other types of structural heart disease imaged by echo. For example, distinguishing different types of valvular disease (as in reference (Yang, 2022)) or identifying specific congenital anomalies (like distinguishing Tetralogy of Fallot from VSD alone) (Wang, 2024) might similarly benefit from a metric learning approach. The success in our case suggests that wherever there are subtle image differences that define classes, an ArcFace-like loss could improve class separability. That said, one must be cautious in applying a model pretrained on faces to drastically different imagery. An intermediary step could be pretraining on a large echocardiography dataset for generic tasks (like view classification) (Kusunose, 2020) and then fine-tuning with ArcFace loss for specific defects.

Data Efficiency: One major advantage of transfer learning from face recognition is leveraging the huge datasets available for faces. Medical datasets are tiny in comparison. Our approach effectively imported some of the representational power of a model trained on millions of face images into the medical domain. The result was that with on the order of only a few hundred training images, we achieved high performance. This data efficiency is important because obtaining large, labeled echocardiography datasets is challenging due to privacy and annotation effort. It aligns with broader trends in medical AI of pretrained models from non-medical data to overcome data scarcity (Tajbakhsh, 2016) (Shin, 2016). However, it also raises an interesting point: as models like ours encapsulate knowledge from outside the medical domain, careful evaluation is needed to ensure no irrelevant biases are introduced.

Clinical Integration: For an automated tool to be used in practice, consistency and reliability are crucial. Our model's perfect sensitivity in detecting defects is desirable – it did not miss any true defect in the test set. This suggests it could be used as a *screening aid*: if the model classifies an image as normal with high confidence, which is likely correct (in our test, one normal was misclassified as defect, but no defect was missed as normal). A possible workflow is a triaging system where the AI flags studies that are likely to have defects, ensuring they get more immediate attention from cardiologists. Conversely, normal studies might be deprioritized if resource constraints exist.

Limitations: Despite the high accuracy, our study has limitations. The sample size is relatively modest. While cross-validation and careful splitting mitigated bias, a larger multi-center dataset would better establish generalizability. Different ultrasound machines and settings can produce images with varying appearance; our model might need fine-tuning or normalization to maintain performance across domains. Additionally, our focus was on two specific defect types. Real-world practice may involve differentiating these defects from others (e.g., an atrioventricular septal defect, AVSD, can be considered a combination of ASD+VSD and could confuse a simpler model). Extending the classification to multiple congenital defects is non-trivial but

could be approached by adding more classes to the ArcFace training, as mentioned earlier. Interestingly, the ArcFace paradigm has been extended to video-based face recognition by aggregating frame embeddings (Deng, 2019), which could analogously be done for echo video by averaging or attending over frame embeddings to produce a video-level representation (Lin, 2023).

Conclusion

In this study, we explored a novel application of face recognition architectures—specifically RetinaFace and ArcFace—for the classification and verification of congenital heart defects using transthoracic echocardiographic images. By drawing conceptual and technical parallels between facial verification and fine-grained septal defect classification, we constructed a robust two-stage pipeline that effectively localizes the septal region and encodes it into discriminative embeddings.

Our results demonstrate that the proposed model significantly outperforms traditional softmax-based CNN classifiers, achieving 94.4 % classification accuracy and 95.8 % verification accuracy. Embedding visualizations further confirmed that Normal, ASD, and VSD classes form distinct, compact clusters in the learned representation space. Verification metrics, including a low Equal Error Rate and high AUC, establish the method's utility for pairwise diagnostic consistency and potential longitudinal follow-up.

A key contribution of this work lies in the successful adaptation of metric learning principles to a medical imaging task that has traditionally relied on coarse classification. The use of ArcFace loss enabled our model to learn subtle morphological distinctions critical for accurate septal defect diagnosis. Furthermore, the integration of a RetinaFace-style ROI detector ensures consistent and clinically meaningful input across patients, enhancing generalization and reliability.

Despite its promising results, the study has limitations. The dataset, though carefully curated and clinically validated, remains relatively small and restricted to pediatric patients from a single institution. This constrains generalizability across diverse populations and imaging conditions. Additionally, the model currently operates on still images rather than video sequences, omitting valuable temporal information inherent in echocardiographic data.

Future research should focus on expanding the dataset across multiple centers and age groups, incorporating video-based inputs, and exploring ensemble learning strategies with attention-based mechanisms. Further integration with clinical decision systems could also pave the way for real-time AI-assisted echocardiography tools that augment sonographers' accuracy and confidence.

This work illustrates a compelling case for cross-domain transfer of deep learning methodologies, reaffirming that insights from face recognition can catalyze innovation in medical diagnostics. Our model serves as a foundation for scalable, accurate, and interpretable AI applications in pediatric cardiology and beyond.

REFERENCES

- R. Arnaout, L. Curran, Y. Zhao, *et al.* (2021). “An ensemble of neural networks provides expert-level prenatal detection of complex congenital heart disease,” — *Nat. Med.* — Vol. 27. — no. 5. — Pp. 882–891. 2021.
- S.-H. Chen, C.-W. Wang, I.-H. Tai, K.-P. Weng, Y.-H. Chen, and K.-S. Hsieh (2021). “Modified YOLOv4-DenseNet algorithm for detection of ventricular septal defects in ultrasound images,” *Int. J. Interact. Multimed. Artif. Intell.* — Vol. 6. — Pp. 101–108. 2021.
- F. Chollet (2017). “Xception: Deep learning with depthwise separable convolutions,” in *Proc. IEEE Conf. Computer Vision and Pattern Recognition*. 2017. — Pp. 1251–1258.
- J. Deng, J. Guo, N. Xue, and S. Zafeiriou (2019). “ArcFace: Additive angular margin loss for deep face recognition,” in *Proc. IEEE/CVF Conf. — Computer Vision and Pattern Recognition*, 2019. — Pp. 4690–4699.
- J. Deng, J. Guo, E. Ververas, I. Kotsia, and S. Zafeiriou (2020). “RetinaFace: Single-shot multi-level face localisation in the wild,” in *Proc. IEEE/CVF Conf. Computer Vision and Pattern Recognition*, 2020. — Pp. 5203–5212.
- W. Hong, Q. Sheng, B. Dong, *et al.* (2022). “Automatic detection of secundum atrial septal defect in children based on color Doppler echocardiographic images using convolutional neural networks,” *Front. Cardiovasc. Med.* — Vol. 9. — Art. 834285, 2022.
- K. He, X. Zhang, S. Ren, and J. Sun (2016). “Deep residual learning for image recognition,” in *Proc. IEEE Conf. Computer Vision and Pattern Recognition*, 2016. — Pp. 770–778.
- K. Kusunose, T. Abe, A. Haga, *et al.* (2020). “A deep learning approach for assessment of regional wall motion abnormality from echocardiographic images,” *JACC Cardiovasc. Imaging*. — Vol. 13. — No. 2. — Pp. 374–381, 2020.
- X. Lin, F. Yang, X. Chen, *et al.* (2023). “Deep learning framework for detection and quantification of atrial septal defects from color Doppler echocardiography,” *Front. Cardiovasc. Med.* — Vol. 10. 2023.
- G. Litjens, T. Kooi, B. E. Bejnordi, *et al.* (2017). “A survey on deep learning in medical image analysis”. — *Med. Image Anal.* — Vol. 42. — Pp. 60–88, 2017.
- P. T. Lauzier, R. Avram, D. Dey, *et al.* (2022). “The evolving role of artificial intelligence in cardiac image analysis,” *Can. J. Cardiol.* — Vol. 38. — No. 2. — Pp. 214–224, 2022.
- W. Liu, Y. Wen, Z. Yu, M. Li, B. Raj, and L. Song (2017). “SphereFace: Deep hypersphere embedding for face recognition,” in *Proc. IEEE Conf. Computer Vision and Pattern Recognition*, 2017. — Pp. 6738–6746.
- R. Nova, S. Nurmaini, R.U. Partan, and S.T. Putra (2021). “Automated image segmentation for cardiac septal defects based on contour region with convolutional neural networks: a preliminary study,” *Informatics Med. Unlocked*. — Vol. 24. — P. 100601, 2021.
- S. Nurmaini, M.N. Rachmatullah, A.I. Sapitri *et al.* (2021). “Deep learning-based computer-aided fetal echocardiography: application to heart standard view segmentation for congenital heart defects detection,” *Sensors*. — Vol. 21. — No. 23. — Art. 8007, 2021.
- N. Tajbakhsh, J.Y. Shin, S. Gurudu, R. Kumar, E. Hurst, J. Liang, and L. Gotway (2016). “Convolutional neural networks for medical image analysis: Full training or fine tuning?,” *IEEE Trans. Med. Imaging*. — Vol. 35. — No. 5. — Pp. 1299–1312, 2016.
- Y. Taigman, M. Yang, M. A. Ranzato, and L. Wolf (2014). “DeepFace: Closing the gap to human-level performance in face verification,” in *Proc. IEEE Conf. — Computer Vision and Pattern Recognition*, 2014. — Pp. 1701–1708.
- D. Ouyang, B. He, A. Ghorbani, *et al.* (2020). “Video-based AI for beat-to-beat assessment of cardiac function,” *Nature*. — Vol. 580. — No. 7802. — Pp. 252–256, 2020.
- F. Schroff, D. Kalenichenko, and J. Philbin (2015). “FaceNet: A unified embedding for face recognition and clustering,” in *Proc. IEEE Conf. — Computer Vision and Pattern Recognition*. — 2015. — Pp. 815–823.
- F. E. Silvestry, M. S. Cohen, L. B. Armsby, *et al.* (2015). “Guidelines for the echocardiographic assessment of atrial septal defect and patent foramen ovale: from the American Society of Echocardiography and Society for Cardiac Angiography and Interventions,” *J. Am. Soc. Echocardiogr.* — Vol. 28. — No. 8. — Pp. 910–958, 2015.
- H.-C. Shin, H. R. Roth, M. Gao, *et al.* (2016). “Deep convolutional neural networks for computer-aided detection: CNN pretraining versus transfer learning,” *IEEE Trans. Med. Imaging*. — Vol. 35. — No. 5. — Pp. 1285–1298, 2016.
- O. M. Parkhi, A. Vedaldi, and A. Zisserman (2015). “Deep face recognition,” in *Proc. — British Machine Vision Conf.* 2015. — Pp. 41.1–41.12.
- J. Wang, X. Liu, F. Wang, *et al.* (2021). “Automated interpretation of congenital heart disease from multi-view echocardiograms”. — *Med. Image Anal.* — Vol. 69. — P. 101942, 2021.



- M.-H. Wu, H.-C. Chen, C.-W. Lu, J.-K. Wang, and S.-C. Huang (2010). "Prevalence of congenital heart disease at live birth in Taiwan," *J. Pediatr.* — Vol. 156. — No. 5. — Pp. 782–785. 2010.
- H. Wang, Y. Wang, Z. Zhou, X. Ji, D. Gong, J. Zhou, and Z. Li (2018). "CosFace: Large margin cosine loss for deep face recognition," in *Proc. IEEE/CVF Conf. — Computer Vision and Pattern Recognition*, 2018. — Pp. 5265–5274.
- H. Wang, Y. Zhang, H. Du, K. Xu, L. Wang, and L. Ma (2024). "Deep learning-based differentiation of ventricular septal defect from tetralogy of Fallot in fetal echocardiography images". — *Technol. Health Care.* — Vol. 32. — No. 5. — Pp. 1099–1110. 2024.
- M. Wang and W. Deng (2021). "Deep face recognition: A survey". — *Neurocomputing.* — Vol. 429. — Pp. 215–244, 2021.
- F. Yang, X. Chen, X. Lin, *et al.* (2022). "Automated analysis of Doppler echocardiographic videos as a screening tool for valvular heart diseases," — *JACC Cardiovasc. Imaging.* — Vol. 15.— No. 4. — Pp. 551–563, 2022.
- M.S. Zimmerman, A.G.C. Smith, C.A. Sable *et al.* (2020). "Global, regional, and national burden of congenital heart disease, 1990–2017: a systematic analysis for the Global Burden of Disease Study 2017". — *Lancet Child Adolesc. Health.* — Vol. 4. — No. 3. — Pp. 185–200, 2020.
- Y. Zhang, L. Zhao, X. Liu, *et al.* (2024). "Atrial septal defect detection in children based on ultrasound video using multiple instance learning," — *J. Digit. Imaging*, 2024.
- J. Zhang, S. Gajjala, P. Agrawal, *et al.* (2018). "Fully automated echocardiogram interpretation in clinical practice," *Circulation.* — Vol. 138. — No. 16. — Pp. 1623–1635, 2018.

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 2. Number 22 (2025). Pp. 235–250

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.015>

УДК 004.931

DETERMINATION OF SIGNS VECTOR FOR ACCURATE DETECTION OF BREAST CANCER IN MAMMOGRAM IMAGES

D. Ussipbekova¹, M. Yessenova², N. Uzakkyzy², R. Muratkhan³, P. Schmidt⁴

¹Kazakh National Medical University named after S.D. Asfendiyarov, Almaty, Kazakhstan;

²L.N. Gumilyov Eurasian National University, Astana, Kazakhstan;

³E.A. Buketov Karaganda University, Karaganda, Kazakhstan;

⁴University of Economics, Bratislava, Slovakia.

E-mail: moldir_11.92@mail.ru

Ussipbekova D. — PhD, lecturer, «the Department of Information Communication Technologies», Kazakh National Medical University named after S.D. Asfendiyarov, Almaty, Kazakhstan

E-mail: d.ussipbekova20@gmail.com, <https://orcid.org/0009-0001-8567-6274>;

Yessenova M. — PhD, senior lecturer, «the Department of Information Systems», L.N. Gumilyov Eurasian National University, Astana, Kazakhstan

E-mail: moldir_11.92@mail.ru, <https://orcid.org/0000-0002-2644-0966>;

Uzakkyzy N. — PhD, senior lecturer, «the Department of Computer and Software Engineering», L.N. Gumilyov Eurasian National University, Astana, Kazakhstan

E-mail: nura_astana@mail.ru, <https://orcid.org/0000-0002-8262-0240>;

Muratkhan R. — PhD, associate professor, E.A. Buketov Karaganda University, Karaganda, Kazakhstan

E-mail: raikhan.muratkhan@mail.ksu.kz, <https://orcid.org/0000-0002-2030-8948>;

Schmidt P. — PhD, professor, Head of the Department of Applied Informatics, Bratislava, University of Economics, Bratislava, Slovak Republic

E-mail: peter.schmidt@euba.sk, <https://orcid.org/0000-0001-5928-2821>.

© D. Ussipbekova, M. Yessenova, N. Uzakkyzy, R. Muratkhan, P. Schmidt, 2025

Abstract. This paper presents a hybrid method for breast cancer classification based on Digital Imaging and Communications in Medicine (DICOM) mammography images. The method is based on the combination of deep learning techniques and textural and geometric characteristics of images. The aim of the study is to integrate textural and geometric characteristics into the neural network architecture to improve the classification accuracy and localization of abnormal areas in medical images. The relevance of the study is due to the growing incidence of cancer and the need to improve the diagnostic accuracy in resource-limited healthcare settings. The proposed method is based on a modified Faster Region-Based Convolutional Neural Network (Faster R-CNN) architecture that includes additional feature extraction units such as eccentricity, texture metrics, entropy, and mean intensity. The image preprocessing



stage includes look-up table (LUT) transforms, normalization, and histogram equalization. These changes allow us to improve the key structural features of the image. The efficiency of the method was further improved by integrating texture and geometric characteristics, which reduced the overall cost by 30 % and improved the quality of classification and localization.

Key words: Mammography, breast cancer, deep learning, machine learning, DICOM, texture features, Faster R-CNN, medical diagnostics

For citation: D. Ussipbekova, M. Yessenova, N. Uzakkyzy, R. Muratkhan, P. Schmidt. Determination of signs vector for accurate detection of breast cancer in mammogram images//International journal of information and communication technologies. 2025. Vol. 6.No. 22. Pp. 235-250. (in Kaz.). <https://doi.org/10.54309/IJICT.2025.22.2.015>.

Conflict of interest: The authors declare that there is no conflict of interest.

МАММОГРАФИЯЛЫҚ СУРЕТТЕРДЕ СҮТ БЕЗІ ҚАТЕРЛІ ІСІГІН ДӘЛ АНЫҚТАУҒА АРНАЛҒАН БЕЛГІЛЕР ВЕКТОРЫН ҚҰРУ

Д.И. Усипбекова¹, М.Б. Есенова², Н. Ұзаққызы², Р. Муратхан³, П. Шмидт⁴*

¹С.Ж. Асфендияров атындағы Қазақ Ұлттық Медициналық Университеті, Алматы, Қазақстан;

²Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан;

³Е.А. Бөкетов атындағы Қарағанды университеті, Қарағанды, Қазақстан;

⁴Братислава экономикалық университеті, Словакия.

E-mail: moldir_11.92@mail.ru

Усипбекова Д. — «Ақпараттық коммуникациялық технологиялар» кафедрасының PhD, лекторы, С.Ж. Асфендияров атындағы Қазақ Ұлттық Медициналық Университеті, Алматы, Қазақстан

E-mail: .ussipbekova20@gmail.com, <https://orcid.org/0009-0001-8567-6274>;

Есенова М. — PhD, Л.Н. Гумилев атындағы Еуразия ұлттық университетінің «Ақпараттық жүйелер» кафедрасының аға оқытушысы, Астана, 010008, Қазақстан Республикасы

E-mail: moldir_11.92@mail.ru, <https://orcid.org/0000-0002-2644-0966>;

Ұзаққызы Н. — PhD, Л.Н.Гумилев атындағы Еуразия ұлттық университетінің «Компьютерлік және программалық инженерия» кафедрасының аға оқытушысы, Астана, 010008, Қазақстан Республикасы

E-mail: nura_astana@mail.ru, <https://orcid.org/0000-0002-8262-0240>;

Муратхан Р. — Е.А. Бөкетов атындағы Қарағанды университеті, қауымдастырылған профессор, PhD, Қарағанды қ., Қазақстан

E-mail: raikhan.muratkhon@mail.ksu.kz, <https://orcid.org/0000-0002-2030-8948>;

Шмидт П. — философия докторы (PhD), профессор, Братислава экономикалық университеті, «Қолданбалы информатика» кафедрасының меңгерушісі, Братислава қ., Словакия Республикасы

E-mail: peter.schmidt@euba.sk, <https://orcid.org/0000-0001-5928-2821>.

© Д.И. Усипбекова, М.Б. Есенова, Н. Ұзаққызы, Р. Муратхан, П. Шмидт, 2025

Аннотация. Бұл жұмыста Digital Imaging and Communications in Medicine (DICOM) форматындағы маммографиялық кескіндер негізінде сүт безі қатерлі ісігін жіктеуге арналған гибриді әдіс ұсынылады. Әдіс терең оқыту әдістерін

және кескіндердің текстуралық және геометриялық сипаттамаларын біріктіруге негізделген. Зерттеудің мақсаты – медициналық кескіндердегі аномальды аймақтарды жіктеу мен локализациялау дәлдігін арттыру үшін текстуралық және геометриялық белгілерді нейрондық желі архитектурасына біріктіру. Зерттеудің өзектілігі қатерлі ісік ауруларының өсуімен және медициналық мекемелердегі шектеулі ресурстар жағдайында диагностика дәлдігін арттыру қажеттілігімен байланысты. Ұсынылған әдістің негізінде Faster Region-based Convolutional Neural Network (Faster R-CNN) модификацияланған архитектурасы жатыр, оған эксцентриситет, текстуралық метрикалар, энтропия және орташа қарқындылық сияқты қосымша белгілерді шығару блоктары енгізілді. Кескіндерді алдын ала өңдеу кезеңіне Lookup Table (LUT) түрлендірулері, нормализация және гистограмманы теңестіру жатады. Бұл өңдеулер кескіннің негізгі құрылымдық ерекшеліктерін жақсартуға мүмкіндік береді. Әдістің тиімділігіне қосымша текстуралық және геометриялық белгілерді интеграциялау ықпал етті, бұл жалпы шығын деңгейін 30 %-ға төмендетуге, сондай-ақ классификация мен локализация көрсеткіштерін жақсартуға мүмкіндік берді.

Түйін сөздер: Маммография, сүт безі обыры, терең оқыту, машиналық оқыту, DICOM, текстуралық белгілер, Faster R-CNN, медициналық диагностика

Дәйексөздер үшін: Д.И. Усипбекова, М.Б. Есенова, Н. Ұзаққызы, Р. Муратхан, П. Шмидт. Маммографиялық суреттерде сүт безі қатерлі ісігін дәл анықтауға арналған белгілер векторын құру//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 235–250 бет. (қазақ тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.015>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

ОПРЕДЕЛЕНИЕ ВЕКТОРА ПРИЗНАКОВ ДЛЯ ТОЧНОГО ВЫЯВЛЕНИЯ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ НА ИЗОБРАЖЕНИЯХ МАММОГРАММЫ

*Д.И. Усипбекова¹, М.Б. Есенова² *, Н. Узаккызы², Р. Муратхан³,
П. Шмидт⁴*

¹Казахский национальный медицинский университет имени С.Д. Асфендиярова, Алматы, Казахстан;

²Евразийский национальный университет имени Л.Н. Гумилёва, Астана, Казахстан;

³Карагандинский университет имени Е.А. Букетова, Караганда, Казахстан;

⁴Братиславский экономический университет, Братислава, Словакия.

E-mail: moldir_11.92@mail.ru

Усипбекова Д. — PhD, лектор, кафедра «Информационных коммуникационных технологий», Казахский национальный медицинский университет имени С.Д. Асфендиярова, Алматы, Казахстан



E-mail: d.ussipbekova20@gmail.com, <https://orcid.org/0009-0001-8567-6274>;

Есенова М. — PhD, старший преподаватель, кафедра «Информационных систем», Евразийский национальный университет имени Л.Н. Гумилёва, Астана, Казахстан

E-mail: moldir_11.92@mail.ru, <https://orcid.org/0000-0002-2644-0966>;

Узаккызы Н. — PhD, старший преподаватель, кафедра «Компьютерной и программной инженерии», Евразийский национальный университет имени Л.Н. Гумилёва, Астана, Казахстан

E-mail: nura_astana@mail.ru, <https://orcid.org/0000-0002-8262-0240>;

Муратхан Р. — PhD, ассоциированный профессор, Карагандинский университет им. Е.А. Букетова, Караганда, Казахстан

E-mail: raikhan.muratkhan@mail.ksu.kz, <https://orcid.org/0000-0002-2030-8948>;

Шмидт П. — доктор философии (PhD), профессор, заведующий кафедрой «Прикладной информатики», Братиславский экономический университет, Братислава, Словацкая Республика

E-mail: peter.schmidt@euba.sk, <https://orcid.org/0000-0001-5928-2821>.

© Д.И. Усипбекова, М.Б. Есенова, Н. Узаккызы, Р. Муратхан, П. Шмидт 2025

Аннотация. В данной статье представлен гибридный метод классификации рака молочной железы на основе маммографических изображений в формате цифровой визуализации и коммуникаций в медицине (DICOM). Метод основан на объединении методов глубокого обучения и текстурных и геометрических характеристик изображений. Целью исследования является интеграция текстурных и геометрических характеристик в архитектуру нейронной сети для повышения точности классификации и локализации аномальных областей на медицинских изображениях. Актуальность исследования обусловлена ростом заболеваемости раком и необходимостью повышения точности диагностики в условиях ограниченных ресурсов медицинских учреждений. Предлагаемый метод основан на модифицированной архитектуре сверточной нейронной сети на основе более быстрых регионов (Faster R-CNN), которая включает в себя дополнительные блоки извлечения признаков, такие как эксцентриситет, метрики текстуры, энтропия и средняя интенсивность. Этап предварительной обработки изображения включает в себя преобразования таблицы поиска (LUT), нормализацию и выравнивание гистограммы. Эти изменения позволяют улучшить ключевые структурные особенности изображения. Эффективность метода была дополнительно повышена за счет интеграции текстурных и геометрических характеристик, что позволило сократить общую стоимость на 30%, а также улучшить качество классификации и локализации.

Ключевые слова: маммография, рак молочной железы, глубокое обучение, машинное обучение, DICOM, текстурные признаки, Faster R-CNN, медицинская диагностика

Для цитирования: Д.И. Усипбекова, М.Б. Есенова, Н. Узаккызы, Р. Муратхан, П. Шмидт. Определение вектора признаков для точного выявления рака молочной железы на изображениях маммограммы // Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. №. 22. Стр. 235–250. (На англ.). <https://doi.org/10.54309/IJICT.2025.22.2.015>.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Кіріспе

Сүт безі қатерлі ісігін (Orazayeva et. al., 2024; Orazayeva et. al., 2022;) маммографиялық кескіндер негізінде жіктеудің тиімді әдістерін әзірлеу қазіргі заманғы медициналық диагностиканың негізгі міндеттерінің бірі болып табылады (Orazayeva et. al., 2022; Tian et. al., 2024;). Сүт безі қатерлі ісігі (Tzenios et. al., 2024; Naizagarayeva et. al., 2023;) онкологиялық аурулардың ішінде таралуы мен өлім-жітім деңгейі бойынша алдыңғы орындардың бірін алады, бұл оның ерте және дәл анықталуының маңыздылығын көрсетеді. DICOM форматындағы маммографиялық кескіндерді қолдану тіндердің құрылымын егжей-тегжейлі визуализациялауға мүмкіндік береді, алайда мұндай деректерді талдау күрделілігі жасанды интеллект негізіндегі автоматтандырылған тәсілдерді қажет етеді. Бұл саладағы негізгі мәселелердің бірі — жалған-оң және жалған-теріс нәтижелердің жоғары жиілігі. Дәстүрлі маммографиялық кескіндерді талдау әдістері көбіне адамның тәжірибесіне тәуелді, бұл диагностикалық қателіктерге алып келуі мүмкін. Жалған-оң нәтижелер пациенттерге психологиялық жүктемені арттырып, қажетсіз медициналық араласуларға әкелсе, жалған-теріс нәтижелер ауруды ерте сатысында анықтамауға себеп болуы мүмкін. Бұл кезеңде емдеу мүмкіндіктері ең жоғары деңгейде болады. Сонымен қатар, білікті мамандардың қолжетімділігі шектеулі, әсіресе табысы төмен аймақтарда, онда дәрігерлердің жүктемесі жоғары болып, мәліметтерді мұқият талдауға уақыты жетпейді. Бұл мәселелер үлкен көлемдегі медициналық деректерді өңдеу қажеттілігімен күрделене түседі, сондықтан қолмен талдау жасау баяу және тиімсіз процесс болып саналады.

Тағы бір маңызды мәселе – кескіндердің әртүрлілігі мен олардың сапасы (Abdikirimova et. al., 2023; Jones et. al., 2024;), бұл қолданылатын жабдық пен оның параметрлеріне байланысты өзгереді. Бұл жағдай әмбебап диагностикалық модельдерді әзірлеуді қиындатады, өйткені олар әртүрлі жағдайларда бірдей тиімді жұмыс істеуі қажет. Сонымен қатар, қазіргі заманғы терең оқыту алгоритмдері (Kar et. al., 2024; Zhang et. al., 2024;) жоғары тиімділігіне қарамастан, жиі төмен интерпретативтілікке ие. Мұндай модельдер «қара жәшік» ретінде жұмыс істейді, бұл дәрігерлер арасында сұрақтар тудырады, өйткені жүйенің шешімін түсіндіру немесе негіздеу қиынға соғады. Аталған мәселелерді шешу үшін деректерді өңдеудің дәстүрлі әдістері мен терең оқытудың артықшылықтарын біріктіретін гибридті талдау әдістерін пайдалану қажет. Текстуралық және құрылымдық сипаттамаларды машиналық оқыту алгоритмдеріне біріктіру арқылы аномальды аймақтардың пішіні, тығыздығы және тіндердің гетерогенділігі сияқты маңызды ерекшеліктерін ескере отырып, диагностика дәлдігін арттыруға болады. Жасанды интеллектке негізделген диагностикалық процестерді автоматтандыру (Zeng et. al., 2024; Abou Ghayda


et. al., 2024;) адам факторына тәуелділікті азайтып, қателік ықтималдығын төмендетіп, деректерді талдаудың стандартталуын қамтамасыз етеді.

Бұл жұмыстың негізгі мақсаты – DICOM форматындағы сүт безі кескіндеріндегі аномальды аймақтарды автоматты түрде анықтау және жіктеу моделін әзірлеу және оқыту. Жұмыстың маңызды элементі – кескіндердің текстуралық және құрылымдық сипаттамаларынан алынатын қосымша белгілерді интеграциялау. Бұл белгілер аномальды аймақтарды классификациялау мен локализациялау сапасын жақсартып алады, әсіресе медициналық деректерді талдау кезінде, себебі диагностика дәлдігі пациенттің емделу нәтижесіне тікелей әсер етеді. Сондай-ақ, кескін сапасын жақсарту маңызды рөл атқарады, ол LUT-трансформациялар, нормализация және гистограмманы теңестіру сияқты алдын ала өңдеу әдістерін қолдану арқылы жүзеге асырылады. Бұл әдістер шуылды жойып, тіндердің құрылымдық ерекшеліктерінің контрастылығын арттыруға мүмкіндік береді. Ұсынылған әдіс шешімдерді интерпретациялау мүмкіндігін де жақсартады. Бұл эксцентриситет, орташа қарқындылық, текстуралық параметрлер және энтропия сияқты қосымша белгілерді модельге енгізу арқылы жүзеге асады. Бұл дәрігерлерге тек талдау нәтижелерін ғана емес, сонымен қатар олардың негіздемесін алуға мүмкіндік береді, осылайша жасанды интеллект жүйелеріне деген сенімділікті арттырады. Зерттеудің өзектілігі сүт безі қатерлі ісігін диагностикалауды автоматтандыру қажеттілігінің артуымен байланысты. Диагностикалық жағдайлардың көбеюі және үлкен көлемдегі деректерді өңдеуге деген сұраныс дәстүрлі әдістердің тиімділігін шектейді. Кеңістіктік және текстуралық ерекшеліктерді ескеретін гибриді әдістерді әзірлеу диагностика жылдамдығын арттырып қана қоймай, сонымен қатар шектеулі ресурстар жағдайында жоғары сапалы медициналық қызметке қолжетімділікті қамтамасыз етуге мүмкіндік береді.

Әдістер мен материалдар

Сүт безі қатерлі ісігін маммографиялық кескіндер негізінде жіктеуге арналған гибриді әдісті әзірлеу үшін терең оқыту мен текстуралық және құрылымдық сипаттамаларды дәстүрлі талдау әдістерін біріктіретін тәсіл қолданылды. Әдістің негізі ретінде қосымша белгілерді шығару блоктарымен толықтырылған модификацияланған Faster R-CNN архитектурасы алынды, бұл диагностиканың дәлдігін және модельдің интерпретациялануын айтарлықтай жақсартуға мүмкіндік берді. 1-суретте DICOM форматындағы медициналық кескіндердегі аномальды аймақтарды анықтау және жіктеу үшін жасалған қосымша белгілері бар Faster R-CNN моделінің алгоритмі көрсетілген. 1-сурет деректерді дайындаудан бастап модельді оқытуға дейінгі кезеңдерді, сондай-ақ текстуралық және геометриялық сипаттамалар сияқты қосымша белгілерді шығару және өңдеу үдерістерін қамтиды.

Деректерді жүктеу. Бірінші қадамда зерттеушілер аннотацияланған DICOM кескіндерін қамтитын деректерді жүктейді.



Сур. 1. Қосымша белгілері бар Faster R-CNN моделі алгоритмі

Деректер жиынындағы әрбір элемент қызығушылық объектілерін және BIRADS деңгейлері сияқты сынып белгілерін көрсететін анықталған шектеу жолақтары бар кескін болып табылады. Аннотациялар құрылымдық құжатта, кескін идентификаторлары, қорап координаттары және сәйкес сынып белгілері туралы ақпаратты қамтитын матрицада сақталады. Бұл деректер кейінгі талдау және модельдік оқыту үшін негіз болады (1):

$$D = \{d_i\}, d_i = (ID_i, x_{min_i}, y_{min_i}, x_{max_i}, y_{max_i}, class_i) \quad (1)$$

мұндағы ID_i – бірегей кескін идентификаторы, $x_{min_i}, y_{min_i}, x_{max_i}, y_{max_i}$ - суреттегі әрбір нысан үшін шектеу өрісінің координаттары, $class_i$ - сынып белгісі (мысалы, BIRADS классификациясы). Дұрыс емес координаттары бар аннотацияларды жою үшін сүзу қолданылады (2):

$$D_{filtered} = \{d_i \in D | x_{min_i} > 0, y_{min_i} > 0, x_{max_i} > 0, y_{max_i} > 0\} \quad (2)$$

Деректер жиынын оқыту D_{train} және валидация D_{valid} үлгілеріне (3) функциясы арқылы бөлуді белгілейік:

$$D_{train}, D_{valid} = train_test_split(D_{filtered}, test_size = 0.2) \quad (3)$$

Деректерді сүзу нөл немесе теріс жақтау координаттары бар жарамсыз жолдарды жою үшін орындалады. Кескінді алдын ала өңдеу. Кескінді алдын ала өңдеу қадамында зерттеушілер бірегей идентификатормен анықталған әрбір сурет үшін DICOM файлдарынан деректерді жүктейді. Бұл процесс пиксельдік деректерді, кескіндердің құрылымын талдау үшін пайдаланылатын сұр қарқындылық массивін шығаруды қамтиды. Бұл деректер визуализацияны жақсарту және негізгі тіндік мүмкіндіктерді ерекшелеу үшін қалыпқа келтіруді және гистограмманы теңестіруді қоса түрлендіреді. Бұл кескіндерді келесі мүмкіндікті шығаруға және үлгіні оқыту қадамына дайындайды (4):

$$I = read_{dicom}(ID) \quad (4)$$

мұндағы I - кескін идентификаторының пиксель қарқындылығының екі өлшемді массиві. Қызығушылық мәнін іздеу кестесін (VOI LUT) пайдалану кескіндердегі клиникалық маңызды мәліметтерді ерекшелеу үшін пиксель мәндерінің ауқымын түрлендіретін медициналық бейнелеудегі маңызды қадам болып табылады. Бұл әдіс әсіресе DICOM пішіміндегі медициналық кескіндермен, соның ішінде рентген сәулелерімен, компьютерлік томографиямен (КТ) және магнитті-резонансты бейнелеумен (МРТ) жұмыс істеу үшін өте маңызды. Мұндай кескіндердегі пиксель қарқындылығының мәндері айтарлықтай өзгеруі мүмкін, кейде стандартты мониторлардың визуализация мүмкіндіктерінен асып кетеді. Мысалы, 12-биттік кескіндер 0-ден 4095-ке дейінгі қарқындылық мәндерін қамтуы мүмкін, ал стандартты мониторлар тек 256 сұр деңгейді (8-биттік көрініс) көрсете алады. Тиімді талдау патологияны көрсететін аймақтар сияқты диагностикалық мәні бар қарқындылық деңгейлерін ғана бөлектеуді талап етеді.

VOI LUT мәндері азырақ деректердің әсерін азайта отырып, осы аумақтарды айқынырақ ету үшін пиксель мәндерін түрлендіреді. Бұл процесс медициналық мамандардың кескінді интерпретациялауын жеңілдетіп, визуализация сапасын айтарлықтай жақсартады. VOI LUT функциясы бастапқы кескіннің пиксельдік мәндерін көрсету үшін қолайлы ауқымға түрлендіреді. VOI LUT түрлендіру келесідей орындалады (5):

$$I'(x, y) = LUT(I(x, y), W, C) \quad (5)$$

мұндағы $I(x, y)$ - координаттардағы пиксел қарқындылығының мәні (x, y) , W - терезе ені, C - терезенің ортасы $I'(x, y)$ - LUT қолданғаннан кейінгі жаңа пиксель мәні. VOI LUT берілген W және C параметрлеріне қатысты олардың қарқындылығына байланысты пиксель мәндерін келесі ережеге (6) сәйкес түрлендіреді:

$$I'(x, y) = \begin{cases} 0, \\ 255, \\ \frac{I(x, y) - (C - \frac{W}{2})}{W} * 255, \end{cases} \quad (6)$$

Деректерді стандарттау үшін пиксел қарқындылығының мәндері 0-ден 1-ге дейінгі диапазонға (7) қалыпқа келтіріледі:

$$I_{norm}(x, y) = \frac{I'(x, y)}{\max(I'(x, y))} \quad (7)$$

мұндағы $I_{norm}(x, y)$ - нормаланған пиксель қарқындылығы мәні, $\max(I'(x, y))$ - суреттегі максималды қарқындылық мәні. Кескін MONOCHROME1 фотометриялық интерпретациясымен кодталған болса, кескіннің ашық аймақтарында интенсивтілік мәндері төмен болады. Бұл жағдайда кескін төңкеріледі (8):

$$I_{inv}(x, y) = \max(I(x, y)) - I(x, y) \quad (8)$$

мұндағы $I_{inv}(x, y)$ – инверттелген пиксель мәні. Кескін контрастын жақсарту үшін гистограмма теңестіру қолданылады. Әрбір $I(x, y)$ пикселі үшін келесі түрлендіру (9) орындалады:

$$T(I) = (L - 1) \sum_{i=0}^I p(i) \quad (9)$$

Мұндай мүмкіндіктерді біріктіру кезінде туындайтын бір маңызды сұрақ олардың модельдің жалпы өнімділігіне әсері болып табылады. Тәжірибе көр-

сеткендей, бұл мүмкіндіктерді қосу әдеттен тыс аймақтарды локализациялаудың да, жіктелуінің де дәлдігін жақсартады. Өйткені текстураның ерекшеліктері конволюционды желіде жетіспейтін ісіктің табиғаты туралы қосымша ақпаратты бере алады. Мысалы, тіндердің құрылымындағы өзгерістер қатерлі процестердің маркерлері болуы мүмкін, бұл оларды автоматтандырылған диагностикалық жүйе үшін маңызды көрсеткіштерге айналдырады.

Нәтижелер және оларды талқылау


Ұсынылған әдіс VinDr-Mammo деректер жинағын пайдалана отырып әзірленді, ол зерттеулердің жоғары қайталану дәрежесін қамтамасыз ететін DICOM форматындағы ең маңызды ашық сандық маммография ресурстарының бірі. Деректер көзі – Вьетнамда орналасқан Ханой медициналық университеті (НМУН) және 108 ауруханасы (Н108). «VinBigData» АҚ деректер жинағын PhysioNet платформасында жариялады, бұл оның ғылыми зерттеулер мен нәтижелерді тексеруге еркін қол жеткізуіне кепілдік береді.

Деректер жинағы әрқайсысы төрт кескіннен (әр емшек үшін екі көрініс) тұратын 5 000 маммографиялық зерттеулерді қамтиды, барлығы 20 000 жоғары ажыратымдылықтағы кескінді (3518 x 2800 пиксель) құрайды. Бұл деректер BI-RADS жүйесіне сәйкес аннотацияланған, BI-RADS диагностикалық санаттарының 1–5 – әдеттегіден ықтималдығы жоғары қатерлі істерге дейін. Сонымен қатар, аннотациялар тіндердің тығыздығы (A–D санаттары) және массалар, кальцинациялар, асимметриялар және архитектуралық деформациялар сияқты әртүрлі патологиялық жағдайлар туралы ақпаратты қамтиды. Бұл әртүрлілік деректер жиынтығын диагностикалық сценарийлердің кең ауқымын зерттеудің жоғары өкілі етеді.

Faster R-CNN үлгісін оқыту үдерісін аяқтағаннан кейін, ол аномалияларды анықтау және жіктеудегі модельдің тиімділігін анықтау үшін бірнеше негізгі көрсеткіштерді қолдану арқылы мұқият бағаланды. Жетекші көрсеткіштер: Total Loss, Classifier Loss, Box Regression Loss, Objectness Loss және RPN Box Loss. Бұл көрсеткіштер модельдің объектінің жіктелуінен бастап олардың локализациясының дәлдігіне дейінгі оның өнімділігінің әртүрлі аспектілерімен қаншалықты жақсы күресетінін тереңірек түсінуге мүмкіндік береді. Мысалы, Total Loss үлгі өнімділігінің жалпы сапасын көрсетеді және классификациямен, қораптың регрессиясымен, нысандылығымен және сөйлем шеңберін болжаумен (RPN) байланысты барлық жеке шығындардың қосындысы болып табылады. Төмен жалпы жоғалту мәндері модельдің классификациядағы да, локализациядағы да қателерді азайту мүмкіндігін көрсетеді, бұл оның жалпы өнімділігі үшін өте маңызды. Әрбір көрсеткіш үлгі өнімділігін бағалауда рөл атқарады. Классификатордың жоғалуы модельге, мысалы, қатерсіз және қатерлі ісіктерді ажыратуға мүмкіндік беретін объектінің классификациясының дәлдігін анықтайды. Box Regression Loss локализацияның дәлдігі диагнозды анықтайтын медициналық кескінді талдауда ерекше маңызды болып табылатын шектейтін қорап

координаттарын болжау дәлдігін бағалайды. Нысанды жоғалту үлгіге маңызды нысанның ұсынылған жолақта орналасу ықтималдығын анықтауға көмектеседі, жалған оң мәндерді азайтады. Соңында, RPN Box Loss аймақтық ұсыныстардың дұрыстығына жауап береді және әрі қарай талдаудың жылдамдығы мен дәлдігіне әсер етеді. Бұл көрсеткіштер бірігіп, оның жұмысының барлық кезеңдерінде, қораптық ұсыныстарды қалыптастырудан бастап, нысандардың соңғы жіктелуіне дейін үлгінің өнімділігінің толық бейнесін береді.


2-суретте 15 дәуір үшін дайындалған екі үлгіге арналған Орташа жалпы шығынды салыстыру диаграммасы көрсетілген. 2-суретте Faster R-CNN үлгісінің екі түрлі нұсқасы көрсетілген, мысалы, Модель-1 (қосымша мүмкіндіктерсіз) көк түспен және Модель-2 (қосымша мүмкіндіктері бар) қызғылт сары түспен көрсетілген. Абсцисса (X) осі үлгілер дайындалған дәуірлер санын, ал ордината (Y) осі әрбір дәуір үшін Орташа жалпы жоғалту мәндерін көрсетеді.



Сур. 2. Модельді оқыту кезіндегі жалпы жоғалту нәтижесі (жалпы жоғалтулар)


Модель-1 және Модель-2 салыстырмалы талдау эксцентристик текстуралық және статистикалық сипаттамалар сияқты қосымша мүмкіндіктерді қосуға байланысты соңғысының маңызды артықшылығын көрсетеді. 2-модель оқу үдерісінде айтарлықтай төмен Total Loss мәндерін көрсетті, бұл оның қателерді тиімдірек азайту мүмкіндігін көрсетеді. Жаттығудың бастапқы кезеңдерінде Орташа жалпы жоғалтудың айырмашылығы байқалды. Бірінші дәуірде Модель-1 шамамен 0,26 шығынға ие болды, ал Модель-2 шамамен 0,22 төмен мәнмен басталды. Себебі қосымша мүмкіндіктер үлгі 2-ге аномальды аймақтардың текстуралық және құрылымдық ерекшеліктерін қарастыруға мүмкіндік беріп, үлгіні жақсырақ тануға және қателерді азайтуға ықпал етті. 2-модель үшін жалпы жоғалтудың төмендеу қарқыны оқу барысында да айқынырақ болды. Мысалы, жетінші дәуірде ол шамамен 0,14 мәнге

жетті, ал Модель-1 шамамен 0,19 шамасында қалды. Он бесінші дәуірде Модель-2 шамамен 0,11 жоғалтуға қол жеткізді, ал Модель-1 шамамен 0,16 жоғалтумен аяқталды. Бұл қосымша мүмкіндіктер оның аномалияларды тану және локализациялаудағы дәлдігін айтарлықтай жақсартқанын растайды. 2-модель нысандар мен фондарды ажыратуға және шектейтін жәшіктердің координаталарын дәл анықтауға қабілетті болды, бұл соңғы жоғалтуды айтарлықтай азайтты. Керісінше, 1-үлгіде қосымша мүмкіндіктердің болмауы оның аномалияларды тану мүмкіндігін шектеді, нәтижесінде жоғалту жоғары болды. Бұл нәтижелер терең оқыту үлгілерінің өнімділігін жақсарту үшін текстуралық және геометриялық мүмкіндіктерді пайдаланудың тиімділігін растайды. 3-суретте 15 дәуірге арналған жаттығу кезінде Faster R-CNN үлгісінің екі нұсқасы үшін орташа жіктеуші жоғалтуды салыстыру диаграммасы көрсетілген. Диаграммада көгілдір түспен Модель-1 (қосымша мүмкіндіктерсіз) және қызғылт сары түспен Модель-2 (қосымша мүмкіндіктері бар) нәтижелері көрсетілген. Абсцисса (X) осі дәуірлер санын, ал ордината (Y) осі әрбір дәуірдің орташа жіктеу жоғалту мәндерін білдіреді.




Сур. 3. Модельдерді оқыту кезіндегі классификаторды жоғалту нәтижесі

Жалған позитивтердің санын азайту үшін маңызды ерекшелік 1-үлгіде оқытудың басында 0,80-ден 0,94-ке дейін өсті. Осымен қатар, текстуралық-геометриялық көрсеткіштер қосылған 2-модельде ерекшелік 0,82-ден басталып, он бес дәуірден кейін 0,97-ге жетті. Бұл айырмашылық (соңғы итерацияда шамамен 0,03–0,05) патологиясы жоқ аймақтарды локализациялау мен жіктеудің жоғары дәлдігін және қосымша мүмкіндіктер жинағын пайдалану кезінде жалған позитивтердің аз екендігін көрсетеді. 4-суретте ROC-AUC мәндерінің эволюциясы көрсетілген, сүт безі тініндегі ықтимал қатерлі аймақтарды анықтау кезінде екі модельдің де сезімталдығы мен ерекшелігі арасындағы тепе-теңдікті көрсетеді.



Сур. 4. Маммографиялық диагностикадағы ROC-AUC көрсеткішінің салыстырмалы талдауы

График 1-үлгінің бұл көрсеткішті 0,75-тен 0,93-ке дейін арттырғанын көрсетеді, ал 2-үлгі тезірек жақсартуды көрсетеді: 0,78-ден 0,96-ға дейін. Айырмашылық әсіресе орта дәуірлерде (6–10) байқалады, мұнда 2-үлгінің ROC-AUC тұрақты түрде 0,04–0,06 жоғары болады. Мұндай өсу гибриді терең оқыту тәсілінің және қосымша текстуралық-геометриялық белгілердің қатерлі ісіктерді қалыпты аймақтардан дәлірек ажырату мүмкіндігін көрсетеді, компьютерлік диагностиканың сапасын айтарлықтай жақсартады. 5-сурет қатерлі өзгерістерге арналған маммографиялық кескіндерді жіктеу кезінде FasterR-CNN екі нұсқасының дәлдігі қалай өзгередінін көрсетеді.



Сур. 5. Патологияны танудағы соңғы дәлдікті (дәлдік) бағалау

1-үлгіде дәлдік $\approx 0,70$ -тен (1-дәуір) 0,91-ге (15-дәуір) дейін өсті, ал 2-үлгі 0,73-тен басталып, жаттығудың соңында 0,99 дерлік жететін жақсартудың же-

делдетілген жылдамдығын көрсетті. Екінші үлгідегі секіріс әсіресе аралық кезеңдерде (5–8 дәуірлер) байқалады, мұнда дәлдік $\approx 0,83$ -тен $0,87$ -ге дейін өсті, ал 1-үлгі $0,80$ - $0,84$ деңгейінде қалды. Бұл нәтижелер 2-модельге қосылған мүмкіндіктердің (энтропия, орташа қарқындылық, эксцентристік және GLCM мүмкіндіктері сияқты) классификатордың жалпылау қабілетін жақсартатынын растайды, бұл маммографиялық деректердің шектеулі контрасты және гетерогенділігі жағдайында ісік құрылымдарын дәлірек анықтауға мүмкіндік береді. Бұл нәтижелер күрделі анықтау тапсырмаларында терең оқыту үлгілерінің өнімділігін жақсарту үшін қосымша мүмкіндіктерді пайдаланудың маңыздылығын көрсетеді.

Қорытынды

Ұсынылған жұмыс терең оқыту әдістері мен кескіндердің текстурасы мен геометриялық сипаттамаларын талдаудың үйлесімі негізінде сүт безі обыры классификациясының гибриді әдісін әзірлеуге және талдауға арналған. Ұсынылған әдіс өзгертілген Faster Region-based Convolutional Neural Network (Faster R-CNN) архитектурасын қолданып, қалыптан тыс аймақтарды жіктеу мен локализациялауда жоғары тиімділікті көрсетті. Текстуралық метрика және эксцентристік сияқты қосымша мүмкіндіктерді қосу диагностикалық дәлдікті жақсартуға ғана емес, сонымен қатар нәтижелердің түсіндірмелілігін арттыруға мүмкіндік берді. Тәжірибелер ұсынылған тәсілдің негізгі үлгімен салыстырғанда жоғалтуларды айтарлықтай азайтуды және дәлдікті арттыруды қамтамасыз ететінін көрсетті. Бұл оны медициналық тәжірибеде енгізу үшін перспективалы етеді, мұнда автоматтандыру және кескінді талдаудың жоғары дәлдігі негізгі талаптар болып табылады. Мысалы, жалпы жоғалтудың 30% -ға төмендеуі және жіктеу өнімділігінің жақсаруы текстура мен геометриялық мүмкіндіктерді біріктіру терең оқыту үлгілерінің өнімділігін арттырудың маңызды бағыты екенін растайды. Бұған қоса, қалыпқа келтіру, гистограмманы теңестіру және LUT пайдалану сияқты кескінді алдын ала өңдеу әдістерін енгізу тіндердің құрылымдық ерекшеліктерін визуализациялауды жақсартты. Бұл үлгінің дәлдігін арттырып қана қоймай, сонымен қатар DICOM пішіміндегі медициналық кескіндермен жұмыс істеу кезінде ерекше маңызды болып табылатын бастапқы деректер сапасының нашарлығының әсерін азайтты. Болашақ зерттеулер клиникалық параметрлер, генетикалық ақпарат және медициналық бейнелеудің басқа түрлері сияқты мультидисциплинарлық деректерді қамтитын гибриді модельдерді одан әрі дамытуға бағытталуы мүмкін. Бұл дәлірек және жекелендірілген диагностикалық модельдерді жасауға мүмкіндік береді. Сонымен қатар, есептеу шығындарын оңтайландыру ұсынылған тәсілдерді нақты әлемдегі клиникалық жағдайларда, әсіресе ресурстары шектеулі аймақтарда пайдалану үшін қол жетімді етеді. Бұл тәсіл жоғары дәлдікті, түсіндіруді және практикалық қолдануды біріктіретін әмбебап медициналық диагностикалық жүйелерді құру жолындағы маңызды қадам болуы мүмкін.

ӘДЕБИЕТТЕР

Оразаева А., Түсіпов Ж., Шаңғытбаева Г., Ғалымова А., Жүнісова У., Тергеуссизова А., Кенжебаева З. (2024). Машиналық оқыту әдістерін қолдана отырып, сүт безі патологиясын Тиімді анықтау // *Халықаралық Электротехника Және Есептеу Техникасы Журналы*. — Рр. 2088–8708. — 2024. — Том. 14. — № 5.

Оразаева А., Войчик В., Павлов С., Тимченко Л., Кокриацка Н., Твердомед В., Семенова Л. (2022). контурларды дайындауға негізделген биомедициналық кескінді сегментациялау әдісі // *Астрономия, Байланыс, Өнеркәсіп Және Жоғары Энергетикалық Физика Эксперименттеріндегі Фотоника Қолданбалары* 2022. — Том. 12476. — Б.21–26. Б.13–20.

Тянь Д., Чен В., Сю Д., Сю Л., Сю Г., Гуо Ю., Яо Ю. (2024). машиналық оқытуды қолдана отырып, дәстүрлі Қытай медицинасының диагностикасына шолу: Инспекция, аускультация-ніс сезу, анықтау және пальпация // *Биология Мен Медицинадағы Компьютерлер*. 2024. — № 108074.

АҚШ-Тың Профилактикалық Қызметтерінің Жұмыс Тобының сүт безі қатерлі ісігінің Скринингі // *JAMA*. 2024. — Том. 331. — № 22. — Б.1973–1974 Цениос Н., Тазаниос М. Е., Чахин М. (2024). ВМІ – нің сүт безі қатерлі ісігіне әсері-жаңартылған жүйелі шолу және мета-анализ // *Медицина*. 2024. — Том. 103. — № 5. — е36831.

Obeagu E. I., Obeagu G. U. Сүт безі қатерлі ісігі: қауіп факторлары мен диагностикасына шолу // *Медицина*. 2024. — Том. 103. — № 3. — е36905.

Найзағараева А., Абдикеримова Г., Шайханова А., Глазырина Н., Бекмағамбетова Г., Мutowина Н., Танирбергенев А. (2023). терең оқыту әдістерін қолдана отырып, жүрек патологиясын Анықтау // *Халықаралық Электротехника Және Есептеу Техникасы Журналы* (2088-8708). 2023. — Том. 13. — № 6.

Әбдікерімова Г., Шекербек А., Төленбаев М., Сұлтанова Б., Беглерова С., Джаулыбаева Е., Рысбекқызы Б. фракталдық әдіспен өкпе патологиясын Анықтау // *Халықаралық Электротехника Және Есептеу Техникасы Журналы* (2088-8708). – 2023. - Том. 13, № 6.

Джонс К., Кастро Д. К., Де Souza Рибейро Ф., Октай О., Маккрадден М., Глокер Б. медициналық бейнелеу үшін машиналық оқытудағы деректер жиынтығының біржақтылығының себептік перспективасы // *Nature Machine Intelligence*. – 2024. - Том. 6, № 2. – Б.138-146.

Кар Н. К., Яна С., Рахман А., Ашокрао П. Р., Индхумати Г., Мангай Р. А. Медициналық Кескінді Талдауда Терең Оқытуды Қолдана отырып, Интракраниальды Қан Кетуді Автоматтандырылған Анықтау // *2024 Халықаралық Деректер Ғылымы Және Желілік Қауіпсіздік Конференциясы (ICDSNS)*. – 2024. – Б.1-6.

Чжан Дж., Сяо Л., Чжан Ю., Лай Дж., Ян Ю. медициналық кескінді өңдеудегі терең оқыту алгоритмін Оңтайландыру және өнімділікті бағалау // *Есептеу Және Интеллектуалды Жүйелердегі Шекаралар*. – 2024. - Том. 7, № 3. – Б.67-71.

Zeng Q., Sun W., Xu J., Wan W., Pan L. Машиналық Оқытуға негізделген Медициналық Бейнелеуді Анықтау және Диагностикалық Көмек // *Халықаралық Информатика Және Ақпараттық Технологиялар Журналы*. – 2024. - Том. 2, № 1. – Б.36-44.

Алаттар М., Говинд А., Майнали С. ұйқы медицинасындағы стандартты диагностиканы автоматтандыруға арналған Жасанды интеллект модельдері—жүйелі шолу // *Биоинженерия*. – 2024. - Том. 11, № 3. – Б.206.

Әбу Гайда Р., Каннарелла Р., Калогеро А. Е., Шах Р., Рамбхатла А., Зоди В., Форум Г. а. андрологиядағы Жасанды интеллект: шәует анализінен кескін диагностикасына дейін // *Дүниежүзілік Ерлер Денсаулығы Журналы*. – 2024. - Том. 42, № 1. – Б.39.



REFERENCES

- Orazayeva A., Tussupov J., Shangytbayeva G., Galymova A., Zhunisova U., Tergeussizova A., Kenzhebayeva Z. (2024). Effective detection of breast pathology using machine learning methods // *International Journal of Electrical & Computer Engineering*. — Pp. 2088–8708. 2024. — Vol. 14. — No. 5. (in Eng.)
- Orazayeva A., Wójcik W., Pavlov S., Tymchenko L., Kokriatska N., Tverdomed V., Semenova L. (2022). Biomedical image segmentation method based on contour preparation // *Photonics Applications in Astronomy, Communications, Industry, and High Energy Physics Experiments* 2022. — Vol. 12476. — P. 21–26. (in Eng.)
- Orazayeva A., Wójcik W., Pavlov S., Tussupov J., Prokopovich I., Kovalchuks O., Zhunisova U. (2022). Imaging fuzzy expert system for assessing dynamic changes in biomedical tumor images in breast cancer // *Photonics Applications in Astronomy, Communications, Industry, and High Energy Physics Experiments* 2022. — Vol. 12476. — Pp. 13–20. (in Eng.)
- Tian D., Chen W., Xu D., Xu L., Xu G., Guo Y., Yao Y. (2024). A review of traditional Chinese medicine diagnosis using machine learning: Inspection, auscultation-olfaction, inquiry, and palpation // *Computers in Biology and Medicine*. — 2024. — No. 108074. (in Eng.)
- Tzenios N., Tazianos M. E., Chahine M. (2024). The impact of BMI on breast cancer – an updated systematic review and meta-analysis // *Medicine*. 2024. — Vol. 103. — No. 5. — e36831. (in Eng.)
- Obeagu E. I., Obeagu G. U. Breast cancer: A review of risk factors and diagnosis // *Medicine*. 2024. — Vol. 103. — No. 3. — e36905. (in Eng.)
- Naizagarayeva A., Abdikerimova G., Shaikhanova A., Glazyrina N., Bekmagambetova G., Mutovina N., Tanirbergenov A. (2023). Detection of heart pathology using deep learning methods // *International Journal of Electrical & Computer Engineering*. — Pp. 2088–8708. 2023. — Vol. 13. — No. 6. (in Eng.)
- Abdikerimova G., Shekerbek A., Tulenbayev M., Sultanova B., Beglerova S., Dzhaulybaeva E., Rysbekkyzy B. (2023). Detection of lung pathology using the fractal method // *International Journal of Electrical & Computer Engineering*. — Pp. 2088–8708. 2023. — Vol. 13. — No. 6. (in Eng.)
- Jones C., Castro D. C., De Sousa Ribeiro F., Oktay O., McCradden M., Glocker B. (2024). A causal perspective on dataset bias in machine learning for medical imaging // *Nature Machine Intelligence*. 2024. — Vol. 6. — No. 2. — P. 138–146. (in Eng.)
- Kar N.K., Jana S., Rahman A., Ashokrao P.R., Indhumathi G., Mangai R.A. (2024). Automated Intracranial Hemorrhage Detection Using Deep Learning in Medical Image Analysis // *2024 International Conference on Data Science and Network Security (ICDSNS)*. 2024. — P. 1–6. (in Eng.)
- Zhang J., Xiao L., Zhang Y., Lai J., Yang Y. (2024). Optimization and performance evaluation of deep learning algorithm in medical image processing // *Frontiers in Computing and Intelligent Systems*. 2024. — Vol. 7. — No. 3. — P. 67–71. (in Eng.)
- Zeng Q., Sun W., Xu J., Wan W., Pan L. (2024). Machine Learning-Based Medical Imaging Detection and Diagnostic Assistance // *International Journal of Computer Science and Information Technology*. 2024. — Vol. 2. — No. 1. — Pp. 36–44. (in Eng.)
- Alattar M., Govind A., Mainali S. (2024). Artificial intelligence models for the automation of standard diagnostics in sleep medicine—a systematic review // *Bioengineering*. 2024. — Vol. 11. — No. 3. — P. 206. (in Eng.)
- Abou Ghayda R., Cannarella R., Calogero A.E., Shah R., Rambhatla A., Zohdy W., Forum G.A. (2024). Artificial intelligence in andrology: from semen analysis to image diagnostics // *The World Journal of Men's Health*. 2024. — Vol. 42. — No. 1. — P. 39. (in Eng.)

**ХАЛЫҚАРАЛЫҚ АҚПАРАТТЫҚ ЖӘНЕ
КОММУНИКАЦИЯЛЫҚ ТЕХНОЛОГИЯЛАР ЖУРНАЛЫ**

**МЕЖДУНАРОДНЫЙ ЖУРНАЛ ИНФОРМАЦИОННЫХ И
КОММУНИКАЦИОННЫХ ТЕХНОЛОГИЙ**

**INTERNATIONAL JOURNAL OF INFORMATION AND
COMMUNICATION TECHNOLOGIES**

Правила оформления статьи для публикации в журнале на сайте:

<https://journal.iitu.edu.kz>

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Собственник: АО «Международный университет
информационных технологий» (Казахстан, Алматы)

ОТВЕТСТВЕННЫЙ РЕДАКТОР
Мрзабаева Раушан Жалиқызы

НАУЧНЫЙ РЕДАКТОР
Ермакова Вера Александровна

ТЕХНИЧЕСКИЙ РЕДАКТОР
Рашидинов Дамир Рашидинович

КОМПЬЮТЕРНАЯ ВЕРСТКА
Асанова Жадыра

Подписано в печать 15.06.2025.

Формат 60x881/8. Бумага офсетная. Печать - ризограф. 9,0 п.л. Тираж 100
050040 г. Алматы, ул. Манаса 34/1, каб. 709, тел: +7 (727) 244-51-09).

Издание Международного университета информационных технологий
Издательский центр КБТУ, Алматы, ул. Толе би, 59