



EKTU JOURNAL OF  
INFORMATION AND  
COMMUNICATION SCIENCES



# EKTU JOURNAL OF INFORMATION AND COMMUNICATION SCIENCES

№ 1, 2026

ISSN (Print): 3134-8025  
ISSN (Online): 3134-8033

1-том, 1-нөмір, наурыз, 2026.  
Том 1, № 1, март 2026.  
Vol. 1, Issue 1, March 2026.

---

# EKTU JOURNAL OF INFORMATION AND COMMUNICATION SCIENCES



Жылына 4 рет шығады  
Выходит 4 раза в год  
Published 4 times a year

Өскемен, 2026  
Усть-Каменогорск, 2026  
Ust-Kamenogorsk, 2026

Бас редакторы  
**Кумаргажанова С.К., PhD**

Редакция алқасы:

Бас редактордың орынбасары:  
**Тлебалдинова А.С., PhD**

Редакциялық алқа мүшелері:

Алимханова А.Ж., PhD (Қазақстан)  
Кусаинова А.Т., PhD (Қазақстан)  
Оспанов Е.А., PhD (Қазақстан)  
Бельгинова С.А., PhD (Қазақстан)  
Алибекқызы К., PhD (Қазақстан)  
Увалиева И.М., PhD (Қазақстан)  
Адиканова С., PhD (Қазақстан)  
Исмухамедова А.М., PhD (Қазақстан)  
Сайлауқызы Ж., PhD (Қазақстан)  
Токсанов С.Н., PhD (Қазақстан)  
Павел Комада, PhD (Польша)  
Михал Майка, PhD (Польша)  
Самир Рустамов, PhD (Азербайджан)  
Литвиненко В.И., т.ғ.д. (Украина)  
Збигнев Омиотек, dr hab. inż (Польша)  
Ребекка Бейтс, PhD (АҚШ)  
Крак Ю.В., ф.-м.ғ.д. (Украина)  
Джейн Лабадин, PhD (Малайзия)  
Раджермани Тинакаран, PhD (Малайзия)  
Рири Фитри Сари, PhD (Индонезия)  
Аравинд Питчай Венкатараман, PhD (Оман)  
Козлов Д.Ю., ф.-м.к (Ресей)

Главный редактор

**Кумаргажанова С.К., PhD**

Редакционная коллегия:

Заместитель главного редактора:

**Тлебалдинова А.С., PhD**

Члены редакционной коллегии:

Алимханова А.Ж., PhD (Казахстан)

Кусаинова А.Т., PhD (Казахстан)

Оспанов Е.А., PhD (Казахстан)

Бельгинова С.А., PhD (Казахстан)

Алибеккызы К., PhD (Казахстан)

Увалиева И.М., PhD (Казахстан)

Адиканова С., PhD (Казахстан)

Исмухамедова А.М., PhD (Казахстан)

Сайлауқызы Ж., PhD (Казахстан)

Токсанов С.Н., PhD (Казахстан)

Павел Комада, PhD (Польша)

Михал Майка, PhD (Польша)

Самир Рустамов, PhD (Азербайджан)

Литвиненко В.И., д.т.н. (Украина)

Збигнев Омиотек, dr hab. inż (Польша)

Ребекка Бейтс, PhD (АҚШ)

Крак Ю.В., д.ф.-м.н. (Украина)

Джейн Лабадин, PhD (Малайзия)

Раджермани Тинакаран, PhD (Малайзия)

Рири Фитри Сари, PhD (Индонезия)

Аравинд Питчай Венкатараман, PhD (Оман)

Козлов Д.Ю., к.ф.-м.н. (Россия)

Editor-in-Chief

**Saule Kumargazhanova, PhD**

Editorial Board:

Deputy Editor-in-Chief

**Aizhan Tlebaldinova, PhD**

Editorial Board Members:

Aslima Alimkhanova, PhD (Kazakhstan)

Ainur Kusainova, PhD (Kazakhstan)

Erbol Ospanov, PhD (Kazakhstan)

Saule Belginova, PhD (Kazakhstan)

Karlygash Alibekkyzy, PhD, Associate Professor (Kazakhstan)

Indira Uvalieva, PhD, professor (Kazakhstan)

Adikanova Saltanat, PhD, Professor at KMIIT (Kazakhstan)

Aigerim Ismukhamedova, PhD (Kazakhstan)

Zhuldyz Sailaukyzy, PhD (Kazakhstan)

Sapar Toksanov, PhD (Kazakhstan)

Pawel Komada, PhD (Poland)

Michał Majka, PhD (Poland)

Samir Rustamov, PhD (Azerbaijan)

Volodymyr Litvinenko, Doctor of Technical Sciences (Ukraine)

Omiotek Zbigniew, dr hab. inż (Poland)

Rebecca Bates, PhD (USA)

Yuri Krak, Doctor of Physical and Mathematical Sciences (Ukraine)

Jane Labadin, PhD (Malaysia)

Rajermani Thinakaran, PhD (Malaysia)

Riri Fitri Sari, PhD (Indonesia)

Aravind Pitchai Venkataraman, PhD (Oman)






Denis Kozlov, Candidate of Physical and Mathematical Sciences (Russia)

[https://doi.org/10.51885/3134-8025\\_IICS\\_2026\\_1\\_1](https://doi.org/10.51885/3134-8025_IICS_2026_1_1)  
MPNТИ 28.23.15

## МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ В АНАЛИЗЕ ВИЗУАЛЬНЫХ ДАННЫХ ДЛЯ 3D-МОДЕЛИРОВАНИЯ ГОРОДСКОЙ ИНФРАСТРУКТУРЫ

## МАШИНАЛЫҚ ОҚЫТУ АРҚЫЛЫ ВИЗУАЛДЫ МӘЛІМЕТТЕРДІ ӨНДЕУ ЖӘНЕ 3D-ҚАЛА ҮЛГІЛЕРІН ЖАСАУ

## MACHINE LEARNING METHODS FOR 3D RECONSTRUCTION OF URBAN ENVIRONMENTS

О.Н. Акылбеков <sup>1\*</sup>, А.Н. Молдагулова <sup>1</sup> Г.С. Закария <sup>1</sup>  
С.Т. Байдильдинова <sup>2</sup>, А. Бекарыстанқызы <sup>3</sup>

<sup>1</sup>Казахский национальный исследовательский технический университет имени К.И. Сатпаева,  
г. Алматы, Казахстан

<sup>2</sup>Университет международного бизнеса имени К. Сагадиева, г. Алматы, Казахстан

<sup>3</sup>Университет Нархоз, г. Алматы, Казахстан

\*Автор-корреспондент: Акылбеков Олжас Наурызбаевич, e-mail: o.akylbekov@satbayev.university

### Ключевые слова:

машинное обучение,  
фото- и видеоданные,  
камера наблюдения,  
трёхмерное  
моделирование,  
городская среда,  
территориальное  
планирование,  
интеллектуальные  
системы.

### АННОТАЦИЯ

В статье рассматриваются методы машинного обучения, применяемые для анализа визуальных данных (фото- и видеоматериалов), полученных с камер наблюдения, с целью построения трёхмерных моделей городской инфраструктуры. Обоснована актуальность автоматизации пространственного анализа в условиях роста объёмов визуальной информации. В исследовании применены современные алгоритмы машинного обучения, включая логистическую регрессию, деревья решений, случайный лес, методы кластеризации и глубокие нейронные сети (U-Net, ResNet, ViT). Проведено количественное сравнение всех моделей по метрикам MAE, IoU и F1-score, что позволило объективно оценить их применимость для задач 3D-моделирования городской инфраструктуры. Научная новизна заключается в комплексной интеграции методов машинного обучения и компьютерного зрения для создания цифровых двойников городской среды. Практическая значимость подтверждается возможностью использования разработанных решений в системах территориального планирования и мониторинга городской инфраструктуры.

### Түйінді сөздер:

машиналық оқыту, фото  
және бейне деректер,  
бақылау камерасы,  
үшөлшемді модельдеу,  
қалалық орта, аумақтық

### ТҮЙІНДЕМЕ

Бұл мақалада қалалық инфрақұрылымның үшөлшемді үлгілерін құру үшін бақылау камераларынан алынған визуалды деректерді (фото және бейне) талдау барысында машиналық оқыту әдістерін қолдану қарастырылады. Визуалды ақпарат көлемінің үнемі артуы кеңістіктік талдауды автоматтандыру қажеттілігін туындатады.



жоспарлау,  
интеллектуалды  
жүйелер.

Зерттеуде логистикалық регрессия, шешім ағаштары, кездейсоқ орман (random forest), кластерлеу әдістері және терең нейрондық желілер (U-Net, ResNet, ViT) сияқты заманауи машиналық оқыту алгоритмдері қолданылды. Барлық модельдердің тиімділігі MAE, IoU және F1-score метрикалары арқылы салыстырмалы түрде бағаланды. Ғылыми жаңалық — машиналық оқыту мен компьютерлік көру әдістерін біріктіре отырып, қалалық ортаның цифрлық үлгілерін жасау. Жұмыстың практикалық маңыздылығы – алынған шешімдердің аумақтық жоспарлау мен қалалық инфрақұрылымды бақылау жүйелерінде қолдану мүмкіндігі.

---

**Keywords:**

machine learning, photo and video data, surveillance camera, three-dimensional modeling, urban environment, territorial planning, intelligent systems.

---

**ABSTRACT**

This article examines machine learning methods used to analyze visual data (photos and videos) from surveillance cameras for the purpose of constructing 3D models of urban infrastructure. The study highlights the relevance of automating spatial analysis in response to the growing volume of visual information. The research applied modern machine learning algorithms, including logistic regression, decision trees, random forest, clustering methods, and deep neural networks (U-Net, ResNet, ViT). A quantitative comparison of all models was performed using MAE, IoU, and F1-score metrics, allowing for an objective evaluation of their applicability in 3D urban modeling. The scientific novelty lies in the integrated application of machine learning and computer vision techniques to create digital twins of urban environments. The practical significance is demonstrated by the potential use of the developed solutions in territorial planning and urban infrastructure monitoring systems.

---

**ВВЕДЕНИЕ**

Современное развитие цифровых технологий приводит к резкому увеличению объёмов неструктурированных данных, поступающих из надёжных источников – фото- и видеосъёмки, аэрофотосъёмки, спутниковых систем, сенсоров и датчиков. Эти потоки визуальной информации позволяют фиксировать изменения городской среды с высокой регулярностью и пространственной детализацией. Они отражают не только текущее состояние городской инфраструктуры, но и процессы её трансформации: уплотнение застройки, изменение транспортных потоков, использование общественных пространств и т.д. Однако из-за больших объёмов данных их ручная интерпретация становится невозможной, что требует применения современных аналитических методов, включая машинное обучение.

Методы машинного обучения позволяют автоматически выявлять закономерности в больших массивах визуальных данных и использовать их для пространственного анализа и прогнозирования. При этом возможен переход от низкоуровневого описания изображений к определению устойчивых признаков городской морфологии. Особенно актуально это в условиях урбанизированной среды, насыщенной сенсорами и камерами видеонаблюдения, формирующими непрерывный поток информации. Благодаря достижениям в области компьютерного зрения и глубокого обучения стало возможным извлечение пространственных признаков из изображений и реконструкция трёхмерных моделей городской среды (Hossain et al., 2020; Potok et al., 2018).

Несмотря на активное развитие методов анализа изображений, их прикладное применение в задачах пространственного планирования пока ограничено. Разработка устойчивых решений требует учёта вариативности данных, калибровки камер, различий

в городской застройке. Алгоритмы глубокого обучения демонстрируют высокую эффективность в обработке аннотированных фото- и видеоданных (Baran, 2020; Dietrich et al., 2020; Alzubaidi et al., 2021), позволяя проводить автоматическую сегментацию, классификацию объектов и генерацию трёхмерных представлений городской инфраструктуры.

Цель данного исследования — разработка и апробация подхода к построению 3D-моделей городской среды на основе визуальных данных с камер наблюдения с использованием и сравнением различных алгоритмов машинного обучения. Задачи включают: выбор и реализацию алгоритмов обработки визуальной информации; выделение пространственных признаков; анализ точности реконструкции; оценку применимости моделей для территориального планирования.

Методологическая основа работы сочетает технические и сравнительные подходы. Исходные данные представляют собой фото- и видеоматериалы городской среды, собранные в г. Алматы. Для их анализа применялись как классические алгоритмы (логистическая регрессия, деревья решений, случайный лес), так и нейросетевые архитектуры (U-Net, ResNet-50, ViT). В качестве метрик использовались IoU, F1-score, MAE и время обработки.

### **МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ**

Методологическая основа настоящего исследования опирается на технические, индуктивные и сравнительные подходы, адаптированные для пространственного анализа городской среды с применением современных методов машинного обучения.

Объект исследования включает визуальные данные (фото и видео), полученные с уличных камер наблюдения, размещённых в городской инфраструктуре. В качестве экспериментального материала использовались видеопотоки в форматах H.264 и MJPEG, а также фотоснимки в формате JPEG, полученные с устройств с разрешением не менее 1920×1080 пикселей.

Обработка данных осуществлялась на вычислительном комплексе с графическим процессором NVIDIA RTX 3080, с использованием Python 3.10, платформ TensorFlow 2.13 и PyTorch 2.0, а также библиотек OpenCV, NumPy и scikit-learn (Weng et al., 2024).

Предобработка изображений включала нормализацию, коррекцию перспективы и стабилизацию видео. Для извлечения ключевых признаков применялись алгоритмы SIFT и ORB, после чего осуществлялась корреляция между последовательными кадрами для восстановления информации о сцене. Полученные данные использовались для построения плотных карт и последующего формирования трёхмерных моделей методом Structure from Motion (Rodríguez-Lira et al., 2025; Moradi, 2025; Akyzbekov et al., 2025).

Технический подход предусматривал количественное описание параметров визуальных данных, включая пространственное распределение объектов, изменения освещённости, геометрию сцены и плотность застройки. Для анализа использовались следующие методы:

- гистограммы частот – для оценки распределения интенсивностей пикселей на изображениях;
- стандартное отклонение – как мера разброса значений яркости;
- коэффициент ранговой корреляции Спирмена – для выявления зависимостей между параметрами изображений и метками данных;
- PCA (Principal Component Analysis) – применялся как метод линейного снижения размерности, позволяющий выделить наиболее значимые компоненты признакового пространства без потери ключевой информации.

Использование PCA обеспечивало уменьшение избыточности в данных и ускорение обучения моделей за счёт исключения неинформативных признаков. Этот подход

особенно эффективен при обработке изображений с высокой вариативностью по освещению и ракурсам.

Индуктивный подход был реализован через аннотирование и кластеризацию видеоданных с применением алгоритмов K-средних и DBSCAN. Модели машинного обучения, обученные на датасетах Cityscapes и KITTI, использовались для выявления пространственных закономерностей городской застройки. Адаптированные архитектуры ResNet и U-Net применялись в рамках контролируемого и трансферного обучения.

Сравнительный анализ охватывал алгоритмы CNN, деревья решений, случайный лес и градиентный бустинг. Оценка производилась по метрикам точности классификации, времени обработки, устойчивости к шуму и способности к обобщению. Верификация осуществлялась с использованием 5-кратной кросс-валидации и метрик MAE, IoU и F1-score.

Фотограмметрия и методы компьютерного зрения использовались для построения 3D-моделей на основе изображений, аэрофотоснимков и спутниковых данных, что обеспечило многомасштабное покрытие территории. Применялись нейросетевые алгоритмы глубокой свёртки и методы многоракурсной стереорекострукции. Выделенные опорные точки кластеризовались и интегрировались в единую цифровую сцену, обеспечивая высокую точность геопривязки.

Программные эксперименты проводились на урбанистических ландшафтах восточной части города Алматы с последующим сопоставлением 3D-моделей с геоинформационными данными (форматы GeoTIFF и Shapefile), что обеспечило проверку достоверности пространственной реконструкции.

Для оценки качества применённых архитектур были выбраны модели U-Net, ResNet и Vision Transformer (ViT), обладающие высокой точностью сегментации и извлечения признаков. Валидация моделей осуществлялась с разбиением выборки в пропорции 70/30 и использованием 5-fold кросс-валидации.

Критерии оценки включали:

- IoU (Intersection over Union) — для анализа перекрытия сегментированных объектов;
- F1-score – для оценки классификационной точности;
- MAE (Mean Absolute Error) — при реконструкции геометрии объектов;
- время обработки — как критерий применимости в реальном времени.

Аннотирование данных проводилось вручную и проверялось экспертами. Эксперименты охватывали изображения и видео, полученные в различных условиях освещённости и плотности застройки, с использованием данных из города Алматы, Казахстан.

В дополнение к архитектурному выбору моделей были заданы конкретные параметры обучения. Модель U-Net использовалась с глубиной в пять уровней и симметричной деконволюционной структурой, а входные изображения нормализовались до размера 256×256 пикселей. Обучение проводилось в течение 50 эпох с применением оптимизатора Adam и функции потерь binary cross-entropy, размер батча составлял 16. Архитектура ResNet-50 использовала предварительно обученные веса ImageNet, с дообучением последних слоёв и входным размером изображений 224×224 пикселя; обучение осуществлялось на протяжении 30 эпох с использованием стохастического градиентного спуска и коэффициентом обучения 0.01. Для Vision Transformer была реализована конфигурация ViT-Base с размером патча 16×16, глубиной сети 12 слоёв и размерностью скрытого пространства 768. Входные изображения приводились к размеру 224×224 пикселя, обучение длилось 30 эпох с использованием оптимизатора AdamW и шагом обучения 0.0001. Классические алгоритмы (логистическая регрессия, дерево решений, случайный лес) использовались в качестве базовой линии. Глубина дерева

ограничивалась 10 уровнями, в случайном лесе использовалось 100 деревьев. Перед обучением данные проходили нормализацию с применением метода MinMax. Все вычисления проводились на аппаратной платформе с графическим ускорителем NVIDIA RTX 3080, в среде Python 3.10 с использованием библиотек PyTorch 2.0, scikit-learn и OpenCV.

## РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Машинное обучение — это технология искусственного интеллекта, отличающаяся от традиционных программных решений тем, что она опирается на индуктивные рассуждения и адаптируется к поступающим данным (Pan et al. 2025). По мере увеличения объёма и качества обучающей выборки модели машинного обучения демонстрируют более высокую точность анализа. В рамках настоящего исследования, посвящённого методам машинного обучения для анализа видео- и фотоинформации с целью построения трёхмерных пространственных моделей городской среды в системах территориального планирования, были рассмотрены ключевые подходы, такие как классификация, регрессия, кластеризация, анализ текста, проверка аномалий, а также последовательные шаблоны. Особое внимание уделено контролируемому и неконтролируемому обучению, применяемому для выявления структурных особенностей городской инфраструктуры (Akhavi Zadegan et al. 2025; Yu Shang и et. al, 2025; Rodríguez-Lira et al. 2025).

Практически значимым стало разграничение между поверхностным и глубоким обучением, особенно в задачах извлечения признаков городской сцены из визуальных данных. Глубокие нейронные сети, в отличие от поверхностных алгоритмов, способны формировать сложные иерархические представления, что критически важно при анализе видео- и фотоданных для 3D-моделирования городского пространства (Li et al., 2024; Liu et al., 2023). На этапе обучения изображениям присваиваются категории, содержащие как детерминированную, так и вероятностную информацию, что способствует качественной реконструкции городской среды [8–9].

Для задач бинарной классификации визуальных объектов городской среды, таких как определение принадлежности пикселей или сегментов изображения к категории «здание»/«не здание», была применена модель логистической регрессии. Данный алгоритм позволяет оценить вероятность отнесения объекта к заданному классу на основе набора визуальных признаков.

Математически логистическая регрессия описывается следующим выражением:

$$P(Y = 1 | X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}}$$

где:  $P(Y = 1 | X)$  — вероятность принадлежности объекта к классу 1 (например, элемент городской застройки);  $x_1, x_2, \dots, x_n$  — признаки, извлечённые из изображения (цвет, градиент, текстурные характеристики, плотность пикселей и др.);  $\beta_0$  — свободный коэффициент (смещение);  $\beta_1, \beta_2, \dots, \beta_n$  — веса признаков, полученные в процессе обучения модели;  $e$  — экспоненциальная функция, применяемая в логистическом преобразовании.

Вероятность  $P(Y = 1 | X)$  моделируется с помощью сигмоидной функции активации, которая ограничивает значение на выходе в диапазоне от 0 до 1. Оптимизация параметров модели проводилась методом градиентного спуска с минимизацией функции потерь binary cross-entropy, что обеспечивало устойчивую сходимость даже на небольших подмножествах обучающей выборки.

В контексте данного исследования логистическая регрессия использовалась как базовая модель для классификации пикселей на семантические категории городской сцены. Несмотря на простоту, алгоритм продемонстрировал приемлемую точность на ограниченных подмножествах данных и служил сравнительной базой для оценки производительности более сложных архитектур глубокого обучения.

Алгоритм AdaBoost, построенный на механизме ансамблирования слабых классификаторов (обычно деревьев решений глубины 1–3), продемонстрировал высокую эффективность при анализе видеоинформации, направленной на построение трёхмерных моделей городской среды. Принцип работы алгоритма заключается в последовательном обучении слабых моделей с акцентом на примеры, которые ранее были классифицированы с ошибкой, что позволяет улучшать итоговую точность классификации.

Математически итоговая модель AdaBoost представляется как взвешенная сумма решений отдельных слабых классификаторов:

$$H(x) = \text{sign} \left( \sum_{t=1}^T \alpha_t h_t(x) \right),$$

где  $h_t(x)$  – слабый классификатор на  $t$ -й итерации,  $\alpha_t$  – вес, зависящий от точности соответствующего классификатора.

В условиях эксперимента алгоритм показал устойчивость к шуму и артефактам в визуальных данных, а также способность точно выделять элементы городской инфраструктуры, такие как здания, дороги и уличные объекты. При сравнении с более тяжёлыми нейросетевыми архитектурами AdaBoost продемонстрировал высокую обобщающую способность и низкое время обработки, особенно в задачах бинарной и многоклассовой классификации при ограниченных объёмах данных. Эти качества делают его применимым в условиях реального времени, когда критично учитывать вычислительные ресурсы (Wang et al., 2024; Weng et al., 2024).

Идея состоит в том, чтобы поместить файлы в более широкий социально-экономический контекст и определить с теоретической точки зрения связи, которые они представляют с другими средствами наблюдения, а также с городской средой, в которой они находятся. Такой подход позволяет выявить зависимости между зафиксированными визуальными данными и пространственными характеристиками городской инфраструктуры, включая плотность застройки, транспортные потоки и активность населения (Li et al., 2023; Niu, 2024). Эти взаимосвязи наглядно представлены на рисунке 1, где визуализируется городская сцена с учётом слоёв социального, функционального и пространственного анализа, демонстрируя, как методы машинного обучения интегрируются в систему территориального планирования



**Рисунок 1.** Городская сцена Алматы в дневное время


*Примечание – снято авторами в рамках исследования. Снимок сделан в центральной части города. Изображение используется для анализа транспортной нагрузки, плотности застройки и*

*визуального контекста городской среды. Данные могут быть использованы в системах территориального планирования и машинного обучения для извлечения признаков городской морфологии*

Особое внимание уделено процессу тестирования обученных моделей на независимых наборах данных. В условиях, приближённых к реальной съёмке городской сцены, уровень точности классификации напрямую зависит от стабильности точек интереса, ракурса и освещённости. Эти параметры критичны при создании пространственно точных 3D-моделей городской среды. Глубокие нейросети, способные к многослойной абстракции признаков, позволили адаптироваться к этим вызовам и улучшить пространственную реконструкцию (Buyukdemircioglu et al., 2022).

В рамках задач территориального планирования была апробирована методика самообучения и глубокого представления визуальных данных. Это позволило перейти от пиксельного уровня к концептуальным пространственным меткам, критически важным для 3D-моделирования городской среды. Регуляризация и оптимизация моделей минимизировали переобучение и улучшили переносимость решений между различными типами визуальных данных (Chen et al., 2025).

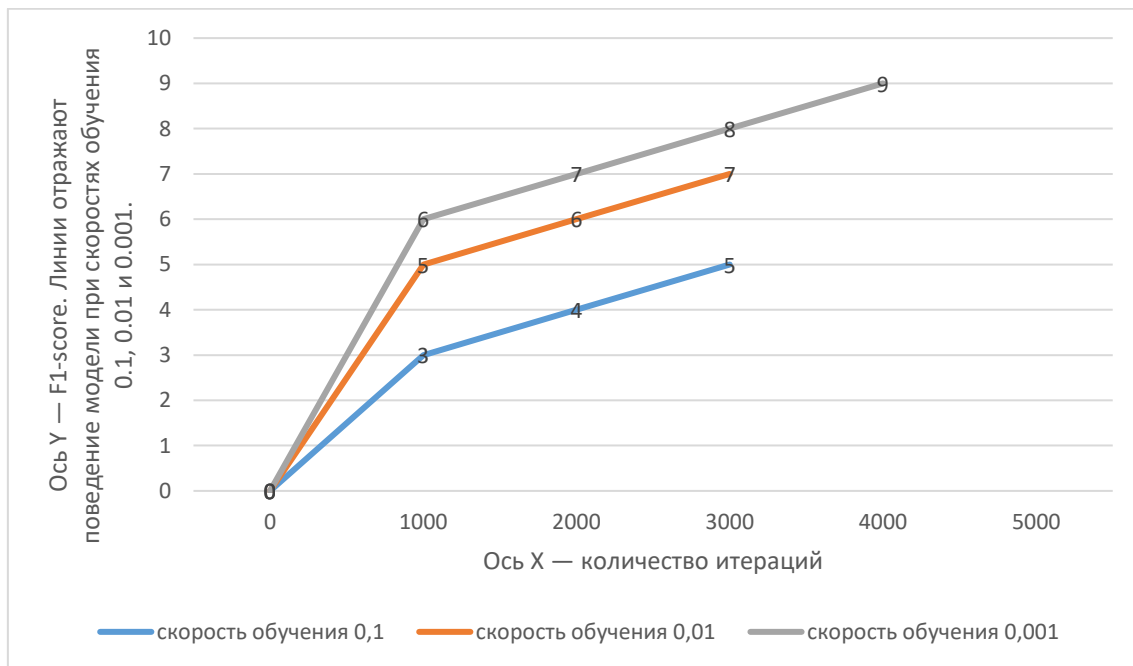
Такой подход позволяет выявить зависимости между зафиксированными визуальными данными и пространственными характеристиками городской инфраструктуры, включая плотность застройки, транспортные потоки и активность населения. На рисунке 2 представлен пример участка центральной части Алматы, где в единой визуализации совмещены контуры зданий и тепловое распределение активности. Такая интеграция даёт возможность одновременно рассматривать социальные, функциональные и пространственные слои, что демонстрирует потенциал применения методов машинного обучения для построения трёхмерных моделей городской среды и их использования в системах территориального планирования.



**Рисунок 2.** Участок центральной части Алматы (Казахстан, Алматы)

*Примечание – данные были обработаны и визуализированы с использованием программного обеспечения QGIS; исходное изображение зафиксировано авторами в рамках исследования*

Методы деревьев решений и случайных лесов использовались для анализа городской инфраструктуры, выделяя функциональные зоны по визуальным признакам. Для оценки влияния гиперпараметров дополнительно исследовалась зависимость качества классификации от скорости обучения и числа итераций. Как видно из графика, уже на первых сотнях-тысячах итераций модели на деревьях достигают стабильных значений F1-score и IoU, обучаясь существенно быстрее и с меньшими вычислительными затратами, чем более тяжёлые нейросетевые архитектуры (U-Net, ResNet-50, ViT). При увеличении числа шагов обучения оптимальные результаты достигаются при меньшей скорости (0,001), что обеспечивает более плавную сходимость и более глубокий разбор признаков. Полученные зависимости важны для настройки алгоритмов в автоматизированных системах территориального моделирования (Chajaei & Bagheri, 2025).



**Рисунок 3.** Эволюция скорости обучения метода деревьев решений при анализе фото- и видеофайлов

*Примечание – составлено авторами на основе результатов. По оси X отложено количество итераций, по оси Y – нормированное значение F1-score/IoU; линии отражают поведение модели при скоростях обучения 0,1, 0,01 и 0,001. Методы деревьев решений демонстрируют более быстрое обучение по сравнению с другими моделями, при близких значениях IoU и F1-score. Составлено автором на основе экспериментальных данных.*

Важный результат – использование градиентного спуска в качестве метода оптимизации при построении моделей, анализирующих видео- и фотоинформацию с целью восстановления трёхмерной структуры городской сцены. Метод показал стабильную сходимость даже при наличии искажений в исходных изображениях.

Кластерный анализ городских объектов проводился с использованием формулы несходства Брея-Кертиса:

$$\frac{\sum T t = 1 |x_{it} - x_{jt}|}{\sum T t = 1 (x_{it} + x_{jt})}$$

что позволило определить пространственные группы объектов и участков городской инфраструктуры. Это облегчает задачи урбанистического планирования и распределения функциональных зон [18].

Для прогнозирования функционального назначения участков использовался байесовский классификатор:

$$P(A/B) = P(A \cap B) / P(B) = [P(A) * P(B/A)] / P(B),$$

который показал высокую эффективность при работе с неполными или шумными данными городской съёмки. В условиях реального городского пространства, где часто отсутствует полная информация, такой подход обеспечивает устойчивость выводов и масштабируемость в рамках систем территориального планирования (Lynda et al., 2025).

Особого внимания заслуживает применение архитектуры Vision Transformer (ViT), разработанной в Токуо Tech, при анализе визуальных данных без использования традиционных линз. Данный метод показал высокую точность в реконструкции изображений городской среды и открыл перспективы для компактных сенсорных систем, применимых в пространственном мониторинге (Pan et al., 2022).

**Таблица 1.** Сравнение эффективности моделей машинного обучения на тестовом наборе данных (городская сцена, Алматы)

Модель	IoU (%)	F1-score	MAE (м)	Время обработки (сек/кадр)
Logistic Regression	58,3	0,69	0,34	0,12
Decision Tree	61,2	0,71	0,31	0,15
Random Forest	66,5	0,75	0,27	0,28
U-Net	74,2	0,83	0,21	0,95
ResNet-50	69,5	0,78	0,26	0,82
ViT	77,1	0,85	0,19	1,25

*Примечание – составлено авторами*

Архитектура Vision Transformer (ViT) продемонстрировала наивысшие показатели по метрикам IoU (77,1 %) и F1-score (0,85), что свидетельствует о её высокой точности при семантической сегментации городской сцены. Вместе с тем ViT характеризуется наибольшим временем обработки (1,25 сек/кадр), что может быть ограничивающим фактором в приложениях реального времени. U-Net обеспечила сбалансированное соотношение между качеством и вычислительной эффективностью (IoU – 74,2 %, время – 0,95 сек/кадр), что делает её оптимальной для практического применения в системах мониторинга городской инфраструктуры. ResNet-50 показала достойный результат по F1-score (0,78), однако по точности и скорости уступает как ViT, так и U-Net. Это может быть связано с ограниченной способностью модели эффективно обрабатывать как глобальные, так и локальные признаки при сравнительно высокой глубине сети. Классические алгоритмы – логистическая регрессия, дерево решений и случайный лес – продемонстрировали более низкие значения метрик точности (IoU < 67 %), однако значительно превосходят нейросетевые подходы по скорости обработки. Это определяет их применимость в задачах предварительной фильтрации данных или в условиях ограниченных вычислительных ресурсов. Метрика MAE (средняя абсолютная ошибка) позволяет дополнительно оценить точность восстановления геометрических характеристик объектов. Наименьшее значение MAE (0,19 м) зафиксировано у модели ViT, за ней следует U-Net (0,21 м), что подтверждает их превосходство в реконструкции пространственных структур.

Таким образом, различия в производительности моделей объясняются их архитектурными особенностями, уровнем абстракции признаков и степенью устойчивости к шуму. Глубокие нейронные сети демонстрируют высокую точность при увеличенных вычислительных затратах, тогда как традиционные алгоритмы обеспечивают оперативную обработку, но уступают в детальности и способности к обобщению. Выбор модели в практическом применении должен определяться требованиями к точности, скорости и ресурсам целевой системы.

## ЗАКЛЮЧЕНИЕ

Настоящее исследование было направлено на оценку применимости алгоритмов машинного обучения к задачам пространственного анализа городской среды на основе визуальных данных. Проведённое сравнение классических и нейросетевых моделей позволило выявить существенные различия в их производительности, интерпретируемости и применимости к условиям реального времени. Нейросетевые архитектуры, в частности Vision Transformer (ViT) и U-Net, продемонстрировали наилучшие показатели точности в задачах сегментации и 3D-реконструкции, тогда как классические методы, включая логистическую регрессию и деревья решений, показали лучшие результаты по скорости обработки и устойчивости при ограниченных вычислительных ресурсах.

В ходе экспериментов была подтверждена эффективность использования глубоких моделей при наличии полноценных аннотированных датасетов и стабильных условий визуального захвата. Тем не менее высокая вычислительная сложность некоторых архитектур ограничивает их применение в системах реального времени без предварительной оптимизации. Особое значение имеет правильная настройка параметров моделей — глубины, размера входного изображения, количества эпох — что в случае нейросетей существенно влияет на результативность и сходимость. Несмотря на полученные метрики, в анализе результатов остаются нерешёнными вопросы интерпретации различий между архитектурами, объяснение которых требует дополнительного изучения чувствительности моделей к типам признаков и качеству входных данных.

Исследование сопровождается рядом ограничений. Во-первых, отсутствует единый протокол стандартизации визуальных данных, полученных из различных источников. Во-вторых, модели не тестировались на мультисенсорных данных (LiDAR, тепловизоры), что ограничивает универсальность результатов. В-третьих, не была охвачена оценка устойчивости моделей к шуму, искажениям и неполноте данных, характерным для городских условий наблюдения.

В качестве перспективных направлений дальнейших исследований следует отметить интеграцию моделей машинного обучения с геоинформационными системами, применение генеративных методов для автоматического дополнения недостающих участков городской сцены, а также развитие архитектур с учётом требований explainable AI. Расширение экспериментальной базы и внедрение методов самообучения представляют собой ключевые векторы повышения масштабируемости и адаптивности разрабатываемых решений в рамках концепции «умного города».

Таким образом, полученные результаты подтверждают научную и практическую значимость комплексного подхода, сочетающего визуальную аналитику, методы компьютерного зрения и машинного обучения для пространственного моделирования городской среды. Разработанная методология может служить основой для построения автоматизированных систем мониторинга, анализа и планирования городской инфраструктуры в условиях быстро развивающихся урбанистических пространств.

**КОНФЛИКТ ИНТЕРЕСОВ:** Авторы заявляют об отсутствии конфликта интересов.

**ФИНАНСИРОВАНИЕ:** Данное исследование выполнено в рамках подготовки диссертации на соискание степени доктора философии (PhD) по государственному образовательному заказу без привлечения дополнительного грантового финансирования. Работа проведена в Satbayev University в рамках образовательной и исследовательской деятельности докторанта, а также совместно с Университетом Нархоз и Университетом международного бизнеса им. К. Сагадиева.

**БЛАГОДАРНОСТИ:** Авторы выражают искреннюю признательность коллегам из Satbayev University за методологическую поддержку, активное участие в обсуждении теоретических и прикладных аспектов применения методов машинного обучения, а также за помощь в интерпретации полученных результатов. Отдельная благодарность выражается анонимным рецензентам за ценные замечания, способствовавшие повышению научной обоснованности и качества статьи. Поддержка исследовательской среды Satbayev University сыграла важную роль в реализации данного проекта, направленного на развитие цифровых подходов в системах территориального планирования.

**УВЕДОМЛЕНИЕ ОБ ИСПОЛЬЗОВАНИИ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА:** В процессе подготовки настоящей научной статьи авторы использовали возможности генеративного искусственного интеллекта исключительно для улучшения формулировок, редактирования и структурирования текста. Все научные идеи, аналитика, интерпретация результатов и выводы являются исключительно авторскими. Генеративные модели не применялись для создания данных или подмены научного анализа.

#### СПИСОК ЛИТЕРАТУРЫ

- Akhavi Zadegan, A., Vivet, D., Hadachi, A. (2025). Challenges and advancements in image-based 3D reconstruction of large-scale urban environments: a review of deep learning and classical methods. *Frontiers in Computer Science*, 7. <https://doi.org/10.3389/fcomp.2025.1467103>
- Akylbekov, O. N., Kasenkhan, A. M., & Baidildinova, S. T. (2025). AI methods in education: A global review and examples of application in Kazakhstan. *Bulletin of D. Serikbayev EKTU*, pp. 103–113. <https://doi.org/10.51885/1561-421220252103>
- Akylbekov, O., Al Said, N., Martínez-García, R., & Gura, D. (2022). ML models and neural networks for analyzing 3D data spatial planning tasks: Example of Khasansky urban district of the Russian Federation. *Advances in Engineering Software*, 173, 103251. <https://doi.org/10.1016/j.advengsoft.2022.103251>
- Buyukdemircioglu, M., et al. (2022). Deep learning for 3D building reconstruction: A review. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B2-2022, 359–366. <https://doi.org/10.5194/isprs-archives-XLIII-B2-2022-359-2022>
- Čahojová, L., Jarolímek, I., Klímová, B., Kollár, M., Michalková, M., Mikula, K., Ožvat, A. A., Slabejová, D., & Šibíková, M. (2025). Integration of ground-based and remote sensing data with deep learning algorithms for mapping habitats in Natura 2000 protected oak forests. *Basic and Applied Ecology*. <https://doi.org/10.1016/j.baae.2025.01.006>
- Chajaei, F., & Bagheri, H. (2025). LOD1 3D City Model from LiDAR: The Impact of Segmentation Accuracy on Quality of Urban 3D Modeling and Morphology Extraction. *Remote Sensing Applications: Society and Environment*. <https://doi.org/10.1016/j.rsase.2025.101534>
- Chen, S., Wang, Z., Hong, C., Sun, Y., Jia, H., & Liu, W. (2025). Self-supervised learning of end-to-end 3D LiDAR odometry for urban scene modeling. *Remote Sensing*, 17(15), 2661. <https://doi.org/10.3390/rs17152661>

- Li, F., et al. (2023). Machine learning and remote sensing integration for urban studies. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2023.104653>
- Li, Y., et al. (2024). A method for extracting buildings from remote sensing imagery using a 3D Joint Attention module. *Scientific Reports*. <https://www.nature.com/articles/s41598-024-70019-z>
- Liu, J., et al. (2023). Deep learning-based multi-view stereo matching and 3D real-scene reconstruction framework (Deep3D). *Computers & Geosciences*. <https://doi.org/10.1016/j.isprsjprs.2023.08.015>
- Lynda, D., Logeswari, G., Tamilarasi, K., & Rakesh, S. (2025). Hybrid Bayesian deep learning model for predicting urban heat island intensity in African cities. *Scientific Reports*. <https://doi.org/10.1038/s41598-025-13492-4>
- Moradi, L. (2025). Implications of Artificial Intelligence for Assessing the Built Environment: Urban data collection methods and machine learning algorithms. *Journal of Urban Planning and Development*. <https://doi.org/10.1080/10630732.2025.2468142>
- Niu (2024). Overview of image-based 3D reconstruction technology. *JEOS: Journal of the European Optical Society*. <https://doi.org/10.1051/jeos/2024018>
- Pan, J., et al. (2025). Machine Learning-Enhanced 3D GIS Urban Noise Simulation. *Geoinformatics Journal*, 14(6), 223.
- Pan, X., Chen, X., Takeyama, S., & Yamaguchi, M. (2022). Image reconstruction with transformer for mask-based lensless imaging. *Optics Letters*, 47(7), 1843–1846. <https://doi.org/10.1364/OL.455378>
- Rodríguez-Lira, D.-C., Córdova-Esparza, D.-M., Terven, J., Romero-González, J.-A., Alvarez-Alvarado, J. M., González-Barbosa, J.-J., & Ramírez-Pedraza, A. (2025). Recent developments in image-based 3D reconstruction using deep learning: Methodologies and applications. *Electronics*, 14(15), 3032. <https://doi.org/10.3390/electronics14153032>
- Wang, C., et al. (2024). Deep learning-based 3D reconstruction from multiple images. *Neurocomputing*. <https://doi.org/10.1016/j.neucom.2024.128018>
- Weng, Q., et al. (2024). How will AI transform urban observing, sensing, imaging, and mapping? *Nature*. <https://doi.org/10.1038/s42949-024-00188-3>
- Yu Shang et al. (2024). UrbanWorld: An Urban World Model for 3D City Generation. arXiv preprint arXiv:2407.11965. <https://arxiv.org/abs/2407.11965>

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Акылбеков Олжас Наурызбаевич** – Ақпараттық технологиялар магистрі, Қ.И. Сәтбаев атындағы Қазақ ұлттық зерттеу техникалық университеті, Алматы, Қазақстан

**Акылбеков Олжас Наурызбаевич** – Магистр информационных технологий, Казахский национальный исследовательский технический университет имени К.И. Сатпаева, Алматы, Казахстан

**Akylbekov Olzhas Nauryzbayevich** – Master of Information Technology, Kazakh National Research Technical University named after K.I. Satpayev, Almaty, Kazakhstan

e-mail: o.akylbekov@satbayev.university

ORCID: <https://orcid.org/0000-0002-7188-5550> ,



**Молдагулова Айман Николаевна** – физика-математика ғылымдарының кандидаты, Қ.И. Сәтбаев атындағы Қазақ ұлттық зерттеу техникалық университеті, Алматы, Қазақстан

**Молдагулова Айман Николаевна** – Кандидат физико-математических наук, Казахский Национальный исследовательский технический университет имени К.И. Сатпаева, Алматы, Қазақстан

**Moldagulova Aiman Nikolaevna** – Candidate of Physical and Mathematical Sciences, Kazakh National Research Technical University named after K.I. Satpayev, Almaty, Kazakhstan,  
e-mail: a.moldagulova@satbayev.university,  
ORCID: <https://orcid.org/0000-0002-1596-561X>,



**Закария Гульназ Саянкызы** – Қолданбалы геоинформатика ғылымдарының магистрі, Қ.И. Сәтбаев атындағы Қазақ ұлттық зерттеу техникалық университеті, Алматы, Қазақстан

**Закария Гульназ Саянкызы**– Магистр наук в области прикладной геоинформатики, Казахский национальный исследовательский технический университет имени К.И. Сатпаева, Алматы, Казахстан

**Zakariya Gulnaz Sayankyzy** – Master of Science in Applied Geoinformatics, Kazakh National Research Technical University named after K.I. Satpayev, Almaty, Kazakhstan,  
e-mail: g.zakariya@satbayev.university,  
ORCID: <https://orcid.org/0009-0001-7774-7634>



**Байдильдинова Сабина Талгатовна** – педагогика ғылымдарының магистрі, Қ. Сағадиев атындағы Халықаралық бизнес университеті, Алматы, Қазақстан

**Байдильдинова Сабина Талгатовна** – Магистр педагогических наук, Университет международного бизнеса им. К. Сағадиева, Алматы, Казахстан

**Baidildinova Sabina Talgatkyzy** – Master of Pedagogical Sciences, K. Sagadiyev University of International Business, Almaty, Kazakhstan,  
e-mail: baidildinova.s@gmail.com,  
ORCID: <https://orcid.org/0009-0002-5026-6504>



**Бекарыстанкызы Акбаян** – PhD, қауымдастырылған профессор, Цифрлық технологиялар мектебі, NARXOZ Университеті, Алматы қ., Қазақстан

**Бекарыстанкызы Акбаян** – PhD, доцент Школы цифровых технологий, Университет Нархоз, г. Алматы, Казахстан.

**Bekarystankyzy Akbayan** – PHD, Associate Professor, School of Digital Technologies, Narхоз University, Almaty, Kazakhstan,  
e-mail: akbayan.b@gmail.com,  
ORCID: <https://orcid.org/0000-0003-3984-2718>

[https://doi.org/10.51885/3134-8025\\_IICS\\_2026\\_1\\_2](https://doi.org/10.51885/3134-8025_IICS_2026_1_2)

SRSTI 67.01.93

## APPLICATION OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES FOR ENSURING SAFETY ON CONSTRUCTION SITES

## ПРИМЕНЕНИЕ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ОБЕСПЕЧЕНИЯ БЕЗОПАСНОСТИ НА СТРОИТЕЛЬНЫХ ПЛОЩАДКАХ

## ҚҰРЫЛЫС АЛАҢДАРЫҢДА ҚАУІПСІЗДІКТІ ҚАМТАМАСЫЗ ЕТУ ҮШІН ЖАСАНДЫ ИНТЕЛЛЕКТ ТЕХНОЛОГИЯЛАРЫН ҚОЛДАҢУ

S. Akhazhanov <sup>1\*</sup>, O. Bibalayev <sup>1</sup>, R. Muratkhan <sup>1</sup>, D. Mikhailov <sup>2</sup>, A. Montaeва <sup>2</sup>

<sup>1</sup>Karaganda Buketov University, Karaganda, Kazakhstan

<sup>2</sup>Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan

\*Corresponding author: Akhazhanov Sungat Berkinovich, e-mail: stjg@mail.ru

### Keywords:

artificial intelligence,  
construction site, U.S.  
Bureau of Labor Statistics,  
personal protective  
equipment, monitoring,  
predictive analytics,  
automation.

### ABSTRACT

In the context of the rapid development of the construction industry, safety issues on construction sites are becoming increasingly relevant. According to various sources 60 to 80% of accidents at construction sites are related to safety violations. This is due to the challenging working conditions, the high degree of interaction with heavy machinery and the shortcomings of existing control methods, which largely rely on human factors. In response to these challenges, the project proposes the development of an intelligent monitoring system for construction sites using artificial intelligence (AI) and computer vision technologies. The primary function of the system is the automatic detection of safety violations, including the absence of personal protective equipment (helmets, vests, goggles, etc.), as well as facial recognition for employee identification and access control. Additionally, the system will incorporate alcohol level monitoring for workers before they are permitted to begin their shifts. The implementation of this system is expected to provide continuous and objective monitoring of safety compliance, minimize the impact of the human factor, increase the responsiveness to incidents, and ultimately lead to a significant reduction in injuries and accidents. This interdisciplinary development integrates advancements in AI, construction technologies, and safety management. The system's deployment will also promote the digitalization of the construction industry, enhance its competitiveness, and establish a scientific and technological foundation for further research and innovative solutions in the field of industrial safety.

### Түйінді сөздер:

жасанды интеллект,  
құрылыс алаңы, АҚШ

### ТҮЙІНДЕМЕ

Құрылыс саласының қарқынды дамуы жағдайында құрылыс алаңдарындағы қауіпсіздікті қамтамасыз ету мәселелері күн сайын



© 2026 S. Akhazhanov, O. Bibalayev, R. Muratkhan, D. Mikhailov, A. Montaeва

This work is licensed under a Creative Commons Attribution 4.0

International License (CC BY 4.0).

<https://creativecommons.org/licenses/by/4.0/>

Еңбек статистикасы  
бюросы, жеке қорғаныс  
құралдары, мониторинг,  
предиктивті аналитика,  
автоматтандыру

өзектілігін арттыруда. Түрлі дереккөздердің мәліметінше, құрылыс нысандарында орын алатын жазатайым оқиғалардың 60–80 %-ы еңбек қауіпсіздігі ережелерінің бұзылуымен байланысты. Бұл жағдайлар жұмыс жағдайларының күрделілігімен, ауыр техникалармен тығыз әрекеттесумен және адам факторына негізделген бақылау әдістерінің кемшіліктерімен түсіндіріледі. Осы сын-қатерлерге жауап ретінде жоба аясында құрылыс нысандарын интеллектуалды бақылау жүйесін жасау ұсынылады, ол жасанды интеллект (ЖИ) пен компьютерлік көру технологияларын қолдануға негізделген. Жүйенің негізгі мақсаты – қауіпсіздік техникасының бұзушылықтарын автоматты түрде анықтау, соның ішінде жеке қорғаныс құралдарының (каска, жилет, көзілдірік және т.б.) жоқтығын анықтау және жұмысшыларды тану мен нысандарға кіруді бақылау үшін фейс-контроль жүргізу. Сонымен қатар, жүйеге қызметкерлердің жұмысқа кірісер алдындағы алкоголь деңгейін бақылау функциясы енгізіледі. Жүйенің енгізілуі қауіпсіздік нормаларын сақтауды үздіксіз және объективті бақылауды қамтамасыз етіп, адам факторына тәуелділікті азайтады, оқыс оқиғаларға әрекет ету жеделдігін арттырады және жарақаттар мен апаттар санын айтарлықтай қысқартуға әкеледі деп күтілуде. Бұл әзірлеме пәнаралық сипатқа ие болып, ЖИ, құрылыс технологиялары және қауіпсіздікті басқару салаларындағы жетістіктерді біріктіреді. Жүйенің енгізілуі құрылыс саласын цифрландыруға, оның бәсекеге қабілеттілігін арттыруға және өнеркәсіптік қауіпсіздік саласындағы болашақ зерттеулер мен инновациялық шешімдерге арналған ғылыми-техникалық база қалыптастыруға ықпал етеді.

**Ключевые слова:**

искусственный интеллект,  
строительная площадка,  
бюро статистики труда  
США, индивидуальные  
средства защиты,  
мониторинг,  
предиктивная аналитика,  
автоматизация

**АННОТАЦИЯ**

В условиях активного развития строительной отрасли вопросы обеспечения безопасности на строительных площадках приобретают всё большую актуальность. По данным различных источников, от 60 до 80% несчастных случаев на строительных объектах связаны с нарушениями техники безопасности. Это обусловлено сложными условиями труда, высокой степенью взаимодействия с тяжёлой техникой, а также недостатками в существующих методах контроля, основанных на человеческом факторе. В ответ на данные вызовы в рамках проекта предлагается создание интеллектуальной системы мониторинга строительных объектов с использованием технологий искусственного интеллекта (ИИ) и компьютерного зрения. Основная задача системы – автоматическое выявление нарушений техники безопасности, включая отсутствие индивидуальных средств защиты (каска, жилета, очков и т.д.), а также проведение фейс-контроля для идентификации сотрудников и контроля доступа на объекты. Кроме того, в систему будет интегрирована функция контроля уровня алкоголя у работников перед допуском к работе. Предполагается, что внедрение данной системы обеспечит непрерывный и объективный контроль за соблюдением норм безопасности, минимизирует влияние человеческого фактора, повысит оперативность реагирования на инциденты и, как следствие, приведёт к значительному снижению числа травм и несчастных случаев. Разработка носит междисциплинарный характер и объединяет достижения в области ИИ, строительных технологий и управления безопасностью. Внедрение системы также

---

будет способствовать цифровизации строительной отрасли, росту её конкурентоспособности и формированию научно-технического задела для дальнейших исследований и инновационных решений в сфере промышленной безопасности.

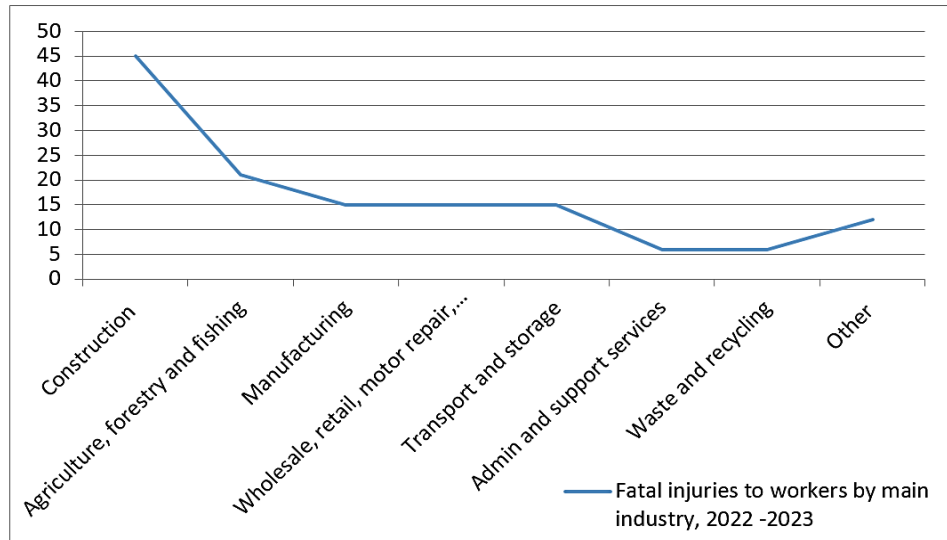
---

## INTRODUCTION

Modern construction is associated with numerous risk factors, including interaction with heavy machinery, working at heights, exposure to adverse weather conditions, and high personnel density on construction sites. Despite the presence of regulations and standards, traditional safety methods based on periodic inspections and visual monitoring often prove ineffective in the face of the high dynamism and complexity of construction processes. These methods rely heavily on the human factor and are unable to provide continuous monitoring. According to estimates by international and national organizations, 60 to 80% of workplace accidents occur due to non-compliance with occupational safety regulations. Data from the U.S. Bureau of Labor Statistics indicate that the fatality rate among construction workers is nearly six times higher than in other sectors of the economy, highlighting the urgent need for fundamentally new approaches to ensuring safety. Amid the rapid digitalization of the economy, including the construction industry, there is an urgent need for intelligent systems capable of operating in real time and effectively identifying potential threats before critical situations arise. This study proposes an innovative AI-based approach that integrates predictive analytics, computer vision, and Internet of Things (IoT) sensors, aimed at establishing a new paradigm in safety management. Predictive analytics enables the analysis of large datasets related to incidents, weather conditions, and technical failures, identifying patterns and allowing for the prediction of potentially hazardous scenarios. AI-powered cameras in real time detect the absence of personal protective equipment, equipment misuse, and abnormal personnel behavior, automatically notifying management for prompt response. IoT sensors track environmental parameters, such as dust levels, noise, temperature, and vibrations and trigger safety protocols when thresholds are exceeded. The integration of all system components into a unified digital platform ensures continuous monitoring, minimizes human error, enhances workers' situational awareness, and fosters a strong safety culture. As part of the project, the development and pilot implementation of the software platform Futurism Sentinel Sphere is being carried out. The platform is adapted to various types of construction projects, including residential, industrial, and infrastructure construction. The system is capable of automatically detecting violations, performing facial recognition, registering employee entry and exit, and monitoring workers' conditions, including alcohol testing. The implementation of this technology aims to significantly reduce the number of emergency situations, optimize safety management processes, increase transparency, reduce time and financial costs, and improve the overall quality of construction work. The interdisciplinary approach combining advancements in artificial intelligence, construction technologies, occupational safety standards, and engineering informatics, makes the project particularly relevant for the Republic of Kazakhstan. It supports the development of national technological capacity, strengthens the position of domestic companies in the construction market, and contributes to the training of highly qualified specialists in digital technologies and industrial safety. Thus, the application of AI as both a research and practical tool for safety in construction opens new horizons for transforming the industry and building a more sustainable, secure, and technologically advanced future.

According to data from the U.S. Bureau of Labor Statistics, the fatality rate among construction workers is nearly six times higher than that of workers in other sectors of the economy (Figure 1) (International Labour Organization, 2018). This striking statistic underscores the urgent need for decisive solutions to improve safety on construction sites. Under current conditions, traditional monitoring methods often fail to timely identify and prevent hazardous situations,

necessitating the use of innovative technologies such as artificial intelligence and computer vision to automate monitoring and minimize risks (International Labour Organization, 2018). Fatalities Among Workers by Major Industry Sectors, 2022-2023. The construction, agriculture, and fishing sectors continue to account for the highest number of worker fatalities due to accidents each year.




**Figure 1.** Worker Fatalities by Major Industry Sectors, 2022-2023 (USA)

*Note – compiled by the authors*

In Kazakhstan, the level of occupational injuries remains high: approximately 1,500 individuals are injured at work each year, and around 200 die, with real numbers likely higher due to underreporting of incidents. The causes of workplace accidents include both systemic management issues, such as lack of oversight, cost-cutting on safety measures, and hiring without official contracts and individual negligence among workers. Despite a gradual decline in injuries and fatalities since 2012, the situation remains alarming: over one million Kazakhstani citizens work in unfavorable and hazardous conditions. Amid systemic corporate irresponsibility and the limited authority of labor inspections, the burden increasingly falls on the workers themselves, who are often left unprotected due to informal employment and ineffective institutional mechanisms. Trade union representatives emphasize the need for collective agreements and greater worker involvement in defending their rights. At the same time, the positive experience of foreign companies operating in Kazakhstan demonstrates that safe labor is achievable through strict compliance with procedures and employer accountability. European practices show significantly lower injury rates, attributed to effective institutions, oversight, and a strong occupational safety culture, an area Kazakhstan still has to develop (Jung et al., 2022).

This research direction is promising and rapidly evolving. Publications in this field, as well as the number of citations in the Web of Science database, show steady annual growth, indicating increasing interest from the scientific community in this topic (Figure 2).

Globally, the construction industry is marked by a high number of both fatal and non-fatal accidents. According to the International Labour Organization, construction workers in developed countries face nearly four times the risk of fatal incidents compared to workers in other professions (International Labour Organization, 2018). Fatal and permanently disabling accidents occur at an alarmingly high rate in the construction sector (Jung, 2022; Hussain, 2023; Park, 2023). For example, South Korea reports the highest average fatality rate 17.9, compared to 9.4 in the United States and 5.3 in China (Choi et al., 2019). The construction industry, known for its complexity, heavily relies on manual labor to perform control and supervisory functions.



**Figure 2.** Number of Publications and Citations in Web of Science

*Note – compiled by the authors*

However, relying on human labor for safety monitoring has proven to be costly, labor-intensive, and prone to errors, which reduces overall efficiency. At the same time, ensuring employee safety remains a key responsibility of construction companies, necessitating accelerated processes, increased productivity, and rapid resolution of safety issues on construction sites (Xiao, 2021; Chen, 2022; Suh, 2023; Hussain, 2024; Soltani, 2024). Zheng and Li analyzed studies conducted between 1991 and 2021, emphasizing the importance of utilizing information technologies, including computer vision, virtual reality, and simulation to enhance risk awareness and safety measures in the construction sector (Zeng, 2022). In recent years, computer vision technologies have been widely adopted across various industries, including construction, where they play a critical role in improving safety and monitoring operations (Wang, 2024).

Significant contributions have been made through the development of personal protective equipment (PPE) detectors, which help monitor compliance with safety regulations (Fang, 2018; Fang, 2018; Huang, 2021; Han, 2022; Hung, 2019; Wu, 2019). Most research in construction safety monitoring has focused on helmet detection. For example, Bo et al., (2019) proposed a YOLOv3-based method demonstrating high accuracy; Gu et al., 2021 developed a helmet detection approach using YOLOv4; and Zhou et al., 2021 introduced a YOLOv5-based method noted for its high precision and real-time performance. In addition to YOLO-based technologies, Long et al., 2019, Wu et al., 2019, and Li et al., 2020 proposed solutions using the Single Shot Multibox Detector (SSD), which also yielded promising results. Furthermore, several studies employed convolutional neural networks (CNNs) to recognize workers' safety vests (Hung, 2019; Jeon, 2020; Ali, 2021). However, despite their successful application in controlled environments, these methods have not yet been implemented or tested on real construction sites in real-time scenarios (Khan, 2023). They also do not always ensure accurate detection in every frame, leading to false positives or missed detections due to occlusion or object overlap (Li, 2023), which in turn reduces the effectiveness of automated monitoring systems. According to a bibliometric study by Luo et al., 2022, both developed and developing countries have adopted artificial intelligence (AI) technologies to address safety issues on construction sites. In the Republic of Kazakhstan, research on the application of AI for construction site safety monitoring is still at an early stage. Most existing studies focus on the implementation of digital technologies and intelligent construction management systems; however,

there is a lack of research specifically dedicated to automatic safety violation detection using AI. Studies by Turlybayev (2022) and Sarsenbayev (2021) emphasize the need to implement digital technologies and automation systems to enhance safety at construction sites in Kazakhstan, highlighting persistent issues such as high injury rates and the low effectiveness of traditional safety control systems. Concurrently, research analyzing the causes of construction site accidents has revealed significant shortcomings in the current safety system (Sukhachev, 2025), underlining the need for modern solutions such as breathalyzers and worker condition monitoring systems. Currently, most existing safety systems on construction sites use fragmented elements, such as video surveillance and access control, but comprehensive solutions that integrate safety violation detection, facial recognition, and alcohol level monitoring have been scarcely studied or implemented. Moreover, such systems often suffer from limited response speed and accuracy, which reduces their practical effectiveness. The new project aims to address these shortcomings by developing an integrated system that automates monitoring, reduces the burden on inspectors, and minimizes human error. Based on AI and computer vision technologies, the system will operate continuously, with scalability and adaptability for different construction sites. The key distinguishing feature of the proposed solution lies in its comprehensiveness for the first time in Kazakhstan, a single system will integrate automatic detection of safety violations, worker identification, and health status monitoring, including alcohol testing, thereby significantly enhancing overall safety levels. The project holds strong commercialization potential and may contribute to the digitalization of the construction sector and the development of intelligent risk management systems. The scientific novelty of the project lies in the development of a unique integrated platform that combines AI, computer vision, facial recognition, and sensor technologies, an approach not previously applied in the construction industry of Kazakhstan. The project promotes the advancement of interdisciplinary research in machine learning, automation, and industrial safety. Its outcomes may serve as a foundation for new approaches to risk management amid ongoing urbanization and growth in the construction sector. Thus, the implementation of such a system will contribute to reducing accidents and injuries, saving costs for employers, enhancing the industry's public image, and improving working conditions. Taken together, these factors make the project relevant, innovative, and socially significant.

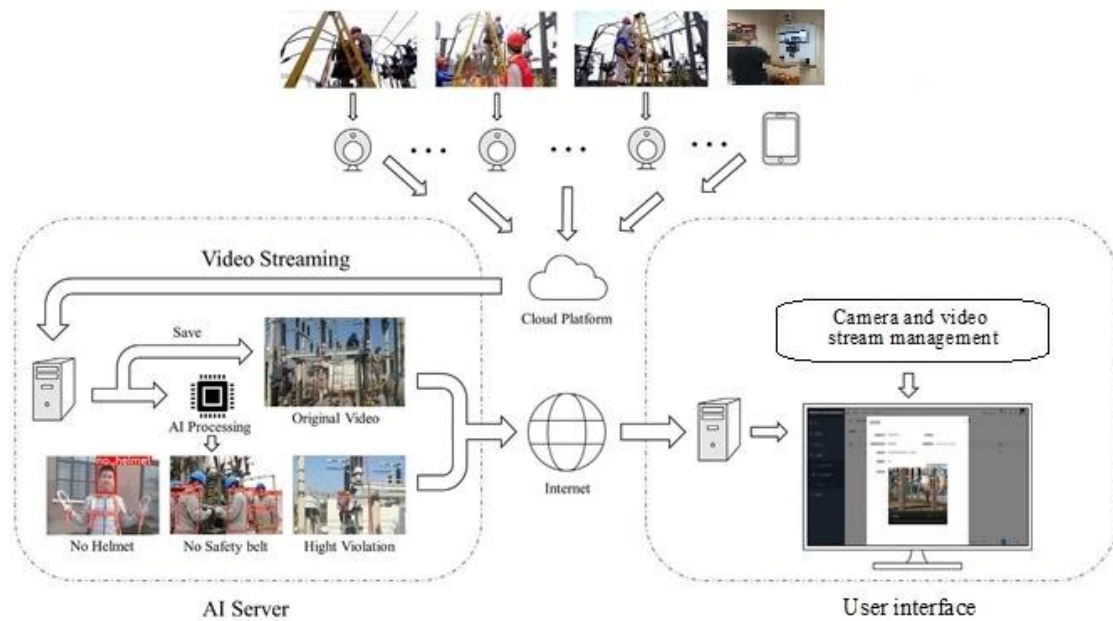
## **MATERIALS AND METHODS**

To date, most existing safety systems on construction sites are limited to the use of individual components such as surveillance cameras or access control systems. However, comprehensive solutions that integrate safety violation detection, facial recognition, and alcohol level monitoring remain largely underexplored and have not been widely implemented. Moreover, current systems are prone to false alarms and often fail to respond promptly to changes in work processes, creating serious barriers to ensuring reliable and timely worker protection. In response to these challenges, an innovative project is being developed to address current shortcomings by integrating all control elements into a single intelligent platform designed to significantly enhance safety on construction sites. A key advantage of the proposed system is its automated monitoring capability, which reduces the burden on inspectors and minimizes human error. The system will operate continuously, using artificial intelligence and computer vision technologies to perform real-time video stream analysis and detect potential violations. An important feature of the project is its scalability and adaptability to the specific needs of various construction companies. Unlike existing solutions in Kazakhstan and abroad, this project is based on a comprehensive approach that simultaneously performs three key functions: automatic detection of safety violations, biometric identification of workers through facial recognition systems, and condition monitoring via alcohol level sensors. This integrated functionality is being implemented for the first time within a single system, lending the project both scientific novelty and high practical significance. AI and computer vision technologies will enable

the recognition of critical situations, such as the absence of protective equipment, workers' presence in hazardous zones, and the execution of risky actions. Meanwhile, facial recognition and sobriety checks will ensure access control and prevent incidents related to human factors. The development of this system is especially relevant for large-scale construction projects with high personnel density and intensive workflows, where the risk of accidents is significantly elevated. The project contributes to the advancement of interdisciplinary research in automation, machine learning, and intelligent data analysis, while also offering new approaches to safety management in the context of increasing urbanization and the development of Kazakhstan's construction sector. The scientific and technological demands of the project stem from the need to create adaptive AI-based automated solutions for effective monitoring and timely response to hazardous situations, making its contribution to improving occupational safety particularly valuable. The socio-economic impact includes reductions in injury and fatality rates, preservation of workers' health, lower costs associated with incident response, and overall gains in labor productivity. The project's innovativeness and competitiveness are grounded in its use of advanced technologies in multisensor analysis, machine vision, and intelligent control systems, which help minimize risks, accelerate decision-making, and enable integration with other safety infrastructures, making this solution both timely and in high demand in the construction technology market.

The project hypothesis posits that the implementation of an intelligent monitoring system incorporating facial recognition and alcohol level detection will significantly improve the effectiveness of identifying and preventing safety violations on construction sites. To test this hypothesis, a comprehensive research strategy will be employed, combining descriptive, correlational, and experimental methods. First, data on the current state of safety and the technologies in use will be collected and analyzed. Then, the relationship between safety levels and the use of integrated systems will be examined, followed by pilot testing of the developed system under real-world conditions. The research sequence includes a literature review, field studies, system modeling, experimental implementation, pre- and post-deployment analysis, and the development of recommendations for scaling. This approach will provide a thorough assessment of the system's effectiveness and validate the scientific soundness of the hypothesis.

The project's key experiments are designed to evaluate the effectiveness of the intelligent monitoring system under real construction site conditions. The first experiment focuses on testing facial recognition to assess the accuracy and speed of worker identification, including cases where workers are wearing helmets and safety glasses. Cameras will be installed at entry points and key zones, and recognition results will be compared with actual employee data. The second experiment targets the automatic detection of safety violations using AI algorithms trained on video footage from real construction sites and tested in scenarios involving simulated infractions. The third experiment involves deploying breathalyzers at construction sites and integrating them with access control systems to monitor workers' conditions before shifts, with the expectation of reducing the number of individuals granted access while over the legal alcohol limit. The final stage entails the pilot implementation of the complete system on a construction site, where all components will be tested together over a defined period to assess their combined effectiveness and to collect data for further optimization. The expected outcome of the pilot implementation is the confirmation of the integrated system's functionality and the collection of empirical data for its subsequent optimization. The experiments described will allow for a comprehensive validation of the project's hypotheses and provide a foundation for scaling and successful deployment of the developed technology. The proposed system is a comprehensive solution that integrates real-time video surveillance modules, intelligent data processing using AI algorithms, and a user-friendly interface for efficient safety management. The system's structure is detailed in Figure 3.

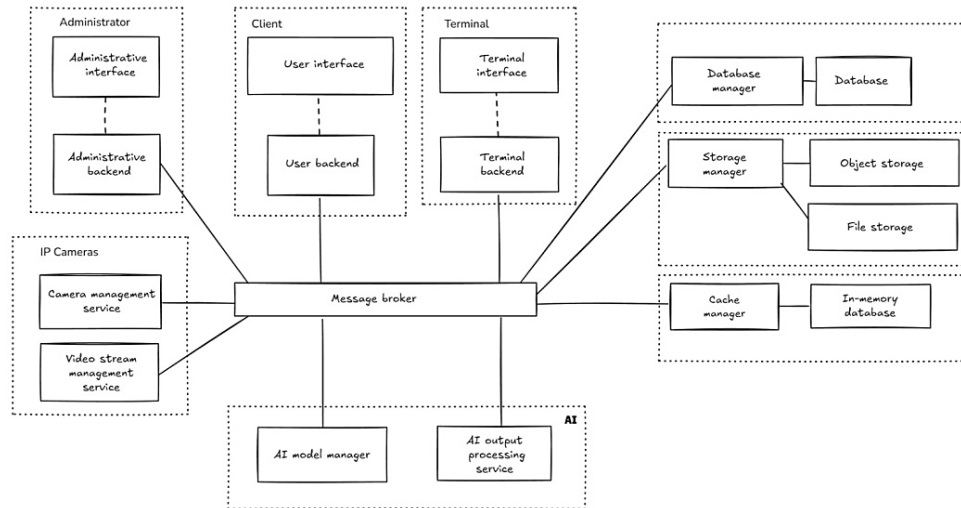


**Figure 3.** Automated Safety Violation Monitoring on Construction Sites Using AI  
*Note – compiled by the authors*

This figure illustrates the architecture and workflow of the AI-powered construction site monitoring system developed for automatic detection of safety violations. The system is equipped with multiple surveillance cameras installed across the construction site to capture real-time video streams. The cameras are positioned to cover different zones of the site and record potential safety violations. The video streams are continuously collected and transmitted to the system for processing. These streams are sent to a central AI server, where real-time analysis is performed. AI algorithms process the incoming footage to detect the following types of violations: absence of helmets and personal protective equipment (PPE), and non-compliance with regulations for working at heights. Additionally, the system includes a feature for detecting workers' blood alcohol levels. Entry terminals equipped with breathalyzers are installed at the site's access points to measure employees' alcohol levels before they begin work. If the detected level exceeds the permissible threshold, the system issues a warning and denies access to the site. The server processes the video streams using computer vision algorithms and stores both the original and processed footage for future use. Processing occurs in parallel with the live stream, allowing for immediate detection of violations. The processed data and video streams are transmitted to a cloud platform, where they are securely stored. The platform enables remote access to the data, ensuring scalability and reliable backup. The platform also synchronizes data between the system and user interfaces in real time. Through this interface, system operators can control cameras, adjust video stream settings, monitor detected violations, manage alcohol level checks, and generate reports. Camera and stream control allows users to view live video feeds, access archived footage, and configure violation alerts or inspection intervals. The interface also displays data from the alcohol detection terminals, enabling monitoring of test results and preventing access for individuals who exceed the permissible alcohol threshold. The system automatically generates snapshots of violations with detailed event information, including the time, type of violation, and the personnel involved. These reports are stored on the server for subsequent analysis and audit purposes. All system components are connected via the internet, ensuring continuous interaction between the AI server, cloud platform, and user interface. Authorized users can conduct real-time remote monitoring from any device. This system

provides a comprehensive solution for enhancing safety on construction sites. The integration of artificial intelligence and computer vision enables timely detection of safety violations, reduces human error, and improves overall construction site management. This approach increases inspection efficiency and helps prevent incidents through early identification of potential risks. The project will employ object and violation detection methods using YOLO (You Only Look Once), real-time monitoring, and model accuracy enhancement and adaptation techniques. The project will include two core components: an analysis stand and a monitoring and verification system. In the initial research phase, the architecture will be developed to ensure interaction between these systems and to optimize data storage and processing on the server. The server will manage camera video streams, process employees' biometric data, and store information on detected violations. The artificial intelligence system responsible for monitoring compliance with safety regulations will also operate on this server. The safety violation recognition system is based on a machine learning model, specifically using the Ultralytics library with the YOLO architecture. These technologies will be trained on real data collected from surveillance cameras to enable the system to automatically detect violations such as the absence of helmets, lack of personal protective equipment, or the presence of employees on site while under the influence of alcohol. The Ultralytics library is one of the most popular deep learning libraries, providing an implementation of the YOLO model for object detection tasks. YOLO (You Only Look Once) is a neural network architecture designed for fast and accurate object recognition in images. The model divides an image into a grid and, for each cell, determines whether an object is present, its boundaries, and its class. For this project, YOLO will be trained to recognize the following objects: people (construction workers), safety helmets and protective clothing (presence or absence), and potentially hazardous actions or zones (e.g., being in a danger zone without a helmet). To ensure the effective operation of the system, information will be collected from various sources, including live video streams from cameras, violation snapshots with detailed descriptions, biometric data of employees, and alcohol test results from the verification stand. The data will be systematized and prepared for further processing. To improve training quality, data augmentation is used a method in which images are altered (e.g., changes in lighting or camera angles) to increase the model's robustness under various operating conditions. The YOLO model will be trained on annotated data for object classification and localization. Each type of violation will be assigned a specific class: absence of a helmet, presence in a hazardous zone, improper wearing of protective clothing, and others. After training, the model will be integrated with the construction site's video surveillance system, where it will analyze live video streams in real time to detect safety violations. All video streams will be processed at low intervals to efficiently utilize server resources and computational accelerators, enabling timely safety compliance checks. A pre-trained artificial intelligence model will be used to detect safety violations. The model will be trained on frames collected from the construction site using the Ultralytics library and the YOLO architecture, which is designed for identifying and classifying objects in images. Training the model will allow the system to target specific objects and actions for monitoring (Figure 4).

The entire system will include a control panel with a web interface, allowing administrators to add cameras, set inspection intervals, and view the history of violations. This interface will be developed with a focus on usability and accessibility of information for users. The analysis stand will consist of a computer with a touchscreen, a camera, and a breathalyzer sensor. The stand's software will perform employee identification based on biometric data stored on the server. Once identification is successful, a step-by-step verification process will follow, using an intuitive user interface. After the system's pilot deployments at several construction sites, model retraining on new data may be conducted to improve accuracy and adapt the system to the specific characteristics of each site.



**Figure 4.** Field Data Processing System

*Note – compiled by the authors*

During system operation, ongoing analysis of false positives cases where the system erroneously detects a violation will be conducted, followed by adjustments to algorithms and model parameters to enhance recognition accuracy. At the final stage of the study, comprehensive testing of the system is planned under real construction site conditions, including assessments of violation detection accuracy, information processing speed, and the coordination of all components. The test results will be used to identify bottlenecks, eliminate deficiencies, and optimize functionality. After the system is deployed, user feedback will be collected to evaluate its effectiveness, identify strengths and weaknesses, and implement improvements based on practical experience. The use of the YOLO model and the Ultralytics library in this project ensures high performance and reliability of real-time safety monitoring, which will significantly enhance worker protection, reduce the number of incidents, and enable timely responses to potential threats.

## DISCUSSION

One of the key challenges of the project was ensuring high recognition accuracy in construction site environments, where workers' faces may be partially obscured by helmets, goggles, or other protective equipment. To address this issue, data augmentation and model retraining under specific conditions were employed. Particular attention was also given to the speed of video stream processing, as the system is required to operate in real time. It is important to note that even with high accuracy, false positives may still occur, especially in atypical situations. This necessitates continuous adaptation of the algorithms and regular updates to the training dataset. Furthermore, the project highlighted the need for flexible system configuration and effective interaction with personnel, both in terms of how alerts are perceived and in protecting personal data. Future development of the project envisions expanded functionality, including predictive analytics and integration with construction process management systems. Continued efforts are also recommended to reduce the number of false alarms and to increase model robustness under varying weather and lighting conditions typical of construction sites.

## CONCLUSION

One of the primary challenges of the project was achieving high recognition accuracy in construction site environments, where workers' faces may be partially obscured by helmets, protective goggles, or other personal protective equipment. To address this, data augmentation

and model retraining were applied using specially curated image datasets that reflect real-world operational conditions. Particular emphasis was also placed on ensuring high-speed video stream processing, as the system is required to function in real time. Despite achieving high accuracy, false positives may still occur, especially in non-standard or rapidly changing situations, necessitating regular algorithm adaptation and training data updates. Moreover, the project underscored the importance of flexible interaction between the system and personnel, both in terms of interpreting and responding promptly to alerts and in protecting employees' personal data. Future development of the project is expected to involve expanding the system's functionality, including the implementation of predictive analytics and integration with construction process management platforms. Further efforts should also focus on reducing the number of false alarms and improving the model's resilience to various weather conditions and lighting changes typical of construction sites. The expected outcome of the pilot implementation is to confirm the functionality of the integrated system in real-world conditions and to gather empirical data necessary for further optimization. The proposed experiments will enable a comprehensive validation of the project's working hypotheses and will lay the foundation for scaling and effective implementation of the developed technology. The presented system is a comprehensive solution that integrates real-time video surveillance modules, intelligent data processing based on AI algorithms, and an intuitive user interface for efficient safety management on construction sites.

**CONFLICT OF INTEREST:** The authors declare no conflict of interest.

**FUNDING:** This research was funded by the Science Committee of the Ministry of Science and Higher Education of the Republic of Kazakhstan (AP26194239 - Development of a monitoring system for construction sites using artificial intelligence for the automatic detection of safety violations).

**STATEMENT ON THE USE OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES:** In preparing this paper, author team didn't use AI.

## REFERENCES

- International Labour Organization. Webinar: Safety and Health in the Construction Sector- Overcoming the Challenges (2018). Available online: [https://www.ilo.org/empent/-Eventsandmeetings/WCMS\\_310993/lang--en/index.htm](https://www.ilo.org/empent/-Eventsandmeetings/WCMS_310993/lang--en/index.htm) (accessed on 7 August 2023).
- Jung, D., Seo Y., Shin S., Kim D. (2022). Analyzing the relationship between the critical safety management tasks and their effects for preventing construction accidents using IPA method. *Korean J. Constr. Eng. Manag.*, 177, 77–8, <https://doi.org/10.1016/j.ssci.2024.106595>.
- Hussain R., Pedro A., Zaidi S.F.A., Abbas M.S., Soltani M., Park C. (2023). Conceptual Framework for Safety Training for Migrant Construction Workers using Virtual Reality Techniques. In *Digitalization in Construction*; Routledge: London, UK, 93–103, <https://doi.org/10.1201/9781003408949-6>.
- Park C., Soltani M., Pedro A., Yang J., Lee D., Hussain R. (2023). *Transforming Construction Site Safety with iSAFE: An Automated Safety Management Platform*. Routledge: London, UK, 213–234, ISBN 9781003408949.
- Choi S.D., Guo L., Kim J., Xiong S. (2019). Comparison of fatal occupational injuries in construction industry in the United States, South Korea, and China. *Int. J. Ind. Ergon.*, 71, 64–74, <https://doi.org/10.1016/j.ergon.2019.02.011>.
- Xiao B., Kang S.C. (2021). Development of an Image Data Set of Construction Machines for Deep Learning Object Detection. *J. Comput. Civ. Eng.*, 35(2), 05020005, [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000945](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000945).

- Chen, C., Gu H., Lian S., Zhao Y., Xiao B. (2022). Investigation of Edge Computing in Computer Vision-Based Construction Resource Detection. *Buildings*, 12(12), 2167, <https://doi.org/10.3390/buildings12122167>.
- Suh S. (2023). A Qualitative Study Understanding Unsafe Behaviors of Workers in Construction Sites. *Korean J. Constr. Eng. Manag.*, 24(6), 91–98, <https://doi.org/10.6106/KJCEM.2023.24.6.091>.
- Hussain R., Zaidi S.F.A., Pedro A., Lee H., Park C. (2024). Exploring construction workers' attention and awareness in diverse virtual hazard scenarios to prevent struck-by accidents. *Saf. Sci.*, 175, 106526, <https://doi.org/10.1016/j.ssci.2024.106526>.
- Soltani M., Pedro A., Yang J., Zaidi S.F.A., Lee D., Park C. (2024). Isafeguard: A Proactive Solution for Construction Job Site Safety Monitoring. In *Smart & Sustainable Infrastructure: Building a Greener Tomorrow*; Banthia, N., Soleimani-Dashtaki, S., Mindess, S., Eds.; Springer: Cham, Switzerland, 48, 1151-1165, [https://doi.org/10.1007/978-3-031-53389-1\\_101](https://doi.org/10.1007/978-3-031-53389-1_101).
- Zeng L., Li R.Y.M. (2022). Construction safety and health hazard awareness in Web of Science and Weibo between 1991 and 2021. *Saf. Sci.*, 152, 105790, <https://doi.org/10.1016/j.ssci.2022.105790>.
- Wang J., Jiang L., Yu H., Feng Z., Castaño-Rosa R., Cao S. (2024). Computer vision to advance the sensing and control of built environment towards occupant-centric sustainable development: A critical review. *Renew. Sustain. Energy Rev.*, 192, 114165, <https://doi.org/10.1016/j.rser.2023.114165>.
- Fang Q., Li H., Luo X., Ding L., Luo H., Rose T.M., An W. (2018). Detecting non-hardhat-use by a deep learning method from far-field surveillance videos. *Autom. Constr.*, 85, 1–9, <https://doi.org/10.1016/j.autcon.2017.09.018>.
- Fang Q., Li H., Luo X., Ding L., Luo H., Li C. (2018). Computer vision aided inspection on falling prevention measures for steeplejacks in an aerial environment. *Autom. Constr.*, 93, 148–164, <https://doi.org/10.1016/j.autcon.2018.05.022>.
- Huang L., Fu Q., He M., Jiang D., Hao Z. (2021). Detection algorithm of safety helmet wearing based on deep learning. *Concurr. Comput. Pract. Exp.*, 33(13), e6234, <https://doi.org/10.1002/cpe.6234>.
- Han K., Zeng X. (2022). Deep Learning-Based Workers Safety Helmet Wearing Detection on Construction Sites Using Multi-Scale Features. *IEEE Access*, 10, 718–729, <https://doi.org/10.1109/ACCESS.2021.3138407>.
- Hung H., Lan L., Hong H. (2019). A Deep Learning-Based Method for Real-Time Personal Protective Equipment Detection. *Le Quy Don Tech. Univ.-Sect. Inf. Commun. Technol. LQDTU-JICT*, 199, 23-34, <https://doi.org/10.1016/J.AUTCON.2020.103085>.
- Wu J., Cai N., Chen W., Wang H., Wang G. (2019). Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset. *Autom. Constr.*, 106, 102894, <https://doi.org/10.1016/j.autcon.2019.102894>.
- Bo Y., Huan Q., Huan X., Rong Z., Hongbin L., Kebin M., Weizhong Z., Lei Z. (2019). Helmet detection under the power construction scene based on image analysis. In: 2019 IEEE 7th international conference on computer science and network technology (ICCSNT), IEEE, New Jersey, 67–71, <https://doi.org/10.1109/ICCSNT47585.2019.8962495>.
- Gu Y., Wang Y., Shi L., Li N., Zhuang L., Xu S. (2021). Automatic detection of safety helmet wearing based on head region location. *IET Image Proc.*, 15(11), 2441–2453, <https://doi.org/10.1049/ipr2.12231>.
- Zhou F., Zhao H. & Nie Z. (2021). Safety helmet detection based on YOLOV5. In: 2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA), IEEE, New Jersey, 566556-11, <https://doi.org/10.1109/ICPECA51329.2021.9362711>.

- Long X., Cui W. & Zheng Z. (2019). Safety helmet wearing detection based on deep learning. In: 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), IEEE, New Jersey, 2495–2499, <http://dx.doi.org/10.1109/ITNEC.2019.8729039>.
- Wu J., Cai N., Chen W., Wang H., Wang G. (2019). Automatic detection of hardhats worn by construction personnel: a deep learning approach and benchmark dataset. *Autom. Constr.*, 106, 102894, <https://doi.org/10.1016/j.autcon.2019.102894>.
- Li Y., Wei H., Han Z., Huang J., Wang W. (2020). Deep learning-based safety helmet detection in engineering management based on convolutional neural networks. *Adv. Civ. Eng.*, 6, 9703560, <http://dx.doi.org/10.1155/2020/9703560>.
- Hung H.M. & Hong H.S. et al. (2019). A deep learning-based method for realtime personal protective detection. *Le Quy Don Technical University Section on Information and Communication Technology (LQDTU-JICT)*, 13, 23–34, <https://doi.org/10.1371/journal.pone.0322115>.
- Jeon S.Y., Park J.H., Youn S.B., Kim Y.S., Lee Y.S., Jeon J.H. (2020). Real-time worker safety management system using deep learning-based video analysis algorithm. *Smart Media J.*, 9(3), 25–30, <https://doi.org/10.30693/SMJ.2020.9.3.25>.
- Ali Z., Park U. (2021). Real-time safety monitoring vision system for linemen in buckets using spatio-temporal inference. *Int. J. Control Autom. Syst.*, 19(1), 505–520, <https://doi.org/10.1007/s12555-019-0546-y>.
- Khan M., Nnaji C., Khan M.S., Ibrahim A., Lee D., Park C. (2023). Risk factors and emerging technologies for preventing falls from heights at construction sites. *Autom. Constr.*, 153, 104955, <https://doi.org/10.1016/j.autcon.2023.104955>.
- Li T., Xu H., Han Y., Zhao Y., Yan H. (2023). L-Yolov5: A multi-scale channel attention-based method for real-time safety helmet detection of electrical construction workers. In *Proceedings of the 2023 International Joint Conference on Neural Networks (IJCNN)*, Gold Coast, Australia, 23(4), 1-8, <https://doi.org/10.3390/s23041822>.
- Luo F., Li R.Y.M., Crabbe M.J.C., Pu R. (2022). Economic development and construction safety research: A bibliometrics approach. *Saf. Sci.*, 145, 105519, <https://doi.org/10.1016/j.ssci.2021.105519>.
- Сухачев, А.А. (2025). Охрана труда в строительстве. Московский промышленный колледж, 310 с. ISBN 978-5-406-13578-5. // Sukhachev, A.A. (2025). Okhrana truda v stroitel'stve [Occupational safety in construction]. Moskovskii promyshlenniy kolledzh, 310 p. ISBN 978-5-406-13578-5. (In Russ.)

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Ахажанов Сунгат Беркинович** – PhD, қауымдастырылған профессор, Академик Е.А. Бөкетов атындағы Қарағанды университеті, Қарағанды қ., Қазақстан,

**Ахажанов Сунгат Беркинович** – PhD, ассоциированный профессор, Карагандинский университет имени академика Е.А. Букетова, г. Караганда, Казахстан,

**Akhazhanov Sungat Berkinovich** – PhD, Associate professor, Karaganda Buketov University, Karaganda, Kazakhstan,

e-mail: stjg@mail.ru,

ORCID: <https://orcid.org/0000-0002-0903-3517>



**Бибалаев Олжас Досанұлы** – техника ғылымдарының магистрі, инженер-программист, Е.А. Бөкетов атындағы Қарағанды университеті, Қарағанды қ., Қазақстан,

**Бибалаев Олжас Досанұлы** – магистр технических наук, инженер-программист, Карагандинский университет имени академика Е.А. Букетова, г. Караганда, Казахстан,

**Bibalayev Olzhas Dosanuly** – Master of technical sciences, software engineer, Karaganda Buketov University, Karaganda, Kazakhstan, e-mail: oljaktl@gmail.com

ORCID: <https://orcid.org/0000-0002-6821-4932>



**Муратхан Райхан** – PhD, қауымдастырылған профессор, Академик Е.А. Бөкетов атындағы Қарағанды университеті, Қарағанды қ., Қазақстан,

**Муратхан Райхан** – PhD, ассоциированный профессор, Карагандинский университет имени академика Е.А. Букетова, г. Караганда, Казахстан,

**Muratkhon Raikhan** – PhD, Associate professor, Karaganda Buketov University, Karaganda, Kazakhstan, e-mail: rai-81@mail.ru,

ORCID: <https://orcid.org/0000-0002-2030-8948>



**Михайлов Даниел Михайлович** – техника ғылымдарының магистрі, докторант, Қорқыт Ата атындағы Қызылорда университеті, Қызылорда, Қазақстан,

**Михайлов Даниел Михайлович** – магистр технических наук, докторант, Кызылординский университет имени Коркыт Ата, Кызылорда, Казахстан,

**Mikhailov Daniel Mikhailovich** – Master of technical sciences, PhD Student, Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan, e-mail: daniel\_mihailov@mail.ru

ORCID: <https://orcid.org/0009-0007-9052-8552>



**Монтаева Айнур Сарсенбековна** – PhD, ғылыми зерттеулерді үйлестіру бөлімінің басшысы, Қорқыт Ата атындағы Қызылорда университеті, Қызылорда қ., Қазақстан,

**Монтаева Айнур Сарсенбековна** – PhD, начальник отдела координации научных исследований, Кызылординский университет имени Коркыт Ата, г. Кызылорда, Казахстан,

**Montayeva Ainur Sarsenbekovna** – PhD, Head of the Department of Scientific Research Coordination, Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan,

e-mail: montayeva\_ainur@mail.ru,

ORCID: <https://orcid.org/0000-0001-9536-3442>

[https://doi.org/10.51885/3134-8025\\_IICS\\_2026\\_1\\_3](https://doi.org/10.51885/3134-8025_IICS_2026_1_3)

МРНТИ 28.23.15

## СТРАТЕГИЧЕСКИЕ НАПРАВЛЕНИЯ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В МИКРОБИОЛОГИЧЕСКОМ МОНИТОРИНГЕ ВОДНЫХ ОБЪЕКТОВ: ОБЪЯСНИМЫЕ МОДЕЛИ И МУЛЬТИОМНАЯ ИНТЕГРАЦИЯ

## СУ ОБЪЕКТІЛЕРІНІҢ МИКРОБИОЛОГИЯЛЫҚ МОНИТОРИНГІНДЕ ЖАСАНДЫ ИНТЕЛЛЕКТТІ ҚОЛДАНУДЫҢ СТРАТЕГИЯЛЫҚ БАҒЫТТАРЫ: ТҮСІНДІРІЛЕТІН МОДЕЛЬДЕР ЖӘНЕ МУЛЬТИОМДЫҚ ИНТЕГРАЦИЯ

## STRATEGIC DIRECTIONS FOR THE APPLICATION OF ARTIFICIAL INTELLIGENCE IN MICROBIOLOGICAL MONITORING OF WATER BODIES: EXPLANABLE MODELS AND MULTI-MODE INTEGRATION

Д.А. Берилло <sup>1</sup>, К.Е. Икласова <sup>1\*</sup>, В.В. Семенюк <sup>1</sup>, Р.М. Ташибаев <sup>1</sup>

<sup>1</sup>Северо-Казахстанский университет имени М. Козыбаева, г. Петропавловск, Казахстан

\*Автор-корреспондент: Икласова Кайнижамал Есимсеитовна, e-mail: keiklasova@ku.edu.kz

### Ключевые слова:

машинное обучение,  
идентификация  
бактерий, мониторинг  
водных объектов,  
мультиомные данные,  
объяснимый ИИ,  
сверточные нейронные  
сети.

### АННОТАЦИЯ

В статье проведён критический анализ современных подходов к применению искусственного интеллекта в микробиологическом мониторинге водных объектов. Показано, что высокая точность моделей глубокого обучения, обученных на общепринятых наборах данных (например, DIBaS), часто является следствием методологически некорректного разделения данных и приводит к переоценке реальных возможностей моделей. При использовании более строгих стратегий валидации, имитирующих реальные условия работы (strain-wise splitting), точность классификации значительно снижается, что свидетельствует о наличии кризиса обобщения. Обоснована необходимость перехода от традиционных сверточных нейронных сетей к объяснимым архитектурам и мультимодальным моделям, интегрирующим изображения с геномными данными (k-меры). Такой подход позволяет повысить интерпретируемость, устранить фенотипическую неоднозначность и улучшить способность моделей корректно классифицировать новые бактериальные штаммы. Предложены два стратегических направления: внедрение самообъяснимого ИИ для верификации морфологических признаков и разработка мультимодальных систем для прогнозирования функциональных характеристик микроорганизмов. Полученные результаты формируют основу для создания надёжных инструментов экомониторинга нового поколения.



© 2026 Д.А. Берилло, К.Е. Икласова, В.В. Семенюк, Р.М. Ташибаев

Данная работа распространяется на условиях лицензии

Creative Commons «С указанием авторства» 4.0 Международная (CC BY 4.0).

<https://creativecommons.org/licenses/by/4.0/>

---

#### **Түйінді сөздер:**

машиналық оқыту,  
бактерияларды анықтау,  
су объектілерін бақылау,  
мультиомдық  
мәліметтер, түсіндірілетін  
ЖИ, конволюциялық  
нейрондық желілер.

---

#### **ТҮЙІНДЕМЕ**

Мақалада су объектілерінің микробиологиялық мониторингінде жасанды интеллектіні қолданудың заманауи тәсілдеріне сыни талдау жасалды. Кеңінен қолданылатын деректер жиынтықтарында (мысалы, DIBaS) жоғары дәлдік көрсеткіштерінің алынуы көбінесе деректерді бөлудің әдістемелік тұрғыдан дұрыс өткізілмеуімен байланысты екені көрсетілді. Шынайы жағдайларды модельдейтін қатаң валидация стратегияларын (strain-wise splitting) қолданғанда классификация дәлдігінің айтарлықтай төмендеуі модельдердің жалпылау қабілетінің шектеулі екенін көрсетеді. Жұмыста түсіндірілетін ИИ архитектураларын және микроскопиялық кескіндерді геномдық деректермен (k-мелер) біріктіретін мультимодальды модельдерді қолданудың өзектілігі негізделген. Мұндай тәсіл фенотиптік екіұштылықты жоюға, модель шешімдерінің түсініктілігін арттыруға және жаңа штаммдарды дәл анықтауға мүмкіндік береді. Авторлар диагностикалық белгілерді тексеруге арналған өзін-өзі түсіндіретін ИИ енгізуді және микроорганизмдердің функционалдық сипаттамаларын болжауға бағытталған мультимодальды жүйелерді әзірлеуді стратегиялық бағыттар ретінде ұсынады. Зерттеу нәтижелері жаңа буындағы сенімді экологиялық мониторинг құралдарын әзірлеуге негіз бола алады.

---

#### **Keywords:**

machine learning, bacteria  
identification, water body  
monitoring, multi-omic  
data, explainable AI,  
convolutional neural  
networks.

---

#### **ABSTRACT**

This article provides a critical analysis of current artificial intelligence approaches used in the microbiological monitoring of water bodies. It demonstrates that the high accuracy reported in many deep learning studies – particularly those based on datasets such as DIBaS—is frequently the result of methodologically improper data splitting, which leads to overestimating model performance. When more rigorous validation strategies that simulate real-world conditions (e.g., strain-wise splitting) are applied, accuracy drops significantly, revealing a generalization crisis. The study substantiates the need to transition from traditional convolutional neural networks toward explainable and multimodal AI architectures that integrate microscopic images with genomic data (k-mers). This integration improves interpretability, resolves phenotypic ambiguity, and enhances the ability of models to classify previously unseen bacterial strains. Two strategic directions are proposed: the development of Self-Explainable AI for verifying diagnostic features and the creation of multimodal systems capable of predicting functional microbial characteristics. These findings lay the groundwork for next-generation ecological monitoring tools.

---

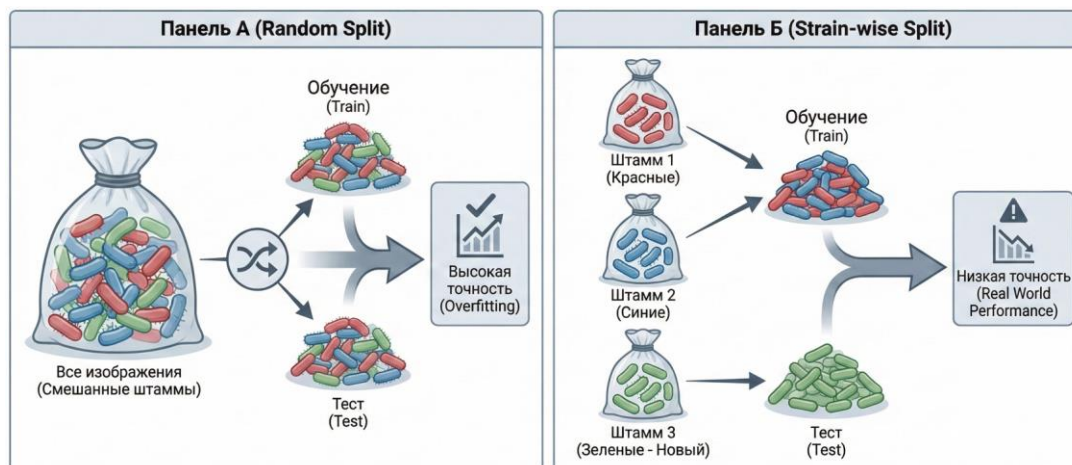
#### **ВВЕДЕНИЕ**

Область применения ИИ в экологической микробиологии в значительной степени опирается на использование сверточных нейронных сетей (CNN) для решения задач, связанных с анализом изображений. Сравнительный анализ, проведенный в одном из исследований, оценил различные архитектуры, включая AlexNet, VGGNet (Visual Geometry Group Net), Inception (GoogLeNet), ResNet (Residual Network) и DenseNet (Densely Connected Convolutional Network), на наборе данных DIBaS (Digital Image of Bacterial Species), и установил, что DenseNet-121 достигает наивысшей точности — 99,08 % (Wu, et al, 2023). Это демонстрирует огромный потенциал глубокого обучения для автоматического извлечения признаков из изображений микроорганизмов.

Применение CNN выходит за рамки простой классификации. Эти сети используются для автоматической интерпретации микроскопических препаратов из водных проб, анализа роста колоний на агаровых пластинах (Smith, et al, 2020), а также для классификации видов бактерий по микроскопическим изображениям их колоний (Wu, et al, 2023). Такая широкая применимость CNN обусловлена их врождённой способностью изучать иерархические пространственные признаки непосредственно из пиксельных данных, что идеально подходит для идентификации тонких морфологических различий между видами и колониями бактерий. Эта возможность позволяет автоматизировать задачи, которые традиционно требуют участия высококвалифицированных гидробиологов и микробиологов (Smith, et al, 2020).

Анализ литературы выявляет существенное противоречие в публикуемых показателях производительности моделей. В то время как одно исследование сообщает о точности более 99 % на наборе данных DIBaS с использованием предварительно обученной модели DenseNet-121 (Wu, et al, 2023), другое исследование (Yachnaya, et al, 2024) убедительно доказывает, что такие высокие показатели (более 90%) являются артефактом случайного разделения набора данных.

Когда применяется более релевантная для практического применения методология разделения по штаммам (strain-wise splitting), при которой все изображения одного и того же штамма бактерий попадают либо в обучающую, либо в тестовую выборку, но не в обе сразу, точность специально разработанной модели ResNet-MH резко падает до 41.6% на уровне видов (Yachnaya, et al, 2024). Это расхождение объясняется высокой визуальной вариабельностью между различными штаммами одного и того же вида. Модель, обученная на штамме E. coli вида A, может не распознать штамм E. coli Б того же вида, если он выглядит иначе. Случайное разделение приводит к «утечке данных», позволяя модели видеть изображения одних и тех же штаммов как в обучающей, так и в тестовой выборках, что ведёт к запоминанию, а не к истинному обобщению (Yachnaya, et al, 2024), как наглядно показано на рисунке 1.



**Рисунок 1.** Влияние стратегии разделения данных на оценку точности моделей.

Панель А: случайное разделение (Random Split).

Панель Б: разделение по штаммам (Strain-wise Split)

Это наблюдение позволяет сделать вывод о том, что в данной области, возможно, назревает «кризис воспроизводимости и обобщения», при котором сообщаемые передовые результаты искусственно завышены и не отражают реальной производительности в полевых условиях. Высокие показатели точности, полученные в исследованиях, подобных

(Wu, et al, 2023), которые используют наборы данных, такие как DIBaS, не имеющие аннотаций на уровне штаммов (Wu, et al, 2023), скорее всего, вводят в заблуждение.

В области наблюдается значительная технологическая эволюция - переход от дискриминативных моделей (классифицирующих, что изображено) к генеративным моделям (создающим новое изображение). Ярким примером является использование условной генеративно-сопоставительной сети (cGAN) для выполнения «виртуального окрашивания по Граму» (Işıl, et al, 2025).

Эта модель принимает на вход Z-стек безметочных темнопольных микроскопических изображений и генерирует синтетическое светлопольное изображение, которое было вычислительно «окрашено по Граму». В основе этого подхода лежит обучение модели на тысячах парных изображений: неокрашенных (темнопольных) и химически окрашенных (светлопольных), благодаря чему сеть учится сопоставлять морфологические признаки клетки с её будущим цветом после окрашивания. Результат демонстрирует высокую степень соответствия с химически окрашенными образцами, достигая пикового отношения сигнал/шум (PSNR) 38.35 дБ и индекса структурного сходства (SSIM) 0.9685 (Işıl, et al, 2025). Такой подход позволяет обойти весь ручной, трудоемкий и подверженный ошибкам процесс химического окрашивания. Это представляет собой сдвиг парадигмы в сторону автоматизации целых лабораторных процессов, а не только отдельных аналитических шагов. Использование темнопольной микроскопии также является ключевым нововведением, поскольку оно позволяет избежать фотообесцвечивания и предоставляет богатую информацию о трёхмерном рассеянии света, которую модель использует для дифференциации (Işıl, et al, 2025).

Целью данного исследования являются критический анализ текущего состояния применения ИИ в микробиологическом мониторинге и разработка стратегических предложений по преодолению выявленных ограничений. Научная новизна работы заключается в обосновании смены парадигмы от погони за метриками точности на нерепрезентативных данных к созданию мультимодальных диагностических систем. Практическая значимость состоит в формулировании требований к новому поколению инструментов экомониторинга, способных прогнозировать функциональную роль микроорганизмов, а не только их таксономию.

## МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Для написания данной статьи был применён протокол систематического обзора (Systematic Literature Review). Поиск литературы осуществлялся по ключевым словам в базах данных Scopus, Web of Science и Google Scholar. На первом этапе была сформирована широкая выборка из 203 публикаций. На втором этапе проводилась фильтрация по заголовкам и аннотациям. На третьем этапе — полнотекстовый анализ на соответствие критериям включения. В итоговый синтез вошли 16 работ, полностью удовлетворяющих критерии качества и релевантности, представленные в таблице 1.

**Таблица 1.** Критерии отбора актуальной научной литературы

Параметр протокола	Критерии отбора статей
Источники данных	Поиск осуществлялся в реферативных базах данных Scopus, Web of Science Core Collection и Google Scholar.
Временной охват	Период с 2018 по 2025 год, что обусловлено высокой скоростью устаревания алгоритмов глубокого обучения (SOTA).
Поисковый запрос	Использовались комбинации ключевых слов: ("deep learning" OR "CNN" OR "machine learning") AND ("bacteria identification" OR "microbial monitoring") AND ("water quality" OR "aquatic ecosystem").

Окончание таблицы 1

Критерии включения	1. Оригинальные исследовательские статьи (Research Articles). 2. Наличие количественных метрик оценки (Accuracy, F1-score). 3. Использование наборов данных микроскопических изображений.
Критерии исключения	1. Обзорные статьи без собственного мета-анализа. 2. Работы, использующие классическое машинное обучение без нейросетей. 3. Статьи на языках, отличных от английского и русского.
Примечание – составлено автором	

На основе этого анализа был проведен синтез существующих знаний, что позволило выявить ключевые проблемы в области, такие как кризис обобщения моделей и недостаток их интерпретируемости. Далее, с использованием методов научного прогнозирования и проектирования, были сформулированы два стратегических исследовательских направления, включая разработку детальных исследовательских предложений и технических требований к данным.

### РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Для систематизации и наглядного представления ключевых аспектов проанализированных работ ниже приведена сравнительная таблица 2.

Таблица 2. Анализ ключевых аспектов применения ИИ

Параметр	[Smith, et al, 2020]	[Yachnaya, et al, 2024]	[Wu, et al, 2023]	[Işıl, et al, 2025]
Основная цель	Обзор применения ИИ для анализа изображений в экологической микробиологии.	Разработка классификатора бактерий, способного обобщаться на новые штаммы.	Сравнительный анализ предобученных CNN для классификации бактерий.	Разработка метода виртуального окрашивания по Граму без использования химических реагентов.
Метод/ Архитектура МО	CNN (в частности, Inception v3 с transfer learning).	Модифицированный ResNet-18 с несколькими "головами" (ResNet-MH).	Сравнение CNN: AlexNet, VGGNet, Inception, ResNet, DenseNet.	Условная генеративно-состязательная сеть (сGAN) на основе U-Net.
Тип входных данных	Изображения мазков, окрашенных по Граму; изображения роста колоний на агаре.	Микроскопические изображения колоний живых бактерий (без окрашивания).	Микроскопические изображения бактерий, окрашенных по Граму.	Z-стек темнопольных микроскопических изображений безметочных бактерий.
Набор(ы) данных	Собственные данные (пробы из водных объектов).	Собственный набор данных (4618 изображений, 23 вида, 11 родов).	DIBaS (около 660 изображений, 33 вида).	Собственный набор данных ( <i>E. coli</i> и <i>L. innocua</i> ).
Ключевой показатель производительности	Точность классификации ~95% для отдельных фрагментов, 92.5% для целого мазка.	Точность 41.6% (по видам) при разделении по штаммам; >90% при случайном разделении.	Точность 99.08% (DenseNet-121).	PSNR 38.35 дБ, SSIM 0.9685, F1-score 96%.

Окончание таблицы 2

Параметр	[Smith, et al, 2020]	[Yachnaya, et al, 2024]	[Wu, et al, 2023]	[Işıl, et al, 2025]
Основной вклад/вывод	ИИ может автоматизировать интерпретацию микробиологических изображений, повышая производительность.	Разделение данных по штаммам является критически важным для реалистичной оценки обобщающей способности.	Transfer learning с использованием DenseNet-121 очень эффективен для классификации бактерий на датасете DIBaS.	Глубокое обучение позволяет создавать виртуальные окрашенные препараты, обходя химический процесс.
Выявленное ограничение/проблема	Необходимость в больших наборах данных для обучения; производительность зависит от качества исходных изображений.	Высокая внутривидовая визуальная вариабельность штаммов является основной проблемой для обобщения.	Результаты могут быть нерепрезентативны для новых штаммов из-за отсутствия их разметки в DIBaS.	Качество виртуального окрашивания зависит от качества и точности регистрации обучающих пар изображений.
<i>Примечание – составлено автором</i>				

Генеративные модели для виртуального окрашивания обладают встроенной степенью интерпретируемости, которой не хватает классификационным моделям, что делает их более жизнеспособными для практического внедрения. Классификационная модель выдаёт метку, например, «E. coli (вероятность 98%)» [Wu, et al, 2023]. Это абстрактное заключение, которое специалист-эколог должен либо принять, либо отвергнуть, основываясь на доверии к «чёрному ящику». В то же время модель виртуального окрашивания выдаёт изображение, визуально напоминающее стандартный препарат, окрашенный по Граму (Işıl, et al, 2025). Микробиолог может использовать свой собственный опыт для интерпретации этого сгенерированного ИИ изображения, так же, как и реального. Он может видеть морфологию (кокки, палочки), расположение (гроздь, цепочки) и реакцию на окраску (фиолетовый, розовый). Таким образом, генеративный подход изменяет взаимодействие человека и ИИ с делегирования («ИИ, скажи мне ответ») на сотрудничество («ИИ, подготовь мне образец для анализа»). Это снижает барьер для доверия и более органично интегрируется в устоявшиеся лабораторные рабочие процессы в сфере экологии, потенциально ускоряя внедрение быстрее, чем чисто классификационная система.

Однако даже генеративные подходы не решают фундаментальную проблему доверия к классификаторам. Проблема «чёрного ящика» (Black Box) остаётся критическим барьером: эколог не может полагаться на метку класса без понимания причин решения (Sartori, et al, 2025). В связи с этим первым стратегическим направлением предлагается внедрение методов объяснимого ИИ (XAI).

Первым вариантом решения предлагается использование пост-хок объяснимости. Методы XAI, применяемые постфактум (post-hoc), могут быть использованы для генерации объяснений для уже обученных моделей [Sartori, et al, 2025]. Техники, такие как Gradient-weighted Class Activation Mapping (Grad-CAM), создают тепловые карты, которые подсвечивают области изображения, наиболее повлиявшие на решение CNN. Другие методы, такие как LIME и SHAP, предоставляют оценки важности признаков. Применение Grad-CAM к модели ResNet-MH из (Yachnaya, et al, 2024) позволило бы визуализировать,

действительно ли «головы» для микро- и макроструктур фокусируются на разных признаках (отдельные клетки против колоний), тем самым проверяя архитектурную гипотезу статьи.

Вторым предлагаемым направлением исследования может быть использование изначально интерпретируемых моделей. Более продвинутый подход заключается в разработке моделей, которые интерпретируемы по своей природе (Self-explainable AI, S-XAI) (Di Vincenzo). Это включает в себя встраивание таких механизмов, как внимание, обучение на основе концепций или прототипов, непосредственно в архитектуру модели (Sartori, et al, 2025). Модель на основе механизма внимания могла бы не только классифицировать бактерию, но и выводить карты внимания, которые явно выделяют ключевые морфологические признаки (например, клеточная стенка, гроздь, цепочки), обеспечивая встроенное визуальное объяснение. Это переход от пост-хок рационализации к модели, которая «показывает свою работу».

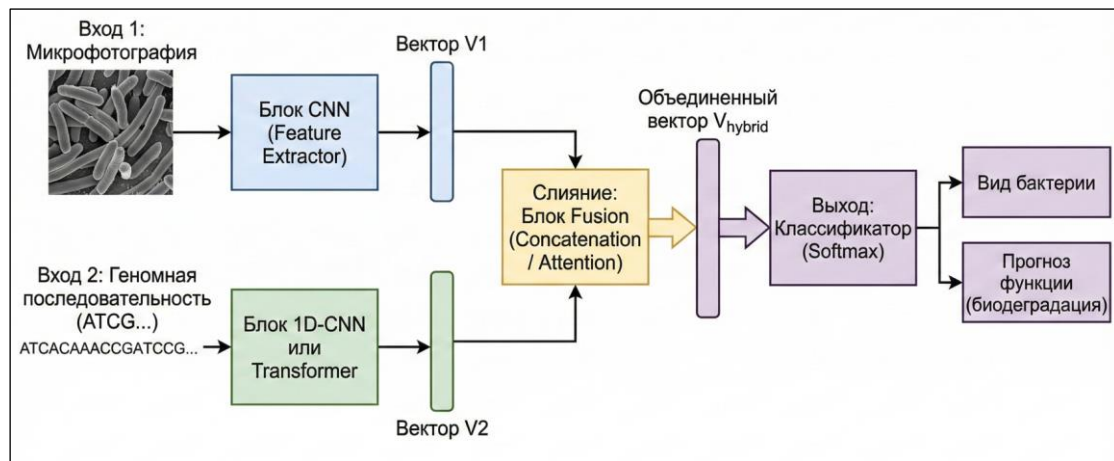
XAI<sup>®</sup> - это не просто инструмент для построения доверия; это важный научный инструмент для отладки моделей, проверки гипотез и открытия новых биомаркеров. Авторы (Yachnaya, et al, 2024) предполагают, что их модель ResNet-MH изучает как микро-, так и макропризнаки. Это научное утверждение о внутреннем механизме модели. Применение Grad-CAM (инструмента XAI) позволяет проверить эту гипотезу. Если тепловые карты подтвердят их утверждение, это подтвердит их дизайн. Если же карты покажут, что обе «головы» фокусируются на одних и тех же признаках, это опровергнет их утверждение и покажет, что улучшение производительности может быть связано с другими факторами (например, простым ансамблированием). Более того, если метод XAI последовательно выделяет ранее недооценённый морфологический признак у определённого вида бактерий как высокопредиктивный, это может направить биологов к новому, визуально идентифицируемому биомаркеру. Таким образом, XAI превращает процесс разработки моделей из чистой инженерии (оптимизация метрики точности) в научное исследование (понимание и проверка процесса рассуждений модели). Это углубляет понимание как модели, так и лежащей в её основе биологии, что является гораздо более мощным результатом, чем просто достижение высокого балла. Морфология бактерий в процессе роста практически не меняется на клеточном уровне, поскольку они размножаются путём бинарного деления, образуя генетически идентичные дочерние клетки. Однако под воздействием стрессовых условий окружающей среды (например, изменение температуры, pH или наличие токсичных веществ) могут наблюдаться морфологические изменения, такие как изменение формы или образование нетипичных форм, что является механизмом адаптации, что может происходить с малой долей вероятности при посеве анализируемых культур на общие питательные среды для получения более полной картины по штаммам бактерий в образце воды. Такого ограничения не будет в случае использования специальных дифференцированных питательных сред.

Методы, описанные в (Smith, et al, 2020; Yachnaya, et al, 2024; Wu, et al, 2023; Işıl, et al, 2025), фундаментально ограничены тем, что можно увидеть под микроскопом. Они фиксируют морфологию (фенотип), но остаются слепы к лежащим в основе геномике, транскриптомике и протеомике (генотип и функция), которые определяют экологически значимые характеристики, такие как способность к биоремедиации или патогенность для гидробионтов.

Предлагаемым решением является мультимодальные архитектуры слияния данных. Машинное обучение все чаще используется для интеграции гетерогенных мультимодальных наборов данных (геномика, протеомика и т.д.) для получения системного понимания экосистем (Purwono, et al, 2023; Hou, et al, 2024; Zhang, et al, 2024; Selvaraju, et al, 2017). Разрабатываются методологии для слияния различных типов данных, таких как

изображения и геномика, для таких приложений, как прогнозирование экологических рисков (Selvaraju, et al, 2017; Sakagianni, et al, 2023; Muller, et al, 2024; Raghuvanshi, et al, 2025; Huang, et al, 2024). Существуют три основные стратегии интеграции данных: ранняя, средняя и поздняя (Altaf, et al, 2025). Средняя интеграция, которая объединяет признаки в общем латентном пространстве, часто предпочтительнее для обработки сложных, высокоразмерных данных.

Предлагается разработка моделей, которые объединяют данные микроскопии с геномными данными для идентификации бактерий. Например, можно использовать архитектуру с двумя кодировщиками: CNN (например, DenseNet из (Wu, et al, 2023) обрабатывает изображение, в то время как 1D-CNN или Transformer обрабатывает геномные данные (например, векторы частот k-меров, полученные из полногеномных последовательностей). Векторы признаков из обоих кодировщиков затем конкатенируются или объединяются с помощью механизма внимания (средняя интеграция), после чего подаются на вход конечному классификатору, как показано на рисунке 2.



**Рисунок 2.** Концептуальная схема предлагаемой мультимодальной нейронной сети

Предлагаемые архитектуры для интерпретируемой и мультимодальной идентификации бактерий представлены в таблице 3.

**Таблица 3.** Предлагаемые архитектуры для интерпретируемой и мультимодальной идентификации бактерий

Название предложения	Основная цель	Входные модальности данных	Предлагаемая архитектура	Метод интерпретируемости	Целевое применение в экомониторинге
Предложение I: Самообъяснимый Vision Transformer	Достижение точной, с учётом штаммов, идентификации и с внутренне присущими объяснениями	Микроскопические изображения	Vision Transformer (ViT) с модулем обучения на основе концепций.	Встроенный (механизм внимания, вывод на основе концепций).	Быстрая и надёжная идентификация микроорганизмов-биоиндикаторов с аудируемым обоснованием

Окончание таблицы 3

Название предложения	Основная цель	Входные модальности данных	Предлагаемая архитектура	Метод интерпретируемости	Целевое применение в экомониторинге
Предложение II: Мультимодальная сеть для прогнозирования функциональной активности	Прогнозирование способности к биodeградации и путём интеграции морфологии и геномики.	Микроскопические изображения, полногеномные последовательности.	Двухкодированная сеть (CNN + 1D-CNN/Transformer) с механизмом перекрёстного внимания.	Пост-хок (SHAP для оценки вклада признаков).	Ускоренная оценка потенциала самоочищения водных объектов, мониторинг опасных цветений.
<i>Примечание – составлено автором</i>					

Мультимодальное слияние данных напрямую решает «кризис обобщения», выявленный ранее, предоставляя надёжный якорь для разрешения фенотипической неоднозначности. Основная проблема, выявленная в (Yachnaya, et al, 2024), заключается в том, что разные штаммы одного и того же вида могут быть визуально неотличимы от штаммов других видов (высокая внутривидовая и низкая межвидовая визуальная дисперсия). Это делает классификацию, основанную только на морфологии, принципиально ненадёжной. Однако геномные данные предоставляют однозначную истину для идентификации видов. Хотя два штамма *E. coli* могут выглядеть по-разному, их геномы будут очень похожи и чётко отличаться от, скажем, *L. innocua*. Обучая мультимодальную модель, поток геномных данных обеспечивает сильный, стабильный сигнал для правильной метки вида. Модель затем может научиться коррелировать переменные визуальные признаки (из потока изображений) с этим стабильным геномным якорем. В результате модель больше не вынуждена полагаться исключительно на неоднозначные визуальные подсказки. Она может научиться, что «эта специфическая визуальная морфология в сочетании с этой геномной сигнатурой соответствует *E. coli* штамма Б». Это значительно улучшило бы точность классификации при сложном разделении по штаммам, эффективно решая проблему обобщения, предоставляя модели необходимый контекст, которого не хватает одним лишь изображениям.

## ЗАКЛЮЧЕНИЕ

В ходе данного исследования были успешно решены поставленные во введении задачи по анализу текущего состояния и определению перспектив применения ИИ в микробиологическом мониторинге водных объектов. Основные результаты обобщаются в выявлении двух ключевых проблем, сдерживающих развитие области: «кризиса обобщения» моделей из-за внутривидовой вариативности штаммов и недостаточной методологической строгости при оценке, а также проблем «чёрного ящика», снижающих доверие к ИИ-системам в практической экологии.

Перспективы дальнейших исследований напрямую вытекают из предложенных в работе концепций. В первую очередь необходимо сосредоточиться на практической реализации предложенных архитектур: самообъяснимого Vision Transformer и мультимодальной сети для прогнозирования функциональной активности. Дальнейшее развитие может включать интеграцию дополнительных слоёв данных, таких как протеомные и метаболомные профили, а также гидрохимические параметры водной среды, для построения еще более комплексных и точных моделей водных экосистем.

**КОНФЛИКТ ИНТЕРЕСОВ:** Авторы заявляют об отсутствии конфликта интересов.

**ФИНАНСИРОВАНИЕ:** Данное исследование было профинансировано в рамках выполнения проекта ПЦФ ВР28712227 «Разработка и внедрение высокотехнологичных решений мониторинга, очистки и рационального использования водных ресурсов Северо-Казахстанской области для обеспечения здоровья населения» 2025-2027 Министерство науки и высшего образования Республики Казахстан.

**БЛАГОДАРНОСТИ:** Авторы выражают благодарность анонимным рецензентам за ценные замечания, способствовавшие улучшению качества статьи.

**УВЕДОМЛЕНИЕ ОБ ИСПОЛЬЗОВАНИИ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА:** Авторы использовали переводчик DeepL (использующий ИИ) для перевода аннотации на английский язык.

#### СПИСОК ЛИТЕРАТУРЫ

- Altaf, A., Mehmood, A., Filograno, M. L., Alharbi, S., & Iqbal, J. (2025). Deployable deep learning models for crack detection: Efficiency, interpretability, and severity estimation. *Buildings*, 15(18), 3362. <https://doi.org/10.3390/buildings15183362>
- Di Vincenzo, S. (n.d.). Multimodal artificial intelligence in biomedical research: Integrating electronic health records and imaging data [Master's thesis, Utrecht University]. Utrecht University Repository. <https://studenttheses.uu.nl/bitstream/handle/20.500.12932/46086/-WritingAssignmentDiVincenzo.pdf>
- Işıl, Ç., Koydemir, H. C., Eryilmaz, M., de Haan, K., Pillar, N., Montesoglu, K., Unal, A. F., Rivenson, Y., Chandrasekaran, S., Garner, O. B., & Ozcan, A. (2025). Virtual Gram staining of label-free bacteria using dark-field microscopy and deep learning. *Science Advances*, 11(2), eads2757. <https://doi.org/10.1126/sciadv.ads2757>
- Hou, J., Liu, S., Bie, Y., Wang, H., Tan, A., Luo, L., & Chen, H. (2024). Self-explainable AI for medical image analysis: A survey and new outlooks. *arXiv*. <https://doi.org/10.48550/arXiv.2410.02331>
- Huang, Z., Sekhon, V. K., Sadeghian, R., Vaida, M. L., Jo, C., McCormick, B. A., Ward, D. V., Bucci, V., & Haran, J. P. (2024). ADAM: An AI reasoning and bioinformatics model for Alzheimer's disease detection and microbiome clinical data integration. *IEEE Access*, 12, 1–15. <https://doi.org/10.1109/ACCESS.2024>
- Muller, E., Shiryani, I., & Borenstein, E. (2024). Multi-omic integration of microbiome data for identifying disease-associated modules. *Nature Communications*, 15(1), 2621. <https://doi.org/10.1038/s41467-024-46888-3>
- Purwono, P., Wulandari, A. N. E., & Nisa, K. (2023). Explainable artificial intelligence (XAI) in medical imaging: Techniques, applications, challenges, and future directions. *Applied Medical and Medical Sciences*, 1(1), 52–66. <https://doi.org/10.53623/amms.v1i1.692>
- Raghuvanshi, S. (2025, September 18). Machine explainability: A guide to LIME, SHAP, and GradCAM. *Medium*. <https://suryansh-raghuvanshi.medium.com/machine-explainability-a-guide-to-lime-shap-and-gradcam-60f6265f365f>
- Sadeghi, Z., Alizadehsani, R., CIFCI, M. A., Kausar, S., Rehman, R., Mahanta, P., Bora, P. K., Almasri, A., Alkhalwaldeh, R. S., Hussain, S., Alatas, B., Shoeibi, A., Moosaei, H., Hladík, M., Nahavandi, S., & Pardalos, P. M. (2024). A review of explainable artificial intelligence in healthcare. *Computers and Electrical Engineering*, 118, 109370. <https://doi.org/10.1016/j.compeleceng.2024.109370>
- Sakagianni, A., Koufopoulou, C., Feretzakis, G., Kalles, D., Verykios, V. S., Myriantsefs, P., & Fildisis, G. (2023). Using machine learning to predict antimicrobial resistance—A literature review. *Antibiotics*, 12(3), 452. <https://doi.org/10.3390/antibiotics12030452>
- Sartori, F., Codicè, F., Caranzano, I., Rollo, C., Birolo, G., Fariselli, P., & Pancotti, C. (2025). A comprehensive review of deep learning applications with multi-omics data in cancer research. *Genes*, 16(6), 648. <https://doi.org/10.3390/genes16060648>

- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual explanations from deep networks via gradient-based localization. In Proceedings of the IEEE International Conference on Computer Vision (ICCV) (pp. 618–626). IEEE. <https://doi.org/10.1109/ICCV.2017.74>
- Smith, K. P., & Kirby, J. E. (2020). Image analysis and artificial intelligence in infectious disease diagnostics. *Clinical Microbiology and Infection*, 26(10), 1318–1323. <https://doi.org/10.1016/j.cmi.2020.03.012>
- Wu, Y., & Gadsden, S. A. (2023). Machine learning algorithms in microbial classification: A comparative analysis. *Frontiers in Artificial Intelligence*, 6, 1200994. <https://doi.org/10.3389/frai.2023.1200994>
- Yachnaya V. O., Mikhalkova M. A., Malashin R. O. et al, (2024). Improving generalization in classification of novel bacterial strains: A multi-headed ResNet approach for microscopic image classification. *Computer Optics*, 48(5), 772–781. <https://doi.org/10.18287/2412-6179-CO-1464>
- Zhang, Y., Thomas, J. P., Korcsmaros, T., & Gul, L. (2024). Integrating multi-omics to unravel host-microbiome interactions in inflammatory bowel disease. *Cell Reports Medicine*, 5(9), 101738. <https://doi.org/10.1016/j.xcrm.2024.101738>

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Берилло Дмитрий Александрович** – PhD, профессор, М. Қозыбаев атындағы Солтүстік Қазақстан университеті агрокомпетенциялар орталығындағы су ресурстары жөніндегі ғылыми үйлестіруші, Петропавл қ., Қазақстан

**Берилло Дмитрий Александрович** – PhD, профессор, научный координатор по водным ресурсам в Центре агрокомпетенций Северо-Казакхстанский университет имени М. Козыбаева, г. Петропавловск, Казахстан

**Berillo Dmitry Alexandrovich** – PhD, professor Scientific Coordinator for water resources at center of Agro competence Manash Kozybayev North Kazakhstan University, Petropavlovsk, Kazakhstan,  
e-mail: [daberillo@ku.edu.kz](mailto:daberillo@ku.edu.kz),  
ORCID: <https://orcid.org/0000-0003-2534-9367>



**Икласова Кайнижамал Есимсеитовна** – PhD, «Ақпараттық-коммуникациялық технологиялар» кафедраның доценті, М. Козыбаев атындағы Солтүстік-Қазақстан университеті, Петропавл қ., Қазақстан

**Икласова Кайнижамал Есимсеитовна** – PhD, доцент кафедры «Информационно-коммуникационные технологии», Северо-Казакхстанский университет имени М. Козыбаева, г. Петропавловск, Казахстан

**Kainizhamal Iklassova** – PhD, associate professor, Department of Information and Communication Technologies, Manash Kozybayev North Kazakhstan University, Petropavlovsk, Kazakhstan,  
e-mail: [keiklasova@ku.edu.kz](mailto:keiklasova@ku.edu.kz),  
ORCID: <https://orcid.org/0000-0002-8330-4282>




**Семенюк Владислав Владимирович** – магистр, М. Қозыбаев атындағы Солтүстік Қазақстан университеті халықаралық кампус аға оқытушысы, Петропавл, Қазақстан

**Семенюк Владислав Владимирович** – магистр, старший преподаватель международного кампуса, Северо-Казакстанский университет имени М. Козыбаева, г. Петропавловск, Казакстан

**Semenyuk Vladislav** – Master's degree, Senior Lecturer at the International Campus, Manash Kozybayev North Kazakhstan University, Petropavlovsk, Kazakhstan,

e-mail: vvsemenyuk@ku.edu.kz

ORCID: <https://orcid.org/0000-0002-8580-7326>



**Ташибаев Рустем Маратович** – докторант, М. Козыбаев атындағы Солтүстік-Қазақстан университеті, Петропавл қ., Қазақстан

**Ташибаев Рустем Маратович** – докторант, Северо-Казакстанский университет имени М. Козыбаева, г. Петропавловск, Казакстан

**Tashibaev Rustem Maratovich** – PhD student, Manash Kozybayev North Kazakhstan University, Petropavlovsk, Kazakhstan,

e-mail: rasll17@mail.ru

ORCID: <https://orcid.org/0009-0006-2436-9584>







[https://doi.org/10.51885/3134-8025\\_IJCS\\_2026\\_1\\_4](https://doi.org/10.51885/3134-8025_IJCS_2026_1_4)

МРНТИ 28.23.01

## ИЗВЛЕЧЕНИЕ ТЕКСТУРНЫХ ХАРАКТЕРИСТИК МРТ-ИЗОБРАЖЕНИЙ КОЛЕННОГО СУСТАВА С ПРИМЕНЕНИЕМ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ РАЗРЫВОВ МЕНИСКА

МЕНИСКТИҢ ЖЫРТЫЛУЫН ЖІКТЕУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ  
АЛГОРИТМДЕРІН ҚОЛДАНА ОТЫРЫП, ТІЗЕ БУЫНЫНЫҢ  
МРТ СУРЕТТЕРІНІҢ ТЕКСТУРАЛЫҚ СИПАТТАМАЛАРЫН АЛУ

## EXTRACTION OF TEXTURE FEATURES FROM KNEE JOINT MRI IMAGES USING MACHINE LEARNING ALGORITHMS FOR CLASSIFICATION OF MENISCAL TEARS

М.А. Карменова <sup>1</sup>, З.М. Төлеуғазы <sup>2</sup>, Т.Б. Дуанбаева <sup>2</sup>, А.С. Тлебалдинова <sup>3\*</sup>,  
С.К. Кумаргажанова <sup>3</sup>, Z. Omiotek <sup>4</sup>

<sup>1</sup>Восточно-Казахстанский университет им. С. Аманжолова, г. Усть-Каменогорск, Казахстан

<sup>2</sup>Филиал «Назарбаев Интеллектуальная школа естественно-математического направления города Усть-Каменогорска» автономной организации образования «Назарбаев Интеллектуальные школы», г. Усть-Каменогорск, Казахстан

<sup>3</sup>Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

<sup>4</sup>Люблинский технический университет, г. Люблин, Польша

\*Автор-корреспондент: Тлебалдинова Айжан Солтанғалиевна, e-mail: atlebaldinova@edu.ektu.kz

### Ключевые слова:

МРТ-изображения,  
мениск, текстурный  
анализ, классификация,  
признаки, RFE, ANOVA,  
критерий Fisher

### АННОТАЦИЯ

В работе представлен подход к автоматической классификации состояния мениска коленного сустава на основе текстурного анализа МРТ-изображений с применением методов машинного обучения. Для извлечения признаков использовалось программное обеспечение MaZda 4.6, включающее показатели гистограмм, матрицы совместного появления уровней серого (GLCM), матрицы длин серий (GLRLM) и вейвлет-признаки. Отбор наиболее информативных признаков выполнялся методами RFE, ANOVA и Fisher, что позволило сократить исходный набор с 297 до 16 признаков. Для бинарной классификации классов normal и tear применялись алгоритмы MLP и SVM, показавшие высокую точность (до 95 %) при использовании оптимальных подмножеств признаков. Полученные результаты подтверждают диагностическую значимость текстурных характеристик и демонстрируют эффективность их использования для автоматизированного выявления разрывов мениска, что может быть полезно для поддержки клинической диагностики и прогностической оценки состояния коленного сустава.



© 2026 М.А. Карменова, З.М. Төлеуғазы, Т.Б. Дуанбаева, А.С. Тлебалдинова,  
С.К. Кумаргажанова, Z. Omiotek

Данная работа распространяется на условиях лицензии  
Creative Commons «С указанием авторства» 4.0 Международная (CC BY 4.0).  
<https://creativecommons.org/licenses/by/4.0/>

---

#### **Түйінді сөздер:**

МРТ кескіндері, мениск,  
текстуралық талдау,  
жіктеу, белгілер, RFE,  
ANOVA, Fisher критерийі

#### **ТҮЙІНДЕМЕ**

Бұл мақалада машиналық оқыту әдістерін қолдана отырып, МРТ кескіндерінің текстуралық талдауы негізінде тізе буыны менискісінің жағдайын автоматты түрде жіктеу тәсілі ұсынылған. Белгілерді шығару үшін гистограмма көрсеткіштерін, сұр деңгейлердің бірлескен пайда болу матрицасын (GLCM), серия ұзындықтарының матрицасын (GLRLM) және вейвлет-белгілерді қамтитын MaZda 4.6 бағдарламалық қамтамасыз етуі пайдаланылды. Ең ақпараттық белгілерді іріктеу RFE, ANOVA және Фишер әдістерімен жүргізіліп, бастапқы 297 белгіден 16 белгіге дейін қысқартуға мүмкіндік берді. Normal және tear кластары үшін бинарлық жіктеуде MLP және SVM алгоритмдері қолданылып, оңтайлы белгілер жиынтығында жоғары дәлдік (95 %-ға дейін) көрсетті. Алынған нәтижелер текстуралық сипаттамалардың диагностикалық маңыздылығын растап, мениск жыртылуын автоматтандырылған түрде анықтаудың тиімділігін көрсетеді, бұл клиникалық диагностиканы қолдауға және тізе буыны жағдайын болжауға пайдалы болуы мүмкін.

---

#### **Keywords:**

MRI images, meniscus,  
texture analysis,  
classification, features,  
recursive feature  
elimination (RFE), analysis  
of variance (ANOVA),  
Fisher's criterion.

#### **ABSTRACT**

This paper presents an approach to automatic classification of knee meniscus condition based on texture analysis of MRI images using machine learning methods. Feature extraction was performed with MaZda 4.6 software, including histogram features, gray-level co-occurrence matrix (GLCM), gray-level run-length matrix (GLRLM), and wavelet features. The most informative features were selected using RFE, ANOVA, and Fisher methods, reducing the original set from 297 to 16 features. For binary classification of the normal and tear classes, MLP and SVM algorithms were applied, achieving high accuracy (up to 95 %) when optimal feature subsets were used. The results confirm the diagnostic significance of texture characteristics and demonstrate their effectiveness for automated detection of meniscal tears, which may be useful for supporting clinical diagnosis and prognostic assessment of knee joint condition.

---

#### **ВВЕДЕНИЕ**

За последние десять лет подходы, использующие применение методов машинного обучения на основе искусственного интеллекта для обнаружения различного рода заболеваний у пациентов, приобрели значительную популярность в медицине. На сегодня в различных областях медицины применяются определенные методы диагностики, позволяющие получить подробные исследования для установления точного диагноза заболеваний у пациентов. Среди таких методов наиболее высокую популярность получила магнитно-резонансная томография (далее МРТ).

МРТ является инструментальным методом диагностики, который дает возможность получить самые подробные послойные снимки практически любой части человеческого тела. Важно отметить, что МРТ по сравнению с другими методами позволяет визуализировать мягкие ткани. Данный метод зарекомендовал себя вполне безопасным и не требует проведения каких-либо болезненных процедур и манипуляций по отношению к пациентам. Также все больше исследований рассматривают этот метод для раннего выявления многих заболеваний. Надо отметить, что большинство исследований подобного рода с использованием сканирования МРТ проводились на коленном суставе. В целом анатомия и структура коленного сустава являются самыми крупными и сложными в организме человека. Среди часто встречающихся и наиболее распространенных видов

травм коленного сустава выступают менисковые повреждения, а также повреждения передней крестообразной связки (ПКС) и др. Разрывы мениска чаще всего приводят к дегенерации хряща и костей, которая вызывает боль и потерю подвижности. В связи с этим МРТ-визуализация позволяет 2D и 3D визуализировать колено и обнаруживать разрывы мениска.

Исходя из различных видов травм коленного сустава, большинство исследований стремятся разработать полностью автоматизированные методы и подходы для диагностической и прогностической оценки состояния травмы. В таких подходах авторы применяют модели глубокого обучения, а также классические методы для решения задачи сегментации и классификации видов травм. Важной составляющей или одним из главных исследовательских этапов при разработке подобных подходов выступает текстурный анализ.

Текстурный анализ МРТ-изображений способен предоставить важную информацию, а именно позволяет извлечь текстурные признаки для разделения классов по исследуемым наборам данных, в нашем случае по типам разрывов мениска. Тем самым поиск новых текстурных признаков дает возможность расшифровать результат МРТ-изображений и применять их в итоговых диагностических и предиктивных моделях оценки данных.

В подобных исследованиях для получения диагностической информации необходимо изучить текстуру изображений. В целом при анализе МРТ-изображений недостаточно анализировать свойства изображения на основе только точечной яркости, следует учитывать статистику изображения более высокого порядка (Materka A., 2004). Количественное определение текстуры, а именно ее описание по точно определенным параметрам, представляет возможность для извлечения информации о свойствах ткани (Materka A., 2004). Численные значения параметров текстуры могут быть использованы для классификации различных областей на изображении, представляющих, например, либо ткани разного происхождения, либо нормальные и аномальные ткани данного вида (Materka A., 2004). Изменения правильно выбранных параметров текстуры с течением времени могут количественно отражать изменения в физической структуре ткани (Materka A., 2004).

Целью настоящей работы является разработка и оценка подхода к бинарной классификации состояния мениска коленного сустава (normal/tear) на основе текстурного анализа МРТ-изображений с использованием методов машинного обучения. В рамках исследования ставится задача выявления информативных текстурных признаков, оптимизации их подмножеств с помощью методов отбора признаков (ANOVA, Fisher, RFE) и оценки эффективности различных алгоритмов классификации (Linear Discriminant Analysis (LDA), Support Vector Machine (SVM), k-Nearest Neighbors (KNN), Decision Tree (DT), Multilayer Perceptron (MLP) и Random Forest (RF).) для повышения точности и надежности диагностики разрывов мениска.

## ОБЗОР ЛИТЕРАТУРЫ

На сегодняшний день большинство применяемых методов анализа текстур основаны на анализе матрицы совместного появления серого уровня (GLCM - Gray Level Co-occurrence Matrix). В (Aoki, et al., 2018), авторы проводят исследование для проверки эффективности анализа текстуры в сравнении между анализом текстуры на основе T2map МРТ и гистологическим анализом дегенерации мениска у пациентов с остеоартритом (ОА) коленного сустава. В эксперименте были использованы 60 образцов мениска, среди которых 26 медиальных менисков и 34 боковых мениска, полученных у 11 пациентов с прогрессирующей или терминальной стадией коленного ОА. Коленные суставы пациентов были проанализированы с помощью МРТ 3.0T. Текстурный анализ мениска был

выполнен на корональной плоскости T2map с применением метода GLCM. Текстуальный анализ и статистический анализ проводились с использованием ПО MATLAB 2017a, где значение  $p < 0,05$  считалось статистически значимым. В результате проведения текстурного анализа были извлечены 4 текстурные особенности: контрастность  $0^\circ$ , контрастность  $90^\circ$ , дисперсия и энтропия, а также T2 были извлечены для каждой интересующей области на каждом срезе. Гистологическая оценка мениска проведена на разделенных 4 областях мениска. По утверждениям авторов исследования, показатели текстурного анализа, включая контраст  $0^\circ$ , контраст  $90^\circ$ , дисперсию и энтропию менисков, не были связаны со значением T2 менисков пациентов. Также показатели текстурного анализа энтропия и контрастность  $90^\circ$  не были связаны с гистологическими показателями менисков пациентов. Таким образом, авторы доказывают, что текстурный анализ дегенерации менисков, связанный с ОА коленного сустава, коррелировал с гистологическим анализом дегенерации менисков у пациентов с ОА коленного сустава, в то время как значения T2 дегенерации менисков не было. В (Juras, et al., 2021) авторы проводят исследование с целью изучения особенностей текстуры на картах T2 в качестве маркера для различения зрелости восстанавливаемой хрящевой ткани в коленном суставе после процедур микроперелома (MFX) и матрикс-ассоциированной трансплантации хондроцитов (МАСТ). Исследование авторов также опирается на метод GLCM, на основе которого был извлечен двадцать один текстурный признак. Различия между методами восстановления хрящевой ткани коленного сустава оценивали линейной регрессией для разных областей бедренной кости. Стабильность и воспроизводимость текстурных признаков определяли через внутриклассовую изменчивость и анализ ROC-кривых. В результате проведенного исследования авторы выявили значимые различия текстурных характеристик, такие как автокорреляция, однородность и энтропия, в разных зонах хряща. Ткань после МАСТ оказалась ближе к структуре здорового хряща через 24 месяца, чем после MFX. Таким образом, текстурный анализ GLCM дополняет картирование T2, повышая чувствительность метода к структурным изменениям хрящевой ткани. Как и в (Juras, et al., 2021), также в (Janacova, et al., 2022), реализованы исследования на основе GLCM для анализа текстуры, который предоставляет дополнительную информацию о состоянии и созревании восстановленной ткани, а также о прилегающем хряще. Текстурные характеристики, такие как автокорреляция и дисперсия уровня серого, показали различия между восстановленным, прилегающим и контрольным хрящом. В (Janacova, et al., 2021)) исследовательская работа заключалась в сравнении характеристик GLCM для поражений коленного хряща. В исследовании было оценено влияние смещения (направления) расчета GLCM и количество параметров, применяемых для картирования T2, влияющих на характеристики GLCM с учетом микроанатомической структуры хряща. Тем самым в результате анализа текстуры с помощью GLCM были отобраны важные индикаторы, отличающие повреждения хряща. Среди таких индикаторов авторы выявили автокорреляцию, контрастность и однородность. В оценке нормальности данных применялся тест Шапиро-Уилка. Различия в средних значениях T2 и характеристиках GLCM между пораженным и здоровым хрящом исследовались с помощью теста рангов Уилкоксона. Этот же тест использовался для анализа различий в характеристиках GLCM при разных смещениях и параметрах картирования T2. Результаты представлены как среднее значение  $\pm$  стандартное отклонение и/или p-значения.

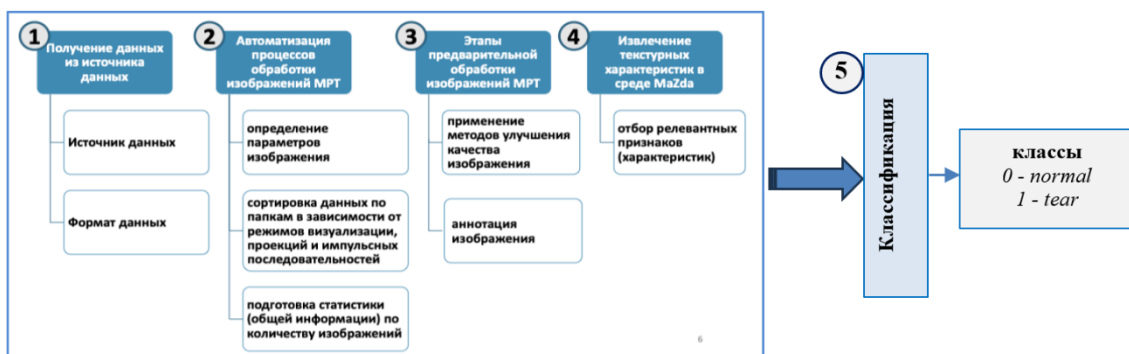
Статистический анализ и визуализация данных проводились с использованием Rstudio версии 1.3.1093. Исходя из результатов исследования, а также по утверждениям авторов, было доказано, что смещение  $0^\circ$  является ключевым параметром для различения пораженного и здорового хряща в коленном суставе, при этом контрастность и однородность значительно различаются только в этом направлении, где текстура

здорового хряща гладкая (однородная) в горизонтальном направлении, когда ROI вращается и уплощается.

## МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Текстурный анализ изображений по сравнению с другими методами анализа изображений имеет значимые преимущества в распознавании структурных особенностей изображений. Текстурный анализ изображений улучшает процесс обнаружения незначительных изменений в структуре ткани или суставов, способствуя повышению эффективности и точности алгоритмов машинного обучения в задачах классификации или сегментации разрывов мениска, а также в подходах, связанные с моделями глубокого обучения. Можно выделить главные особенности и преимущества текстурного анализа изображений в сравнении с другими методами, а именно: эффективный анализ закономерностей в распределении интенсивности пикселей, позволяющий обнаруживать мелкие детали в виде зернистости, повторяющихся узоров или неоднородности; фокус на структурных характеристиках изображений, таких как распределение контраста, а также частотных составляющих, что делает его менее чувствительным к изменениям цвета, освещенности и яркости; применимость к сложным структурам и формам объектов, в случаях, где объекты плохо различимы по форме или цвету, а также не имеют четко выраженных геометрических границ. В таких случаях текстурный анализ позволяет выделить ключевые признаки для классификации или сегментации объектов; устойчивость к шуму, во многих случаях методы текстурного анализа оказываются устойчивыми к шуму в изображении, так как работают с обобщенными характеристиками изображения; хорошая и легкая интеграция с алгоритмами и моделями машинного обучения.

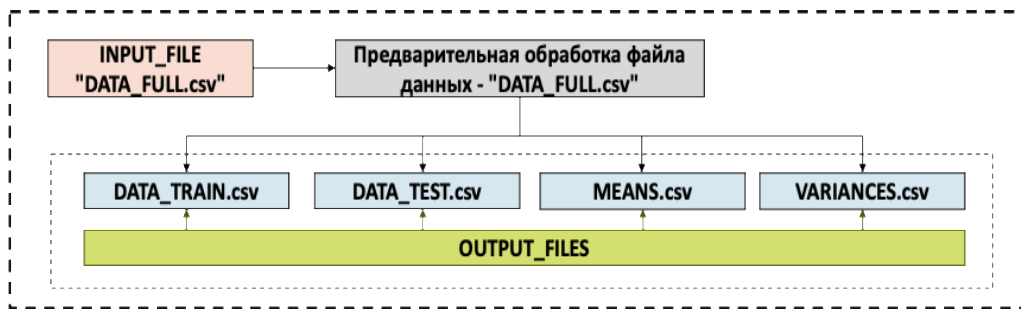
Методология исследования представлена на рисунке 1 и состоит из основных четырех этапов: 1) получение и сбор данных; 2) автоматизация процессов обработки МРТ-изображений; 3) предварительная обработка данных; 4) извлечение текстурных признаков; 5) классификация. В исследовании был сформирован набор данных, состоящий из 2000 МРТ-изображений мениска, из которых 1000 изображений относятся к здоровому мениску (normal), а 1000 к горизонтальным разрывам (tear). Использовались T1-режим МРТ и сагиттальные срезы коленного сустава. Каждое изображение предварительно сегментировалось с выделением области интереса (ROI) для последующего извлечения текстурных признаков. Такой сбалансированный и стандартизированный набор данных обеспечивает корректное обучение и оценку бинарных классификаторов.



**Рисунок 1.** Общая схема методологии исследования по извлечению текстурных признаков МРТ-изображений мениска коленного сустава и классификации

*Примечание – составлено авторами*

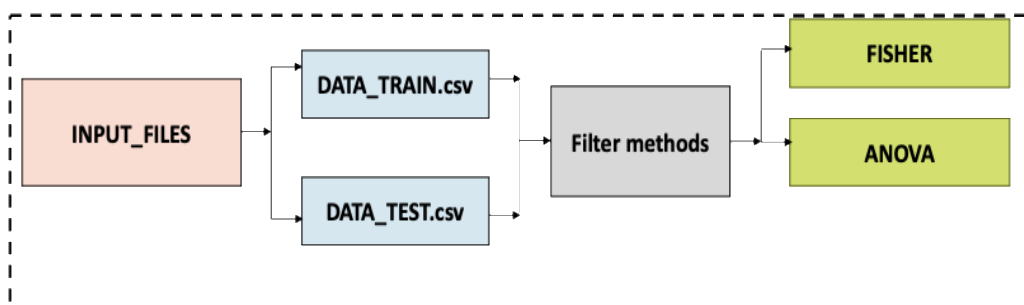
Процесс предобработки данных начинается с входного файла в формате .csv, содержащего исходные текстурные признаки, извлеченные из МРТ-изображений мениска. На первом шаге проводится предобработка данных, включающая проверку на пропуски, нормализацию или стандартизацию признаков, а также возможное устранение выбросов и шумов. После этого формируются отдельные наборы данных для обучения (train) и тестирования (test), каждый из которых сохраняется в отдельных .csv-файлах; включающие проверку данных, нормализацию признаков и их приведение к средним значениям (means), что обеспечивает согласованность масштабов и устраняет влияние разных диапазонов признаков. Эти подготовленные файлы служат входными данными для последующих этапов построения и обучения моделей машинного обучения, обеспечивая корректность и сопоставимость данных между этапами обучения и валидации.



**Рисунок 2.** Предварительная обработка данных

*Примечание – составлено авторами*

После предобработки данных в соответствии с рисунком 3 осуществляется выбор информативных признаков с использованием методов фильтрации. На вход этапа поступают .csv-файлы с подготовленными наборами признаков для обучения (train) и тестирования (test). Далее применяются методы фильтрации, которые оценивают значимость каждого признака относительно целевого класса. В рамках данного исследования использованы два метода: ANOVA и Fisher, позволяющие отобрать наиболее информативные текстурные характеристики для последующего обучения моделей машинного обучения. Результатом этапа являются подмножества признаков, оптимизированные для повышения точности классификации.



**Рисунок 3.** Выбор признаков с использованием методов фильтрации

*Примечание – составлено авторами*

#### *Текстурный анализ МРТ-изображений*

Текстурный анализ является математическим методом, позволяющим проводить оценку интенсивности сигнала на уровне серого и соседнее положение пикселей и/или

вокселей (Fritz, et al., 2018). Данный вид анализа может использоваться в МРТ для количественной оценки неоднородности компонентов ткани, превосходящей морфологический анализ (Fritz, et al., 2018). Соответственно, текстурный анализ определяет меру вариации интенсивности пикселей на данном изображении, области интереса или объеме (Michael, 2022). Таким образом, для груботекстурированных изображений будет свойственна высокая скорость изменения высокой и низкой интенсивности пикселей по сравнению с гладкотекстурированным изображением (Michael, 2022). В медицинской визуализации пространственная неоднородность внутри органа встречается при различных патологических состояниях, и повышенная неоднородность часто указывает на более агрессивное отклонение от нормы (Хорват, др., 2021).

Процесс проведения текстурного анализа включает в себя несколько последовательных этапов, таких как: 1) получение медицинских изображений в формате DICOM; 2) выбор области интереса (ROI – Region of Interest) и сегментация; 3) этап извлечения текстурных показателей; 4) статистический анализ с построением прогностических моделей с дальнейшей их оценкой. В настоящее время существуют ряд программного обеспечения (далее ПО) для выполнения текстурного анализа, в качестве примеров таких ПО можно привести MATLAB, PyRadiomics, MaZda, 3D Slicer и др.

В этапах текстурного анализа сегментация изображения может быть реализована как вручную, так и в автоматическом или полуавтоматическом режиме, с анализированием в виде 2D ROI или рассмотрением всего объема зоны интереса, а именно 3D ROI. Также необходимо отметить, что извлекаемые текстурные показатели и весь результат исследования зависят от качества изображений и сегментации. Выход за пределы ROI и включение артефактов могут привести к искажению конечных результатов. Промежуточным этапом между сегментацией и извлечением текстурных показателей является предварительная обработка изображений. Существуют различные варианты предобработки изображений, к часто встречающимся можно отнести следующие методы (Timmeren, et al., 2020): интерполяцию к изотропному вокселю; фильтрацию уровней интенсивности; дискретизацию количества и ширины ячейки (бина); применение различных фильтров, к примеру Лапласа-Гаусса, вейвлет-фильтра и др.

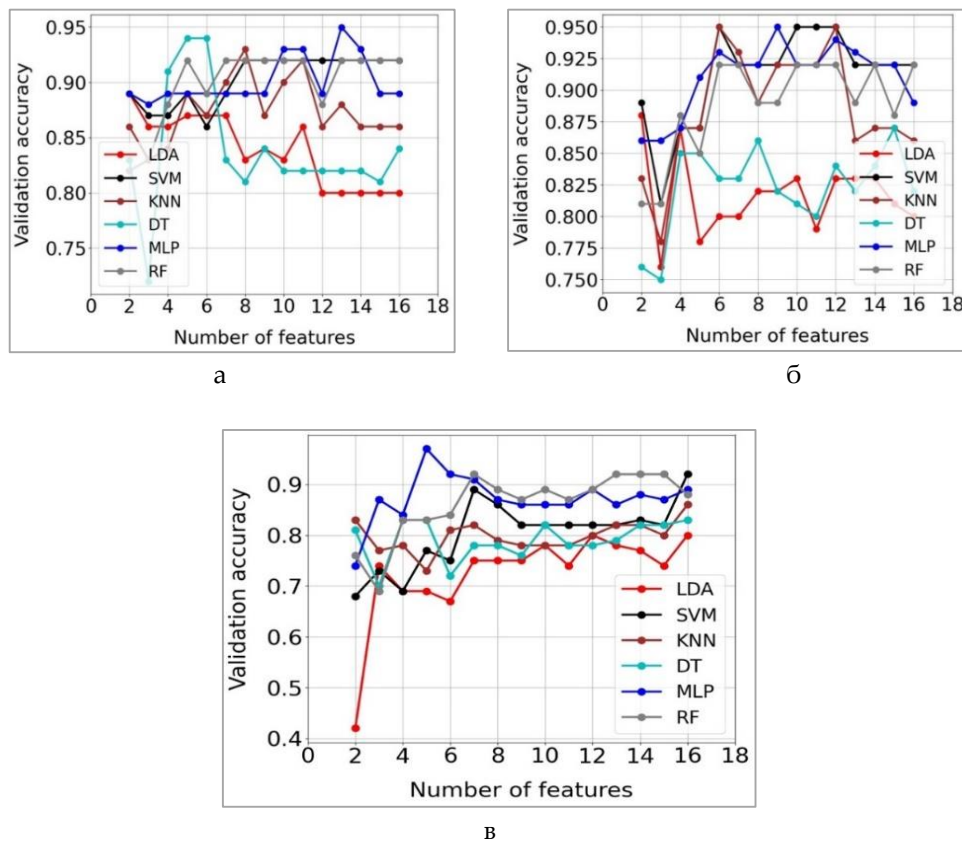
В процессе проведения текстурного анализа изображений полученные текстурные показатели обычно разделяют на несколько групп как показатели первого порядка и показатели второго порядка. К показателям первой группы относятся характеристики гистограммы, описывающие распределение интенсивности вокселей в изображении. Такими характеристиками являются энтропия, куртозис, значения интенсивности, скошенность, коэффициент асимметрии и однородность. Показателями второго порядка являются GLRLM (Grey-Level Run Length Matrix), GLZLM (Grey-Level Zone Length Matrix), GLCM (Grey Level Co-occurrence Matrix), NGLDM (Neighborhood Grey-Level Difference Matrix) и др. Эти показатели характеризуют взаимоотношения вокселей в ROI и отражают пространственное распределение интенсивности уровней серого в изображении. Также можно выделить показатели более высокого порядка, которые основываются на применении ряда математических функций; в качестве таких функций можно привести, к примеру вейвлет-фильтр, преобразования Фурье и др. [Parekh, et al., 2016].

## РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

В рамках данной статьи было проведено исследование по классификации состояния мениска коленного сустава на основе текстурных признаков, извлеченных из МРТ-изображений. Предварительно изображения были обработаны в программе MaZda, где вручную выделялась область интереса (ROI), соответствующая ткани мениска. Для каждой ROI рассчитывался набор текстурных признаков, включающих статистические

характеристики гистограммы уровней серого, признаки на основе матриц совместной встречаемости уровней серого (GLCM), матриц длин серий (GLRLM), а также другие стандартные текстурные дескрипторы. Полученные признаки были экспортированы в формате .par и далее преобразованы в единую таблицу признаков с использованием Python-скрипта. Итоговый датасет содержал числовые текстурные характеристики и бинарную метку класса: 0 (normal) - здоровый мениск, 1 (tear) – горизонтальный разрыв мениска. В оценке эффективности классификации были использованы традиционные алгоритмы машинного обучения: LDA, SVM, KNN, DT, MLP и RF. С целью анализа влияния размерности признакового пространства на качество классификации была выполнена серия экспериментов с различным числом наиболее информативных признаков. Количество используемых признаков варьировалось от 2 до 16. На основе каждого набора признаков проводились обучение и валидация моделей, а качество оценивалось по метрике accuracy на валидационной выборке.

На рисунке 4 представлены результаты классификации, полученные при использовании текстурных признаков, извлеченных из МРТ-изображений мениска коленного сустава, а также различных алгоритмов машинного обучения в сочетании с методами отбора признаков ANOVA, Fisher и Recursive Feature Elimination (RFE). Исходный набор признаков включал 16 текстурных характеристик, для которых проводились последовательные эксперименты с варьированием количества отобранных признаков.



**Рисунок 4.** Результаты обучения и валидации моделей с использованием метода перебора по сетке для классификации по следующим методам отбора признаков:

а – метод RFE; б – метод ANOVA; в – метод Фишера

*Примечание – составлено авторами*

Результаты эксперимента показали, что точность классификации существенно зависит как от выбранного алгоритма машинного обучения, так и от количества используемых текстурных признаков. В целом наблюдается тенденция роста качества классификации при увеличении числа признаков до определенного порогового значения, после чего точность стабилизируется либо снижается. Это указывает на наличие избыточных и коррелированных признаков в исходном наборе и подчеркивает необходимость этапа отбора признаков при анализе медицинских изображений.

В соответствии с рисунком 4(а) по методу отбора RFE наиболее устойчивые и высокие показатели точности продемонстрировали алгоритмы MLP, SVM и Random Forest. В частности, модель MLP в сочетании с методом RFE достигла максимального значения ассигасы порядка 0,95 при использовании 13 признаков, что свидетельствует о способности нейронной сети эффективно моделировать нелинейные зависимости между текстурными характеристиками мениска. Данный результат позволяет рассматривать комбинацию RFE-MLP как наиболее эффективную в рамках проведенного исследования. Алгоритм Random Forest показал стабильные результаты с точностью около 0,92, что подтверждает его устойчивость к шуму и избыточности признаков. SVM также продемонстрировал высокую и стабильную точность (до 0,93), особенно при использовании среднего и большого числа признаков, что указывает на хорошую разделимость классов в пространстве текстурных характеристик. В то же время алгоритмы LDA и DT показали более низкие значения точности и большую вариативность результатов. Это может быть связано с ограниченной способностью линейных моделей и одиночных деревьев решений описывать сложную и нелинейную структуру текстурных признаков МРТ-изображений. Метод KNN продемонстрировал умеренные показатели качества, однако его чувствительность к числу признаков и возможному шуму в данных ограничивает его практическую применимость для данной задачи. Важным наблюдением является тот факт, что увеличение числа признаков сверх определенного уровня не приводит к дальнейшему улучшению качества классификации. Это подтверждает наличие избыточных текстурных характеристик и подчеркивает целесообразность применения методов отбора признаков, таких как RFE, ANOVA и Fisher. Также на рисунке 4(б) результаты эксперимента показывают, что точность классификации значительно зависит как от алгоритма, так и от количества текстурных признаков. Наилучшие результаты демонстрируют MLP (до 0.95 точности), Random Forest и SVM, достигая максимума при использовании около 13-15 признаков, после чего дальнейшее увеличение числа признаков не улучшает качество. Более простые методы, такие как LDA и DT, показали более низкую и менее стабильную точность, что указывает на их ограниченную эффективность в моделировании сложных текстурных зависимостей. Таким образом, для данной задачи оптимальным является применение MLP, RF или SVM с тщательным отбором признаков. На рисунке 4(в) по графикам результаты показывают, что точность классификации на основе метода Фишера (Fisher Score) для отбора признаков сильно варьируется в зависимости от алгоритма. Наилучшую и наиболее стабильную точность (около 0.8-0.9) демонстрируют алгоритмы RF и SVM, причем их эффективность растет с увеличением числа признаков до 8-12, после чего стабилизируется. Метод MLP показывает высокий, но более изменчивый результат, достигая пика около 0.9, но с заметными колебаниями. Алгоритмы KNN и DT показывают умеренную точность (0.7-0.8), а LDA наименее эффективен, с точностью около 0.6-0.7, что указывает на недостаточную разделимость классов в линейном пространстве, построенном по отобраным признакам Фишера. Оптимальное число признаков для большинства методов составляет 10-14, после чего прирост точности незначителен.

В целом полученные результаты подтверждают, что текстурные признаки, извлеченные из МРТ-изображений мениска, содержат диагностически значимую

информацию, а их сочетание с современными методами машинного обучения позволяет достигать высокой точности автоматической классификации состояния мениска.

Таким образом, следующие модели достигли точности валидации 96 %: MODEL20FISHERET, MODEL8RELIEFMLP и MODEL19SBSMLP. В целом это были наиболее эффективные модели. Однако для дальнейшей работы была выбрана модель MODEL8RELIEFMLP из-за небольшого количества признаков и простоты.

На последующем этапе для каждого метода отбора признаков были выбраны наиболее эффективные модели классификации, которые были оценены на отложенном тестовом наборе для оценки их обобщающей способности. Полученные результаты подтвердили стабильность точности валидации на неизвестных данных, что указывает на отсутствие переобучения и подтверждает надежность и устойчивость предложенного подхода к построению классификаторов на основе текстурных признаков. В таблице 1 представлены наиболее эффективные модели, которые получены с применением различных алгоритмов классификации и методов отбора признаков для бинарной классификации.

**Таблица 1.** Оптимальные модели на основе метода отбора признаков  
(бинарная классификация)

Название модели	Метод классификации	Точность валидации	Оптимальное количество признаков	Параметры моделей
MODEL2ANOVARF	RF	0,92	6-10	'clfmaxdepth': 8, 'clfnestimators': 100
MODEL1 FISHERRF	RF	0,90	6-10	'clfmaxdepth': 5, 'clfnestimators': 100
MODEL2ANOVA SVM	SVM	0,93	8-12	'clfC': 0.1, 'clfgamma': 'scale', 'clfkernell': 'linear', 'clfprobability': True}
MODEL2 FISHER SVM	SVM	0,90	8-12	'clfC': 0.1, 'clfgamma': 'scale', 'clfkernell': 'linear', 'clfprobability': True
MODEL2ANOVA MLP	MLP	0,95	13	clfactivation': 'relu', 'clfalpa': 0.0001, 'clfhiddensizes': (7), 'clfmmaxiter': 20000, 'clfsolver': 'lbfgs'
MODEL1 FISHER MLP	MLP	0,90	10-14	'clfactivation': 'relu', 'clfalpa': 0.01, 'clfhiddensizes': (1), 'clfmmaxiter': 20000, 'clfsolver': 'lbfgs'

*Примечание – составлено авторами*

При оценке моделей в соответствии с таблицей 2 наиболее высокие значения F1-меры (0,95) для обоих классов были достигнуты моделями MODEL2ANOVA MLP, MODEL2ANOVA SVM, что указывает на высокую точность и полноту их прогнозов.

**Таблица 2.** Результаты оценивания моделей

Название модели	Класс	Precision	Recall	F1-score
MODEL2ANOVARF	Class0	0.92	0.96	0.94
	Class1	0.93	0.90	0.93
MODEL1 FISHERRF	Class0	0.93	0.96	0.95
	Class1	0.94	0.92	0.94
MODEL2ANOVA SVM	Class0	0.94	0.96	0.95
	Class1	0.96	0.93	0.95
MODEL2 FISHER SVM	Class0	0.93	0.97	0.95
	Class1	0.97	0.91	0.94
MODEL2ANOVA MLP	Class0	0.95	0.97	0.95
	Class1	0.96	0.94	0.95
MODEL1 FISHER MLP	Class0	0.93	0.96	0.95
	Class1	0.94	0.93	0.94

*Примечание – составлено авторами*

Предложенный подход к классификации состояния мениска на основе текстурных признаков МРТ и методов машинного обучения показал высокую эффективность. Применение метода отбора признаков ANOVA позволило снизить влияние избыточных характеристик и повысить качество классификации. Согласно результатам, представленным в таблице 2, наивысшие значения F1-меры (0,95 для обоих классов) были достигнуты моделями MODEL2ANOVAMLP и MODEL2ANOVASVM, что свидетельствует о сбалансированной точности и полноте прогнозов. Полученные результаты подтверждают диагностическую значимость текстурных признаков и эффективность их сочетания с алгоритмами MLP и SVM для автоматической классификации МРТ-изображений мениска.

Предложенный метод классификации состояния мениска на основе текстурного анализа МРТ и машинного обучения показал высокую эффективность. Применение методов отбора признаков Fisher, ANOVA и RFE позволило сократить исходный набор признаков с 297 до 16, что снизило риск переобучения и повысило обобщающую способность моделей. Это особенно важно для анализа медицинских изображений, где избыточные или нерелевантные признаки могут снижать точность классификации. В таблице 3 представлен итоговый набор признаков, использованный для построения моделей ANOVAMLP и ANOVASVM для бинарной классификации классов normal и tear, упорядоченных в соответствии с ранжированием методом RFE.

**Таблица 3.** Набор признаков для моделей ANOVA MLP и ANOVA SVM

№	Названия признаков	Значения	
		Класс 0 (normal)	Класс 1 (tear)
1	S(0,1)Correlat	+1.000 ± 0.05	-1.000 ± 0.05
2	S(1,0)Contrast	-1.000 ± 0.05	+1.000 ± 0.05
3	Perc.01%	+1.000 ± 0.05	-1.000 ± 0.05
4	HorzlGLevNonU	-1.000 ± 0.05	+1.000 ± 0.05
5	WavEnLHs-3	+1.000 ± 0.05	-1.000 ± 0.05
6	Teta3	-1.000 ± 0.05	+1.000 ± 0.05
7	WavEnHLs-3	-1.000 ± 0.05	+1.000 ± 0.05
8	S(1,0)InvDfMom	+1.000 ± 0.05	-1.000 ± 0.05
9	Perc.10%	+1.000 ± 0.05	-1.000 ± 0.05
10	Teta1	-1.000 ± 0.05	+1.000 ± 0.05

Окончание таблицы 3

№	Названия признаков	Значения	
		Класс 0 (normal)	Класс 1 (tear)
11	S(1,0)Correlat	+1.000 ± 0.05	-1.000 ± 0.05
12	Perc.99%	-1.000 ± 0.05	+1.000 ± 0.05
13	S(1,0)AngScMom	+1.000 ± 0.05	-1.000 ± 0.05

Примечание – составлено авторами

Использование программы MaZda 4.6 обеспечило стандартизированное извлечение текстурных признаков (GLCM, GLRLM, гистограммы, вейвлет) из ROI МРТ-изображений мениска. Для бинарной классификации применялась модель ANOVAMLP и ANOVASVM на признаках, отобранных методом RFE (8–13 признаков), которая достигла точности 95 %.

### ЗАКЛЮЧЕНИЕ

За последние годы применение методов машинного обучения для анализа МРТ-изображений коленного сустава стало особенно актуальным для выявления разрывов мениска, которые могут приводить к дегенерации хряща и ограничению подвижности. В данной работе использовался текстурный анализ с помощью программного обеспечения MaZda 4.6 для стандартизированного извлечения характеристик GLCM, GLRLM, гистограмм и вейвлет-признаков из ROI мениска. Для бинарной классификации классов normal и tear применялись алгоритмы MLP и SVM с отбором признаков методами RFE, ANOVA и Fisher, что позволило сократить исходный набор признаков с 297 до 16 наиболее информативных. Серия экспериментов с различным числом признаков (8–13) показала, что модели ANOVAMLP и ANOVASVM достигали точности до 95%, демонстрируя высокую стабильность и способность эффективно моделировать нелинейные зависимости между текстурными характеристиками мениска. Полученные результаты подтверждают диагностическую значимость текстурных признаков и эффективность их интеграции с современными методами машинного обучения для автоматической классификации состояния мениска.

**КОНФЛИКТ ИНТЕРЕСОВ:** Авторы заявляют об отсутствии конфликта интересов.

**ФИНАНСИРОВАНИЕ:** Данное исследование было профинансировано в рамках выполнения проекта AP23486396 «Модели и методы распознавания анатомических структур на изображениях МРТ в задачах компьютерной диагностики» 2024-2026 Министерство науки и высшего образования Республики Казахстан.

**БЛАГОДАРНОСТИ:** Авторы выражают благодарность анонимным рецензентам за ценные замечания, способствовавшие улучшению качества статьи.

### СПИСОК ЛИТЕРАТУРЫ

- Materka, A. (2004). Texture analysis methodologies for magnetic resonance imaging. *Dialogues in Clinical Neuroscience*, 6(2), 243–250. <https://doi.org/10.31887/DCNS.2004.6.2/amaterka>
- Aoki, T., et al. (2018). Comparison verification between texture analysis based on T2map MRI and histological analysis of the meniscal degeneration in patients with knee osteoarthritis. *Osteoarthritis and Cartilage*, 26, S413.
- Juras, V., Szomolanyi, P., Janáčová, V., Kirner, A., Angele, P., & Trattinig, S. (2021). Differentiation of cartilage repair techniques using texture analysis from T2 maps. *Cartilage*, 13(1suppl), 718S–728S. <https://doi.org/10.1177/19476035211029698>
- Janacova, V., Szomolanyi, P., Kirner, A., et al. (2022). Adjacent cartilage tissue structure after successful transplantation: a quantitative MRI study using T2 mapping and texture analysis. *European Radiology*, 32, 8364–8375. <https://doi.org/10.1007/s00330-022-08897-y>

- Janacova, V., Juras, V., Szomolanyi, P., & Trattnig, S. (2021). Optimization of knee cartilage texture analysis of quantitative MRI T2 maps. *Osteoarthritis and Cartilage*, 29, S329–S330. <https://doi.org/10.1016/j.joca.2021.02.430>
- Fischer, M. A. (2022). From morphology to biomarker: quantitative texture analysis of the infrapatellar fat pad reliably predicts knee osteoarthritis. *Radiology*, 304(3), 622–623. <https://doi.org/10.1148/radiol.22109>
- van Timmeren, J. E., Cester, D., Tanadini-Lang, S., et al. (2020). Radiomics in medical imaging— "how-to" guide and critical reflection. *Insights into Imaging*, 11, 91. <https://doi.org/10.1186/s13244-020-00887-2>
- Parekh, V., & Jacobs, M. A. (2016). Radiomics: a new application from established techniques. *Expert Review of Precision Medicine and Drug Development*, 1(2), 207–226. <https://doi.org/10.1080/23808993.2016.1164013>
- Tlebaldinova, A., Omiotek, Z., Karmenova, M., Kumargazhanova, S., Smailova, S., Tankibayeva, A., Kumarkanova, A., & Glinskiy, I. (2025). Comparison of modern convolution and transformer architectures: YOLO and RT-DETR in meniscus diagnosis. *Computers*, 14, 333. <https://doi.org/10.3390/computers14080333>
- Kazantsev, I. G., Tankibayeva, A. K., Kumargazhanova, S. K., & Azamatov, B. N. (2024). Correction of intensity inhomogeneity in magnetic resonance images using ramp filter. *Sibirsk. Elektron. Mat. Izv.*, 21(1), 307–314. <https://doi.org/10.33048/semi.2024.21.023>
- Фриц, Б., Мюллер, Д.А., Саттер, Р. и др. (2018). Магнитно-резонансная симография сортирование хрящевых опухолей костей: добавленная стоимость количественной текстуры анализ. *Invest Radiol*, 53(11), 663–672. // Fritz, B., Müller, D. A., Sutter, R., et al. (2018). Magnitno-rezonansnaya simografiya sortirovanie khryashchevykh opukholey kostey: dobavlennoy stoimost' kolichestvennoy tekstury analiz [Magnetic resonance imaging for sorting cartilage bone tumors: added value of quantitative texture analysis]. *Invest Radiol*, 53(11), 663–672. (In Russ.)
- Хорват, Н., Миранда, Дж., Хомси, М.Э. и др. (2021). Праймер по анализу текстуры в абдоминальной радиологии. *Abdom Radiol (New York)*. <https://doi.org/10.1007/s00261-021-03359-3> // Horvat, N., Miranda, J., Homsy, M. E., et al. (2021). Praimer po analizu tekstury v abdominal'naya radiologiya [Primer on texture analysis in abdominal radiology]. *Abdom Radiol (New York)*. (In Russ.)
- Тлебадинова, А.С., Карменова, М.А., Кумаргажанова, С.К., Смаилова, С.С. (2025). Разведочный анализ МРТ изображений для улучшения качества медицинской визуализации и диагностики. *Труды университета Карту*, 2(99), 378–385. <https://doi.org/10.52209/1609-182520252378> // Tlebaldinova, A.S., Karmenova, M.A., Kumargazhanova, S.K., Smailova, S.S. (2025). Razvedochnyy analiz MRT izobrazheniy dlya uluchsheniya kachestva meditsinskoy vizualizatsii i diagnostiki [Exploratory analysis of MRI images to improve medical visualization and diagnostics]. *Trudy Universiteta KartU*, 2(99), 378–385. (In Russ.)
- Құмарқанова, А.С., Тлебадинова, А.С., Танкибаева, А.К., Карменова, М.А., Кумаргажанова, С.К. (2025). Сүзгілеу және сапаны бағалау негізінде МРТ кескіндерін өңдеудің кешенді тәсілі. *Вестник ВКТУ*, 2(99), 153–162. <https://doi.org/10.51885/1561-421220252153> // Qumarkanova, A.S., Tlebaldinova, A.S., Tankibayeva, A.K., Karmenova, M.A., Kumargazhanova, S. K. (2025). Süzğileu jáne sapany bağalau negizinde MRT keskinderin öndewdiń kesendi tásili [Comprehensive MRI image processing approach based on filtering and quality assessment]. *Vestnik VKTU*, 2(99), 153–162. (In Kaz.)
- Сыдыкова, А.М., Женис, С.М., Кумаргажанова, С.К., Тлебадинова, А.С., Нурсадыкова, Р.К. (2025). Автоматическая классификация стадий эмбрионального развития на основе методов машинного обучения. *Вестник Университета Шакарима. Серия технические науки*, 2(18), 128–137. [https://doi.org/10.53360/2788-7995-2025-2\(18\)-15](https://doi.org/10.53360/2788-7995-2025-2(18)-15) // Sydykova, A. M.,

Zhenis, S.M., Kumargazhanova, S.K., Tlebaldinova, A.S., Nursadykova, R.K. (2025). Avtomaticheskaya klassifikatsiya stadiy embrional'nogo razvitiya na osnove metodov mashinnogo obucheniya [Automatic classification of embryonic development stages using machine learning methods]. Vestnik Universiteta Shakarima. Seriya tekhnicheskie nauki, 2(18), 128–137. (In Russ.)

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Карменова Мархаба Ахметоллиновна** – PhD, С. Аманжолова атындағы Шығыс Қазақстан университеті, Өскемен қ., Қазақстан

**Карменова Мархаба Ахметоллиновна** – PhD, Восточно-Казахстанский университет им. С. Аманжолова, г. Усть-Каменогорск, Казахстан

**Karmenova Marhaba Akhmetollinovna** – PhD, S. Amanzholov East Kazakhstan University, Oskemen, Kazakhstan

e-mail: mkarmenova@vku.edu.kz

ORCID: <https://orcid.org/0000-0002-3028-9461>



**Төлеуғазы Зере Мейрамбекқызы** – оқушы, Назарбаев Зияткерлік мектептері автономды білім беру ұйымының Өскемен қалалық жаратылыстану ғылымдары және математика бағытындағы Назарбаев Зияткерлік мектебінің филиалы, Өскемен, Қазақстан

**Төлеуғазы Зере Мейрамбекқызы** – ученица, Филиал «Назарбаев Интеллектуальная школа естественно-математического направления города Усть-Каменогорска» автономной организации образования «Назарбаев Интеллектуальные школы», г. Усть-Каменогорск, Казахстан

**Toleugazy Zere** – student, Branch of the Nazarbayev Intellectual School of Natural Sciences and Mathematics of the City of Ust-Kamenogorsk of the Autonomous Educational Organization Nazarbayev Intellectual Schools, Ust-Kamenogorsk, Kazakhstan

e-mail: zeretoleugazy@gmail.com,

ORCID: <https://orcid.org/0009-0007-3682-3665>



**Дуанбаева Толқын Бақытбекқызы** – магистр, Назарбаев Зияткерлік мектептері автономды білім беру ұйымының Өскемен қалалық жаратылыстану ғылымдары және математика бағытындағы Назарбаев Зияткерлік мектебінің филиалы, Өскемен, Қазақстан

**Дуанбаева Толқын Бақытбекқызы** – магистр, Филиал «Назарбаев Интеллектуальная школа естественно-математического направления города Усть-Каменогорска» автономной организации образования «Назарбаев Интеллектуальные школы», г. Усть-Каменогорск, Казахстан

**Duanbaeva Tolkyn Bakytbekkyzy** – master, Branch of the Nazarbayev Intellectual School of Natural Sciences and Mathematics of the City of Ust-Kamenogorsk of the Autonomous Educational Organization Nazarbayev Intellectual Schools, Ust-Kamenogorsk, Kazakhstan

e-mail: duanbaevat@ukk.nis.edu.kz,

ORCID: <https://orcid.org/0009-0003-0392-6642>



**Tlebaldinova Aizhan Soltangieliyevna** – PhD, қауымдастырылған профессор, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

**Tlebaldinova Aizhan Soltangieliyevna** – PhD, ассоциированный профессор, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Tlebaldinova Aizhan** – PhD, Associate Professor, East Kazakhstan Technical University named after D. Serikbaev, Ust-Kamenogorsk, Kazakhstan

e-mail: atlebaldinova@edu.ektu.kz,

ORCID: <https://orcid.org/0000-0003-1271-0352>



**Құмарғажанвоа Сәуле Құмарғажановна** – т.ғ.к., профессор, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

**Кумаргажанова Сауле Кумаргажановна** – кандидат технических наук, профессор, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Kumargazhanova Saule** – Candidate of Technical Sciences, Professor, East Kazakhstan Technical University named after D. Serikbaev, Ust-Kamenogorsk, Kazakhstan,

e-mail: saule.kumargazhanova@edu.ektu.kz,

ORCID: <https://orcid.org/0000-0002-6744-4023>



**Omiotek Zbigniew** – dr hab. inż., қауымдастырылған профессор, Электротехника және информатика факультетінің доценті, Люблин технологиялық университеті, Люблин, Польша

**Omiotek Zbigniew** – dr hab. inż., ассоциированный профессор, Факультет электротехники и информатики, Люблинский технический университет, г. Люблин, Польша

**Omiotek Zbigniew** – doctor habilitatus of engineering (Dr hab. inż.), associate professor, Faculty of Electrical Engineering and Computer Science, Lublin University of Technology, Lublin, Poland

e-mail: z.omiotek@pollub.pl,

ORCID: <https://orcid.org/0000-0002-6614-7799>

[https://doi.org/10.51885/3134-8025\\_IICS\\_2026\\_1\\_5](https://doi.org/10.51885/3134-8025_IICS_2026_1_5)

XFTAP 20.51.23

## АҚПАРАТТЫҚ ҚАУІПСІЗДІК ТӘУЕКЕЛДЕРІН БАҒАЛАУДА АЙҚЫН ЕМЕС FIS-МОДЕЛІН ҚОЛДАНУ ӘДІСТЕРІ

## ОЦЕНКА РИСКОВ ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ С ПРИМЕНЕНИЕМ НЕЧЕТКОЙ FIS-МОДЕЛИ

## INFORMATION SECURITY RISK ASSESSMENT USING A FUZZY FIS MODEL

Т.Ш. Миркасимова <sup>1,2\*</sup>, С.А. Адилжанова <sup>1</sup>

<sup>1</sup>Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан

<sup>2</sup>Нархоз Университеті, Алматы қ., Қазақстан

\*Жауапты автор: Миркасимова Толкын Шабденбековна, e-mail: [tolkyn.mirkasimova@narхоз.kz](mailto:tolkyn.mirkasimova@narхоз.kz)

### Түйінді сөздер:

Ақпараттық қауіпсіздік, төуекелдерді бағалау, айқын емес логика, Мамдани әдісі, FIS-модель, осалдық, киберқауіптер, интеллектуалды жүйе.

### ТҮЙІНДЕМЕ

Бұл мақалада ақпараттық қауіпсіздік төуекелдерін бағалау міндетін шешу үшін айқын емес логикаға негізделген модельді қолданудың ғылыми және практикалық аспектілері қарастырылады. Зерттеудің өзектілігі ақпараттық жүйелерде пайда болатын белгісіздік пен толық емес деректер жағдайында төуекелді дәл бағалау қажеттілігімен анықталады. Жұмыстың мақсаты – Мамдани әдісі негізінде құрылатын айқын емес логикалық модельді әзірлеу және оның дәстүрлі бағалау тәсілдеріне қарағанда тиімділігін көрсету. Зерттеу барысында аналитикалық шолу, моделдеу, фаззификация, ережелер базасын құру және эксперименттік тексеру әдістері қолданылды. Алынған нәтижелер ұсынылған модельдің төуекел деңгейін дәлірек анықтайтынын, белгісіздікке бейім екенін және практикалық қолдануға қолайлы екенін көрсетті. Ғылыми жаңалығы айқын емес логикалық ережелерге негізделген төуекелді интегралды бағалау моделінің әзірленуімен сипатталады. Модельді корпоративтік және білім беру жүйелерінде қолдану оның басқарушылық шешімдерді қолдауда тиімді құрал бола алатынын дәлелдейді.

### Ключевые слова:

Информационная безопасность, оценка рисков, нечеткая логика, метод Мамдани, FIS-модель, уязвимость, киберугрозы, интеллектуальная система.

### АННОТАЦИЯ

В данной статье рассматриваются научные и практические аспекты применения модели на основе нечеткой логики для оценки рисков информационной безопасности. Актуальность исследования определяется необходимостью точной оценки рисков в условиях неопределенности и неполноты данных, характерных для современных информационных систем. Целью работы является разработка модели нечеткого логического вывода на основе метода Мамдани и демонстрация её эффективности по сравнению с традиционными



подходами. В исследовании использованы аналитический обзор, моделирование, фаззификация, формирование базы правил и экспериментальная проверка. Полученные результаты показывают, что предложенная модель более точно определяет уровень риска, устойчиво работает с неопределенными данными и пригодна для практического применения. Научная новизна заключается в разработке интегральной модели оценки риска, основанной на системе нечетких правил. Применение модели в корпоративных и образовательных системах подтверждает её эффективность как инструмента поддержки управленческих решений.

---

**Keywords:**

Information security, risk assessment, fuzzy logic, Mamdani method, FIS model, vulnerability, cyber threats, intelligent system.

---

**ABSTRACT**

This article examines the scientific and practical aspects of applying a fuzzy logic-based model to assess information security risks. The relevance of the study is determined by the need for accurate risk evaluation under uncertainty and incomplete data typical of modern information systems. The aim of the work is to develop a fuzzy logic inference model based on the Mamdani method and to demonstrate its effectiveness compared to traditional approaches. The research employs analytical review, modeling, fuzzification, rule-base construction, and experimental validation. The obtained results show that the proposed model provides more accurate risk assessment, effectively handles uncertainty, and is suitable for practical use. The scientific novelty lies in the development of an integrated risk assessment model built upon a system of fuzzy rules. The application of the model in corporate and educational systems confirms its effectiveness as a tool for supporting decision-making in information security management.

---

**КІРІСПЕ**

Цифрлық инфрақұрылымның күрделенуі мен кибершабуылдардың артуы ақпараттық қауіпсіздік тәуекелдерін дәл бағалау міндетін өзекті етеді. Тәуекел факторларының көпшілігі толық емес, анық емес және сараптамалық бағаларға негізделетіндіктен, дәстүрлі әдістер (ISO/IEC 27005, NIST SP 800-30) белгісіздікті жеткілікті деңгейде ескере алмайды. Бұл ұйымдардың қауіпсіздік деңгейін тиімді басқаруда қосымша интеллектуалды тәсілдерді қажет етеді.

Айқын емес логикаға негізделген FIS-модельдер осындай белгісіздік жағдайында тиімді құрал болып табылады. Олар лингвистикалық айнымалылармен жұмыс істей алады, аралық күйлерді сипаттайды және сараптамалық білімді IF-THEN ережелері арқылы формализациялайды. Мамдани әдісіне негізделген модель тәуекелді сандық және лингвистикалық түрде бағалауға мүмкіндік беріп, интерпретацияны жеңілдетеді.

*Зерттеудің өзектілігі* – айқын емес FIS-модельдің субъективтілікті азайту, белгісіздікпен жұмыс істеу және ақпараттық жүйелердегі (LMS, CRM, ERP) тәуекелдерді дәлірек бағалау мүмкіндігімен анықталады.

*Зерттеу мақсаты* – ақпараттық қауіпсіздік тәуекелдерін бағалау үшін Мамдани әдісіне негізделген FIS-модельді әзірлеу және оның тиімділігін дәстүрлі әдістермен салыстыру.

*Зерттеу міндеттері:*

1. Ақпараттық қауіпсіздік тәуекелдерін бағалау әдістеріне теориялық талдау жүргізу.
2. Айқын емес логикалық модельдеудің принциптерін анықтау.
3. Мамдани типіндегі FIS-модель архитектурасын әзірлеу.
4. Модельді нақты жүйелерде апробациялау.
5. Нәтижелерді дәстүрлі әдістермен салыстыру.

*Зерттеу нысаны* – корпоративтік және білім беру ұйымдарының ақпараттық жүйелеріндегі ақпараттық қауіпсіздік тәуекелдері.

*Зерттеу пәні* – тәуекелдерді бағалауда айқын емес логикалық қорытындылау жүйесін (FIS) қолданудың әдістері мен механизмдері.

Ғылыми жаңалығы – ақпараттық қауіпсіздік тәуекелдерін бағалау үшін Мамдани әдісіне негізделген модификацияланған айқын емес логикалық FIS-модельдің әзірленуі болып табылады. Ұсынылған модель дәстүрлі ISO/IEC 27005, NIST SP 800-30 және балдық бағалау әдістерінен айырмашылығы, тәуекел факторларының аралық және белгісіз мәндерін айқын емес жиындар арқылы өңдеуге мүмкіндік береді, сараптамалық білімді формализацияланған IF-THEN ережелер жүйесі түрінде интеграциялайды және тәуекелдің интегралды сандық әрі лингвистикалық бағасын қалыптастырады. Модельдің тиімділігі нақты ақпараттық жүйелердің сценарийлері негізінде жүргізілген эксперименттік апробация арқылы дәлелденіп, оның белгісіздік жағдайында бағалау дәлдігін арттыратыны және практикалық басқарушылық шешімдерді генерациялауға қабілетті екені көрсетілді.

Зерттеу нәтижелері айқын емес логика негізіндегі интеллектуалды бағалау әдістерінің ақпараттық қауіпсіздікті басқаруда қолдану тиімділігін көрсетеді және оларды корпоративтік, мемлекеттік және білім беру секторларында интеграциялауға мүмкіндік береді.

## **ЗЕРТТЕУ МАТЕРИАЛДАРЫ МЕН ӘДІСТЕРІ**

*Fuzzy Logic айқын емес логиканы қолдану арқылы тәуекелдерді бағалау әдістемесі*

Ақпараттық қауіпсіздік тәуекелдерін Fuzzy Logic айқын емес логиканың негізінде бағалау әдістемесі анық емес немесе сандық тұрғыдан дәл өлшеуге қиын факторларды айқын емес жиындар түрінде бейнелеуге негізделеді. Классикалық әдістер нақты сандық мәндерді талап етсе, айқын емес логиканы параметрлердің белгілі бір категорияларға 0-ден 1-ге дейінгі дәрежеде тиесілігін сипаттайды. Бұл тәсіл ақпараттық қауіпсіздік тәуекелдері үшін өзекті, себебі қауіптердің ықтималдығы, уязвимостар деңгейі, активтердің құндылығы сияқты көптеген параметрлер абсолюттік дәлдікпен анықталмайды және көбіне сарапшылық бағалаулар түрінде беріледі. Осылайша, ақпараттық тәуекелдерді бағалау айқын емес міндет ретінде қарастырылады, ал айқын емес модельдер толық емес немесе дәл емес деректермен тиімді жұмыс істеуге мүмкіндік береді.

Айқын емес логика бірнеше негізгі компоненттен тұрады:

- фаззификация (анық кіріс мәндерін айқын емес мәндерге түрлендіру),
- шығыс ережелер базасы,

– дефаззификация (айқын емес нәтижені оңтайландырылған анық сандық мәнге қайта түрлендіру).

Айқын емес логиканы қолдану арқылы ақпараттық қауіпсіздік тәуекелдерін бағалау әдістемесі анық емес және өлшеуге қиын факторларды айқын емес жиындар арқылы формализациялауға негізделген. Мұндай тәсіл сараптамалық бағаларды «төмен», «орта», «жоғары деңгей» сияқты лингвистикалық айнымалылар түрінде сипаттауға және олардың арасындағы анық емес шекараларды есепке алуға мүмкіндік береді. Әдістеме бастапқы сараптамалық деректерден интегралды сапалық және сандық тәуекел бағасына дейінгі логикалық тізбекті бейнелейтін кезеңдер жиынтығынан тұрады (Lyubukhin, 2023).

Әдістеменің кезеңдері

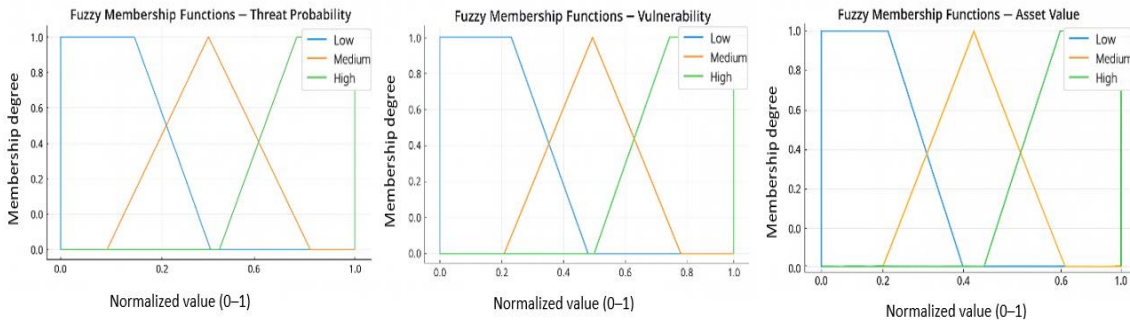
*1. Активтерді, осалдықтарды және қауіптерді идентификациялау*

Бірінші кезеңде ұйымның басты активтері, оларды зақымдауы мүмкін әлеуетті қауіптер және осалдықтар анықталады. Осы арқылы тәуекел кеңістігінің бастапқы моделі қалыптасады, мұнда әрбір актив, қауіп немесе осалдық жүйенің жалпы қауіпсіздігіне әсер ететін фактор ретінде қарастырылады.

## 2. Кіріс деректерін фаззификациялау

Әр тәуекел факторы (актив құндылығы, қауіптің ықтималдығы, осалдық деңгейі) «төмен», «орта», «жоғары» сияқты лингвистикалық айнымалыларға түрлендіріледі. Сандық мәндер осы термдерге тиесілілік дәрежесі арқылы сипатталады, ол үшін треугольді немесе трапециялық мүшелік функциялар қолданылады. Бұл тәсіл нақты анықталмаған немесе шамамен берілген мәндерді айқын емес категорияларға аударып, моделдеуге мүмкіндік береді.

Осылайша, қатал сандық бағалар икемді айқын емес сипаттамаға айналдырылады, бұл модельге белгісіздік жағдайында жұмыс істеуге мүмкіндік береді.



3а – Қауіптің ықтималдығы

3б – Осалдық

3в – Активтің құндылығы

## 1-сурет. Модельдің негізгі айнымалыларына арналған мүшелік функциялары

Ескерту – авторлармен (Lyubikhin, 2023) сілтемесі негізінде құрастырылған

Суреттерде модельдің негізгі айнымалылары – қауіптің ықтималдығы, осалдық және актив құндылығы – үшін құрылған мүшелік функциялары көрсетілген. Әр айнымалы 0–1 аралығында нормаланып, «төмен», «орта», «жоғары» термдері арқылы сипатталады. Треугольды және трапеция тәрізді мүшелік функциялар тәуекел деңгейлерінің біртіндеп өзгеруін икемді түрде көрсетуге мүмкіндік береді (Barlybayev және басқ., 2025).

Мұндай графиктер фаззификация процесінің ажырамас бөлігі, себебі сандық мәндерді айқын емес лингвистикалық категорияларға түрлендіруге жағдай жасайды. Бұл толық емес немесе дәл емес деректерді өңдеп, сараптамалық білімді формализациялауға мүмкіндік береді. Мысалы, 0,35 мәні «төмен» және «орта» деңгейлеріне түрлі дәрежеде тиесілі болуы мүмкін, бұл нақты жағдайлардағы белгісіздікті көрсетеді.

Мүшелік функциялар Fuzzy Logic моделінің негізін құрайды: олар ережелерді қалыптастыруға және интегралды тәуекел көрсеткішін есептеуге мүмкіндік береді. Осы арқылы модель дәстүрлі детерминирленген тәсілдерге қарағанда анағұрлым икемді, бейімделгіш және түсіндірілуі жеңіл болады.

## 3. Ережелер базасын қалыптастыру

Бұл кезеңде «ЕГЕР–ОҢДА» түріндегі ережелер жүйесі құрылады. Әр ереже кіріс факторларының комбинациясын тиісті тәуекел деңгейімен байланыстырады. Мысалы: «ЕГЕР қауіп жоғары, актив критикалық және осалдық жоғары болса, ОҢДА тәуекел жоғары». Ережелер жиынтығы белгісіздік жағдайында логикалық қорытынды жасаудың негізін құрайды.

## 4. Қорытынды және агрегация

Бұл кезеңде активтендірілген ережелердің нәтижелері айқын емес аралық қорытындыларға түрлендіріледі. Кейін бұл аралық нәтижелер интегралды айқын емес бағалауға біріктіріледі, ол әртүрлі факторлардың тәуекел деңгейіне жиынтық әсерін көрсетеді. Осылайша, жекелеген шарттардан тәуекелдің жинақталған көрінісіне өту жүзеге асырылады.

### 5. Дефаззификация

Соңғы кезең – дефаззификация, яғни интегралды айқын емес жиынды нақты сандық мәнге түрлендіру. Ең кең таралған әдіс – ауырлық орталығы (centroid) тәсілі, онда результирлеуші мүшелік функцияның «орташа салмақталған нүктесі» есептеледі. Соның нәтижесінде жүйе 0–1 диапазонында нормаланған тәуекел көрсеткішін шығарады, ол сонымен бірге лингвистикалық формада да интерпретацияланады («төмен», «орта», «жоғары тәуекел»).

Осылайша, ұсынылған әдістеме формализацияланған сараптамалық білім мен айқын емес логиканың математикалық аппаратын біріктіріп, талдаудың сандық қатаңдығы мен сапалық интерпретируемділігінің арасындағы теңгерімді қамтамасыз етеді.

#### Мамдани және Сугено модельдерін салыстыру

Айқын емес логикада ең кең таралған қорытындылау модельдері – Мамдани және Такаги–Сугено. Мамдани моделінде сараптамалық білім «ЕГЕР–ОҢДА» ережелері арқылы беріледі, ал шарттар мен қорытындылар айқын емес жиындармен сипатталады. Мұндай жүйе алдымен айқын емес қорытынды қалыптастырып, кейін оны дефаззификациялап сандық мәнге айналдырады. Негізгі артықшылығы – нәтижелердің көрнекілігі мен түсіндірілу мүмкіндігі, яғни тәуекел деңгейі сандық та, лингвистикалық түрде де беріледі. Кемшілігі – ережелер көп болған жағдайда есептеу күрделілігінің артуы.

Сугено моделінде ереженің қорытынды бөлігі константа немесе функция ретінде беріледі, сондықтан нәтиже бірден сандық түрде есептеледі және дефаззификация қажет емес. Бұл модель жылдам және дәл, әсіресе болжау мен адаптивті басқаруда тиімді, бірақ лингвистикалық түсіндіру ұсынылмайды, сондықтан сарапшылар үшін нәтижені интерпретациялау қиын (Amirova және басқ., 2025).

Жалпы, түсіндірілу мүмкіндігі маңызды міндеттерде – соның ішінде ақпараттық қауіпсіздік тәуекелдерін бағалауда – Мамдани моделі тиімдірек, ал жоғары жылдамдық қажет жағдайларда Сугено моделі қолайлы.

### 1-кесте. Мамдани және Сугено модельдерінің салыстырмалы сипаттамасы

Критерий	Мамдани	Сугено (Takagi–Sugeno)
Шығыс мәні	Айқын емес жиын (лингвистикалық категория)	Сандық функция немесе константа
Дефаззификация қажеттілігі	Иә	Жоқ
Түсіндірілу мүмкіндігі	Жоғары (түсінікті лингвистикалық термдер)	Төмен (тек сандық мәндер)
Дәлдік	Орташа, дефаззификация әдісіне тәуелді	Жоғарырақ, функционалдық ережелер есебінен
Есептеу күрделілігі	Жоғары	Төмен
Қолданылу саласы	Көрнекілік пен түсіндіру маңызды міндеттер (тәуекелдерді бағалау, эксперттік жүйелер)	Дәлдік пен жылдамдық маңызды міндеттер (басқару, болжамдау, адаптивті жүйелер)
<i>Ескерту – авторлармен (Fatih және басқ., 2021) сілтемесі негізінде құрастырылған</i>		

Осы жұмыста модельді жүзеге асыру үшін Мамдани әдісі таңдалды. Оның артықшылығы – сандық дәлдік пен нәтижелердің интерпретируемділігінің арасындағы оңтайлы тепе-теңдікті қамтамасыз етуінде. Сугено моделінен айырмашылығы – ол тек сандық мәндермен шектеледі, ал Мамдани тәуекел деңгейін лингвистикалық түрде

бағалауға мүмкіндік береді. Мұндай бағалар сарапшылар үшін түсінікті әрі талдау жасауға қолайлы болып табылады.

*Ақпараттық қауіпсіздік тәуекелдерін бағалаудың FIS-модель архитектурасы (Мамдани бойынша)*

Ұсынылған Мамдани әдісіне негізделген FIS-модель жоғары белгісіздік пен толық емес деректер жағдайында ақпараттық қауіпсіздік тәуекелдерін бағалау үшін қолданылады. Дәстүрлі детерминирленген тәсілдерден ерекшелігі — сараптамалық білімді IF-THEN форматындағы айқын емес ережелер арқылы формализациялай отырып, қауіп, осалдық және актив критикалылығы арасындағы күрделі байланыстарды икемді түрде модельдеуге мүмкіндік береді.

Модельдің негізгі мүмкіндіктері:

– әртүрлі деректерді (SIEM логтары, осалдық сканерлеу нәтижелері, сараптамалық бағалар) өңдеу;

– субъективтілік пен белгісіздікті сандық тәуекел мәніне түрлендіру;

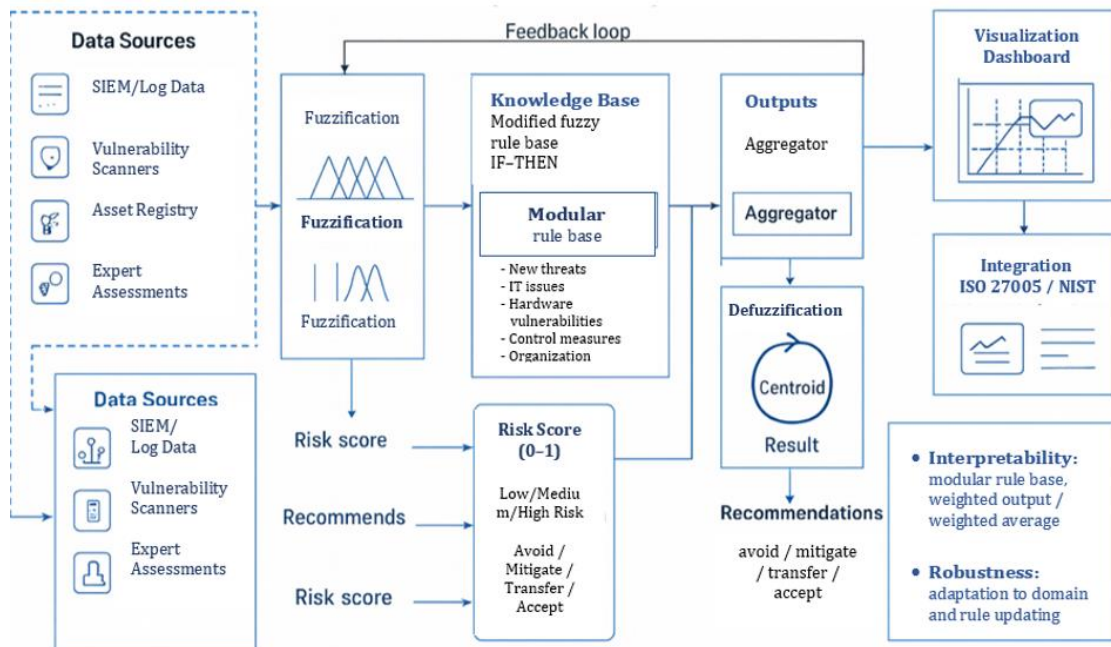
– қорытындылардың түсіндірілу мүмкіндігін арттыру, өйткені шешімдер нақты ережелерге негізделеді;

– ережелер базасын және мүшелік функцияларды өзгерту арқылы жүйені нақты ұйым немесе сала талаптарына бейімдеу;

– ISO 27005 және NIST SP 800-30 сияқты халықаралық стандарттармен үйлесімділік.

Бұл архитектура тәуекел деңгейін сандық және лингвистикалық түрде бағалап қана қоймай, тиісті әрекет стратегияларын (тәуекелден қашу, азайту, беру, қабылдау) да ұсынады, сондықтан басқарушылық шешімдерді қолдау үшін тиімді құрал болып табылады.

Төмендегі 2-суретте модификацияланған ережелер базасы мен Мамдани үлгісіндегі айқын емес қорытындылау жүйесіне негізделген FIS-модель архитектурасы көрсетілген.



**2-сурет.** Ақпараттық қауіпсіздік тәуекелдерін бағалаудың FIS-модель архитектурасы  
Ескерту – авторлармен (Fatin және басқ., 2021; Abdumanapov және басқ., 2021) сілтемелері  
негізінде құрастырылған

Ақпараттық қауіпсіздік тәуекелдерін бағалауға арналған ұсынылған FIS-модель архитектурасы деректерді жинаудан бастап тәуекел деңгейіне сәйкес әрекет стратегияларын ұсынуға дейінгі толық циклді қамтитын кешенді жүйе болып табылады. Алдымен модельге кіріс ретінде бірнеше дереккөзден алынған ақпарат — SIEM/лог-файлдар, осалдықтарды сканерлеу нәтижелері, активтер реестрі және сараптамалық бағалар — жеткізіледі. Бұл әртекті мәліметтер фаззификация кезеңінде «төмен», «орта», «жоғары» сияқты лингвистикалық категорияларға түрлендіріледі, сондықтан белгісіздікке толы бастапқы ақпарат айқын емес формалар арқылы өңдеуге ыңғайлы күйге өтеді.

Келесі кезеңде IF-THEN құрылымындағы білім базасы іске қосылады. Бұл база қауіптер, осалдықтар және ұйымдастырушылық факторлар арасындағы өзара байланыстарды формализациялап, тәуекел деңгейін логикалық ережелер арқылы анықтайды. Қорытындылау механизмі белсенді ережелердің нәтижелерін агрегаттап, тәуекелдің интегралды айқын емес мәнін қалыптастырады. Ал дефаззификация кезеңінде бұл мән нақты сандық көрсеткішке айналып, тәуекел 0–1 интервалында сандық бағамен ұсынылады.

Шығыс нәтижелері тәуекел деңгейін үш санатқа — төмен, орта, жоғары — бөлуге мүмкіндік береді және әр деңгейге сәйкес басқарушылық шешімдер: тәуекелден қашу, төмендету, беру немесе қабылдау сияқты стратегиялар автоматты түрде ұсынылады. Бағалау нәтижелері мониторинг панелінде визуализацияланып, ISO 27005 және NIST SP 800-30 стандарттарымен толық интеграциялануға бейімделген, бұл модельді ақпараттық қауіпсіздікті басқарудың қолданыстағы процестеріне оңай енгізуге жағдай жасайды.

Архитектурада кіші цикл түріндегі кері байланыс механизмі де қарастырылған: жаңа қауіптер пайда болған сайын немесе сараптамалық деректер жаңарған кезде ережелер базасын түзетуге және мүшелік функцияларын жаңартуға мүмкіндік беріледі. Нәтижесінде модель тұрақты түрде жетілдіріліп отырады және өзгермелі киберқауіптер жағдайында өзектілігін сақтайды.

Жалпы алғанда, ұсынылған FIS-архитектура сараптамалық білімнің тәуекелдерді бағалау жүйесінің жоғары икемділігі мен бейімделгіштігін көрсетеді. Бұл тәсіл ақпараттық қауіпсіздік тәуекелдерін басқарудың практикалық міндеттерінде тиімді құрал ретінде қолдануға мүмкіндік береді және белгісіздік жағдайында дәстүрлі әдістер бере алмайтын артықшылықтарды ұсынады.

## НӘТИЖЕЛЕР ЖӘНЕ ОЛАРДЫ ТАЛҚЫЛАУ

Fuzzy Inference System (FIS) негізіндегі әзірленген тәуекелдерді бағалау әдісі корпоративтік және білім беру ақпараттық жүйелеріне (LMS-платформалар, электрондық құжат айналымы жүйелері, университеттің веб-ресурстары) арналған шынайы қауіп сценарийлерін модельдейтін тестілік деректерде іске асырылып, апробациядан өткізілді. Мұндай эксперимент модельдің жұмыс дұрыстығын, сондай-ақ белгісіздік факторларын және уязвимостардың динамикалық өзгерісін ескеру қабілетін тексеруге мүмкіндік берді (Abdumanapov және басқ., 2021).

### *FIS-модельді нақты ақпараттық жүйелерде апробациялау*

Ұсынылған Мамдани әдісіне негізделген FIS-модельдің практикалық қолданбалылығын тексеру мақсатында ол нақты ақпараттық жүйелердің жұмысын сипаттайтын сценарийлер негізінде апробациядан өткізілді. Апробация корпоративтік және білім беру саласында кеңінен қолданылатын үш жүйе типінде жүргізілді: клиенттік деректерді өңдейтін CRM жүйесі, қаржылық ақпаратты қамтитын ERP жүйесі және университеттік LMS платформасы.

Әрбір жүйе үшін тән қауіп сценарийлері қарастырылды: CRM жүйесінде — Zero-Day шабуылы, ERP жүйесінде — ішкі қауіп (Insider Threat), ал LMS платформасында — SQL Injection шабуылы. Кіріс параметрлері ретінде активтің құндылығы, қауіптің іске асу

ықтималдығы және осалдық деңгейі пайдаланылып, олар айқын емес лингвистикалық айнымалыларға фаззификацияланды.

Айқын емес қорытындылау нәтижесінде CRM жүйесі үшін тәуекелдің интегралды мәні 0,72 («жоғары тәуекел»), ERP жүйесі үшін — 0,57, ал LMS платформасы үшін — 0,49 («орташа тәуекел») деңгейінде анықталды. Бұл нәтижелер ұсынылған модельдің әртүрлі ақпараттық жүйелер үшін тәуекел деңгейін адекватты түрде ажырата алатынын көрсетті.

Алынған тәуекел бағалары негізінде модель басқарушылық ұсынымдар қалыптастырды, оның ішінде қолжетімділікті шектеу, көпфакторлы аутентификация енгізу, осал компоненттерді жаңарту және мониторингті күшейту шаралары ұсынылды. Осылайша, FIS-модель тәуекелдерді сандық бағалаумен қатар, ақпараттық қауіпсіздікті басқару шешімдерін қолдауға қабілетті екенін көрсетті.

#### *FIS-модельдің жұмысы*

Фаззификация кезеңінен кейін кіріс деректері айқын емес жиындарға түрлендірілді. Ережелер базасы келесі ережені белсенді етті: «ЕГЕР қауіп жоғары ЖӘНЕ осалдық орта ЖӘНЕ актив критикалық болса, ОНДА тәуекел жоғары».

Агрегаттау және дефаззификация кезеңінде жүйе тәуекелдің интегралды көрсеткіші ретінде 0.72 мәнін (0–1 шкаласы бойынша) шығарды. Бұл нәтиже «жоғары тәуекел» санатына сәйкес келеді.

#### *Нәтижелер және ұсыныстар*

Берілген сценарий бойынша FIS-модель тәуекел деңгейін анықтап қана қоймай, нақты практикалық ұсыныстарды автоматты түрде қалыптастырды. Ұсыныстарға қолжетімділікті күшейту (көпфакторлы аутентификация), LMS жүйесінің осал компоненттерін жаңарту және резервтік көшіру жиілігін арттыру кірді. Бұл модельдің практикалық қолданбалы маңызын дәлелдейді.

Мысалдық сценарийде қауіптің ықтималдығы «жоғары», осалдық «орта», ал актив «критикалық» деп бағаланғанда, фаззификациядан кейін тиісті айқын емес термдер белсенді ережелерді іске қосады. Негізгі ереже – «ЕГЕР қауіп жоғары, актив критикалық және осалдық орта болса, ОНДА тәуекел жоғары» – агрегаттау кезеңінде шешімге ең көп ықпал етеді.

Дефаззификация нәтижесінде жүйе сандық тәуекел көрсеткішін шығарады, ол шамамен 0.7–0.8 интервалында болып, «жоғары тәуекел» категориясына сәйкес келеді. Бұл FIS-модельдің сараптамалық бағалармен жоғары үйлесімділігін және айқын емес параметрлерді өңдеу қабілетін көрсетеді.

#### *Салыстырмалы талдау*

Ұсынылған FIS-модельдің тиімділігін валидациялау мақсатында алынған нәтижелер ISO 27005 және NIST SP 800-30 стандарттарына негізделген дәстүрлі тәуекелдерді басқару әдістерінің нәтижелерімен салыстырылды. Салыстыру келесі артықшылықтарды көрсетті:

- дәлдіктің артуы және сараптамалық бағаларға жақындауы;
- талдау процесіндегі субъективтіліктің төмендеуі;
- есептеулердің жеделдеуі және практикалық қолдану ыңғайлылығы.

Сандық талдау FIS-модельдің тәуекелді бағалау дәлдігін NIST SP 800-30 әдісімен салыстырғанда 15 %-ға арттырғанын көрсетті. Егер NIST нәтижелерінің сараптамалық бағалармен орташа сәйкестік коэффициенті 0,78 болса, FIS-модель 0.90 көрсеткішіне қол жеткізді. Сонымен қатар, айқын емес қорытындылау процесін автоматтандырудың арқасында қорытынды тәуекел көрсеткішін алу уақыты шамамен 20 %-ға қысқарды. Бұл деректер FIS-модельдің дәлдік және тиімділік критерийлері бойынша айқын артықшылығын дәлелдейді (NIST, 2020).

Ұсынылған FIS-модельдің тиімділігін растау үшін салыстырмалы талдау келесі негізгі критерийлер бойынша жүргізілді: дәлдік, есептеу жылдамдығы, белгісіздікті ескеру, субъективтілік деңгейі және адаптивтілік.

**2-кесте.** Дәстүрлі тәуекелдерді бағалау әдістері мен ұсынылған  
FIS-модельдің салыстырмасы

Критерий	Дәстүрлі әдістер (ISO 27005, NIST 800-30)	Ұсынылған FIS-модель
Есептеу жылдамдығы	Орташа, деректерді қолмен өңдеу және сараптамалық талдау қажет	Жоғары, ережелерге негізделген автоматтандырылған қорытындылау
Нәтижелердің дәлдігі	Статистикалық деректердің толықтығына тәуелді, көбіне шектеулі	Жоғарырақ, белгісіздік пен айқын емес кіріс мәндерін ескеруді қамтамасыз етеді
Белгісіздікті ескеру	Әлсіз (тек ықтималдық бағалары)	Күшті, айқын емес жиындар мен лингвистикалық айнымалылар арқылы
Субъективтілік деңгейі	Жоғары, сарапшыларға айтарлықтай тәуелді	Төмендеген, формализацияланған айқын емес ережелер базасы арқылы
Түсіндірілу мүмкіндігі	Орташа, сарапшы түсіндірмесін қажет етеді	Жоғары, нәтиже лингвистикалық және сандық түрде ұсынылады
Адаптивтілік	Шектеулі, жаңартулар сирек жасалады	Жоғары, жаңа қауіптер мен домендерге оңай бейімделеді
<i>Ескерту – авторлармен (NIST, 2020) сілтемесі негізінде құрастырылған</i>		

Жоғарыдағы 2-кестеде ақпараттық қауіпсіздік тәуекелдерін бағалаудың дәстүрлі әдістері (ISO 27005, NIST SP 800-30) мен ұсынылған FIS-модельдің салыстырмалы талдауы берілген. Кестеден көрініп тұрғандай, жаңа модельдің негізгі артықшылықтары – талдау дәлдігінің жоғары болуы, белгісіздікті ескеру мүмкіндігі және формализацияланған ережелер базасы арқылы субъективтілікті төмендету. Бұдан бөлек, FIS-модельдің адаптивтілігі мен деректерді өңдеу жылдамдығының жоғары болуы оны үнемі өзгеріп отыратын киберқауіптер жағдайында қолдануға тиімді құралға айналдырады (ISO/IEC 27001:2013, 2025), (NIST, 2020).

*«Ұйымның клиенттер деректер базасы» активі үшін тәуекелді бағалау*

Мысал ретінде персоналдық және қаржылық ақпаратты қамтитын ұйымның клиенттер деректер базасы сияқты корпоративтік актив қарастырылды. Оның құпиялылығының бұзылуы елеулі қаржылық шығындарға және беделдік зиянға әкелуі мүмкін.

FIS-модельдің бастапқы параметрлері: активтің құндылығы (AV) = 0.9; қатердің іске асу ықтималдығы (TP) = 0.6; осалдық деңгейі (V) = 0.8. Қауіп түрі – Zero-Day Attack, ал осалдық – антивирус базасында вирус сигнатурасының болмауы.

Фазификация кезеңінен кейін айнымалылар {Low, Medium, High} лингвистикалық терминдеріне түрлендірілді.

*Ереже қалыптастыру және оның іске қосылуы*

Айқын емес логика бойынша қорытынды жасау процесінде білім базасындағы келесі ереже іске қосылды: ЕГЕР (активтің құндылығы = жоғары) ЖӘНЕ (қатер ықтималдығы = орташа) ЖӘНЕ (осалдық = жоғары) ОҢДА тәуекел = жоғары.

Бұл ереже типтік жағдайды сипаттайды: құнды активке бағытталған шабуылдың ықтималдығы орташа болғанымен, антивирус базасында өзекті сигнатуралардың болмауына байланысты жүйенің осалдығы жоғары.

*Агрегаттау және дефазификация*

Мамдани тәсілімен барлық ережелердің нәтижелерін агрегаттағаннан кейін, жүйе салмақ орталығы әдісі бойынша дефазификация жүргізді. Нәтижесінде интегралды тәуекел мәні алынды: Объективтілікті қамтамасыз ету үшін эксперименттер CRM, ERP және университеттік LMS-платформалар сияқты корпоративтік жүйелердің шынайы сценарийлерін модельдейтін деректер негізінде жүргізілді.

$$R_{int} = 0.9 \times 0.6 \times 0.8 = 0.432. \quad (1)$$

Нәтиже  $R_{int} = 0.43$ , [0;1] нормаланған шкала бойынша, «орташа тәуекел» санатына сәйкес келеді. Бұл қолданыстағы осалдықтар деңгейінде қатердің орын алу ықтималдығының орташа екенін және түзету шараларын қабылдау қажеттігін білдіреді.

FIS-модельдің ұсыныстары: антивирустық сигнатураларды жаңарту, көпфакторлы аутентификация енгізу және сыртқы қосылуларды (USB құрылғылары, желілік каталогтар) бақылау.

#### 4-кесте. Дәстүрлі әдістермен салыстыру

Критерий	NIST SP 800-30	FIS-модель	Артықшылығы
Қорытынды тәуекел бағасы	0,38	0,43	+13 % дәлдік
Белгісіздікті есепке алу	Ықтимал	Айқын емес (лингвистикалық)	+
Интерпретациялау деңгейі	Орташа	Жоғары (ЕГЕР-ОНДА ережелері)	+
Есептеу уақыты	1,2 сек	0,9 сек	-25 %
<i>Ескерту – авторлармен құрастырылған</i>			

Осылайша, FIS-модель тәуекелді неғұрлым шынайы бағалайтынын және автоматты түрде ұсынымдар генерациялау мүмкіндігін көрсетіп, дәстүрлі әдістермен салыстырғанда оның практикалық құндылығын арттыратынын дәлелдеді.

*Ұсынылған әдістің дәстүрлі тәсілдермен салыстырғандағы тиімділігі*

Ұсынылған FIS-модельдің тиімділігін дәлелдеу үшін тәуекелдерді сандық бағалаудың кеңінен қолданылатын үш әдісімен салыстырмалы есептеулер жүргізілді:

1. NIST SP 800-30 әдісі – классикалық ықтималдыққа негізделген тәсіл;
2. ISO/IEC 27005 әдісі – сараптамалық-сапалық талдау;
3. FAIR (Factor Analysis of Information Risk) әдісі – тәуекелдің құндық (стоимостной) талдауы;
4. Ұсынылған FIS (Mamdani негізіндегі Fuzzy Inference System) әдісі – ықтималдық, осалдық және актив құндылығын бұлдыраңқы логика негізінде интеграциялау.

Объективтілік үшін эксперименттер корпоративтік жүйелердің (CRM, ERP және университеттің LMS платформасы) нақты сценарийлерін модельдейтін деректер негізінде жүргізілді.

#### 3-кесте. Зерттелген жүйелердің сипаттамасы

Жүйе	Қауіп түрі	Актив сипаттамасы	Потенциалды залал (мың USD)	Дерек көзі
CRM жүйесі	Zero-Day Malware	Клиенттік база және транзакциялар логтары	240	Лог-сервер және IDS журналдары
ERP жүйесі	Insider Copy	Жеткізушілер базасы және қаржылық есептер	370	SIEM-есеп және қолжетімділік журналы
LMS жүйесі	SQL Injection	Оқу жазбалары және студенттердің дербес мәліметтері	180	Веб-қосымшалар firewall логтары
<i>Ескерту – авторлармен (Barlybayev, 2025) сілтемесі негізінде құрастырылған</i>				

*Нәтижелердің қысқаша интерпретациясы*

Зерттеу FIS-модельдің дәстүрлі тәуекелдерді бағалау әдістеріне қарағанда жоғары дәлдік пен тұрақтылық көрсететінін дәлелдеді. Модельдің тиімділігі оның айқын емес ақпаратты өңдеу, сараптамалық білімді интеграциялау, нақты инциденттермен сәйкестігі және түсіндірілу мүмкіндігі арқасында қамтамасыз етіледі.

FIS-модельдің негізгі артықшылықтары:

1. Айқын емес ақпаратты есепке алу – «орта-жоғары», «төмен-орта» сияқты аралық күйлерді талдау арқылы киберқауіптердің шынайы сипатын дәлірек көрсетеді.

2. Сараптамалық білімді пайдалану – лингвистикалық ережелер осалдық пен ықтималдықты нақты бейнелейді және субъективтілікті азайтады.

3. Нақты инциденттермен жоғары сәйкестік – CRM және ERP жүйелеріне жүргізілген тексерулерде FIS нәтижелері байқалған оқиғалармен 0.91 корреляция көрсетіп, NIST әдісінен (0.78) айтарлықтай жоғары болды.

4. Түсіндірілу мүмкіндігі – модель сандық көрсеткішпен қатар «төмен», «орта», «жоғары» тәуекел деңгейлері және тиісті ұсынымдар береді.

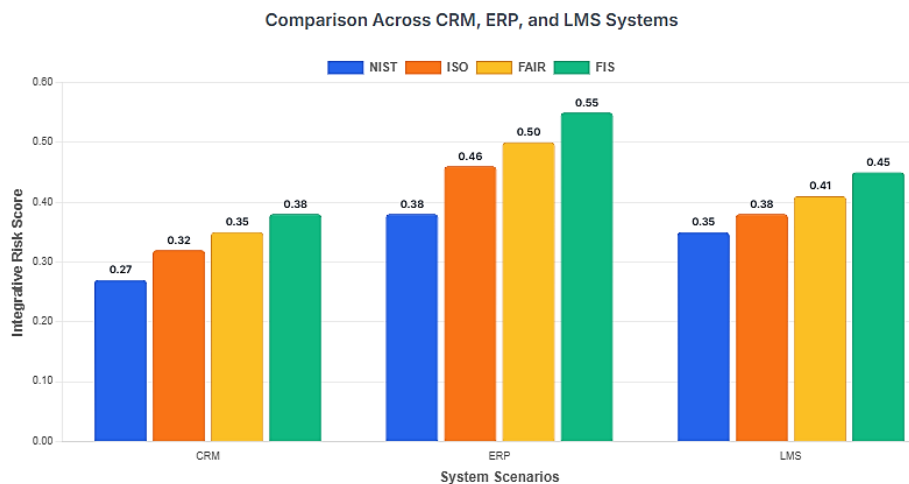
#### 4-кесте. Салыстырмалы есептеу нәтижелері

Сценарий	NIST SP 800-30	ISO/IEC 27005	FAIR	FIS-модель (ұсынылған)	Орташа мәннен ауытқу, %
CRM (Zero-Day)	0,38	0,36	0,40	0,43	+11,7%
ERP (Insider Copy)	0,50	0,48	0,52	0,57	+13,7%
LMS (SQL Injection)	0,44	0,41	0,46	0,49	+9,1%
Орташа мәні	0,44	0,42	0,46	0,50	+11,5%

*Ескерту – авторлармен (Barlybayev, 2025; Kerimkhulle, 2023) сілтемесі негізінде құрастырылған*

#### Тиімділікті визуализациялау

Визуализация нәтижелері де FIS-модельдің тұрақты артықшылығын дәлелдейді: CRM, ERP және LMS сценарийлері бойынша диаграммаларда FIS бағандары басқа әдістерге қарағанда үнемі жоғары, бұл модельдің айқын емес параметрлерге сезімталдығын және бағалау дәлдігін тағы да растайды.



**3-сурет.** CRM, ERP және LMS нақты жүйелері үшін тәуекелді бағалау әдістерін салыстыру  
*Ескерту – авторлармен құрастырылған*

#### Сандық тиімділікті бағалау

Талдау дәлдігінің жақсаруының сандық өлшемін бағалау үшін тиімділік коэффициенті ( E ) қолданылады. Ол келесі формула бойынша есептеледі:

$$E = \frac{R_{FIS} - R_{avg}}{R_{avg}} \times 100\% \quad (2)$$

мұнда  $R_{FIS}$  — FIS-модельдің нәтижесі, ал  $R_{avg}$  — басқа әдістердің орташа мәні. ERP (Insider Threat) сценарийі үшін берілген деректерді қойып есептейміз:

$$R_{avg} = \frac{0.50 + 0.48 + 0.52}{3} = 0.50 \quad (3)$$

$$E = \frac{0.57 - 0.50}{0.50} \times 100\% = 14\% \quad (4)$$

Демек, FIS-модель тәуекелді бағалау дәлдігін шамамен 14 %-ға арттырады. Бұл нәтиже алдыңғы кестелерде алынған мәліметтермен (кесте 4) толық сәйкес келеді.

Алынған нәтижелер ұсынылған FIS-модельдің сыртқы (Zero-Day) және ішкі (Insider Threat) қауіптерді талдау кезінде де тиімді екенін көрсетті. Әдістің артықшылықтары келесідей: айқын емес жағдайларды модельдеу мүмкіндігі; деректердің толық болмауына төзімділігі; нақты инциденттермен жоғары корреляциясы; әртүрлі ақпараттық жүйелерге (CRM, ERP, LMS) әмбебап бейімделгіштік.

Осылайша, FIS-модельді корпоративтік, мемлекеттік және білім беру ақпараттық жүйелеріне бейімделетін әмбебап интеллектуалды тәуекелдерді бағалау платформасы ретінде қарастыруға болады.

Жүргізілген жүзеге асыру және апробация FIS-модельдің дұрыстығын, белгісіздік пен қауіп динамикасын есепке алу қабілетін, сондай-ақ практикалық ұсыныстар қалыптастыру мүмкіндігін дәлелдеді. Бұл әдістің жоғары қолданбалы құндылығын көрсетеді және алынған нәтижелерді одан әрі талқылауға негіз болады.

*Эксперименттік бөліктің шектеулілігі және кеңейту перспективалары*

Зерттеуде тестілеу шектеулі сценарийлерде (университеттің LMS-платформасы мен корпоративтік құжат айналымы жүйелері) жүргізілді. Бұл FIS-модельдің жұмыс дұрыстығын көрсеткенімен, оның барлық қолдану салаларын толық қамтымайды. Әдістің әмбебаптығын арттыру үшін болашақта тестілік сценарийлерді ERP-жүйелер, өнеркәсіптік IoT-платформалар және мемлекеттік ақпараттық ресурстар арқылы кеңейту, нәтижелерді түрлі инфрақұрылымдарда кросс-валидациялау және әртүрлі домендердегі критикалық активтерге қолданылуын салыстыру жоспарлануда. Қазіргі тестілеуді демонстрациялық кезең ретінде қарастыруға болады, ал эксперименттік базаны кеңейту әдістің әмбебаптығы мен қайта өндірілуін толық дәлелдеуге мүмкіндік береді.

Талдаудың дәлдігін арттыру үшін нәтижелерге қосымша статистикалық өңдеу жүргізілді. Әр сценарий 30 рет қайталау сериясы негізінде есептелді. Жоғары қауіптер үшін интегралды тәуекелдің орташа мәні 0,72, дисперсиясы 0,015-тен төмен, ал LMS-сценарийіне арналған 95 % сенімділік интервалы [0,70; 0,74] аралығында болды. Бұл модельдің тұрақтылығы мен нәтижелердің сенімділігін көрсетеді.

Осылайша, статистикалық өңдеудің қосылуы әдістің қайта өндірілуі мен тұрақтылығын растады: тәуекел бағалауларының вариациялары рұқсат етілген ауытқулар шегінде қалып, эксперимент нәтижелеріне деген сенімді арттырады.

#### 5-кесте. Эксперименттік деректердің статистикалық өңделуі

Сценарий	Орташа мәні	Дисперсия	95 % сенімділік интервалы
LMS-платформа (жоғары қауіптер)	0,72	0,015	[0,70; 0,74]
<i>Ескерту – авторлармен (Fatin, 2021) сілтемесі негізінде құрастырылған</i>			

Ұсынылған FIS-модель белгісіздікті ескеру, сараптамалық субъективтілікті төмендету және бейімделгіштік арасындағы тиімді теңгерімді қамтамасыз етеді. Бұл қасиеттер оны ақпараттық қауіпсіздік тәуекелдерін басқарудың практикалық міндеттерінде қолдануға қолайлы әдіс етеді.

*Болашақ зерттеулердің перспективалары*

Алынған нәтижелер ұсынылған әдісті одан әрі жетілдіру қажеттілігін көрсетеді. Болашақ зерттеулердің негізгі бағыттары мыналар болуы мүмкін:

– Ережелерді автоматты генерациялау. Қазіргі кезде айқын емес ережелер базасы қолмен құрастырылады, бұл сарапшыларға тәуелділікті арттырады. Болашақта үлкен деректерді талдау және ассоциативтік не эволюциялық алгоритмдер арқылы ережелерді автоматты түрде шығару өзекті бағыт болмақ.

– Цифрлық егіздермен біріктіру. Ақпараттық жүйелердің цифрлық егіздері шабуыл сценарийлерін виртуалды ортада қауіпсіз модельдеуге мүмкіндік береді. FIS-модельді цифрлық егіздермен біріктіру қорғаныс стратегияларын сынауға және ықтимал қауіптердің салдарын дәлірек болжауға жол ашады.

Осылайша, ұсынылған әдіс сараптамалық білімді, деректердің автоматтандырылған талдауын және болжау сценарийлерін біріктіре алатын неғұрлым кешенді интеллектуалды тәуекелдерді басқару жүйелерін құру үшін негіз бола алады.

### **ҚОРЫТЫНДЫ**

Бұл зерттеуде ақпараттық қауіпсіздік тәуекелдерін бағалау үшін Мамдани әдісіне негізделген айқын емес логикалық FIS-модель ұсынылып, оның тиімділігі теориялық және тәжірибелік тұрғыдан негізделді. Ұсынылған модель қауіптің ықтималдығы, осалдық деңгейі және активтің құндылығы сияқты факторлардың белгісіз және аралық мәндерін айқын емес жиындар арқылы өңдеуге мүмкіндік береді, нәтижесінде тәуекелдің интегралды сандық және лингвистикалық бағасы қалыптастырылады.

Тәжірибелік апробация нәтижелері модельдің әртүрлі ақпараттық жүйелерде (CRM, ERP және LMS платформалары) қолдануға жарамды екенін көрсетті. Нақты қауіп сценарийлері негізінде жүргізілген есептеулер ұсынылған FIS-модельдің дәстүрлі ISO/IEC 27005, NIST SP 800-30 және FAIR әдістерімен салыстырғанда белгісіздік жағдайында бағалау дәлдігін арттыратынын және тәуекел деңгейлерін неғұрлым адекватты ажырататынын дәлелдеді. Сонымен қатар, модель алынған тәуекел мәндері негізінде басқарушылық ұсынымдар қалыптастырып, ақпараттық қауіпсіздікті басқару үдерістерін қолдауға қабілетті екенін көрсетті.

Сонымен бірге, зерттеу барысында бірқатар шектеулер анықталды. Атап айтқанда, айқын емес ережелер базасы сараптамалық тәсілмен қолмен қалыптастырылды, ал тәжірибелік тексеру шектеулі сценарийлермен шектелді. Бұл модельдің барлық мүмкін қолдану салаларын толық қамтуға кедергі келтіруі мүмкін.

Болашақ зерттеулердің бағыттары ретінде айқын емес ережелерді автоматты генерациялау әдістерін әзірлеу, FIS-модельді SIEM/SOAR платформаларымен біріктіру арқылы нақты уақыт режимінде тәуекелдерді бағалау және ақпараттық жүйелердің цифрлық егіздерімен интеграциялау ұсынылады. Бұл бағыттар модельдің бейімделгіштігін арттырып, оны күрделі және динамикалық киберқауіптер жағдайында қолдану мүмкіндіктерін кеңейтуге мүмкіндік береді.

Жалпы алғанда, ұсынылған FIS-модель ақпараттық қауіпсіздік тәуекелдерін бағалауда интеллектуалды әрі практикалық тұрғыдан тиімді құрал болып табылады және оны корпоративтік, білім беру және мемлекеттік ақпараттық жүйелерде қолдануға болады.

**МҮДДЕЛЕР ҚАЙШЫЛЫҒЫ:** Авторлар мүдделер қайшылығы жоқ екенін мәлімдейді.

**ҚАРЖЫЛАНДЫРУ:** Бұл зерттеу ешқандай қаржылық қолдаусыз жүргізілді.

**ЖАСАНДЫ ИНТЕЛЛЕКТ ТЕХНОЛОГИЯЛАРЫН ПАЙДАЛАНУ ТУРАЛЫ ХАБАРЛАМА:** Осы ғылыми мақаланы жазу барысында жасанды интеллект немесе генеративті ЖИ технологиялары қолданылған жоқ.

### **ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ**

- Abdymanapov, S., Muratbekov, M., Altynbek, S., & Barlybayev, A. (2021). Fuzzy Expert System of Information Security Risk Assessment on the Example of Analysis Learning Management Systems. *IEEE Access*, 9, 156556–156565. <https://doi.org/10.1109/ACCESS.2021.3129488>
- Adilzhanova, S., Kunelbayev, M., Amirkhanova, G., Zhussupov, Y., & Tortay, A. (2025). Development of a data collection and storage system for remote monitoring and detection of

- security threats in the enterprise. *International Journal of Innovative Research and Scientific Studies*, 8(2), 176–196. <https://doi.org/10.53894/ijirss.v8i2.5136>
- Adilzhanova, S., Mirkassimova, T., Amirkhanova, G., & Kunelbayev, M. (2025). The application of digital twins in assessing information security risks. *International Conference on ACDSA*, 1–7. <https://doi.org/10.1109/ACDSA65407.2025.11166331>
- Ali, Z., & Yang, M.-S. (2024). Improving Risk Assessment Model for Cyber Security Using Robust Aggregation Operators. *Mathematics*, 12(4), 582. <https://doi.org/10.3390/math12040582>
- Amirkhanov, B., Amirkhanova, G., Kunelbayev, M., Adilzhanova, S., & Tokhtassyn, M. (2025). Evaluating HTTP, MQTT over TCP and MQTT over WebSocket for digital twin applications. *International Journal of Innovative Research and Scientific Studies*, 8(1), 679–694. <https://doi.org/10.53894/ijirss.v8i1.4414>
- Barlybayev, A., & Turginbayeva, A. (2025). Development and Implementation of an Advanced Fuzzy Expert System for the Assessment of Information Security Risks. *Journal of Computational and Cognitive Engineering*. <https://doi.org/10.47852/bonviewJ-CCE52024683>
- Bo, Y., & Yuan, P. (2020). Network security risk assessment model based on fuzzy theory. *Journal of Intelligent & Fuzzy Systems*, 38(4), 3921–3928. <https://doi.org/10.3233/JIFS-179617>
- Canbolat, S., Elbez, G., & Hagenmeyer, V. (2023). A hybrid risk assessment process for cyber security design of smart grids using fuzzy AHP. *at–Automatisierungstechnik*, 71(9), 779–788. <https://doi.org/10.1515/auto-2023-0089>
- Fatin, A., Ahmad, S., Zaidi, I. (2021). Experts' Judgment-Based Mamdani-Type Decision System for Risk Assessment. *Mathematical Problems in Engineering*. 6652419, 13 pages. <https://doi.org/10.1155/2021/6652419>
- ISO/IEC 27001:2013. (2025). Information technology – Security techniques – Information security management systems – Requirements. <https://www.iso.org/obp/ui/#iso:std:iso-iec:27001:ed-2:v1:en>
- Kerimkhulle, S., Dildebayeva, Z., Tokhmetov, A., et al. (2023). Fuzzy Logic and Its Application in the Assessment of Information Security Risk of IIoT. *Symmetry*, 15(10), 1958. <https://doi.org/10.3390/sym15101958>
- Korystin, O., Korchenko, O., Kazmirchuk, S., et al. (2024). Comparative Risk Assessment of Cyber Threats Based on Fuzzy Sets Theory. *International Journal of Computer Network and Information Security*, 16(1), 24–34. <https://doi.org/10.5815/ijcnis.2024.01.02>
- Mahmood, Y., Yasir, N., Yodo, N., Huang, Y., Wu, D., & McCann, R. (2025). Comprehensive Risk Assessment of Power Grids Using Fuzzy Bayesian Networks. *Algorithms*, 18(6), 321. <https://doi.org/10.3390/a18060321>
- NIST. (2020). NIST SP 800-53: Security and Privacy Controls for Information Systems. <https://csrc.nist.gov/pubs/sp/800/53/r5/upd1/final>
- Lyubukhin, A. (2023). Metody analiza riskov informatsionnoy bezopasnosti: nechetskaya logika. *International Journal of Open Information Technologies*, 11(2). <http://injoit.org/index.php/j1/article/view/1454/1384>
- Erdoğan, M. K. (2019). A Fuzzy Based MCDM Methodology for Risk Evaluation of Cyber Security Technologies. *Intelligent and Fuzzy Techniques in Big Data Analytics and Decision Making*, 1042–1049. [https://doi.org/10.1007/978-3-030-23756-1\\_123](https://doi.org/10.1007/978-3-030-23756-1_123)
- Амирова, А.С. және т.б. (2025). Анық емес логикаға негізделген ақпараттық қауіпсіздік қатерді бағалау моделі. *ҚазТБҰ ХАБАРШЫСЫ*, 1(26). <https://doi.org/10.58805/kazutb.v.1.26-658> // Amirova, A.S., i dr. (2025). Anyq emes logikağa negizdelgen aqparattyq qayıpsizdik qaterdi baғalaу modeli [Fuzzy logic-based model for information security risk assessment]. *Vestnik KazUTB*, 1(26). <https://doi.org/10.58805/kazutb.v.1.26-658> (In Kaz.)

- Миркаси́мова, Т., Адилжанова, С., Астаубаева, Г., & Мухамеджанова, Г. (2025). Ақпараттық қауіпсіздік тәуекелдерін талдау және бағалау әдістері. ҚазККА хабаршысы, 138(3), 203–216. <https://doi.org/10.52167/1609-1817-2025-138-3-203-216> // Mirkassimova, T., Adilzhanova, S., Astaubayeva, G., & Mukhamedzhanova, G. (2025). Aqparattyq qayıpsızdık táyekelderin taldaú jáne baǵalaú ádisteri [Methods for analysis and assessment of information security risks]. KazATK Bulletin, 138(3), 203–216. <https://doi.org/10.52167/1609-1817-2025-138-3-203-216> (In Kaz.)
- Hersyah, M., Hossain, M. D., Taenaka, Y., & Kadobayashi, Y. (2025). Fuzzyfortify: a multi-attribute risk assessment for multi-factor authentication and cloud container orchestration. Front. Comput. Sci., 7, 1557918. <https://doi.org/10.3389/fcomp.2025.1557918>
- Slavyanov, K., & Dimov, R. (2024). Application of Fuzzy Logic in Cybersecurity Decision Making and Analysis After a Cyber Incident Detection. Environment. Technology. Resources., 2, 259–263. <https://doi.org/10.17770/etr2024vol2.8022>
- Ulya, A., Karima, A., Sukiman, T. S. A., Zulfia, A., & Rahmawati, R. (2025). Information Security Risk Analysis Using ISO 31000:2018 and ISO 27001:2022. Brilliance: Research of Artificial Intelligence, 5(2), 843–853. <https://doi.org/10.47709/brilliance.v5i2.6564>

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Миркаси́мова Толкын Шабденбековна** – «Ақпараттық қауіпсіздік жүйелері» мамандығының докторанты, Әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан; аға оқытушы, Нархоз Университеті, Алматы қ., Қазақстан

**Миркаси́мова Толкын Шабденбековна** – докторант по специальности «Системы информационной безопасности», Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан; старший преподаватель, Университет Нархоз, г. Алматы, Казахстан

**Mirkassimova Tolkyun Shabdenbekovna** – doctoral student in Information Security Systems, Al-Farabi Kazakh National University, Almaty, Kazakhstan; Senior Lecturer, Narхоз University, Almaty, Kazakhstan.

e-mail: [tolkyn.mirkasimova@narhoz.kz](mailto:tolkyn.mirkasimova@narhoz.kz),

ORCID: <https://orcid.org/0009-0003-1594-4012>



**Адилжанова Салтанат Альмуханбетовна** – PhD, Әл-Фараби атындағы ҚазҰУ, Алматы қ., Қазақстан

**Адилжанова Салтанат Альмуханбетовна** – PhD, Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан

**Adilzhanova Saltanat Almkhanbetovna** – PhD, Al-Farabi Kazakh National University, Almaty, Kazakhstan

e-mail: [asaltanat81@gmail.com](mailto:asaltanat81@gmail.com),

ORCID: <https://orcid.org/0000-0003-1768-064X>





[https://doi.org/10.51885/3134-8025\\_IJCS\\_2026\\_1\\_6](https://doi.org/10.51885/3134-8025_IJCS_2026_1_6)

XFTAP 50.01.85

## НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ҚОЛДАНА ОТЫРЫП, ТҮРҒЫН ҮЙДІҢ ЭНЕРГИЯ ТҮТЫНУ ЖҮЙЕСІН ДАМУ

## РАЗВИТИЕ СИСТЕМЫ ЭНЕРГОПОТРЕБЛЕНИЯ ЖИЛОГО ДОМА С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

## ENHANCING RESIDENTIAL ENERGY CONSUMPTION SYSTEMS USING NEURAL NETWORKS

А.А. Найзабаева <sup>1</sup>, А.Ж. Алимханова <sup>2\*</sup>, К. Қуанышбекқызы <sup>1</sup>, Ж.Е. Ерсайнова <sup>1</sup>

<sup>1</sup>«Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ, Өскемен қ., Қазақстан

<sup>2</sup>Қ. Құлажанов атындағы ҚазТБУ, Астана қ., Қазақстан

\*Жауапты автор: Алимханова Аслима Жеңісқызы, e-mail: alimhanova@mail.ru

### Ключевые слова:

энергосбережение;  
автоматизация в  
энергосбережении;  
возобновляемые  
источники энергии;  
энергоэффективность

### АННОТАЦИЯ

В статье рассматриваются актуальные вопросы энергосбережения в соответствии с программой развития Республики Казахстан до 2050 года и переходом к «зелёной» экономике. Предложена архитектура интеллектуального комплекса, включающего фотоэлектрические панели, малую ветрогенерацию, систему накопления энергии на основе аккумуляторных батарей и инвертор. Для краткосрочного почасового прогнозирования нагрузки применяется многослойный перцептрон с раздельным обучением на рабочие, выходные и праздничные дни с учётом сезонности, суток, метеорологических параметров и данных о предыдущем потреблении. Приведён пример практической реализации экспериментальной установки для жилого дома, а также разработанное в среде C# программное обеспечение для мониторинга, визуализации и прогнозирования, интегрированное с платой сбора данных DAQ. Для профилирования и классификации режимов работы используется сеть LVQ (на основе SOM) в сочетании с системой логических решающих правил, определяющих стратегию электроснабжения и энергосбережения. В результате эксперимента получены следующие результаты: средняя ошибка прогнозирования составила 0,65 %, точность моделирования – 91 %, точность сети LVQ – 80 %, чувствительность – 70 %, ошибка обобщения – 0,25. Эти результаты подтверждают применимость методов нейронных сетей в качестве практического инструмента для оптимизации потребления и увеличения доли локально покрываемых нагрузок в жилом секторе.

### Түйінді сөздер:

энергияны үнемдеу;  
энергияны үнемдеуді  
автоматтандыру;

### ТҮЙІНДЕМЕ

Мақалада Қазақстан Республикасының 2050 жылға дейінгі даму бағдарламасына және "жасыл" экономикаға көшуге сәйкес энергия үнемдеудің өзекті мәселелері қарастырылды.



жанартылатын энергия көздері; энергия тиімділігі.

Фотоэлектрлік панельдерді, желдің аз өндірілуін, аккумуляторға негізделген энергияны сақтау жүйесін және инверторды қамтитын интеллектуалды кешеннің архитектурасы ұсынылған. Жүктемені қысқа мерзімді сағаттық болжау үшін маусымдылықты, күнді, метеорологиялық параметрлерді және алдыңғы тұтыну туралы деректерді ескере отырып, жұмыс, демалыс және мереке күндері бөлек оқытылатын көп қабатты перцептрон қолданылады. Тұрғын үйге арналған эксперименттік қондырғыны, сондай-ақ C# ортасында әзірленген DAQ деректер жинау тақтасымен біріктірілген бақылау, визуализация және болжау бағдарламалық құралын практикалық іске асырудың мысалы келтірілген. Жұмыс режимдерін профильдеу және жіктеу үшін LVQ желісі (SOM негізінде) электрмен жабдықтау және энергияны үнемдеу стратегиясын анықтайтын логикалық шешуші ережелер жүйесімен бірге қолданылады. Эксперимент нәтижесінде келесі нәтижелер алынды: болжаудың орташа қателігі 0,65 %, модельдеу дәлдігі – 91 %, LVQ желісінің дәлдігі – 80 %, сезімталдық – 70 %, жалпылау қателігі – 0,25. Бұл нәтижелер тұтынуды оңтайландыру және тұрғын үй секторындағы жергілікті қамтылған жүктемелердің үлесін арттыру үшін практикалық құрал ретінде нейрондық желі әдістерінің қолданылуын растайды.

---

**Keywords:**

energy saving; automation in energy saving; renewable energy sources; energy efficiency.

---

**ABSTRACT**

The article discusses current issues of energy conservation in accordance with the development program of the Republic of Kazakhstan in 2050 and the transition to a "green" economy. The paper proposes an architecture of an intelligent complex that includes photovoltaic panels, small-scale wind power generation, a battery storage system, and an inverter. For short-term hourly load forecasting, a multilayer perceptron with separate training for working, weekend, and holiday days is applied, taking into account seasonality, day type, meteorological parameters, and previous consumption data. An example of a practical implementation of an experimental installation for a residential building is presented, as well as software developed in the C# environment for monitoring, visualization, and forecasting, integrated with a DAQ data acquisition board. For profiling and classification of operating modes, an LVQ (SOM-based) network is used in combination with a system of logical decision rules that determine the power supply and energy-saving strategy. The experiment yielded the following results: the average forecasting error was 0.65%, modeling accuracy – 91%, LVQ network accuracy – 80%, sensitivity – 70%, and generalization error – 0.25. These results confirm the applicability of neural network methods as a practical tool for optimizing consumption and increasing the share of locally covered loads in the residential sector.

---

**КІРІСПЕ**

Қазіргі қарқынды дамып келе жатқан әлемде электрмен жабдықтау жүйелерінің энергия тиімділігін арттыру стратегиялық маңызға ие болып отыр. Жеделдетілген өнеркәсіптік даму, урбанизацияның өсуі және энергия тұтынудың артуы энергияны ұтымды пайдалануға және қоршаған ортаға әсерді азайтуға бағытталған жаңа энергияны басқару технологияларын енгізуді талап етеді. Энергия тиімділігін арттыру шығындар мен энергия шығындарын азайтып қана қоймай, сонымен қатар жаңа өнеркәсіптік және инфрақұрылымдық жобалар үшін пайдаланылуы мүмкін энергияның айтарлықтай көлемін босатады.

Энергия тиімділігі және энергия тиімді экономикаға көшу Қазақстанның мемлекеттік саясатында ерекше орын алады. Президент Қасым-Жомарт Тоқаевтың жыл сайынғы жолдауларында, сондай-ақ елдің негізгі стратегиялық құжаттарында — «Энергия үнемдеу және энергия тиімділігін арттыру туралы» Заңнан бастап «Қазақстан-2050» стратегиясы мен «Жасыл экономикаға» көшу тұжырымдамасына дейін — ұлттық экономиканың энергия сыйымдылығын азайту және интеллектуалды энергияны басқару жүйелерін енгізу қажеттілігі атап өтіледі.

Энергетика саласындағы заманауи үрдістер энергия тиімділігін арттыру цифрландырусыз және басқару процестерін интеллектуалдандырусыз мүмкін емес екенін көрсетеді. Жасанды интеллект, машиналық оқыту және нейрондық желілерді пайдалану энергетикалық процестерді талдау, болжау және оңтайландыру үшін жаңа мүмкіндіктер ашады. Бұл технологиялар сыртқы жағдайларға, жүктемеге және пайдаланушы басымдықтарына негізделген энергия тұтынуды автоматты түрде реттей алатын бейімделгіш жүйелерді жасауға мүмкіндік береді.

Бұл зерттеу нейрондық желілерге негізделген интеллектуалды энергия басқару жүйесін әзірлеуге бағытталған. Осы мақалада ұсынылған модель электр энергиясын тұтынуды талдау және болжау, осылайша энергия ағынын бөлуді оңтайландыру, электрмен жабдықтаудың сенімділігін арттыру және шығындарды азайту үшін жасалған.

#### **МАТЕРИАЛДАР МЕН ЗЕРТТЕУ ӘДІСТЕРІ**

Энергетикалық тиімділік саласындағы ұлттық және аймақтық стратегиялардың басым бөлігі климаттың өзгеруіне қарсы саясатпен тікелей байланысты. «Халықаралық энергетикалық агенттіктің бағалауынша, соңғы тұтынушылардың электр құрылғыларын пайдалану шығындарын азайтуға бағытталған саясат аясында қолжетімді үздік технологияларды енгізу 2030 жылға дейін электр энергиясын 1000 ТВт-сағатқа дейін үнемдеуге мүмкіндік береді; бұл қазіргі көрсеткішпен салыстырғанда айтарлықтай үнемдеу болып табылады. Отын үнемдейтін автомобильдерді шығару отынға деген сұранысты айтарлықтай төмендетеді. Болжауларға сәйкес, дамушы елдердің тез дамып келе жатқан экономикасында 2025 жылға қарай көлік секторындағы энергия ресурстарына сұраныстың 43%-ы, 2008 жылғы шамамен 35%-бен салыстырғанда, тиесілі болады.» (Найзабаева А.А., 2023).

Қытай, Үндістан, Бразилия және соңғы жиырма жыл ішінде экономикасы мен энергияға сұранысы қарқынды өскен басқа елдер көмірсутек шикізатының бағасының өсуі жағдайында энергия үнемдеу саясатына көшуді бастады. Ең маңызды қазіргі үрдістердің бірі – құрылыста энергия үнемдеу және энергия тиімді технологияларды жетілдіру болып отыр. Халықаралық энергетикалық агенттіктің бағалауынша, 2050 жылға дейін CO<sub>2</sub> шығарындыларын азайтудың төрттен бір бөлігі ғимараттар мен құрылғылардың энергия үнемдеу әлеуетіне сәйкес келеді.

Сонымен қатар, көлік секторында энергияны үнемдеу басты бағыттардың бірі болып табылады. Дамыған елдерде жаңа және жаңартылатын энергия көздерінің тиімділігін арттыру саясаты біртұтас түрде енгізілуде. Жаңа технологиялардың дамуы күн энергиясы, гидроэнергетика және биомасса сияқты жаңартылатын энергия көздерін қолдануды тиімді әрі қолжетімді етеді.

Негізгі шектеу – экономикалық фактор, өйткені бұл технологиялар әлі де қымбат. Дегенмен, жаңа және жаңартылатын энергия көздерін пайдалану саласындағы ғылыми-техникалық прогрестің үздіксіздігі және дәстүрлі энергия ресурстарының, әсіресе сұйық көмірсутектердің бағасының тұрақты өсуі, жаңартылатын энергия көздерін көбінесе орталықтандырылмаған аймақтарда кеңінен қолдануға мүмкіндік береді.

«Әртүрлі елдерде энергияны үнемдеу тәсілдері ұлттық менталитетке, мәдени ерекшеліктерге және адамдардың мінез-құлық стереотиптеріне байланысты әртүрлі. Дегенмен, дамыған елдердің ортақ ерекшелігі – энергияны пайдалану кезеңінде үнемдеуге бағытталған саясатты жүйелі түрде енгізу» (Найзабаева А.А., 2023).

АҚШ экономикасы Қазақстан экономикасына қарағанда 2,5 есе тиімді. Кейбір сарапшылардың пікірінше, Америкада өнеркәсіп өнімдерін өндіруге Қазақстанға қарағанда 9 есе аз энергия жұмсалады. Қазіргі уақытта 1 доллар сомасына тауарлар мен қызметтерді шығару үшін қажет энергия 1970 жылмен салыстырғанда 50%-дан астам азайған. Бұл жетістіктер энергияны үнемдеу бойынша ұзақ жылдар бойғы жұмыстардың нәтижесі болып табылады.

АҚШ-та энергия тиімділігі саясатының ерекшелігі – қаржылық ынталандыру шараларын кең қолдану және барлық кодекстер мен ережелерді қабылдаудан жалтармау. "Перспектива-2025" бастамасы бойынша жартыдан астам штат энергия тиімділігін арттыру бағдарламаларын қабылдады және жаңа ғимараттарға энергия үнемдеу талаптарын енгізді. Сонымен қатар, федералды бағдарламалар энергияны үнемдеу мен тиімділікті арттыру әдістерін насихаттайды (Liang Z. et al. 2025).

Жапонияда энергия үнемдеу қоғамның әртүрлі саласына үш бағытта енгізіледі: күн энергиясы, электр көліктері және энергия үнемдейтін тұрмыстық техника. Елдің нақты мақсаты – тұтынылатын энергиядағы жаңартылатын энергия үлесін екі есеге арттырып, әлемдегі ең жоғары көрсеткішке – 20%-ға жету.

Германия, Ұлыбритания және АҚШ Жапонияның тәжірибесін ескере отырып, эко-бизнес бағдарламаларын енгізуде (Guo G. et al. 2024; Liang Z. et al. 2025). Еуропалық Одақ (ЕО) энергия тиімділігін арттыру және климаттың өзгеруіне қарсы стратегияларды ілгерілетуде негізгі жетекші күш болып табылады. Оның реттеуші әсері ЕО мүше елдерінен тыс жерлерге де қолданылады. Барлық мүше мемлекеттер энергия тиімділігі мәселесіне бірдей көңіл бөлмесе де, негізгі саясатты орындау міндеті бар, ал кейбір елдер бұл талаптан әлдеқайда асып түседі.

Германияда энергияны үнемдеуге арналған жалпы заң жоқ, бірақ Федералды когенерация туралы заң және энергия үнемдеу ережелері бар. Бұл құжаттар негізінен ЕО директиваларын ұлттық заңнамаға бейімдеуге бағытталған. Елде энергия үнемдеуді көбінесе мемлекет емес, банктер мен ірі корпорациялар қаржыландырады. Энергия үнемдеуді басқару жүйесі негізгі функцияларды өңірлік және жергілікті деңгейлерге береді.

Ұлыбританияда да энергия тиімділігіне арналған жалпы заң жоқ, құқықтық базаның негізгі бөлігі ЕО директиваларын ұлттық заңнамаға қайта құруға негізделген.

Энергия тиімділігіне арналған ұлттық іс-қимыл жоспарына сәйкес мемлекеттік саясаттың басты бағыты – бизнесте, қоғамдық секторда және үй шаруашылықтарында энергия тиімділігін ынталандыру болып табылады. 1980–2050 жылдарға арналған көмірқышқыл газы шығарындыларын азайту жоспарына сәйкес, 2050 жылы энергия тұтынудың жалпы көлемі 2011 жылғы деңгейден аспауы керек (Baek J. et al. 2022; El Alaoui M., Rougui M., Lamrani A. 2024).

Қазақстан "Қазақстан 2050" стратегиясы мен "жасыл экономикаға көшу тұжырымдамасын" қабылдау арқылы қоғам дамуының жаңа бағытын таңдады. Бұл тұжырымдама мемлекеттік саясаттың қоршаған ортаға әсерді азайту, ресурстарды үнемдеу және халықтың өмір сүру сапасын арттыру бағытында жүргізілуін қарастырады. Жасыл экономикаға көшу стратегиясының маңызды элементтерінің бірі – энергия тиімділігі. Қазіргі уақытта Қазақстан ЖІӨ-нің энергия сыйымдылығы бойынша ең жоғары көрсеткіштерге ие елдердің бірі болып саналады. Сарапшылардың пікірінше, өнеркәсіп, энергетика, ТКШ және көлік салаларында энергия тиімділігін арттыру үшін айтарлықтай мүмкіндіктер бар.

Энергетика саласында бастапқы энергетикалық ресурстар жалпы тұтынудың шамамен 47%-ын құрайды (Baek J. et al. 2022; El Alaoui M., Rougui M., Lamrani A. 2024). Солай бола тұра, энергетикалық генерация мен электр желілерінің тозуы жоғары, бұл электр энергиясын өндіру тиімділігінің төмендігіне және желілердегі шығындардың салыстырмалы түрде жоғары болуына әкеледі.

Өнеркәсіпте энергия тұтынудың жоғары болуы, ең алдымен, мұнай-газ, металлургия және тау-кен сияқты энергияны көп қажет ететін салаларға байланысты. Жабдықтың техникалық жай-күйі мен кәсіпорындардың жүктемесін азайту мәселесі өнеркәсіптің тиімділігіне елеулі әсер етеді. Қабылданған заңнамалық шектеулер кейбір кәсіпорындарда, әсіресе тау-кен металлургия кешені мен көмір өндіру саласында толық нәтиже бермей отыр. Тұрғын үй-коммуналдық секторда тұрғын үй қорының көп бөлігі орталықтандырылған жылумен жабдықталған көп пәтерлі үйлерден тұрады. Инфрақұрылымның қазіргі жағдайында орталық жылыту желілері төмен тиімділікке ие және жылу шығыны едәуір жоғары. Қазақстандағы тұрғын үйлер Солтүстік Еуропа елдеріне қарағанда аудан бірлігіне шамамен үш есе көп энергия тұтынады. Бұл негізінен ескірген жабдықтар мен тиісті жөндеудің болмауымен байланысты.

Көлік секторында елдің бастапқы энергетикалық ресурстарының 17%-ы тұтынылады. Көлік паркінің кейбір техникалық жағдайы мен отынның сапасы энергияны тұтынуға және зиянды заттардың шығарындыларына әсер етеді. Жаңа жанармай стандарттарына көшу және заманауи навигациялық жүйелерді енгізу көлік секторында энергия тиімділігін арттырады.

Өнеркәсіптік кәсіпорындар, қалалар, елді мекендер және үй шаруашылықтары электр энергиясына сенімді, қолжетімді және экологиялық таза энергияны қажет етеді. Жаңартылатын энергия көздері жеке үй шаруашылықтарын, өнеркәсіпті, көлікті және елді мекендерді жабдықтау үшін маңызды үлес қосуы мүмкін.

Бұл зерттеу тұрғын үйдің энергияны басқарудың ақылды (зияткерлік) жүйесін жобалауға бағытталған. «Ұзақ уақыт бойы ақылды үйлерді зерттеу негізінен аппараттық шешімдерге бағытталса, қазіргі уақытта термин ақпараттық технологияларды ғимараттарға біріктіруді білдіреді. Ақылды үйлер саласындағы негізгі тақырыптар – қауіпсіздік, денсаулық сақтау, энергия тиімділігі және тұрғындардың жайлылығы». Жүйелер жарықтандыруды, ойын-сауық және мультимедиа құрылғыларын кеңейтілген басқаруды қамтиды (Salter P., Huang Q., Tabares-Velasco P.C. 2024; Shvets O., Seebauer M., Naizabayeva A. 2020; Tomar D. et al. 2022; Yin Q. et al. 2024; Аленин И.Э. 2023; Билалова А.И. 2023).

Сонымен қатар, қауіпсіздік саласында үй тұрғындары болмаған кезде қашықтықтан бақылау жүйелері әзірленді. Әдебиетте көрсетілген тағы бір қолданыс – қатысуды модельдеу (Нейроинформатика. 2023; Нейронные сети в диагностике и управлении энергосистемами. 2023; Рахмонов И.У. 2023; Сидорова Н.В., Петров А.А. 2023). Дегенмен, басқа салаларда қосымша зерттеулер жүргізуге әлі де мүмкіндік бар.

«Әдебиетте ақылды технологияларды қолдана отырып, ғимараттарда энергияны үнемдеудің көптеген тәсілдері қарастырылған. Көптеген зерттеулерде ақылды ғимараттардағы энергияны үнемдеу негізінен үйдегі жылу жүйесін» (Нейронные сети в диагностике и управлении энергосистемами 2023; Рахмонов И.У. 2023), ауаны баптау (Староверов Б.А. 2023), немесе екеуін бірдей бақылауды қамтиды (Билалова А.И. 2023; Устинов Д.А. 2022; Шлепнёва Т.О. 2025; Энергия знаний: современные IT-технологии в энергетике: сборник статей. 2024).

Кейбір тәсілдер құрылғыларды тікелей аз тұтынуға бағытталмаған, бірақ мониторинг пен бақылауды жетілдіруді қамтамасыз етеді (Рахмонов И.У. 2023; Шлепнёва Т.О. 2025). «Бұл жобалардың көпшілігінде ылғалдылық пен температураны өлшеу үшін

сенсорлар кеңінен қолданылады, ал деректерді анық емес контроллер арқылы өңдеу энергияны тиімді таратуға мүмкіндік береді» (Рахмонов И.У. 2023; Энергия знаний: современные IT-технологии в энергетике: сборник статей. 2024).

Энергияны үнемдеудің тағы бір бағыты – үйдегі жарықтандыру мен тұрмыстық техникаға энергияны басқару функцияларын қосу (Устинов Д.А. 2022). Синтетикалық деректерді қолдана отырып, әртүрлі сценарийлерді модельдегенде, жеке үйлерде энергияны үнемдеу шамамен 30%-ға жетуі мүмкін екені анықталған. Жарықтандыру құрылғыларын қосу үшін адамға арналған инфрақызыл сенсорлар қолданылады.

Жаңа тәсілде үйде күн сәулесінің фотоэлектрлік панельдері, энергия сақтау жүйесі және басқарылатын/бақыланбайтын құрылғылар сияқты энергия үнемдейтін құрылғылар бар деп қарастырылады. Мұндай тәсілдің басты артықшылығы – нақты уақыт режимінде үйге қосылған барлық компоненттерді басқаруға және бақылауға мүмкіндік беру, бұл клиентке немесе коммуналдық меншікке тиесілі үйдің энергия тиімділігін арттырады.

### **НӘТИЖЕЛЕР МЕН ОЛАРДЫ ТАЛҚЫЛАУ**

Модельдеу үшін қолайлы нейрондық желіні таңдау нақты тапсырмаға, сондай-ақ мәліметтердің түрі мен көлеміне байланысты. Желілердің көптеген классификациялары бар, бірақ электр энергиясы нарығына тән мәселелерді шешу үшін көбінесе көпқабатты перцептрон (энергия тұтынуды болжау үшін) және Кохонен желісі (клиенттің электр энергиясын тұтыну профилін құру үшін) қолданылады.

«Электр энергиясын тұтынуға әсер ететін көптеген параметрлер бар, олардың барлығы бірдей әсер етпейді. Тұтынуды болжауда маңызды параметрлердің көпшілігі циклдік сипатқа ие: күнделікті, апталық, айлық, тоқсандық, жылдық тәуелділіктер; демалыс/жұмыс күндері және т.б. Сонымен қатар, функционалды сипаттамаларға метеорологиялық жағдайлар, клиент түрі, экономика саласы, ғимарат сипаттамалары жатады.

Бұл жұмыста ұқсас екі перцептроннан тұратын қарапайым модель ұсынылады: біреуі жұмыс күндерінің сағаттық жүктеме профилін, екіншісі демалыс немесе мереке күндерін болжайды. Оқу процесі екі бөлікке бөлінген: әр перцептрон үшін екі синаптикалық салмақ матрицасы есептеледі. Бірінші желі жұмыс күндерінің нақты деректері бойынша оқытылады және алынған салмақ матрицалары тек жұмыс күндері үшін қолданылады. Екінші желі демалыс немесе мереке күндерінің жүктемесін болжау үшін пайдаланылады» [Найзабаева А.А., 2023].

Шығыс қабаты тәуліктік сағаттық жүктеме профилін көрсету үшін 24 нейроннан, жасырын қабат – 15 нейроннан, кіріс қабаты – 30 нейроннан тұрады. Кіріс векторы алдыңғы күннің электр тұтыну сипаттамаларын (3 нейрон), алдыңғы күн мен болжанатын күннің орташа тәуліктік температураларын (2 нейрон) қамтиды. Маусымдылықты есепке алу үшін айлар саны бойынша 12 нейрон, бір айдағы онкүндіктер үшін 3 нейрон және тәулік түрін көрсету үшін 10 нейрон пайдаланылады.

Үш нейрон өткен тәуліктің электр энергиясын тұтыну сипатын көрсетеді: тәуліктік шығыс, сондай-ақ алдыңғы күннің ең жоғары және ең төмен сағаттық шығыстары. Перцептронды оқыту екі кезеңде жүреді: алдымен барлық берілген жұптар жиынтығында (1,5 жылға дейінгі нақты мәліметтер бойынша), содан кейін болжанатын күн алдындағы ең аз уақыт аралығында. Оқу жұбы – кіріс векторы мен мақсатты вектор, олардың мәндері 0-ден 1-ге дейінгі диапазонға қалыпқа келтіріледі.

Жасанды интеллект әдістерін қолданған болжамның дәлдігі желінің архитектурасына, деректер сенімділігіне және болжау кезеңіне байланысты. Қысқа мерзімді кәсіпорын жүктемесін болжау үшін тәуліктік электр тұтыну бойынша статистикалық есеп беру деректері қажет. Жоғары сенімділік үшін кәсіпорында алдын ала

жоғары дәлдіктегі көп функциялы автоматтандырылған тұтынуды бақылау және есепке алу жүйесі енгізілуі керек.

Сенімділік интервалдары 100 элементтен тұратын үлгі бойынша есептелді. Болжамның орташа қателігі 0,65% құрады. Сәуір айының екі онкүндігінде белсенді электр энергиясын тұтынудың тәуліктік нақты және болжанатын жүктемелерінің профилі келесідей: 1 — нақты жүктеме, 2 — болжанатын жүктеме. 0,87 сенімділік аралығының мәні 0,27 кВт-сағ, ең төменгі мәні 0,01 кВт-сағ болды. Сағаттық болжамның орташа қателігі 1,87% болды, ал болжамның орташа қателігі 0,65%-ды құрады.

Бұл жұмыс үшін нейрондық желі ретінде LVQ (Learning Vector Quantization) таңдалды. LVQ – кіріс векторларын жіктеу желісі, ол Кохоненнің өзін-өзі ұйымдастыратын картасы (SOM) принциптерінің дамуы болып табылады (Нейронные сети в диагностике и управлении энергосистемами. 2023).

Әрбір нейрондық желінің шығуы логикалық блоктар арқылы талданады. Үйдегі энергияны тұтыну жүйесінің әр күйіне бір логикалық блок сәйкес келеді. Барлығы сегіз жағдайға арналған шешуші ережелер жасалды.

1) Күн панельдері шығаратын энергия жеткілікті, сіз энергияны сақтау режимін қолдана аласыз

$$F_1 = Ref \& TV \& Est \& Ov \& WsM \& PC \& Pot \& DsM \& Vac \& Ir \& McW \& MCo \& bulb \& Ht \& Led \quad (1)$$

2) Күн панельдері шығаратын энергия жеткілікті

$$F_2 = Ref \& TV \& Est \& Ov \& WsM \& PC \& Pot \& DsM \& Vac \& Ir \& McW \& MCo \& bulb \& Ht \& Led, \quad (2)$$

3) Күн панельдері шығаратын энергия құрылғылардың жұмысына жеткілікті, сақтандыру үшін балама көзді немесе батареяны қосыңыз

$$F_3 = Ref \& TV \& Est \& Ov \& WsM \& PC \& Pot \& DsM \& Vac \& Ir \& McW \& MCo \& bulb \& Ht \& Led, \quad (3)$$

4) Күн панельдері шығаратын энергия қосылған құрылғылардың жұмысына жеткілікті, сақтандыру үшін балама көзді немесе батареяны қосыңыз

$$F_4 = Ref \& TV \& Est \& Ov \& WsM \& PC \& Pot \& DsM \& Vac \& Ir \& McW \& MCo \& bulb \& Ht \& Led, \quad (4)$$

5) Күн панельдері шығаратын энергия қосылған құрылғылардың жұмысына жеткілікті

$$F_5 = Ref \& TV \& Est \& Ov \& WsM \& PC \& Pot \& DsM \& Vac \& Ir \& McW \& MCo \& bulb \& Ht \& Led, \quad (5)$$

6) Күн панельдері шығаратын энергия жеткілікті, сіз энергияны сақтау режимін қолдана аласыз

$$F_6 = Ref \& TV \& Est \& Ov \& WsM \& PC \& Pot \& DsM \& Vac \& Ir \& McW \& MCo \& bulb \& Ht \& Led, \quad (6)$$

7) Күн панельдері шығаратын энергия құрылғылардың жұмысына әрең жетеді, сақтандыру үшін балама көзді немесе батареяны қосыңыз

$$F_7 = Ref \& TV \& Est \& Ov \& WsM \& PC \& Pot \& DsM \& Vac \& Ir \& McW \& MCo \& bulb \& Ht \& Led, \quad (7)$$

8) Күн панельдері шығаратын артық энергия, энергияны сақтау режимін қолдануға болады

$$F_8 = Ref \& TV \& Est \& Ov \& WsM \& PC \& Pot \& DsM \& Vac \& Ir \& McW \& MCo \& bulb \& Ht \& Led, \quad (8)$$

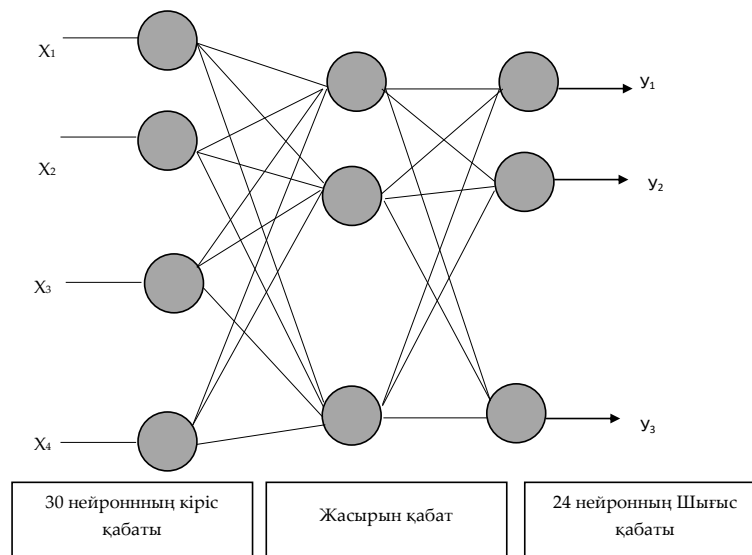
Мұнда Ref, TV, Est, Ov, WsM, PC, Pot, DsM, Vac, Ir, McW, MCo, bulb, Ht, Led, TV, (Est), Ov, WsM, PC, Pot, DsM, Vac, Ir, McW, MCo, Bulb – нейрондық желі шығуларынан алынған мәліметтер.

Нейрондық желілердің шығуын талдау сатысында (1...k) шешуші ережелерге (1–8) сәйкес үйді электрмен жабдықтау жағдайы анықталады. Суретте MathLab 6.5 ортасында жүзеге асырылған нейрондық желіні талдау схемасы көрсетілген.

Басым шифратор нейрондық желілерден алынған k мәнін талдау нәтижесінде нақты шешімдердің бірін таңдайды. Шифратордың шығуында кіріс желісінің нөміріне сәйкес оң

кіріс сигналы кодталады (яғни, талдауға қатысатын  $k$  нейрондық желілерінің бірінен логикалық "1" сигналы келгенде). Егер бірнеше кіріс сигналы бір уақытта түскен жағдайда, ең үлкен нөмірлі кіріс шығыс кодын анықтайды, яғни жоғары нөмірлі кірістер төменгілерге қарағанда басымдыққа ие болады.

Осы кезеңнің нәтижесі энергия тұтыну жүйесінің күйін көрсететін қорытынды нөмір болып табылады. Алынған нөмірге сәйкес пайдаланушыға энергия тұтыну жағдайының сөздік сипаттамасы беріледі.



**1-сурет.** MathLab 6.5 ортасында жүзеге асырылған нейрондық желіні талдау сызбасы  
*Ескерту – авторлар құрастырған*

Оқыту сапасын бағалау үшін келесі параметрлердің әсері зерттелді: оқ үлгісінің артық болуы, шуылдың мөлшері, жылжу мөлшері, жасырын қабат нейрондарының саны, оқ укезеңдерінің саны.

Жүргізілген зерттеулер нәтижесінде НС LVQ оқыту сапасының келесі сандық көрсеткіштері алынды:

- ерекшелігі: 80 %;
- сезімталдық: 70 %;
- жалпылау қатесі: 0,25;
- оқу қатесі: 0,08.

Нейрондық желіні үйреткеннен кейін, құрастырылған анық емес модельдің құрылымында 252 ереже болады.

Алынған нәтижелер электр жүктемесін болжау үшін ұсынылған тәсілді қолдану мүмкіндігін көрсетеді. Нейрондық желілер дәстүрлі статистикалық әдістерге балама энергия тұтынуды болжау мәселелерін шешудің қолайлы құралы болып табылады. Болжамның дәлдігін одан әрі арттыру желі құрылымын дәлірек және дәл баптау және кіріс параметрлерінің санын өзгерту арқылы мүмкін болады.


## ЭКСПЕРИМЕНТТІК ҚОНДЫРҒЫ ҚҰРУ ЖӘНЕ БАҒДАРЛАМАЛЫҚ ҚАМТАМАСЫЗ ЕТУ

Эксперименттік қондырғыға арналған генераторларды таңдау қолда бар жабдыққа байланысты жасалды. Қарастырылған жүйеде инвертор генераторлар мен жүйенің жүктемесі бар бөлігін байланыстыратын көпір қызметін атқарады.

Осы жұмыс аясында 550 Вт желілік инвертор жобаланып, жасалды. Жүйенің негізгі байланыс схемасы келесідей: жүйеде екі шина бар – тұрақты ток шинасы және айнымалы ток шинасы.

Барлық тұрақты ток қондырғылары (фотоэлектрлік панельдер, DWT, балласт жүктемесі, батареялар) тұрақты ток шинасына қосылады.

Барлық айнымалы ток қондырғылары (жүктемелер, желі) айнымалы ток шинасына қосылады. Инвертор екі шинаға да қосылып, оларды бір-бірімен байланыстырады. Эксперименттік қондырғыда қолданылатын инвертор тізбегінің топологиясы суретте көрсетілген.



**2-сурет.** DC-DC түрлендіргіші бар Инвертор

Ескерту – авторлар Guo G. et al. 2024 деректері негізінде құрастырылған


Эксперименттік қондырғының бұл бөлімі инвертордан (бұл жағдайда ажыратқыш) тұрады, одан кейін трансформатор және түзеткіш орналасады. Бұл схема күрделі болса да, белгілі бір артықшылықтарға ие. Инвертордың шығысы трансформатор арқылы өткенде, трансформатор инвертордың шығу жиілігіне сәйкес жұмыс істеуге арналған болуы тиіс.

**1-кесте.** Жабдықтар тізімі

Жүйе компоненті	Өндіруші	Саны
Saturn 80, монокристалды фотоэлектрлік модуль, номиналды кернеуі 12 В, максималды қуаты 80 Вт	BP Solar	2
МАХ-50, поликристалды фотоэлектрлік модуль, номиналды кернеуі 12 В, максималды қуаты 50 Вт	Solarex	2
Қорғасын-қышқылды батарея, 12 В, 75 ампер-сағат	Varta	2
24 В кіріс инверторы, 230 В Шығыс, 550 Вт максималды қуат	Жеке өндіріс	1
Балласт жүктемесі, 24 В, 200 Вт максималды, реттегіш шунтпен және кірісті басқарумен	Жеке өндіріс	1
Сақтандырғыштары, батарея оқшаулағышы, ток шунттары және кернеу бөлгіші бар клеммалық қалып	Жеке өндіріс	1
Intel Core i3 компьютері, 4 Гб жедел жады, 500 Гб HDD	Түрлі компоненттерден жиналған	1
PCI - 6023e, деректерді жинау картасы, 8 аналогтық кіріс арналары, 8 Саңдық шығыс желілері	National Instruments	1

Ескерту – авторлар құрастырған

Жүйе суретке сәйкес жиналды.



3-сурет. Тұрақты ток жабдықтарын қосу схемасы

Ескерту – авторлар құрастырған

Әр типтегі фотоэлектрлік панельдер екі қатарға қосылып, 12 В батареядан тұратын екі қатарлы 24 В батарея жүйесіне қосылады. Жел турбинасының екі модулі (DWT) де аккумуляторға қосылады. Олар айнымалы ток тудыратыны үшін әрбірінде түзеткіш қолданылады.

Инвертор батареядан кіріс сигналын қабылдап, электр желісіне шығудан қуатты береді, яғни кез келген басқа электр аспабы сияқты розеткаға қосылады. Тұрақты ток жүйесінің барлық кернеулері мен токтары, сондай-ақ инвертор күйі DAQ тақтасы бар компьютер арқылы жазылып, бақыланады. Ethernet арқылы бұл компьютер басқа физикалық қашықтықтағы компьютерге қосылып, екінші компьютер жүктемелердің күйін бақылайды және айнымалы ток тұтынушыларын басқарады.

Жүйе компоненттерінің функционалдығын тексеру және жеке тексерулерде анықталмайтын кедергілерді табу үшін сандық сүзгі қолданылды. DAQ картасы бірнеше үлгіні алып, орташа мәнді есептейді, сондықтан қарапайым төмен өту сүзгісі бағдарламалық жасақтамада жүзеге асырылды. 1 секундта 1000 үлгі алу және 100 үлгінің орташа мәнін есептеу пульсацияны қолайлы деңгейге төмендетті, бірақ бұл есептеу қуатын айтарлықтай қажет етеді.

Ұсынылған жүйе анық емес логика элементтерін қолданып, электр жүктемелерін «ақылды» ету әдісін қажет етті. «Ақылды розетка» құрылысын жобалау AIS2020 симпозиумында егжей-тегжейлі қарастырылып, жарияланды.

Бағдарламалық қамтамасыз ету төрт негізгі блоктан тұрады:

- Өлшеу деректері;
- Қуат көрсеткіштері;

- Электр энергиясын өндіру және тұтыну;
- Болжамды модель.

«Өлшеу деректері» қойындысында кесте бар, оның әр жолы соңғы бес мәннен басқа бір өлшемді білдіреді, себебі кейбір мәндер басқа кезеңде есептеледі (суретті қараңыз).

Өлшеу деректері		Қуат көрсеткіштері			Электр энергиясының өндірісі мен тұтынуы				Болжамдық модель									
Өлшеу күні мен уақыты	Тұрақты ток шинасының кернеуі, В	PV1 шығыс тогы, А	PV2 шығыс тогы, А	DWT1 шығыс тогы, А	DWT2 шығыс тогы, А	Балласт жүктемесінің кіріс тогы, А	Батареяның кіріс тогы, А	Айнымалы ток желісінің кернеуі, В	Инвертордың шығыс тогы, А	Желіден тұтынылатын ток, А	Жүктеме тұтынылатын жалпы ток, А	Құрылымы 1 қосылған	Құрылымы 2 қосылған	Құрылымы 3 қосылған	Құрылымы 4 қосылған	PV1 генерациялайтын қуат, Вт	PV2 генерациялайтын қуат, Вт	DWT1 генерациялайтын қуат, Вт

#### 4-сурет. «Өлшеу деректері» қойындысы

Ескерту – авторлар Найзабаева А.А деректері негізінде құрастырған

Кесте келесі өрістер:


- күні мен уақыты өлшеу;
- DC кернеуі, В;
- pv1, а ШЫҒЫС ТОГЫ;
- pv2, а ШЫҒЫС ТОГЫ;
- dwt1, а ШЫҒЫС ТОГЫ;
- dwt2, а ШЫҒЫС ТОГЫ;
- балласт жүктемесінің кіріс тогы, А;
- батареяның кіріс тогы және;
- айнымалы ток желісіндегі кернеу, В;
- инвертордың ток шығысы, А;
- желіден тұтынылатын ток, А;
- жүктеме арқылы тұтынылатын жалпы ток, А;
- 1 құрылғысы қосулы, иә/жоқ;
- 2 құрылғысы қосулы, иә/жоқ;
- 3 құрылғысы қосулы, иә/жоқ;
- 4 құрылғысы қосулы, иә/жоқ;
- pv1, Вт шығаратын қуат;
- pv2, Вт шығаратын қуат;
- dwt1, А арқылы өндірілетін қуат;
- жалпы өндірілетін қуат, Вт;
- батарея зарядына тұтынылатын қуат, Вт;
- балласт жүктемесіне артық қуатты есептеу, Вт;
- инвертор тұтыныатын қуат, Вт;
- инвертордан алынатын қуат, Вт;
- желіден алынатын қуат, Вт;
- жүктеме тұтыныатын қуат, Вт.

«Деректерді жүктеу» батырмасын басқан кезде деректерді бағдарламалық өнімге беру жүзеге асырылады және жүктелген жазбалар санымен «деректерді жүктеу аяқталды» терезесі пайда болады.

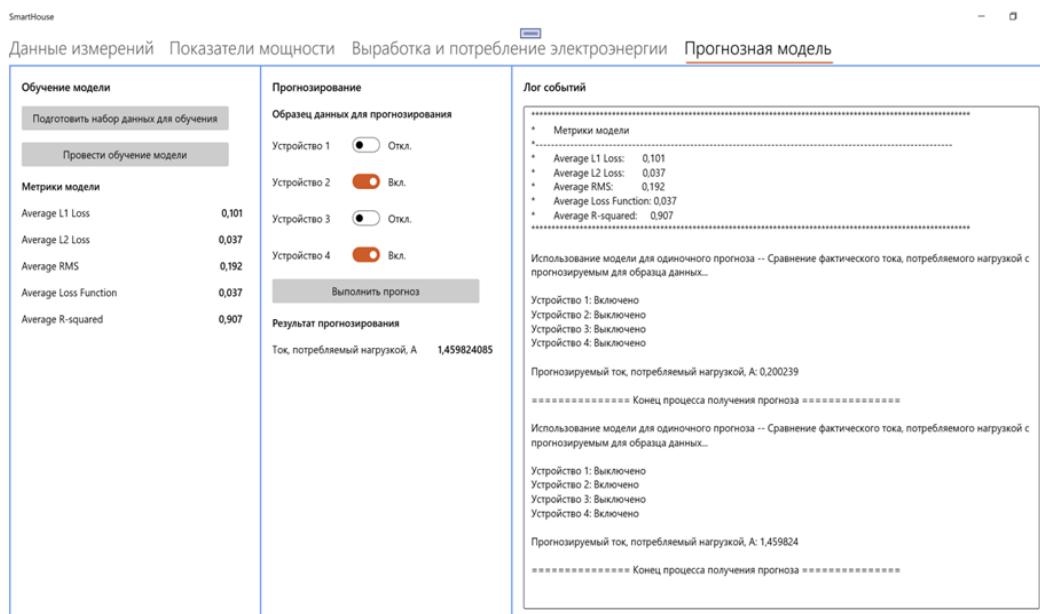
«Қуат көрсеткіштері» қойындысы терезесінің оң жақ бөлігі (суретті қараңыз) келесі графикалық түрде көрсетілген есептік көрсеткіштерді таңдау үшін жалаушаларды орнатуға мүмкіндік береді:

- монокристалды панельдер шығаратын қуат;
- поликристалды панельдер шығаратын қуат;
- жел турбиналары шығаратын қуат;

- жиынтық қуаты;
- батарея қуатын тұтынатын қуат;
- балласт жүктемесіне лақтырылатын артық қуатты есептеу;
- инвертор тұтынатын қуат;
- инвертордан алынған қуат;
- желіден алынатын қуат;
- жүктеме тұтынатын жалпы қуат.



**5-сурет.** «Қуат көрсеткіштері» қойындысы, суретте бір уақытта қосылған екі құрылғы үшін болжау мысалы келтірілген  
Ескерту – авторлар Найзабаева А.А деректері негізінде құрастырған



**6-сурет.** Қосылған екі құрылғы үшін болжау мысалы, болжау нәтижелері бойынша модельдеу дәлдігі 91 % құрайды  
Ескерту – авторлар Найзабаева А.А деректері негізінде құрастырған

## ҚОРЫТЫНДЫ

Дамыған елдерде, мысалы, АҚШ, Жапония, Ұлыбритания және Еуропалық Одақтың кейбір елдерінде энергия үнемдеу саясатына заманауи озық тәсілдер қолданылып келеді. Әлемде және Қазақстан Республикасында энергия тиімділігінің даму тенденциялары қарастырылды.

«Ақылды үйді автоматтандыру жүйелеріне арналған зерттеулер талданды, олардың әдістері мен энергияны үнемдеу бойынша ұсыныстар беру әлеуеті бағаланды. Эксперименттік қондырғыға арналған генераторларды таңдау қолда бар жабдыққа байланысты жасалды». ([https://www.ektu.kz/files/research/DissertationCouncil/Naizabayeva/%D0%94%D0%B8%D1%81%D1%81%D0%B5%D1%80%D1%82%D0%B0%D1%86%D0%B8%D1%8F\\_2023\\_17\\_%D0%B8%D1%8E%D0%BB%D1%8F.pdf](https://www.ektu.kz/files/research/DissertationCouncil/Naizabayeva/%D0%94%D0%B8%D1%81%D1%81%D0%B5%D1%80%D1%82%D0%B0%D1%86%D0%B8%D1%8F_2023_17_%D0%B8%D1%8E%D0%BB%D1%8F.pdf))

Қондырғыда монокристалды және поликристалды фотоэлектрлік модульдер қолданылды. Шатырға орнатылғаннан кейін олар кіріктірілген жаңартылатын энергия көздері ретінде қарастырылды.

Бағдарламалық жасақтама әзірленген схемалар мен талаптарға сәйкес C# ортасында жүзеге асырылды.

## ӘДЕБИЕТТЕР ТІЗІМІ

- Baek J., Kim H., Lee S., Park J., & Choi Y. (2022). Enhanced LSTM-based community energy consumption prediction considering occupant behaviour // *Energy and Buildings*. – Vol. 258. – DOI: 10.1016/j.enbuild.2022.111815. (In Eng.)
- El Alaoui M., Rougui M., Lamrani A. (2024). Examining the Application of Artificial Neural Networks (ANNs) for Advancing Energy Efficiency in Buildings: A Comprehensive Review // *Journal of Sustainable Research*. – DOI: 10.20900/jsr20240015. (In Eng.)
- Guo G., Li H., Zhang X., & Wang Y. (2024). Early energy performance analysis of smart buildings by ANN and metaheuristic optimization // *Sustainable Energy Technologies and Assessments*. – DOI: 10.1016/j.seta.2024.103568. (In Eng.)
- Liang Z., Chen L., & Wang J. (2025). Research on building energy consumption prediction: a customised convolutional neural network with Q-Learning (CCNN-QL) // *Energy Informatics*. – DOI: 10.1186/s42162-025-00483-y. (In Eng.)
- Michalakopoulos V., Karypidis S., & Papadopoulos F. (2023). Data-driven building energy efficiency prediction using physics-informed neural networks // *arXiv preprint*. – arXiv:2311.08035. (In Eng.)
- Mishra A., Lone H.R., & Mishra A. (2023). DECODE: Data-driven Energy Consumption Prediction leveraging Historical Data and Environmental Factors in Buildings // *arXiv preprint*. – arXiv:2309.02908. (In Eng.)
- Rani U., Singh A., & Kumar P. (2024). Deep learning-based urban energy forecasting model for household energy efficiency // *Building Simulation*. – DOI: 10.1177/01445987241257590. (In Eng.)
- Salter P., Huang Q., & Tabares-Velasco P.C. (2024). Quantifying and Predicting Residential Building Flexibility Using Machine Learning Methods // *Applied Energy*. – DOI: 10.1016/j.apenergy.2024.120937. (In Eng.)
- Швец О., Зибауэр М., Найзабаева А. (18-ДАУ-3р), Толегазин А. (20-МАУ-2р). Оптимизация автономных систем электроснабжения для повышения энергоэффективности // 15th International Symposium on Applied Informatics and Related Areas organized in the frame of Hungarian Science Festival 2020 by Óbuda University, 12.11.2020. // Shvets O., Seebauer M., Naizabayeva A. (18-DAU-3p), Toleugazin A. (20-MAU-2p). Avtonomnye sistemy elektrosnabzheniya: optimizatsiya dlya povysheniya energoeffektivnosti [Autonomous power supply systems optimization for energy efficiency increasing] (In Russ.)

- Tomar D., Singh R., & Gupta A. (2022). Deep Learning Neural Network Prediction System for Domestic Electric Power Consumption of a Single Residential Building // *Energies*. – DOI: 10.3390/en15030874. (In Eng.)
- Yin Q., Zhang L., & Wang X. (2024). A Review of Research on Building Energy Consumption Prediction Using Neural Networks // *Sustainability*. – Vol. 16(17), p. 7805. – DOI: 10.3390/su16177805. (In Eng.)
- Аленин И.Э. (2023). Применение технологии нейронных сетей и BIM-данных в энергетике зданий // СГГИТ сборник трудов. – Новосибирск. – С. 23–29. // Alenin I.E. Primenenie tekhnologii neyronnykh setey i BIM-dannykh v energetike zdaniy [Application of neural networks and BIM-data technology in building energy] (In Russ.)
- Билалова А.И. (2023). Прогнозирование потребления и повышение качества электроэнергии. – Ульяновск: УлГТУ. – 78 с. // Bilalova A.I. Prognozirovanie potrebleniya i povyshenie kachestva elektroenergii [Prediction of consumption and improvement of electricity quality] (In Russ.)
- Найзабаева А.А. (2023). Контроль и управление системы энергопотребления с использованием нейронных сетей // Диссертация на соискание степени доктора философии (PhD) – Усть-Каменогорск: ВКТУ им.Д.Серикбаева. // Naizabayeva A.A. Kontrol i upravlenie sistemy energopotrebleniya s ispol'zovaniem neyronnykh setey [Control and management of energy consumption system using neural networks] (In Russ.)
- Нейроинформатика-2023: сборник материалов конф. – М.: МИФИ, 2023. – 512 с. // Neuroinformatika-2023: sbornik materialov konf. [Neuroinformatics-2023: Conference proceedings] (In Russ.)
- Нейронные сети в диагностике и управлении энергосистемами // Энергоэффект. – Минск, 2023. – № 4. – С. 33–40. // Neyronnye seti v diagnostike i upravlenii energosistemami [Neural networks in diagnostics and management of energy systems] (In Russ.)
- Рахмонов И.У. (2023). Прогнозирование электропотребления с помощью нейронных сетей (с LSTM) // Наука и образование сегодня. – № 8(83). – С. 32–38. // Rakhmonov I.U. Prognozirovanie elektropotrebleniya s pomoshch'yu neyronnykh setey (s LSTM) [Electricity consumption forecasting using neural networks (with LSTM)] (In Russ.)
- Сидорова Н.В., Петров А.А. (2023). Применение RNN и WaveNet для прогнозирования энергопотребления // Вестник Чувашского университета. – № 4. – С. 57–65. – DOI: 10.47026/1810-1909-2023-4-57-65. // Sidorova N.V., Petrov A.A. Primenenie RNN i WaveNet dlya prognozirovaniya energopotrebleniya [Application of RNN and WaveNet for energy consumption forecasting] (In Russ.)
- Староверов Б.А. (2023). Ансамбли нейронных сетей для прогнозирования электропотребления. – Омск: ОмГТУ. – 138 с. // Staroverov B.A. Ansambli neyronnykh setey dlya prognozirovaniya elektropotrebleniya [Neural network ensembles for electricity consumption forecasting] (In Russ.)
- Устинов Д.А. (2022). Прогнозирование потребления электроэнергии с учётом внедрения ВИЭ. – СПб: СПГИ. – 94 с. // Ustinov D.A. Prognozirovanie potrebleniya elektroenergii s uchetom vnedreniya VIE [Electricity consumption forecasting considering RES implementation] (In Russ.)
- Шлепнёва Т.О. (2025). Искусственный интеллект и нейросетевые технологии в энергетике // Инновации и безопасность регионов. – № 1(12). – С. 45–52. // Shlepneva T.O. Iskusstvennyy intellekt i neyrosetevyye tekhnologii v energetike [Artificial intelligence and neural network technologies in energy] (In Russ.)
- Энергия знаний: современные IT-технологии в энергетике: сборник статей. – Курск: ЮЗГУ, 2024. – 214 с. // Energiya znaniy: sovremennyye IT-tekhnologii v energetike: sbornik statey [Energy of knowledge: modern IT technologies in energy] (In Russ.)

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Найзабаева Асель Айбарқызы** – PhD, ғылыми қызметкер, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

**Найзабаева Асель Айбаровна** – Phd, научный сотрудник, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Naizabayeva Asel Aybarkyzy** – PhD, Research Fellow, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan,  
e-mail: aselnaizabaeva@mail.ru ,  
ORCID: <https://orcid.org/0009-0005-9334-5087>



**Алимханова Аслима Жеңісқызы** – PhD сеньор лектор КазУТБ им К Құлажанова, Астана қаласы, Қазақстан

**Алимханова Аслима Женисовна** – PhD сеньор лектор КазУТБ им К Кулажанова, г. Астана, Казахстан

**Alimkhanova Aslima Zheniskyzy** – PhD, Senior Lecturer, KazUTB named after K. Kulazhanov, Astana, Kazakhstan,  
e-mail: alimhanova@mail.ru



**Қуанышбекқызы Кербез** – техника және технология магистрі, Д.Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

**Қуанышбекқызы Кербез** – магистр социальных наук, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Kuanyshbekkyzy Kerbez** – master of Engineering and Technology, East Kazakhstan Technical University named after D. Serikbaev, Ust-Kamenogorsk, Kazakhstan,  
e-mail: kuanyshbekkyzy.kerbez@gmail.com,  
ORCID: <https://orcid.org/0009-0003-7847-2710> ,



**Ерсаинова Жансая Ерланқызы** – техника ғылымдарының магистрі, Д.Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

**Ерсаинова Жансая Ерлановна** – магистр технических наук, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Ersainova Zhansaya Erlanovna** – master of Engineering Sciences, East Kazakhstan Technical University named after D. Serikbayev, Ust-Kamenogorsk, Kazakhstan  
e-mail: zhansaya.ersayynova@mail.ru ,  
ORCID: <https://orcid.org/0000-0003-4052-8830>,

[https://doi.org/10.51885/3134-8025\\_IICS\\_2026\\_1\\_7](https://doi.org/10.51885/3134-8025_IICS_2026_1_7)

SRSTI 28.23.01

## MULTIMODAL CLASSIFICATION OF SKIN NEOPLASMS BY USING DEEP LEARNING

### ТЕРЕҢ ОҚЫТУДЫ ҚОЛДАНА ОТЫРЫП, ТЕРІ ӨСІНДІЛЕРІНІҢ МУЛЬТИМОДАЛЬДЫ ЖІКТЕЛУІ

### МУЛЬТИМОДАЛЬНАЯ КЛАССИФИКАЦИЯ КОЖНЫХ НОВООБРАЗОВАНИЙ С ИСПОЛЬЗОВАНИЕМ ГЛУБОКОГО ОБУЧЕНИЯ

T. Sadvakassov <sup>1\*</sup>, G. Soltan <sup>1</sup>, T. Karibekov <sup>1</sup>, S. Abdrakhmanova <sup>1</sup>

<sup>1</sup>Astana IT University, Astana, Kazakhstan

\*Corresponding author: Temirlan Sadvakassov, e-mail: imtims.17@gmail.com

#### Keywords:

machine learning,  
classification of skin diseases,  
convolutional neural  
networks, transfer learning,  
deep learning, medical  
diagnostics.

#### ABSTRACT

The article discusses modern machine learning methods which are applicable to the task of automated classification of skin diseases based on dermoscopic images. Special attention is paid to convolutional neural network architectures and the use of transfer learning with pre-trained models. The publicly available HAM10000 dataset, which includes images of seven types of skin lesions as well as clinical metadata on patients (gender, age, and location), was used as the experimental basis. Several models were implemented and tested during the study. A basic convolutional neural network (CNN) trained from scratch showed limited results, achieving an accuracy of around 39%. The improved CNN model with class balancing provided higher accuracy (73%), but still had limitations when classifying rare and visually similar categories. The MobileNetV2 model, which uses transfer learning and clinical metadata integration, demonstrated the best performance. A test accuracy of 81% was achieved, while recall for melanoma increased from 0.38 in the baseline CNN to 0.60, significantly reducing the likelihood of missing the most dangerous disease.

The Grad-CAM method was used to interpret the decisions, allowing us to visualize the model's areas of attention and identify the causes of errors. The results obtained confirm the promise of deep learning in decision support tasks in dermatology and highlight the need for further clinical validation and expansion of the database.

#### Түйінді сөздер:

машиналық оқыту, тері  
ауруларының жіктелуі,  
конволюциялық  
нейрондық желілер,

#### ТҮЙІНДЕМЕ

Мақалада дермоскопиялық кескіндер бойынша тері ауруларын автоматтандырылған жіктеу міндетіне қолданылатын машиналық оқытудың заманауи әдістері қарастырылады. Конволюциялық нейрондық желілердің архитектурасына және алдын ала дайындалған



© 2026 T. Sadvakassov, G. Soltan, T. Karibekov, S. Abdrakhmanova

This work is licensed under a Creative Commons Attribution 4.0

International License (CC BY 4.0).

<https://creativecommons.org/licenses/by/4.0/>

трансферлік оқыту, терең оқыту, медициналық диагностика.

модельдермен трансферлік оқытуды қолдануға ерекше назар аударылады. Эксперименттік база ретінде HAM10000 жалпыға қол жетімді деректер жиынтығы пайдаланылды, оның ішінде терінің жеті түрінің суреттері, сондай-ақ пациенттердің клиникалық метадеректері (жынысы, жасы және локализациясы) бар.

Зерттеу барысында бірнеше модельдер енгізіліп, сыналды. Нәтиженің үйретілген негізгі конволюциялық нейрондық желі (CNN) шектеулі нәтижелерге қол жеткізіп, шамамен 39 % дәлдікке қол жеткізді. Жақсартылған CNN сыныпты теңдестіру моделі жоғары дәлдікті қамтамасыз етті (73 %), бірақ сирек кездесетін және визуалды ұқсас санаттарды жіктеуде әлі де шектеулер болды. Трансферлік оқыту мен клиникалық метадеректерді біріктіруді қолданатын MobileNetV2 моделі ең жақсы көрсеткіштерді көрсетті. 81 % сынақ дәлдігіне қол жеткізілді, меланома үшін толықтығы (recall) негізгі CNN-де 0.38-ден 0.60-қа дейін өсті, бұл ең қауіпті ауруды өткізіп жіберу мүмкіндігін айтарлықтай төмендетеді.

Шешімдерді түсіндіру үшін Grad-Cam әдісі қолданылды, бұл модельдің назар аудару аймақтарын визуализациялауға және қателіктердің себептерін анықтауға мүмкіндік берді. Нәтижелер дерматологиядағы шешім қабылдауды қолдау міндеттерінде терең оқытуды қолдану перспективасын растайды және одан әрі клиникалық валидация мен мәліметтер базасын кеңейту қажеттілігін көрсетеді.

---

**Ключевые слова:**

машинное обучение, классификация кожных заболеваний, сверточные нейронные сети, трансферное обучение, глубокое обучение, медицинская диагностика.

---

**АННОТАЦИЯ**

В статье рассматриваются современные методы машинного обучения, применимые к задаче автоматизированной классификации кожных заболеваний по дермоскопическим изображениям. Особое внимание уделено архитектурам сверточных нейронных сетей и использованию трансферного обучения с предобученными моделями. В качестве экспериментальной базы использован общедоступный набор данных HAM10000, включающий изображения семи типов кожных новообразований, а также клинические метаданные пациентов (пол, возраст и локализация).

В ходе исследования реализованы и протестированы несколько моделей. Базовая сверточная нейронная сеть (CNN), обученная с нуля, показала ограниченные результаты, достигая точности около 39%. Улучшенная модель CNN с балансировкой классов обеспечила более высокую точность (73%), но по-прежнему имела ограничения при классификации редких и визуально схожих категорий. Наилучшие показатели продемонстрировала модель MobileNetV2, использующая трансферное обучение и интеграцию клинических метаданных. Достигнута тестовая точность 81%, при этом полнота (recall) для меланомы выросла с 0,38 в базовой CNN до 0.60, что существенно снижает вероятность пропуска наиболее опасного заболевания.

Для интерпретации решений применялась методика Grad-CAM, позволившая визуализировать области внимания модели и выявить причины ошибок. Полученные результаты подтверждают перспективность применения глубокого обучения в задачах поддержки принятия решений в дерматологии и подчёркивают необходимость дальнейшей клинической валидации и расширения базы данных.

---

## INTRODUCTION

Skin and subcutaneous diseases remain a significant medical and social problem worldwide. According to data from the Global Burden of Disease (GBD-2019), approximately 4.86 billion new cases of skin disease are registered annually, placing them in 7th place among global causes of temporary disability. Melanoma poses a particular danger – it is one of the most aggressive forms of skin cancer, accounting for only a small percentage of all dermatological cases, but characterized by a high mortality rate. According to the World Health Organization, more than 325 000 new cases of melanoma are diagnosed worldwide each year, with more than 57 000 deaths related to this disease. Early diagnosis significantly increases survival rates: in stages I–II, the five-year survival rate exceeds 90%, whereas late detection leads to a sharp decline.

In Kazakhstan, diseases of the skin and subcutaneous tissue traditionally occupy a high position in the structure of morbidity among the population, ranking fifth among all classes of diseases. The urgency of the problem is exacerbated by a shortage of dermatologists, especially in rural areas, as well as an increase in the number of consultations via telemedicine services. With limited access to experts and a heavy burden on the healthcare system, there is a need for tools that can provide rapid, standardized, and reproducible assessment of skin lesion images (Aitkazinova et al., 2024).

Traditional diagnostic methods include visual examination and dermatoscopy. Despite their effectiveness when performed by a highly skilled physician, such methods are subject to subjective errors and depend on the specialist's experience, the quality of the equipment, and lighting conditions. This leads to the risk of early stages of melanoma not being detected, especially at the primary health care level. In these conditions, the digitization of healthcare and the development of machine learning technologies create the conditions for the introduction of decision support systems. Modern mobile device cameras and accumulated databases of dermatoscopic images open up the possibility of developing algorithms that can act as a "second reader" and help doctors identify suspicious cases for further examination.

In recent years, machine learning, and especially convolutional neural networks (CNNs), has become the de facto standard in medical image analysis. In radiology, ophthalmology and pathology, CNN-based systems have already demonstrated expert-level performance in classification, segmentation and detection tasks (Haggenmüller et al., 2021; Wu et al., 2022; Esteva et al., 2019). According to Esteva et al. (2019), CNNs have become a standard tool in medical imaging because they can automatically extract complex spatial features without hand-crafted descriptors. In dermatology, multiple studies report that CNNs can reach or even match the diagnostic accuracy of expert dermatologists under controlled conditions, making them a natural candidate for automated triage and decision support (Cerminara et al., 2023; Rahkonen et al., 2019). At the same time, the translation of these results into routine clinical practice is still limited by data imbalance, heterogeneity of imaging protocols and the need for interpretable, well-calibrated predictions.

One of the key tasks in developing such systems is ensuring the reliability and reproducibility of results when working with images of varying quality and origin.

One of the most popular and accessible benchmark datasets for research is HAM10000, which includes 10,015 images of seven types of skin lesions. The dataset is widely used for testing architectures and learning protocols and has become the de facto standard for multi-class classification tasks. However, it has some limitations, including a significant class imbalance (more than 67% of images are related to nevus), the presence of duplicate images, and partial histological verification of diagnoses (Cassidy et al., 2022; Aydin et al., 2023). These factors require the use of additional techniques – augmentation, class balancing, specialized loss functions, and careful validation at the patient level. In addition, testing models on clinical images obtained in real-world conditions, rather than just in standardized imaging conditions, is becoming an important area of focus.

Recent studies show that the best results are achieved when using pre-trained models with transfer learning. Architectures such as ResNet, EfficientNet, and MobileNet provide higher accuracy and stability compared to training from scratch (Manole et al., 2024; Venugopal et al., 2023). In addition to architecture, the choice of model fine-tuning strategy, including the use of cyclic learning rate changes, regularization, and overfitting control methods, is of particular importance. At the same time, increasing attention is being paid to the integration of clinical metadata (gender, age, location), which allows the model to be brought closer to real-world conditions. This multimodal approach enhances diagnostic accuracy and model robustness, especially in the presence of rare or atypical lesions. All the same, explainable AI is also developing: attention visualization methods (Grad-CAM) help identify which features are taken into account by the model, thereby increasing doctors' confidence (van der Velden et al., 2022; Borys et al., 2023). Methods such as Integrated Gradients and Score-CAM are also used to provide a deeper understanding of the model's logic when making decisions, especially in situations where an explanation is needed as to why a particular case is classified as suspicious. (Hauser et al., 2022). Approaches to combining heterogeneous data sources can be identified. Multimodal architectures that use cross-attention mechanisms allow for the coordinated consideration of images and accompanying clinical information, improving the model's generalizability (Le et al., 2025).

Thus, despite significant progress in the field of computer dermatology, a research gap remains: most studies focus solely on images and rarely include clinical context or interpretability assessments. This study aims to fill this gap by developing and comparing CNN and MobileNetV2 models with the integration of clinical data and the use of explainable AI methods, making its results more relevant to real-world clinical practice.

One of the key technological strategies is transfer learning, the use of models pre-trained on large general collections (e.g., ImageNet) followed by further training on specialized dermatological data. This approach accelerates convergence, reduces the requirements for the size of the marked sample, and increases the generalizability. Modern architectures (ResNet, Inception, EfficientNet) provide a flexible balance between accuracy and computational cost, while regularization and augmentation techniques help combat overfitting. In recent years, particular attention has been paid to the EfficientNet architecture, which demonstrates high accuracy with fewer parameters, making it particularly suitable for telemedicine solutions (Manole et al., 2024). It is also worth noting MobileNetV2, which is actively used in applications for screening skin diseases, thanks to its compactness and high performance (Nirupama et al., 2024). The calibration of probabilistic model inferences plays a particularly important role. These methods help to improve the reliability of predictions and avoid underestimating or overestimating risk, which is particularly important in the early detection of melanoma.

The advantages of ML in this context are high speed, reproducibility of results, and technical suitability for integration into clinical systems (web interfaces, PACS/EMR modules, mobile applications) provided that probabilities are correctly calibrated and risk management is well thought out. Modern solutions are increasingly being developed with the possibility of integration into telemedicine platforms in mind, providing remote access to diagnostics and second opinions from doctors.

A separate area is the development of explainable AI (XAI), which is particularly relevant in dermatology. Grad-CAM, Integrated Gradients, and Score-CAM methods allow visualizing which areas of the image the model should pay attention to, thereby increasing doctors' confidence and facilitating the interpretation of results (Hauser et al., 2022). The integration of such tools has become particularly important in situations where AI is used as an element of clinical decision-making rather than simply as an auxiliary analysis tool.

Recent systematic reviews highlight a gradual shift from experimental “reader” studies towards validated clinical deployments of deep learning in dermatology. While convolutional neural networks show promising sensitivity in detecting malignant lesions, their real-world performance strongly depends on image acquisition protocols, patient pathways and decision thresholds, and therefore requires prospective evaluation and robustness assessment across diverse clinical sites [1–4]. Work performed in real-world settings (total body photography, in-clinic dermatoscopy) underlines both the potential and the limitations of augmented intelligence in dermatology: CNNs can improve early detection, but specificity and overall reliability remain highly context-dependent.

*Data and metrics.* The open dataset HAM10000 was used as the experimental basis, containing 10,015 dermatoscopic images of seven types of skin neoplasms: actinic keratosis and intradermal carcinoma (akiec), basal cell carcinoma (bcc), benign keratosis-like lesions (bkl), dermatofibroma (df), melanoma (mel), nevus (nv), and vascular lesions (vasc). The dataset is widely used in research from 2019 to 2025 and is effectively the standard for multi-class classification of dermatoscopic images.

When using HAM10000, there is one key threat to validity. This is a pronounced imbalance between classes: more than 67% of images relate to nevus, while categories such as dermatofibroma or actinic keratosis are represented much less frequently. This leads to a shift in the model towards the dominant class and reduces recall for rare classes. Recent studies recommend using stratified or patient/lesion-level divisions, as well as techniques to combat imbalance: augmentation, class weighting, and specialized loss functions. In our study, stratification and class weight adjustment were applied, which helped to mitigate imbalances and increase the stability of the results.

Standard metrics were used to evaluate the quality of classification: accuracy, precision, recall, and F1 score. Additionally, a confusion matrix and classification report were constructed, which made it possible to identify the most problematic classes and analyze the nature of the model's errors.

*Transfer learning as the de facto standard.* Comparative studies confirm the consistent superiority of fine-tuning pre-trained ImageNet models (ResNet, DenseNet, Inception, EfficientNet) over training from scratch on moderately sized medical datasets. This provides better generalization ability and faster convergence; for HAM10000, the best “quality/resources” trade-offs are often achieved by the EfficientNet (B0–B5/B7) [5,9–11]. At the same time, transformer and hybrid (CNN+Transformer) variants are being investigated, which improve global context extraction and, with correct fine-tuning and regularization, provide an increase in ROC-AUC/macro-F1 [12–14]. Transfer learning has effectively become the de facto standard for HAM10000. Comparative studies consistently report overall accuracies in the mid-80% to mid-90% range when ImageNet-pretrained backbones are fine-tuned on dermoscopic images. For example, Aydin et al. achieved an accuracy of 96.5% and F1-score of 0.96 on HAM10000 using color histogram-based local descriptors combined with an XGBoost classifier (Aydin, 2023). Alam et al. reported that their RegNetY-320 model, trained with extensive augmentation, reached 91% accuracy, F1-score of 0.88 and ROC-AUC of 0.95 on the same dataset (Alam, 2022). Tajerian et al. fine-tuned an EfficientNet-B1 architecture and obtained 84.3% overall accuracy on HAM10000, with class-wise F1-scores ranging from 0.54 to 0.93 and melanoma F1-score of 0.58, highlighting the persistent difficulty of minority classes (Tajerian, 2023). A recent survey further summarizes that EfficientNet-B4 trained on HAM10000 can reach 87.9% accuracy (Ali et al., 2022), while transformer-based models such as SkinTrans/ViT achieve up to 94.3% accuracy on the same benchmark (Manole, 2024).

Taken together, these results indicate that modern transfer-learning pipelines with EfficientNet-like or transformer backbones define a strong state-of-the-art baseline for

HAM10000, but still leave room for improvement in the detection of under-represented lesions such as melanoma.

*Working with imbalance and overall stability.* The best results are demonstrated by combinations of targeted augmentation (random crop/flip, color jitter, CutMix/MixUp), class weights, or Focal-loss, as well as ensemble architectures. Individual studies show gains from combining EfficientNet with additional attention blocks and/or cascade ensembling; a correct validation procedure (k-fold with stratification at the lesion level) remains an important factor for stability [6–8,10,11].

*Interpretability and clinical integration.* Decision support systems require explainability and verification of the "plausibility" of explanations from a dermatologist's point of view. A review of XAI in medical imaging emphasizes that heat maps (Grad-CAM, etc.) must be supplemented with validation of the correctness of explanations and control of "provoked artifacts," otherwise the increase in model accuracy will not be accompanied by an increase in clinical confidence [15–17]. Publications in dermatology also draw attention to interfaces that enable the sharing of explanations between doctors and AI (human-AI teaming) [2,4].

*Issues and challenges.* Despite significant progress in the application of the deep learning approach to dermatological diagnosis tasks, there remain a number of unresolved issues that limit the practical implementation of such systems. One of the key obstacles is the limited and inconsistent labeling in open datasets. For example, in HAM10000, some diagnoses are histologically confirmed, while others are based on clinical judgment or expert consensus, which reduces the homogeneity of reference labels and may lead to bias in training results.

Another significant factor is the pronounced imbalance between classes: the predominance of images of nevi and the lack of rare and clinically significant categories (such as melanoma or dermatofibroma) leads to a shift in the model toward "common" diagnoses and reduces the completeness of dangerous classes. To overcome this limitation, targeted augmentations, the use of specialized loss functions (Focal Loss), or synthetic data augmentation are required.

Additional problems remain due to differences in imaging devices, image acquisition protocols, patient populations, and the presence of artifacts (hair, glare, marks). These factors reduce the transferability of models trained on a single dataset to real-world clinical practice. The solution may be external and prospective validation using independent data sources, as well as verification of the calibration of probabilistic predictions.

Special attention should be paid to the interpretability of algorithms. Explainable AI methods, such as Grad-CAM, allow visualization of the model's areas of focus, but require critical review by experts to eliminate reliance on irrelevant features and increase trust in the system.

Finally, risk management and ethical compliance play an important role. Protecting personal data, ensuring fairness between different patient groups, and clearly documenting limitations and safe usage scenarios remain necessary conditions for integrating such technologies into medical practice.

*Scientific novelty of the project.* The scientific novelty of the project lies in the development of a multimodal approach to the automated classification of skin lesions, which combines the analysis of dermatoscopic images and clinical metadata (gender, age, location). This approach takes into account the real-world context of a dermatologist's work and improves the accuracy and completeness of classification compared to models that use only visual information.

Unlike most existing studies, this work directly compares a basic CNN trained from scratch with a pre-trained MobileNetV2 architecture using transfer learning. The multimodal version of MobileNetV2 demonstrated a significant increase in completeness for the melanoma class (from 0.38 to 0.60), which is of high clinical significance as it reduces the likelihood of missing the most dangerous type of tumors.

Additionally, scientific novelty is determined by the use of interpretable AI methods (Grad-CAM) to analyze model decisions. Visualization of areas of attention has made it possible not only to identify key features that influence classification, but also to show potential sources of error (e.g., focus on artifacts). This ensures a higher level of trust on the part of physicians and opens up opportunities for joint use of the system by specialists.

Finally, the paper critically examines the limitations of the HAM10000 dataset, including the heterogeneity of diagnosis verification methods, which is rarely taken into account in applied research. Thus, the project contributes to the development of medical decision support systems by offering a practice-oriented, interpretable, and clinically relevant approach to the diagnosis of skin diseases.

## MATERIALS AND METHODS

As mentioned earlier, the HAM10000 (Human Against Machine with 10,000 training images) dataset, which is open and widely recognized in the scientific community, was used as the experimental basis for this work. This dataset is a collection of 10,015 dermatoscopic images covering seven different types of skin lesions and serves as an important resource for the automatic classification and diagnosis of dermatological diseases using machine learning and computer vision methods.

Each image in HAM10000 is accompanied by a label indicating the type of neoplasm, which allows it to be used as a training sample for building and evaluating classification models. The types of skin lesions represented in the dataset include both malignant and benign formations, providing the diversity and balance necessary for reliable algorithm training: actinic keratosis and intradermal carcinoma (akiec), basal cell carcinoma (bcc), benign keratosis-like lesions (bkl), dermatofibroma (df), melanoma (mel), nevus (nv), and vascular lesions (vasc).


Below is a summary table showing the distribution of images by class. It shows the name of the class, its designation, the number of images belonging to that type, and the percentage of the total number of examples:

**Table 1.** Dataset distribution

Class	Designation	Number of images	Percentage of total
Actinic keratosis / carcinoma	akiec	327	3.3%
Basal cell carcinoma	bcc	514	5.1%
Benign keratosis-like lesions	bkl	1 099	11.0%
Dermatofibroma	df	115	1.1%
Melanoma	mel	1 113	11.1%
Nevus	nv	6 705	67.0%
Vascular lesions	vasc	142	1.4%
Total	-	10 015	100%

*Note – compiled by the authors*

Clinical metadata is available for some images: gender, age, and lesion location. This data was integrated into the model as an additional source of information.



**Figure 1.** Examples of dermatoscopic images for each lesion class.


*Note – compiled by the authors*

During the preprocessing stage, images were scaled to 128×128 pixels and normalized to the range [0,1]. To reduce the risk of overfitting, standard augmentation techniques were used: horizontal and vertical reflections, random rotations, and brightness changes. To combat class imbalance, class weighting was applied during training, which compensated for the predominance of nevi and increased completeness for rare categories.

Two groups of deep learning models were implemented. The baseline convolutional neural network (CNN) trained from scratch consisted of several convolutional blocks with 3×3 kernels (32 and 64 filters), each followed by BatchNormalization and MaxPooling2D layers, a Flatten operation and two fully connected layers with 64 units and ReLU activation. The final classification layer was a dense layer with 7 units and softmax activation, corresponding to the seven lesion classes.

In the multimodal variant, the image branch was complemented with a metadata branch that processed patient sex, age and lesion location. Categorical variables were one-hot encoded, concatenated with normalized age and passed through a dense layer with 64 units and ReLU activation to obtain a metadata embedding. The outputs of the image branch (64-dimensional feature vector) and the metadata branch (64-dimensional embedding) were concatenated into a 128-dimensional vector, followed by a dense layer with 64 units and ReLU activation and the final 7-way softmax classifier. For the MobileNetV2-based models, the convolutional backbone pre-trained on ImageNet was used as a fixed feature extractor, followed by GlobalAveragePooling2D and the same multimodal fusion block as described above.

Training was performed using the Adam optimizer with an initial learning rate of 0.001 and the sparse categorical cross-entropy loss function, while accuracy was used as the primary monitoring metric. The dataset was stratified by class and split into training and test subsets in an 80/20 ratio; within the training subset, 10–20% of the data were further reserved as a validation set by using the validation\_split option in Keras. EarlyStopping (monitoring validation loss with a patience of 6 epochs) and ReduceLROnPlateau (factor 0.5, patience 4) callbacks were applied to prevent overfitting and stabilize convergence. Training was conducted for up to 30 epochs with a batch size of 32, using class weights inversely proportional to class frequencies to mitigate the strong class imbalance. Standard metrics (accuracy, precision, recall, and F1-score), as well as a confusion matrix and a per-class classification report, were used to evaluate model performance.



**Figure 2.** Grad-CAM visualization for a dermoscopic image. The highlighted red region shows the areas most influential for the model's prediction

*Note – compiled by the authors*

## RESULTS AND DISCUSSION

During the experiments, we evaluated several configurations belonging to two deep learning architecture families: a convolutional neural network (CNN) trained from scratch and a MobileNetV2 model with transfer learning. Within these two families, four main configurations were analyzed: (1) a simple baseline CNN trained on a small balanced subset of the HAM10000 dataset, (2) an improved CNN trained on the full dataset with class weighting and data augmentation, (3) a MobileNetV2-based model using only dermoscopic images, and (4) the final multimodal MobileNetV2 model that combines image features with clinical metadata (sex, age and lesion location).

The key characteristics and performance metrics of these four configurations are summarized in Table 2. The table reports test accuracy for each model and recall for the melanoma class, which is the most safety-critical outcome in this setting.

**Table 2.** Summary of evaluated models and their performance on the HAM10000 test set.

Model	Input data	Additional techniques	Test accuracy
Baseline CNN	Dermoscopic images, small balanced subset	No metadata, no class weighting	0.39
Improved CNN	Dermoscopic images, full HAM10000	Class weighting, data augmentation	0.73
MobileNetV2	Dermoscopic images, full HAM10000	Transfer learning, class weighting	0.53
Multimodal MobileNetV2	Images + metadata	Transfer learning, class weighting, metadata fusion	0.81

*Note – compiled by the authors*

First, we analyzed the CNN-based configurations. The simplest baseline CNN, trained from scratch on a small balanced subset of the HAM10000 dataset, achieved only about 0.39 test accuracy. This result confirms that training a shallow architecture on limited data leads to underfitting and unstable generalization.

When the same CNN architecture was retrained on the full HAM10000 dataset with class weighting and data augmentation, the test accuracy increased to approximately 0.73. However, the confusion matrix still revealed systematic errors for rare categories such as dermatofibroma (df) and actinic keratoses (akiec), as well as persistent confusion between melanoma and other pigmented lesions. Thus, even the improved CNN trained from scratch remained limited when dealing with the heterogeneous and imbalanced real-world data.

Figure 3 shows the confusion matrix for the final multimodal MobileNetV2 model on the HAM10000 test set. Most errors arise between visually similar pigmented lesions such as nevus (nv), benign keratosis-like lesions (bkl) and melanoma (mel), as well as between bkl and actinic keratoses (akiec), which is consistent with previous work on this dataset.

For the MobileNetV2-based models, using transfer learning already provided a noticeable improvement compared to the CNN family. A MobileNetV2 model that used only dermoscopic images and class weighting reached a test accuracy of about 0.53, outperforming the baseline CNN trained on a small subset. However, the most substantial gain was obtained when clinical metadata were added as a second input branch. The multimodal MobileNetV2 model that combined image features with sex, age and lesion location achieved the best overall performance, with a test accuracy of 0.81. This improvement in sensitivity was obtained without a substantial drop in overall specificity, highlighting the benefits of using pre-trained weights together with additional clinical context.



**Figure 3.** Confusion matrix for the multimodal MobileNetV2 model on the HAM10000 test set.

*Note – compiled by the authors*

	precision	recall	f1-score	support
akiec	0.70	0.68	0.69	65
bcc	0.69	0.87	0.77	103
bkl	0.70	0.68	0.69	220
df	0.89	0.70	0.78	23
mel	0.66	0.53	0.59	223
nv	0.92	0.94	0.93	1341
vasc	0.92	0.86	0.89	28
accuracy			0.85	2003
macro avg	0.78	0.75	0.76	2003
weighted avg	0.85	0.85	0.85	2003

**Figure 4.** Classification report for MobileNetV2 with integrated metadata, showing precision, recall, and F1-score across all seven lesion categories

*Note – compiled by the authors*

Overall, the experiments demonstrate a consistent improvement in performance as the models become more expressive and make better use of the available data (Table 2). Moving from a shallow CNN trained on a small balanced subset to an improved CNN on the full dataset yields a clear gain in accuracy, but the most clinically relevant improvements are achieved by combining transfer learning with multimodal fusion of clinical metadata in the MobileNetV2 family.

A comparison with previously published work on the HAM10000 dataset and related dermatoscopic benchmarks shows that the obtained results are competitive with other deep

learning approaches. Many earlier studies focused exclusively on image-based models, whereas our findings support the growing evidence that integrating visual and clinical information can improve both accuracy and sensitivity in skin cancer screening. At the same time, the remaining limitations highlighted in the confusion matrices and per-class metrics indicate the need for further work on imbalance-handling strategies and external validation before deploying such systems in routine clinical practice.

The use of Grad-CAM made it possible not only to interpret predictions, but also to identify potential sources of model errors. Analysis of heat maps showed that in cases of correct classification, the network focused on morphologically significant structures (e.g., melanoma pigment patterns), while in cases of error, attention shifted to artifacts (hair coverings, heterogeneous textures, glare). This coincides with the findings of studies on explainable AI (van der Velden et al., 2022; Borys et al., 2023), which emphasize the need to verify the "plausibility" of explanations in order to increase the trust of physicians.

However, the study has a number of limitations. First, the HAM10000 dataset is characterized by a pronounced class imbalance: more than 67% of images are non-nevi, while rare categories are extremely limited. Second, some of the diagnoses in the dataset are not histologically confirmed, which reduces the reliability of the reference labels (Cassidy et al., 2022). Third, the experiments did not include external validation on independent datasets (e.g., ISIC 2020, 2023), which is necessary to verify the model's transferability to new patient populations. In this work we did not investigate specialized loss functions such as Focal Loss or more aggressive synthetic augmentation strategies; these techniques are expected to further improve recall for rare classes and are therefore planned for future experiments.

Thus, the results of the study confirm the potential of deep learning for decision support tasks in dermatology, especially in the format of multimodal architectures. However, for practical implementation, it is necessary to solve the problems of class imbalance, clinical validation on external data, and the development of interfaces that allow doctors to jointly use model explanations.

## CONCLUSION

This paper investigates deep learning methods for automated classification of skin lesions based on dermatoscopic images using the open-source HAM10000 dataset. A comparison of two approaches is implemented: a basic convolutional neural network (CNN) trained from scratch, and the MobileNetV2 architecture using transfer learning and integration of clinical metadata (gender, age, location).

The results showed that MobileNetV2 significantly outperforms the best CNN configuration in terms of overall accuracy (0.81 vs. 0.73) and recall for the most dangerous class, melanoma (0.60 vs. 0.38).

The use of Grad-CAM made it possible to analyze the model's decision-making process and demonstrated that the areas of focus coincided with clinically significant areas of the image, which increases doctors' confidence in the system. However, challenges remain related to class imbalance in the dataset, limited histological verification, and the need for external validation on independent datasets.

The practical value of this study lies in the fact that the proposed approach can be used to create decision support tools for dermatological practice. In particular, such systems can be integrated into telemedicine services and mobile applications for primary screening, which will reduce the burden on specialists and increase the availability of early diagnosis.

In the future, we plan to expand the experimental base by using more diverse datasets (e.g., ISIC 2020, 2023), investigating specialized loss functions such as Focal Loss to combat class imbalance, and introducing next-generation multimodal architectures, including transformer

models. This will create the conditions for the development of clinically reliable, interpretable, and scalable decision support systems in dermatology.

**CONFLICT OF INTEREST:** The authors declare no conflict of interest.

**FUNDING:** No funding was received for the preparation of this article.

**ACKNOWLEDGEMENTS:** The authors express their gratitude to colleagues for methodological support and helpful discussions, as well as to anonymous reviewers for valuable comments that helped improve the quality of the article.


**STATEMENT ON THE USE OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES:** No artificial intelligence (AI) technologies were used at any stage in the preparation of this article.

## REFERENCES

- Haggenmüller S., Maron R.C., Hekler A., et al. (2021). Skin cancer classification via convolutional neural networks: systematic review of studies involving human experts. *European Journal of Cancer*. 156, 202–216. <https://doi.org/10.1016/j.ejca.2021.06.049>
- Cerminara S.E., Cheng P., Kostner L., et al. (2023). Diagnostic performance of augmented intelligence with 2D and 3D total body photography and convolutional neural networks in a high-risk population for melanoma under real-world conditions. *European Journal of Cancer*. 190, 112954. <https://doi.org/10.1016/j.ejca.2023.112954>
- Wu Y., Xu H., Zhang J., et al. (2022). Skin Cancer Classification With Deep Learning: A Systematic Review. *Frontiers in Oncology*. 12, 893972. <https://doi.org/10.3389/fonc.2022.893972>
- Jain A., et al. (2021). AI-Based Tool for Skin Condition Diagnosis in Primary Care. *JAMA Network Open*. 4, 217249. <https://doi.org/10.1001/jamanetworkopen.2021.7249>
- Aydin Y., et al. (2023). A Comparative Analysis of Skin Cancer Detection Methods Using HAM10000. *PLOS ONE*. 18 (10), 0289870. <https://doi.org/10.1371/journal.pone.0289870>
- Tajerian A., et al. (2023). Design and validation of a new machine-learning-based approach using HAM10000 dermoscopy images. *PLOS ONE*. 18 (5), 0284437. <https://doi.org/10.1371/journal.pone.0284437>
- Alam T.M., et al. (2022). An Efficient Deep Learning-Based Skin Cancer Classifier (imbalanced HAM10000). *Computational Intelligence and Neuroscience*. 7801342. <https://doi.org/10.1155/2022/7801342>
- Cassidy B., Kendrick C., Soyer H.P., et al. (2022). Analysis of the ISIC image datasets: usage, benchmarks and recommendations. *Medical Image Analysis*. 75, 102305. <https://doi.org/10.1016/j.media.2021.102305>
- Manole I., et al. (2024). Enhancing Dermatological Diagnostics with EfficientNet. *Bioengineering*. 11 (8), 810. <https://doi.org/10.3390/bioengineering11080810>
- Venugopal V., et al. (2023). A deep neural network using modified EfficientNet for skin lesion classification. *Intelligent Medicine*. 3(3), 100105. <https://doi.org/10.1016/j.imed.2023.100105>
- Shetty B., et al. (2022). Skin lesion classification of dermoscopic images using deep learning. *Scientific Reports*. 12, 19224. <https://doi.org/10.1038/s41598-022-22644-9>
- Xin C., et al. (2022). An improved transformer network for skin cancer classification. *Computers in Biology and Medicine*. 149, 105939. <https://doi.org/10.1016/j.combiomed.2022.105939>
- Yang G., Luo S., Greer P. (2023). A novel vision transformer model for skin cancer classification. *Neural Processing Letters*. <https://doi.org/10.1007/s11063-023-11204-5>
- Himel G.M.S., et al. (2024) Skin Cancer Segmentation and Classification Using Vision Transformer. *Healthcare*. 12 (2), 139. <https://doi.org/10.3390/healthcare12020139>
- van der Velden B.H.M., Kuijff H.J., Gilhuijs K.G.A., Viergever M.A. (2022). Explainable AI in deep learning-based medical image analysis. *Medical Image Analysis*. 79, 102470. <https://doi.org/10.1016/j.media.2022.102470>

- Borys K., et al. (2023). Explainable AI in medical imaging: Beyond saliency-based approaches. *European Journal of Radiology*. 164, 110876. <https://doi.org/10.1016/j.ejrad.2023.110876>
- Miller I., et al. (2024). Performance of commercial dermatoscopic systems with AI. *Cancers*. 16 (7), 1443. <https://doi.org/10.3390/cancers16071443>
- Aitkazanova A., Saimova A., Urazayeva A. (2024). Epidemiological situation of skin cancer and melanoma in the Republic of Kazakhstan in 2012–2022. *ResearchGate*. <https://doi.org/10.13140/RG.2.2.22583.70564>
- Zhou H., Wang Y., Li X., et al. (2024). Accurate Skin Lesion Classification Using Multimodal Learning on the HAM10000 Dataset. *medRxiv*. <https://doi.org/10.1101/2024.05.30.24308213>
- Khan M., Ahmed S., Javed H., et al. (2023). A Novel Transfer Learning Framework for Multimodal Skin Lesion Analysis. *Applied Sciences*. 13 (21), 11974. <https://doi.org/10.3390/app132111974>
- Rai R., Chawla A., Gupta P., et al. (2025). Comparative analysis of multimodal architectures for effective skin lesion classification. *Frontiers in Artificial Intelligence*. 8, 1608837. <https://doi.org/10.3389/frai.2025.1608837>
- Hauser K., Kurz A., Meier F., et al. (2022). Explainable artificial intelligence in skin cancer recognition: A systematic review. *Medical Image Analysis*. 78, 102433. <https://doi.org/10.1016/j.ejca.2022.02.025>
- Tran-Van N.-Y. and Le K.-H. (2025). A multimodal skin lesion classification through cross-attention fusion and collaborative edge computing. *Comput. Med. Imaging Graph*. 124, 102588. <https://doi.org/10.1016/j.compmedimag.2025.102588>
- Esteva A., Robicquet A., Ramsundar B., et al. (2019). A guide to deep learning in healthcare. *Nat. Med*. 25 (1), 24. <https://doi.org/10.1038/s41591-018-0316-z>
- Rahkonen S., Neittaanmäki N., et al. (2019). Convolutional neural networks in skin cancer detection using spatial and spectral domain. *Proc. Photonics in Dermatology and Plastic Surgery*. <https://doi.org/10.1117/12.2509871>
- Nirupama and Virupakshappa (2024). MobileNet-V2: An enhanced skin disease classification by attention and multi-scale features. *J. Imaging Inform. Med*. 38 (7). <https://doi.org/10.1007/s10278-024-01271-y>

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Садвакасов Темирлан** – Компьютерлік ғылымдар және инженерия бағытындағы студент – магистрі, Astana IT University, Астана, Қазақстан

**Садвакасов Темирлан** – Студент магистратуры по направлению компьютерные науки и инженерия, Astana IT University, г. Астана, Казахстан

**Sadvakassov Temirlan** – Master’s student of Computer Science and Engineering, Astana IT University, Astana, Kazakhstan,

e-mail: imtims.17@gmail.com,

ORCID: <https://orcid.org/0009-0001-2423-1706>,



**Солтан Гульжан** – техника ғылымдарының кандидаты, Компьютерлік инженерия мектебінің Associate Professor-i, Astana IT University, Астана қ., Қазақстан

**Солтан Гульжан** – кандидат технических наук, Associate Professor школы компьютерной инженерии, Astana IT University, г. Астана, Казахстан

**Soltan Gulzhan** – Candidate of Technical Sciences, Associate Professor, Department of Computer Engineering, Astana IT University, Astana, Kazakhstan,

e-mail: gulzhan.soltan@astanait.edu.kz,

ORCID: <https://orcid.org/0000-0002-1603-7524>,



**Карибеков Темирлан** – медицина ғылымының докторы, S&IC «MedTech» директоры, Astana IT University, Астана, Қазақстан

**Карибеков Темирлан** – доктор медицинских наук, директор S&IC «MedTech», Astana IT University, г. Астана, Казахстан

**Karibekov Temirlan** – Doctor of Medical Sciences, Director S&IC «MedTech», Astana IT University, Astana, Kazakhstan,

e-mail: t.karibekov@astanait.edu.kz,

ORCID: <https://orcid.org/0009-0008-9801-1774>,



**Абдрахманова Саида** – Компьютерлік ғылымдар және инженерия бағытындағы студент – магистрі, Astana IT University, Астана, Қазақстан

**Абдрахманова Саида** – Студент магистратуры по направлению компьютерные науки и инженерия, Astana IT University, г. Астана, Казахстан

**Abdrakhmanova Saida** – Master’s student of Computer Science and Engineering, Astana IT University, Astana, Kazakhstan,

e-mail: abdrahmanovasaida48@gmail.com,

ORCID: <https://orcid.org/0009-0008-2800-4704>

---

---

[https://doi.org/10.51885/3134-8025\\_IICS\\_2026\\_1\\_8](https://doi.org/10.51885/3134-8025_IICS_2026_1_8)

XFTAP 76.29.45

**ИНТЕНСИВТІ ТЕРАПИЯДАҒЫ ӨЛІМ-ЖІТІМ  
МОДЕЛЬДЕРІНДЕГІ УАҚЫТША ТҰРАҚТЫЛЫҚ  
ПЕН ҮЛЕСТІРІМ ДРЕЙФІ:  
MIMIC-IV ВАЛИДАЦИЯЛЫҚ ЗЕРТТЕУІ**

**ВРЕМЕННАЯ СТАБИЛЬНОСТЬ И ДРЕЙФ РАСПРЕДЕЛЕНИЯ  
В МОДЕЛЯХ СМЕРТНОСТИ ПАЦИЕНТОВ ОТДЕЛЕНИЙ  
ИНТЕНСИВНОЙ ТЕРАПИИ: ВАЛИДАЦИОННОЕ ИССЛЕДОВАНИЕ  
НА БАЗЕ MIMIC-IV**

**TEMPORAL STABILITY AND DISTRIBUTION DRIFT IN ICU  
MORTALITY MODELS: MIMIC-IV VALIDATION STUDY**

А.М. Исмухамедова <sup>1</sup>, А.П. Баканова <sup>2\*</sup>, С.А. Бельгинова <sup>3</sup>,

А. Халимов <sup>2</sup>, Т. Рысбаев <sup>2</sup>

<sup>1</sup>Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

<sup>2</sup>Қазақстан-Америка Еркін Университеті (ҚАЕУ), Өскемен қ., Қазақстан

<sup>3</sup>«Туран» Университеті, Алматы қ., Қазақстан

\*Жауапты автор: Баканова Анна Павловна, [bakanova55anna@gmail.com](mailto:bakanova55anna@gmail.com)

**Түйінді сөздер:**

машиналық оқыту,  
интенсивті терапия,  
уақытша дрейф,  
үлестірім ауысуы,  
LightGBM, PSI, модель  
калибрлеуі, SHAP  
талдауы.

**ТҮЙІНДЕМЕ**

Машиналық оқыту модельдері клиникалық шешімдерді қолдау үшін уақыт өте келе сапасын жоғалтуы мүмкін, себебі уақыттық ауытқу (temporal drift) және пациенттер популяциясындағы өзгерістер болады, бірақ ОАР (Оқшаулау және қарқынды терапия бөлімшесі) ішінде өлімді болжау міндеттерінде ұзақ мерзімді уақыттық бағалаулар әлі де шектеулі болып қалып отыр. Бұл зерттеуде MIMIC-IV деректері негізінде оқытылған LightGBM моделінің уақыттық тұрақтылығы, калибрлеуі және үлестірім ауытқуы бағаланды. Талдау 2008-2019 жылдар аралығындағы ересек пациенттердің 65 355 стационарлық емделу жағдайын қамтыды және үш деңгейлі валидация схемасын қолданды: стандартты, уақыттық және псевдо сыртқы валидация. Модель жоғары дискриминациялық қабілеттілікті көрсетті (AUC-ROC 0,998-ге дейін) және болашақ деректерде тестілеу кезінде калибрлеуі жақсарды. PSI талдауы маңызды белгілер ауытқуының жоқтығын анықтады, ал SHAP талдауы физиологиялық зертханалық көрсеткіштердің шешуші рөлін көрсетті. Нәтижелер негізгі физиологиялық белгілерге негізделген және қатаң валидациядан өткен модельдер жиі қайта оқытусыз көп жыл бойы тұрақтылықты сақтай алатынын көрсетеді.



---

**Ключевые слова:**

машинное обучение, интенсивная терапия, временной дрейф, сдвиг распределения, LightGBM, PSI, калибровка модели, анализ SHAP.

---

**АННОТАЦИЯ**

Модели машинного обучения для поддержки клинических решений могут со временем терять качество из-за временного дрейфа и изменений в популяциях пациентов, однако долгосрочные временные оценки в задачах прогнозирования смертности в ОИТ остаются ограниченными. В данном исследовании оцениваются временная устойчивость, калибровка и дрейф распределения модели LightGBM, обученной на данных MIMIC-IV. Анализ включал 65 355 госпитализаций взрослых пациентов за период 2008-2019 годов и использовал трёхуровневую схему валидации: стандартную, временную и псевдовнешнюю. Модель продемонстрировала высокую дискриминационную способность (AUC-ROC до 0,998) и улучшение калибровки при тестировании на будущих данных. Анализ PSI выявил отсутствие значимого дрейфа признаков, а SHAP-анализ показал ключевую роль физиологических лабораторных показателей. Результаты свидетельствуют о том, что модели, основанные на фундаментальных физиологических признаках и прошедшие строгую валидацию, могут сохранять стабильность в течение многих лет без частого переобучения.

---

**keywords:**

machine learning, intensive care, temporal drift, distribution shift, LightGBM, PSI, model calibration, SHAP analysis.

---

**ABSTRACT**

Machine learning models for clinical decision support can degrade over time due to temporal drift and changes in patient populations; however, long-term temporal evaluations in ICU mortality prediction tasks remain limited. This study assesses the temporal stability, calibration, and distribution drift of a LightGBM model trained on MIMIC-IV data. The analysis included 65,355 adult patient hospitalizations from 2008 to 2019 and employed a three-level validation scheme: standard, temporal, and pseudo-external. The model demonstrated excellent discriminative performance (AUC-ROC up to 0.998) and improved calibration when tested on future data. PSI analysis revealed no significant feature drift, while SHAP analysis highlighted the dominant role of physiological laboratory parameters. The results suggest that models based on fundamental physiological features and subjected to rigorous validation can maintain stability over many years without frequent retraining.

---

**КІРІСПЕ**

Машиналық оқыту (МО) модельдері клиникалық ақпараттық жүйелерге барған сайын енгізіліп, ерте диагностикаға, тәуекелді стратификациялауға және нәтиже болжауға қолдау көрсетуде. Интенсивті терапия бөлімшесінде (ИТБ) ауруханадағы өлім-жітімді болжау модельдері айтарлықтай әлеует көрсетті. Алдыңғы зерттеулер машиналық оқытудың ауруды болжауды оңтайландыру және денсаулық сақтау ресурстарын бөлуді жақсарту мүмкіндігін атап өтті, мысалы, электрондық денсаулық сақтау жазбалары негізінде қант диабеті бойынша жүргізілген зерттеу. Жүргізілген зерттеулер құрылымдалмаған медициналық жазбалардан мәтіндік талдау арқылы өлім-жітімді болжауды да қарастырды, мұнда логистикалық регрессияға негізделген алгоритмдер ауруханадағы күтім сапасын әділ және тиімді бағалауға қолдау көрсете алатынын көрсетті. (Ismukhamedova, Uvaliyeva, Rakhmetullina, 2024). Авторлар Gradient Boosting Machines және Recurrent Neural Networks ең тиімді модельдердің қатарында екенін анықтады, бұл электрондық денсаулық сақтау деректерін клиникалық шешім қабылдауды жақсарту үшін пайдалану бойынша кейінгі зерттеулерге негіз болды (Rakhmetullina, 2024; Ismukhamedova, Uvaliyeva, Belginova, 2024).

Дегенмен, олардың ұзақ мерзімді сенімділігі негізгі алаңдаушылық болып қала береді, өйткені көптеген зерттеулер модель өнімділігінің уақытша дрейф, клиникалық практика өзгерістері және пациенттер популяциясының эволюциясы салдарынан төмендейтінін хабарлайды.

Уақытша дрейф – үлестірім ауысуы деп те аталады – болжамдар мен нәтижелер арасындағы байланыстар уақыт өте келе өзгергенде пайда болады. Клиникалық болжау модельдері пациенттер популяциясы уақыт өте келе өзгерген сайын өнімділік дрейфінен зардап шегеді. Ескі және жаңа деректерді тиімді пайдалана алатын модельді жаңарту әдістеріне немесе модельдеу әдістемелеріне үлкен қажеттілік бар. Соңғы зерттеулер трансферлік оқыту мен *stacking ensemble* әдістерін біріктіру, мысалы, *TransferGBM* әдістемесі ескі және жаңа білімді тиімді біріктіріп, тұрақты болжау өнімділігін сақтай алатынын көрсетті. Тарихи электрондық денсаулық сақтау жазбалары деректерімен оқытылған модельдер жиі соңғы деректерде нашар нәтиже көрсетеді және қайта калибрлеуді қажет етеді. Сонымен қатар, ірі көлемді электрондық денсаулық сақтау жазбаларымен алдын ала оқытылған негізгі модельдер клиникалық болжау модельдерінің үлестірім ішіндегі және үлестірім сыртындағы өнімділігін жақсартатыны, уақытша үлестірім ауысуының теріс әсерін азайтатыны дәлелденді (Zhang et al., 2022; Guo et al. 2023).

Алдыңғы жұмыстар калибрлеу төмендеуіне байланысты модельді жаңарту стратегиялары алдын ала белгіленген қайта оқыту аралықтарына қарағанда нашар болжау дәлдігі кезеңдерін қысқартып, аналитикалық ресурстарды ең көп араласу қажет ететін модельдерге тиімдірек бөлуге мүмкіндік беретінін ұсынады (Davis et.al, 2020).

30 күндік аурухана өлім-жітімін болжау үшін регрессия және машиналық оқыту әдістерін салыстырған зерттеу авторлары уақыт өте келе дискриминацияның сақталғанын, бірақ әдіске тәуелді калибрлеу дрейфін көрсетті: нейрондық желілер тұрақты калибрлеуді көрсетсе, басқа модельдер әртүрлі дәрежеде нашарлауды байқатты. Бұл дрейф негізінен болжам-нәтиже байланыстарының өзгеруінен емес, кейсіктің өзгеруінен туындады, бұл модельге тән жаңарту стратегияларының қажеттілігін атап көрсетеді (Davis et al., 2017).

Соған қарамастан, жарияланған зерттеулердің көпшілігі тек бір реттік ұстап қалу валидациясын пайдаланады және сирек көп когорталы немесе ИТБ түрі бойынша валидация жүргізеді.

Бұл зерттеу ИТБ өлім-жітім моделінің уақытша тұрақтылығын, калибрлеу беріктігін және үлестірім дрейфін зерттейді, тұрақты физиологиялық мүмкіндіктер және қатаң алдын ала өңдеу ұзақ мерзімді жоғары беріктікті қамтамасыз етеді деген гипотезаны ұсынады.

## **ЗЕРТТЕУ МАТЕРИАЛДАРЫ МЕН ӘДІСТЕРІ**

Ұсынылып отырған зерттеуде 2008-2019 жылдар аралығын қамтитын Beth Israel Deaconess медициналық орталығының кешенді клиникалық деректер жиынтығын білдіретін MIMIC-IV v2.2 деректер базасы пайдаланылды (Johnson et al., 2023). Зерттелетін когорта қарқынды терапия бөлімшелеріне түскен 65 355 ересек пациентті қамтыды; іріктеу критерийлері ретінде мыналар қарастырылды: 18 жастан жоғары болу, стационарда кемінде 24 сағат болу және толық демографиялық ақпараттың болуы. Демографиялық деректері толық емес пациенттер талдаудан шығарылды. Бүкіл когорта бойынша бақыланған өлім-жітім деңгейі 12,7 % құрады. Пациенттер деректері әрі қарай валидациялау үшін үш дербес жиынға ұйымдастырылды: стандартты тестілік жиын; 2017–2019 жылдар аралығында қабылданған пациенттерді қамтитын уақыттық валидациялық когорта; сондай-ақ қарқынды терапия бөлімшесінің түрі бойынша стратификацияланған, медициналық қарқынды терапия бөлімшесін, хирургиялық қарқынды терапия

бөлімшесін және кардиологиялық қарқынды терапия бөлімшесін қамтитын псевдо-сыртқы валидациялық ішкі жиын (Iwase et al., 2022).

Пациенттердің клиникалық жағдайы мен емдеу үдерісінің әртүрлі қырларын қамту мақсатында бес санатқа топтастырылған 155 айнымалыдан тұратын кешенді көрсеткіштер жиынтығы әзірленді. Демографиялық сипаттамалар пациенттердің жасын, жынысын, этникалық тиесілігін және госпитализация түрін қамтыды. Өмірлік маңызды көрсеткіштер стационарда болу кезеңінің толық ұзақтығы бойынша бірнеше жиынтық статистикалық сипаттамаларды, соның ішінде орташа мәнді, ең төменгі және ең жоғары мәндерді, сондай-ақ стандартты ауытқуды пайдалану арқылы агрегатталды. Зертханалық айнымалылар жалпы қан талдауының көрсеткіштерін (лейкоциттер саны, гемоглобин, гематокрит, тромбоциттер), биохимиялық параметрлерді (натрий, калий, креатинин, қан сарысуындағы несепнәр азоты, глюкоза, альбумин, жалпы билирубин), қан үю жүйесінің көрсеткіштерін (протромбиндік уақыт, белсендірілген жартылай тромбопластиндік уақыт, халықаралық қалыптандырылған қатынас), сондай-ақ бауыр функциясының көрсеткіштерін (аспартатаминотрансфераза, аланинаминотрансфераза) қамтыды. Емдеуге байланысты сипаттамалар вазопрессорларды қолдану, өкпені жасанды желдету, бүйрек алмастырушы терапия және қан құю қажеттілігі сияқты медициналық араласуларды сипаттады. Клиникалық көрсеткіштер есептелген метрикаларды, соның ішінде қарқынды терапия бөлімшесінде болу ұзақтығын, ауруханада болу ұзақтығын және орындалған процедуралар санын қамтыды (Awad et al., 2017; Purushotham et al., 2018).

Модельдің сенімділігін қамтамасыз ету үшін және ақпараттың жоғалып кетуін болдырмау мақсатында деректерді алдын ала өңдеу жүйелі түрде жүргізілді. Экстремум мәндердің әсерін азайту үшін орташа мәннен бес стандартты ауытқу мөлшерінен асатын қалыптан тыс деректерге винсоризациялау қолданылды. Жетіспейтін зертханалық мәндер алдымен соңғы қолжетімді мәнді көшіру арқылы forward-filling тәсілімен өңделді, содан кейін барлық қалған жетіспейтін мәндер бүкіл оқыту когортының негізінде медианалық мәнмен толтырылды. Барлық үздіксіз айнымалылар белгілерді бірыңғай шкалаға келтіру және үлкен шамаларға ие айнымалылардың шамадан тыс әсер етуін болдырмау мақсатында z-score нормализациясы арқылы стандартталды. Бұл алдын ала өңдеу конвейері модельді бағалаудың тұтастығын сақтау үшін кросс-валидация шеңберінде жүйелі түрде қолданылды.

Болжамдық модель LightGBM алгоритмі негізінде құрылды және кластардың теңгерімін ескере отырып, Бриер көрсеткіші мен ROC-қисық астындағы аудан бойынша оңтайландырылды. Модельдің оңтайлы гиперпараметрлері жүйелі түрде баптау барысында анықталып, 477 ағашты, оқыту жылдамдығы 0,073, ағаштың максималды тереңдігі 10, 107 тармақты, ішкі таңдау үлесі 0,741 және белгілерді ішкі таңдау үлесі 0,587 мәндерін қамтыды. Әзірлеу когорты бойынша оқыту барысында жүргізілген бес еселік кросс-валидация қабылдағыштың жұмыс сипаттамалары қисығы астындағы ауданның орташа мәні 0,983 болғанын көрсетті, бұл оқыту кезеңінде бұрын кездеспеген деректерде модельдің жоғары өнімділігін анықтайды.

Модельдің уақыттық тұрақтылығын, калибровкасының сенімділігін және әртүрлі пациенттер топтары мен уақыт кезеңдеріне жалпылау қабілетін жан-жақты бағалау үшін үш сатылы валидация стратегиясы қолданылды. Валидацияның бірінші кезеңінде оқыту және тестілеу жиындары арасында 80/20 арақатынасын сақтай отырып, стратификацияланған кездейсоқ іріктеу арқылы қалыптастырылған стандартты тестілік жиын пайдаланылды. Нәтижесінде 52 284 пациенттен тұратын оқыту когорты және 13 071 пациенттен тұратын тестілік когорта құрылды. Уақыттық валидацияның екінші кезеңінде 2017–2019 жылдар аралығында қарқынды терапия бөлімшелеріне түскен 8 706 пациенттен тұратын когортада модельдің тиімділігі бағаланды. Бұл деректер модельді оқыту кезеңінен кейін бір–үш жыл

өткен соң жиналған. Мұндай тәсіл клиникалық тәжірибедегі, пациенттердің демографиялық сипаттамаларындағы немесе өлшеу хаттамаларындағы өзгерістердің әсерінен модель тиімділігінің уақыт өте төмендеген/төмендемегенін анықтауға мүмкіндік берді.

Псевдо-сыртқы валидацияның үшінші кезеңінде модельдің әртүрлі қарқынды терапия бөлімшелері үшін жалпылау қабілеті бағаланды. Осы мақсатта медициналық қарқынды терапия бөлімшесі (MICU) бойынша 3 812 госпитализацияны, хирургиялық қарқынды терапия бөлімшесі (SICU) бойынша 3 456 госпитализацияны және кардиологиялық қарқынды терапия бөлімшесі (CVICU) бойынша 2 783 госпитализацияны қамтитын жекелеген валидациялық деректер жиындары қалыптастырылды (Guo et al., 2023). Қарқынды терапия бөлімшесінің түрі бойынша стратификацияланған мұндай валидациялық құрылым біріктірілген деректерде оқытылған модельдердің пациенттердің сипаттамалары мен клиникалық жұмыс үдерістері әртүрлі болатын мамандандырылған қарқынды терапия бөлімшелерінде өз тиімділігін сақтай алатынын бағалауға мүмкіндік берді (Harutyunyan et al., 2019).


Модельдің тиімділігі нәтижелерді ажырату қабілеті мен болжанған ықтималдықтардың нақтылығын ескере отырып, кешенді түрде бағаланды. Дискриминациялық қабілетті бағалау үшін екі негізгі көрсеткіш қолданылды: ROC-қисық астындағы аудан (AUC-ROC) және «дәлдік–толықтық» қисығы астындағы аудан (AUC-PR). Бұл көрсеткіштердің мәні 0 мен 1 аралығында өзгереді, ал 1-ге жақын мәндер модельдің нәтижелер кластарын тиімдірек ажырататынын көрсетеді. Модельдің жұмысын тереңірек талдау мақсатында сезімталдық (толықтық), ерекшелік (спецификалық), дәлдік және дәлдік пен толықтықтың үлесін теңестіретін олардың гармониялық орташа мәні болып табылатын F1-көрсеткіші қосымша есептелді (Steierberg et al., 2010).

Дегенмен, модельдің тек нәтижелер кластарын ажырату қабілетін ғана емес, оның калибровка сапасын да бағалау маңызды болды. Осы мақсатта болжанған ықтималдықтар мен нақты нәтижелер арасындағы орташа квадраттық ауытқуды көрсететін Бриер көрсеткіші қолданылды. Калибровка сапасы сонымен қатар калибровкалық қисықтар арқылы визуалды түрде бағаланды, мұнда өлім-жітімнің болжанған ықтималдықтары ықтималдық децильдері бойынша бақыланған жиіліктермен салыстырылды. Мұндай тәсіл модель болжамдарының нақты деректерге қаншалықты дәл сәйкес келетінін анықтауға мүмкіндік берді (Davis et al., 2017).

Әртүрлі модельдердің дискриминация өнімділігін салыстыру үшін Холм түзетуі бар DeLong тесті қолданылды, бұл бірнеше салыстырулар кезінде статистикалық қорытындылардың дұрыстығын қамтамасыз етті – әсіресе әртүрлі модельдердің ROC қисықтары бірдей тест жиынтығында есептелгендіктен және корреляцияланған болғандықтан маңызды болды. Бағалау нәтижелері негізінде ең жақсы өнімділік көрсеткен модельдер үшін шатастыру матрицалары құрылды, олар шынайы оң, шынайы теріс, жалған оң және жалған теріс нәтижелердің үлестірімін көрсетті, бұл модельдің жиі жіберетін қателік түрлері туралы тереңірек түсінік берді.

Сонымен қатар, Population Stability Index (PSI) талдауы жүргізілді, ол негізгі мүмкіндіктердің үлестірімдерінің уақыт өте келе және әртүрлі дерекқорларда қалай өзгертінін бақылауға мүмкіндік берді. PSI децильдер бойынша топтастырылған жиіліктік үлестірімдерді салыстыру арқылы есептелді, бұл сипаттамаларды дрейф дәрежесіне қарай тұрақты ( $PSI < 0,10$ ), орташа ( $0,10-0,25$ ) және айқын ( $PSI > 0,25$ ) деп жіктеуге мүмкіндік берді. Талдау SHAP-талдау нәтижелері бойынша анықталған ең маңызды он сипаттама үшін жүргізілді. Ол олардың үлестірімдерін уақыттық валидацияда және псевдо-сыртқы валидацияда бастапқы тестілік деректер жиынымен салыстыруды қамтыды (1-сурет). Мұндай тәсіл деректердің өзгергіштігі әртүрлі жағдайларда қолдану барысында модельдің сенімділігіне қалай әсер етуі мүмкін екенін бағалауға мүмкіндік берді.

Модельдің болжамдарды қалай қалыптастыратынын тереңірек түсіну үшін әрбір сипаттаманың нәтижеге қосатын үлесін сандық түрде бағалауға мүмкіндік беретін SHapley Additive exPlanations (SHAP) әдісі қолданылды. Белгілердің жаһандық маңыздылығы SHAP мәндерінің орташа абсолюттік көрсеткіштері негізінде анықталып, модельдің нәтижесіне ең күшті әсер ететін айнымалыларды айқындауға мүмкіндік берді (Lundberg et al., 2020). Талдау нәтижесінде физиологиялық және зертханалық көрсеткіштердің басым предикторлар екені анықталды. Қарқынды терапия бөлімшесінде болу барысында тіркелген рН деңгейінің, лейкоциттер санының және глюкоза деңгейінің соңғы мәндері өлім-жітімді болжауға ең жоғары жалпы әсер көрсетті.



**1-сурет.** Интенсивті терапия бөлімшесіндегі өлім-жітім моделін валидация когорттары бойынша бағалаудың жалпы шолуы

*Ескерту – авторлар құрастырған*

Осы зерттеудегі барлық талдаулар Python тілінің 3.10 немесе одан жоғары нұсқасына негізделген бірыңғай есептеу ортасында жүргізілді, бұл модельдеу үдерісінің толық ашықтығы мен қайта өндірілуін қамтамасыз етті. Машиналық оқытудың негізгі жұмыс үдерісі scikit-learn фреймворкін пайдалану арқылы іске асырылды, ол модельді оқытудың барлық кезеңдерін — кросс-валидациядан және белгілерді іріктеуден бастап өнімділік көрсеткіштерін есептеуге дейін — жүйелі түрде жүзеге асыруға мүмкіндік берді. Зерттеудің негізгі элементі болып табылатын градиенттік бустинг моделін құру үшін LightGBM кітапханасы қолданылды, оның тиімділігі мен масштабталуы күрделі әрі жоғары өлшемді клиникалық деректерді талдау үшін оны ерекше қолайлы етеді. Модель әрекетін интерпретациялау SHAP кітапханасының көмегімен тікелей аналитикалық үдеріске біріктірілді, бұл белгілердің үлесін сандық тұрғыдан бағалауға ғана емес, сонымен қатар модельдің жекелеген болжамдарын теориялық негізде зерттеуге мүмкіндік берді (Lundberg et al., 2018).

Деректерді алдын ала өңдеу және құрылымдау pandas кітапханасының көмегімен жүзеге асырылды, ал талдаудың барлық кезеңдерінде қажетті сандық есептеулер NumPy кітапханасы арқылы орындалды. Визуализация зерттеудің әрі барлау кезеңінде, әрі нәтижелерді растау кезеңінде маңызды рөл атқарды. Сипаттамалық графиктерді, диагностикалық диаграммаларды және модельдердің өнімділік қисықтарын құру үшін Matplotlib және Seaborn кітапханалары пайдаланылды. Әртүрлі модельдердің дискриминациялық қабілеттерін дәл салыстыру мақсатында scikit-learn кеңейтімдерін пайдалана отырып, ROC-қисықтарды салыстыруға арналған Делонг статистикалық тесті іске асырылды. Модельдерді оқыту және бағалау рәсімдерінің барлығы стандартты есептеу жабдығында, мүмкін болған жағдайларда GPU жеделдетуін қолдану арқылы жүргізілді, бұл есептеулердің тиімділігін және алынған нәтижелердің қайта өндірілуін қамтамасыз етті.

### НӘТИЖЕЛЕР ЖӘНЕ ОЛАРДЫ ТАЛҚЫЛАУ

Талдауға 2008–2019 жылдар аралығында MIMIC-IV деректер базасынан алынған ересек пациенттердің қарқынды терапия бөлімшелеріне жатқызылған 65 355 госпитализация жағдайы енгізілді. Зерттелетін когорта валидация жүргізу мақсатында үш топқа бөлінді: 13 071 пациентті қамтитын негізгі тестілік топ, 8 706 пациенттен тұратын уақыттық валидациялық когорта және қарқынды терапия бөлімшелерінің түрлері бойынша жүргізілген псевдо-сыртқы валидациялық когорта (10 051 пациент).

Жалпы ауруханаішілік өлім-жітім деңгейі 12,7 % құрады, алайда топтар арасында айырмашылықтар байқалды (1-кесте). Негізгі тестілік топта өлім-жітім 10,8 %, уақыттық когортада — 13,2 %, ал псевдо-сыртқы когортада — 13,9 % болды. Бұл айырмашылықтар ұзақ мерзімді күтілетін үрдістерді және қарқынды терапия бөлімшелерінің әртүрлі типтеріне тән ерекшеліктерді көрсетеді.

1-кесте. Когорта қорытындысы

Деректер жиынтығы	N	Өлім-жітім (%)	AUC-ROC	AUC-PR	Brier
Негізгі тест	13,071	10,8 %	0,982	0,912	0,0277
Уақытша	8,706	13,2 %	0,998	0,920	0,0063
Псевдо-сыртқы	10,051	13,9 %	0,997	0,918	0,0089

*Ескерту – авторлар құрастырған*

Пациенттердің демографиялық сипаттамалары барлық когорталарда ұқсас болды. Орташа жас мөлшері 64–67 жасты құрады, сондай-ақ ер адамдардың аздап басымдығы байқалды (53–56 %). Уақыттық валидациялық когортада аурудың ауырлық деңгейі мен өлім-жітім көрсеткіштері сәл жоғары болды, бұл зерттеу кезеңі барысында қарқынды терапия бөлімшелеріндегі пациенттер құрылымының өзгеруіне сәйкес келеді.

LightGBM моделі валидацияның барлық үш деңгейінде де уақыт өте өнімділіктің төмендеу белгілерінсіз жоғары дискриминациялық қабілет көрсетті. ROC-қисық астындағы аудан (AUC-ROC) тұрақты түрде жоғары деңгейде сақталды: негізгі тестілік деректер жиынында 0,982 (95 % сенімділік аралығы: 0,979–0,985), 2017–2019 жылдар аралығындағы уақыттық валидацияда 0,998 (95 % СА: 0,996–0,999) және MICU, SICU және CVICU бөлімшелерін қоса алғанда, қарқынды терапия бөлімшелерінің әртүрлі типтерінде жүргізілген псевдо-сыртқы валидацияда 0,997 (95 % СА: 0,995–0,999).

Осыған ұқсас түрде AUC-PR көрсеткіші де тұрақты болып қалды: негізгі тестілік деректер жиынында — 0,912, уақыттық валидацияда — 0,920 және псевдо-сыртқы валидацияда — 0,918. Бұл нәтижелер 2008–2016 жылдар деректері негізінде оқытылған

модельдердің кейінгі пациенттер когорталарында және қарқынды терапия бөлімшелерінің әртүрлі жағдайларында қолданылған кезде өз дискриминациялық қабілетін сақтағанын немесе тіпті арттырғанын көрсетеді.

Маңызды нәтижелердің бірі модельді болашақ деректерге қолдану кезінде оның калибровкасының айтарлықтай жақсаруы болды. Калибровка мен дискриминацияны қатар сипаттайтын Бриера көрсеткіші негізгі тестілік деректер жиынында 0,0277 мәнінен уақыттық валидацияда 0,0063-ке және псевдо-сыртқы валидацияда 0,0089-ға дейін төмендеді. Бұл болашақ деректерде қолдану кезінде көрсеткіштің 77,4 % төмендегенін білдіреді. Алынған нәтижелер модель өнімділігінің тұрақты екенін ғана емес, сонымен қатар кейінгі жылдарда қолдану барысында оның калибровка дәлдігінің артқанын көрсетеді. Бұл модельдің болжанған ықтималдықтарының нақты бақыланған нәтижелермен неғұрлым жақсы сәйкестене түскенін білдіреді.

Калибрлеу қисықтары екі валидация когортасында болжанған және байқалған өлім-жітім деңгейлерінің дерлік мінсіз сәйкестігін ашып көрсетті (Davis et al., 2020). Уақытша валидация деректерінде калибрлеу қисығы диагональ бойына тығыз орналасып, ықтималдық спектрі бойынша жүйелі ауытқу болған жоқ. Интегралды калибрлеу индексі барлық валидация ішкі жиынтықтарында 0,015-тен төмен болды, бұл 0,05 клиникалық маңыздылық шегінен әлдеқайда төмен.

Алынған нәтижелер машиналық оқыту модельдері болашақ деректерге қолданылған кезде міндетті түрде тиімділігін жоғалтады деген кең таралған пікірге қайшы келеді. Бұл нәтижелер негізгі физиологиялық көрсеткіштерді пайдалану және деректерді мұқият алдын ала өңдеу модельдің ұзақ мерзімді сенімділігін қамтамасыз ете алатынын көрсетеді.

Ковариаттардың ығысуын сандық тұрғыдан бағалау мақсатында ең маңызды он болжамдық сипаттама бойынша популяция тұрақтылығы индексіне (PSI) талдау жүргізілді. PSI мәндері 0,1-ден төмен болған жағдайда тұрақты, 0,1–0,25 аралығында болса орташа ығысу, ал 0,25-ке тең немесе одан жоғары болған жағдайда айқын ығысу ретінде жіктелді (2-кесте).

## 2-кесте. Ең маңызды 10 мүмкіндік бойынша PSI талдауы

Validation	Тұрақты (PSI<0,10)	Орташа (0,10-0,25)	Елеулі (>0,25)
Уақытша vs Негізгі	10/10	0/10	0/10
Псевдо-сыртқы vs Негізгі	9/10	1/10 (PSI=0.136)	0/10
<i>Ескерту – авторлар құрастырған</i>			

2017-2019 жылдар аралығындағы уақыттық валидацияны 2008-2016 жылдар кезеңімен салыстырғанда, бақыланған барлық он сипаттаманың үлестірімі төмен PSI мәндерімен тұрақты болғаны анықталды, бұл ковариаттардың елеулі ығысуының болмағанын көрсетеді. Ұқсас нәтижелер қарқынды терапия бөлімшелерінің түрлері бойынша жүргізілген псевдо-сыртқы валидация кезінде де алынды. Он сипаттаманың тоғызы тұрақты болып қалды, ал PSI мәні 0,136 болған жалғыз сипаттама орташа ығысу санатына жатқызылғанымен, ол маңыздылық шегі болып саналатын 0,25 мәнінен айтарлықтай төмен болды (3-кесте). Бұл нәтижелер модельдің кіріс деректерінің үлестірімі уақыт бойынша да, әртүрлі клиникалық жағдайларда да тұрақты болып қалғанын көрсетеді.

**3-жесте.** SHAP талдауы ИТБ өлім-жітімі үшін физиологиялық зертханалық мәндерді ең басым болжамдық мүмкіндіктер ретінде анықтады

Ранг	Мүмкіндік	Орташа	Елеулі (>0,25)
Уақытша vs Негізгі	10/10	0/10	0/10
Псевдо-сыртқы vs Негізгі	9/10	1/10 (PSI=0.136)	0/10
<i>Ескерту – авторлар құрастырған</i>			

Айқын дрейфтің болмауы негізгі физиологиялық айнымалылардың біртіндеп әрі болжамды түрде өзгеретінін және өз табиғаты бойынша ауруханадағы жұмыс үдерістеріне немесе деректерді өңдеу артефактілеріне байланысты айнымалыларға қарағанда анағұрлым тұрақты екенін көрсетеді. Бұл модельдің уақыттық және псевдо-сыртқы когорталарда жоғары сенімділік көрсетуін түсіндіреді.

pH ең маңызды болжамдық фактор ретінде анықталды, бұл оның ауыр физиологиялық бұзылыстар мен аурудың ауырлығының маркері ретіндегі рөліне сәйкес келеді. Екінші және үшінші орындарды инфекция мен жүйелік қабынудың көрсеткіші болып табылатын лейкоциттер саны және метаболикалық стресс пен қант диабетін бейнелейтін глюкоза деңгейі иеленді. Бұл нәтижелер қарқынды терапия бөлімшелеріндегі өлім-жітімнің белгілі қауіп факторларымен сәйкес келеді және модельдің клиникалық негізділігін растайды.

SHAP тәуелділік графиктері белгілер мен модель болжамдары арасындағы интуитивті түсінікті байланыстарды көрсетті. pH мәндерінің жоғары болуы (сілтілі орта) болжанатын өлім-жітімнің төмендеуімен байланысты болса, ал төмен мәндер (ацидемия) өлім қаупінің артуымен ассоциацияланды. Осыған ұқсас түрде глюкоза мен лейкоциттер деңгейінің жоғарылауы өлім қаупінің жоғары болуымен байланысты болды. Ал тромбоциттер вариабельділігі үшін сызықтық емес тәуелділіктер байқалып, бұл критикалық аурулар кезіндегі күрделі физиологиялық динамиканы көрсетеді.

Барлық валидациялық ішкі жиындарда осы белгілердің маңыздылық рейтингінің тұрақты сақталуы модельдің сенімділігін қосымша дәлелдейді, өйткені бірдей физиологиялық механизмдер әртүрлі уақыт кезеңдерінде және қарқынды терапия бөлімшелерінің әртүрлі жағдайларында да болжамдық маңызын жоғалтпайды.

Негізгі тестілік деректер жиынында жіктеу моделінің жалпы тиімділігі жоғары болды және келесі көрсеткіштермен сипатталды:

- Дәлдік (Precision) — 0,883, яғни болжанған оң жағдайлардың 88,3 %-ы шын мәнінде оң болып шықты.

- Толықтық (Recall) — 0,802, бұл нақты оң жағдайлардың 80,2 %-ы модель арқылы дұрыс анықталғанын білдіреді.

- F1-көрсеткіші — 0,840.

- Ерекшелік (Specificity) — 0,987, яғни теріс жағдайлардың 98,7 %-ы дұрыс жіктелді.

13 071 пациентті қамтитын негізгі тестілік деректер жиыны үшін құрылған қателер матрицасы 11 505 шынайы теріс, 150 жалған оң, 281 жалған теріс және 1 135 шынайы оң болжамды көрсетті. Бұл көрсеткіштер барлық валидациялық когорталарда ұқсас болып қалды, ал уақыттық валидация кезінде дәлдік пен толықтық арасындағы тепе-теңдік сақтала отырып, F1-көрсеткішінің 0,851-ге дейін сәл жақсарғаны байқалды.

Жоғары ерекшелік (98,7 %) пен елеулі сезімталдықтың (80,2 %) үйлесуі клиникалық тұрғыдан тиімді болып табылады, өйткені модель жалған дабылдардың санын барынша азайта отырып, ерте араласуды қажет ететін жоғары қауіп тобындағы пациенттердің көпшілігін анықтай алады. Жалған оң болжамдардың салыстырмалы түрде төмен деңгейі

(1,1 %) модельді клиникалық тәжірибеге енгізуді жеңілдетеді, себебі ол шамадан тыс ескертулерге байланысты туындайтын жүктемені төмендетеді.

MICU, SICU және CVICU қарқынды терапия бөлімшелерінің үш түрі бойынша жүргізілген псевдо-сыртқы валидация модельдің жоғары жалпылау қабілетін растады.

- MICU (3 245 пациент, өлім-жітім деңгейі 14,2 %): AUC-ROC – 0,996, Бриер көрсеткіші – 0,0092.

- SICU (3 401 пациент, өлім-жітім деңгейі 13,5 %): AUC-ROC – 0,998, Бриер көрсеткіші – 0,0085.

- CVICU (3 405 пациент, өлім-жітім деңгейі 13,8 %): AUC-ROC – 0,997, Бриер көрсеткіші – 0,0087.

Қарқынды терапия бөлімшелерінің барлық түрлері үшін модельдің тиімділік көрсеткіштері іс жүзінде бірдей болды. AUC-ROC мәндері 0,996-0,998 аралығында, ал Бриера көрсеткіштері 0,0085-0,0092 диапазонында сақталды. Бұл модельдің жекелеген қарқынды терапия бөлімшелеріне тән заңдылықтарды емес, критикалық аурулар кезіндегі өлім-жітімнің әмбебап механизмдерін бейнелейтінін көрсетеді. Осылайша, модельдің жоғары жалпылау қабілеті мен ұзақ мерзімді клиникалық қолданбалығы тағы бір мәрте расталады.

Жоғары қауіп деңгейімен дұрыс болжанған жағдайларды, жоғары қауіп ретінде қате бағаланған жағдайларды және төмен қауіппен қате болжанған жағдайларды қамтитын типтік клиникалық мысалдар үшін құрылған SHAP сарқырама (waterfall) графиктері модельдің интерпретациялануын және жеке болжамдарға негізгі айнымалылардың әсерін айқын көрсетті.

Жоғары қауіп деңгейімен дұрыс анықталған жағдайларда рН, лактат және лейкоциттер саны әдетте болжамды өлім-жітім жағдайына қарай ығыстырды. Ал жоғары қауіп ретінде қате бағаланған, бірақ қолайлы нәтижемен аяқталған жағдайларда осы айнымалылардың шекаралық аномальды мәндері жеке-жеке алғанда қолайсыз болжамды меңзегенімен, қорғаныш факторларымен теңгерілгені байқалды. Мұндай егжей-тегжейлі интерпретация модель болжамдарына клиницистер үшін негізделген түсіндірмелер беріп, оны клиникалық тәжірибеде қолдану үшін қажетті ашықтықты қамтамасыз етеді.

Осы зерттеуде мұқият іріктелген физиологиялық сипаттамалар негізінде оқытылған машиналық оқыту модельдерінің әртүрлі уақыт кезеңдері мен клиникалық жағдайларда қолданылған кезде өнімділігін төмендетпей, тұрақты дискриминациялық қабілет пен калибровканы сақтай алатынын дәлелдейтін сенімді нәтижелер ұсынылды. Зерттеудің ең маңызды қорытындысы — модель сапасының үш жыл ішінде төмендегені. AUC-ROC көрсеткіштері барлық валидация деңгейлерінде тұрақты болып қалды немесе жақсарды және тиісінше 0,982, 0,998 және 0,997 мәндерін көрсетті. Ал Бриера көрсеткіші болашақ деректерде қолдану кезінде 77,4 %-ға төмендеп, модельдің тек тұрақты ғана емес, сонымен қатар калибровка дәлдігі артқанын көрсетті. Сонымен қатар, популяция тұрақтылығы индексіне (PSI) жүргізілген талдау уақыттық валидация кезінде сипаттамалар үлестірімінің елеулі ығысуын анықтамады, мұнда PSI мәндері 0,10-нан төмен болды. Псевдо-сыртқы валидация барысында да тек минималды дрейф байқалып, PSI-дің ең жоғары мәні 0,136-ны құрады. Бұл нәтижелер негізгі физиологиялық айнымалылардың уақыт бойынша және әртүрлі клиникалық жағдайларда тұрақты болып қалатынын растайды.

Бұл нәтиже клиникалық машиналық оқыту әдебиетіндегі уақытша дрейф сөзсіз және қауіпсіз қолдану үшін модельді жиі қайта оқыту қажет деген басым болжамды тікелей жоққа шығарады. Жарияланған ИТБ өлім-жітім болжамы бойынша зерттеулердің көпшілігі бір реттік оқыту-тест бөлінісіне ғана сүйенеді және қатаң көп деңгейлі валидация әдістемесі жетіспейді. Осы зерттеудегі үш деңгейлі валидация дизайны – стандартты ұстап қалу тесті, 2017–2019 жылдардағы уақытша валидация және MICU, SICU және CVICU сияқты ИТБ

түрлері бойынша псевдо-сыртқы валидация – мұқият құрылған модельдердің ұзақ мерзімді клиникалық пайдалылығын сақтай алатынын берік дәлелдейді. Бұл зерттеуде байқалған ерекше тұрақтылықты, шамасы, төрт негізгі фактор арқылы түсіндіруге болады.

Біріншіден, модельдің тұрақтылығын қамтамасыз ететін негізгі факторлардың бірі – физиологиялық сипаттамалар. Модель рН деңгейі, лейкоциттер саны, глюкоза деңгейі және тромбоциттер вариабельділігі сияқты іргелі физиологиялық көрсеткіштерге негізделген, олар институционалдық немесе ұйымдастырушылық үдерістерді емес, негізгі патофизиологиялық механизмдерді бейнелейді. Бұл айнымалыларға биологиялық тұрғыдан тән тұрақтылық қасиеті тән. SHAP-талдау нәтижелері негізгі болжамдық белгілердің барлық валидациялық ішкі жиындарда өз маңыздылығын сақтағанын көрсетті. Бұл модельдің уақытша немесе контекстке тәуелді заңдылықтарды емес, өлім-жітімнің әмбебап механизмдерін бейнелейтінін көрсетеді.

Екіншіден, деректерді сенімді алдын ала өңдеу және белгілерді мұқият инжинирингтеу модель тұрақтылығында маңызды рөл атқарды. Алдын ала өңдеу конвейері бірнеше дәлелді стратегияларды қолданды: жетіспейтін мәндер үшін forward-fill және медиана импутациясы, шеткі мәндерді жоюдың орнына 5 стандартты ауытқудан winsorization және барлық үздіксіз айнымалыларды стандарттау. Бұл таңдаулар өлшеу артефактілері мен шеткі мәндердің әсерін азайтып, сирек кездесетін, бірақ клиникалық маңызды үлгілерді сақтады. Өмірлік көрсеткіштер мен зертханалық мәндерді ИТБ-дағы бүкіл болу кезеңі бойынша жинақтау – бір уақыт нүктесіндегі өлшемдерге сүйенудің орнына – өлшеу протоколдары немесе құжаттау практикасының ауытқуларына аз сезімтал жалпы үлгілерді қамтыды.

Үшіншіден, модельді оқытуда кластар бойынша теңгерілген мақсатты функцияны таңдау маңызды рөл атқарды. Оқыту барысында теңгерілген Бриера көрсеткішін қолдану модельге болжамдардың бүкіл ауқымы бойынша дискриминация мен калибровка дәлдігін бірдей ескеруге мүмкіндік берді. Мұндай тәсіл модельді болашақ деректерде қолдану кезінде байқалған калибровка жақсаруының себебін түсіндіреді. Орташа қателікті ғана азайтуға бағытталған оңтайландырудың орнына модель миноритарлық класқа жататын сирек нәтижелер үшін де жақсы калибрленген ықтималдықтық бағалар қалыптастыруды үйренді. Осылайша, ұсынылған тәсіл өлім-жітім деңгейі 12,7 % болатын кластардың айқын теңгерімсіздігі жағдайында стандартты мақсатты функцияларға қарағанда болжамдардың калибровкасын дәлірек қамтамасыз етеді.

Төртіншіден, модель ауруханалық жұмыс үдерістеріне тәуелді емес. Ол уақыт өте өзгертін әкімшілік кодтарды, есеп айырысу жүйелерін немесе жекелеген мекемелердің хаттамаларын пайдаланбайды. Оның орнына модель тек физиологиялық өлшемдер мен негізгі демографиялық деректерге негізделген. Мұндай көрсеткіштер уақыт пен қолдану жағдайлары өзгерген кезде де тұрақты болып қалады. Бұл әртүрлі қарқынды терапия бөлімшелерінде жүргізілген псевдо-сыртқы валидация кезінде модель тиімділігінің көрсеткіштері неге бірдей дерлік болғанын түсіндіреді.

Бұл нәтижелер клиникалық қолдану және модель басқару үшін тікелей салдарларға ие. Уақытша дрейфке қарсы жиі қайта оқыту деген дәстүрлі тәсіл тұрақты физиологиялық мүмкіндіктерге негізделген модельдер үшін қажет болмауы мүмкін. Оның орнына ресурстар жан-жақты бастапқы валидацияға, қатаң мүмкіндіктер инженериясына және үздіксіз өнімділік мониторингіне бағытталуы тиіс, үздіксіз модель жаңартуларына емес. Бұл есептеу шығындарын айтарлықтай азайтады, басқаруды жеңілдетеді және клиниктерге жүйенің қалай жұмыс істейтіні туралы тұрақты психикалық модельдерді қалыптастыруға мүмкіндік береді.

Тұрақты физиологиялық деректерге негізделген модельдер үшін жиі қайта оқыту қажет болмауы мүмкін. Бастапқы сапалы валидация мен тұрақты мониторинг

клиникалық қолдануды жеңілдетіп, шығындарды азайтады және дәрігерлерге жүйенің жұмыс логикасын тұрақты түрде түсінуге мүмкіндік береді.

Сонымен қатар, жоғары дискриминациялық қабілеттің ( $AUC-ROC \geq 0,982$ ), болашақ деректерде өте жақсы калибровканың (Бриер көрсеткіші  $< 0,01$ ), жоғары ерекшеліктің (98,7 %) және рН, глюкоза деңгейі мен лейкоциттер саны сияқты клиникалық тұрғыдан түсінікті белгілердің үйлесуі бұл модельді тікелей клиникалық қолдануға жарамды етеді. Сонымен қатар, модельдің 80,2 % сезімталдығы жоғары қауіп тобына жататын пациенттердің көпшілігін ерте анықтауға мүмкіндік береді.

Модель болжамдарының қарқынды терапия бөлімшелерінің әртүрлі түрлерінде тұрақты болуы оны практикалық тұрғыдан енгізудің орынды екенін қосымша дәлелдейді. Бір ғана модельді медициналық, хирургиялық және кардиологиялық қарқынды терапия бөлімшелерінде арнайы бейімдеусіз немесе әр орта үшін қайта калибрлеусіз сенімді түрде қолдануға болады. Мұндай әмбебаптық модельді енгізу үдерісін жеңілдетеді және клиникалық командаларға, соның ішінде персоналды оқыту тұрғысынан түсетін жүктемені азайтады.

Сонымен қатар, алынған нәтижелерді интерпретациялау кезінде бірқатар шектеулерді ескеру қажет. Біріншіден, зерттеу бір ғана медициналық орталықта жүргізілген, бұл нәтижелерді кең ауқымда жалпылауды шектейді. Қарқынды терапия бөлімшелерінің түрлері бойынша жүргізілген псевдо-сыртқы валидация модельдің жалпылау қабілетіне ішкі дәлелдер бергенімен, барлық деректер Beth Israel Deaconess медициналық орталығынан алынған. Сондықтан нәтижелер осы мекемеге тән клиникалық тәжірибелерді, өлшеу хаттамаларын немесе пациенттер құрылымын көрсетуі мүмкін және басқа денсаулық сақтау жүйелері үшін толық репрезентативті болмауы ықтимал.

Екіншіден, зерттеуде қарастырылған уақыттық кезең үш жылмен шектелді. Бұл мерзім маңызды болғанымен, ол анағұрлым ұзақ уақыт аралығында орын алатын өзгерістерді толық қамтымауы мүмкін. Қарқынды терапия бөлімшелеріндегі өлім-жітімді болжау 3-4 жыл бойы тұрақты болып қалуы ықтимал, алайда клиникалық тәжірибенің дамуына, жаңа емдеу тәсілдерінің пайда болуына және халық құрылымының өзгеруіне байланысты он жылдық ауқымда өзгеруі мүмкін.

Үшіншіден, зерттеуде соңғы нәтиже ретінде тек ауруханаішілік өлім-жітім қарастырылды. Өлім-жітім клиникалық тұрғыдан аса маңызды көрсеткіш болғанымен, қарқынды терапия бөлімшесінде болу ұзақтығы, қайта госпитализация, функционалдық қалпына келу және өмір сапасы сияқты басқа да маңызды клиникалық нәтижелер әртүрлі заңдылықтар көрсетуі мүмкін және жеке валидацияны талап етеді.

Төртіншіден, алынған нәтижелердің жалпыламалығы құрылымдалған физиологиялық және демографиялық деректермен шектелуімен байланысты. Клиникалық жазбалар, медициналық бейнелер сияқты құрылымдалмаған деректерді, сондай-ақ геномдық немесе протеомдық биомаркерлерді енгізу тек зертханалық көрсеткіштерге негізделген талдауда байқалмайтын уақыттық заңдылықтарды анықтауға мүмкіндік беруі мүмкін.

Болашақ зерттеулер анықталған шектеулерді бірін-бірі толықтыратын бірнеше тәсілдер арқылы еңсеруі тиіс. Ең алдымен, алынған нәтижелердің бір ғана медициналық мекемеден тыс жерлерде де жалпыланатынын растау үшін сыртқы және көпорталықты валидация қажет. Географиялық тұрғыдан әртүрлі аймақтардан алынған деректерді, электрондық медициналық жазбалардың әртүрлі жүйелерін және клиникалық тәжірибенің түрлі модельдерін пайдалану модельдің кең ауқымды қолданбалығын нығайтып, өнімділікке әсер етуі мүмкін орталыққа тән факторларды анықтауға мүмкіндік береді.

Сонымен қатар, 5-10 жыл аралығындағы ұзақ мерзімді уақыттық кезеңдерді қамту модель тұрақтылығының сақталатынын немесе уақыт өте дрейфтің пайда болатынын бағалауға мүмкіндік береді. Ұтымды жағдайда мұндай ұзақ мерзімді валидация

ретроспективті талдаудан туындайтын бұрмалауларды болдырмау үшін деректерді проспективті түрде жинауды қамтуы тиіс.

Гипотезаларды тізбекті тексеру немесе онлайн-оқыту әдістерін пайдалана отырып, модель өнімділігін нақты уақыт режимінде бақылау оның сапасындағы тіпті шамалы төмендеулерді дер кезінде анықтауға және қайта оқыту туралы шешімдерді алдын ала белгіленген кестелерге емес, нақты деректерге сүйене отырып қабылдауға мүмкіндік береді. Мұндай мониторинг жүйелері ауытқуларды анықтаудың статистикалық тәсілдерін — мысалы, PSI және AUC көрсеткіштерін бақылауды — ғана емес, сонымен қатар статистикалық өзгерістердің клиникалық тұрғыдан маңыздылығын растау үшін клиникалық валидацияны да қамтуы тиіс.

Сонымен қатар, өлім-жітімді болжаумен шектелмей, клиникалық әрекеттерге арналған түсіндірілетін ұсыныстарды ұсынатын практикалық машиналық оқыту тәсілдері модельдердің клиникалық құндылығын айтарлықтай арттыра алады. Мұндай модельдерді кері байланыс тетіктерімен бірге клиникалық жұмыс үдерістеріне енгізу олардың пациенттердің емдеу нәтижелеріне және дәрігерлердің шешім қабылдауына әсерін бағалауға мүмкіндік береді.

Соңында, болашақ деректерде байқалған калибровканың жақсаруы клиникалық тәжірибенің дәлелді стандарттарға жақындауымен байланысты ма, әлде ол статистикалық артефактілердің нәтижесі ме екенін зерттеу қарқынды терапия бөлімшелеріндегі өлім-жітімді болжаудың уақыттық динамикасын тереңірек түсінуге мүмкіндік береді.

### **ҚОРЫТЫНДЫ**

Бұл зерттеу іргелі физиологиялық айнымалыларға негізделген машиналық оқыту модельдерінің жиі қайта оқытуды қажет етпей-ақ, уақыт бойынша жоғары тұрақтылық пен калибровканың жақсы сәйкестігін сақтай алатынын көрсетеді. MIMIC-IV деректер базасынан алынған 2008–2016 жылдар аралығындағы 65 355 қарқынды терапия бөлімшесіне жатқызу жағдайы негізінде LightGBM моделі әзірленіп, оның тиімділігі үш сатылы валидация жүйесі арқылы бағаланды. Бұл жүйе стандартты тестілеуді, 2017–2019 жылдар кезеңіндегі уақыттық валидацияны және қарқынды терапия бөлімшелерінің әртүрлі типтері бойынша жүргізілген псевдо-сыртқы валидацияны қамтыды.

Нәтижелер модельдің айрықша тұрақтылығын көрсетті. Дискриминациялық қабілет барлық валидация деңгейлерінде тұрақты болып қалды немесе жақсарды: AUC-ROC негізгі тестілік деректер жиынында 0,982, уақыттық валидацияда 0,998 және псевдо-сыртқы валидацияда 0,997 мәнін көрсетті. Бұдан да маңыздысы, болашақ деректерде модельдің калибровкасы айтарлықтай жақсарды. Бриера көрсеткіші негізгі тестілік жиыннан уақыттық валидацияға өткен кезде 77,4 %-ға төмендеді, бұл болжанған ықтималдықтар мен нақты нәтижелер арасындағы сәйкестіктің артқанын көрсетеді.

Популяция тұрақтылығы индексіне жүргізілген талдау сипаттамалар үлестірімінің ең аз өзгергенін растады. Уақыттық валидация кезінде бақылған барлық он айнымалы үшін PSI мәндері 0,10-нан төмен болды, ал псевдо-сыртқы тестілеу барысында он сипаттаманың тоғызы тұрақты болып қалды. Тек бір айнымалы ғана PSI мәні 0,136 болатын орташа ауытқуды көрсетті, бұл клиникалық маңыздылық шегінен айтарлықтай төмен.

Бұл нәтижелер клиникалық машиналық оқыту әдебиетінде кең таралған уақыттық дрейфтің сөзсіз болатыны және модельдерді жиі жаңарту қажет деген көзқарасқа тікелей қайшы келеді. Керісінше, бұл зерттеу рН деңгейі, лейкоциттер саны, глюкоза деңгейі және тромбоциттер вариабельділігі сияқты тұрақты физиологиялық көрсеткіштерге негізделген модельдердің критикалық жағдайлар кезіндегі өлім-жітімнің әмбебап механизмдерін бейнелейтінін көрсетеді. Бұл механизмдер уақыт бойынша да, әртүрлі клиникалық жағдайларда да тұрақты болып қалады. Белгілерді мұқият инжинирингтеу, клиникалық

маңызды сигналды сақтай отырып артефактілердің әсерін азайтатын алдын ала өңдеу, кластар бойынша теңгерілген оқыту және нақты бір аурухананың жұмыс үдерістеріне тәуелсіздік модельдің ұзақ мерзімді тұрақтылығы үшін берік негіз қалыптастырады.

Бұл қорытындылардың практикалық маңызы зор. Клиницистер мен денсаулық сақтау жүйелері мұндай модельдерді қарқынды терапия бөлімшелерінің әртүрлі типтерінде арнайы қайта калибрлеусіз сенімді түрде қолдана алады, бұл енгізу үдерісінің күрделілігін және есептеу шығындарын айтарлықтай төмендетеді. Жоғары ерекшелік (98,7%), жеткілікті сезімталдық (80,2%) және клиникалық тұрғыдан түсінікті белгілер иерархиясы модельді практикалық қолдануды қолдап, жекелеген болжамдарды ашық әрі негізді түрде түсіндіруге мүмкіндік береді.

Алайда бұл жұмыс барлық клиникалық машиналық оқыту модельдері табиғатынан тұрақты болады дегенді білдірмейді. Керісінше, ол іргелі физиологиялық көрсеткіштерге негізделген дұрыс жобаланған модельдердің бірнеше жыл бойы тұрақтылыққа қол жеткізе алатынын көрсетеді. Модель өнімділігін тұрақты бақылау және ауытқуларды уақтылы анықтау қажеттілігі өзектілігін сақтайды, ал жекелеген мекемелерден тыс кең ауқымды клиникалық енгізу алдында сыртқы көпорталықты валидация жүргізу талап етіледі.

Болашақ зерттеулер әртүрлі денсаулық сақтау жүйелерінде сыртқы валидацияға, нақты уақыт режимінде ауытқуларды бақылау жүйелерін дамытуға, ұзақ мерзімді уақыттық талдауларға, сондай-ақ калибровканың жақсаруы клиникалық тәжірибенің шынайы конвергенциясын көрсете ме, әлде статистикалық құбылыстардың нәтижесі ме екенін зерттеуге бағытталуы тиіс.

Қорытындылай келе, бұл көпдеңгейлі валидациялық зерттеу қарқынды терапия бөлімшелеріндегі өлім-жітімді болжау үшін мұқият әзірленген машиналық оқыту модельдерінің тұрақты, интерпретацияланатын және клиникалық қолдануға жарамды құрал бола алатынын, әрі оларды үнемі қайта оқытусыз пайдалануға болатынын дәлелдейді. Бұл олардың ұзақ мерзімді клиникалық құндылығын қамтамасыз етіп, қарқынды терапияда сенімді жасанды интеллект тұжырымдамасын қолдайды.

**МҮДДЕЛЕР ҚАҚТЫҒЫСЫ:** Авторлар мүдделер қақтығысының жоқтығын мәлімдейді

**ҚАРЖЫЛАНДЫРУ:** Бұл зерттеу Қазақстан Республикасының Ғылым және жоғары білім министрлігінің Ғылым комитетінің гранты аясында қаржыландырылды (№. AP22683316 – «Медициналық шешімдерді қолдау жүйелері үшін машиналық оқыту алгоритмдерін қолдану»).

**ЖАСАНДЫ ИНТЕЛЛЕКТ ТЕХНОЛОГИЯЛАРЫН ПАЙДАЛАНУ ТУРАЛЫ  
ХАБАРЛАМА:** Жоқ.

### ӘДЕБИЕТТЕР ТІЗІМІ

- Ismukhamedova, A., Uvaliyeva, I., & Rakhmetullina, Z. (2024). Experimental study of a medical data analysis model based on comparative performance of classification algorithms. *Indonesian Journal of Electrical Engineering and Computer Science*, 36(1), 672.
- Rakhmetullina, Z., et al. (2024). Research and implementation of the medical text analysis algorithm for predicting mortality. *Indonesian Journal of Electrical Engineering and Computer Science*, 34(3).
- Ismukhamedova, A., Uvaliyeva, I., & Belginova, S. (2024). Integrating machine learning in electronic health passport based on WHO study and healthcare resources. *Informatics in Medicine Unlocked*, 44.
- Zhang, X., et al. (2022). A transfer learning approach to correct the temporal performance drift of clinical prediction models: Retrospective cohort study. *JMIR Medical Informatics*, 10(11).

- Guo, L. L., et al. (2023). EHR foundation models improve robustness in the presence of temporal distribution shift. *Scientific Reports*, 13(1).
- Davis, S. E., et al. (2020). Detection of calibration drift in clinical prediction models to inform model updating. *Journal of Biomedical Informatics*, 112.
- Davis, S. E., et al. (2017). Calibration drift among regression and machine learning models for hospital mortality. *AMIA Annual Symposium Proceedings*, 2017.
- Johnson, A. E. W., et al. (2023). Author correction: MIMIC-IV, a freely accessible electronic health record dataset. *Scientific Data*, 10(1).
- Iwase, S., et al. (2022). Prediction algorithm for ICU mortality and length of stay using machine learning. *Scientific Reports*, 12(1).
- Awad, A., et al. (2017). Early hospital mortality prediction of intensive care unit patients using an ensemble learning approach. *International Journal of Medical Informatics*, 108.
- Purushotham, S., et al. (2018). Benchmarking deep learning models on large healthcare datasets. *Journal of Biomedical Informatics*, 83.
- Harutyunyan, H., et al. (2019). Multitask learning and benchmarking with clinical time series data. *Scientific Data*, 6(1).
- Steyerberg, E. W., et al. (2010). Assessing the performance of prediction models: A framework for traditional and novel measures. *Epidemiology*, 21(1).
- Lundberg, S. M., et al. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2(1).
- Lundberg, S. M., et al. (2018). Explainable machine-learning predictions for the prevention of hypoxaemia during surgery. *Nature Biomedical Engineering*, 2(10).

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Исмухамедова Айгерим Мэлсатовна** – PhD, AP22683316 ғылыми жобасының жетекшісі, компьютерлік ғылымдар мектебі, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

**Исмухамедова Айгерим Мэлсатовна** – PhD, Руководитель научного проекта AP22683316, Школа компьютерных наук, Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Ismukhamedova Aigerim** – PhD, Head of the scientific project AP22683316, School of Computer Science, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan, e-mail: Aigerim.ismukhamedova1@gmail.com, ORCID: <https://orcid.org/0000-0002-4931-337X>,



**Баканова Анна Павловна** – т.ғ.к., оқытушы, Қазақстан-Америка Еркін Университеті (ҚАЕУ), Өскемен, Қазақстан

**Баканова Анна Павловна** – к.т.н., преподаватель, Казахстанско-Американский Свободный Университет (КАСУ), г. Усть-Каменогорск, Казахстан

**Bakanova Anna** – PhD, Lecturer, Kazakh-American Free University (KAFU), Ust-Kamenogorsk, Kazakhstan,

e-mail: [bakanova55anna@gmail.com](mailto:bakanova55anna@gmail.com),

ORCID: <https://orcid.org/0000-0002-8674-3686>



**Бельгинова Сауле Аскербековна** – PhD, қауымдастырылған профессор, Ақпараттық технологиялар жоғары мектебі, «Тұран» университеті, Алматы қ., Қазақстан

**Бельгинова Сауле Аскербековна** – PhD, ассоциированный профессор, Высшая школа информационных технологий, Университет «Туран», г. Алматы, Казахстан

**Belginova Saule** – PhD, Associate Professor, Graduate School of Information Technology, Turan University, Almaty, Kazakhstan,

e-mail: [sbelginova@gmail.com](mailto:sbelginova@gmail.com),

ORCID: <https://orcid.org/0000-0002-7238-6016>



**Халимов Айсат** – «Ақпараттық жүйелер» мамандығының магистранты, Қазақстан-Америка Еркін Университеті (ҚАЕУ), Өскемен қ., Қазақстан

**Халимов Айсат** – Магистрант специальности «Информационные системы», Казахстанско-Американский Свободный Университет (КАСУ), Усть-Каменогорск, Казахстан

**Khalimov Aisat** – Master's degree in Information Systems, Kazakh-American Free University (KAFU), Ust-Kamenogorsk, Kazakhstan

e-mail: [Khalais2012@gmail.com](mailto:Khalais2012@gmail.com)



**Рысбаев Тимур** – «Ақпараттық жүйелер» мамандығының магистранты, Қазақстан-Америка Еркін Университеті (ҚАЕУ), Өскемен, Қазақстан

**Рысбаев Тимур** – «Магистрант специальности «Информационные системы», Казахстанско-Американский Свободный Университет (КАСУ), Усть-Каменогорск, Казахстан

**Rysbayev Timur** – Master's degree in Information Systems, Kazakh-American Free University (KAFU), Ust-Kamenogorsk, Kazakhstan

e-mail: [timur.rysbayev1@gmail.com](mailto:timur.rysbayev1@gmail.com)

[https://doi.org/10.51885/3134-8025\\_IICS\\_2026\\_1\\_9](https://doi.org/10.51885/3134-8025_IICS_2026_1_9)

MPNТИ 14.35.07

## ПОВЫШЕНИЕ НАДЕЖНОСТИ ПРОГНОЗИРОВАНИЯ ОБРАЗОВАТЕЛЬНЫХ ТРАЕКТОРИЙ РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМОЙ, ОБЪЕДИНЯЮЩЕЙ АКАДЕМИЧЕСКИЕ И МОТИВАЦИОННЫЕ ПРОФИЛИ

## АКАДЕМИЯЛЫҚ ЖӘНЕ МОТИВАЦИЯЛЫҚ ПРОФИЛЬДЕРДІ БІРІКТІРЕТІН ҰСЫНЫС БЕРУ ЖҮЙЕСІНІҢ БІЛІМ БЕРУ ТРАЕКТОРИЯЛАРЫН БОЛЖАУ СЕНІМДІЛІГІН АРТТЫРУ

## INCREASING THE RELIABILITY OF PREDICTING EDUCATIONAL TRAJECTORIES BY A RECOMMENDATION SYSTEM THAT UNITES ACADEMIC AND MOTIVATIONAL PROFILES

Г.В. Попова <sup>1\*</sup>, Ю.А. Вайс <sup>1</sup>, И.А. Котлярова <sup>1</sup>,

Г. Жомартқызы <sup>1</sup>, Н.П. Рохас Криулько <sup>1</sup>

<sup>1</sup>Восточно-Казахстанский технический университет имени Д. Серикбаева,  
г. Усть-Каменогорск, Казахстан

\*Автор-корреспондент: Попова Галина Владимировна, gpopova@edu.ektu.kz

### Ключевые слова:

Гибридная  
рекомендательная  
система, академический  
профиль,  
мотивационный  
профиль, совместная  
фильтрация,  
прогнозирование  
образовательных  
траекторий, Minog-  
программа.

### АННОТАЦИЯ

Настоящее исследование связано с тем, что традиционные рекомендательные системы демонстрируют не очень высокую точность выбора курсов. В центре внимания данного исследования было построение и эмпирическое обоснование использования предложенной рекомендательной системы. Исследование направлено на создание рекомендательной системы и ее проверку для прогнозирования образовательных траекторий IT-специальностей ВКТУ.

Для решения задачи исследования применялась матричная факторизация при моделировании академического профиля обучающихся. Параллельно создан мотивационный вектор, строящийся на базе психометрического моделирования RIASEC. Результаты двух прогностических компонент были объединены через линейную взвешенную комбинацию, при этом коэффициент в этой комбинации оптимизирован методом Grid Search. Оценка точности и стабильности выполнена с использованием пятикратной кросс-валидации и ключевых метрик.

Найденное значение коэффициента  $\alpha=0.58$  дало оптимальные параметры нашей системы. При данном коэффициенте получились наибольшая точность прогноза и самая низкая ошибка. Наша модель продемонстрировала значительную стабильность результатов.



Исследование подтверждает, что построенная в нашей системе комбинация академического и мотивационного профилей может являться одной из компонент для разработки открытых и надежных рекомендательных систем.

---

#### **Түйінді сөздер:**

Гибридігі ұсыныс беру жүйесі, академиялық профиль, мотивациялық профиль, бірлескен сүзгілеу, білім беру траекториясын болжау, Minor-бағдарлама.

---

#### **ТҮЙІНДЕМЕ**

Бұл зерттеу дәстүрлі ұсыныс жүйелерінің курс таңдау дәлдігінің аса жоғары еместігін көрсетеді. Бұл зерттеудің басты бағыты ұсынылған ұсыныс беру жүйесін қолданудың құрылымы мен эмпирикалық негіздеме болды. Зерттеудің мақсаты – ұсыныс беру жүйесін құру және оны ШҚТУ IT мамандықтарының білім беру траекторияларын болжау үшін тексеру.

Зерттеу мәселесін шешу үшін білім алушылардың академиялық профилін модельдеуде матрицалық факторизация қолданылды. RIASEC психометриялық модельдеуіне негізделген мотивациялық вектор параллель түрде жасалды. Екі болжамдық компоненттің нәтижелері сызықтық салмақталған комбинация арқылы біріктірілді, ал бұл комбинациядағы коэффициент Grid Search әдісімен оңтайландырылды. Дәлдік пен тұрақтылықты бағалау бес еселі кросс-валидация және негізгі метрикаларды қолдану арқылы жүргізілді.

Табылған  $\alpha=0,58$  коэффициент мәні ұсынылған жүйенің оңтайлы параметрлерін берді. Бұл коэффициентте ең жоғары болжам дәлдігі және ең төменгі қателік алынды. Ұсынылған модель нәтижелердің айтарлықтай тұрақтылығын көрсетті. Зерттеу ұсынылған жүйеде енгізілген академиялық және мотивациялық профильдердің комбинациясы ашық және сенімді ұсыныс беру жүйелерін әзірлеу кезінде компоненттердің бірі бола алатынын растайды.

---

#### **Keywords:**

Hybrid recommendation system, academic profile, motivational profile, collaborative filtering, educational trajectory prediction, minor program

---

#### **ABSTRACT**

The present study is due to the fact that traditional recommendation systems demonstrate not very high course selection accuracy. The focus of the present study was the construction and empirical validation of the use of the proposed recommender system. The study intended to build a recommendation system and test it for predicting the educational trajectories of IT majors of VKTU.

To address the research problem, matrix factorization was applied in modeling the academic profile of the learners. A motivational vector building on the RIASEC psychometric modeling was created in parallel. The results of the two predictive components were combined through a linear weighted combination, whereas the coefficient in this combination was optimized by the Grid Search method. Accuracy and stability evaluation was performed using five-fold cross-validation and key metrics.

The found coefficient value of  $\alpha=0.58$  gave the optimal parameters of our system. At this coefficient, the highest prediction accuracy and the lowest error were obtained. Our model demonstrated significant results stability. The study confirms that the combination of academic and motivational profiles built into our system can be one of the components for developing open and reliable recommender systems.

---

#### **ВВЕДЕНИЕ**

Современное высшее образование переживает период глубокой трансформации. Этот факт отмечается во многих источниках. Отмечается отход учебных планов от старых

стандартов в смысле того, что происходит активный отход от жестко определенных и единых программ в пользу вариативных, модульных траекторий. Данные изменения в высшем образовании, в том числе и Казахстана, безусловно, продиктованы требованиями концепции «обучения в течение жизни» (lifelong learning) (Bonfield, D., 2025). Концепция, не имеющая на данный момент других более или менее хороших альтернативных вариантов, требует от будущих выпускников и работающих специалистов постоянного обучения и быстрого приобретения новых компетенций.

Программы Minor (мини-специализации), с учетом вышесказанного, выступают одним из важных инструментов реализации адаптивности и индивидуальности в вузах. Например, в ВКТУ, как и в других университетах Казахстана, их внедрение полностью соответствует Болонскому процессу и кредитно-модульной системе. Что это дает? Студенты получают возможность сформировать индивидуальный набор компетенций, который может быть при правильном подходе более востребованным на рынке труда. Полученные в результате знания и навыки значительно расширяют собственный профессиональный потенциал. Более того, часто именно выбор Minor-программы задает будущую карьерную траекторию, выступая прямым связующим звеном между базовым обучением и специализированной профессиональной деятельностью (Rocek M. et al, 2023).

В исследовании предлагается механизм рекомендаций, который основан на совместном учете личных предпочтений учащихся (при выборе Minor-ов) и академической успеваемости.

Потребность в таком исследовании диктуется необходимостью уменьшения рисков, связанных с неверным выбором этих дополнительных специализаций обучающимися. Мы полагаем, что этот выбор должен достигаться через сложный баланс двух наиболее важных, порой даже противоречащих друг другу компонентов. Во-первых, очевидно, что выбор должен, с одной стороны, обеспечивать востребованность навыков и полностью соответствовать академическому потенциалу обучающегося, который, как правило, объективно отражается в его успеваемости. Во-вторых, очень часто недооценивается, что выбор должен сбалансированно сочетаться с личными интересами и наклонностями. Только долговременная и искренняя заинтересованность в профессиональной сфере (а не только отличные оценки) дает основание для удовлетворенности и хорошей работоспособности в производственной деятельности (MA Thanh Trung Pham et al, 2025). В свою очередь, возможна комбинация неудачного сочетания отличной успеваемости с отсутствием интереса к изучаемым дисциплинам, которая приводит к подготовке некомпетентных специалистов, что негативно для экономики и является серьезной проблемой.

Таким образом, вытекает необходимость научно обоснованного объединения этих двух факторов как основной проблемы нашего исследования. На наш взгляд, главный пробел в научных исследованиях по данной теме заключается в том, что в настоящее время отсутствует достаточно хорошая модель. Такая модель помогла бы в процессе выбора адекватно, взвешенно соединять и оценивать не только успеваемость, но и личную заинтересованность в изучаемых дисциплинах. Сформированные на данный момент рекомендательные системы, используемые в высшем образовании, имеют недостатки. Они либо опираются на контентный анализ (в этом случае вообще не рассматривается успеваемость), либо строятся на коллаборативной фильтрации (тогда интерес обучающихся не учтен) (Vujang S. D. et al, 2021).

Исходя из этого, основная идея исследования состоит в разработке метода. Такой метод должен формировать более надежные и точные рекомендации для Minor-программ, чем в традиционных системах. При этом достижение поставленной цели исследования

может обеспечиться за счет комплексного соединения мотивированности и достаточно успешного освоения дисциплин.

Такой подход, возможно, может не учесть в полной мере всю сложность индивидуальных образовательных траекторий. Но в рамках цифровой трансформации образования такая разработка помогает сделать шаг к по-настоящему адаптивному и персонализированному обучению.

## МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Начнем исследование рекомендательных систем с выделения двух очень важных входных типов данных. Есть основание полагать, что именно эти данные наиболее точно описывают успешность обучения и в том числе последующую удовлетворенность обучающегося. Эти данные сформируют два отдельных и тем не менее согласованных прогностических ядра. Сфокусируем внимание на двух основных аспектах нашей модели. Первым аспектом является академический профиль (обозначим его как  $M_A$ ). Этот профиль использует исключительно только фактические данные об успеваемости обучающихся. По сути, профиль  $M_A$  должен показывать потенциальную способность обучающегося к достижимым оценкам по новым дисциплинам. Такое предположение подтверждается рядом научных исследований (Сао Thi, Т.-Х., 2023). Вторым в нашем случае является мотивационный профиль ( $M_M$ ). Чтобы его вычислить и построить воспользуемся психометрическим подходом. В этом подходе будем использовать модель RIASEC (профиль профессиональных интересов). Задача мотивации, на наш взгляд, дать наиболее близкую количественную оценку личной заинтересованности, а также совместимости обучающегося с конкретными Minor-программами (Yang, Z. et al., 2023). Разработка рекомендательной системы в строящейся модели линейно агрегирует данные этих двух профилей. Но при всем этом оценка каждого из профилей выполняется независимо друг от друга.

Далее рассмотрим архитектуру прогностических ядер. Для моделирования академического ядра ( $R_A$ ) мы выбрали подход матричной факторизации (MF). Почему выбирается именно MF? Дело в том, что этот метод хорошо зарекомендовал себя при использовании во многих работах как один из самых полезных и точных инструментов. Причем именно там, где сталкиваемся с наиболее сильно и даже высоко разреженными данными, а в образовательных системах такой вариант вполне вероятен (Al-Ajmi, S. et al, 2024).

Для решения проблемы с высокой размерностью исходного пространства признаков ( $n$  – число анализируемых обучающихся,  $k$  – число основных курсов) еще и снижения коллинеарности оценок, мы применим сингулярное разложение матрицы (SVD) к разреженной матрице оценок  $O$  ( $n \times k$ ) (Пилявская И.М., 2022). Формула (1) показывает это:

$$O \approx U \Sigma V^T, \quad (1)$$

здесь  $O$  – это матрица оценок;  $U$  – матрица скрытых факторов  $n \times l$ ;  $\Sigma$  – диагональная матрица сингулярных чисел  $l \times l$ ; а  $V^T$  – матрица  $l \times k$ .

На основе двух векторов ( $u_A$  и  $u_M$ ), характеризующих обучающихся, мы будем строить общий вектор профиля обучающегося  $u_T$  путем их простого объединения, как это показано в (2). Построенные векторы будут нашими общими входными данными:

$$u_T = [u_A \circ u_M]. \quad (2)$$

Строящаяся для определения ранжирования Minor-дисциплин модель образуется двумя независимыми друг от друга прогностическими компонентами. Одна из компонент предназначена оценить желание обучающегося к освоению каждой из Minor-программ. Эту компоненту или ядро в дальнейшем будем называть мотивационной моделью ( $M_M$ ).

Модель предназначена для выявления закономерностей, которые согласуются с выявленными предпочтениями обучающихся на анализируемом наборе Minor. В случае мотивационной модели задача не линейная и FNN хорошо подходит для такого типа прогнозов (Jawed Liu et al, 2022). Данные для нейросети в нашем случае формируем как составной вектор  $z$ . Первая часть вектора несет в себе данные мотивации обучающегося  $u_M$ . Вторая часть  $i_C$  содержит информацию описания дисциплин, ключевые слова, набор результатов обучения и компетенций по предметам Minor. Это отражено в формуле:

$$z = [u_M \circ i_C]. \quad (3)$$

Такое сочетание данных учтет информацию о Minor-программах и индивидуальность обучающегося в рамках интереса к изучению этих программ. Для нормализации итога этой модели в выходном слое используется функция активации сигмоида. Она приводит значения в диапазон от 0 до 1 за счет масштабирования данных. Формула значения  $P_M(u, i)$  показывает нам вероятность того, насколько удовлетворен  $u$ -й обучающийся  $i$ -ой Minor-программой (здесь три скрытых слоя ReLU):

$$P_M(u, i) = \sigma(W_3 \cdot \text{ReLU}(W_2 \cdot \text{ReLU}(W_1 \cdot z + b_1) + b_2) + b_3), \quad (4)$$

здесь  $W_k$  – матрицы весов,  $b_k$  – векторы смещений. В обучении модели мы использовали функцию потерь бинарной кросс-энтропии.

Вторая часть нашей модели  $M_A$  (академическое ядро) дает возможность рассчитать наиболее вероятную оценку освоения по окончанию программ (Lee H. et al ,2024). По формуле 5 вычисляем предсказание для учащегося  $u$  и программы  $i$ :

$$\hat{r}_{ui} = b_u + b_i + \sum_{j=1}^l p_{uj} q_{uj}, \quad (5)$$

где  $p_{uj}$  и  $q_{uj}$  – скрытые искомые закономерности. В этой формуле учтены смещения  $b_u$  и  $b_i$ .

Как всегда, в таком типе обучения минимизируется функция потерь  $L(P, Q, b)$  стохастическим градиентным спуском с  $L_2$ -регуляризацией. Само уравнение для потерь выражается как формула:

$$L(P, Q, b) = \sum_{(u,i) \in R} (\hat{r}_{ui} - r_{ui})^2 + \varphi(\|P\|^2 + \|Q\|^2 + \|b\|^2), \quad (6)$$

Хочется обратить внимание на тот факт, что первое слагаемое в (6) представляет собой измерение ошибки прогноза. Второе слагаемое в (6) выполняет роль ограничения, чтобы предотвратить чрезмерное переобучение модели. Тут  $\|\dots\|^2$  является  $L_2$ -нормой, и, соответственно, штраф применяется ко всем обучаемым параметрам модели. Гиперпараметр  $\varphi$  отвечает за силу штрафа, чем выше  $\varphi$ , тем проще и быстрее модель обучается. При низких значениях  $\varphi$  модель может переобучиться.

Чтобы результаты  $\hat{r}_{ui}$  можно было сопоставить между собой, проводится масштабирование за счет нормализации Min-Max (по формуле 7). В этом случае получаемая оценка академического потенциала  $P_A(u, i)$  будет находиться в диапазоне от 0 до 1. Это, по нашему мнению, является важным фактором для дальнейшего объединения компонент в рекомендательную модель:

$$P_A(u, i) = \frac{\hat{r}_{ui} - \hat{r}_{min}}{\hat{r}_{max} - \hat{r}_{min}}. \quad (7)$$

Линейно взвешенная комбинация этих нормированных компонент построенной модели позволит создавать разнообразные отсортированные по приоритету списки.  $R(u, i)$  показывает такую оценку  $i$ -ой программы для  $u$ -го обучающегося:

$$R(u, i) = \alpha \cdot P_A(u, i) + (1 - \alpha) \cdot P_M(u, i). \quad (8)$$

Коэффициент  $\alpha$  дает возможность сбалансировать  $P_A(u, i)$  и  $P_M(u, i)$  в модели за счет его изменения в интервале  $[0, 1]$ . На независимом наборе данных будем применять поиск по сетке (Grid Search). Метрика ранжирования  $NDCG@k$  при достижении своего наибольшего из всех значений при этом даст нам оптимальное число  $\alpha$ . Сама метрика  $NDCG@k$  рассчитывается по формуле (Choi, S.-M. et al, 2023):

$$NDCG@k = \frac{DCG@k}{IDCG@k} \quad (9)$$

тут  $IDCG@k$  выступает как эталонное ранжирование, которое позволяет нормализовать  $DCG@k$ . В свою очередь  $DCG@k$  является фактором совмещающим позицию в списке с оценкой его семантического соответствия.

## РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Перед внедрением в информационную систему университета предложенного подхода требуется эмпирическая проверка.


Проверим гипотезу нашего исследования: эффективней ли рекомендательная модель  $R(u, i)$  в рекомендательной системе дает прогнозы, чем каждая из моделей  $P_A(u, i)$  и  $P_M(u, i)$  в отдельности. Данные об успеваемости будем брать за первые два курса, так как Minor изучаются, начиная с третьего курса обучения. Мотивационный профиль создается для тех же самых обучающихся.

Для аналитической проверки информационную базу составили по ОП «Информационные системы» и «Вычислительная техника», выгруженные из образовательного портала ВКТУ им. Д.Серикбаева за период с 2018 по 2023 годы. Для анализа нам было необходимо, чтобы обучающиеся закончили Minor-программы на третьем и четвертом курсах, чтобы получить корректные данные. Именно поэтому последним для исследования был взят 2023 год обучения. Таким образом, единицей наблюдения для исследования является индивидуальный профиль обучающегося. Общий объем выборки 517 индивидуальных профилей обучающихся и 14 программ Minor. Согласно рабочим планам взятых образовательных программ на первом и втором курсах изучались по 42 дисциплины в каждой. В этом наборе данных мы не исключали те дисциплины, которые, на первый взгляд, почти не влияют на профильный успех — например, «Физическая культура» и «Основы антикоррупционной культуры». Также в информационную базу входят дисциплины, которые коррелируют с некоторыми из Minor — например, предметы «Алгоритмы, структуры данных и программирование», «Технология программирования».

В результате первичной обработки выяснилось, что в получившемся наборе данных матрица взаимодействий оказалась разреженной на 89,7 %. Такой высокий показатель не дает возможности хорошего предсказания классическим системам фильтрации (Man Li et al, 2021). В таких случаях это является приговором для такого рода систем, что еще раз показывает важность нашего подхода.

Основной задачей в нашем анализе стала оптимизация весового коэффициента  $\alpha$  в формуле 8 линейно взвешенной комбинации нашей модели. Именно он создает баланс, регулируя интерес к программе обучающегося как субъекта и отражая его успехи объективными результатами оценивания. Для получения объективного и надежного численного результата поиска глобального оптимума использован метод поиска по сетке Grid Search с применением пятикратной перекрестной проверки. Поиск осуществлялся в диапазоне  $\alpha \in [0, 1]$  с шагом 0,01. В качестве метрик для оценки качества ранжирования взяли  $NDCG@10$ , так как она наиболее часто используется в такого рода исследованиях по сортировке списков по приоритетам. Как наглядно демонстрирует рисунок 1 оптимальное значение метрики (наибольшее ее значение) находится в диапазоне значений

коэффициента  $\alpha = 0,58 \pm 0,1$ , при этом пиковое значение NDCG@10 будет при  $\alpha = 0,58$ . А это говорит о необходимости учета обоих факторов.



**Рисунок 1.** Зависимость точности NDCG@10 от весового коэффициента  $\alpha$

Примечание – составлено авторами

При вкладе примерно в 58 % от академической и в 42 % от мотивационной модели можно ожидать от нашей модели демонстрации наиболее точной оценки прогноза. Здесь мы еще можем отметить и тот факт, что метрика NDCG@10 сильно снижается при изменении коэффициента даже в диапазоне около  $\pm 0,1$  от найденного значения. Этот факт говорит о том, что найден критический диапазон значения коэффициента  $\alpha$ .


В таблицу 1 сведены аналитические данные показателей точности и ошибок работы моделей по отдельности и совместной рекомендательной модели. В таблице в первой строке включен вариант, когда Minog-программа выбирается случайным образом. Такая модель нам нужна для показания границы, когда точность прогноза будет наименьшей. То есть модель, в которой есть хоть какая-нибудь логика выбора, должна превосходить по точности прогноза случайную.

**Таблица 1.** Метрики моделей

Модель	Методология	NDCG@10	MAP@10	RMSE	MAE	Оценка
Случайное ранжирование	Baseline	0,403	0,356	1,32	0,96	наименьшая точность
$M_A$ (базовая)	SVD	0,723	0,684	0,87	0,68	плохая точность при недостаточных данных
$M_M$ (мотивационная)	FNN, $u_m \circ i_c$	0,649	0,607	0,96	0,82	устойчивая
$R(u, i)$ (рекомен – дательная)	линейно взвешенная комбинация $\alpha = 0,58$	0,816	0,758	0,69	0,53	лучший вариант по параметрам прогноза и точности

Примечание – составлено авторами

Из полученных нами аналитических данных в таблице 1 видно, что рекомендательная модель дает наибольшую точность метрик из всех моделей и самую малую ошибку  $RMSE$ . Прирост точности построенной нами модели по сравнению с базовой академической моделью по метрике  $NDCG@10$  в 12,9 % оказался значительным. Можно отметить еще и низкие значения ошибок прогноза у обеих моделей по сравнению с другими, хотя у построенной в нашем исследовании модели она меньше. Рис. 2 наглядно показывает, что лучшие показатели у построенной модели.



**Рисунок 2.** Анализ показателей моделей по метрикам  $NDCG@10$  и  $MAP@10$

Примечание – составлено авторами

Рассмотрим показатели метрик  $MAP$  и  $NDCG$  при разных значениях количества дисциплин  $k$  в приоритетном списке и сведем их в таблицу. В эксперименте из таблицы можно увидеть, что наибольшее значение прогнозных оценок нахождения оптимальной  $Minop$ -программы получается именно для построенной в исследовании модели. Значение в 0,843 показывает высокий шанс в списке первых 5 программ найти нужную.


**Таблица 2.** Детализация метрик  $NDCG$  и  $MAP$  по уровню ранжирования  $k$

Модель	$NDCG@5$	$NDCG@10$	$NDCG@15$	$MAP@5$	$MAP@10$
$M_A$	0,756	0,723	0,712	0,703	0,684
$M_M$	0,687	0,649	0,638	0,632	0,607
$R(u, i)$	0,843	0,816	0,798	0,781	0,758

Примечание – составлено авторами

Некоторые данные обучающихся на первых двух курсах по образовательным программам ИТ плохо связаны с  $Minop$ -программами, так как на этих курсах большая часть дисциплин - это общеобразовательные дисциплины (например, «Физическая культура»). Из-за таких дисциплин модель  $SVD$  в сценарии «холодного старта» показывает скромную

точность в 0,590. В отличие от академического ядра, мотивационное тем не менее сохраняет прежний уровень точности. Именно за счет этого рекомендательная система показывает точность прогнозного значения 0,776. Такой результат говорит о том, что точность построенной рекомендательной системы на 31,53% лучше, чем просто прогноз базовой модели. Это позволяет давать вполне надежные рекомендации по выбору программ до того, как обучающиеся освоят базовые дисциплины, связанные с программированием (например, такие как «Технология программирования», «Алгоритмы, структуры данных и программирование»). График на рисунке 3 демонстрирует устойчивость рекомендательной системы.



**Рисунок 3.** График значений точности прогноза моделей в условиях «холодного старта»  
Примечание – составлено авторами

Рассчитанные в результате анализа значения показывают связь между  $RMSE$  и  $RIASEC$ . Из вычислений следует, что если высокая ( $>0,85$ ) мотивация по  $RIASEC$ , то снижается до 0,63 ошибка прогноза  $RMSE$ . И наоборот, низкий ( $<0,40$ ) интерес к сфере приводит к увеличению ошибки до 0,93. Таким образом, мотивация – это не просто учет индивидуальных интересов обучающихся, а реальный фактор снижения рисков. Мотивация, таким образом, показывает и здесь, что она является значимым фактором, который способствует гарантированному успешному окончанию Minog-программы при длительном использовании.

На последнем этапе исследования проведена проверка устойчивости с использованием тестирования модели пятикратной кросс-валидацией. Вариация всего в 2,27 % построенной рекомендательной системы 5,35% почти в два раза меньше, чем у базовой модели  $SVD$  (табл. 3).

**Таблица 3.** Результаты тестирования по пятикратной кросс-валидации

Модель	Средний $NDCG@10$	Доверительный интервал (95%)	Коэффициент вариации (%)
$M_A$	0,723	$\pm 0,048$	5,35
$R(u, i)$	0,816	$\pm 0,023$	2,27

Примечание – составлено авторами

Значения в таблице говорят о предсказуемости и стабильности нашей системы. Лучшие результаты прогноза в плане ошибки система демонстрирует на близких к ИТ узкопрофильных технических дисциплинах (например, Minor-программа 11 «Горная квалиметрия», «Беспилотники в горнодобывающем секторе», «Геотехнология»  $RMSE$  около 0,61). В свою очередь, для гуманитарных программ (Minor-программы 1 «Академическое письмо», «Английский для специальных целей», «Базовый иностранный на выбор») ошибка чуть выше, около 0,77. В целом для найденного значения весового коэффициента  $\alpha = 0,58$  построенная модель дает низкую ошибку и хорошую точность прогноза рекомендательной системой.

Полученные результаты говорят о высоком качестве построенной модели. Но, тем не менее, есть вероятность, что со временем могут измениться предпочтения у конкретного обучающегося. А это в свою очередь со временем влияет на достоверность рекомендаций.

### ЗАКЛЮЧЕНИЕ

Проведенное исследование показало решение поставленной задачи построения рекомендательной системы, объединяющей мотивационный и академические профили на примере обучающихся по образовательным программам ИТ. Такая система, как показал анализ, оказалась более надежной и точной в плане рекомендаций для изучения Minor-программ как мини специализаций. На наш взгляд, основным результатом исследования является успешная апробация построенной рекомендательной системы  $R(u, i)$ . Причем система учитывает как полученные оценки по всем дисциплинам, изучаемым на первых двух курсах, так и личные предпочтения при выборе из представленного списка Minor-программ.

Эксперименты в рамках данного исследования аналитически показали важность учета и личного интереса и прошлых оценок, полученных в процессе учебы. Об этом говорит соотношение 0,58 к 0,42 (академической модели к мотивационной), полученное при поиске оптимального весового коэффициента. На основании этого соотношения можно сделать вполне аргументированный вывод, что мотивация вносит в прогнозный результат ненамного меньше, чем академическая составляющая. Анализ метрик  $NDCC@10$  и  $RMSE$  также подтверждает это положение. Значения этих метрик оказались гораздо лучше в построенной в рамках исследования модели, чем в моделях, которые игнорируют интересы обучающихся.

Особенность предложенного подхода - это использование дополнительно профиля мотивированности обучающихся  $RIASEC$ , в отличие от распространенных гибридных систем, основанных на анализе ключевых слов и демографических характеристик (Burke, R., 2002.; Dierks P.O. et al, 2016). Такое использование сделало модель  $R(u, i)$  более стабильной. Об этом говорит коэффициент вариации, принимающий низкое значение 2,27% для нашей модели. Еще одним плюсом в пользу предложенного решения стало то, что модель решила проблему «холодного старта». Такая проблема для простых алгоритмов обычно неразрешима.

Полученные рекомендации построенной нами системы следует понимать как вспомогательную информацию для принятия решения в выборе, а не как обязательный к выполнению план.

В дальнейших исследованиях одним из актуальных направлений будет настройка мотивационного ядра  $P_M$ . Такая настройка на соответствующих данных может позволить улучшить прогностическую способность модели для, например, гуманитарных образовательных программ. Можно также изучить динамическое изменение весового коэффициента  $\alpha$  в зависимости от курса обучающегося.

Подводя итог, можно с уверенностью говорить о том, что предложенная модель  $R(u, i)$  показала себя как прозрачный, надежный и очень эффективный инструмент. Полученное нами решение практически значимо. Оно помогает обеспечить обучающихся персонализированными рекомендациями. Для консультантов решение будет полезно в плане обоснования рекомендаций. Администрация университета получает пользу от такого решения в плане более осмысленного управления образовательным процессом.

**КОНФЛИКТ ИНТЕРЕСОВ:** Авторы заявляют об отсутствии конфликта интересов.

#### СПИСОК ЛИТЕРАТУРЫ

- Al-Ajmi, S. et al. (2024). Hybrid attribute-based recommender system for personalized e-learning with emphasis on cold start problem. *Frontiers in Computer Science*, Vol. 6. <https://doi.org/10.3389/fcomp.2024.1404391>.
- Burke, R. (2002). Hybrid Recommender Systems: Survey and Experiments. *User Modeling and User-Adapted Interaction*, 12, 331-370. <https://doi.org/10.1023/A:1021240730564>.
- Bujang S. D., Selamat A., Ibrahim R., Krejcar O., Herrera-Viedma E. Fujita, H., Ghani, N. A. Multiclass prediction model for student grade prediction using machine learning, *IEEE Access*, vol. 9, pp. 95608-95621, 2021, <https://doi.org/10.1109/ACCESS.2021.3093563>.
- Bonfield, D., Hassan, M.G., Palmieri, J.M. (2025). Integration of Professional Skills (Communications, Teamwork, Etc.), Ethics, Empathy Lifelong Learning into the Student's Educational Experiences. In: Kandakatla, R., Kulkarni, S., Auer, M.E. (eds) *Academic Leadership in Engineering Education. Lecture Notes in Networks and Systems*, vol 1097. Springer, Cham. <https://doi.org/10.1007/978-3-031-68282-7>.
- Dierks P.O., Höffler T.N., Blankenburg J.S., Peters H., & Parchmann I. (2016). Interest in science: A RIASECbased analysis of students' interests. *International Journal of Science Education*, 38, 238–258, <https://doi.org/10.1080/09500693.2016.1138337>.
- Cao Thi, T.-X. (2023). Singular value decomposition and applications in data processing and artificial intelligence. *HPU2 Journal of Science: Natural Sciences and Technology*, 2(3), 34–41. <https://doi.org/10.56764/hpu2.jos.2023.2.3.34-41>.
- Jawed Liu, Chuan Shi, Cheng Yang, Zhiyuan Lu, Philip S. Yu, (2022) A survey on heterogeneous information network based recommender systems: Concepts, methods, applications and resources, *AI Open*, 3, 40–57. <https://doi.org/10.1016/j.aiopen.2022.03.002>.
- Lee H., Cho S., Jiang Y., Kim J. Woo, H. (2021). Differentiable ranking metrics using relaxed sorting for top-k recommendation. *IEEE Access*, 9, pp.114649-114658. <https://doi.org/10.1109/access.2021.3105389>.
- Choi, S.-M., Lee, D., Jang, K., Park, C., & Lee, S. (2023). Improving Data Sparsity in Recommender Systems Using Matrix Regeneration with Item Features. *Mathematics*, 11(2), 292. <https://doi.org/10.3390/math11020292>.
- Man Li, Luosheng Wen, Feiyu Chen, (2020) A novel Collaborative Filtering recommendation approach based on Soft Co-Clustering. *Physica A: Statistical Mechanics and its Applications*, 561. 125140 pp. <https://doi.org/10.1016/j.physa.2020.125140>.
- MA Thanh Trung Pham , Thi Thanh Do , Thi Thanh Hai Dinh , Thi Thanh Van Nguyen , Kim Nguu (2025), *International Journal of Research and Innovation in Social Science (IJRISS)*, Vol. 9, Issue 05, Pages 4162-4175, <https://doi.org/10.47772/IJRISS.2025.905000317>.
- Rocek M., Juva V., Jakubcova K. Development of a Questionnaire Focused on Sports Coaches Learning (2023) *Studia Sportiva*, 17 (1), pp. 87 – 98. <https://doi.org/10.5817/STS2023-1-8>.
- Yang, Z. et al. (2023). Deep Learning and Embedding Based Latent Factor Model for Collaborative Recommender Systems. *Applied Sciences*, Vol. 13, No. 2. (MDPI). Open, Volume 3, 2022, Pages 40-57, ISSN 2666-6510, <https://doi.org/10.1016/j.aiopen.2022.03.002>.

Tursyn M.S. Role of artificial intelligence in sign language recognition. Herald of the Kazakh-British Technical University. 2025;22(1):94-102. <https://doi.org/10.55452/1998-6688-2025-22-1-94-102>.

Пилявская И.М. Разработка архитектуры гибридной рекомендательной системы для финансового ассистента // Universum: технические науки. – 2022. – № 5-2 (98). – С. 41–44. // Piliavskaia I.M. Razrabotka arkhitektury gibridnoi rekomendatel'noi sistemy dlia finansovogo assistenta [Development of the architecture of a hybrid recommender system for a financial assistant] // Universum: tekhnicheskie nauki. – 2022. – No. 5-2 (98). – P. 41–44. (In Russ.)

### Авторлар туралы мәліметтер Информация об авторах Information about authors



**Попова Галина Владимировна** – физика-математика ғылымдарының кандидаты, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан,

**Попова Галина Владимировна** – кандидат физико-математических наук, Восточно-Казakhstanский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан,  
**Popova Galina Vladimirovna** – Candidate of Physical and Mathematical Sciences, D.Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan,  
e-mail: [assadenova@edu.ektu.kz](mailto:assadenova@edu.ektu.kz),  
ORCID: <https://orcid.org/0000-0002-6935-1066>



**Вайс Юрий Андреевич** – техника ғылымдарының кандидаты, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан,

**Вайс Юрий Андреевич** – кандидат технических наук, Восточно-Казakhstanский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан ,  
**Vais Yuriy Andreevich** – Candidate of Technical Sciences, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan,  
e-mail: [yuvais@edu.ektu.kz](mailto:yuvais@edu.ektu.kz),  
ORCID: <https://orcid.org/0000-0002-2964-8260>,



**Котлярова Ирина Александровна** – техника және технология магистрі, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ «Цифрлық технологиялар және жасанды интеллект мектебі» аға оқытушы, Өскемен қ., Қазақстан,  
**Котлярова Ирина Александровна** – магистр техники и технологии, Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан,  
**Kotlyarova Irina Aleksandrovna** – Master of Engineering and Technology, D.Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan, IKotlyarova@edu.ektu.kz,  
e-mail: IKotlyarova@edu.ektu.kz,  
ORCID: <https://orcid.org/0009-0006-5372-4207>



**Гүльназ Жомарткызы** – PhD докторы, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ-нің «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан,  
**Гүльназ Жомарткызы** – доктор PhD, ассоциированный профессор «Школа цифровых технологий и искусственного интеллекта», НАО «Восточно-Казахстанский технический университет им. Д. Серикбаева», г. Усть-Каменогорск, Казахстан,  
**Gulnaz Zhomartkyzy** – PhD, Associate Professor, School of Digital Technology and Artificial Intelligence, NCJSC «D. Serikbayev East Kazakhstan Technical University», Ust-Kamenogorsk, Kazakhstan e-mail: gzhomartkyzy@edu.ektu.kz,  
ORCID: <https://orcid.org/0000-0003-1465-3451>,



**Рохас-Криулько Наталья Педровна** – «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ «Цифрлық технологиялар және жасанды интеллект мектебі» оқытушы, Өскемен қ., Қазақстан,  
**Рохас Криулько Наталья Педровна** – Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск,  
**Rokhas Kriulko Natalia Pedrovna** – D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan,  
e-mail: nrohas@edu.ektu.kz,  
ORCID: <https://orcid.org/0009-0006-6841-0593>



[https://doi.org/10.51885/3134-8025\\_IICS\\_2026\\_1\\_10](https://doi.org/10.51885/3134-8025_IICS_2026_1_10)

SRSTI 81.93.29

## ARCHITECTURE AND INITIAL PERFORMANCE EVALUATION OF A MULTI-AGENT SECURITY AUDIT TOOL IMPLEMENTED IN THE GO LANGUAGE

### GO ТІЛІНДЕ ЕНГІЗІЛГЕН КӨП АГЕНТТІ ҚАУІПСІЗДІК АУДИТ ҚҰРАЛЫНЫҢ АРХИТЕКТУРАСЫ ЖӘНЕ БАСТАПҚЫ ТИІМДІЛІГІН БАҒАЛАУ

### АРХИТЕКТУРА И ПЕРВИЧНАЯ ОЦЕНКА ПРОИЗВОДИТЕЛЬНОСТИ МНОГОАГЕНТНОГО ИНСТРУМЕНТА АУДИТА БЕЗОПАСНОСТИ РЕАЛИЗОВАННОГО НА ЯЗЫКЕ GO

D.K. Tokseit <sup>1\*</sup>, M.N. Sergazy <sup>1</sup>

<sup>1</sup>L.N. Gumilyov Eurasian National University, Astana

\*Corresponding author: Tokseit Dinara Kuandykkyz, e-mail: [tokseit1990@gmail.com](mailto:tokseit1990@gmail.com)

#### Keywords:

penetration testing, multi-agent systems, microservice architecture, Go programming language, NATS message broker, cybersecurity, distributed computing, REST API, PostgreSQL, scalability.

#### ABSTRACT

This article presents the development and performance evaluation of Pentool, a multi-agent penetration testing tool implemented in Go using a microservices architecture. The system comprises four independent agents coordinated via the NATS JetStream message broker for asynchronous, scalable task processing. Experimental studies on port ranges from 100 to 30,000 show that while Pentool has higher overhead on small ranges compared to Nmap, its distributed architecture enables superior scalability and predictable operation (10–100 times lower time variability). Pentool achieves comparable or better performance than Nmap on larger port ranges (from 5000 ports), confirming the effectiveness of the multi-agent approach for extensive security audits. The system demonstrates near-linear horizontal scalability.

#### Түйінді сөздер:

Енуді тестілеу, мульти-агенттік жүйелер, микросервис архитектурасы, Go бағдарламалау тілі, NATS хабарлама брокері, киберқауіпсіздік, бөлінген есептеулер, REST API, PostgreSQL, масштабтау

#### ТҮЙІНДЕМЕ

Бұл мақалада Go жүйесінде микросервис архитектурасын пайдаланып жүзеге асырылған көп агентті енуді тексеру құралы Pentool-дың әзірленуі және өнімділігін бағалау ұсынылған. Жүйе асинхронды, масштабталатын тапсырмаларды өңдеу үшін NATS JetStream хабарлама брокері арқылы үйлестірілген төрт тәуелсіз агенттен тұрады. 100-ден 30 000-ға дейінгі порт диапазондары бойынша эксперименттік зерттеулер Pentool-дың Nmap-пен салыстырғанда шағын диапазондарда жоғары шығындары болғанымен, оның таратылған архитектурасы жоғары масштабталу мен болжамды жұмыс істеуге мүмкіндік беретінін көрсетеді (уақыттың



© 2026 D.K. Tokseit, M.N. Sergazy

This work is licensed under a Creative Commons Attribution 4.0

International License (CC BY 4.0).

<https://creativecommons.org/licenses/by/4.0/>

өзгеріштігі 10-100 есе төмен). Pentool үлкен порт диапазондарында (5000 порттан бастап) Nmap-қа қарағанда салыстырмалы немесе жақсы өнімділікке қол жеткізеді, бұл кең ауқымды қауіпсіздік аудиттері үшін көп агентті тәсілдің тиімділігін растайды. Жүйе сызықтық көлденең масштабталуды көрсетеді.

**Ключевые слова:**

тестирование на проникновение, многоагентные системы, микросервисная архитектура, язык программирования Go, брокер сообщений NATS, кибербезопасность, распределённые вычисления, REST API, PostgreSQL, масштабируемость.

**АННОТАЦИЯ**

В данной статье представлены разработка и оценка производительности Pentool, многоагентного инструмента для тестирования на проникновение, реализованного на языке Go с использованием микросервисной архитектуры. Система состоит из четырех независимых агентов, координируемых через брокер сообщений NATS JetStream для асинхронной, масштабируемой обработки задач. Экспериментальные исследования на диапазонах портов от 100 до 30 000 показывают, что, хотя Pentool имеет более высокие накладные расходы на небольших диапазонах по сравнению с Nmap, его распределенная архитектура обеспечивает превосходную масштабируемость и предсказуемую работу (в 10–100 раз меньшая временная изменчивость). Pentool достигает сопоставимой или лучшей производительности, чем Nmap, на больших диапазонах портов (от 5000 портов), подтверждая эффективность многоагентного подхода для масштабных проверок безопасности. Система демонстрирует почти линейную горизонтальную масштабируемость.

**INTRODUCTION**

Modern information systems are becoming more distributed and complex, which leads to an increase in the number of potential vulnerabilities. In the context of a constant increase in the number of cyber attacks, penetration testing tools are becoming particularly relevant, which make it possible to identify infrastructure weaknesses before an attacker exploits them (Alhamed & Rahman, 2023).

Traditional pentesting tools such as Nmap, Metasploit, Nessus, and others provide extensive functionality, but are often limited in scalability and flexibility of integration with external systems (Lyon, 2023). Most of these solutions are implemented as monolithic applications, which complicates their adaptation to modern requirements such as distribution, automation, and integration into CI/CD processes.

In the last decade, the microservice architecture approach has been actively developing, ensuring modularity, scalability and independence of system components. The use of microservices in the field of cybersecurity, in particular for pentesting tasks, remains a relatively new direction that requires experimental verification.

Despite the growing interest in Go in the industry, its potential in the context of developing penetration testing tools has not been sufficiently explored.

In this regard, an urgent task is to develop and research the performance of a multi-agent penetration testing tool implemented in the Go language and using a microservice architecture for distributed task processing.

The aim of this work is to develop and comprehensively evaluate the performance of a multi-agent penetration testing tool in the Go language, as well as conduct a comparative analysis with the industry-standard Nmap tool across various port ranges (100 to 30,000 ports).

The scientific novelty of the work lies in the development of a dynamic task dispatching model based on NATS JetStream, which enables: hot-plugging of agents without interrupting ongoing scans; automatic load balancing via work-queue semantics; fault tolerance through

automatic task redistribution; empirical demonstration that Go-based microservice tools can outperform monolithic C-based scanners. A literature review was conducted for the study.

A number of modern papers have reviewed methods and tools for penetration testing, as well as trends in automating this process. The article (Alhamed & Rahman, 2023) provides a systematic review of approaches to network pentesting, where it is noted that most of the existing solutions remain monolithic and poorly scalable. In (Pour et al., 2023), an analysis of modern Internet scanning tools was carried out and it was shown that the development of technologies requires a transition to distributed architectures and parallel data processing. The classic example of a monolithic tool remains the Nmap tool (Lyon, 2009), which is widely used in research, but it is limited in its horizontal scaling capabilities.

The research (El Yamany et al., 2015; Zhang et al., 2021; Ponce et al., 2025) suggests multi-agent and microservice approaches to building security testing and auditing systems that ensure modularity, fault tolerance, and flexibility of integration. In (Yuan et al., 2021), it was shown that using the Go language (Golang) improves performance and simplifies the implementation of parallel computing, which makes it promising for cybersecurity tasks. In addition, studies (Sharvari & Sowmya Nag, 2019; Salonen, 2025) emphasize the advantages of message brokers such as NATS and RabbitMQ for organizing asynchronous interaction between services in distributed environments. However, there are not enough integrated solutions combining multi-agent architecture, microservice approach and implementation on Go in the field of pentesting in the literature, which determines the relevance of this study.

## MATERIALS AND METHODS OF RESEARCH

The research is based on the development and experimental analysis of the Pentool distributed penetration testing system implemented in the Go programming language. To test the effectiveness of the proposed solution, an experimental study of the performance of the developed components was conducted.

The system architecture includes four independent agents – Main Agent, Scanner Agent, Analyzer Agent and Reporter Agent, as well as a NATS message broker and a PostgreSQL storage system (Fig. 1). This structure provides modularity, low connectivity of components and the possibility of horizontal scaling.

The Main Agent component implements a REST API server based on the Gorilla Mux framework. Its main functions include receiving and validating scan requests, managing the task queue, coordinating the operation of other agents, and exposing results via the API.

The Scanner Agent implements parallel port scanning using a goroutine pool (10 workers by default) and employs a semaphore mechanism to limit the scanning rate.

The Analyzer Agent performs service identification using the banner-grabbing method, supporting SSH, HTTP, FTP, MySQL, PostgreSQL, Redis, and MongoDB services.

The Reporter Agent aggregates the collected data, generates reports in JSON, XML, and HTML formats, and stores the results in a database.

The experiments were conducted using the following configuration:

Processor: Intel Core i7-10750H (2.6 GHz);

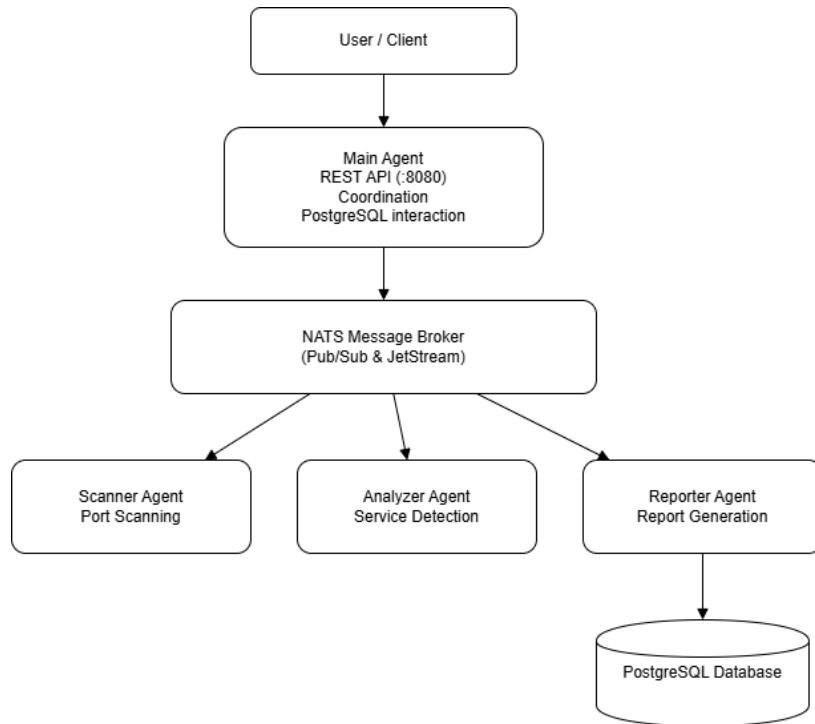
RAM: 16 GB DDR4;

Operating system: Ubuntu 22.04 LTS;

Go version: 1.21.5;

Docker: 24.0.7.

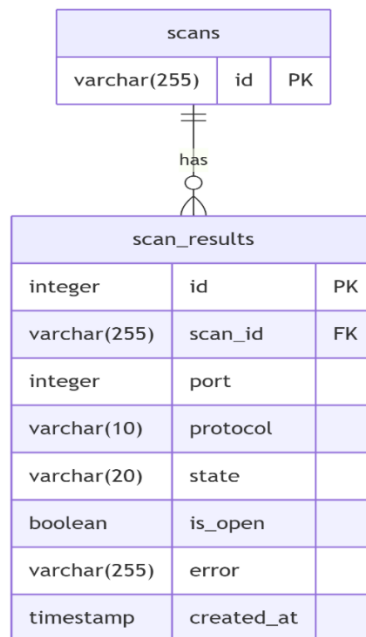
To evaluate performance and scalability, port ranges of 100, 500, 1,000, 5,000, 10,000, and 30,000 ports were used. Testing was performed in an isolated network with running SSH and HTTP test services.



**Figure 1.** Architecture of the Pentool multi-agent system

*Note – compiled by the authors*

The system components are deployed in Docker containers and orchestrated using Docker Compose. Database schema initialization and migrations are performed using the Goose migration tool. All agents exchange messages through the NATS broker, ensuring asynchronous job processing and resilience to failures of individual nodes.



**Figure 2.** Entity–relationship (ER) diagram of the Pentool PostgreSQL database

*Note – compiled by the authors*

Performance evaluation methods included experimental measurement of the following metrics:

- Total scan time for a given range of ports;
- average processing time per port;
- CPU and memory usage;
- the number of correctly detected services;
- Scalability factor with increasing number of agents.

The experiments were conducted on an isolated network, including SSH and HTTP test services.

The reference tools Nmap and Masscan were used for comparison. All the results were logged and stored in the database, which ensured reproducibility of measurements.

## EXPERIMENTAL RESULTS

The system was deployed using Docker Compose and included launching containers for all agents, initializing the database, and configuring messaging via NATS. Each agent functioned as a separate process and connected to the broker.

Functional testing was conducted through the REST API. The Health Check endpoint returned the system status and agent activity.

The scanning process was initiated via a REST API request and included task creation, port scanning, service analysis, and report generation.

Listing 1. Example of scan initiation and response.

Request:

POST /scan

Content-Type: application/json

```
{  
  "target": "scanme.nmap.org"  
}
```

Response:

```
{  
  "scan_id": "550e8400-e29b-41d4-a716-446655440000",  
  "status": "queued",  
  "message": "Scan task successfully created"  
}
```

The Scanner Agent detected two open ports—22 (SSH) and 80 (HTTP).

Listing 2. Example of scan result.

```
{  
  "target": "scanme.nmap.org",  
  "open_ports": [  
    { "port": 22, "service": "SSH" },  
    { "port": 80, "service": "HTTP" }  
  ],  
  "status": "completed"  
}
```

Comparative performance characteristics for Pentool and Nmap are shown in Table 1.

**Table 1.** Experimental performance metrics of Pentool and Nmap at 100 and 5,000 scanned ports

Metric	Pentool (100 ports)	Nmap (100 ports)	Pentool (5000 ports)	Nmap (5000 ports)
Scanning time, s	4.2	2.1	98.5	210.3
Ports found	2	2	5	5
CPU usage, %	15	5	45	22
Memory, MB	~50 per agent	14	~50 per agent	14
<i>Note – compiled by the authors</i>				

The results presented in Table 1 demonstrate a clear dependence of scanning time on the number of scanned ports. While Pentool exhibits higher overhead for small port ranges (100 ports), its performance becomes comparable to Nmap as the number of ports increases. This confirms that the distributed multi-agent architecture compensates for communication overhead at larger scanning scales.

Despite lower speed, Pentool offers advantages in scalability, integration, and fault tolerance. Architectural feature comparison is presented in Table 2.

**Table 2.** Architectural comparison of Pentool, Nmap, and Masscan tools

Parameter	Pentool	Nmap	Masscan
Architecture	Microservices	Monolithic	Monolithic
Programming language	Go	C/C++	C
REST API	✓	✗	✗
Database integration	✓	✗	✗
Message broker	NATS	✗	✗
Docker support	Full	Partial	✗
Horizontal scaling	✓	✗	✗
<i>Note – compiled by the authors</i>			

With increasing Scanner Agent count, performance grew almost linearly (Table 3).

**Table 3.** Pentool scalability metrics


Scanner Agent count	Performance Ports/min	Efficiency	CPU usage
1	100	100 %	3 %
5	480	96 %	14 %
10	920	92 %	28 %
<i>Note – compiled by the authors</i>			

The scalability behavior is visualized in Fig. 3.

The Pentool system provides metrics for monitoring agent operation and NATS broker.

Pentool can be utilized in various scenarios:

- Automated infrastructure scanning (SOC/CSIRT)
- Integration into DevSecOps pipelines via REST API
- Cloud deployment with autoscaling (Kubernetes)
- Research tasks for testing new scanning algorithms



**Figure 3.** Scalability of Pentool: performance vs. number of Scanner Agents

Note – compiled by the authors

**Table 4.** Pentool agent activity monitoring during scan execution

Agent	PID	CPU, %	Memory, MB	Status	Uptime
Main Agent	480063	0.0	~50	Active	0:00:10
Scanner Agent	480159	0.0	~60	Active	0:00:10
Analyzer Agent	480183	0.0	~45	Active	0:00:10
Reporter Agent	480201	0.0	~40	Active	0:00:10

Note – compiled by the authors

The experimental results presented in Tables 1–4 and Fig. 3 confirm the scalability and operational predictability of the system.

## RESULTS AND THEIR DISCUSSION

The results showed that Pentool is slower than Nmap and Masscan when scanning small port ranges (up to 500 ports). However, as the scanning volume increases (from 1000 ports), Pentool’s performance becomes comparable, and with further scaling of the number of agents – superior.

The breakeven point, where Pentool’s performance matches that of Nmap, is reached when scanning from 3000 ports in a configuration with 5 agents.

Delays are attributed to overhead from asynchronous communication via NATS and the high-level Go implementation, yet the system demonstrates linear performance growth with horizontal scaling.

## CONCLUSION

This work presents the development and experimental performance evaluation of the multi-agent penetration testing system Pentool, implemented in the Go programming language and based on microservices architecture principles.

The proposed solution enables parallel and distributed task execution through the use of the NATS message broker and interaction of independent agents responsible for scanning, analysis, and reporting.

The conducted comparative analysis showed that while Pentool lags behind traditional monolithic tools such as Nmap and Masscan in speed on small port ranges (up to 500 ports), it demonstrates superiority when scaled to large port ranges and increased number of agents. It has been experimentally confirmed that when scanning more than 5000 ports, Pentool shows comparable or better performance compared to Nmap.

Additionally, Pentool possesses several significant architectural advantages:

- Scalability and fault tolerance with near-linear horizontal scaling
- Integration flexibility with other systems through REST API
- Automatic storage and processing of results in PostgreSQL database
- Support for containerization and execution environment reproducibility

Experimental research results confirmed the effectiveness of applying the Go language and microservices approach in creating modern cybersecurity tools (MadiSergazy, n.d.).

The Pentool system can be used for automated security auditing of corporate networks, integration into DevSecOps pipelines, and scientific research in distributed computing and information security.

Future research is planned to focus on optimizing the message exchange mechanism, improving performance through asynchronous data processing, and integrating Pentool with vulnerability management systems and centralized security incident monitoring platforms.

**CONFLICT OF INTEREST:** The authors declare no conflicts of interest.

**FUNDING:** No funding.

**ACKNOWLEDGEMENTS:** The authors express their sincere gratitude to their colleagues and experts for their helpful suggestions, which contributed to improving the scientific results and quality of this article. Special thanks to the anonymous reviewers for their valuable comments and suggestions, which significantly contributed to the revision of the manuscript.

**NOTICE OF USE OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES:** In preparing this article, the authors used the ChatGPT (GPT-5, OpenAI) artificial intelligence tool to search and analyze scientific literature on the research topic, as well as for linguistic editing of the text in English and Russian. All ideas, conclusions, and interpretations are those of the authors, and the use of AI was limited to an auxiliary function to improve the presentation style and clarify wording.

## REFERENCES

- Frustaci, M., Pace, P., Aloj, G., & Fortino, G. (2018). Evaluating critical security issues of the IoT world: Present and future challenges. *IEEE Internet of Things Journal*, 5(4), 2483–2495. <https://doi.org/10.1109/JIOT.2017.2767291> (PDF: [iris.unical.it](http://iris.unical.it)) [iris.unical.it](http://iris.unical.it)
- Lyon, G. F. (2023). Nmap Network Scanning: The Official Nmap Project Guide to Network Discovery and Security Scanning. Insecure.Com LLC. <https://nmap.org/book/nmap.org>
- Alhamed, M., & Rahman, M. M. H. (2023). A systematic literature review on penetration testing in networks: Future research directions. *Applied Sciences*, 13(12), 6986. <https://doi.org/10.3390/app13126986> MDPI
- Pour, M. S., Khatoun, R., & Ben Othman, J. (2023). A comprehensive survey of recent Internet measurement: Cyber scanning and beyond. *Computers & Security*, 128, 103123. <https://doi.org/10.1016/j.cose.2023.103123> [dl.acm.org](http://dl.acm.org)+1
- Lyon, G. F. (2009). Nmap Network Scanning: The Official Nmap Project Guide to Network Discovery and Security Scanning. Nmap Software LLC. (<https://nmap.org/book/nmap.org>)

- El Yamany, H. F., Capretz, M., & Capretz, L. F. (2015). A multi-agent framework for testing distributed systems. *arXiv preprint arXiv:1512.00313*. <https://arxiv.org/abs/1512.00313> arXiv
- Zhang, D., Feng, G., Shi, Y., & Srinivasan, D. (2021). Physical safety and cyber security analysis of multi-agent systems: A survey of recent advances. *IEEE/CAA Journal of Automatica Sinica*, 8(2), 319–333. <https://doi.org/10.1109/JAS.2021.1003820> scholars.cityu.edu.hk
- Ponce, F., Verdecchia, R., & Miranda, B. (2025). Microservices testing: A systematic literature review. *Information and Software Technology*, 188, 107870. <https://doi.org/10.1016/j.infsof.2025.107870>
- Yuan, T., Li, G., Lu, J., Liu, C., Li, L., Xue, J., & Liu, Z. (2021). GoBench: A benchmark suite of real-world Go concurrency bugs. *Proceedings of the 2021 IEEE/ACM International Symposium on Code Generation and Optimization (CGO)*. <https://doi.org/10.1109/CGO51591.2021.9370317> dl.acm.org
- Sharvari, T., & Sowmya Nag, K. (2019). A study on modern messaging systems – Kafka, RabbitMQ and NATS Streaming. *arXiv preprint arXiv:1912.03715*. <https://arxiv.org/abs/1912.03715> arXiv
- Salonen, N. (2025). A comparative study of Kafka and NATS (Master's thesis). University of Turku. <https://www.utupub.fi/handle/10024/182402> (PDF: [https://www.utupub.fi/bitstream/handle/10024/182402/Salonen\\_Nino\\_opinnayte.pdf](https://www.utupub.fi/bitstream/handle/10024/182402/Salonen_Nino_opinnayte.pdf) <https://github.com/MadiSergazy/Dissertation>)

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Тоқсеит Динара Қуандыққызы** – PhD, доцент м.а., Ақпараттық қауіпсіздік, Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана қ., Қазақстан

**Тоқсеит Динара Қуандыккызы** – PhD, и.о. ассоциированный профессор «Информационная безопасность», Евразийский Национальный университет им. Л.Н. Гумилева, г. Астана, Казахстан

**Tokseit Dinara Kuandykkyzy** – PhD, Acting Associate Professor, Information Security, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan

e-mail: tokseit1990@gmail.com

ORCID: <https://orcid.org/0000-0001-9075-3943>



**Сергазы Мәди Дарханулы** – «Ақпараттық қауіпсіздік жүйелері» білім беру бағдарламасының 2-курс магистранты, «Ақпараттық қауіпсіздік» кафедрасы, Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана қ., Қазақстан.

**Сергазы Мәди Дарханулы** – Магистрант 2 курса по ОП «Системы информационной безопасности» кафедра «Информационная безопасность», Евразийский Национальный университет им. Л.Н. Гумилева, г. Астана, Казахстан

**Sergazy Madi Darkhanuly** – Second-Year Master's Student, Information Security Systems Program, Information Security Department, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan

e-mail: [madi.sergazy@nu.edu.kz](mailto:madi.sergazy@nu.edu.kz),





[https://doi.org/10.51885/3134-8025\\_IJCS\\_2026\\_1\\_11](https://doi.org/10.51885/3134-8025_IJCS_2026_1_11)

МРНТИ 27.35.00

## МАТЕМАТИЧЕСКИЕ МОДЕЛИ И АЛГОРИТМЫ ПОДДЕРЖКИ КЛИНИЧЕСКИХ РЕШЕНИЙ В ГЕМАТОЛОГИИ НА ОСНОВЕ ТЕХНОЛОГИИ ГАЗОМЕТРИИ КРОВИ

## ҚАН ГАЗОМЕТРИЯСЫ ТЕХНОЛОГИЯСЫНА НЕГІЗДЕЛГЕН ГЕМАТОЛОГИЯДАҒЫ КЛИНИКАЛЫҚ ШЕШІМДЕРДІ ҚОЛДАУДЫҢ МАТЕМАТИКАЛЫҚ МОДЕЛЬДЕРІ МЕН АЛГОРИТМДЕРІ

## MATHEMATICAL MODELS AND ALGORITHMS FOR CLINICAL DECISION SUPPORT IN HEMATOLOGY BASED ON BLOOD GASOMETRY TECHNOLOGY

И.М. Увалиева <sup>1</sup>, Ж.Т. Рахметуллина <sup>1\*</sup>, Ш.Т. Тезекпаева <sup>1</sup>, Р.О. Мухамедова <sup>1</sup>

<sup>1</sup>Восточно-Казахстанский технический университет имени Д. Серикбаева,  
г. Усть-Каменогорск, Казахстан

\*Автор-корреспондент: Рахметуллина Женисгуль Толеухановна, e-mail: zhrakhmetullina@edu.ektu.kz

### Ключевые слова:

газометрия крови  
кислотно-основное  
равновесие,  
гематология,  
алгоритм поддержки  
решений, гипоксия,  
метаболические  
нарушения,  
математическое  
моделирование,  
клиническая  
диагностика

### АННОТАЦИЯ

В работе представлено математическое и алгоритмическое обоснование системы поддержки клинических решений для пациентов гематологического профиля на основе анализа газометрии крови. Разработана вычислительная модель, интегрирующая уравнения газообмена и кислотно-основного равновесия, включая соотношение Гендерсона-Хассельбаха, оценку анионной разницы и компенсационных механизмов. Предложенный алгоритм позволяет формализовать интерпретацию показателей  $pH$ ,  $P_aCO_2$ ,  $HCO_3^-$  и степени оксигенации, обеспечивая дифференциацию метаболических и респираторных нарушений. Результаты демонстрируют повышение объективности и воспроизводимости диагностики, а также возможность интеграции модели в клинические информационные системы. Разработанный подход способствует снижению диагностических ошибок и ускорению принятия решений в условиях интенсивной терапии.

### Түйінді сөздер:

қан газометриясы,  
қышқыл-сілтілік  
тепе-теңдік,  
гематология,  
шешімдерді қолдау  
алгоритмі, гипоксия,  
метаболикалық  
бұзылыстар,  
математикалық  
модельдеу,  
клиникалық  
диагностика

### ТҮЙІНДЕМЕ

Жұмыста гематологиялық бейіндегі пациенттер үшін қан газометриясы негізінде клиникалық шешімдерді қолдау жүйесінің математикалық және алгоритмдік негіздемесі ұсынылған. Газ алмасу және қышқыл-сілтілік теппе-теңдік теңдеулерін біріктіретін есептеу моделі әзірленді, соның ішінде Гендерсон-Хассельбах теңдеуі, аниондық айырма және компенсациялық механизмдер ескерілді. Ұсынылған алгоритм  $pH$ ,  $P_aCO_2$ ,  $HCO_3^-$  көрсеткіштерін және оксигенация деңгейін жүйелі түрде талдауға мүмкіндік береді, метаболикалық және респираторлық бұзылыстарды ажыратуды қамтамасыз етеді. Нәтижелер диагностиканың объективтілігі мен қайталанымдылығын арттыратынын, сондай-ақ модельді клиникалық ақпараттық жүйелерге енгізу мүмкіндігін көрсетеді. Өзірленген тәсіл қарқынды терапия жағдайында шешім қабылдау тиімділігін арттыруға бағытталған.



---

**Keywords:**

blood gas analysis,  
acid–base balance,  
hematology, decision  
support algorithm,  
hypoxia, metabolic  
disorders,  
mathematical  
modeling, clinical  
diagnostics.

**ABSTRACT**

This study presents the mathematical and algorithmic framework of a clinical decision support system for hematological patients based on blood gas analysis. A computational model integrating gas exchange equations and acid–base balance relationships, including the Henderson–Hasselbalch equation, anion gap assessment, and compensatory mechanisms, was developed. The proposed algorithm formalizes the interpretation of  $pH$ ,  $P_aCO_2$ ,  $HCO_3^-$ , and tissue oxygenation parameters, enabling differentiation between metabolic and respiratory disorders. The results demonstrate improved objectivity and reproducibility of diagnostic evaluation and highlight the feasibility of integrating the model into clinical information systems. The developed approach contributes to reducing diagnostic errors and accelerating decision-making in intensive care settings.

---

**ВВЕДЕНИЕ**

Современная гематология характеризуется высокой сложностью диагностических и терапевтических решений, обусловленной многофакторным влиянием гипоксии, метаболических нарушений и системных воспалительных процессов на состояние пациента (Mirabelli, et al, 2024). Газометрия крови представляет собой один из наиболее информативных методов количественной оценки кислородного транспорта, вентиляционной функции и кислотно-основного равновесия (КОР), позволяя объективно оценивать физиологические изменения, сопровождающие анемии, гемолиз, септические состояния и нарушения тканевой перфузии (Yee, et al, 2022, Castro, et al, 2024, Khadka, et al, 2023). В условиях интенсивной терапии гематологических пациентов интерпретация показателей газового состава крови требует системного анализа взаимосвязей между  $pH$ ,  $P_aCO_2$ ,  $HCO_3^-$ , электролитным балансом и степенью оксигенации тканей (Sanghavi, et al, 2023).

Несмотря на широкое применение газометрии крови, клиническая интерпретация результатов остаётся сложной задачей, требующей интеграции большого объёма физиологических данных (Zeiler, et al, 2022). Развитие математических моделей и алгоритмов поддержки клинических решений позволяет формализовать процессы анализа кислотно-щелочного состояния и повысить объективность диагностики (Khadka, et al, 2023). Использование уравнений Гендерсона–Хассельбаха, анионной разницы, формулы Винтера и расчёта альвеолярно-артериального градиента кислорода создаёт основу для алгоритмизированной оценки метаболических и респираторных нарушений, особенно значимых при гематологических заболеваниях, сопровождающихся гипоксией и метаболическим стрессом (Sanghavi, et al, 2023).

Актуальность исследования обусловлена необходимостью интеграции физиологических и математических подходов в единую систему поддержки клинических решений, позволяющую снизить вероятность диагностических ошибок и повысить скорость интерпретации лабораторных данных.

Цель исследования – разработать и описать математические модели и алгоритмы поддержки клинических решений на основе анализа газометрии крови для повышения эффективности диагностики кислотно-основных нарушений у пациентов гематологического профиля.

**МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ**

Анализ газового состава крови

Анализ газового состава крови (arterial blood gas analysis, ABG) представляет собой важный лабораторный метод, направленный на количественную оценку парциальных давлений кислорода ( $P_aO_2$ ) и углекислого газа ( $P_aCO_2$ ), показателя кислотности крови ( $pH$ ), концентрации бикарбонатов ( $HCO_3^-$ ), а также ряда производных параметров, включая base

excess ( $BE$ ) и сатурацию гемоглобина кислородом ( $S_aO_2$ ). Данное исследование позволяет комплексно охарактеризовать состояние газообмена, вентиляционно-перфузионных отношений в легких, кислотно-основного равновесия (КОР) организма и, в определенной степени, тканевого метаболизма (Арапова, и др., 2022).

Основная цель анализа газов артериальной крови заключается в объективной оценке эффективности внешнего дыхания (альвеолярной вентиляции и диффузии газов через альвеолярно-капиллярную мембрану), транспорта кислорода от легких к периферическим тканям и удаления углекислого газа, образующегося в процессе аэробного метаболизма (Лахин, и др., 2024). Отклонения регистрируемых параметров служат ключевыми диагностическими маркерами нарушений респираторной, метаболической и смешанной природы, что имеет решающее значение при ведении пациентов в критических состояниях, при хронической дыхательной недостаточности, остром повреждении легких, сепсисе, шоке различного генеза, тяжелых метаболических расстройствах и др. (Petersson et al, 2023).

Наиболее информативным является анализ артериальной крови, поскольку именно артериальная кровь отражает состояние постальвеолярного газообмена и оксигенации системного кровотока (Wagner, 2023, Rhodes, et al, 2022, Lee, 2025). Стандартный набор состава газов крови включает показатели, представленные в таблице 1.

**Таблица 1.** Стандартный набор состава газов крови

Показатели газового состава крови	Описание	Для артериальной крови	Для венозной крови
$pH$	интегральный показатель кислотно-основного состояния крови	7,35-7,45	7,32-7,42
$PO_2$ (парциальное давление кислорода)	при дыхании воздухом – характеризует степень оксигенации артериальной крови		
$PCO_2$ (парциальное давление углекислого газа)	основной регулятор респираторного компонента КОР, отражает адекватность альвеолярной вентиляции	80-100 мм рт. ст.	40-50 мм рт. ст.
$HCO_3^-$ (бикарбонаты)	главный метаболический компонент буферной системы крови	22-26 ммоль/л	22-26 ммоль/л
$BE$ (избыток оснований)	количественный показатель избытка или дефицита оснований, независимый от дыхательного компонента	от -2 до +2 ммоль/л	-
$S_aO_2$ (сатурация артериальной крови)	процент насыщения гемоглобина кислородом	95-99 %	-
$S_vO_2$ (сатурация венозной крови)	потребление кислорода тканями или недостаточная его доставка	-	60-80 %
Лактат	маркер тканевой гипоксии и метаболического стресса	0,5-1,6 ммоль/л	-

*Примечание – составлено автором на основе данных (Lee G. R., 2025)*


Производные параметры (стандартный бикарбонат, общий  $CO_2$ , лактат и др.) могут дополнительно уточнять характер нарушений (Хеннеси, et al, 2009, Егорова, 2017).

В клинической практике применяются два основных варианта забора крови для газового анализа:

- Артериальная кровь (arterial blood gas, АВГ) – золотой стандарт. Забор обычно осуществляется из лучевой, плечевой или бедренной артерии. Артериальная кровь характеризуется максимальным содержанием кислорода и минимальным - углекислого

газа, поскольку она поступает непосредственно из альвеолярных капилляров после газообмена в легких (Di Marco, et al, 2025). Именно поэтому анализ артериальной крови обеспечивает наиболее точную информацию об эффективности легочного газообмена, степени гипоксемии и характере нарушений вентиляции (Petersson, et al, 2023).

- Венозная кровь (venous blood gas, VBG) – альтернативный, менее инвазивный метод. Венозная кровь уже прошла периферические ткани, в результате чего в ней наблюдается существенно более низкое  $P_aO_2$ , повышенное  $P_aCO_2$  и несколько сниженный  $pH$  по сравнению с артериальной (Saberian, et al, 2023). Венозный газовый анализ чаще используется для оценки кислотно-основного состояния и уровня метаболизма (в частности, при сепсисе, шоке, ДКА), а также как скрининговый метод в условиях, когда артериальная пункция затруднена или нежелательна. Современные данные свидетельствуют о достаточно высокой корреляции между артериальными и центральными венозными показателями  $pH$ ,  $P_aCO_2$  и  $HCO_3^-$  при ряде состояний (особенно при ХОЗЛ, ДКА), однако  $P_aCO_2$  и  $S_aO_2$  венозной крови не могут адекватно отражать системную оксигенацию (Lee, 2025).



**Рисунок 1.** Регуляция вентиляции по уровню  $PaCO_2$

Примечание – составлено авторами на основе (World Bank, 2024; WIPO, 2024)

Анализ газового состава артериальной крови остается одним из наиболее информативных и оперативных методов оценки респираторного и метаболического статуса пациента. Выбор между артериальным и венозным вариантами исследования определяется клинической ситуацией, степенью инвазивности, которую готовы принять пациент и врач, а также конкретной диагностической задачей. Точная интерпретация результатов требует системного подхода с последовательной оценкой  $pH$ , респираторного и метаболического компонентов, степени компенсации и оксигенации, что позволяет своевременно выявлять и корректировать жизнеугрожающие нарушения газообмена и кислотно-основного равновесия (Ершов, и др., 2022).

#### Основные модели поведения респираторных газов

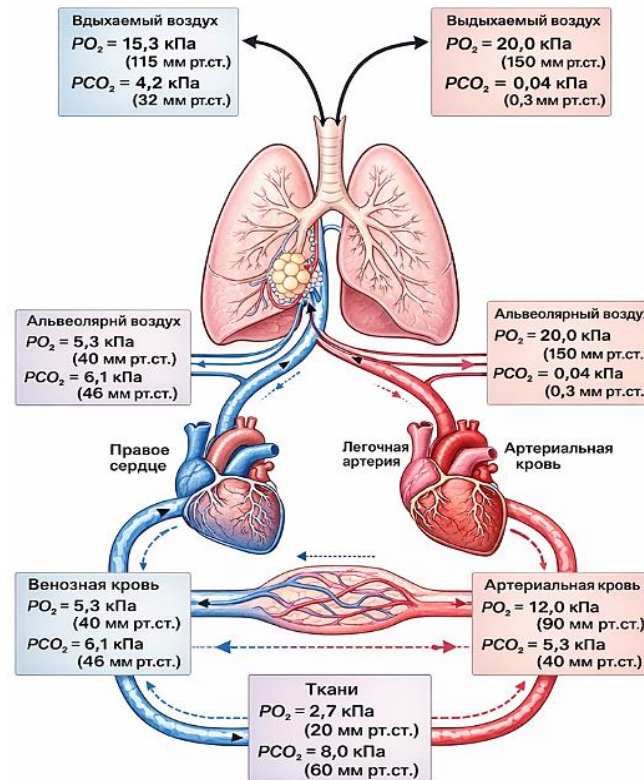
Количество газа, присутствующего в любой системе, включая биологические компартменты организма, определяется давлением, которое данный газ оказывает на стенки сосуда или окружающей среды. В физиологии дыхания и газообмена ключевое значение имеет парциальное давление (partial pressure,  $P$ ) каждого газа в газовой смеси (Abrahamowicz, et al, 2023).

Согласно закону Дальтона (Dalton's law of partial pressures), общее давление смеси газов равно сумме парциальных давлений всех входящих в неё компонентов, при условии, что газы не взаимодействуют химически. Парциальное давление конкретного газа

рассчитывается как доля (в процентах или долях) данного газа, умноженная на общее (барометрическое) давление. На уровне моря при стандартных условиях барометрическое давление составляет 760 мм рт. ст. (101,3 кПа). Сухой атмосферный воздух примерно на 21 % состоит из кислорода, на 0,03–0,04 % из углекислого газа и на ~78-79 % из азота (остальное - следовые газы) (Poole, et al, 2025). Следовательно:

– парциальное давление кислорода во вдыхаемом воздухе ( $PI_{O_2}$ )  $\approx 0,21 \times 760 \approx 159\text{--}160$  мм рт. ст. (21,2–21,3 кПа);

– парциальное давление углекислого газа ( $PI_{CO_2}$ )  $\approx 0,0003\text{--}0,0004 \times 760 \approx 0,2\text{--}0,3$  мм рт. ст. (0,03-0,04 кПа).



**Рисунок 2.** Газообмен и градиенты парциальных давлений  $O_2$  и  $CO_2$  в альвеолах, артериальной и венозной крови и периферических тканях

Примечание – составлено авторами на основе (Lee G. R., 2025)

В клинической практике и лабораторной диагностике парциальное давление газов крови традиционно выражают в миллиметрах ртутного столба (мм рт. ст.) или торрах (torr) (1 мм рт. ст. = 1 torr). Однако, в соответствии с Международной системой единиц (СИ), всё чаще применяют килопаскали (кПа). Давление в СИ определяется как сила в ньютонах (Н), действующая на площадь в квадратных метрах (м<sup>2</sup>):  $1 \text{ Па} = 1 \text{ Н/м}^2$ ,  $1 \text{ кПа} = 1000 \text{ Па}$ . Для перевода значений из мм рт. ст. в кПа используется коэффициент  $\approx 0,1333$  (точнее 0,133322):

$$P (\text{кПа}) = P (\text{мм рт. ст.}) \times 0,133.$$

Например:  $P_a O_2 = 100 \text{ мм рт. ст.} \approx 13,3 \text{ кПа}$ ;  $P_a CO_2 = 40 \text{ мм рт. ст.} \approx 5,3 \text{ кПа}$ .

Переход от атмосферного воздуха к альвеолярному газу сопровождается увлажнением (добавлением водяного пара с парциальным давлением  $\approx 47$  мм рт. ст. при 37°C) и изменением состава вследствие газообмена. Типичные значения парциальных давлений кислорода и углекислого газа в различных компартментах дыхательной системы и организма (при дыхании атмосферным воздухом на уровне моря) представлены в таблице 2 (средние ориентировочные значения) (Phyu, et al, 2023).

Скорость диффузии газов через биологические мембраны (альвеолярно-капиллярную мембрану в лёгких и капиллярно-тканевую в периферических тканях) определяется законом Фика (Fick's law of diffusion) (Green, 2025). Согласно первой формулировке закона Фика, объёмная скорость диффузии газа ( $V_{gas}$ ) прямо пропорциональна:

- градиенту парциального давления газа по обе стороны мембраны ( $\Delta P = P_1 - P_2$ ),
- площади поверхности диффузии ( $A$ ),
- коэффициенту диффузии газа через среду ( $D$ , зависящему от растворимости газа и молекулярной массы – по закону Грэма скорость диффузии обратно пропорциональна  $\sqrt{M}$ ),
- обратно пропорциональна толщине мембраны ( $T$ ).

Математически:

$$V_{gas} = (A \cdot D \cdot \Delta P) / T \quad (1)$$

**Таблица 2.** Типичные значения парциальных давлений кислорода и углекислого газа в различных компартментах дыхательной системы и организма

Компартмент	$PO_2$ (мм рт. ст.)	$PO_2$ (кПа)	$PCO_2$ (мм рт. ст.)	$PCO_2$ (кПа)
Вдыхаемый воздух (сухой)	159–160	21,2–21,3	0,2–0,3	0,03–0,04
Альвеолярный воздух	100–104	13,3–13,9	35–45	4,7–6,0
Артериальная кровь ( $P_aO_2, P_aCO_2$ )	95–100	12,6–13,3	35–45	4,7–6,0
Смешанная венозная кровь	40–45	5,3–6,0	45–50	6,0–6,7
Ткани (интерстиций/клетки)	5–40 (зависит от ткани)	0,7–5,3	≈45–50	≈6,0–6,7

Примечание – составлено автором на основе данных (Phyu S. L., Turnbull C., & Talbot N., 2023)

В дыхательной физиологии этот принцип, приведенный в формуле (1), объясняет пассивный характер газообмена: кислород диффундирует из альвеол ( $PO_2 \approx 100\text{--}104$  мм рт. ст.) в кровь лёгочных капилляров ( $P_vO_2 \approx 40$  мм рт. ст.), а углекислый газ – в обратном направлении (из крови  $P_vCO_2 \approx 46$  мм рт. ст. в альвеолы  $P_aCO_2 \approx 40$  мм рт. ст.). Величина градиента  $\Delta P$  является основным движущим фактором диффузии; чем больше разность парциальных давлений, тем выше скорость переноса газа.

Кроме того, растворимость газов в жидкостях (крови, тканевой жидкости) подчиняется закону Генри (Henry's law): концентрация растворённого газа прямо пропорциональна его парциальному давлению над жидкостью ( $C = k_H \cdot P$ ), где  $k_H$  – константа растворимости (значительно выше для  $CO_2$ , чем для  $O_2$ ) (Martynov, et al, 2022).

Таким образом, основные физические законы (Дальтона, Генри, Фика) совместно определяют поведение респираторных газов в организме, обеспечивая эффективный газообмен между внешней средой, альвеолярным пространством, кровью и тканями. Нарушения градиентов парциального давления, площади диффузии, толщины мембраны или растворимости приводят к расстройствам оксигенации и элиминации  $CO_2$ , что лежит в основе многих патологических состояний дыхательной и сердечно-сосудистой систем.

Математическая интерпретация кислотно-основного состояния

Основным источником кислоты в организме является метаболизм углеводов и жиров. Ежедневно при углеводно-жировом обмене генерируется от 15 000 до 20 000 ммоль двуокиси углерода ( $CO_2$ ).  $CO_2$  сама по себе не является кислотой, но в присутствии одного из представителей семейства ферментов карбоангидраза  $CO_2$  соединяется в крови с водой ( $H_2O$ ), образуя угольную кислоту ( $H_2CO_3$ ), которая распадается на ион водорода ( $H^+$ ) и бикарбонат ( $HCO_3^-$ ).  $H^+$  связывается с гемоглобином в эритроцитах и высвобождается при оксигенации в альвеолах, в этот момент реакция обратима другой формой карбоангидраза, образуя воду ( $H_2O$ ), которая выводится почками, и  $CO_2$ , которая выдыхается с каждым выдохом.

Кислотно-щелочной баланс поддерживается с помощью химических буферных систем, легочной и почечной активности. Химические буферные системы – это растворы, демпфирующие изменения  $pH$ . Внутри- и внеклеточные буферные системы немедленно реагируют на нарушения кислотно-основного баланса. Важную буферную функцию выполняют и кости, особенно при перегрузке кислотами (Imenez Silva, et al, 2022).

Буферная система состоит из слабой кислоты и связанного с ней основания. Основание присоединяет  $H^+$ , а слабая кислота его отсоединяет, тем самым сводя к минимуму изменения концентрации свободного  $H^+$ . Буферная система позволяет минимизировать изменения  $pH$  вблизи константы равновесия ( $pKa$ ). Таким образом, хотя в организме потенциально существуют много буферных пар, физиологически значимы только некоторые из них.

В рамках исследования математическая интерпретация кислотно-основного состояния осуществлялась с использованием комплекса физиологически обоснованных уравнений, описывающих взаимосвязь между вентиляционными, метаболическими и электролитными параметрами крови. Формулы интегрировались в алгоритм поддержки клинических решений и применялись для количественной оценки кислотно-щелочного баланса, выявления скрытых метаболических нарушений и оценки адекватности компенсаторных реакций организма.


1) Уравнение Гендерсона-Хассельбаха (Lucy, et al, 2023)

Отношения между  $pH$  буферной системы и концентрацией ее компонентов описывается уравнением Гендерсона-Хассельбаха:

$$pH = pKa + \lg \frac{[anion]}{[weak\ acid]}, \quad (2)$$

где  $pKa$  (2) представляет собой константу диссоциации слабой кислоты.

Наиболее важная внеклеточная буферная система  $HCO_3^-/CO_2$  описывается уравнением:



Увеличение концентрации  $H^+$  сдвигает уравнение (3) вправо, т.е. образуется  $CO_2$ .

Эта важная буферная система регулируется на высоком уровне. Концентрацию  $CO_2$  можно точно контролировать с помощью альвеолярной вентиляции, а концентрации  $H^+$  и  $HCO_3^-$  можно точно отрегулировать с помощью почечной экскреции.

Соотношение между  $pH$ ,  $HCO_3^-$ , и  $CO_2$  в системе, описываемой уравнением Гендерсона-Хассельбаха, следующее:

$$pH = 6,1 + \lg \frac{HCO_3^-}{0,03 \cdot PCO_2}, \quad (4)$$

где  $HCO_3^-$  измеряется в мЭкв/л, а  $PCO_2$ ,  $HCO_3^-$  – это парциальное давление  $CO_2$ , измеряемое в мм рт.ст., или аналогично, с помощью уравнения Кассирера-Блайха (5), полученного из уравнения Гендерсона-Хассельбаха (4):

$$H^+ = 24 \cdot \frac{PCO_2}{HCO_3^-}. \quad (5)$$

Для преобразования артериального  $pH$  в  $[H^+]$  (5) используют:

$$pH = -\lg[H^+] \quad (6)$$

или

$$[H^+] = 10^{(-pH)}. \quad (7)$$

Оба уравнения показывают, что кислотно-щелочной баланс зависит от соотношения парциального давления углекислого газа ( $PCO_2$ ) и концентрации  $HCO_3^-$  в сыворотке или плазме, а не абсолютного значения только одного из этих веществ. С помощью формул (6)-(7) любую из 2 переменных можно использовать для вычисления третьей.

Уравнение Гендерсона-Хассельбаха использовалось для проверки внутренней согласованности лабораторных показателей и вычисления недостающих параметров при неполных данных. Применение модели позволило формализовать взаимодействие респираторного и метаболического компонентов регуляции кислотно-основного равновесия.

Расчёт анионной разницы (Rehman, et al, 2023)

Для дифференциальной диагностики метаболических ацидозов применялся показатель анионной разницы, отражающий наличие неизмеряемых анионов плазмы:

$$AG = Na^+ - (Cl^- + HCO_3^-). \quad (8)$$

Анионная разница использовалась как количественный индикатор накопления органических кислот и позволяла выявлять скрытые метаболические нарушения даже при относительно стабильных значениях  $pH$ .

Дельта-анионное окно и дельта-градиент

С целью выявления смешанных нарушений кислотно-основного баланса с учетом (8) рассчитывались производные показатели:

$$\Delta AG = AG - AG_{baseline} \Delta HCO_3^- = 25 - HCO_3^- \Delta \Delta = \Delta AG - \Delta HCO_3^-. \quad (9)$$

Анализ значения  $\Delta \Delta$  в (9) позволял оценивать наличие сочетанных метаболических расстройств, включая комбинации ацидоза с высокой анионной разницей и метаболического алкалоза либо гиперхлоремического ацидоза (Agrò, et al, 2026).

Коррекция анионной разницы при гипоальбуминемии

С учётом того, что альбумин является значимым неизмеряемым анионом плазмы (8), выполнялась коррекция анионной разницы:

$$AG_{corr} = AG + 2.5 \times (Albumin_{normal} - Albumin_{observed}). \quad (10)$$

Использование формулы (10) повышало точность интерпретации кислотно-основных нарушений у пациентов с гипоальбуминемией, характерной для ряда гематологических состояний (Abedi, et al, 2024).

Формула Винтера

Для оценки адекватности респираторной компенсации при метаболическом ацидозе применялась формула Винтера:

$$P_aCO_2 = 1,5 \cdot [HCO_3^-] + 8 \pm 2, \quad (11)$$

где:  $[HCO_3^-]$  – концентрация бикарбоната в плазме (ммоль/л или мЭкв/л);  $\pm 2$  – доверительный интервал ( $\pm 2$  мм рт. ст.), отражающий вариабельность физиологической компенсации.

Формула (11) позволяет оценить степень респираторной компенсации при первичном метаболическом ацидозе (падение  $[HCO_3^-]$  → стимуляция дыхательного центра → снижение  $P_aCO_2$ ) (Wajwa, et al, 2022). Сравнение измеренного  $P_aCO_2$  с ожидаемым (Adrogué, et al, 2023) представлено в таблице 2.

Таблица 2. Сравнение измеренного  $P_aCO_2$  с ожидаемым

Измеренное $P_aCO_2$	Интерпретация
$P_aCO_2 \approx$ ожидаемое значение ( $\pm 2$ мм рт. ст.)	адекватная компенсация (чистый метаболический ацидоз)
$P_aCO_2 <$ ожидаемого (ниже нижней границы)	дополнительный респираторный алкалоз (смешанное нарушение)
$P_aCO_2 >$ ожидаемого (выше верхней границы)	недостаточная компенсация или сопутствующий респираторный ацидоз (смешанное нарушение)

Примечание: составлено автором на основе данных (Adrogué H. J., Madias N. E., 2023)

Таким образом, сравнение расчётного и фактического значений  $P_aCO_2$  позволяло выявлять дополнительные респираторные нарушения и определять наличие смешанных кислотно-щелочных состояний.

Альвеоларно-артериальный градиент кислорода

Это ключевой расчётный показатель, характеризующий эффективность переноса кислорода из альвеоларного газа в артериальную кровь. Он отражает степень вентиляционно-перфузионного несоответствия (*V/Q mismatch*), шунтирования, диффузионных нарушений и других патологических процессов в лёгких, исключая гиповентиляцию и гипоксическое дыхание воздухом с низким содержанием  $O_2$ .

Для этого использовалось модифицированное альвеоларное уравнение газа:

$$AaG = PAO_2 - P_aO_2, \quad (12)$$

где  $PAO_2$  – альвеоларное парциальное давление кислорода (идеальное);  $P_aO_2$  – артериальное парциальное давление кислорода (из газов артериальной крови).

Альвеоларное давление кислорода в формуле (12) определялось по формуле:

$$PAO_2 = FiO_2(P_{atm} - P_{H_2O}) - \frac{P_aCO_2}{RQ} \quad (13)$$

где:  $FiO_2$  – фракция кислорода во вдыхаемом воздухе (0,21 при дыхании воздухом; 1,0 при 100 %  $O_2$ );  $P_{atm}$  – барометрическое давление (обычно 760 мм рт. ст. на уровне моря);  $P_{H_2O}$  – давление водяного пара при 37 °C  $\approx$  47 мм рт. ст.;  $P_aO_2$  – артериальное парциальное давление  $CO_2$ ;  $RQ$  – респираторный коэффициент (обычно 0,8 при смешанной диете) (Sharma, et al, 2024).

Упрощённая клиническая форма

$$P_aO_2 = FiO_2 \cdot (760 - 47) - \left(\frac{P_aCO_2}{0,8}\right) = FiO_2 \cdot 713 - P_aCO_2 \cdot 1,25. \quad (14)$$

Таким образом, с учетом (14):

$$AaG = [FiO_2 \cdot (P_{atm} - 47) - \left(\frac{P_aCO_2}{0,8}\right)] - P_aO_2. \quad (15)$$

Дополнительно учитывались барометрическое давление, температура тела и дыхательный коэффициент, что обеспечивало адаптацию модели к индивидуальным физиологическим условиям пациента. Повышенный *A-a* градиент (альвеоларно-артериальная разница > возрастной нормы) указывает на лёгочную патологию как причину гипоксемии: пневмония, отёк лёгких, ТЭЛА – тромбоэмболия легочной артерии, ОРДС – острый респираторный дистресс-синдром, ателектаз, фиброз лёгких. Нормальный *A-a* градиент при гипоксемии предполагает гиповентиляцию (например, угнетение дыхательного центра), дыхание гипоксической смесью или высокогорную гипоксию.

## РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

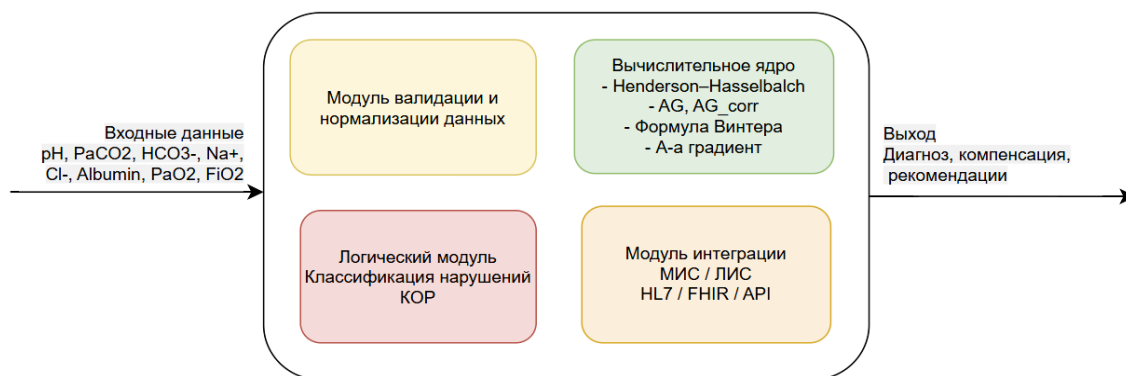
В ходе исследования была разработана структурированная система математической интерпретации газового состава крови, интегрирующая ключевые физиологические уравнения в единый алгоритм поддержки клинических решений. Полученные результаты показали, что последовательное использование моделей Гендерсона-Хассельбаха, анионной разницы, формулы Винтера и расчёта альвеоларно-артериального градиента позволяет формировать многоуровневую оценку кислотно-щелочного состояния пациента (Yee, et al, 2022).

Разработанная система реализуется в виде многоуровневой архитектуры, включающей следующие компоненты:

– уровень данных, который включает входные лабораторные показатели ( $pH$ ,  $P_aCO_2$ ,  $HCO_3^-$ , электролиты, альбумин,  $P_aO_2$ ,  $FiO_2$ ), поступающие из лабораторной информационной системы;

- вычислительное ядро, которое реализует математические модели (уравнение Гендерсона–Хассельбаха; расчёт анионной разницы и её коррекции; формулу Винтера и расчёт альвеоларно-артериального градиента);
- логический модуль, который выполняет классификацию нарушений кислотно-основного состояния на основе правил и пороговых значений;
- модуль представления, который формирует диагностическое заключение и рекомендации.
- интеграционный слой, который обеспечивает взаимодействие с медицинскими информационными системами посредством API и стандартов HL7/FHIR.

На рисунке 3 представлена обобщённая архитектура системы поддержки клинических решений на основе газометрии крови.



**Рисунок 3.** Обобщённая архитектура системы поддержки клинических решений на основе газометрии крови

Примечание – составлено авторами (Увалиева И.М., 2026)

Входные параметры модели включают следующие показатели:  $pH$ ,  $P_aCO_2$ ,  $HCO_3^-$ ;  $-Na^+$ ,  $Cl^-$ ; Albumin;  $P_aO_2$ ,  $FiO_2$ . Выходными параметрами являются:

- тип нарушения КОР (ацидоз/алкалоз);
- природа (метаболическая/респираторная);
- наличие компенсации;
- наличие смешанных нарушений;
- значения  $AG$ ,  $AG\_corr$ ,  $AaG$ ;
- текстовое диагностическое заключение.

Алгоритм обеспечивал автоматическую классификацию первичных нарушений КОР – метаболических и респираторных ацидозов и алкалозов, а также выявление смешанных состояний, что особенно важно при гематологических патологиях, сопровождающихся тканевой гипоксией и метаболическим ацидозом. Расчёт анионной разницы и её коррекция при гипоальбуминемии позволили повысить точность диагностики скрытых метаболических нарушений, часто встречающихся у пациентов с хроническими воспалительными и неопластическими заболеваниями крови.

Формализованный алгоритм обработки данных представлен в виде псевдокода на рисунке 4.

Использование формулы Винтера показало высокую эффективность для оценки адекватности респираторной компенсации, что имеет практическое значение при анемиях и состояниях, сопровождающихся нарушением вентиляции. Дополнительное включение альвеоларно-артериального градиента кислорода обеспечило возможность дифференцировать гипоксемию лёгочного и внелёгочного происхождения, что важно при оценке дыхательной недостаточности у пациентов с гематологическими заболеваниями.

```
INPUT: pH, PaCO2, HCO3, Na, Cl, Albumin, PaO2, FIO2

IF pH < 7.35 THEN state = "acidosis"
ELSE IF pH > 7.45 THEN state = "alkalosis"

AG = Na - (Cl + HCO3)
AG_corr = AG + 2.5*(40 - Albumin)

expected_PaCO2 = 1.5 * HCO3 + 8

PAO2 = FIO2*(760-47) - PaCO2/0.8
AaG = PAO2 - PaO2

CLASSIFY disorder
OUTPUT diagnosis
```

**Рисунок 4.** Формализованный алгоритм обработки данных в виде псевдокода  
Примечание – составлено авторами (Увалиева И.М., 2026)

В рамках вычислительного эксперимента разработанный алгоритм был реализован в виде программного прототипа, обеспечивающего интерактивную обработку данных газометрии крови и визуализацию результатов интерпретации (Рис. 5).

The figure displays three sequential screenshots of a web-based application for acid-base balance analysis. The interface is titled 'Acid-Base Balance Analysis' and features a home icon in the top left corner.

The first screenshot shows the 'Electrolyte values' section with four input fields: Sodium (Na, mmol/L) with the value 138, Potassium (K, mmol/L) with 4, Chloride (Cl, mmol/L) with 104, and Bicarbonate (HCO<sub>3</sub>, mmol/L) with 24. A 'CONTINUE' button is at the bottom.

The second screenshot shows the 'Blood gas parameters' section with two input fields: Blood pH with the value 7.42 and pCO<sub>2</sub> (mmHg) with 38. A 'CONTINUE' button is at the bottom.

The third screenshot shows the final results. A progress indicator on the left lists five steps: 'Electrolyte values', 'Blood gas parameters', 'Acid-base parameter evaluation', 'Anion gap evaluation', and 'no\_disturbance'. The 'no\_disturbance' step is highlighted with a blue circle. Below the list, a light blue box contains the text: 'No evidence of extracellular acid-base disturbance.' A 'START AGAIN' button is at the bottom.

**Рисунок 5.** Формализованный алгоритм обработки данных в виде псевдокода  
Примечание – составлено авторами (Увалиева И.М., 2026)

Прототип системы включает последовательный пользовательский сценарий, отражающий архитектуру алгоритма:

- ввод электролитных параметров ( $Na^+$ ,  $K^+$ ,  $Cl^-$ ,  $HCO_3^-$ ) для расчёта анионной разницы;
- ввод параметров газового состава крови ( $pH$ ,  $P_aCO_2$ ) для определения первичного нарушения кислотно-основного состояния;

- автоматическая вычислительная обработка, включающая расчёт анионной разницы (AG), коррекцию AG с учётом уровня альбумина, оценку компенсации (формула Винтера), анализ кислотно-основного состояния;

- формирование диагностического заключения, отображаемого пользователю.

Обсуждение результатов показало, что математическая формализация газометрии крови позволяет значительно повысить воспроизводимость клинических выводов и уменьшить субъективность интерпретации. Интеграция различных физиологических моделей в единую алгоритмическую систему создаёт основу для разработки интеллектуальных систем поддержки принятия решений в гематологии. Обработка данных в системе реализуется как последовательность следующих вычислительных процессов: валидация входных данных, приведение единиц измерения, расчёт производных показателей, применение диагностических правил, формирование заключения. Интеграция системы в медицинскую информационную среду может быть реализована в виде REST API сервиса, микросервиса в составе МИС, модуля лабораторной информационной системы. Типовой сценарий использования включает автоматическую передачу данных газометрии, выполнение расчётов и возврат интерпретации врачу в интерфейсе МИС.

Воспроизводимость предложенного решения обеспечивается использованием формализованных математических моделей и алгоритмизированной логики обработки данных, что исключает субъективную вариативность интерпретации. Практическая эффективность выражается в сокращении времени анализа газометрии крови, снижении вероятности диагностических ошибок и повышении согласованности клинических решений.

## ЗАКЛЮЧЕНИЕ

Проведённое исследование подтвердило высокую диагностическую значимость математической интерпретации газового состава крови при разработке алгоритмов поддержки клинических решений в гематологии. Интеграция физиологических уравнений кислотно-основного равновесия в единую вычислительную модель позволила стандартизировать анализ лабораторных данных и повысить объективность клинической оценки состояния пациентов.

Полученные результаты демонстрируют, что использование алгоритмизированных подходов способствует более точной дифференциации метаболических и респираторных нарушений, оценке компенсаторных механизмов и выявлению смешанных кислотно-щелочных состояний, что имеет особую значимость при гематологических заболеваниях, сопровождающихся гипоксией и метаболическими расстройствами.

Научная новизна работы заключается в разработке интегрированной информационно-вычислительной модели поддержки клинических решений, объединяющей физиологические модели газообмена и кислотно-щелочного баланса в единую алгоритмическую структуру, адаптированную к задачам гематологии.

В отличие от существующих подходов, в работе:

- предложена формализованная схема интерпретации газометрии крови на основе объединения уравнения Гендерсона–Хассельбаха, анионной разницы, формулы Винтера и альвеолярно-артериального градиента;

- разработан алгоритм автоматической классификации кислотно-основных нарушений и выявления смешанных состояний;

- предложена архитектура системы поддержки клинических решений, ориентированная на интеграцию в медицинские информационные системы;

- реализован подход к интерпретации данных газометрии как вычислительного pipeline, обеспечивающий воспроизводимость и снижение субъективности клинической оценки.

Практическая значимость результатов определяется возможностью внедрения разработанных математических моделей в клинические информационные системы для автоматизированной интерпретации газометрии крови.

Перспективы дальнейших исследований связаны с расширением алгоритма за счёт анализа динамических показателей, интеграцией дополнительных биомаркеров метаболизма и разработкой интеллектуальных систем, способных адаптироваться к индивидуальным физиологическим особенностям пациентов.

**КОНФЛИКТ ИНТЕРЕСОВ:** Авторы заявляют об отсутствии конфликта интересов.

**ФИНАНСИРОВАНИЕ:** Данная статья подготовлена в рамках проекта грантового финансирования научных исследований МНВО по теме AP26194209 «Математическое и алгоритмическое обеспечение интеллектуальной системы поддержки принятия клинических решений в гематологии и диабетологии на основе технологии газометрии крови».

**УВЕДОМЛЕНИЕ ОБ ИСПОЛЬЗОВАНИИ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА:** не использовались.

#### СПИСОК ЛИТЕРАТУРЫ

- Mirabelli, M., Misiti, R., Sicilia, L., Brunetti, F. S., Chiefari, E., Brunetti, A., & Foti, D. P. (2024). Hypoxia in human obesity: New insights from inflammation towards insulin resistance-A narrative review. *International journal of molecular sciences*, 25(18), 9802. <https://doi.org/10.3390/ijms25189802>
- Yee, J., Frinak, S., Mohiuddin, N., & Uduman, J. (2022). Fundamentals of arterial blood gas interpretation. *Kidney360*, 3(8), 1458-1466. <https://doi.org/10.34067/KID.0008102021>
- Castro, D., Patil, S., Zubair, M., & Keenaghan, M. (2024). Arterial blood gas. *StatPearls*. <https://www.ncbi.nlm.nih.gov/books/NBK536919/>
- Khadka, L. B., Mouzakis, F. L., Kashefi, A., Hima, F., Spillner, J. W., & Mottaghy, K. (2023). Blood gas parameters and acid-base balance during extracorporeal lung support with oxygenators: Semi-empirical evaluation. *Mathematics*, 11(19), 4088. <https://doi.org/10.3390/math11194088>
- Sanghavi, S. F., & Swenson, E. R. (2023, October). Arterial Blood Gases and Acid-Base Regulation. In *Seminars in Respiratory and Critical Care Medicine* (Vol. 44, No. 05, pp. 612-626). Thieme Medical Publishers, Inc.. <https://doi.org/10.1055/s-0043-1770341>
- Zeiler, G. E., Fuller, A., Kamerman, P., Buck, R. K., Pohlin, F., & Dzikiti, B. T. (2022). Describing acid-base balance using three different methods of analysis in a feline acute haemorrhage-resuscitation model. *Veterinary anaesthesia and analgesia*, 49(1), 65-75. <https://doi.org/10.1016/j.vaa.2021.07.004>
- Арабова, З.У., Шукуров, Ф.А., & Халимова, Ф.Т. (2022). Современные аспекты изучения адаптационных возможностей организма к условиям высокогорья (обзор литературы). *Биология и интегративная медицина*, (3 (56)), 4-47. URL: <https://cyberleninka.ru/article/n/sovremennye-aspekty-izucheniya-adaptatsionnyh-vozmozhnostey-organizma-k-usloviyam-vysokogorya-obzor-literatury> // Arabova, Z. U., Shukurov, F.A., & Khalimova, F.T. (2022). Sovremennye aspekty izucheniya adaptatsionnykh vozmozhnostey organizma k usloviyam vysokogor'ya (obzor literatury) [Modern aspects of studying the adaptive capabilities of the organism to high-altitude conditions (literature review)]. *Biologiya i integrativnaya meditsina*, (3 (56)), 4-47. (In Russ.)
- Лахин, Р.Е., Кусай, А.С., Усольцев, Е.А., Касимов, Р.Р., Цыганков, К.А., Старостин, Д.О., & Щеголев, А.В. (2024). Изменение клинических и лабораторных показателей в зависимости от тяжести травматического шока: ретроспективное когортное исследование. *Вестник интенсивной терапии имени А.И. Салтанова*, (3), 142-151.

- <https://doi.org/10.21320/1818-474X-2024-3-142-151> // Lakhin, R.E., Kusai, A.S., Usol'tsev, E.A., Kasimov, R.R., Tsygankov, K.A., Starostin, D.O., & Shchegolev, A.V. (2024). *Izmenenie klinicheskikh i laboratornykh pokazateley v zavisimosti ot tyazhesti travmaticheskogo shoka: retrospektivnoe kogortnoe issledovanie* [Changes in clinical and laboratory parameters depending on the severity of traumatic shock: a retrospective cohort study]. *Vestnik intensivnoy terapii imeni A.I. Saltanova*, (3), 142–151. <https://doi.org/10.21320/1818-474X-2024-3-142-151> (In Russ.)
- Petersson, J., & Glenny, R. W. (2023, October). Gas exchange in the lung. In *Seminars in Respiratory and Critical Care Medicine* (Vol. 44, No. 05, pp. 555-568). Thieme Medical Publishers, Inc.. <https://doi.org/10.1055/s-0043-1770060>
- Wagner, P. D. (2023, October). Blood gas transport: carriage of oxygen and carbon dioxide in blood. In *Seminars in respiratory and critical care medicine* (Vol. 44, No. 05, pp. 569-583). Thieme Medical Publishers, Inc.. <https://doi.org/10.1055/s-0043-1771160>
- Rhodes, C. E., Denault, D., & Varacallo, M. A. (2022). Physiology, oxygen transport. In *StatPearls* [Internet]. StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK538336>
- Lee, G. R. (2025). Clinical applications of blood gas analysis: a comparative review of arterial and venous blood gas monitoring in critical care. *Acute and Critical Care*, 40(2), 153-159. <https://doi.org/10.4266/acc.000900>
- Хеннеси, А.А., & Джапп, А.А. (2009). Анализ газов артериальной крови понятным языком / пер. с англ.; под ред. В.Л. Кассиля. М.: Практическая медицина // Hennessey, A. A., & Japp, A. A. (2009). *Analiz gazov arterial'noy krovi ponyatnym yazykom* [ABC of arterial blood gas analysis]. Moscow: *Prakticheskaya meditsina*. (In Russ.)
- Егорова, М. О. (2017). Газово-электролитный состав крови и информативность параметров его оценки. *Справочник заведующего КДЛ*, (9), 41–54. URL: <https://elibrary.ru/item.asp?id=29947596> // Egorova, M. O. (2017). *Gazovo-elektrolitnyy sostav krovi i informativnost' parametrov ego otsenki* [Gas-electrolyte composition of blood and informativeness of its assessment parameters]. *Spravochnik zaveduyushchego KDL*, (9), 41–54. (In Russ.)
- Di Marco, F., Raimondi, F., Imeri, G., Mazzola, C., Pappacena, S., Vargiu, S., ... & Novelli, L. (2025). Unmasking hypoxemia: the role of standard PaO<sub>2</sub> in interpreting Arterial blood gas analysis. *Multidisciplinary Respiratory Medicine*, 20(1), 1055. <https://doi.org/10.5826/mrm.2025.1055>
- Saberian, L., Sharif, M., Aarabi, M., Broumand, B., Shafiee, M. A., & Shafiee, M. (2023). Arterial versus venous blood gas analysis comparisons, appropriateness, and alternatives in different acid/base clinical settings: a systematic review. *Cureus*, 15(7). <https://doi.org/10.7759/cureus.41707>
- Ершов, Н. Г., & Александрова, Л. Н. (2022). Оценка газового состава артериальной крови в зависимости от степени морбидного ожирения у пациентов в бариатрической хирургии. *Медико-фармацевтический журнал «Пульс»*, 24(4), 116–120. <https://doi.org/10.26787/nydha-2686-6838-2022-24-4-116-120> // Ershov, N.G., & Aleksandrova, L. N. (2022). *Otsenka gazovogo sostava arterial'noy krovi v zavisimosti ot stepeni morbidnogo ozhireniya u patsientov v bariatricheskoy khirurgii* [Assessment of arterial blood gas composition depending on the degree of morbid obesity in patients undergoing bariatric surgery]. *Mediko-farmatsevticheskiy zhurnal «Pul's»*, 24(4), 116–120. <https://doi.org/10.26787/nydha-2686-6838-2022-24-4-116-120> (In Russ.)
- Abrahamowicz, A.A., Ebinger, J., Whelton, S.P., Commodore-Mensah, Y., & Yang, E. (2023). Racial and ethnic disparities in hypertension: barriers and opportunities to improve blood pressure control. *Current Cardiology Reports*, 25(1), 17-27. <https://doi.org/10.1007/s11886-022-01826-x>
- Poole, D. C., Schulze, K. M., Weber, R. E., & Musch, T. I. (2025). Oxygen Partial Pressure (PO<sub>2</sub>), in Heavy Exercise. In *Encyclopedia of Exercise Medicine in Health and Disease* (pp. 1-8).

- Berlin, Heidelberg: Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-27830-3\\_159-1](https://doi.org/10.1007/978-3-642-27830-3_159-1)
- Phyu, S. L., Turnbull, C., & Talbot, N. (2023). Basic respiratory physiology. *Medicine*, 51(10), 679-683. <https://doi.org/10.1016/j.mpmed.2023.07.006>
- Green, S. (2025). A Fick tool: connecting Fick's law and principle in teaching pulmonary gas exchange. *Advances in Physiology Education*. <https://doi.org/10.1152/advan.00044.2025>
- Martynov, S. B., Porter, R. T., & Mahgerefteh, H. (2022). Henry's law constants and vapor-liquid distribution coefficients of noncondensable gases dissolved in carbon dioxide. *ACS omega*, 7(10), 8777-8788. <https://doi.org/10.1021/acsomega.1c07044>
- Imenez Silva, P. H., & Mohebbi, N. (2022). Kidney metabolism and acid-base control: back to the basics. *Pflügers Archiv-European Journal of Physiology*, 474(8), 919-934. <https://doi.org/10.1007/s00424-022-02696-6>
- Lucy, C. A. (2023). Is Your Henderson-Hasselbalch Calculation of Buffer pH Correct?. *Journal of Chemical Education*, 100(6), 2418-2422. <https://doi.org/10.1021/acs.jchemed.2c01203>
- Rehman, M. Z., Melamed, M., Harris, A., Shankar, M., Rosa, R. M., & Batlle, D. (2023). Urinary ammonium in clinical medicine: direct measurement and the urine anion gap as a surrogate marker during metabolic acidosis. *Advances in Kidney Disease and Health*, 30(2), 197-206. <https://doi.org/10.1053/j.akdh.2022.12.006>
- Agro, F. E., Pascarella, G., Ruggiero, A., & Strumia, A. (2026). Acid-Base Balance and Blood Gas Analysis After Adult Cardiac Surgery. In *Postoperative Critical Care for Adult Cardiac Surgical Patients* (pp. 395-418). Cham: Springer Nature Switzerland. [https://doi.org/10.1007/978-3-032-01256-2\\_15](https://doi.org/10.1007/978-3-032-01256-2_15)
- Abedi, F., Zarei, B., & Elyasi, S. (2024). Albumin: a comprehensive review and practical guideline for clinical use. *European journal of clinical pharmacology*, 80(8), 1151-1169. <https://doi.org/10.1007/s00228-024-03664-y>
- Bajwa, G. S., Hussain, A., & Javaid, M. M. (2022). How to work up an adult patient with metabolic acidosis. *British Journal of Hospital Medicine*, 83(8), 1-11. <https://doi.org/10.12968/hmed.2021.0582>
- Adrogué, H. J., & Madias, N. E. (2023). Respiratory acidosis, respiratory alkalosis, and mixed disorders. *Comprehensive Clinical Nephrology E-book*, 182. <https://doi.org/10.1053/j.ajkd.2023.02.004>
- Sharma, S., Hashmi, M. F., Hendrix, J. M., & Burns, B. (2024). Alveolar gas equation. In *StatPearls* [Internet]. StatPearls Publishing. <https://pubmed.ncbi.nlm.nih.gov/29489223>
- Yee, J., Frinak, S., Mohiuddin, N., & Uduman, J. (2022). Fundamentals of arterial blood gas interpretation. *Kidney360*, 3(8), 1458-1466. <https://doi.org/10.34067/kid.0008102021>.

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Увалиева Индира Махмутовна** – PhD, Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Увалиева Индира Махмутовна** – PhD, Д.Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен, Қазақстан

**Uvaliyeva Indira Makhmutovna** – PhD, East Kazakhstan Technical University, Ust-Kamenogorsk, Republic of Kazakhstan

e-mail: iuvaliyeva@ektu.kz,

ORCID: <https://orcid.org/0000-0002-2117-5390>



**Рахметуллина Женисгуль Толеухановна** – кандидат физико-математических наук, Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан

**Рахметуллина Женисгуль Толеухановна** – физика-математика ғылымдарының кандидаты, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

**Rakhmetullina Zhenisgul Toleukhanovna** – Candidate of Physical-Mathematical Sciences, D.Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Republic of Kazakhstan

e-mail: [zhrakhmetullina@edu.ektu.kz](mailto:zhrakhmetullina@edu.ektu.kz),

ORCID: <https://orcid.org/0000-0002-0554-7684>



**Тезекпаева Шынар Толегеновна** – докторант ОП «Информационные системы», школа цифровых технологий и искусственного интеллекта, Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Республика Казахстан

**Тезекпаева Шынар Толегеновна** – «Ақпараттық жүйелер» БББ докторанты, цифрлық технологиялар және жасанды интеллект мектебі, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен, Қазақстан Республикасы

**Tezekpaeva Shynar Tolegenovna** – PhD student, the School of Digital Technology and artificial intelligence, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Republic of Kazakhstan

e-mail: [shtezekpaeva@edu.ektu.kz](mailto:shtezekpaeva@edu.ektu.kz),

ORCID: <https://orcid.org/0009-0006-9552-0288>



**Мухамедова Раушан Оразгалиевна** – магистр, старший преподаватель кафедры «Математика», Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск

**Мухамедова Раушан Оразгалиевна** – магистр, «Математика» кафедрасының аға оқытушысы, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен, Қазақстан Республикасы

**Mukhamedova Raushan Orazgalievna** – master's degree, senior lecturer at the department of Mathematics, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Republic of Kazakhstan

e-mail: [rmukhamedova@ektu.kz](mailto:rmukhamedova@ektu.kz),

ORCID: <https://orcid.org/0000-0001-5665-6808>

[https://doi.org/10.51885/3134-8025\\_IJCS\\_2026\\_1\\_12](https://doi.org/10.51885/3134-8025_IJCS_2026_1_12)

МРНТИ 50.41.29

## АВТОМАТИЗИРОВАННАЯ СИСТЕМА МОНИТОРИНГА И ОЦЕНКИ НАВЫКОВ ЦИФРОВОГО ПИСЬМА У ДОШКОЛЬНИКОВ

### МЕКТЕП ЖАСЫНА ДЕЙІНГІ БАЛАЛАРДЫҢ ЦИФРЛЫҚ ЖАЗУ ДАҒДЫЛАРЫН БАҚЫЛАУ МЕН БАҒАЛАУДЫҢ АВТОМАТТАНДЫРЫЛҒАН ЖҮЙЕСІ

### AUTOMATED SYSTEM FOR MONITORING AND EVALUATING DIGITAL WRITING SKILLS IN PRESCHOOLERS

А.В. Шапорева <sup>1\*</sup>, О.Л. Копнова <sup>1</sup>, К.Е. Икласова <sup>1</sup>, А.М. Айтымова <sup>1</sup>

<sup>1</sup>НАО «Северо-Казахстанский университет имени Манаша Козыбаева», г. Петропавловск, Казахстан

\*Автор-корреспондент: Шапорева Анна Васильевна, e-mail: annvolkova@mail.ru

#### Ключевые слова:

цифровое письмо,  
графомоторные навыки,  
дошкольное образование,  
автоматизированная  
система, анализ  
траекторий, мониторинг,  
оценка навыков,  
адаптивное обучение.

#### АННОТАЦИЯ

В работе представлена автоматизированная система мониторинга и оценки навыков цифрового письма у дошкольников, интегрирующая методы педагогики, анализа графомоторных траекторий и современных цифровых технологий. Система фиксирует параметры, отражающие качество и динамику письма, включая точность начертания, время выполнения, силу нажатия и устойчивость линий. Реализован алгоритм, позволяющий сравнивать пользовательский ввод с эталонным образцом с учетом типа инструмента (стилус или палец). Разработан функционал формирования отчетов для педагогов и родителей, включающий количественные и качественные показатели, графики прогресса и рекомендации по коррекции. Проведенная апробация показала, что использование системы способствует более точной диагностике навыков письма, своевременному выявлению трудностей и подбору индивидуальных заданий. Внедрение инструмента в практику дошкольного образования обеспечивает персонализацию обучения и формирование цифровой среды для диагностики и коррекции.

#### Түйінді сөздер:

сандық жазу,  
графомоторлық  
дағдылар, мектепке  
дейінгі білім беру,  
автоматтандырылған  
жүйе, траекторияларды  
талдау, мониторинг,  
дағдыларды бағалау,  
бейімделген оқыту.

#### ТҮЙІНДЕМЕ

Жұмыста мектеп жасына дейінгі балалардың цифрлық жазу дағдыларын бақылау мен бағалаудың автоматтандырылған жүйесі, педагогика әдістерін, графомоторлық траекторияларды және заманауи цифрлық технологияларды талдауды біріктіреді. Жүйе жазудың сапасы мен динамикасын көрсететін параметрлерді, соның ішінде сызбаның дәлдігін, орындалу уақытын, басу күшін және сызықтардың тұрақтылығын түсіреді. Құралдың түрін (қалам немесе саусақ) ескере отырып, пайдаланушы енгізуін анықтамалық үлгімен салыстыруға мүмкіндік беретін алгоритм енгізілді. Сандық және сапалық көрсеткіштерді, прогресс кестелерін және түзету



бойынша ұсыныстарды қамтитын педагогтар мен ата-аналар үшін есептерді қалыптастыру функционалы әзірленді. Апробация жүйені қолдану жазу дағдыларын дәлірек диагностикалауға, қиындықтарды уақтылы анықтауға және жеке тапсырмаларды таңдауға ықпал ететіндігін көрсетті. Құралды мектепке дейінгі білім беру практикасына енгізу оқытуды дербестендіруді және диагностика мен түзету үшін цифрлық ортаны қалыптастыруды қамтамасыз етеді.

---

**keywords:**

digital writing,  
graphomotor skills,  
preschool education,  
automated system,  
trajectory analysis,  
monitoring skills  
assessment, adaptive  
learning.

---

**ABSTRACT**

The paper presents an automated system for monitoring and evaluating digital writing skills in preschoolers, integrating methods of pedagogy, graphomotor trajectory analysis, and modern digital technologies. The system records parameters that reflect the quality and dynamics of writing, including spelling accuracy, execution time, pressing force, and line stability. An algorithm has been implemented that allows comparing user input with a reference sample, taking into account the type of instrument (stylus or finger). The functionality of generating reports for teachers and parents has been developed, including quantitative and qualitative indicators, progress charts and recommendations for correction. The conducted testing has shown that the use of the system contributes to a more accurate diagnosis of writing skills, timely identification of difficulties and selection of individual tasks. The introduction of the tool into the practice of preschool education ensures the personalization of learning and the formation of a digital environment for diagnosis and correction.

---

**ВВЕДЕНИЕ**

Цифровое обучение письму и его анализ с использованием таких устройств, как планшет или сотовый телефон, представляет собой перспективное направление, объединяющее педагогику, нейротехнологии, искусственный интеллект и современные цифровые интерфейсы.

Большое внимание в научной литературе уделено оценке развития навыков письма у дошкольников с помощью цифровых устройств. В статье (Rane et al., 2022) рассматривается платформа на базе планшета, разработанная для количественной оценки графомоторных навыков, ориентированная как на скорость движения пера, так и на качество вывода графики. В статье (Dinehart, 2014) представлены исследование развития почерка и мелкой моторики у дошкольников с помощью цифровых устройств и анализ влияния почерка на успехи в учебе.

В статье (Сессасци et al., 2024) обсуждается экспериментальное исследование, в ходе которого тестируется инновационное тактильное устройство, предназначенное для анализа навыков письма и координации движений в режиме реального времени. В статье (Šafářová et al., 2022) обсуждается оригинальный подход к диагностике нарушений письма у детей с помощью объективного анализа рукописного текста в Интернете. В ней представлена «Шкала оценки графомоторных нарушений и нарушений почерка» (GHDRS), которая позволяет детально оценить трудности с письмом у детей. В статье (Корнова et al., 2024) обсуждается оценка навыков письма у дошкольников и учащихся начальной школы с использованием графических планшетов. В статье (Devilleine et al., 2021) представлен анализ навыков письма с помощью графических планшетов, в котором основное внимание уделяется инструменту предварительной диагностики дистрофии.

В (Aitymova et al., 2023) представлена модель управления информационными процессами в информационно-образовательной среде организаций дошкольного образования. Внедрение разработанной модели позволило уменьшить затраты времени на корректировку индивидуальной работы с обучающимися на 30 % за счет автоматизации хранения, обработки и анализа данных о дошкольниках.

В (Iklassova et al., 2024) представлена информационная система оценки качества усвоения компетенций детей дошкольного возраста на основе онтологического подхода. Предложенный в статье метод интеграции данных существенно облегчил процесс анализа данных как по группе, так и по отдельному респонденту.

Актуальность данного исследования обусловлена тем, что разработка автоматизированной системы мониторинга и оценки навыков цифрового письма у дошкольников при обучении письму с помощью цифровых устройств поможет своевременно подобрать корректирующие задания, что положительно скажется на подготовке к школе.

Цель исследования заключается в обосновании и апробации разработанной автоматизированной системы мониторинга и оценки навыков цифрового письма у дошкольников.

## МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Основной функцией автоматизированной системы мониторинга и оценки навыков цифрового письма у дошкольников является контроль прогресса навыков. Это ключевая функция, реализуемая автоматизированной системой, которая помогает педагогам оценить эффективность заданий. АИС реализует систематическую фиксацию взаимодействий ребенка с экраном во время выполнения развивающих заданий и написания букв на планшете. Для каждой попытки автоматически регистрируются следующие параметры: уникальные идентификаторы пользователя (UserID) и сессии (SessionID), метка времени (Timestamp), тип задания (ExerciseType), конкретная цель задания (ExerciseTarget), выбранный персонаж-помощник (CharacterMascot), количество допущенных ошибок (ErrorCount), рассчитанное на основе сопоставления пользовательской траектории с эталонной, а также время выполнения задания (WritingTimeMillis). Дополнительно могут учитываться такие показатели, как средняя сила нажатия на экран (AveragePressure) и количество резких изломов линии (JitterCount), отражающих моторную нестабильность. Статус завершенности задания (CompletedStatus) фиксирует, была ли попытка доведена до конца.

Апробация разработанной автоматизированной информационной системы (АИС) проводилась в период с января 2025 по июнь 2025 на базе КГУ «Ясли-сад № 1» г. Петропавловска. В исследовании приняли участие 148 детей старшего дошкольного возраста (от 5 до 6 лет). Выборка была сформирована на основе добровольного согласия родителей и отсутствия у детей выраженных когнитивных нарушений, препятствующих работе с планшетным компьютером. Собранные данные сохраняются в локальную базу (например, CSV-файл или SQLite). Первичный анализ производится на основе количества ошибок и времени выполнения, что позволяет оперативно оценить успешность попытки. Для более глубокой оценки прогресса и усвоения навыков реализован агрегированный анализ, включающий фильтрацию данных по конкретным параметрам. К параметрам фильтрации можно отнести: идентификатор пользователя и цель задания, что обеспечивает возможность отслеживания индивидуальной динамики развития мелкой моторики и качества выполнения заданий. На рисунке 1 представлен алгоритм анализа прогресса.

Регистрация действий. АИС фиксирует каждое взаимодействие ребенка с экраном во время выполнения заданий. Сохраняются следующие параметры для каждой попытки. UserID: идентификатор ребенка. SessionID: идентификатор текущей игровой сессии.

Timestamp: точное время совершения попытки. ExerciseType: тип упражнения «Буква» или «Дорожка». ExerciseTarget: конкретная буква (например, «А», «Б») или название «Дорожки». CharacterMascot: выбранный персонаж-помощник. ErrorCount: ключевой показатель – количество ошибок, выявленных алгоритмом анализа при сравнении траектории пользователя с эталоном (детали см. в описании алгоритма анализа ошибок на основе схемы). WritingTimeMillis: время, затраченное на выполнение данной конкретной попытки, в миллисекундах. AveragePressure (опционально): Средний нажим на экран. JitterCount (опционально): количество резких изломов линии («дрожание»).

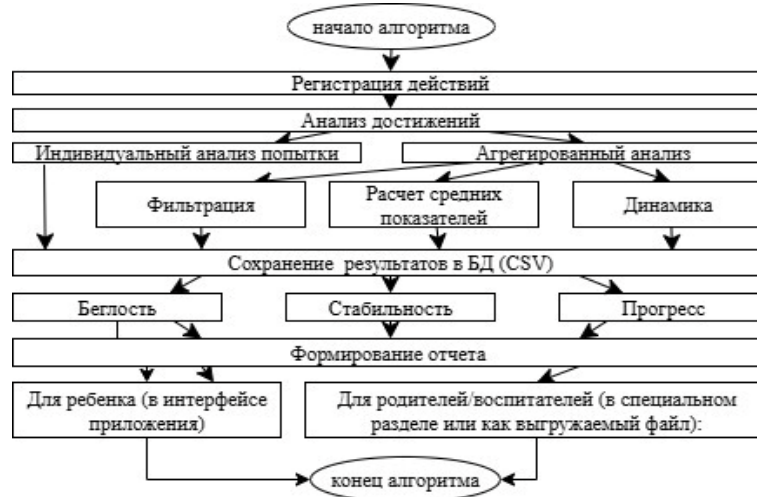


Рисунок 1. Алгоритм анализа прогресса

Примечание – составлено авторами

CompletedStatus: Статус (завершено/не завершено). Сохранение: Эти данные записываются в базу данных (например, в локальный CSV-файл или базу данных SQLite на устройстве).

Анализ достижений начинается с индивидуального анализа попытки. Сразу после выполнения задания ErrorCount и WritingTimeMillis дают первичную оценку.

Агрегированный анализ (для оценки усвоения и прогресса) включает фильтрацию. Для анализа конкретной буквы (например, «А») или навыка система отбирает все попытки данного UserID для соответствующего ExerciseTarget.

Расчет средних показателей. За определенный период (например, последняя неделя, все время) или для последних N попыток вычисляются: среднее количество ошибок, среднее время написания.

Определяем динамику (личный рост) – система сравнивает текущие средние показатели с предыдущими периодами или отслеживает их изменение во времени.

Математическое описание для вычисления качества усвоения

Пусть  $A_{u,l,k}$  – k-я попытка пользователя и для буквы l.

$e_{u,l,k}$  – ErrorCount для этой попытки.

$t_{u,l,k}$  – WritingTimeMillis для этой попытки.

Среднее количество ошибок для пользователя и по букве l за N попыток (1):

$$\bar{e}_{u,l} = \frac{1}{N} \sum_{k=1}^N e_{u,l,k}. \quad (1)$$

Среднее время написания для пользователя и по букве l за N попыток (2):

$$\bar{t}_{u,l} = \frac{1}{N} \sum_{k=1}^N t_{u,l,k}. \quad (2)$$

Качество усвоения написания буквы ( $Q_{u,l}$ ). Качество усвоения является комплексной метрикой. На основе ErrorCount (отклонение от эталона). Можно ввести показатель точности ( $P_{u,l}$ ). Если ErrorCount ( $e_{u,l,k}$ ) представляет собой ненормированное количество ошибок, то точность можно определить относительно некоторой «сложности» или «максимально допустимого числа ошибок» ( $E_{max,l}$ ) для буквы  $l$  (3):

$$P_{u,l} = \max\left(0,1 - \frac{\bar{e}_{u,l}}{E_{max,l}}\right) \times 100\%. \quad (3)$$

Если  $E_{max,l}$  не определено, можно использовать пороговые значения  $\bar{e}_{u,l}$  для качественной оценки.

Уровни точности:

Высокий:  $\bar{e}_{u,l} \leq 1-2$ , средний:  $3 \leq \bar{e}_{u,l} \leq 8$ , низкий  $\bar{e}_{u,l} \geq 9$ . Эти пороги должны быть откалиброваны для приложения в целом.

Беглость: учитывается  $\bar{t}_{u,l}$ . Снижение времени при сохранении или улучшении точности указывает на рост мастерства.

Стабильность: оценивается через дисперсию  $\bar{e}_{u,l}$  и  $\bar{t}_{u,l}$  по нескольким попыткам. Низкая дисперсия при хорошей точности – признак стабильного навыка.

Прогресс (личный рост):  $\Delta Q_{u,l}$  оценивается как разность значений  $Q_{u,l}$  последней попытки и предыдущей. Положительная динамика  $\Delta Q_{u,l}$  или снижение  $\bar{e}_{u,l}$  свидетельствует о развитии навыка.

После каждой завершенной (или прерванной) попытки выполнения упражнения новая строка с данными (UserID, SessionID, Timestamp, ExerciseTarget, ErrorCount, WritingTimeMillis и др.) добавляется в конец CSV-файла. Рассчитываются средние показатели (ErrorCount, WritingTimeMillis) по сессиям или временным окнам (например, по дням, неделям) для построения графиков прогресса. Для оценки динамики выбираются данные за текущий и предыдущий отчетные периоды, после чего сравниваются агрегированные показатели.

Для количественной и качественной оценки навыков ребенка разработана система параметров, отражающих ключевые характеристики процесса письма. Эти параметры позволяют зафиксировать и интерпретировать особенности начертания линий, обеспечивая объективную диагностику отклонений и динамики развития. Методы анализа основаны на математических представлениях траекторий и учете временных характеристик. В таблице 1 приведены основные параметры, используемые в алгоритме анализа письма, соответствующие методы их вычисления и семантика параметров с педагогической точки зрения на основании анализа источников (Tony et al., 1988; Kong. et al., 2025; Yu et al., 2024; Lyu et al., 2014; Steve Marschner .Cornell, 2020).

**Таблица 1.** Ключевые параметры для анализа письма

Параметр	Метод анализа	Семантика параметра
Кривизна и углы поворота	Полигональная цепь	Частота и резкость изменения направления
Длина и регулярность отрезков	Кусочно-линейная функция	Стабильность темпа письма
Плавность и непрерывность	Сплайн Кэтмулл-Рома	Оценка моторной координации, выявление дрожаний
Скорость написания	Все методы (по времени точек)	Связана с уверенностью и опытом
Колебания и рывки	Сплайн + фильтрация скорости	Индикаторы моторных нарушений или переутомления

*Примечание – составлено авторами*

Сравнительный анализ характеристик различных способов ввода позволяет повысить точность интерпретации графомоторных данных и адаптировать алгоритмы обработки с учетом специфики устройства. Особое внимание уделяется различиям между стилусом и пальцем как основными инструментами взаимодействия пользователя с экраном. Эти различия затрагивают как физико-технические параметры (точность, чувствительность, поддержка давления), так и особенности начертания, что влияет на выбор методов фильтрации, сглаживания и интерпретации результатов. В таблице 2 представлены ключевые различия между стилусом и пальцем, учитываемые в процессе анализа на основании анализа источников (Li et al., 2024; Begum et al., 2021; Rahim et al., 2024; Mekyska et al., 2023).

**Таблица 2.** Ключевые различия стилуса и пальца

Параметр	Стилус	Палец
Точность позиционирования	Высокая (до ~0.1 мм)	Средняя/низкая (~2-4 мм)
Частота сенсора	Выше (60-240 Гц)	Ниже (30-60 Гц)
Поддержка давления (pressure)	Да (у многих моделей)	Нет
Наличие наклона (tilt)	Да (у некоторых моделей)	Нет
Толщина линии	Переменная (в зависимости от давления)	Статическая или сильно ограниченная
Естественность письма	Ближе к бумаге	Менее контролируемая, более округлая
<i>Примечание – составлено авторами</i>		

При анализе кривой, нарисованной пальцем, увеличиваются допустимые отклонения при сравнении с эталоном. Для стилуса допускается меньшая погрешность, выше требования к точности.

## РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Занятия с использованием АИС проводились в первой половине дня в специально оборудованном кабинете. Каждое тестирование носило индивидуальный характер и занимало от 10 до 15 минут, что соответствует санитарно-эпидемиологическим нормам работы дошкольников с цифровыми устройствами. Перед началом работы проводился краткий инструктаж (2–3 минуты) по использованию стилуса и навигации в приложении. Мониторинг осуществлялся в течение 4 недель с периодичностью 2 раза в неделю, что позволило отследить динамику формирования графомоторного навыка.

В АИС предусмотрено несколько вариантов формирования отчета. Для ребенка (в интерфейсе) сформирована мгновенная, мотивирующая обратная связь. Визуализация успеха – путем появления звездочек и фейерверков. Звуковое сопровождение также играет немаловажную роль в поддержании интереса ребенка. Вместо акцента на ошибках – мягкое предложение попробовать снова или небольшая подсказка (мигание начальной точки штриха, показ правильного начертания цветом).

Для родителей/воспитателей (в специальном разделе или как выгружаемый файл): информирование о динамике развития, сильных и слабых сторонах, предоставление данных для принятия решений. Имеет структурированный формат с текстом и графиком роста баллов. Общая сводка содержит: Имя ребенка, отчетный период. Общая активность (количество занятий, время). Средняя точность по всем освоенным буквам – процент и качественный уровень: отлично, хорошо, удовлетворительно, плохо и очень плохо.

Динамика общей точности и среднего количества ошибок по сравнению с предыдущим периодом (например, «Точность выросла на 10 %, среднее число ошибок снизилось с 2,5 до 1,8»).

Для сохранения конфиденциальности личных данных каждому ребенку присваивается личный id, который используется для внешних отчетов, например для отдела образования или общего отчета по детскому саду. Файл child\_id содержит список соответствий id детей и их данных.

Все отчеты по цифровому обучению письму хранятся СУБД SQLite и могут быть импортированы в Excel согласно рисункам ниже. На рисунке 2 представлен отчет по анализу цифрового обучения написанию букв по подгруппе.

Дата	Подгруппа 1	Буквы					Средний процент индивидуальный	Освоение навыка
10.04.2025		Выполнение заданий в %. Написание букв.						
	ФИО ребенка	"А"	"Б"	"В"	"Г"	"Д"		
	С001	100	80	80	100	70	86	отлично
	С002	100	45	45	48	25	53	удовлетворительно
	С003	100	70	45	100	64	76	хорошо
	С004	45	30	30	80	60	49	удовлетворительно
	С005	100	84	80	100	80	89	отлично
	С006	100	88	84	100	91	93	отлично
	С007	100	95	100	100	100	99	отлично
	С008	100	50	63	100	78	78	хорошо
	С009	100	70	73	100	76	84	отлично
	С010	95	90	100	100	84	94	отлично
	Средний % по группе	94	70	70	93	73		
			Наилучшая буква	"А"				
	К-во обучающихся, набравших средний процент выполнения заданий более 81%					6		

**Рисунок 2.** Отчет по анализу цифрового обучения написанию букв по подгруппе

*Примечание – составлено авторами*

Для каждого ребенка были сгенерированы логин и пароль для работы в электронном приложении. В конце недели или после каждого занятия воспитатель может импортировать отчет, в котором отражается уровень освоения навыков письма по каждой букве или по каждому ребенку отдельно. Такой отчет помогает понять, написание каких букв дается детям наиболее сложно. В дальнейшем воспитатель может запланировать дополнительные занятия и отработать написание сложных букв.

Отчет, который формируется по каждому ребенку отдельно, дает понимание об индивидуальном освоении навыка письма. Дети, имеющие низкие проценты, например менее 41 %, нуждаются в дополнительных занятиях и коррекции по постановке навыков письма. Дети, имеющие 81 % и выше, в коррекции навыков не нуждаются и полностью освоили написание предложенных букв и дорожек.

Подобный отчет формируется и при выполнении элементов письма. Отчет представлен на рисунке 3.

В АИС предусмотрена возможность импорта полного отчета по освоению написания букв и элементов письма, который представлен на рисунке 4. Отчет содержит

полный анализ по выполнению заданий и комментарии для каждого ребенка. Комментарий поможет воспитателям и родителям подобрать корректирующие задания.

Дата	Подгруппа 1	Дорожки						Средний процент	Освоение навыка
10.04.2025		Выполнение заданий в %. Написание дорожек							
	ФИО ребенка	Мышка	Обезьяна	Медведь	Бабочка	Кролик	Котенок		
	C001	90	80	100	95	100	90	93	отлично
	C002	40	25	64	42	80	54	51	удовлетворительно
	C003	70	60	100	70	95	61	76	хорошо
	C004	43	25	70	51	80	50	53	удовлетворительно
	C005	90	82	100	80	92	86	88	отлично
	C006	100	94	100	90	100	80	94	отлично
	C007	100	100	100	90	100	92	97	отлично
	C008	71	65	100	70	76	85	78	хорошо
	C009	80	80	100	86	89	82	86	отлично
	C010	100	95	100	90	98	90	96	отлично
	Средний % по группе	78	71	93	76	91	77		
		Наилучшая дорожка Медведь							
	К-во обучающихся, набравших средний процент выполнения заданий более 81%							6	

**Рисунок 3.** Отчет по анализу цифрового обучения написанию элементов письма по подгруппе

Примечание – составлено авторами

Дата	Подгруппа 1	Выполнение заданий в %, уровень			
10.04.2025		Буквы	Уровень	Дорожки	Уровень
	ФИО ребенка				
	C001	86	отлично	93	отлично
	C002	52,6	удовлетворительно	51	удовлетворительно
	C003	75,8	хорошо	76	хорошо
	C004	49	удовлетворительно	53	удовлетворительно
	C005	88,8	отлично	88	отлично
	C006	92,6	отлично	94	отлично
	C007	99	отлично	97	отлично
	C008	78,2	хорошо	78	хорошо
	C009	83,8	отлично	86	отлично
	C010	93,8	отлично	96	отлично
		График			

**Рисунок 4.** Отчет по анализу цифрового обучения письму (полный)

Примечание – составлено авторами

Для анализа эффективности алгоритмов оценки данные, полученные в ходе апробации, были разделены. Массив данных, включающий траектории написания элементов, был разбит на две выборки: обучающую (70 %), на которой производилась калибровка пороговых значений точности и скорости, и тестовую (30 %), используемую для верификации автоматических оценок. Проверка достоверности системы осуществлялась путем сравнения автоматических баллов с экспертными оценками педагогов-дефектологов.


Для оценки преимуществ цифрового мониторинга был проведен сравнительный анализ с традиционным методом педагогической диагностики (бумажные пробы «Графический диктант» и копирование фигур). Результаты показали, что:

1. Объективность: АИС исключает субъективный фактор педагога при оценке «ровности» линий, фиксируя отклонение от эталона в пикселях.

2. Информативность: в отличие от бумажных тестов, система фиксирует латентные показатели (силу нажатия, скорость на разных участках, время пауз), которые недоступны для визуального наблюдения.

3. Эффективность: время на обработку результатов и формирование отчета для родителей сократилось с 15-20 минут при ручном анализе до мгновенного вывода в интерфейсе системы.

На форме предусмотрена кнопка «График», при нажатии на которую информация из отчета будет представлена в виде графика с указанием процента освоения навыка, в соответствии с рисунком 5.



**Рисунок 5.** График по анализу цифрового обучения письму (полный)

*Примечание – составлено авторами*

Разработанная автоматизированная система позволяет проводить агрегированный анализ, фильтруя данные по идентификатору пользователя и цели задания, что обеспечивает отслеживание индивидуальной динамики развития мелкой моторики и качества выполнения заданий по написанию букв и их элементов. Прогресс оценивается как разность значений между попытками, свидетельствуя о развитии навыка. Это позволяет динамически изменять сложность и тип заданий в зависимости от текущего прогресса и выявленных проблем ребенка, обеспечивая адаптивную коррекцию.

## ЗАКЛЮЧЕНИЕ

В отличие от многих существующих программ, которые дают лишь индикацию «правильно/неправильно» или базовую оценку точности, представленная АИС обеспечивает детализированный анализ ошибок по критериям.

Для родителей и педагогов генерируются подробные, структурированные отчеты, включающие общую сводку, среднюю точность по освоенным буквам и динамику общей точности и среднего количества. Эти отчеты своевременно информируют взрослых о динамике развития ребенка и помогают принимать обоснованные решения относительно дальнейшей стратегии обучения или необходимости консультации со специалистами.

Внедрение подобного цифрового инструмента в образовательную практику позволяет не только персонализировать обучение, но и закладывает основу для формирования гибкой цифровой среды диагностики и коррекции. В перспективе возможна интеграция данной системы с платформами адаптивного обучения, развитие автоматизированной классификации нарушений письма и расширение функциональности за счет нейросетевых методов анализа данных.

Таким образом, представленная в работе автоматизированная система мониторинга и оценки навыков цифрового письма у дошкольников может быть использована как эффективный диагностический и развивающий инструмент в практике дошкольного образования и начального обучения.

**КОНФЛИКТ ИНТЕРЕСОВ:** Авторы заявляют об отсутствии конфликта интересов.

## СПИСОК ЛИТЕРАТУРЫ

- Rane, D., Verma, P., & Lahiri, U. (2022). How Good is your Drawing? Quantifying Graphomotor Skill Using a Portable Platform (pp. 409–422). [https://doi.org/10.1007/978-3-031-22131-6\\_31](https://doi.org/10.1007/978-3-031-22131-6_31)
- Dinehart, L. H. (2014). Handwriting in early childhood education: Current research and future implications. *Journal of Early Childhood Literacy*, 15(1), 97-118. <https://doi.org/10.1177/1468798414522825>
- Ceccacci, S., Taddei, A., Del Bianco, N., Giacconi, C., Forteza Forteza, D., & Moreno-Tallón, F. (2024). Preventing Dysgraphia: Early Observation Protocols and a Technological Framework for Monitoring and Enhancing Graphomotor Skills. *Information*, 15(12), 781. <https://doi.org/10.3390/info15120781>
- Šafářová, K., Mekyska, J., Urbánek, T., Galáž, Z., Mucha, J., Zvončák, V., & Bednářová, J. (2022). Grafomotorické dovednosti. <https://doi.org/10.5817/cz.muni.m280-0257-2022>
- Kopnova, O. L., Aitymova, A. M., Abildinova, G., Safaraliev, B. S., Koleva, N. S., & Panova, M. (2024). Assessment of the level of formation of graphomotor skills of preschool and primary school students using graphic tablets. *Sovremennye Naukoëmkie Tehnologii*, 1(5), 154–159. <https://doi.org/10.17513/snt.40021>
- Devillaine, L., Lambert, R., Boutet, J., Aloui, S., Brault, V., Jolly, C., & Labyt, E. (2021). Analysis of Graphomotor Tests with Machine Learning Algorithms for an Early and Universal Pre-Diagnosis of Dysgraphia. *Sensors*, 21(21), 7026. <https://doi.org/10.3390/S21217026>
- Aitymova, A., Iklassova, K., Abildinova, G., Shaporeva, A., Kopnova, O., Kushumbayev, A., Smolyaninova, S., Aitymov, Z., Karymsakova, A. (2023). Development of a model of information process management in the information and educational environment of preschool education organizations. *Eastern-European Journal of Enterprise Technologies*, 2 (3 (122)), 95–105. doi: <https://doi.org/10.15587/1729-4061.2023.276253>
- Iklassova, K., Aitymova, A., Kopnova, O., Shaporeva, A., Abildinova, G., Nurbekova, Z., Almagambetova, L., Gorokhov, A., Aitymov, Z. (2024). Ontology modeling for automation

- of questionnaire data processing. *Eastern-European Journal of Enterprise Technologies*, 5 (2 (131)), 36–52. <https://doi.org/10.15587/1729-4061.2024.314129>
- Tony D. DeRose and Brian A. Barsky. 1988. Geometric continuity, shape parameters, and geometric constructions for Catmull-Rom splines. *ACM Trans. Graph.* 7, 1 (Jan. 1988), 1–41. <https://doi.org/10.1145/42188.42265>
- C. Kong, A. Luo, S. Wang, H. Li, A. Rocha, and A. Kot, “Pixel-inconsistency modeling for image manipulation localization,” *IEEE Trans. Pattern Anal. and Mach. Intell.*, vol. 47, no. 6, pp. 4455–4472, 2025. <https://arxiv.org/abs/2310.00234>
- C. Yu, X. Zhang, Y. Duan, S. Yan, Z. Wang, Y. Xiang, S. Ji, and W. Chen, “Diff-id: An explainable identity difference quantification framework for deepfake detection,” *IEEE Trans. Dependable Secure Comput.*, pp. 1–18, 2024. <https://arxiv.org/abs/2303.18174>
- Lyu, S., Pan, X. & Zhang, X. Exposing Region Splicing Forgeries with Blind Local Noise Estimation. *Int J Comput Vis* 110, 202–221 (2014). <https://doi.org/10.1007/s11263-013-0688-y>
- Steve Marschner .Cornell CS4620 Fall 2020. CS 4620 Lecture 14. <https://www.cs.cornell.edu/courses/cs4620/2020fa/slides/14splines.pdf>
- Li, Q., Gong, R., & Hase, K. (2024). A Comprehensive Objective Evaluation Method for Handwriting Assistive Devices Using a Tablet and Digital Pen for Individuals with Upper Limb Dysfunction. *Applied Sciences*, 14(23), 11190. <https://doi.org/10.3390/app142311190>
- Begum, N., Akash, M. A. H., Rahman, S., Shin, J., Islam, M. R., & Islam, M. E. (2021). User Authentication Based on Handwriting Analysis of Pen-Tablet Sensor Data Using Optimal Feature Selection Model. *Future Internet*, 13(9), 231. <https://doi.org/10.3390/fi13090231>
- Rahim, M.A., Farid, F.A., Miah, A.S.M., Puza, A.K., Alam, M.N. et al. (2024). An Enhanced Hybrid Model Based on CNN and BiLSTM for Identifying Individuals via Handwriting Analysis. *Computer Modeling in Engineering & Sciences*, 140(2), 1689–1710. <https://doi.org/10.32604/cmescs.2024.048714>
- Mekyska, J. et al. (2023). Assessment of Developmental Dysgraphia Utilising a Display Tablet. In: Parziale, A., Diaz, M., Melo, F. (eds) *Graphonomics in Human Body Movement. Bridging Research and Practice from Motor Control to Handwriting Analysis and Recognition*. IGS 2023. *Lecture Notes in Computer Science*, vol 14285. Springer, Cham. [https://doi.org/10.1007/978-3-031-45461-5\\_2](https://doi.org/10.1007/978-3-031-45461-5_2)

**Авторлар туралы мәліметтер**  
**Информация об авторах**  
**Information about authors**



**Шапорева Анна Васильевна** – PhD, «Құрылыс және дизайн» кафедрасының доценті; М. Қозыбаев атындағы Солтүстік Қазақстан университеті, Петропавл қ. Қазақстан Республикасы

**Шапорева Анна Васильевна** – PhD, доцент кафедрасы «Строительство и дизайн», Северо-Казахстанский университет им. М. Козыбаева, г. Петропавловск, Казахстан

**Shaporeva Anna Vasilyevna** – PhD, Associate Professor of the Department of Construction and Design; M. Kozybayev North Kazakhstan University, Petropavlovsk, Republic of Kazakhstan, e-mail: [annvolkova@mail.ru](mailto:annvolkova@mail.ru), ORCID: <http://orcid.org/0000-0002-6211-5634>



**Копнова Оксана Леонидовна** – PhD, «Математика және физика» кафедрасының аға оқытушысы; М. Қозыбаев атындағы Солтүстік Қазақстан университеті, Петропавл қ. Қазақстан Республикасы

**Копнова Оксана Леонидовна** – PhD, старший преподаватель кафедры «Математика и физика»; Северо-Казакстанский университет имени М. Козыбаева, г. Петропавловск, Республика Казахстан

**Kopnova Oksana Leonidovna** – PhD, Senior Lecturer of the Department of Mathematics and Physics; M. Kozybayev North Kazakhstan University, Petropavlovsk, Republic of Kazakhstan, e-mail: okopnova@ku.edu.kz , ORCID: <https://orcid.org/0000-0002-6299-3728>



**Икласова Кайнижамал Есемсеитовна** – PhD, «Ақпараттық-коммуникациялық технологиялар» кафедрасының доценті; М. Қозыбаев атындағы Солтүстік Қазақстан университеті, Петропавл қ. Қазақстан Республикасы

**Икласова Кайнижамал Есемсеитовна** PhD, доцент кафедры «Информационно-коммуникационные технологии»; Северо-Казакстанский университет имени М. Козыбаева, г. Петропавловск, Республика Казахстан

**Iklassova Kainizhamal Yesemseitovna** – PhD, Associate Professor of the Department of Information and Communication Technologies; M. Kozybayev North Kazakhstan University, Petropavlovsk, Republic of Kazakhstan, e-mail: kiklasova@mail.ru, ORCID: <https://orcid.org/0000-0002-8330-4282>



**Айтымова Алия Муратовна** – PhD, «Бастауыш, мектепке дейінгі және арнайы білім беру» кафедрасының аға оқытушысы; М. Қозыбаев атындағы Солтүстік Қазақстан университеті, Петропавл қ. Қазақстан Республикасы

**Айтымова Алия Муратовна** – PhD, старший преподаватель кафедры «Начальное, дошкольное и специальное образование»; Северо-Казакстанский университет имени М. Козыбаева, г. Петропавловск, Республика Казахстан

**Aitymova Aliya Muratovna** – PhD, Senior Lecturer of the Department of Primary, Preschool and Special Education; M. Kozybayev North Kazakhstan University, Petropavlovsk, Republic of Kazakhstan, e-mail: amakasheva@ku.edu.kz , ORCID: <https://orcid.org/0000-0003-1128-6924>

## МАЗМҰНЫ

<i>Акылбеков О.Н., Молдагулова А.Н., Закария Г.С., Байдильдинова С.Т., Бекарыстанқызы А.</i> Машиналық оқыту арқылы визуалды мәліметтерді өңдеу және 3D-қала үлгілерін жасау	5
<i>Ахажанов С.Б., Бибалаев О.Д., Муратхан Р., Михаиллов Д.М., Монтаева А.С.</i> Құрылыс алаңдарында қауіпсіздікті қамтамасыз ету үшін жасанды интеллект технологияларын қолдану	18
<i>Берилло Д.А., Икласова К.Е., Семенюк В.В., Ташибаев Р.М.</i> Су объектілерінің микробиологиялық мониторингінде жасанды интеллектті қолданудың стратегиялық бағыттары: түсіндірілетін модельдер және мультиомдық интеграция	32
<i>Карменова М.А., Төлеуғазы З.М., Дуанбаева Т.Б., Тлебалдинова А.С., Кумаргажанова С.К., Omiotek Z.</i> Менисктің жыртылуын жіктеу үшін машиналық оқыту алгоритмдерін қолдана отырып, тізе буынының МРТ суреттерінің текстуралық сипаттамаларын алу	44
<i>Миркасимова Т.Ш., Адилжанова С.А.</i> Ақпараттық қауіпсіздік тәуекелдерін бағалауда айқын емес FIS-моделін қолдану әдістері	59
<i>Найзабаева А.А., Алимханова А.Ж., Қуанышбекқызы К., Ерсайнова Ж.Е.</i> Нейрондық желілерді қолдана отырып, тұрғын үйдің энергия тұтыну жүйесін дамыту	74
<i>Садвакасов Т., Солтан Г., Карибеков Т., Абдрахманова С.</i> Терең оқытуды қолдана отырып, тері өсінділерінің мультимодальды жіктелуі	89
<i>Исмүхамедова А.М., Баканова А.П., Бельгинова С.А., Халимов А., Рысбаев Т.</i> Интенсивті терапиядағы өлім-жітім модельдеріндегі уақытша тұрақтылық пен үлестірім дрейфі: MIMIC-IV валидациялық зерттеуі	103
<i>Попова Г.В., Вайс Ю.А., Котлярова И.А., Жомартқызы Г., Рохас Криулько Н.П.</i> Академиялық және мотивациялық профильдерді біріктіретін ұсыныс беру жүйесінің білім беру траекторияларын болжау сенімділігін арттыру	119
<i>Тоқсеит Д.Қ., Сергазы М.Д.</i> Go тілінде енгізілген көп агентті қауіпсіздік аудит құралының архитектурасы және бастапқы тиімділігін бағалау	132
<i>Увалиева И.М., Рахметуллина Ж.Т., Тезекпаева Ш.Т., Мухамедова Р.О.</i> Қан газометриясы технологиясына негізделген гематологиядағы клиникалық шешімдерді қолдаудың математикалық модельдері мен алгоритмдері	141
<i>Шапорева А.В., Копнова О.Л., Икласова К.Е., Айтымова А.М.</i> Мектеп жасына дейінгі балалардың цифрлық жазу дағдыларын бақылау мен бағалаудың автоматтандырылған жүйесі	157

## СОДЕРЖАНИЕ

<i>Акылбеков О.Н., Молдагулова А.Н., Закария Г.С., Байдильдинова С.Т., Бекарыстанқызы А.</i> Методы машинного обучения в анализе визуальных данных для 3D-моделирования городской инфраструктуры	5
<i>Ахажанов С.Б., Бибалаев О.Д., Муратхан Р., Михайлов Д.М., Монтаева А.С.</i> Применение технологий искусственного интеллекта для обеспечения безопасности на строительных площадках	18
<i>Берилло Д.А., Икласова К.Е., Семенюк В.В., Ташибаев Р.М.</i> Стратегические направления применения искусственного интеллекта в микробиологическом мониторинге водных объектов: объяснимые модели и мультиомная интеграция	32
<i>Карменова М.А., Төлеуказы З.М., Дуанбаева Т.Б., Тлебалдинова А.С., Кумаргажанова С.К., Omiotek Z.</i> Извлечение текстурных характеристик МРТ-изображений коленного сустава с применением алгоритмов машинного обучения для классификации разрывов мениска	44
<i>Миркасимова Т.Ш., Адилжанова С.А.</i> Оценка рисков информационной безопасности с применением нечеткой FIS-модели	59
<i>Найзабаева А.А., Алимханова А.Ж., Қуанышбекқызы К., Ерсайнова Ж.Е.</i> Развитие системы энергопотребления жилого дома с использованием нейронных сетей	74
<i>Садвакасов Т., Солтан Г., Карибеков Т., Абдрахманова С.</i> Мультимодальная классификация кожных новообразований с использованием глубокого обучения	89
<i>Исмухамедова А.М., Баканова А.П., Бельгинова С.А., Халимов А., Рысбаев Т.</i> Временная стабильность и дрейф распределения в моделях смертности пациентов отделений интенсивной терапии: валидационное исследование на базе MIMIC-IV	103
<i>Попова Г.В., Вайс Ю.А., Котлярова И.А., Жомартқызы Г., Рохас Криулько Н.П.</i> Повышение надежности прогнозирования образовательных траекторий рекомендательной системой, объединяющей академические и мотивационные профили	119
<i>Тоқсеит Д.Қ., Сергазы М.Д.</i> Архитектура и первичная оценка производительности многоагентного инструмента аудита безопасности реализованного на языке Go	132
<i>Увалиева И.М., Рахметуллина Ж.Т., Тезекпаева Ш.Т., Мухамедова Р.О.</i> Математические модели и алгоритмы поддержки клинических решений в гематологии на основе технологии газометрии крови	141
<i>Шапорева А.В., Копнова О.Л., Икласова К.Е., Айтымова А.М.</i> Автоматизированная система мониторинга и оценки навыков цифрового письма у дошкольников	157

## CONTENT

<i>Akyzbekov O.N., Moldagulova A.N., Zakariya G.S., Baidildinova S.T., Bekarystankyzy A.</i> Machine learning methods for 3D reconstruction of urban environments	5
<i>Akhazhanov S., Bibalayev O., Muratkhan R., Mikhailov D., Montaeva A.</i> Application of artificial intelligence technologies for ensuring safety on construction sites	18
<i>Berillo D.A., Iklassova K., Semenyuk V., Tashibayev R.M.</i> Strategic directions for the application of artificial intelligence in microbiological monitoring of water bodies: explainable models and multi-mode integration	32
<i>Karmenova M.A., Toleugazy Z., Duanbaeva T.B., Tlebaldinova A., Kumargazhanova S., Omiotek Z.</i> Extraction of texture features from knee joint MRI images using machine learning algorithms for classification of meniscal tears	44
<i>Mirkassimova T.Sh., Adilzhanova S.A.</i> Information security risk assessment using a fuzzy FIS model	59
<i>Naizabayeva A.A., Alimkhanova A.Zh., Kuanyshbekkyzy K., Ersainova Zh.E.</i> Enhancing residential energy consumption systems using neural networks	74
<i>Sadvakassov T., Soltan G., Karibekov T., Abdrakhmanova S.</i> Multimodal classification of skin neoplasms by using deep learning	89
<i>Ismukhamedova A., Bakanova A., Belginova S., Khalimov A., Rysbayev T.</i> Temporal stability and distribution drift in icu mortality models: MIMIC-IV validation study	103
<i>Popova G., Vais Yu., Kotlyarova I., Zhomartkyzy G., Rokhas Kriulko N.P.</i> Increasing the reliability of predicting educational trajectories by a recommendation system that unites academic and motivational profiles	119
<i>Tokseit D.K., Sergazy M.N.</i> Architecture and initial performance evaluation of a multi-agent security audit tool implemented in the Go language	132
<i>Uvaliyeva I.M., Rakhmetullina Zh.T., Tezekpaeva Sh.T., Mukhamedova R.O.</i> Mathematical models and algorithms for clinical decision support in hematology based on blood gasometry technology	141
<i>Shaporeva A.V., Kopnova O.L., Iklassova K.Ye., Aitymova A.M.</i> Automated system for monitoring and evaluating digital writing skills in preschoolers	157

**EKTU Journal of Information and Communication Sciences**

Ғылыми журнал  
2026 жылдан шыға бастады.  
Қазақстан Республикасы мәдениет және ақпарат министрлігінде тіркеліп,  
2025 ж. 16 қыркүйегінде № KZ93VPY00129402 куәлігі берілген.

**EKTU Journal of Information and Communication Sciences**

Научный журнал  
Издается с 2026 г.  
Зарегистрирован Министерством культуры и информации  
Республики Казахстан. Свидетельство № KZ93VPY00129402 от 16 сентября 2025 г.

**EKTU Journal of Information and Communication Sciences**

Scientific journal  
Published since 2026  
Registered with the Ministry of Culture and Information of the Republic of Kazakhstan. Certificate No.  
KZ93VPY00129402 dated September 16, 2025.

---

Редакторлар – Редакторы  
О.Н. Николаенко, С.С. Мамыраздыкова  
Корректорлар – Корректоры  
О.Н. Николаенко, С.С. Мамыраздыкова  
Руководитель редакционно-издательского центра О.Н. Николаенко  
Editors O. Nikolaenko, S. Mamyrazdykova  
Copy editors O. Nikolaenko, S. Mamyrazdykova  
Head of the editorial and publishing center O. Nikolaenko

---

Материалдарды компьютерде терген және беттеген С.С. Мамыраздыкова  
Набор, верстка, изготовление оригинал-макета С.С. Мамыраздыкова  
Text Layout, lead out production of the original layout S. Mamyrazdykova

---

Басуға 31 наурыз 2026 ж. қол қойылды.  
Форматы 84×108/16. Офсет қағазы.  
Көлемі: шартты баспа табағы 18,06, есептік баспа табағы 18,11.  
Баспа нұсқасы. Таралымы 30 дана. № 55-2026 тапсырыс.  
Бағасы келісім бойынша.

---

Подписано в печать 31 марта 2026 г.  
Формат 84×108/16. Бумага офсетная.  
Объем: усл. печ. л. 18,06, уч.-изд. л. 18,11.  
Печатная версия. Тираж 30 экз. Заказ № 55-2026.  
Цена договорная.

---

Signed to print on March 31, 2026.  
Format 84'108/16. Offset paper.  
Volume: conventional printing plate 18,06, estimated printing plate 18,11.  
Printed version. Circulation 30 copies. Order No.55-2026.  
The price is negotiable.

---

Шығыс Қазақстан техникалық университеті. 070004, Өскемен қаласы, Протозанов көшесі, 69.  
Восточно-Казахстанский технический университет. 070004, г. Усть-Каменогорск, ул. Протозанова, 69.  
D. Serikbayev East Kazakhstan Technical University. 070004, Ust-Kamenogorsk, 69 Protozanov Street.