

**М.К. Койбагаров, Ж.Н. Исабеков, Л.А. Курмангалиева, В.К. Байтурганова,
П.М. Рахметова***

Satbayev University,
050000, Республика Казахстан, г.Алматы, ул. Сатпаева 22
*e-mail: p.rakhmetova@gmail.com

РАЗРАБОТКА СИСТЕМЫ ПРЕДИКТИВНОГО ОБСЛУЖИВАНИЯ НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ

Аннотация: В традиционных промышленных условиях методы технического обслуживания, основанные на реактивном ремонте или плановых временных интервалах, часто приводят к простоям и снижению эффективности. В связи с чем, предиктивное обслуживание использует данные для прогнозирования отказов до их фактического наступления. Целью данного исследования является разработка интеллектуальной системы предиктивного обслуживания на основе машинного обучения и внедрение в промышленность Казахстана, ориентируясь на принципы Индустрии 4.0. Система основана на сборе данных с датчиков (ток, температура, давление, вибрация) с помощью ПЛК Siemens, объединённых через протокол OPC UA в промышленную IoT-инфраструктуру. Дополнительно применяется компьютерное зрение для мониторинга состояния оборудования в реальном времени. Полученные данные обрабатываются алгоритмами машинного обучения, в том числе нейронными сетями, линейной регрессией и автоэнкодерами. Для адаптации модели к изменениям она обучается непрерывно с использованием байесовского обновления. Визуализация и взаимодействие с пользователями реализованы через SCADA для инженеров и Power BI для управленцев. Кроме того, в статье рассматриваются проблемы, связанные с развертыванием решений по предиктивному обслуживанию, и предлагаются будущие направления для улучшения масштабируемости, безопасности и возможностей обработки данных в реальном времени. Полученные результаты вносят вклад в растущий объем исследований в области предиктивного обслуживания, демонстрируя его потенциал для повышения эффективности, снижения эксплуатационных расходов и поддержки перехода к интеллектуальным производственным системам, управляемым данными. Работа демонстрирует потенциал интеллектуального обслуживания как решения для стареющих производств с дефицитом инженерных кадров и шаг к цифровизации в рамках Индустрии 4.0.

Ключевые слова: предиктивное обслуживание, искусственный интеллект, машинное обучение, индустрия 4.0, компьютерное зрение, промышленный IoT, SCADA.

Введение

Стремительное развитие Индустрии 4.0 привело к революции в производстве и промышленной автоматизации благодаря интеграции искусственного интеллекта (ИИ), интернета вещей (IoT) и аналитики данных в режиме реального времени в производственные процессы [1]. Одним из наиболее важных аспектов промышленной деятельности является техническое обслуживание оборудования, поскольку незапланированные простои и отказы систем могут привести к значительным финансовым потерям, снижению производительности и нарушению безопасности.

В среднем затраты на техническое обслуживание составляют 15-60% от общей стоимости производства готовой продукции. В тяжелой промышленности эти затраты могут достигать 50% от общих производственных расходов. Это подчеркивает критическую потребность в обслуживании машин и компонентов, используемых в производственных линиях [2].

Промышленный сектор Казахстана представляет собой уникальный случай для применения предиктивного обслуживания из-за зависимости от стареющей инфраструктуры и нехватки рабочей силы в технических областях. Многие промышленные объекты в Казахстане были созданы в советское время и работают на устаревшем оборудовании, подверженном частым поломкам. Высокие затраты, связанные с незапланированными простоями, в сочетании с ограниченным количеством квалифицированного обслуживающего персонала подчеркивают острую необходимость в решениях по предиктивному обслуживанию. [3]. В исследовании Амангельды и Бисембаева (2024) подчеркивается, что

отсутствие стратегий технического обслуживания привело к критическим отказам, таким как масштабная авария на Экибастузской ТЭС, что подчеркивает важность цифровизации и внедрения PdM [4]. Для изучения промышленного сектора Казахстана посещены 10 предприятий из нефтегазовой отрасли, пищевой промышленности, производства напитков и машиностроения.

Интеграция ИИ в предиктивное обслуживание (PdM) более подробно рассматривается в исследовании [5], в котором особое внимание уделяется прогнозированию времени выхода из строя на основе опыта, физических законов и методов машинного обучения (Machine learning, ML). Такой подход способствует своевременной замене неисправных компонентов, повышая тем самым надежность системы. Интеграция ИИ и аналитики данных в PdM широко изучается. Прогнозирование технического обслуживания на основе ИИ в Индустрии 4.0 предполагает использование аналитики данных, глубокого обучения и киберфизических систем для совершенствования стратегий технического обслуживания. В обзоре [6] подчеркивается, что методы PdM на основе ИИ, включая логистическую регрессию, регрессию опорных векторов и нейронные сети, способствуют долговечности оборудования и повышению эффективности эксплуатации. Аналогичным образом, Гао и др. (2023) предложили систему глубокого обучения на основе AutoML для интеллектуальной диагностики неисправностей, продемонстрировав, что модели на основе CNN повышают точность прогнозирования за счет преобразования данных датчиков в представления, подобные изображениям [6].

Одной из основных проблем в PdM является необходимость непрерывного обучения, так как статичные модели ML часто не могут адаптироваться к изменяющимся промышленным условиям. Хуртадо и др. (2023) обсудили ограничения традиционных моделей ML в работе с нестационарными средами и предложили непрерывное обучение в качестве решения для адаптивных моделей PdM [7].

Методология

Стандартизация процессов проектирования и внедрения интеллектуальной системы предиктивного обслуживания в условиях промышленной автоматизации была разработана детализированная дорожная карта. Она охватывает все ключевые этапы жизненного цикла решения – от начального сбора данных до полной интеграции и промышленной эксплуатации. Каждый этап разработан с учетом принципов цифровой трансформации, поддержки непрерывного обучения моделей и применения протокола OPC UA в качестве единой платформы промышленного обмена данными.

OPC UA (Open Platform Communications Unified Architecture) – это промышленный коммуникационный протокол, обеспечивающий надёжный обмен данными между различными устройствами и системами автоматизации. В отличие от других протоколов, таких как Modbus, PROFIBUS и CANopen, OPC UA характеризуется независимостью от платформы, высоким уровнем безопасности и стандартизированной структурой данных. OPC UA основан на архитектуре «клиент-сервер», поддерживая также подходы «издатель-подписчик» (PubSub), что позволяет использовать его в разных сценариях, включая облачные решения и системы реального времени. Основными преимуществами OPC UA являются встроенная защита данных (аутентификация, шифрование и проверка целостности), гибкость и совместимость с широким спектром оборудования и программных решений от разных производителей.

Ключевым преимуществом системы является механизм непрерывного обучения, основанный на байесовском обновлении вероятностей. При поступлении новых данных модель обновляет апостериорное распределение вероятности отказа: Математически это выражается формулой:

$$P(A|B) = P(B|A) \frac{P(A)}{P(B)}, \quad (1)$$

где:

$P(A|B)$ – апостериорная вероятность, то есть вероятность гипотезы A при условии имеющихся данных B .

$P(B|A)$ – правдоподобие (likelihood) – вероятность наблюдения данных B , если гипотеза A верна.

$P(H)$ – априорная вероятность – первоначальная вероятность гипотезы до получения новых данных (ваши предварительные знания или предположения).

$P(D)$ – вероятность самих данных (обычно вычисляется как нормализация и редко считается отдельно).

Теорема Байеса позволяет оценить вероятность наступления отказа оборудования на основании уже зафиксированных симптомов (аномалий в данных сенсоров), даже если изначально известны только вероятности этих симптомов при наличии и отсутствии отказа.

В данной статье будет использован вариационный автоэнкодер (VAE) с байесовскими методами для прогнозирования поломок промышленного оборудования по сенсорным данным [8]. Нам нужно обучить модель на исторических данных и использовать её для своевременного выявления отклонений и поломок.

Обычные автоэнкодеры эффективно кодируют данные в компактное представление, но у них есть один важный недостаток – они не учитывают неопределённость или вероятностную природу данных. Байесовский подход позволяет учитывать и моделировать неопределённость и случайность в данных, благодаря чему сеть может не только восстанавливать исходные данные, но и генерировать новые, ранее не виденные примеры.

Вариационный автоэнкодер (VAE) создает вероятностную модель, описывающую данные. VAE кодирует данные не в один фиксированный вектор, а в параметры вероятностного распределения (чаще всего – нормального). Это позволяет сети генерировать новые данные, случайным образом выбирая значения из распределения, моделировать неопределённость данных, а также улучшать обобщающие способности модели. VAE состоит из двух частей: энкодер (кодировщик) и декодер (декодировщик)

Энкодер (кодировщик) выражается в виде:

$$q_{\phi}(z|x) \sim N(\mu(x), \sigma^2(x)), \quad (2)$$

где, z – латентный вектор (скрытые переменные), x – исходные данные, $\mu(x)$ и σ^2 – среднее и дисперсия латентного распределения (они зависят от нейронов сети).

Декодер берёт латентный вектор (сжатое скрытое представление данных, созданное энкодером) и восстанавливает из него исходные данные, стремясь получить максимально точную реконструкцию оригинального образца.

$$p_{\theta}(x|z) \quad (3)$$

Для прогнозирования оставшегося срока службы (Remaining Useful Life, RUL) применяется линейная регрессия [9]:

$$RUL = \beta_0 + \sum_{i=1}^n \beta_i x_i, \quad (4)$$

где x_i – значения признаков, β_i – веса регрессионной модели, обученные на исторических данных отказов.

Исторические данные сенсоров пропускаются через предварительно обученный энкодер вариационного автоэнкодера. В результате из исходных данных формируются латентные признаки, которые компактно описывают текущее состояние оборудования. На основе полученных латентных признаков обучается линейная регрессия, цель которой заключается в минимизации ошибки предсказания времени до отказа (RUL). Математическая формула линейной регрессии в данном случае выглядит следующим образом:

$$y = \omega_0 + \omega_1 z_1 + \omega_2 z_2 + \dots + \omega_n z_n, \quad (5)$$

где, y – прогнозируемое оставшееся время до отказа (RUL); $z_1, z_2, \dots, z_n$ – латентные признаки, полученные из энкодера VAE; $\omega_1, \omega_2, \dots, \omega_n$ – коэффициенты линейной регрессии, определяемые в процессе обучения.

Модуль машинного зрения занимает важную роль в обеспечении контроля качества продукции и мониторинга состояния оборудования, позволяя своевременно выявлять дефекты сварных соединений [10], трещины, деформации, загрязнения и нарушения технологических процессов. Согласно данным из источника визуальные системы способны регистрировать не только текущие проблемы, но и прогнозировать негативные тенденции, анализируя изображения совместно с сенсорными данными [11]. В работе предлагается использовать сверточные нейронные сети (CNN), в частности архитектуру YOLO (You Only Look Once), отличающуюся высокой скоростью и точностью распознавания объектов на изображениях в реальном времени [12]. Архитектура первой версии YOLO представлена на рисунке 1.




Рисунок 1 – Архитектура YOLO

Детекторная сеть состоит из 24 свёрточных слоёв и 2 полносвязных слоёв в конце. Чередующиеся свёрточные слои с ядром 1×1 уменьшают размерность пространства признаков, полученных из предыдущих слоев. Свёрточные слои предварительно обучаются на задаче классификации ImageNet с половинным разрешением (224×224 пикселей входного изображения), а затем разрешение увеличивается в два раза для задачи детекции.

Результаты и обсуждение

Сравнительный анализ различных ML-моделей демонстрирует превосходство гибридных подходов, объединяющих обнаружение аномалий (автоэнкодеры, CNN), регрессионные модели (линейная регрессия, байесовский вывод) и методы непрерывного обучения. Модели, использующие байесовский вывод для обновления в реальном времени, демонстрируют улучшенную адаптацию к динамичным промышленным средам, уменьшая ошибки прогнозирования и повышая надежность.

Энкодер вариационного автоэнкодера включает три сверточных слоя с ядрами 3×3 и растущим числом фильтров (16, 32, 64), уменьшающих размерность входных спектрограмм, за которыми следуют полносвязные слои. Декодер VAE, являясь зеркальным отражением энкодера, принимает скрытую переменную z и восстанавливает мел-спектрограмму через серию транспонированных сверточных слоёв. Обученный автокодировщик точно воспроизводит нормальный звук, а при аномалиях (например, дребезг подшипника) – ошибка реконструкции резко возрастает, сигнализируя о неисправности.

Матрица ошибок классификатора состояния оборудования демонстрирует высокую точность идентификации классов «норма» и «неисправность» как показано на рисунке 2. Наиболее эффективно модель распознаёт случаи отсутствия объектов (например, банки) благодаря их чёткой визуальной выраженности. Незначительные ошибки наблюдаются при дифференциации перегрева и вибрационных отклонений из-за их схожих характеристик. Большинство предсказаний сосредоточено на диагонали матрицы, что указывает на высокую корректность классификации. Количество ложных срабатываний минимально, а реальные неисправности практически не остаются нераспознанными. Общая точность классификации превышает 95 %, что подтверждает надёжность системы для применения в условиях промышленной эксплуатации и раннего выявления отказов.




Рисунок 2 – Матрица ошибок нейронной сети YOLO

Рисунок 3 иллюстрирует динамику основных метрик процесса обучения и валидации нейронной сети, предназначенной для контроля качества продукции. Верхний ряд графиков отражает ошибки локализации (train/box_loss), классификации (train/cls_loss) и распределённой локализации (train/dfl_loss) на обучающем наборе данных, а также метрики точности (precision) и полноты (recall). Нижний ряд показывает аналогичные показатели на проверочном наборе, включая усреднённую точность (mAP) при различных порогах наложения объектов (IoU). Постепенное снижение ошибок на обучении и валидации, а также рост mAP, свидетельствуют об успешном прогрессе модели в задаче определения качества продукции.




Рисунок 3 – Метрик процесса обучения нейронной сети для контроля качества

Результаты разработанной системы на основе модели нейронной сети YOLO на тестовом изображении после завершения обучения отражены на рисунке 4.



Рисунок 4 – Результаты работы

Видно, что все присутствующие в кадре банки корректно обнаружены и обозначены цветными рамками с метками класса. Уровень уверенности (confidence) модели для каждого обнаруженного объекта высок (более 0.90), что подтверждает надёжность распознавания. Модель уверенно идентифицирует как правильно размещённые объекты, так и выявляет отсутствие банки там, где она ожидается (в случае имитации пропуска). Таким образом, модуль компьютерного зрения дополняет систему мониторинга, автоматически контролируя состояние поточной линии и наличие объектов (банок) на ней.

Заключение

Данная статья демонстрирует преобразующее воздействие машинного обучения (ML) на основе предиктивного обслуживания (PdM) в промышленной автоматизации. Интеграция ML, IoT и аналитики в реальном времени позволяет предиктивному обслуживанию проактивно выявлять сбои, оптимизировать графики обслуживания и сокращать эксплуатационные расходы.

Практическая значимость заключается в возможности использования предлагаемой системы для снижения эксплуатационных затрат, повышения надёжности оборудования, а также в сокращении трудозатрат инженерного персонала за счёт автоматизации процессов диагностики и планирования технического обслуживания. Теоретическая значимость выражается в обосновании архитектурного подхода к интеграции autoencoder-моделей и OPC UA в производственные системы с возможностью адаптации к стареющему оборудованию и нестабильной среде.

Разработка и реализация систем предиктивного обслуживания на основе машинного обучения станут важным шагом на пути к цифровому возрождению промышленного сектора Казахстана. Это решение позволит не только повысить устойчивость и конкурентоспособность отечественных предприятий, но и заложить прочный фундамент для технологического суверенитета страны. Особенно актуально это для таких ключевых отраслей, как машиностроение, горнодобывающая и пищевая промышленность. Более того, подобные проекты способны вдохновить новое поколение казахстанских инженеров и IT-специалистов, формируя современную культуру высоких технологий и возвращая престиж инженерных профессий. Вклад в развитие интеллектуального и промышленного потенциала Родины – это не только моя профессиональная цель, но и гражданская миссия.

Список литературы

1. The advance of digital twin for predictive maintenance: The role and function of machine learning / Chen et al // Journal of Manufacturing Systems. – 2023. – P. 581-594. <https://doi.org/10.1016/j.jmsy.2023.10.010>.
2. Сансызбаева Г.Н. Problems and prospects of Kazakhstan processing industry / Г.Н. Сансызбаева, А. Кузенбаева // Journal of Economic Research & Business Administration. – 2015. – № 91(3). – P.41-45. Retrieved from <https://be.kaznu.kz/index.php/math/article/view/660>.
3. Amangeldy I.S. Enhancing operational efficiency in industry 4.0: a predictive maintenance approach / I.S. Amangeldy, A.S. Bissembayev // Herald of the Kazakh-British technical university. – 2024. <https://api.semanticscholar.org/CorpusID:270993635>.
4. Kairo J. Machine Learning Algorithms for Predictive Maintenance in Manufacturing / J. Kairo // Journal of Technology and Systems. – 2024. – № 6(4). – P.66-79. <https://doi.org/10.47941/jts.2144>.
5. AI Based PDM in Manufacturing Industry 4.0: A Bibliographic Review / S. Hiranmoy et al // International journal of engineering research & technology. – 2024. – № 13(4). <https://www.ijert.org/ai-based-pdm-in-manufacturing-industry-40-a-bibliographic-review>.
6. MD RAISUL ISLAM and MD ZAKIR HOSSAIN ZAMIL and Eshmam Rayed and Md Mohsin Kabir and M.F. Mridha and SATOSHI NISHIMURA and Jungpil Shin. Deep Learning and Computer Vision Techniques for Enhanced Quality Control in Manufacturing Processes. Journal of IEEE Access. – 2024. – № 12. – P.121449-121479. <https://doi.org/10.1109/ACCESS.2024.3453664>.
7. Nunes P.J. Challenges in predictive maintenance – A review / P. Nunes, J. Santos, E. Rocha // CIRP Journal of Manufacturing Science and Technology. – 2023. – P. 53-67. <https://doi.org/10.1016/j.cirpj.2022.11.004>.
8. Continual learning for predictive maintenance: Overview and challenges / Hurtado et al // Intelligent Systems with Applications. – 2023. <https://doi.org/10.1016/j.iswa.2023.200251>.
9. Pagano D. A predictive maintenance model using long short-term memory neural networks and bayesian inference / D. Pagano // Decision Analytics Journal. – 2023. – № 6. – P. 100174. <https://doi.org/10.1016/j.dajour.2023.100174>.
10. Development of in-pipe defects detection and classification system / P. Rakhmetova et al // Eastern-European Journal of Enterprise Technologies. – 2025. – № 1(9 (133)). – P. 80-89. <https://doi.org/10.15587/1729-4061.2025.323293>.
11. Sioma A. Vision System in Product Quality Control Systems / A. Sioma // Applied Sciences. – 2023. – № 13(2). – P. 751. <https://doi.org/10.3390/app13020751>.
12. Hussain M. Sustainable Machine Vision for Industry 4.0 / M. Hussain // A Comprehensive Review of Convolutional Neural Networks and Hardware Accelerators in Computer Vision. – 2025. – № 3. – P. 1324-1356. <https://doi.org/10.3390/ai5030064>.

Информация о финансировании

Данное исследование финансируется Комитетом науки Министерства науки и высшего образования Республики Казахстан (Грант № AP22685781).

М.К. Койбагаров, Ж.Н. Исабеков, Л.А. Курмангалиева, В.К. Байтурганова, П.М. Рахметова*

Satbayev University,
050000, Қазақстан Республикасы, Алматы қ., Сатпаева 22
*e-mail: p.rakhmetova@gmail.com

МАШИНАЛЫҚ ОҚЫТУ НЕГІЗІНДЕ БОЛЖАМДЫҚ ҚЫЗМЕТ КӨРСЕТУ ЖҮЙЕСІН ӨЗІРЛЕУ

Дәстүрлі өнеркәсіптік қондырғыларда реактивті жөндеуге немесе жоспарланған уақыт аралығына негізделген техникалық қызмет көрсету әдістері жиі тоқтап қалуға және тиімділіктің жоғалуына әкеледі. Сондықтан болжамды техникалық қызмет көрсету сәтсіздіктерді олар пайда болғанға дейін болжау үшін деректерді пайдаланады. Бұл зерттеудің мақсаты Индустрия 4.0 қағидаттарына назар аудара отырып, машиналық оқытуға негізделген интеллектуалды болжамды қызмет көрсету жүйесін әзірлеу және оны Қазақстан өнеркәсібіне енгізу. Жүйе OPC UA хаттамасы арқылы өнеркәсіптік IoT инфрақұрылымына қосылған Siemens PLC арқылы сенсорлардан (ток, температура, қысым, діріл) деректерді жинауға негізделген. Сонымен қатар, компьютерлік көру нақты уақытта жабдықтың күйін бақылау үшін қолданылады. Алынған деректер нейрондық желілерді, сызықтық регрессияны және автокодерлерді қамтитын машиналық оқыту алгоритмдерімен өңделеді. Модельді өзгерістерге бейімдеу үшін ол Bayesian жаңартуы арқылы үздіксіз оқытылады. Пайдаланушылармен визуализация және өзара әрекеттесу инженерлер үшін SCADA және менеджерлер үшін Power BI арқылы жүзеге асырылады. Сонымен қатар, құжат болжамды техникалық қызмет көрсету шешімдерін қолданумен байланысты қиындықтарды талқылайды және ауқымдылықты, қауіпсіздікті және нақты уақыттағы деректерді өңдеу мүмкіндіктерін жақсартудың болашақ бағыттарын ұсынады. Нәтижелер болжамды қызмет көрсету саласындағы зерттеулердің өсуіне ықпал етеді, оның тиімділікті арттыру, операциялық шығындарды азайту және деректерге негізделген, интеллектуалды өндіріс жүйелеріне көшуді қолдау үшін әлеуетін көрсетеді. Жұмыс инженерлік персонал тапшылығы бар өнеркәсіптердің қартаюуы үшін шешім және Индустрия 4.0 шеңберінде цифрландыруға қадам ретінде интеллектуалды техникалық қызмет көрсетудің әлеуетін көрсетеді.

Түйін сөздер: болжамды қызмет көрсету, жасанды интеллект, машиналық оқыту, индустрия 4.0, компьютерлік көру, өнеркәсіптік IoT, SCADA.

M.K. Koibagarov, Zh.N. Issabekov, L.A. Kurmangaliyeva, V.K. Baiturganova, P.M. Rakhmetova*

Satbayev University,
050000, Republic of Kazakhstan, Almaty, Satpayev St. 22
*e-mail: p.rakhmetova@gmail.com

DEVELOPMENT OF A PREDICTIVE MAINTENANCE SYSTEM BASED ON MACHINE LEARNING

In traditional industrial settings, maintenance methods based on reactive repairs or scheduled time intervals often lead to downtime and reduced efficiency. Therefore, predictive maintenance uses data to predict failures before they actually occur. The objective of this study is to develop an intelligent predictive maintenance system based on machine learning and implement it in the industry of Kazakhstan, focusing on the principles of Industry 4.0. The system is based on collecting data from sensors (current, temperature, pressure, vibration) using Siemens PLCs, integrated via the OPC UA protocol into the industrial IoT infrastructure. Additionally, computer vision is used to monitor the equipment condition in real time. The obtained data is processed by machine learning algorithms, including neural networks, linear regression, and autoencoders. To adapt the model to changes, it is trained continuously using Bayesian updating. Visualization and interaction with users are implemented via SCADA for engineers and Power BI for managers. In addition, the paper discusses the challenges associated with the deployment of predictive maintenance solutions and suggests future directions for improving scalability, security, and real-time data processing capabilities. The obtained results contribute to the growing body of research in the field of predictive maintenance, demonstrating its potential to improve efficiency, reduce operating costs, and support the transition to data-driven, intelligent manufacturing systems. The work demonstrates the potential of predictive maintenance as a solution for aging industries with a shortage of engineering personnel and a step towards digitalization within the framework of Industry 4.0.

Key words: predictive maintenance, artificial intelligence, machine learning, Industry 4.0, computer vision, industrial IoT, SCADA.

Сведения об авторах

Мейіржан Қойбағарұлы Қойбағаров – магистрант кафедры Робототехники и технических средств автоматизации, Satbayev University, г. Алматы, Республика Казахстан; e-mail: koibagarov01@gmail.com. ORCID: <https://orcid.org/my-orcid?orcid=0009-0006-1858-7534>.

Жанибек Назарбекулы Исабеков – PhD, ассоциированный профессор, кафедры Робототехники и технических средств автоматизации, Satbayev University, г. Алматы, Республика Казахстан; e-mail: z.issabekov@satbayev.university. ORCID: <https://orcid.org/0000-0003-2900-8025>.

Лаззат Амановна Курманғалиева – кандидат технических наук, ассоциированный профессор кафедры Робототехники и технических средств автоматизации, Satbayev University, г. Алматы, Республика Казахстан; e-mail: lezzet@mail.ru. ORCID: <https://orcid.org/0000-0002-2922-2518>.

Винера Канапиявна Байтурганова – магистр, старший преподаватель кафедры Робототехники и технических средств автоматизации, Satbayev University, г. Алматы, 050000, Республика Казахстан, e-mail: v.baiturganova@satpayev.university ORCID: <https://orcid.org/0009-0007-1717-5041>

Перизат Маратқызы Рахметова* – PhD кандидат, старший преподаватель кафедры Робототехники и технических средств автоматизации, Satbayev University, г. Алматы, Республика Казахстан; e-mail: p.rakhmetova@gmail.com. ORCID: <https://orcid.org/0000-0002-5645-5157>.

Авторлар туралы мәліметтер

Мейіржан Қойбағарұлы Қойбағаров – Робототехниканың және техниканың автоматтық құралдары кафедрасының магистранты, Satbayev University, Алматы қ., Қазақстан Республикасы; e-mail: koybagarov01@gmail.com. ORCID: <https://orcid.org/my-orcid?orcid=0009-0006-1858-7534>.

Жанібек Назарбекұлы Исабеков – PhD, Робототехниканың және техниканың автоматтық құралдары кафедрасының қауымдастырылған профессоры, Satbayev University, Алматы қ., Қазақстан Республикасы; e-mail: z.issabekov@satbayev.university. ORCID: <https://orcid.org/0000-0003-2900-8025>.

Лаззат Амановна Курманғалиева – техника ғылымдарының кандидаты, доцент, Робототехниканың және техниканың автоматтық құралдары кафедрасының қауымдастырылған профессоры, Satbayev University, Алматы қ., Қазақстан Республикасы; e-mail: lezzet@mail.ru. ORCID: <https://orcid.org/0000-0002-2922-2518>.

Винера Канапиявна Байтурганова – магистр, Робототехниканың және техниканың автоматтық құралдары кафедрасының аға оқытушысы, Satbayev University, Алматы қ., Қазақстан Республикасы; e-mail: v.baiturganova@satpayev.university. ORCID: <https://orcid.org/0009-0007-1717-5041>.

Перизат Маратқызы Рахметова* – PhD кандидаты, Робототехниканың және техниканың автоматтық құралдары кафедрасының аға оқытушысы, Satbayev University, Алматы қ., Қазақстан Республикасы; e-mail: p.rakhmetova@gmail.com. ORCID: <https://orcid.org/0000-0002-5645-5157>.

Information about the authors

Meiirzhan Koibagaruly Koibagarov – masters of Department of Robotics and Technical Means of Automation, Satbayev University, Almaty, Republic of Kazakhstan; e-mail: koybagarov01@gmail.com. ORCID: <https://orcid.org/my-orcid?orcid=0009-0006-1858-7534>.

Zhanibek Issabekov – PhD, Associate Professor of the Department of Robotics and Technical Means of Automation, Satbayev University, Almaty, Republic of Kazakhstan; e-mail: z.issabekov@satbayev.university. ORCID: <https://orcid.org/0000-0003-2900-8025>.

Lazzat Kurmangaliyeva – Candidate of Technical Sciences, Associate Professor of the Department of Robotics and Technical Means of Automation, Satbayev University, Almaty, Republic of Kazakhstan, e-mail: lezzet@mail.ru. ORCID: <https://orcid.org/0000-0002-2922-2518>.

Vinera Baiturganova – master, senior lecturer of the Department of Robotics and technical means of automation, Satbayev University, Almaty, Republic of Kazakhstan; e-mail: v.baiturganova@satpayev.university. ORCID: <https://orcid.org/0009-0007-1717-5041>.

Perizat Rakhmetova* – PhD candidate, senior lecturer of the Department of Robotics and technical means of automation, Satbayev University, Almaty, Republic of Kazakhstan; e-mail: p.rakhmetova@gmail.com. ORCID: <https://orcid.org/0000-0002-5645-5157>.

Поступила в редакцию 04.04.2025

Поступила после доработки 25.05.2025

Принята к публикации 26.05.2025

[https://doi.org/10.53360/2788-7995-2025-2\(18\)-15](https://doi.org/10.53360/2788-7995-2025-2(18)-15)

МРНТИ: 28.23.01



**А.М. Сыдыкова*, С.М. Женис, С.К. Кумаргажанова, А.С. Тлебалдинова,
Р.К. Нурсадыкова**

Восточно-Казахстанский технический университет им. Д. Серикбаева,
070004, Республика Казахстан, г. Усть-Каменогорск, ул. Серикбаева, 19
*e-mail: aizhansydyk@gmail.com

АВТОМАТИЧЕСКАЯ КЛАССИФИКАЦИЯ СТАДИЙ ЭМБРИОНАЛЬНОГО РАЗВИТИЯ НА ОСНОВЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Аннотация: В данной статье была предложена структурная схема управления информационными потоками в информационно-аналитической системе поддержки принятия решений (ИСППР) для эмбриологов и врачей репродуктивной медицины на основе искусственного интеллекта (ИИ). Данная система позволит оптимизировать работу врачей репродуктивных центров и повысить эффективность программ с использованием вспомогательных репродуктивных технологий (ВРТ) за счет предоставления рекомендаций по проведению/корректировке протоколов, автоматической классификации эмбрионов по стадиям