

<https://doi.org/10.51301/ce.2024.i1.04>

Study of the effectiveness of using machine learning methods to predict the quality of atmospheric air in cities

D. Mukin, F.N. Abdoldina, A.M. Amreyeva*, R.S. Makambetova

Satbayev University, Almaty, Kazakhstan

*Corresponding author: amreal931al@mail.ru

Abstract. The study examines the use of machine learning methods for air quality monitoring in industrial cities. Modern approaches to data collection, their accuracy, continuity, as well as the strengths and weaknesses of algorithms, are analyzed. A comparison of machine learning methods, their efficiency, and limitations is presented. This work will be valuable for environmental sector specialists, offering recommendations to enhance air quality monitoring.

Keywords: *air pollution, air quality monitoring, PM2.5, pollutant forecasting, XGBoost, Support Vector Regression (SVR), Random Forest, LSTM, environmental sustainability, machine learning algorithms, atmospheric air monitoring, environmental management, integrated information systems, air quality forecasting, sustainable development, data analysis.*

1. Введение

Сегодня проблема загрязнения воздуха является одной из самых острых и значимых для промышленных городов. Высокие уровни выбросов вредных веществ, возникающих в результате деятельности промышленности и транспорта, оказывают значительное негативное воздействие на экологию и здоровье населения.

Одним из показателей высокого роста выброса вредных веществ в атмосферу является рост промышленности, на примере Республики Казахстан, согласно данным Бюро национальной статистики Агентства по стратегическому планированию и реформам Республики Казахстан «основные показатели работы промышленности в Республике Казахстан» в январе 2024 года промышленной продукции было произведено на сумму 3 686.7 млрд. тенге, из них в горнодобывающей отрасли - на 1792.5 млрд. тенге (48.6% от общего объема), в обрабатывающей - на 1546.4 млрд. тенге (41.9%). Для эффективного контроля за качеством воздуха и принятия оперативных мер по уменьшению загрязнения необходимо развивать информационные системы, способные обеспечить надежный мониторинг, прогнозирование и обработку данных.

В связи с необходимостью улучшения сложившейся ситуации государства активно финансируют области, направленные на содействие улучшению экологической ситуации, и активно развивают «зеленую экономику» [2].

Исходя из упомянутых ранее концепций следует, что исследование качества воздуха является одним из приоритетов национального развития. Одной из главных задач, наравне с другими является обеспечение благоприятных условий для формирования устойчивого развития страны, что подразумевает собой также и создание благоприятной для жизни и бизнеса

экологической среды, обеспечение высокого уровня здоровья населения.

Исследование и разработка информационной системы для сбора, анализа и обработки информации о состоянии атмосферы промышленного города имеют огромное значение в современной индустриализированной среде. Такая система позволит не только наблюдать за динамикой уровня загрязнения воздуха, но и прогнозировать его изменения, что позволит принимать своевременные меры для улучшения экологической ситуации.

Полученные в ходе исследования и разработки данной информационной системы данные позволят в будущем провести качественную оценку уровня атмосферного загрязнения, а также установить источники, которые оказывают наиболее негативный эффект и являются основными источниками выбросов вредных веществ в атмосферу промышленных городов. На основе данных, полученных в ходе сбора, прогнозирования и обработки данных мониторинга атмосферного воздуха государство, в лице соответствующих исполнительных и законодательных органов может разработать и реализовать эффективные стратегии, и своевременно предпринять меры, которые будут направлены на снижение уровня загрязнения воздуха. Среди возможных предпринятых в будущем мер можно выделить введение более жестких нормативов выбросов, а также, активное стимулирование использования на производствах, которые являются основными источниками вредных выбросов, современных экологически чистых технологий.

Использование современных технологий, таких как алгоритмы машинного обучения, в разработке информационной системы для мониторинга атмосферного воздуха является наиболее эффективным

подходом. Автоматизация процесса анализа данных с помощью таких алгоритмов позволит выявлять закономерности и тренды загрязнения, что в свою очередь обеспечит более точные прогнозы и возможность быстрого реагирования на изменения среды. Данное исследование в свою очередь может способствовать улучшению экологической обстановки в промышленных городах, снизить экологические риски, и впоследствии дать таким городам потенциал привлечения дополнительных инвестиций, а также, способствовать развитию экотуризма и увеличить привлекательность таких городов для проживания и развития предпринимательства.

Следовательно, исследование разработки информационной системы для мониторинга, прогнозирования и обработки данных о качестве воздуха в промышленном городе является актуальной задачей для обеспечения экологической безопасности и улучшения жизни населения. В статье анализируются подходы и современные технологии для решения этой проблемы, подчеркивая важность мониторинга воздуха в промышленных городах Казахстана как основы для внедрения эффективных экологических мер.

2. Материалы и методы

В условиях современности промышленные города все чаще сталкиваются с проблемой загрязнения воздуха из-за выбросов вредных веществ. Решение данной проблемы требует создания информационной системы, которая будет собирать, анализировать и прогнозировать данные, обеспечивая контроль уровня загрязнения и принятие мер для его снижения.

В области разработки информационных систем для мониторинга атмосферного воздуха уже были проведены исследования, интегрирующие алгоритмы машинного обучения.

А также Мауро Кастелли совместно с другими авторами исследовал применение методов машинного обучения для прогнозирования качества атмосферного воздуха в Калифорнии [3].

Для прогнозирования уровней загрязняющих веществ, твердых частиц и индекса качества воздуха применялся метод регрессии опорных векторов (SVR).

Support Vector Regression (SVR) — это метод машинного обучения, используемый для регрессионного анализа [4]. В отличие от стандартных алгоритмов линейной регрессии, подбирающих линию к данным, SVR определяет гиперплоскость, оптимально подходящую для распределения точек в непрерывном пространстве.

В прогнозировании качества воздуха SVR может использоваться для определения концентрации загрязнителей в определенном месте и времени с применением различных методов обработки данных. Точное прогнозирование стало важной задачей для государственных органов, законодателей и общества в условиях растущей озабоченности загрязнением воздуха и его влиянием на здоровье и экологическую устойчивость.

Тип ядра и гиперпараметры существенно влияют на производительность и эффективность SVR, вместе с тем определение оптимальных значений является ключевым решением для успешного прогнозирования в любой области.

После некоторых тестов различных типов ядра было определено, что радиальная базисная функция (RBF) позволяет делать наиболее точные прогнозы.

Радиальная базисная функция (RBF) является одним из наиболее популярных и полезных типов ядер в машинном обучении, в частности, в методе опорных векторов (SVR) [5].

Ядро RBF работает, отображая данные в пространство более высокой размерности, находя скалярные произведения и квадраты всех признаков в наборе данных, а затем выполняя классификацию с использованием базовой идеи линейного SVM.

Для проекции данных в пространство более высокой размерности ядро RBF использует так называемую радиальную базисную функцию, которая может быть записана следующей формулой:

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right),$$

где:

$\|x - x'\|^2$ - квадрат евклидова расстояния, а σ — свободный параметр для настройки уравнения.

3. Результаты и обсуждение

В результате авторами было установлено, что использование полного набора переменных обеспечивает более высокую точность по сравнению с анализом главных компонентов, достигнув 94.1% прогнозирования загрязнения воздуха в Калифорнии.

В другом исследовании Ма и соавторы использовали почасовые прогнозы PM2.5 из системы WRF-Chem Шанхайской метеослужбы, совместив их с данными наземных измерений и метеоусловий, чтобы создать модель машинного обучения для оценки дневной концентрации PM2.5 в Шанхае [6].

Авторы применяют метод машинного обучения XGBoost для прогнозирования уровней загрязнителей, частиц PM2.5 и индекса качества воздуха (AQI). Задача осложняется динамичностью, временной изменчивостью и пространственной вариабельностью данных о загрязнителях.

XGBoost, что означает «Extreme Gradient Boosting», — это оптимизированная библиотека для градиентного бустинга, предназначенная для эффективного и масштабируемого обучения моделей машинного обучения [7]. Этот метод относится к ансамблевому обучению, объединяя прогнозы нескольких слабых моделей для повышения общей точности.

Ключевая особенность XGBoost — способность эффективно работать с пропущенными значениями, минимизируя предварительную обработку данных, а также встроенная поддержка параллельного обучения, ускоряющая работу с большими наборами данных.

XGBoost базируется на методе градиентного бустинга, который заключается в последовательном обучении моделей, таких как деревья решений, на основе ошибок предыдущих моделей. Это позволяет постепенно повышать точность прогнозов. В задачах прогнозирования качества воздуха XGBoost используется для определения уровней загрязнителей в

конкретных местах и времени, учитывая широкий набор данных. Это особенно актуально в условиях растущей обеспокоенности влиянием загрязнения на здоровье и окружающую среду. Среди доступных подходов XGBoost демонстрирует высокую эффективность, особенно при использовании всех доступных переменных, что превосходит результаты методов с отбором признаков, таких как метод главных компонент.

XGBoost улучшает точность прогнозирования WRF-Chem PM2.5, показывая преимущество при использовании полного набора переменных по сравнению с методом главных компонент. Модель эффективно предсказывает почасовые концентрации загрязнителей, таких как CO, SO₂, NO₂, озон и частицы PM2.5, а также AQI для Шанхая, достигая точности 94.1% при классификации AQI в шесть категорий (по стандартам EPA США) на данных валидации.

Результаты показывают, что XGBoost превосходит WRF-Chem, обеспечивая коэффициенты корреляции на 50–100% выше и снижая стандартное отклонение на 14–24 мкг/м³. Это подтверждает его потенциал для точного ежедневного прогнозирования PM2.5 и улучшения мониторинга качества воздуха в Китае.

Похожее решение представлено Алмасбекулы Батуханом в работе о мониторинге окружающей среды Алматы, где загрязнение воздуха является острой экологической проблемой. Автор отмечает отсутствие системы оперативного контроля и анализа данных в промышленном городе и предлагает создать информационную систему на основе временных рядов модели ARIMA, которая сочетает авторегрессию (AR), интеграцию (I) и скользящее среднее (MA) для прогнозирования и анализа экологических данных.

Модель ARIMA используется для анализа и прогнозирования временных рядов. Авторегрессия (AR) описывает связь текущих значений с предыдущими, скользящее среднее (MA) учитывает ошибки прогнозов, а интеграция (I) определяет разницу между текущими и предыдущими значениями ряда.

Данные о качестве воздуха, включая параметр PM2.5, который существенно влияет на здоровье, были получены с сайта aqicn.org. Автор тщательно подобрал параметры модели для достижения максимальной точности прогнозов. Помимо ARIMA, для задач прогнозирования качества воздуха также широко применяются нейронные сети.

К примеру, Борисов Д.В. и Кузнецова И.Н. для исследования качества прогнозирования уровня загрязнения воздуха на основе химических транспортных моделей в Гидрометцентре России использовали постпроцессинг численных прогнозов концентраций приземного озона [11].

Постпроцессинг в машинном обучении относится к набору техник и методов, применяемых к выходным данным модели машинного обучения, чтобы улучшить или уточнить ее результаты [12]. Это может включать такие шаги, как преобразование данных, калибровка и пороговая обработка. Вот некоторые из общих методов постпроцессинга:

Преобразование данных: Методы масштабирования и нормализации применяются к выходным данным модели для их адаптации к дальнейшему анализу или интерпретации.

Калибровка: Калибровка корректирует выходные данные модели для их соответствия истинным вероятностям целевой переменной.

Пороговая обработка: Пороговая обработка может помочь улучшить производительность классификации, корректируя границы решений.

Постпроцессинг применяется для повышения производительности, интерпретируемости и надежности моделей в реальных приложениях. В задачах численного прогнозирования концентраций озона он улучшает точность и надежность прогнозов.

Для расчета концентраций загрязняющих веществ используются модели CHIMERE и COSMO-ART на основе метеоданных системы COSMO-Ru7 и данных об эмиссиях EMEP и TNO. Авторы рассматривают проблемы качества глобальных кадастров эмиссий и методы их корректировки с учетом региональной специфики загрязнения.

Также разработана методика подготовки данных о выбросах городского автотранспорта для их использования в химических транспортных моделях, что улучшает модельные расчеты концентраций. Исследование предлагает направления развития систем прогнозирования качества воздуха с использованием таких моделей.

Авторы представляют методику подготовки данных о выбросах городского автотранспорта для интеграции в химическую транспортную модель и демонстрируют примеры успешного применения постпроцессинга расчетов концентраций. Также обсуждаются направления развития систем прогнозирования качества воздуха с использованием таких моделей.

Датасет включает ретроспективные почасовые прогнозы модели CHIMERE за 2019–2023 годы. Эксперимент показал, что повышение концентрации озона весной и летом связано с перемешиванием воздушных масс в тропосфере. При корректной настройке параметров искусственные нейронные сети демонстрируют высокую эффективность.

В другой работе Рикардо Наварес и Жозе Л. Азнарте для прогнозирования качества воздуха в районе Мадрида [13] использовали рекуррентные искусственные нейронные сети с кратковременной памятью [14]. В исследовании анализируются концентрации загрязнителей воздуха (CO, NO₂, O₃, PM10, SO₂) и пылицы (Plantago, Poaceae), собранные в разных районах Мадрида. Вместо создания отдельных моделей для каждого загрязнителя и места сравниваются различные конфигурации глубоких нейронных сетей для прогноза качества воздуха на день вперед.

Линейная регрессия показала среднее RMSE 0.107 для CO, тогда как Random Forest снизил ошибку до 0.086. Random Forest — алгоритм машинного обучения, основанный на ансамбле деревьев решений, использующий принцип последовательного обучения для улучшения прогнозов, исправляя ошибки предыдущих моделей.

Random Forest применяется для прогнозирования уровней загрязнителей воздуха в конкретных местах и времени, используя разнообразные методы обработки данных. Точное прогнозирование качества воздуха становится важным в условиях растущей обеспокоенности его влиянием на здоровье и экологическую устойчивость, что делает его приоритетом для государственных структур и общества.

RMSE (Root Mean Square Error) — статистическая метрика для оценки точности модели в машинном обучении [16]. RMSE измеряет среднюю ошибку между прогнозируемыми и фактическими значениями, вычисляя квадратный корень из среднего квадрата их разностей (рисунок 1).




Рисунок 1. Схематическая модель алгоритма Random Forest

Технически, RMSE рассчитывается по следующей формуле:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N \|y(i) - \hat{y}(i)\|^2}{N}}$$

где N — количество точек данных, $y(i)$ — i -е измерение, а $\hat{y}(i)$ — соответствующий ему прогноз.

LSTM (Long Short-Term Memory) — это вид рекуррентной нейронной сети (RNN), созданный для работы с последовательными данными, такими как распознавание речи, перевод и прогнозирование временных рядов.

LSTM использует принцип последовательного обучения, схожий с градиентным бустингом, где ошибки предыдущих моделей корректируются для улучшения прогнозов. В задачах прогнозирования качества воздуха LSTM эффективно предсказывает уровни загрязнителей в определенном месте и времени, применяя различные методы обработки данных. С учетом роста обеспокоенности загрязнением и его влиянием на здоровье и окружающую среду, точное прогнозирование стало ключевым для государственных органов и общества.

Все конфигурации LSTM [17] показали лучшие результаты по сравнению со случайным лесом, за исключением SP-LSTM с RMSE 0.093, где в районе Фаролильо RMSE составил 0.127.

В работе Ибрагима Г. и соавторов анализировались данные о загрязнении воздуха, собранные сетью TAQMN на Тайване (2012–2017) [18]. Основное внимание уделялось PM2.5 как наиболее опасному загрязнителю. Используя данные 76 станций мониторинга, авторы преобразовали почасовые значения в дневные и месячные.

Для анализа применялись методы машинного обучения, включая линейную, лассо- и ридж-регрессии, случайный лес, метод ближайших соседей, многослойный перцептрон, деревья решений и градиентный бустинг.

Авторы также применили статистические расчеты метрик, таких как MAE, MSE, RMSE и R^2 , и использовали методы Фурье и сплайн-многочленов для заполнения пропущенных значений в данных TAQMN.

Исследование показало, что градиентный бустинг превосходит другие модели, демонстрируя высокое соответствие между фактическими и прогнозируемыми значениями PM2.5, что подтверждено коэффициентом детерминации (R^2).

Авторы предложили модель Aggregated LSTM (ALSTM), объединяющую данные от локальных станций мониторинга, станций в промышленных районах и внешних источников загрязнения. Для прогноза на основе внешних факторов они агрегировали три модели LSTM. В качестве обучающих данных использовались 17 атрибутов, собранных Тайваньским агентством по охране окружающей среды с 2012 по 2017 год, а тестирование проводилось на данных 2018 года.

Эксперименты сравнили ALSTM с моделями SVR, GBTR, LSTM и другими, оценивая точность прогноза PM2.5 на 1–8 часов с использованием метрик MAE, RMSE и MAPE. ALSTM показала улучшенные результаты, демонстрируя эффективность комплексного подхода для прогнозирования загрязнения воздуха.

Таким образом, результаты, подкрепленные статистическими данными, показывают, что одна комплексная модель может быть лучшим вариантом, чем несколько отдельных моделей. Комплексные модели являются эффективным инструментом, позволяющим делать полезные прогнозы, которые могут применяться в клинических учреждениях для оптимизации ресурсов при ожидаемом росте числа пациентов из-за ухудшения качества воздуха.

4. Выводы

В представленной статье проведен обзор методов машинного обучения, используемых для прогнозирования и мониторинга качества атмосферного воздуха в промышленных агломерациях. Результаты исследований демонстрируют ключевую роль алгоритмов машинного обучения в повышении точности прогностических моделей и эффективности контроля уровня загрязнений.

Перспективное развитие методов машинного обучения открывает значительные возможности для оптимизации мониторинга атмосферных загрязнений, что может существенно снизить их воздействие на экосистемы и здоровье населения. Применение алгоритмов, таких как Support Vector Regression (SVR), XGBoost, Random Forest и LSTM, обеспечивает более глубокий анализ данных и формирует основу для принятия научно обоснованных мер по минимизации выбросов.

Анализ представленных методов подчеркивает актуальность разработки интегрированных информационных систем, способствующих эффективному мониторингу и прогнозированию качества воздуха. Такие системы не только способствуют сохранению экологического баланса, но и служат важным инструментом для защиты здоровья граждан.

Таким образом, совершенствование методик анализа данных и дальнейшие исследования в этой области являются приоритетными задачами для достижения максимальной эффективности в борьбе с загрязнением атмосферы. Применение машинного обучения

предоставляет научно обоснованные инструменты, которые могут быть использованы для принятия решений и разработки стратегий экологического управления.

References / Литература

- [1] Marun'ko, A.S. (2023). Ispol'zovanie metodov mashinnogo obucheniya pri issledovanii jekologicheskoy determiniro-vannosti social'no znachimyh zabolevanij v g. Moskve. Upravlenie razvitiem krupnomasshtabnyh sistem (MLSD'2023): trudy 16-oj mezhdunarodnoj konferencii. <https://doi.org/10.25728/mlsd.2023.0795>
- [2] Hamrakulov, I.B. (2023). Neobhodimost' i vazhnost' ustojchivogo razvitija zelenoj jekonomiki. *Journal of Innovations in Scientific and Educational Research*, 6(4), 1142-1146.
- [3] Castelli, M. (2020). A Machine Learning Approach to Predict Air Quality in California. *Hindawi*, ID 8049504. <https://doi.org/10.1155/2020/8049504>
- [4] Zhang, F., O'Donnell, L.J. (2020). Support vector regression. *Machine Learning*. Academic Press
- [5] Ding, X. (2021). Random radial basis function kernel-based support vector machine. *Journal of the Franklin Institute*, 358(18), 10121-10140
- [6] Ma, J., Yu, Z., Qu, Y., Xu, J. & Cao, Y. (2020). Application of the XGBoost Machine Learning Method in PM2.5 Prediction: A Case Study of Shanghai. *Aerosol Air Quality Research*, 20(1), 128-138. <https://doi.org/10.4209/aaqr.2019.08.0408>
- [7] Li, J. (2022). Application of XGBoost algorithm in the optimization of pollutant concentration. *Atmospheric Research*, (276), 106238
- [8] Almasbekuly, B. (2023). Razrabotka informacionnoj si-stemy monitoringa okruzhajushhej sredy na primere g. Al-maty, Kazakhstan (master dissertation). Tomsk: Nacional'nyj issledovatel'skij Tomskij politehnicheskij universitet. Retrieved from: <http://earchive.tpu.ru/handle/11683/76302>
- [9] Box, G.E.P., Jenkins, G. (1970). Time Series Analysis, Forecasting and Control. *San Francisco: Holden-Day*
- [10] AQICN. Air Quality Monitoring Data. Retrieved from: <https://aqicn.org/city/beijing/>
- [11] Borisov, D.V., Kuznecova, I.N. (2023). Postprocessing chislen-nyh prognozov koncentracij prizemnogozona s is-pol'zovaniem mashinnogo obucheniya. *Gidrometeorologicheskie issledovaniya i prognozy*, 4(390), 86-104
- [12] Sharma, S., Ghimire, G.R., Siddique, R. (2023). Machine learning for postprocessing ensemble streamflow forecasts. *Journal of Hydroinformatics*, 25(1), 126-139
- [13] Navares, R., Aznarte, J.L. (2020). Predicting air quality with deep learning LSTM: Towards comprehensive models. *Ecological Informatics*. <https://doi.org/10.1016/j.ecoinf.2019.1010>
- [14] Bas, E., Egrioglu, E., Kolemen, E. (2022). Training simple recurrent deep artificial neural network for forecasting using particle swarm optimization. *Granular Computing*, 7(2), 411-420
- [15] Genuer, R. (2020). Random forests. *Springer International Publishing*, 33-55
- [16] Hodson, T.O. (2022). Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development Discussions*, (2022), 1-10
- [17] DiPietro, R., Hager, G.D. (2020). Deep learning: RNNs and LSTM. *Handbook of Medical Image Computing and Computer Assisted Intervention*. Academic Press, 503-519
- [18] Harishkumar, K.S. (2020). Forecasting air pollution particulate matter (PM2.5) using machine learning regression models. *Procedia Computer Science*, (171), 2057-2066

Қалалардың атмосфералық ауа сапасын болжау үшін машиналық оқыту әдістерін қолдану тиімділігін зерттеу

Д. Мукин, Ф.Н. Абдолдина, А.М. Амреева*, Р.С. Макамбетова

Satbayev University, Алматы, Қазақстан

*Корреспонденция үшін автор: amreal931al@mail.ru

Аңдатпа. Зерттеуде өнеркәсіптік қалалардағы ауа сапасын бақылау үшін машиналық оқыту әдістерін қолдану мәселесі қарастырылады. Деректерді жинаудың заманауи тәсілдері, олардың дәлдігі мен үздіксіздігі, сондай-ақ алгоритмдердің күшті және әлсіз жақтары талданады. Машиналық оқыту әдістерінің тиімділігі мен шектеулерін салыстыру ұсынылған. Бұл жұмыс атмосфералық ауаны бақылауды жақсарту бойынша ұсыныстар бере отырып, экологиялық сала мамандарына пайдалы болады.

Негізгі сөздер: ауа ластануы, ауа сапасын мониторингілеу, PM2.5, ластаушы заттарды болжау, XGBoost, Support Vector Regression (SVR), Random Forest, LSTM, экологиялық тұрақтылық, машиналық оқыту алгоритмдері, атмосфералық ауаны бақылау, экологиялық басқару, интеграцияланған ақпараттық жүйелер, ауа сапасын болжау, тұрақты даму, деректерді талдау.

Исследование эффективности использования методов машинного обучения для прогноза качества атмосферного воздуха городов

Д. Мукин, Ф.Н. Абдолдина, А.М. Амреева*, Р.С. Макамбетова

Satbayev University, Алматы, Казахстан

*Автор для корреспонденции: amreal931al@mail.ru

Аннотация. Исследование рассматривает использование методов машинного обучения для мониторинга качества воздуха в промышленных городах. Анализируются современные подходы к сбору данных, их точности и непрерывности, а также сильные и слабые стороны алгоритмов. Представлено сравнение методов машинного обучения, их эффективность и ограничения. Работа будет полезна специалистам экологического сектора, предлагая рекомендации для улучшения мониторинга атмосферного воздуха.

Ключевые слова: загрязнение воздуха, мониторинг качества воздуха, PM2.5, прогнозирование загрязнителей, XGBoost, Support Vector Regression (SVR), Random Forest, LSTM, экологическая устойчивость, алгоритмы машинного обучения, мониторинг атмосферного воздуха, экологическое управление, интегрированные информационные системы, прогнозирование качества воздуха, устойчивое развитие, анализ данных.

Received: 22 November 2023

Accepted: 16 March 2024

Available online: 31 March 2024