

Металлургия чёрных, цветных и редких металлов Metallurgy of ferrous, non-ferrous and rare metals

Научная статья
УДК 62-529
DOI: 10.14529/met250201

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В МЕТАЛЛУРГИИ: ПОВЫШЕНИЕ ЭФФЕКТИВНОСТИ ВЕЛЬЦ-ПЕЧИ

Е.В. Бунова, bunovaev@susu.ru

А.А. Цедов

Южно-Уральский государственный университет, Челябинск, Россия

Аннотация. В статье рассматривается применение нейросетевых методов и алгоритмов машинного обучения для оптимизации работы вельц-печи на металлургическом предприятии. На основе реальных производственных данных проведено сравнение эффективности различных алгоритмов (LGBM Regression, CatBoost, Decision Tree, Random Forest и др.) для прогнозирования содержания цинка в клинкере. Лучшие результаты показали LightAutoML ($R^2 = 0,9339$), CatBoost ($R^2 = 0,9218$) и LGBM Regression ($R^2 = 0,9195$). Определены ключевые параметры, влияющие на процесс: содержание цинка в шихте, расход сжатого воздуха, давление в пылевой камере и загрузка коксика. Разработаны рекомендации по управлению процессом, включая контроль качества сырья, оптимизацию газодинамических параметров и мониторинг восстановительных условий. Результаты исследования демонстрируют потенциал ИИ-решений для повышения эффективности металлургических производств в условиях цифровой трансформации промышленности.

Ключевые слова: искусственный интеллект (ИИ), машинное обучение, металлургия, вельц-печь, оптимизация производства, нейросетевые алгоритмы, LightAutoML, CatBoost, LGBM Regression

Для цитирования: Бунова Е.В., Цедов А.А. Применение искусственного интеллекта в металлургии: повышение эффективности вельц-печи // Вестник ЮУрГУ. Серия «Металлургия». 2025. Т. 25, № 2. С. 5–17. DOI: 10.14529/met250201

Original article
DOI: 10.14529/met250201

APPLICATION OF ARTIFICIAL INTELLIGENCE IN METALLURGY: INCREASING THE EFFICIENCY OF THE WALZ KILN

E.V. Bunova, bunovaev@susu.ru

A.A. Tsedov

South Ural State University, Chelyabinsk, Russia

Abstract. The article discusses the application of neural network methods and machine learning algorithms to optimize the operation of the Waelz kiln at a metallurgical plant. Based on real production data, a comparison of the efficiency of various algorithms (LGBM Regression, CatBoost, Decision Tree, Random Forest, etc.) for predicting the zinc content in clinker was carried out. The best results were shown by LightAutoML ($R^2 = 0.9339$), CatBoost ($R^2 = 0.9218$) and LGBM Regression ($R^2 = 0.9195$). The key parameters influencing the process were determined: zinc content in the charge, compressed air consumption, dust chamber pressure and coke loading. Recommendations for process control were developed, including raw material quality control, optimization of gas-dynamic parameters and monitoring of reducing conditions. The results of the study demonstrate the potential of AI solutions for improving the efficiency of metallurgical production in the context of digital transformation of industry.

Keywords: artificial intelligence (AI), machine learning, metallurgy, Waelz kiln, production optimization, neural network algorithms, LightAutoML, CatBoost, LGBM Regression

For citation: Bunova E.V., Tsedov A.A. Application of artificial intelligence in metallurgy: increasing the efficiency of the waltz kiln. *Bulletin of the South Ural State University. Ser. Metallurgy*. 2025;25(2):5–17. (In Russ.) DOI: 10.14529/met250201

© Бунова Е.В., Цедов А.А., 2025

Введение

В настоящее время на российских предприятиях имеется достаточно примеров успешного внедрения нейросетевых алгоритмов в различные процессы предприятий, и с каждым годом таких проектов становится только больше. Во многом это связано с активной поддержкой со стороны государства и реализацией различных программ и инициатив, направленных на развитие искусственного интеллекта в России [1].

В России существуют несколько ключевых государственных программ и инициатив, направленных на поддержку и развитие технологий искусственного интеллекта. Вот некоторые из наиболее значимых:

1. Программа «Цифровая экономика Российской Федерации» [2] – это одна из главных стратегических программ, утвержденная Правительством РФ в 2017 году. Она включает пять направлений, одно из которых посвящено развитию искусственного интеллекта и машинного обучения. Программа предусматривает создание инфраструктуры для хранения и обработки больших данных, поддержку научных исследований и разработку новых технологий на основе ИИ.

2. Национальная стратегия развития искусственного интеллекта до 2030 года [3] – утверждена Президентом РФ в октябре 2019 года. Стратегия направлена на обеспечение лидерства России в сфере искусственного интеллекта путем создания условий для ускоренного развития соответствующих технологий. Включает меры по поддержке образования, научных исследований, а также нормативной базы для регулирования ИИ.

3. Федеральный проект «Искусственный интеллект» [4] – входит в состав национальной программы «Цифровая экономика». Проект направлен на повышение доступности ИИ-решений для бизнеса и государственного управления, создание условий для подготовки кадров в этой области, а также на поддержку стартапов и малых инновационных компаний, работающих над проектами в сфере ИИ.

Программа «Цифровая экономика Российской Федерации» также предполагает стимулирование внедрения AI-технологий в различных отраслях экономики. Эта тенденция также обусловлена рядом факторов, включая растущую доступность вычислительных ресурсов, развитие методов и инструментов обработки больших данных. Как следствие, в работе [4]

приводятся данные от российского патентного ведомства, свидетельствующие о росте числа патентных заявок, связанных с искусственным интеллектом, на 25 % в 2023 году по сравнению с предыдущим периодом, причем общее количество таких заявок с 2017 года увеличилось в 8 раз. Это позволяет предприятиям более продуктивно разрабатывать и применять нейросетевые решения, адаптированные под их индивидуальные требования.

Предприятия, эффективно интегрирующие нейросети в свои бизнес-процессы, достигают значительных экономических преимуществ, включая снижение затрат, повышение производительности, улучшение качества продукции и укрепление своих конкурентных позиций на рынке. Например, в исследовании [5] отмечается, что российские промышленные компании, переходящие на цифровые технологии, уже видят позитивные изменения. Общий экономический эффект от использования искусственного интеллекта составил 26 миллиардов рублей в 2021 году. Использование ИИ признано ключевым фактором повышения конкурентоспособности и обеспечения цифрового суверенитета в промышленности [6]. Предприятия различных отраслей внедряют технологии ИИ, что влияет на оптимизацию бизнес-процессов и их прибыльность [7]. Финансовая нестабильность, ограничения и трудности, с которыми сталкиваются российские предприятия, усиливают потребность в цифровизации и автоматизации, включая использование ИИ [8].

Для преодоления этих проблем рекомендации включают улучшение ИТ-инфраструктуры, обучение специалистов и увеличение государственной поддержки [8]. Несмотря на препятствия, ИИ считается жизненно важным инструментом стратегического экономического развития России, и ожидается, что его внедрение ускорится во всех отраслях [9]. Это стимулирует другие компании к активному внедрению AI-технологий.

В качестве примера можно привести следующие предприятия:

– Кольская ГМК «Норникель» использует цифровой двойник промплощадки. В работе [10] отмечается, что цифровой двойник – «это будущее оперативное управление предприятием в части ремонтов, производства, охраны труда, мониторинга воздуха и не только»;

– ПАО «Газпром нефть» внедрило цифровой двойник Восточного участка Оренбург-

ского месторождения [11]. Эта концепция цифрового двойника позволяет предприятиям быстро обнаруживать и устранять отклонения в производственных процессах, прогнозировать их результаты и обеспечивать наивысшее качество работы. В Центр управления добычей поступают данные о параметрах нефтегазодобывающего и вспомогательного оборудования, трубопроводов и других объектов промышленности. На основе анализа этих данных система выбирает оптимальные режимы загрузки оборудования, учитывая заданные сценарии и множество других факторов;

– АО «АвиаСтар-СП» внедрило систему сбора производственных данных и мониторинг промышленного оборудования для принятия управленческих решений;

– ПАО «НЛМК» применяет сервис на базе машинного обучения, который выдает рекомендации по оптимальному распределению энергоресурсов (природного, доменного и коксового газов) для оборудования собственной электростанции НЛМК [12]. Сервис позволяет компании экономить несколько миллионов рублей ежемесячно.

Несмотря на наличие большого количества успешных примеров внедрения ИИ в промышленность, согласно данным работ [5, 13], в России к 2022 году только 16 % предприятий в обрабатывающей промышленности применяли технологии искусственного интеллекта, что более чем в три раза меньше среднего мирового уровня.

Такой низкий уровень внедрения ИИ в российских компаниях объясняется рядом факторов. Во-первых, разработка и внедрение технологий искусственного интеллекта требует значительных финансовых вложений, что особенно сложно для средних и малых предприятий с ограниченными бюджетами на инновации. Так, в работе [14] указано, что стоимость разработки софта и IT-систем на базе искусственного интеллекта (ИИ) за год (2023) увеличилась в России на 30–40 %, а к концу 2023 года может возрасти еще на 50 %, утверждают разработчики таких систем. Во-вторых, большинство производственных процессов нуждаются в индивидуальной настройке решений, что затрудняет применение стандартных продуктов и повышает расходы на адаптацию. Даже при наличии успешных кейсов по использованию нейросетей универсальных решений для большинства задач не существует и каждый проект разрабатывается отдельно с учетом особенно-

стей конкретного предприятия и требований безопасности. Кроме того, сохраняется дефицит специалистов, обладающих необходимыми компетенциями для успешного внедрения и поддержки таких систем. Важно отметить, что внимание разработчиков смещено в сторону других областей, таких как редактирование текстов (13 494 патентов), биология (5436 патентов) и управление документооборотом (4976 патентов), в то время как сфера промышленности, производства, транспорта и бизнес-решений представлена лишь 2000 патентами [5]. Это подчеркивает недостаточную направленность усилий на потребности промышленного комплекса и технологический прорыв в этой области.

Для преодоления вызовов, связанных с внедрением ИИ в промышленность, необходимо разрабатывать и адаптировать методы оптимизации, эффективно обрабатывающие уникальные данные, характерные для каждой организации. Это подчеркивает ключевую роль адаптации и развития этих методов.

Целью исследования является улучшение процесса вельцевания в вельц-печи за счет разработки и внедрения метода оптимизации, направленного на повышение ее производительности.

Наличие большого количества данных позволяет комплексно анализировать весь производственный цикл с помощью ИИ. Технологии ИИ обрабатывают и систематизируют информацию, после чего формируют рекомендации, на основании которых менеджеры могут принимать взвешенные обоснованные решения в быстро меняющейся обстановке и в ситуациях неопределенности на производстве. На основании сформированной аналитики ИИ может предложить идеи по улучшению процессов производства

Нейросетевые методы и алгоритмы машинного обучения активно применяются в металлургической отрасли для оптимизации производственных процессов, анализа и прогнозирования данных, которая способствует повышению качества продукции, снижению затрат и минимизации рисков. Эти технологии позволяют анализировать большие объемы данных, выявлять сложные зависимости и прогнозировать результаты, что особенно важно в условиях сложных и многофакторных производственных процессов.

Основными направлениями применения нейросетевых методов и алгоритмов машин-

ного обучения в металлургической отрасли являются:

1. Прогнозирование качества продукции.

В металлургии качество конечного продукта зависит от множества факторов: состава сырья, параметров технологического процесса, температуры, давления и других. Нейронные сети, такие как многослойные перцептроны (MLP), рекуррентные нейронные сети (RNN) или сверточные нейронные сети (CNN), могут быть обучены на исторических данных для прогнозирования свойств металлов (например, прочности, твердости, коррозионной стойкости). Это позволяет оптимизировать процесс производства и минимизировать брак.

2. Оптимизация технологических процессов.

Машинное обучение используется для оптимизации параметров плавки, прокатки, литья и других процессов. Например, алгоритмы на основе градиентного бустинга (XGBoost, LightGBM) или глубокого обучения (Deep Learning) могут анализировать данные с датчиков и предлагать оптимальные настройки оборудования. Это помогает снизить энергопотребление, уменьшить износ оборудования и повысить производительность.

3. Прогнозирование отказов оборудования (Predictive Maintenance).

В металлургической отрасли оборудование часто работает в экстремальных условиях, что приводит к его износу. Нейросетевые методы, такие как долгосрочные краткосрочные сети (LSTM), используются для анализа временных рядов данных с датчиков и прогнозирования возможных отказов. Это позволяет своевременно проводить техническое обслуживание и избежать простоев.

4. Оптимизация состава сплавов.

В отрасли цветных металлов важно создавать сплавы с заданными свойствами. Машинное обучение помогает моделировать зависимости между составом сплава и его характеристиками. Например, методы регрессии, случайные леса (Random Forest) или нейронные сети могут использоваться для поиска оптимального соотношения компонентов сплава, что сокращает количество экспериментов и ускоряет разработку новых материалов.

5. Контроль качества в реальном времени.

Нейросетевые методы, такие как сверточные нейронные сети (CNN), применяются для анализа изображений и видео с производст-

венных линий. Это позволяет автоматически выявлять дефекты на поверхности металлов (трещины, пузыри, неровности) и принимать оперативные меры для их устранения.

В настоящее время большое количество трудов российских и зарубежных авторов посвящено использованию нейросетевых методов и алгоритмов машинного обучения, применяемых в программных продуктах для анализа и прогнозирования производственных процессов. Результаты исследования литературных источников показали, что на данный момент наиболее часто используемыми являются следующие методы:

1. **LGBM Regression** – это высокопроизводительный фреймворк для градиентного бустинга, разработанный Microsoft, который использует древовидные алгоритмы обучения. Он предназначен для решения задач классификации и регрессии, обеспечивая высокую производительность, масштабируемость и точность.

Исследования демонстрируют эффективность LGBM Regression в различных областях. В работе [15] при прогнозировании адсорбции свинца в сточных водах, LGBM Regression показала $R^2 = 0,975$, уступив лишь модели Extreme Gradient Boosting (XGB).

Аналогично, в исследовании [16], посвященном оценке и прогнозированию выбросов CO₂ от транспортных средств, алгоритмы ансамблевого обучения, включая LGBM, XGB и Random Forest, показали наилучшие результаты. Несмотря на то, что сложные модели глубокого обучения, такие как сверточные нейронные сети (CNN), глубокие нейронные сети (DNN) и рекуррентные блоки с гейтом (GRU), продемонстрировали высокие значения R^2 , их использование сопряжено со значительными затратами времени на обучение и повышенными требованиями к вычислительным ресурсам. Это подчеркивает практическую ценность и эффективность LGBM Regression для решения широкого круга задач.

2. **CatBoostRegressor** – это относительно новый алгоритм машинного обучения с открытым исходным кодом, разработанный в 2017 году компанией Яндекс. Он объединяет возможности глубокого обучения и градиентного бустинга, а также позволяет комбинировать различные модели для повышения точности.

Этот алгоритм успешно применяется в различных задачах прогнозирования. Напри-

мер, в исследовании [17], посвященном прогнозированию кризиса теплоотдачи, рассмотрены двенадцать классических моделей регрессии, реализованных в библиотеках Scikit-learn, LightGBM, XGBoost, CatBoost, а также нейросетевые методы. CatBoostRegressor показал наилучшие результаты среди множества других моделей, достигнув высокого значения коэффициента детерминации ($R^2 = 0,97$).

В другом исследовании [18], где целью было прогнозирование потребления электроэнергии на промышленном предприятии, были проведены исследования следующих алгоритмов машинного обучения: модели линейной регрессии (LinearRegression, Lasso, Ridge), k-ближайших соседей (KNeighborsRegressor), дерева решений (DecisionTreeRegressor), случайного леса (RandomForestRegressor), линейной регрессии опорных векторов (LinearSVR), многослойного перцептрона (MLPRegressor), экстремального градиентного бустинга (XGBoost) и градиентного бустинга, основанного на деревьях решений, (CatBoost). Модель, основанная на алгоритме CatBoost, обеспечила лучшую точность прогноза, превышающую 92 %. Это позволило сделать вывод о достоверности и адекватности полученной модели для практического применения.

3. **Decision Tree Regressor** – это метод регрессии, который использует дерево решений для предсказания непрерывных значений. Он строит модель в виде дерева, где каждая ветвь представляет собой решение, основанное на значениях входных признаков. Основная идея деревьев решений была разработана Бреттом Л.Б. Фридманом, Джереми Б.С.Л. Хантером и другими. Однако концепция деревьев решений как подхода к классификации и регрессии развивалась на протяжении многих лет с участием различных исследователей.

В контексте использования солнечных панелей, как показано в работе [19], важным является мониторинг температуры и обеспечение надлежащего охлаждения для достижения оптимальных электрических характеристик. Сравнительный анализ нескольких алгоритмов машинного обучения, включая линейную регрессию, Decision Tree Regressor и Random Forest Regressor, выявил, что Decision Tree Regressor с оптимальной настройкой гиперпараметров обеспечивает наилучшую точность – 99,83 %. Это позволяет использовать обученный алгоритм на основе Decision Tree Regressor в системах мониторинга состояния

конструкций в реальном времени для прогнозирования общей стабильности системы.

4. **Random Forest Regressor** – это алгоритм машинного обучения, основанный на методе ансамблевого обучения, который использует множество деревьев решений для улучшения точности предсказаний и уменьшения переобучения. Он работает путем создания множества деревьев на случайных подмножествах данных и усреднения их предсказаний. Random Forest стал популярным благодаря своей эффективности и простоте в применении.

В современном производстве [20] моделирование процессов обработки с использованием машинного обучения для понимания механизма удаления материала и изучения влияния входных параметров на отклики стало необходимым для оптимизации затрат и эффективного использования ресурсов. В этой статье регрессор Random Forest применяется для эффективного прогнозирования значений отклика указанного процесса для заданных наборов входных параметров. Отмечено, что Random Forest Regressor может быть использован в качестве эффективного инструмента прогнозирования с минимальным выбором признаков для любого из процессов обработки.

В работе [21] рассмотрено использование метода при оптимизации производства биогаза. Результаты, полученные с помощью модели Random Forest Regressor, продемонстрировали особенно высокую точность в прогнозировании оптимальных решений. В исследовании, представленном в работе [22], проведен сравнительный анализ трех моделей машинного обучения (Random Forest, Gradient Boost Regressor, AdaBoost Regressor) при прогнозировании прочности бетона на сжатие. Random Forest продемонстрировал наивысшую точность ($R^2 = 0,9636$).

5. **KNeighbors Regressor** – это алгоритм машинного обучения, основанный на методе k-ближайших соседей (k-NN), который используется для регрессии. Он предсказывает значение целевой переменной для нового объекта, основываясь на значениях целевой переменной его k-ближайших соседей в обучающем наборе данных. KNeighbors Regressor получил широкое распространение в различных задачах классификации и регрессии.

Однако, как показывает работа [23], при регрессионном анализе в задаче прогнозирования канцерогенности коэффициент детер-

минации (R^2) для KNeighbors Regressor оказался ниже, чем у других моделей, таких как Random Forest и Gradient Boosting. Это указывает на то, что в данной конкретной задаче KNeighbors Regressor уступает другим алгоритмам машинного обучения по точности предсказаний.

6. **SVR (Support Vector Regression)** – это метод регрессии, основанный на алгоритме опорных векторов (SVM). Он используется для предсказания непрерывных значений и работает, пытаясь найти гиперплоскость, которая минимизирует ошибку предсказания, сохраняя при этом максимальный зазор (margin) между предсказанными значениями и фактическими. Авторы работы [24] предложили математическую модель, описывающую зависимость выходной мощности клистрона от его ключевых параметров. Отличительной особенностью модели является использование метода опорных векторов, который позволил достичь наилучших результатов по сравнению с другими подходами.

7. **Gradient Boosting Regressor (GBR)** – это метод машинного обучения, использующий ансамбль алгоритмов для создания модели регрессии. Он работает путем последовательного добавления слабых моделей, обычно решающих деревьев, для улучшения предсказаний. Каждое новое дерево обучается на остатках (ошибках) предыдущих деревьев, что позволяет постепенно уменьшать ошибку модели.

Основной принцип GBR состоит в постепенном улучшении моделей путем добавления новых деревьев решений, каждое из которых пытается уменьшить ошибку предыдущей модели. Этот процесс аналогичен градиентному спуску, где на каждом этапе минимизируется функция потерь. В контексте производственных процессов это означает, что каждая новая итерация добавляет новые аспекты данных, позволяя постепенно улучшать прогнозы или выявлять скрытые закономерности. В работе [25] представлены результаты разработки прогностических моделей для прогнозирования электропотребления в регионе с крупным минерально-сырьевым комплексом. Модели, основанные на исторических данных и использующие алгоритмы градиентного бустинга и нейронных сетей, обеспечивают краткосрочные прогнозы с погрешностью менее 1 %.

8. **LightAutoML** – это подход к автоматическому машинному обучению (AutoML),

разработанный командой исследователей из Сбербанка в 2019 году.

Основной целью LightAutoML является автоматизация процессов выбора и настройки моделей машинного обучения для решения различных задач, объединяющая в себе современные подходы к обработке данных, оптимизации моделей и интеграции с промышленными системами. Это делает LightAutoML мощным инструментом для повышения эффективности производственных процессов.

LightAutoML активно использует методы ансамблевого обучения, такие как бэггинг и бустинг, позволяя комбинировать результаты нескольких слабых моделей для повышения точности итогового предсказания, что особенно важно в условиях неопределенности и разнообразия данных, характерных для производственных процессов. В статье [26] представлено исследование воздействия светофорных объектов на регистрацию параметров транспортных потоков детекторами транспорта, где показано решение задачи робастного прогноза интенсивности движения с использованием LightGBM и библиотеки LightAutoML для автоматической подготовки данных, настройки и оптимизации модели. Результаты демонстрируют, что модель достаточно хорошо справляется с прогнозом интенсивности движения, различая особенности суточных профилей для рабочих и выходных дней.

В работе [27] освещен подход к прогнозированию генерации тепловой электрической станции с использованием методов машинного обучения. В ходе работы проведена генерация и отбор признаков на основе электрических величин, данных о времени и погодных условиях, а также построены трехуровневые ансамбли моделей на основе линейной регрессии и градиентного бустинга над решающими деревьями с использованием фреймворка LightAutoML для быстрого прототипирования. Полученные метрики качества (коэффициент детерминации на валидационной выборке составил 0,72) позволяют судить о принципиальной возможности использования рассмотренного метода для решения как данной, так и смежных задач, связанных с прогнозированием временных рядов.

Таким образом, ключевые преимущества нейросетевых методов обусловлены их способностью учитывать сложные нелинейные зависимости, что приводит к высокой точности. Адаптивность моделей, позволяющая им

обучаться по мере поступления новых данных, способствует постоянному совершенствованию. Экономия ресурсов является следствием снижения затрат на энергию, сырье и обслуживание оборудования. Автоматизация анализа и принятия решений приводит к значительному ускорению процессов. Однако одним из ключевых факторов, определяющих возможность реализации высокой точности нейросетевых методов, является наличие достаточного количества репрезентативных и качественных данных для обучения моделей.

Методика анализа и выбора методов для использования при разработке метода оптимизации, направленного на повышение ее производительности и улучшение процесса работы вельц-печи

Этап 1. Сбор и предварительная подготовка набора данных

Данные для оптимизации процесса работы вельц-печи предоставило предприятие, относящееся к металлургической отрасли. Предприятие специализируется на производстве цинка и его сплавов, а также других цветных металлов. Это одно из крупнейших

предприятий в России, занимающихся выплавкой цинка из полиметаллических руд.

Данные поступили с информационной системы предприятия, отражающей технологический процесс работы вельц-печи, а также от цинкового анализатора за период с 2021 по 2024 г.

В результате получения данных для исследования из разных источников была сформирована схема данных, которая представлена на рис. 1.

Этап 2. Предобработка данных

Для обеспечения надежного и точного анализа данные подвергаются тщательной предобработке, включающей несколько ключевых шагов. Во-первых, проводится очистка данных, подразумевающая обработку пропущенных значений и выявление с последующим устранением аномальных выбросов. Во-вторых, осуществляется нормализация данных, а также проверка соответствия данных заданным правилам и ограничениям, а также исправление ошибок ввода и устранение несогласованностей.

В рамках данной задачи учитываются следующие параметры: текущая масса загрузки шихты, текущая масса загрузки коксика, рас-

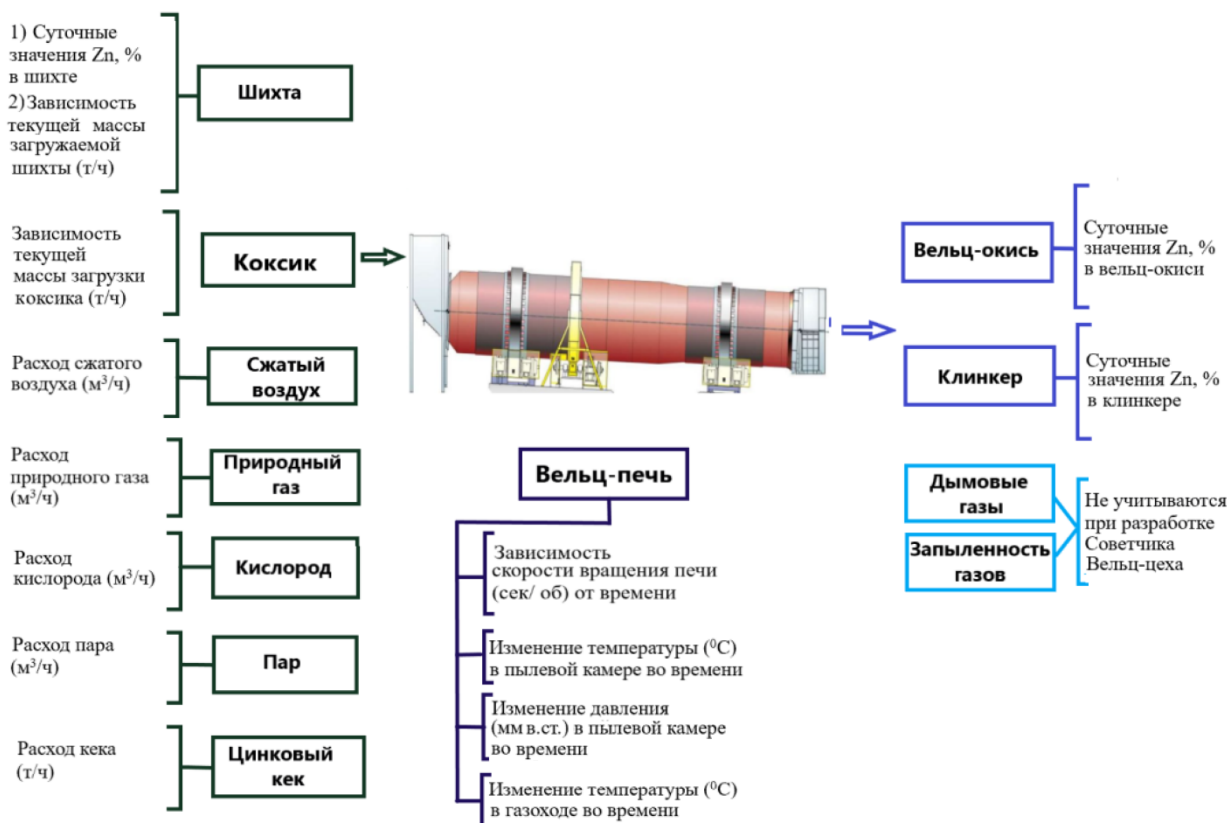


Рис. 1. Входные и выходные параметры работы вельц-печи
Fig. 1. Input and output parameters of the Waelz kiln

ход природного газа, расход сжатого воздуха, изменение температуры в пылевой камере, изменение давления в пылевой камере и значение цинка в шихте. При этом масса загрузки коксика ограничена и не должна превышать 1/3 от массы загрузки шихты. Кек и данные о мастерах не учитываются. Целевой переменной является значение цинка в клинкере.

Этап 3. Обработка данных с использованием нейросетевых методов и алгоритмов машинного обучения

На основе анализа существующих исследований были отобраны следующие алгоритмы машинного обучения и нейросетевые методы для последующего анализа их применимости к поставленной задаче: LGBM Regression, CatBoost, Decision Tree Regressor, Random Forest Regressor, KNeighbors Regressor, SVR и Gradient Boosting Regressor.

Проведен сравнительный анализ указанных алгоритмов на предоставленных исходных данных, результаты которого представлены в табл. 1.

Для оценки качества моделей использовались стандартные метрики, такие как R^2 (коэффициент детерминации), MAE (средняя абсолютная ошибка) и MSE (среднеквадратичная ошибка). Коэффициент детерминации (R^2) показывает, какая доля дисперсии целевой переменной объясняется моделью, где 1 – идеальная модель, а 0 – модель, не объясняющая ничего. Средняя абсолютная ошибка (MAE) представляет собой среднее значение абсолютных разностей между предсказанными и фактическими значениями, а среднеквадратичная ошибка (MSE) – среднее значение квадратов этих разностей. Меньшие значения

MAE и MSE указывают на более высокую точность модели.

Анализ результатов (см. табл. 1) показал, что модели, основанные на LightAutoML, LGBM Regression и CatBoost, демонстрируют наилучшие показатели R^2 (0,9339; 0,9195 и 0,9218 соответственно), что свидетельствует о высокой степени соответствия моделей данным и их способности хорошо объяснять зависимость между переменными. Это означает, что примерно 92 % дисперсии целевой переменной объясняется данными моделями. В связи с этим было принято решение о разработке программного обеспечения на основе моделей LightAutoML, LGBM Regression и CatBoostRegressor для дальнейшего тестирования на большем объеме данных и выбора оптимальной модели для разработки советчика вельц-печи.

На рис. 2 представлены результаты прогнозирования данных с использованием методов LightAutoML, LGBM Regression и CatBoost и их сравнение с фактическими значениями.

Рейтинг важности показателей, представленный в табл. 2, позволяет оценить относительное влияние различных параметров процесса на прогнозируемое содержание цинка в клинкере для каждой из трех моделей (LGBM Regression, CatBoost и LightAutoML).

На основе представленного рейтинга важности показателей для трех моделей (LGBM Regression, CatBoost, LightAutoML) можно сделать выводы о влиянии параметров на содержание цинка в клинкере.

Общим закономерностями являются:

1. Значение цинка в шихте – единогласный лидер во всех моделях, так как основным ис-

Сравнительный анализ использования нейросетевых методов и алгоритмов машинного обучения на предоставленных исходных данных

Таблица 1

Comparative analysis of the use of neural network methods and machine learning algorithms on the provided source data

Table 1

Оценка	Наименование модели на основе нейросетевых методов и алгоритмов машинного обучения							
	LGBM Regression	CatBoost	Decision Tree Regressor	Random Forest Regressor	KNeighbors Regressor	SVR	LightAutoML	Gradient Boosting Regressor
R^2	0,9195	0,9218	0,8155	0,9011	0,8346	0,8344	0,9339	0,881
MAE	0,0776	0,0807	0,0891	0,0712	0,1246	0,1352	0,07221	0,1018
MSE	0,0165	0,016	0,0378	0,0202	0,0338	0,0339	0,01352	0,0243




Рис. 2. Результаты прогнозирования данных с использованием методов LightAutoML, LGBM Regression и CatBoost и их сравнение с фактическими значениями
Fig. 2. Data forecasting results using LightAutoML, LGBM Regression and CatBoost methods and their comparison with actual values

Таблица 2

Важность показателей для выбранных моделей
(наименование параметров представлено на рис. 2)

Table 2

Importance of the indicators for the selected models
(the names of the parameters are shown in Fig. 2)

Рейтинг важности показателя	Наименование показателя		
	LGBM Regression	CatBoost	LightAutoML
1	Значение цинка в шихте	Значение цинка в шихте	Значение цинка в шихте
2	Расход сжатого воздуха	Изменение давления в пылевой камере	Изменение давления в пылевой камере
3	Расход природного газа	Расход сжатого воздуха	Расход сжатого воздуха
4	Изменение давления в пылевой камере	Расход природного газа	Расход кислорода
5	Текущая масса загрузки шихты	Текущая масса загрузки коксика	Текущая масса загрузки коксика
6	Изменение температуры в пылевой камере	Изменение температуры в пылевой камере	Расход природного газа
7	Текущая масса загрузки коксика	Расход кислорода	Изменение температуры в пылевой камере
8	Расход кислорода	Текущая масса загрузки шихты	Текущая масса загрузки шихты

точником цинка в клинкере является исходное сырье (шихта). Чем выше содержание цинка в шихте, тем больше его попадает в продукт.

2. Газодинамические и аэродинамические параметры (расходы воздуха, газа, кислорода, давление в пылевой камере) – занимают высокие позиции:

– давление в пылевой камере – в топ-4 у всех моделей, так как чем выше давление, тем больше летучих соединений цинка может теряться;

– расход сжатого воздуха – в топ-3 у всех моделей, так как воздух влияет на окислительную среду, что может изменять испаряемость цинка;

– расход природного газа и кислорода – также важны, но их влияние варьируется в разных моделях.

Эти параметры определяют температуру и восстановительно-окислительные условия, от которых зависит поведение цинка (испарение, конденсация, включение в клинкер).

3. Масса загрузки коксика – важнее в двух методах, чем масса шихты.

Кокс может влиять на восстановление цинка ($ZnO \rightarrow Zn$), что повышает его летучесть и снижает содержание в клинкере.

4. Температура в пылевой камере есть во всех моделях, но на 6–7-м местах.

Температура косвенно отражает тепловой режим процесса, но, видимо, ее влияние менее прямое, чем у давления и расхода газов.

Различия между моделями:

– CatBoost выше оценивает давление в пылевой камере, чем LGBM и LightAutoML.

– LightAutoML придает большее значение расходу кислорода, чем другие модели.

– LGBM выделяет расход сжатого воздуха на втором месте, тогда как CatBoost и LightAutoML ставят его на третье.

Различия в ранжировании между моделями могут быть связаны с особенностями их

алгоритмов, но общие тенденции подтверждаются всеми тремя.

Таким образом, основной вклад в содержание цинка в клинкере вносят:

1) исходное содержание Zn в шихте (главный фактор);

2) параметры дутья и газового режима (давление, расход воздуха/газа/кислорода);

3) загрузка коксика (влияет на восстановление цинка).

Основываясь на проведенном выше анализе можно сформировать рекомендации для управления рабочим процессом КВП-6 вельцеца, которые включают необходимость регулярного осуществления:

– контроля качества шихты (минимизация цинка в сырье);

– оптимизации дутья и давления для снижения уноса цинка;

– мониторинга загрузки коксика и его влияния на восстановительные условия.

Список литературы

1. Путин призвал создать инфраструктуру в области искусственного интеллекта. URL: <https://ria.ru/20190220/1551123318.html> (дата обращения: 16.09.2024).

2. Программа «Цифровая экономика Российской Федерации». Утверждена распоряжением Правительства Российской Федерации от 28 июля 2017 г. № 1632-р. URL: <http://static.government.ru/media/files/9gFM4FHj4PsB7915v7yLVuPgu4bvR7M0.pdf> (дата обращения: 16.09.2024).

3. Указ Президента Российской Федерации от 10.10.2019 г. № 490 «О развитии искусственного интеллекта в Российской Федерации». URL: <http://www.kremlin.ru/acts/bank/44731> (дата обращения: 16.09.2024).

4. Федеральный проект «Искусственный интеллект». Утвержден Указом Президента Российской Федерации от 10 октября 2019 г. № 490. URL: https://www.consultant.ru/document/cons_doc_LAW_335184/ (дата обращения: 16.09.2024).

5. Искусственный интеллект меняет производство. URL: https://test.nornickel.digital/cifra_v_nornikele/iskusstvennyjj_intellekt_menyat_proizvodstvo (дата обращения: 16.09.2024).

6. Авилова В.В., Владыка М.В. Перспективы и проблемы применения искусственного интеллекта в промышленности // Региональные проблемы преобразования экономики. 2024. № 10 (168). С. 75–83. DOI: 10.26726/rppe2024v10papo. EDN SFFPVY.

7. Мустафин Д.Р. Тенденции внедрения искусственного интеллекта в бизнес-процессы на примере Свердловской области // Научный аспект. 2024. Т. 24, № 5. С. 3230–3236. EDN SMHPJL.

8. Николаева С.Г., Шахбанова З.И., Дудкина А.Е. Цифровизация и автоматизация производства в условиях финансовой нестабильности и ограничений в России // Региональные проблемы преобразования экономики. 2024. № 8 (166). С. 89–94. DOI: 10.26726/rppe2024v8daao. EDN LSFOLV.

9. Гусева И.А. Искусственный интеллект в промышленности: современные тенденции и проблемы // Экономика и предпринимательство. 2024. № 7 (168). С. 1471–1474. DOI: 10.34925/EIP.2024.168.7.292. EDN QRJHQY.

10. Кольской ГМК «Норникеля» использует цифровой двойник промплощадки. URL: <https://www.ttelegraf.ru/news/na-kolskoj-gmk-nornikelya-sozdali-cifrovoj-dvojn timer-promploshhadki/> (дата обращения: 16.09.2024).

11. На Оренбургском месторождении запустили цифровой двойник. URL: <https://neftegaz.ru/news/tsifrovizatsiya/702664-na-orenburgskom-mestorozhdenii-zapustili-tsifrovoy-dvoynik/> (дата обращения: 16.09.2024).

12. НЛМК и «Инфосистемы Джет» при помощи ИИ повышают эффективность потребления газа. URL: <https://www.novostiitkana.ru/news/detail.php?ID=170253> (дата обращения: 16.09.2024).

13. Эффективные отечественные практики на базе технологий искусственного интеллекта в обрабатывающей промышленности. URL: https://cdo2day.ru/wp-content/uploads/2022/11/jeffektivnye_praktiki_na_baze_ii_v_obrabatyvajushhej_promyshlennosti.pdf (дата обращения: 16.09.2024).

14. Интеллект на вес золота. URL: <https://www.kommersant.ru/doc/6082034> (дата обращения: 16.09.2024).

15. Application of machine learning in prediction of Pb^{2+} adsorption of biochar prepared by tube furnace and fluidized bed / W. Huang, L. Wang, J. Zhu et al. // Environmental Science and Pollution Research. 2024. Vol. 31, no. 18. P. 27286–27303. DOI: 10.1007/s11356-024-32951-5

16. Gurcan F. Forecasting CO₂ emissions of fuel vehicles for an ecological world using ensemble learning, machine learning, and deep learning models // PeerJ Computer Science. 2024. Vol. 10. P. e2234. DOI: 10.7717/peerj-cs.2234

17. Абдуракипов С.С., Кирюхина Н.В., Бутаков Е.Б. О прогнозировании кризиса теплоотдачи при кипении в каналах с использованием алгоритмов машинного обучения // Автометрия. 2022. Т. 58, № 1. С. 119–131. DOI: 10.15372/AUT20220113

18. Прогнозирование потребления электрической энергии промышленным предприятием с помощью методов машинного обучения / А.Д. Моргоева, И.Д. Моргоев, Р.В. Ключев, О.А. Гаврина // Известия Томского политехнического университета. Инжиниринг георесурсов. 2022. Т. 333, № 7. С. 115–125. DOI: 10.18799/24131830/2022/7/3527

19. Fiber Bragg grating sensor-based temperature monitoring of solar photovoltaic panels using machine learning algorithms / S. Dhanalakshmi, P. Nandini, S. Rakshit et al. // Optical Fiber Technology. 2022. Vol. 69. P. 102831. DOI: 10.1016/j.yofte.2022.102831

20. Bhattacharya Sh., Chakraborty Sh. Prediction of responses in a CNC milling operation using random forest regressor // Facta Universitatis. Series: Mechanical Engineering. 2023. Vol. 21, no. 4. P. 685. DOI: 10.22190/FUME210728071B

21. Pratap V., Kumar S., Yadav B.R. Optimization of biogas production from thermal-alkali pre-treated sludge using response surface methodology and random forest regressor model // Journal of the Taiwan Institute of Chemical Engineers. May 2024. P. 105571. DOI: 10.1016/j.jtice.2024.105571

22. Predictive modelling of concrete compressive strength incorporating GGBS and alkali using a machine-learning approach / A. Gogineni, I.K. Panday, P. Kumar, R.Kr. Paswan // Asian Journal of Civil Engineering. 2024. Vol. 25, no. 1. P. 699–709. DOI: 10.1007/s42107-023-00805-z

23. Limbu S., Dakshanamurthy S. Predicting Chemical Carcinogens Using a Hybrid Neural Network Deep Learning Method // Sensors. 2022. Vol. 22, no. 21. P. 8185. DOI: 10.3390/s22218185

24. Кушнарев В.О., Климовский А.Б., Клячкин В.Н. Применение метода опорных векторов для прогнозирования качества функционирования блока усилителя мощности // Автоматизация процессов управления. 2024. № 4 (78). С. 76–81.

25. Прогнозирование планового потребления электроэнергии для объединенной энергосистемы с помощью машинного обучения / Р.В. Ключев, А.Д. Моргоева, О.А. Гаврина и др. // Записки Горного института. 2023. Т. 261. С. 392–402.

26. Власов А.А., Кабиров И.Р., Ланчев Э.В. Краткосрочное прогнозирование интенсивности движения в задачах адаптивного управления транспортными потоками // Международный форум KAZAN DIGITAL WEEK – 2021: сб. материалов, Казань, 21–24 сентября 2021 года. Ч. 1. Казань: ГБУ «НЦБЖД», 2021. С. 62–69.

27. Шишков Е.М., Проничев А.В., Савельев А.А. Прогнозирование временных рядов с применением методов машинного обучения на примере графика выдачи мощности электрической станции // Международный научно-исследовательский журнал. 2022. № 2-1 (116). С. 56–60. DOI: 10.23670/IRJ.2022.116.2.009

References

1. Putin called for the creation of infrastructure in the field of artificial intelligence. 2019 Feb. 20. (In Russ.) Available at: <https://ria.ru/20190220/1551123318.html> (accessed 2024 Sep. 16).
2. Digital Economy of the Russian Federation Program Internet. Order of the Government of the Russian Federation No. 1632-r, 2017 Jul. 28. (In Russ.) Available at: <http://static.government.ru/media/files/9gFM4FHj4PsB79I5v7yLVuPgu4bvR7M0.pdf> (accessed 2024 Sep. 16).
3. On the development of artificial intelligence in the Russian Federation. Decree of the President of the Russian Federation No. 490, 2019 Oct. 10. (In Russ.) Available at: <http://www.kremlin.ru/acts/bank/44731> (accessed 2024 Sep. 16).
4. Federal project “Artificial Intelligence”. Decree of the President of the Russian Federation No. 490, 2019 Oct. 10. (In Russ.) Available at: https://www.consultant.ru/document/cons_doc_LAW_335184/ (accessed 2024 Sep. 16).
5. Artificial intelligence changes production. (In Russ.) Available at: https://test.nornickel.digital/cifra_v_normikele/iskusstvennyj_intellekt_menyaet_proizvodstvo (accessed 2024 Sep. 16).
6. Avilova V.V., Vladyka M.V. Prospects and problems of using artificial intelligence in industry. *Regional problems of transforming the economy*. 2024;10(168):75–83. (In Russ.) DOI: 10.26726/rppe2024v10papo
7. Mustafin D.R. [Trends in the implementation of artificial intelligence in business processes on the example of the Sverdlovsk region]. *Nauchnyy aspekt*. 2024;24(5):3230–3236. (In Russ.)
8. Nikolaeva S.G., Shakhbanova Z.I., Dudkina A.E. Digitalization and automation of production in conditions of financial stability and restrictions in Russia. *Regional problems of transforming the economy*. 2024;8(166):89–94. (In Russ.) DOI: 10.26726/rppe2024v8daao
9. Guseva I.A. Artificial intelligence in industry: current trends and problems. *Journal of Economy and entrepreneurship*. 2024;18(7):1471–1474. (In Russ.) DOI: 10.34925/EIP.2024.168.7.292
10. Norilsk Nickel’s Kola MMC uses a digital twin of the industrial site. (In Russ.) Available at: <https://www.ttelegraf.ru/news/na-kolskoj-gmk-nornikelya-sozdali-czifrovoj-dvojn timer-promploshhadki/> (accessed 2024 Sep. 16).
11. A digital twin was launched at the Orenburg field. (In Russ.) Available at: <https://neftegaz.ru/news/tsifrovizatsiya/702664-na-orenburgskom-mestorozhdenii-zapustili-tsifrovoy-dvoynik/> (accessed 2024 Sep. 16).
12. NLMK and Jet Infosystems use AI to increase gas consumption efficiency. (In Russ.) Available at: <https://www.novostiitkanala.ru/news/detail.php?ID=170253> (accessed 2024 Sep. 16).
13. Effective domestic practices based on artificial intelligence technologies in the manufacturing industry. (In Russ.) Available at: https://cdo2day.ru/wp-content/uploads/2022/11/jeffektivnye_praktiki_na_baze_ii_v_obratyvajushhej_promyshlennosti.pdf (accessed 2024 Sep. 16).
14. Intelligence is worth its weight in gold. (In Russ.) Available at: <https://www.kommersant.ru/doc/6082034> (accessed 2024 Sep. 16).
15. Huang W., Wang L., Zhu J. et al. Application of machine learning in prediction of Pb²⁺ adsorption of biochar prepared by tube furnace and fluidized bed. *Environmental Science and Pollution Research*. 2024;31(18):27286–27303. DOI: 10.1007/s11356-024-32951-5
16. Gurcan F. Forecasting CO₂ emissions of fuel vehicles for an ecological world using ensemble learning, machine learning, and deep learning models. *PeerJ Computer Science*. 2024;10:e2234. DOI: 10.7717/peerj-cs.2234
17. Abdurakipov S.S., Kiryukhina N.V., Butakov E.B. On forecasting of the heat transfer crisis at flow boiling in channels by using machine learning. *Avtometriya*. 2022;58(1):119–131. (In Russ.) DOI: 10.15372/AUT20220113
18. Morgoeva A.D., Morgoev I.D., Klyuev R.V., Gavrina O.A. Forecasting of electric energy consumption by an industrial enterprise using machine learning methods. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*. 2022;333(7):115–125. (In Russ.) DOI: 10.18799/24131830/2022/7/3527
19. Dhanalakshmi S., Nandini P., Rakshit S. et al. Fiber Bragg grating sensor-based temperature monitoring of solar photovoltaic panels using machine learning algorithms. *Optical Fiber Technology*. 2022;69:102831. DOI: 10.1016/j.yofte.2022.102831
20. Bhattacharya Sh., Chakraborty Sh. Prediction of responses in a CNC milling operation using random forest regressor. *Facta Universitatis. Series: Mechanical Engineering*. 2023;21(4):685. DOI: 10.22190/FUME210728071B

21. Pratap V., Kumar S., Yadav B.R. Optimization of biogas production from thermal-alkali pre-treated sludge using response surface methodology and random forest regressor model. *Journal of the Taiwan Institute of Chemical Engineers*. 2024 May;105571. DOI: 10.1016/j.jtice.2024.105571
22. Gogineni A., Panday I.K., Kumar P., Paswan R.Kr. Predictive modelling of concrete compressive strength incorporating GGBS and alkali using a machine-learning approach. *Asian Journal of Civil Engineering*. 2024;25(1):699–709. DOI: 10.1007/s42107-023-00805-z
23. Limbu S., Dakshanamurthy S. Predicting Chemical Carcinogens Using a Hybrid Neural Network Deep Learning Method. *Sensors*. 2022;22(21):8185. DOI: 10.3390/s22218185
24. Kushnarev V.O., Klimovskiy A.B., Klyachkin V.N. Application of the support vector method to predict the quality of the power amplifier unit operation. *Automation of control processes*. 2024;4(78):76–81. (In Russ.)
25. Klyuev R.V., Morgoeva A.D., Gavrina O.A., Bosikov I.I., Morgoev I.D. Forecasting planned electricity consumption for the united power system using machine learning. *Journal of Mining Institute*. 2023;261:392–402. (In Russ.)
26. Vlasov A.A., Kabirov I.R., Lanchev E.V. Short-term forecasting of traffic intensity in problems of adaptive control of traffic flows. In: *International Forum KAZAN DIGITAL WEEK – 2021: Collection of Materials, Kazan, September 21–24, 2021. Part 1*. Kazan: State Budgetary Institution “NCBR”, 2021. P. 62–69.
27. Shishkov E.M., Pronichev A.V., Savelyev A.A. Forecasting time series via machine learning methods based on the power output schedule of an electric power station. *International Research Journal*. 2022;2-1(116):56–60. DOI: 10.23670/IRJ.2022.116.2.009

Информация об авторах

Бунова Елена Вячеславовна, канд. техн. наук, доц., доц. кафедры прикладной математики и программирования, Южно-Уральский государственный университет, Челябинск, Россия; bunovaev@susu.ru.

Цедов Алексей Андреевич, магистрант кафедры прикладной математики и программирования, Южно-Уральский государственный университет, Челябинск, Россия.

Information about the authors

Elena V. Bunova, Cand. Sci. (Eng.), Ass. Prof., Ass. Prof. of the Department of Applied Mathematics and Programming, South Ural State University, Chelyabinsk, Russia; bunovaev@susu.ru.

Aleksey A. Tsedov, Master's student of the Department of Applied Mathematics and Programming, South Ural State University, Chelyabinsk, Russia.

Статья поступила в редакцию 10.04.2025

The article was submitted 10.04.2025