

МОДЕЛИ ОПЕРАТИВНОГО ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ ДУГОВЫХ СТАЛЕПЛАВИЛЬНЫХ ПЕЧЕЙ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Б. Р. Саидмуродов, С. Е. Кокин

Уральский федеральный университет
имени первого Президента России Б. Н. Ельцина, г. Екатеринбург

В статье рассматриваются модели прогнозирования энергопотребления электродуговых печей с использованием методов машинного обучения. Изучены классические подходы, такие как анализ временных рядов, регрессионные модели и методы экспоненциального сглаживания, а также современные технологии, включая градиентный бустинг (XGBoost, LightGBM) и нейронные сети (LSTM, CNN). Особое внимание уделено методам оптимизации параметров, таким как перебор по сетке (Grid Search), генетические алгоритмы и байесовская оптимизация, которые повышают точность и адаптивность моделей. Рассматриваются преимущества гибридных моделей, объединяющих классические и машинные методы для учета как линейных, так и нелинейных зависимостей. Обсуждаются практические аспекты внедрения предложенных подходов в управление энергопотреблением, направленные на снижение затрат, повышение устойчивости и оптимизацию производственных процессов.

Ключевые слова: прогнозирование энергопотребления, дуговые сталеплавильные печи, машинное обучение, нейронные сети, управление энергопотреблением, оптимизация параметров, интеллектуальные системы управления, большие данные.

Для цитирования: Саидмуродов Б. Р., Кокин С. Е. Модели оперативного прогнозирования энергопотребления дуговых сталеплавильных печей с использованием методов машинного обучения // Омский научный вестник. 2025. № 3 (195). С. 79–84. DOI: 10.25206/1813-8225-2025-195-79-84. EDN: JDQQCC.



© Саидмуродов Б. Р., Кокин С. Е., 2025.
Контент доступен под лицензией Creative Commons Attribution 4.0 License.

MODELS FOR OPERATIONAL FORECASTING OF ENERGY CONSUMPTION IN ELECTRIC ARC FURNACES USING MACHINE LEARNING METHODS

B. R. Saidmurodov, S. E. Kokin

Ural Federal University named after the First President of Russia B. N. Yeltsin,
Yekaterinburg, Russia

The article examines models for forecasting the energy consumption of electric arc furnaces using machine learning methods. Classical approaches such as time series analysis, regression models, and exponential smoothing methods are studied, along with modern techniques including gradient boosting (XGBoost, LightGBM) and neural networks (LSTM, CNN). Special attention is given to parameter optimization methods, such as grid search, genetic algorithms, and Bayesian optimization, which enhance the accuracy and adaptability of the models. The advantages of hybrid models integrating classical and machine learning methods to account for linear and nonlinear dependencies are highlighted. Practical applications of the proposed approaches in energy consumption management are discussed, aiming at cost reduction, improved sustainability, and production process optimization.

Keywords: energy consumption forecasting, electric arc furnaces, machine learning, neural networks, energy consumption management, parameter optimization, intelligent control systems, Big Data.



Введение

Управление энергопотреблением в электродуговых печах (ЭДП) остается критически важной задачей для повышения энергоэффективности металлургических процессов. Точное прогнозирование энергопотребления позволяет оптимизировать производственные процессы и снижать затраты, что способствует устойчивому развитию промышленности.

Современные достижения в области машинного обучения открывают новые возможности для решения задач прогнозирования. Эти методы позволяют анализировать сложные закономерности в данных, создавая более точные и адаптивные модели энергопотребления. Использование таких технологий позволяет промышленным предприятиям оперативно реагировать на изменения условий энергоснабжения (колебания напряжения и частоты сети, перебои в подаче электроэнергии), состава сырья (химический и фракционный состав, температура шихты), технологических режимов (характеристики дугового разряда, износ электродов, состояние футеровки, эффективность системы охлаждения) и экономических факторов (изменение тарифов, оптимизация затрат на энергоресурсы). Кроме того, такие технологии обеспечивают адаптацию к колебаниям спроса на продукцию, снижая удельное энергопотребление и повышая общую эффективность металлургического производства.

Цель данного исследования — анализ существующих подходов к прогнозированию энергопотребления в ЭДП и выявление перспективных направлений их дальнейшего применения. Также рассматривается интеграция методов машинного обучения с отраслевыми знаниями для решения специфических задач в данной области.

1. Классические подходы к прогнозированию энергопотребления

Классические методы широко применяются для прогнозирования энергопотребления, однако имеют ряд ограничений при работе с динамическими и сложными системами:

- метод ARIMA (Auto-Regressive Integrated Moving Average): используется для анализа временных рядов, эффективен для стационарных данных и учета сезонности. Однако требует сложной предварительной обработки данных и плохо справляется с нестабильными или сильно изменяющимися параметрами [1–2];

- методы экспоненциального сглаживания: просты в реализации и эффективны для краткосрочных прогнозов, но не учитывают сложные нелинейные зависимости [3];

- регрессионные модели: позволяют анализировать линейные зависимости между переменными, но требуют больших объемов данных и не работают в условиях нелинейных динамик [4].

В табл. 1 представлены преимущества и недостатки этих классических методов.

Исследования продемонстрировали практическое применение этих классических методов в прогнозировании энергопотребления, выявляя как их преимущества, так и ограничения. Например, работы [1–2] показывают, что метод ARIMA эффективно моделирует стационарные временные ряды, выявляя тренды и сезонность, однако испытывает трудности при работе с нестабильными данными. В исследованиях, таких как [3], методы экспоненциального сглаживания успешно применялись для краткосрочного прогнозирования, демонстрируя свою простоту и адаптивность, но не способные учитывать нелинейные зависимости. Аналогично, регрессионные модели в [4] оказались эффективными для выявления линейных зависимостей, однако их точность снижается при доминировании нелинейных факторов в системе. Эти исследования подчеркивают важность классических методов, одновременно указывая на необходимость их дальнейшего усовершенствования путем внедрения гибридных моделей и методов машинного обучения для более точного прогнозирования в современных промышленных условиях.

В статьях [5–9] также активно рассматриваются усовершенствования традиционных подходов. Так, в работе [5] предложена комбинация методов ARIMA и экспоненциального сглаживания с применением техники Bagging для повышения точности средне- и долгосрочного прогноза энергопотребления. Авторы демонстрируют, что использование ансамблевых стратегий может значительно повысить устойчивость моделей к флуктуациям данных.

В статье [6] обсуждаются методы компенсации гармоник и искажений, возникающих в электросетях, с применением смешанных и стационарных репетитивных регуляторов. Хотя работа ориентирована на силовую электронику, она содержит полезные идеи по использованию математических моделей для предсказания и коррекции энергопотребления в промышленных условиях.

Работа [7] демонстрирует применение современных методов анализа временных рядов в области медицины, но содержащиеся в ней методологические подходы — особенно по части предобработки данных и выявления скрытых закономерностей — легко адаптируются к задачам энергопотребления. Это подчеркивает междисциплинарный потенциал временных моделей.

Особое внимание заслуживает исследование [8], в котором подробно анализируются статистические методы прогнозирования потребления электроэнергии в дуговых сталеплавильных печах. Авторы используют регрессионное моделирование, опираясь на реальные производственные данные, что придает их выводам высокую прикладную значимость. Результаты показывают, что точность прогноза можно существенно повысить при наличии корректной информации о технологическом процессе и параметрах оборудования.

Данные исследования подчеркивают важность классических методов, одновременно указывая

Таблица 1. Преимущества и недостатки классических методов
Table 1. Advantages and disadvantages of classical methods

Метод	Преимущества	Недостатки
ARIMA	— эффективен для стационарных временных рядов; — учитывает сезонность и тренды	— требует сложной предобработки данных; — неэффективен при нестабильных данных
Методы экспоненциального сглаживания	— просты в реализации и интерпретации; — эффективны для краткосрочных прогнозов	— ограничены для сложных многокомпонентных систем; — не учитывают нелинейные зависимости
Регрессионные модели	— легко анализируют линейные зависимости; — хорошо работают при наличии четких связей между переменными	— не пригодны для нелинейных зависимостей; — требуют больших объемов данных

Таблица 2. Сравнение методов машинного обучения
Table 2. Comparison of machine learning methods

Метод	Преимущества	Применение
XGBoost	высокая точность, способность моделировать нелинейности	прогнозирование в сложных средах данных
LightGBM	высокая скорость обработки, эффективность	работа с крупными объемами данных
LSTM	учет долгосрочных зависимостей	прогнозирование временных рядов, анализ энергопотребления в реальном времени
CNN	анализ структурированных данных, выявление скрытых закономерностей	анализ временных рядов со сложными закономерностями

на необходимость их дальнейшего усовершенствования путем внедрения гибридных моделей и методов машинного обучения для более точного прогнозирования в современных промышленных условиях.

Расширение классических подходов

Для исключения недостатков, присущих классическим методам прогнозирования энергопотребления, была предложена их комбинация с более современными. Одним из таких решений являются гибридные модели, которые сочетают классические методы, такие как ARIMA и регрессионный анализ, с алгоритмами машинного обучения, например, методом опорных векторов (SVM) и искусственными нейронными сетями. Такой подход позволяет моделям учитывать как линейные, так и нелинейные зависимости в данных энергопотребления. Например, в [1–2] показано, что комбинация модели ARIMA с SVM может существенно снизить погрешность прогнозирования. Этот положительный эффект происходит по двум причинам: в ARIMA учитываются линейные участки в данных, а в SVM — нелинейные зависимости.

Кроме того, в процессе исследования применялись методы экспоненциального сглаживания, что позволило повысить точность прогнозирования. В работе [3] рассматривается сочетание экспоненциального сглаживания с многоканальным анализом синхронных кадров, что способствует точному определению гармоник в промышленных электрических системах, таких как электропечи. Данное усовершенствование способствует повышению стабильности и эффективности управления в динамичных промышленных условиях.

Дополнительно были адаптированы регрессионные модели для работы с нелинейными зависимостями. В исследовании [4] показано, что гауссовы процессы регрессии (GPR) способны существенно повысить точность прогнозов за счет моделирования сложных связей между переменными, что делает их более эффективными по сравнению с традиционными линейными моделями. Одним

из ключевых факторов успешного применения является корректный выбор гиперпараметров, который влияет на результаты при промышленном использовании.

В статье [9] описан практический пример построения статистической модели для прогнозирования энергопотребления дуговых печей на основе производственных данных. Использование регрессионных методов в сочетании с эмпирической калибровкой параметров позволило авторам добиться высокой корреляции между предсказанными и фактическими значениями, что подтверждает применимость моделей в реальных производственных условиях.

Кроме того, особое внимание уделяется этапу предобработки данных. Методы нормализации, устранения сезонности и шумоподавления способствуют повышению качества входных данных и, соответственно, точности прогнозов. В статье [8] рассматриваются алгоритмы анализа и моделирования временных рядов в медицинских системах, однако предложенные техники имеют универсальный характер и могут быть успешно адаптированы для задач энергетики. Это также согласуется с выводами из [7], где подчеркивается важность выбора корректного представления сигнала и использования подходящих преобразований координат для повышения точности анализа.

Помимо этого, всё чаще применяются ансамблевые методы, которые позволяют объединить прогнозы нескольких моделей, тем самым повышая надежность системы за счёт уменьшения риска переобучения. Такие методы находят своё отражение в статьях [5, 9], где показано, что совмещение результатов различных моделей даёт лучшие прогнозные характеристики, чем использование одного подхода.

2. Прогнозирование на основе машинного обучения

Методы машинного обучения обеспечивают высокую адаптивность и точность при анализе данных

Таблица 3. Сравнение методов оптимизации
Table 3. Comparison of optimization methods

Метод	Преимущества	Ограничения
Grid Search	— простой и интуитивно понятный; — гарантирует нахождение лучшей комбинации	— ресурсоёмкий в высокоразмерных пространствах; — ограничена эффективность при сложных задачах
Генетические алгоритмы	— эффективны в сложных, высокоразмерных задачах; — избегают локальных минимумов	— требуют точной настройки эволюционных параметров; — могут требовать больше итераций для сходимости
Байесовская оптимизация	— эффективное исследование пространства параметров; — адаптируется к изменениям данных	— сложна в реализации; — зависимость от начальных предположений

в динамических условиях. Среди наиболее эффективных подходов можно выделить:

— градиентный бустинг (XGBoost, LightGBM) [10–11]: позволяет успешно моделировать сложные нелинейные зависимости и широко применяется в промышленности для анализа больших объемов данных;

— рекуррентные нейронные сети (LSTM) [12]: подходят для моделирования временных зависимостей и долгосрочных трендов, что делает их особенно эффективными при прогнозировании энергопотребления в реальном времени;

— сверточные нейронные сети (CNN) [13–15]: демонстрируют высокую эффективность в анализе структурированных данных и выявлении скрытых закономерностей в сложных наборах данных.

В табл. 2 представлено сравнение методов машинного обучения.

Методы машинного обучения предоставляют значительные преимущества перед классическими подходами благодаря способности моделировать сложные нелинейные зависимости и обеспечивать более высокую точность. Например, алгоритмы градиентного бустинга (XGBoost, LightGBM) широко используются в прогнозировании сложных сред данных благодаря их скорости и эффективности в обработке больших объемов информации. Рекуррентные нейронные сети (LSTM) наиболее эффективны при прогнозировании временных рядов, так как способны моделировать долгосрочные зависимости и тренды, что особенно важно для анализа энергопотребления в реальном времени.

Развитие методов машинного обучения

Для повышения точности прогнозирования энергопотребления активно разрабатываются гибридные и ансамблевые подходы, объединяющие преимущества различных алгоритмов. Эти методы обеспечивают адаптивность и высокую точность в условиях изменяющихся данных, что особенно актуально в промышленных приложениях.

Одним из наиболее эффективных решений является интеграция градиентного бустинга (XGBoost, LightGBM) с рекуррентными нейронными сетями (RNN) или сетями долгой краткосрочной памяти (LSTM). Такие комбинации позволяют учитывать как нелинейные зависимости, так и временные характеристики данных, что особенно важно для анализа энергопотребления. В частности, исследования [10, 11] демонстрируют преимущества LightGBM в обработке больших объемов данных, делая его особенно полезным для прогнозирования энергопотребления в реальном времени.

Кроме того, гибридные модели, основанные на сверточных нейронных сетях (CNN) и LSTM,

показывают высокую эффективность при анализе сложных закономерностей энергопотребления. CNN позволяют выявлять пространственные зависимости в структурированных данных, в то время как LSTM эффективно моделирует временные тренды [13–15]. Данные подходы успешно применяются в энергетических системах, что подтверждается исследованиями [13–17], посвященными анализу качества электроэнергии в электродуговых печах.

Масштабируемость моделей машинного обучения позволяет реализовывать их в реальном времени на промышленных объектах. Облачные решения и технологии периферийных вычислений, представленные в [10, 11], способствуют снижению задержек и увеличению оперативности анализа данных.

3. Оптимизация параметров и адаптация моделей

В процессе разработки моделей машинного обучения одной из ключевых задач является оптимизация гиперпараметров, позволяющая повысить точность прогнозирования. Существует несколько эффективных методов оптимизации параметров моделей:

— Grid Search — метод полного перебора, при котором последовательно оцениваются все возможные комбинации гиперпараметров. Хотя этот подход гарантирует нахождение оптимального набора параметров, его вычислительная сложность значительно возрастает при увеличении размерности пространства параметров;

— генетические алгоритмы — основаны на принципах естественного отбора, таких как селекция, скрещивание и мутация. Эти алгоритмы особенно эффективны для поиска оптимальных параметров в сложных многомерных пространствах, где традиционные методы могут оказаться неэффективными;

— байесовская оптимизация — вероятностный метод, учитывающий неопределенность и использующий информацию из предыдущих экспериментов для эффективного исследования пространства параметров. Этот метод особенно полезен при работе с ограниченными вычислительными ресурсами.

Эти методы играют важную роль в повышении точности прогнозирования и адаптации моделей к изменяющимся данным.

В табл. 3 представлено сравнение методов оптимизации.

Оптимизация играет ключевую роль в создании адаптивных моделей, способных обрабатывать динамические и сложные данные. Grid Search является надежным методом для небольших и средне-сложных задач, но его высокая вычислительная

Таблица 4. Эффективность гибридных моделей
Table 4. Efficiency of hybrid models

Модель	Точность прогнозирования	Скорость обработки	Применимость
ARIMA + LSTM	Высокая	Средняя	Сложные временные ряды
XGBoost + CNN	Высокая	Высокая	Большие объемы структурированных данных

стоимость ограничивает применимость для крупных моделей. Генетические алгоритмы обеспечивают надежные решения в многомерных пространствах, позволяя избегать локальных минимумов, что делает их полезными для неконвексных задач оптимизации.

Байесовская оптимизация представляет собой более продвинутый подход [18, 19]. В данных работах описывают сложные модели и методы управления ЭДП, которые используют вероятностные модели для приоритизации поиска в наиболее перспективных областях пространства параметров. Благодаря способности адаптироваться к данным этот метод эффективен при наличии неопределенности и ограниченных вычислительных ресурсов.

4. Гибридные подходы

Гибридные модели объединяют преимущества классических методов и машинного обучения, что позволяет значительно улучшить точность прогнозирования и адаптивность моделей:

— ARIMA + LSTM — модель ARIMA используется для выявления трендов и сезонности в данных, а рекуррентные нейронные сети LSTM применяются для анализа нелинейных зависимостей и учета долгосрочных временных зависимостей. Такой подход позволяет учитывать как линейные, так и нелинейные компоненты данных, что делает его эффективным для прогнозирования временных рядов.

— XGBoost + CNN — сочетание градиентного бустинга XGBoost и сверточных нейронных сетей CNN позволяет учитывать как временные зависимости, так и структурные особенности данных. XGBoost эффективно обрабатывает нелинейные зависимости и сложные паттерны, тогда как CNN распознает скрытые структуры в данных, что делает этот метод особенно полезным при обработке больших объемов данных.

Исследования показывают, что комбинация ARIMA и LSTM позволяет достичь точности прогнозирования свыше 95 % [1–2, 7, 14, 15], значительно превосходя отдельные модели. Гибридные модели позволяют учитывать широкий спектр факторов, влияющих на потребление энергии, что делает их особенно ценными для промышленных приложений [14–17].

В табл. 4 представлена эффективность гибридных моделей.

Преимущества гибридных подходов

Гибридные модели обеспечивают более высокую точность прогнозирования и устойчивость к изменению данных. Они сочетают преимущества классического анализа временных рядов (например, выявление трендов и сезонности с помощью ARIMA) с возможностями машинного обучения (например, моделирование нелинейных зависимостей с помощью LSTM или извлечение признаков с использованием CNN).

В промышленности такие модели особенно полезны для прогнозирования потребления энергии, где данные подвержены как сезонным колебаниям,

так и резким изменениям. Они также применяются для предсказания отказов оборудования, анализа рыночного спроса и планирования производства.

5. Обсуждение: достижения и перспективные направления в прогнозировании энергопотребления

Несмотря на высокую эффективность, гибридные модели требуют тщательной настройки. Например, для интеграции ARIMA и LSTM необходимо правильно выбрать параметры обеих моделей и определить способ объединения их выходных данных. XGBoost и CNN также требуют значительных вычислительных ресурсов и оптимизации.

Будущие исследования будут сосредоточены на разработке более эффективных алгоритмов, способных автоматически адаптироваться к изменяющимся данным. Также перспективным направлением является использование ансамблевых методов и метамоделирования, что позволит создавать еще более устойчивые и точные прогнозные системы, связанные с энергопотреблением ЭДП [18, 19].

В долгосрочной перспективе развитие интеллектуальных и адаптивных систем управления энергопотреблением сыграет ключевую роль в повышении эффективности промышленного производства и сокращении издержек [16–19], что соответствует глобальным целям энергоэффективности и устойчивого развития не только металлургической отрасли, но и всех отраслей, в которых применяется электроэнергия.

Благодарности / Acknowledgments

Авторы выражают искреннюю благодарность Исмоилу Назримадовичу Одинаеву за ценные комментарии и качественное редактирование текста, что значительно улучшило читаемость и краткость статьи. Также выражается глубокая благодарность Муродбеку Холназаровичу Сафаралиеву за предоставление доступа к необходимым данным и информационным ресурсам, что позволило провести более глубокий анализ исследования.

The authors express their sincere gratitude to Ismoil Nazrimadovich Odinaev for valuable comments and high-quality editing of the text, which significantly improved the readability and conciseness of the article. Deep gratitude is also expressed to Murodbek Kholnazarovich Safaraliev for providing access to the necessary data and information resources, which allowed for an in-depth analysis of the study.

Список источников / References

1. Sen P., Roy M., Pal P. Application of ARIMA for forecasting energy consumption and GHG emission: A case study of an Indian pig iron manufacturing organization. *Energy*. 2016. Vol. 116. P. 1031–1038. DOI: 10.1016/j.apenergy.2020.114946.
2. Nie H., Liu G., Liu X., Wang Y. Hybrid of ARIMA and SVMs for short-term load forecasting. *Energy Procedia*. 2012. Vol. 16, part C. P. 1455–1460. DOI: 10.1016/j.egypro.2012.01.229.

3. Balouji E., Salor Ö., Ermis M. Exponential smoothing of multiple reference frame components with GPUs for real-time detection of time-varying harmonics and interharmonics of EAF currents. *IEEE Transactions on Industry Applications*. 2017. Vol. 54 (6). P. 6566–6575. DOI: 10.1109/IAS.2017.8101815.
4. Reimann A., Hay T., Echterhof T. [et al.]. Application and evaluation of mathematical models for prediction of the electric energy demand using plant data of five industrial-size EAFs. *Metals*. 2021. Vol. 11, no. 9. P. 1348. DOI: 10.3390/met11091348.
5. Sen P., Roy M., Pal P. Application of ARIMA for forecasting energy consumption and GHG emission: A case study of an Indian pig iron manufacturing organization. *Energy*. 2016. Vol. 116, Part 1. P. 1031–1038. DOI: 10.1016/j.energy.2016.10.068.
6. Oliveira E. M., Oliveira F. L. C. Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods. *Energy*. 2018. Vol. 144. P. 776–788. DOI: 10.1016/j.energy.2017.12.049.
7. Loh P. C., Tang Y., Blaabjerg F., Wang P. Mixed-frame and stationary-frame repetitive control schemes for compensating typical load and grid harmonics. *IET Power Electronics*. 2011. Vol. 4, issue 2. P. 218–226. DOI: 10.1049/iet-pel.2009.0222.
8. Егоров Д. Б., Захаров С. Д., Егорова А. О. Современные методы анализа и прогнозирования временных рядов и их применение в медицине // Врач и информационные технологии. 2020. № 1. С. 21–26. DOI: 10.37690/1811-0193-2020-1-21-26. EDN: HRGODU.
- Egorov D. B., Zakharov S. D., Egorova A. O. Sovremennyye metody analiza i prognozirovaniya vremennykh ryadov i ikh primeneniye v meditsine [Modern methods of analysis and forecasting of time series and use in medicine]. *Vrach i informatsionnyye tekhnologii. Medical Doctor and Information Technologies*. 2020. No. 1. P. 21–26. DOI: 10.37690/1811-0193-2020-1-21-26. EDN: HRGODU. (In Russ.).
9. Carlsson L. S., Samuelsson P. B., Jönsson P. G. Predicting the electrical energy consumption of electric arc furnaces using statistical modeling. *Metals*. 2019. Vol. 9 (9). 959. DOI: 10.3390/met9090959.
10. Yang L., Li Z., Hu H. [et al.]. Evaluation of energy utilization efficiency and optimal energy matching model of EAF steelmaking based on association rule mining. *Metals*. 2024. Vol. 14 (4). 458. DOI: 10.3390/met14040458.
11. Zhuo Q., Al-Harbi M. N., Pistorius P. C. Feature engineering to embed process knowledge: Analyzing the energy efficiency of electric arc furnace steelmaking. *Metals*. 2025. Vol. 15 (1). DOI: 10.3390/met15010013.
12. Chavosh Nejad M., Hadavandi E., Nakhostin M. M., Mehmanpazir F. A data-driven model for energy consumption analysis along with sustainable production: A case study in the steel industry. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*. 2022. Vol. 44 (2) P. 3360–3380. DOI: 10.1080/15567036.2022.2064943.
13. Pănoiu M., Pănoiu C. Hybrid deep neural network approaches for power quality analysis in electric arc furnaces. *Mathematics*. 2024. Vol. 12 (19). 3071. DOI: 10.3390/math12193071.
14. Carlsson L. S., Samuelsson P. B., Jönsson P. G. Using statistical modeling to predict the electrical energy consumption of an electric arc furnace producing stainless steel. *Metals*. 2020. Vol. 10 (1). 36. DOI: 10.3390/met10010036.
15. Gajic D., Gajic I. S., Savic I. [et al.]. Modelling of electrical energy consumption in an electric arc furnace using artificial neural networks. *Energy*. 2016. Vol. 108. P. 132–139. DOI: 10.1016/j.energy.2015.07.068.
16. Kirschen M., Risonarta V., Pfeifer H. Energy efficiency and the influence of gas burners to the energy related carbon dioxide emissions of electric arc furnaces in steel industry. *Energy*. 2009. Vol. 34 (9). P. 1065–1072. DOI: 10.1016/j.energy.2009.04.015.
17. Trejo E., Martell F., Micheloud O. [et al.]. A novel estimation of electrical and cooling losses in electric arc furnaces. *Energy*. 2012. Vol. 42 (1). P. 446–456. DOI: 10.1016/j.energy.2012.03.024.
18. Fathi A., Saboohi Y., Škrjanc I., Logar V. Comprehensive electric arc furnace model for simulation purposes and model-based control. *Steel Research International*. 2016. Vol. 83. 600083. DOI: 10.1002/srin.201600083.
19. Keplinger T., Haider M., Steinparzer T. [et al.]. Modeling, simulation, and validation with measurements of a heat recovery hot gas cooling line for electric arc furnaces. *Steel Research International*. 2018. Vol. 89. 1800009. DOI: 10.1002/srin.201800009.
- САИДМУРОДОВ Бегмурод Рахимбекович**, аспирант кафедры автоматизированных электрических систем Уральского федерального университета имени Первого Президента России Б. Н. Ельцина (УрФУ), г. Екатеринбург.
Адрес для переписки: saitov.fso@bk.ru
КОКИН Сергей Евгеньевич, доктор технических наук, профессор (Россия), заведующий кафедрой автоматизированных электрических систем УрФУ, г. Екатеринбург.
SPIN-код: 4769-7497
AuthorID (РИНЦ): 610636
ORCID: 0000-0001-7493-172X
AuthorID (SCOPUS): 24577707300
Адрес для переписки: s.e.kokin@urfu.ru
- Прозрачность финансовой деятельности:** авторы не имеют финансовой заинтересованности в представленных материалах и методах. Конфликт интересов отсутствует.
- Статья поступила в редакцию 01.04.2025; одобрена после рецензирования 12.06.2025; принята к публикации 01.07.2025.
- SAIDMURODOV Begmurod Rakhimbekovich**, Postgraduate of the Automated Electrical Systems Department, Ural Federal University named after the First President of Russia B. N. Yeltsin (UrFU), Yekaterinburg.
Correspondence address: saitov.fso@bk.ru
KOKIN Sergey Evgenievich, Doctor of Technical Sciences, Professor, Head of the Automated Electrical Systems Department, UrFU, Yekaterinburg.
SPIN-code: 4769-7497
AuthorID (RSCI): 610636
ORCID: 0000-0001-7493-172X
AuthorID (SCOPUS): 24577707300
Correspondence address: s.e.kokin@urfu.ru
- Financial transparency:** the authors have no financial interest in the presented materials or methods. There is no conflict of interest.
- The article was submitted 01.04.2025; approved after reviewing 12.06.2025; accepted for publication 01.07.2025.