



Прогнозирование электрических потерь при эксплуатации машин и оборудования на основе методов искусственного интеллекта

Ж. З. Косыбаев , **Б.А. Жакишев** , **Ә.Т. Мұстафа** 

Евразийский национальный университет им. Л.Н. Гумилева, Астана, Казахстан

E mail: zhkossybaev@mail.ru, zhakishev_ba@enu.kz, aset.mustafa@gmail.com

Аннотация. Эксплуатация машин и оборудования требует больших энергетических затрат. В этой связи традиционная энергетика на современном этапе развития требует качественного обновления и глубокой модернизации. В условиях стремительного роста цифровых технологий мы всё чаще становимся свидетелями того, как на смену классическим подходам приходят инновационные цифровые решения. Сегодня, в век цифровизации, наблюдается беспрецедентный рост интереса к технологиям машинного обучения и искусственного интеллекта (ИИ), которые становятся ключевыми инструментами решения сложнейших инженерных задач. Данная статья посвящена одной из наиболее острых проблем современной энергетики – повышению точности прогнозирования технологических потерь электрической энергии в национальной электрической сети Республики Казахстан, находящейся под управлением АО «KEGOC».

В отличие от стандартных алгоритмов, LSTM способна эффективно обрабатывать временные ряды, учитывая долгосрочные зависимости и циклические тренды. Работа включает в себя детальное описание процесса интеллектуальной предобработки данных и сравнительный анализ (бенчмаркинг) моделей LSTM, ARIMA и градиентного бустинга. Результаты показывают, что внедрение ИИ позволяет снизить погрешность до уровня менее 5%, что критически важно для оптимизации режимов работы энергосистемы.

Ключевые слова. прогнозирование электропотребления, электрические потери, искусственный интеллект (ИИ), машинное обучение, глубокое обучение, LSTM, нейронные сети, цифровая энергетика.

Введение

Большие объемы затрат электроэнергии при эксплуатации машин и оборудования сопряжены с переходом к концепции Smart Grid, где ключевую роль играет не только физическая инфраструктура, но и интеллектуальные системы управления данными. В условиях роста цифровых технологий традиционная энергетика сталкивается с вызовами, которые невозможно решить классическими методами. Сегодня искусственный интеллект (ИИ) и машинное обучение перестают быть вспомогательными инструментами, превращаясь в основу для обеспечения надежности и экономической эффективности энергосистем. Казахстан, следуя глобальному тренду цифровизации, интегрирует ИИ-решения для управления сложными нелинейными процессами, к которым относится и прогнозирование потерь [16].

Энергосистема Республики Казахстан в последние годы функционирует в режиме беспрецедентного роста нагрузок. По итогам 2025 года фактическое потребление в Единой электроэнергетической системе (ЕЭС) достигло отметки 124,6 млрд кВт·ч [1]. Особую сложность для системного оператора представляют экстремальные пики: так, 18 декабря 2025 года был зафиксирован исторический максимум нагрузки в 17 724 МВт [2]. Такой интенсивный рост потребления неизбежно ведет к увеличению объемов передачи мощности по магистральным сетям АО «KEGOC», что в физическом выражении означает рост нагрузочных потерь. Такие условия требуют совершенствования методов анализа.

Расчет потерь электрической энергии является важнейшим показателем эффективности работы электрических сетей и традиционно востребован при проектировании, нормировании и управлении режимами этих сетей. Актуальность исследования и совершенствования методик расчета потерь, а также обоснование нормативных характеристик потерь, обусловлена необходимостью повышения точности прогнозов и минимизации экономических потерь. [6]

На сегодняшний день применяются статистические методы прогнозирования потерь электроэнергии, которые включают анализ исторических данных и трендов. Хотя эти методы могут давать неплохие результаты в стабильных условиях, они менее эффективны в условиях высокой изменчивости параметров сети. Традиционные методы расчета потерь характеризуются рядом критических недостатков, ограничивающих их эффективность в современных условиях. Прежде всего, они обладают ограниченной точностью, так как базируются на упрощенных математических моделях, не способных учесть сложные нелинейные зависимости и динамическое влияние внешних факторов. Эта проблема усугубляется высокой зависимостью от теоретических предположений и допущений, которые зачастую не соответствуют реальным режимам работы энергосистемы, что ведет к получению недостоверных результатов. Кроме того, такие подходы отличаются высокой трудоемкостью: процесс требует колоссальных затрат времени и человеческих ресурсов для регулярного сбора, верификации и обновления данных, что делает невозможным оперативное управление сетью в режиме реального времени.

В связи с вышеизложенным, внедрение методов искусственного интеллекта становится не просто инновацией, а производственной необходимостью. Алгоритмы машинного обучения, в частности глубокие нейронные сети, способны выявлять скрытые закономерности в огромных массивах данных (Big Data) [3, 15].

Применение ИИ позволяет значительно ускорить и улучшить процесс анализа данных, что может привести к более точным прогнозам и значительной экономии времени [8]. Выделим основные преимущества использования ИИ.

Объект исследования и структура потерь

Электрические потери в сетях классифицируются на три основные группы [9]:

- Технические потери: обусловлены физикой процесса (нагрев проводов, потери в стали трансформаторов). Они делятся на условно-постоянные и нагрузочные (переменные).
- Расход на собственные нужды: энергия, необходимая для работы оборудования подстанций.
- Коммерческие потери: обусловлены погрешностями приборов учета, хищениями и ошибками в расчетах.

Технологические потери в магистральных сетях имеют сложную физическую природу. Согласно анализу эксплуатационных данных, доминирующую роль играют нагрузочные потери в линиях около 63 % и потери на корону около 20 % (смотреть диаграмму 1).



Диаграмма 1. Структура технологических потерь в магистральных сетях

Если условно-постоянные потери (холостой ход трансформаторов, реакторы) поддаются расчету классическими методами, то переменные составляющие напрямую зависят от метеоусловий и нелинейных изменений нагрузки [10]. Именно для прогнозирования этих динамических параметров наиболее эффективно применение нейросетевых моделей.

Традиционные методы (например, метод средних нагрузок или расчет по схемам замещения) часто не учитывают динамическое изменение метеоусловий и сложные нелинейные связи в транзитных сетях 220–500 кВ. Это создает необходимость перехода к интеллектуальным системам прогнозирования.

Методология

Выбор алгоритма зависит от доступности данных, сложности задачи и требуемой точности. Например, для сложных сетей с большим количеством переменных могут лучше подойти глубокие нейронные сети, а для более простых задач – регрессионные модели [7].

Для данного проекта выбран алгоритм «Рекуррентные нейронные сети», так как глубокие нейронные сети используются при наличии в переменных сложных зависимостей данных и пространственные данные. А в случае прогнозирования потерь планируется использование в основном временных данных, для чего отлично подходит алгоритм «Рекуррентные нейронные сети (RNN)», а точнее «Long Short-Term Memory (LSTM)» [4].

В отличие от стандартных нейронных сетей, LSTM обладает механизмами «памяти», что позволяет ей учитывать:

- суточные и сезонные циклы потребления;
- зависимость текущего состояния сети от предыдущих режимов работы.

В ходе исследования проведен сравнительный анализ алгоритмов (бенчмаркинг) трех подходов к прогнозированию:

- ARIMA (Statistical) – хорошо работает с линейными трендами, но плохо справляется с резкими изменениями нагрузки [14].
- CatBoost (Gradient Boosting) – эффективен для табличных данных, но не учитывает временную последовательность напрямую [13].
- LSTM (RNN) – глубокая нейросеть, способная «запоминать» состояние системы.

Обоснование выбора архитектуры

Для реализации системы прогнозирования была выбрана рекуррентная нейронная сеть архитектуры LSTM (Long Short-Term Memory).

LSTM – это разновидность рекуррентной нейронной сети (RNN), которая особенно хорошо подходит для задач прогнозирования на основе временных рядов, таких как прогнозирование потерь электроэнергии.

Выбор данной модели обусловлен несколькими её уникальными структурными особенностями, позволяющими преодолеть ограничения классических рекуррентных сетей (RNN) и статистических моделей.

Первое – это механизм запоминания. Благодаря наличию специальных «ворот» (gates) – входного, выходного и забывающего – LSTM эффективно решает проблему исчезающих градиентов. Это позволяет модели сохранять и использовать информацию о событиях в отдаленном прошлом, что критически важно для учета сезонных циклов и долгосрочных трендов энергопотребления в сетях АО «KEGOC».

Второе – это моделирование сложных нелинейностей. Энергосистема – это среда, где зависимость потерь от нагрузки, напряжения и метеоусловий носит выраженный нелинейный характер. LSTM обладает высокой аппроксимирующей способностью, позволяющей выявлять эти скрытые закономерности без жесткого задания математических функций [5].

Преимущества модели LSTM

Применение данной архитектуры в контексте прогнозирования технологических потерь позволяет реализовать комплексный аналитический подход.

Модель обучается на расширенном векторе признаков, включающем не только исторические данные о потерях, но и экзогенные переменные: метеорологические параметры (температура, влажность), календарные признаки (день недели, праздники) и операционные данные сети. Это позволяет учитывать, например, нелинейный рост потерь на корону при изменении влажности воздуха.

Архитектура LSTM позволяет одновременно обрабатывать как краткосрочные колебания (почасовые изменения нагрузки), так и долгосрочные зависимости (суточную и сезонную цикличность), что существенно повышает точность прогноза в периоды экстремальных пиковых нагрузок.

Использование LSTM-сетей трансформирует процесс прогнозирования из простой экстраполяции данных в интеллектуальный анализ состояния системы. Мировой опыт внедрения аналогичных решений в ведущих энергокомпаниях (например, REE в Испании или TenneT в Германии) подтверждает, что переход к глубокому обучению позволяет не только снизить операционные затраты за счет оптимизации закупок электроэнергии на покрытие потерь, но и значительно повысить наблюдаемость и надежность управления всей энергетической инфраструктурой [4].

Результаты и обсуждение

Архитектура модели LSTM

Программная реализация выполнена на языке Python. Модель обучалась на реальных исторических данных за многолетний период. Входной вектор формировался на основе скользящего окна глубины в 90 часов.




Рисунок 1. Интерактивная модель программы прогнозирования

Процесс включал предобработку данных телеметрии, нормализацию и фильтрацию аномалий, что обеспечило устойчивость алгоритма к «шумам» в данных.

Как показано на рисунке 2 на этапе предобработки программа выполняет парсинг временных меток и преобразование целевого признака файла с данными в числовой формат. На этапе инженерного анализа признаков особое внимание уделено учету долгосрочной периодичности. В модель включены лаговые значения потерь за аналогичные периоды трех предыдущих лет. На этапе формирования обучающей выборки использован метод «скользящего окна» (Sliding Window) с глубиной анализа (look-back) 168 часов для прогнозирования вектора из 24 последующих значений. На этапе конфигурации модели архитектура включает двунаправленный слой Bidirectional LSTM, что позволяет сети учитывать контекст временного ряда в обоих направлениях [11] и слои Dropout для минимизации риска переобучения [12].

```
A[Входные данные: losses12345.csv] --> B[Предобработка и очистка]
B --> C[Feature Engineering]

subgraph "Генерация признаков"
C --> C1[Временные метки: час, день, сезон]
C --> C2[Лаговые признаки: потери за 3 года]
end

C1 & C2 --> D[Масштабирование StandardScaler]
D --> E[Формирование окна: Look-back 168ч]

subgraph "Архитектура нейронной сети LSTM"
E --> F[Bidirectional LSTM - 256 нейронов]
F --> G[Dropout Layer - 0.2]
G --> H[LSTM Layer - 128 нейронов]
H --> I[Dropout Layer - 0.2]
I --> J[Dense Output - 24 нейрона]
end

J --> K[Обратное масштабирование]
K --> L[Прогноз на 24 часа]
L --> M[Оценка: MSE, MAE и Визуализация]
```

**Рисунок 2. Архитектура программного комплекса прогнозирования потерь
электроэнергии**

Для контроля обучения применены механизмы EarlyStopping и ReduceLROnPlateau, которые автоматически корректируют скорость обучения (learning rate) и останавливают процесс при достижении оптимальных показателей на валидационной выборке.

Результаты тестирования

Разработанная модель прошла тестирование на реальных эксплуатационных данных энергосистемы РК. Модель была протестирована на данных за прошедшие три года (2021–2023 г.г.). Использование фактических почасовых графиков потерь позволило обучить нейросеть учитывать реальные физические процессы в сети.

Качество прогнозов оценивалось с помощью метрик среднеквадратичной ошибки (MSE) и средней абсолютной ошибки (MAE). Для оценки точности нейросетевых моделей в

задачах по прогнозированию числовых значений традиционно используются метрики, позволяющие количественно измерить отклонение прогнозных значений потерь от фактических. В данном исследовании основными индикаторами качества выступили MSE и MAE.

Среднеквадратичная ошибка (MSE) – это метрика акцентирует внимание на крупных отклонениях, возводя разницу в квадрат.

$$MSE = (1/n) * \sum (P_i - P'_i)^2,$$

где:

n – количество наблюдений;

$\sum$ – сумма от $i=1$ до n ;

P_i – фактическое значение (реальные потери);

P'_i – предсказание модели (прогноз).

Средняя абсолютная ошибка (MAE) – это метрика, которая показывает среднее линейное отклонение прогноза от реальности в тех же единицах измерения (кВт·ч).

$$MAE = (1/n) * \sum |P_i - P'_i|,$$

где:

$P_i - P'_i$ – абсолютное значение (модуль) разности между фактом и прогнозом.




Рисунок 3. Сопоставление фактических и прогнозных значений потерь электроэнергии на тестовом временном интервале

Результаты тестирования показали, что в периоды устойчивых режимов работы сети предложенная LSTM-архитектура обеспечивает высокую точность прогнозирования с относительной погрешностью менее 5%. Как видно из Рисунка 3, модель наиболее точно предсказывает потери в периоды стабильных температурных режимов. В периоды резких пиков нагрузки отклонения возрастают, что объясняется недостаточной представленностью экстремальных режимов в обучающей выборке и требует дополнительного дообучения модели на экстремальных погодных сценариях.

Преимущества метода

Традиционный расчет потерь по методикам средних нагрузок требует сбора данных из множества систем учета и их ручной сверки. Автоматизированная модель сокращает время подготовки расчетов до считанных минут. Кроме этого, ручные расчеты подвержены ошибкам на основе человеческих факторов, особенно в условиях стресса или высокой загрузки инженеров. Модель ИИ одинаково эффективно и быстро обрабатывает данные в любое время, исключая ошибки ручной работы. Точность прогнозирования также может влиять на финансовые показатели электросетевых компаний в условиях функционирования рынка электроэнергии. Более точный прогноз позволяет закупать электроэнергию на покрытие технологических потерь по наиболее выгодным тарифам, минимизируя значительные отклонения.

Заключение

Проведенное исследование подтверждает, что переход от традиционных статистических методов к алгоритмам глубокого обучения, в частности к архитектуре LSTM, является наиболее перспективным вектором развития для национальной электрической сети Республики Казахстан. Интеграция методов машинного обучения с реальными инженерными данными АО «KEGOC» открывает новые горизонты для цифровой трансформации электроэнергетики, позволяя преодолеть ограничения классических математических моделей в условиях высокой волатильности нагрузок и климатических факторов. В ходе работы была доказана высокая эффективность нейросетевого подхода: предложенная методика позволила снизить погрешность прогнозирования технологических потерь в периоды устойчивых режимов работы сети до уровня менее 5%. Это стало возможным благодаря способности рекуррентных сетей учитывать долгосрочные зависимости во временных рядах, а также успешной предварительной обработке данных, включая нормализацию и фильтрацию аномалий. Сравнительный анализ (бенчмаркинг) наглядно продемонстрировал превосходство LSTM над аналогичными моделями в контексте инерционных процессов энергосистемы. Разработанный инструментарий позволяет глубже понимать внутренние нелинейные закономерности поведения сложных систем и служит надежным фундаментом для создания интеллектуальных систем нового поколения. Самостоятельная программная реализация модели на языке Python и её успешная апробация доказывают готовность

отечественной инженерной практики к внедрению высокотехнологичных ИИ-решений.

Совокупный эффект от внедрения данных решений создает синергию: автоматизация высвобождает время квалифицированного персонала для принятия стратегических решений, точность прогноза минимизирует прямые финансовые убытки, а масштабируемость гарантирует, что инвестиции в разработку ИИ будут приносить пользу на протяжении десятилетий, независимо от роста или трансформации энергосистемы Республики Казахстан. Перспективным направлением дальнейшего развития исследования является использование полученных прогнозов не только для повышения точности определения объемов технологических потерь, но и для последующей оптимизации режимов работы электрической сети. Более точное прогнозирование величины потерь создает информационную основу для принятия обоснованных эксплуатационных и организационных решений, направленных на снижение дополнительных финансовых затрат, связанных с их покрытием.

Вклад авторов

Косыбаев Ж.З.: разработка концепции и дизайна исследования; научное руководство; обеспечение методологической базы, критический пересмотр текста на предмет принципиального интеллектуального содержания; утверждение окончательного варианта статьи.

Жакишев Б.А.: обеспечение методологической базы, проведение экспериментальных исследований (сбор данных); статистическая обработка и анализ результатов; подготовка начального варианта рукописи.

Мұстафа Ә.Т.: разработка концепции, проведение экспериментальных исследований (сбор данных); статистическая обработка и анализ результатов; подготовка начального варианта рукописи; оформление графического материала и библиографического списка, визуализация данных.

Список литературы

1. Министерство энергетики РК. Итоги работы топливно-энергетического комплекса за 2025 год. – Астана, 2026.
2. АО «KEGOC». Аналитический отчет о работе Единой электроэнергетической системы Казахстана. [Электронный ресурс].
3. Nature Scientific Reports. Deep learning for electricity loss forecasting using LSTM networks. - 2023. - Vol. 13.
4. S&P Global Research. Energizing innovation: Exploring AI's impact on the energy industry. - 2024. <https://www.spglobal.com/en/research-insights/special-reports/look-forward/energizing-innovation-exploring-ai-s-impact-on-the-energy-industry>
5. Sepp Hochreiter & Jürgen Schmidhuber (1997) - «Long Short-Term Memory». <https://www.bioinf.jku.at/publications/older/2604.pdf>

6. Sudić I., Mesar M., Franc B., Capuder T., Ivanković T., Pavić K., Pavić I. Short-Term Transmission System Losses Forecast Based on Supervised Machine Learning // IEEE Conference Publication. – 2020.
7. Манусов В.З., Заиграева Ю.Б. Модель прогнозирования потерь мощности в высоковольтных электрических сетях на основе искусственных нейронных сетей // Научный вестник НГТУ. – Новосибирск, 2008. – № 1(30). – С. 131–146.
8. Курбацкий В.Г., Томин Н.В. Анализ потерь электрической энергии на базе современных алгоритмов искусственного интеллекта // Электричество. – 2007. – № 4. – С. 5–12.
9. Железко Ю.С., Артемьев А.В., Савченко О.В. Расчет, анализ и нормирование потерь электроэнергии в электрических сетях: Руководство для практических расчетов. – М.: Изд-во НЦ ЭНАС, 2002. – 280 с.
10. Navani J.P., Sharma N.K., Sapra S. Technical and non-technical losses in power system and its economic consequence in Indian economy // International Journal of Electronics and Computer Science Engineering. – 2016. – Vol. 1, № 2. – P. 757–761.
11. Schuster M., Paliwal K.K. Bidirectional recurrent neural networks // IEEE Transactions on Signal Processing. – 1997. – Vol. 45, № 11. – P. 2673–2681.
12. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // Journal of Machine Learning Research. – 2014. – Vol. 15, № 56. – P. 1929–1958.
13. Prokhorenkova L., Gusev G., Vorobev A., Dorogush A.V., Gulin A. CatBoost: unbiased boosting with categorical features // Advances in Neural Information Processing Systems 31 (NeurIPS 2018). – 2018. – P. 6639–6649.
14. Elsaraiti M., Ali G., Musbah H., Merabet A., Little T. Time series analysis of electricity consumption forecasting using ARIMA model // 2021 IEEE Green Technologies Conference (GreenTech). – 2021. – P. 259–262.
15. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. – 2015. – Vol. 521, № 7553. – P. 436–444.
16. Balamurugan M., Narayanan K., Raghu N., Arjun Kumar G.B., Trupti V.N. Role of artificial intelligence in smart grid – a mini review // Frontiers in Artificial Intelligence. – 2025. – Vol. 8. – Art. 1551661.

Zh. Kossybayev, B. Zhakishev, A. Mustafa

L.N. Gumilyov Eurasian National University, Astana, Kazakhstan

Forecasting electrical losses during the operation of machinery and equipment using artificial intelligence methods

Abstract. The operation of machinery and equipment entails high energy consumption. In this context, the traditional energy sector requires qualitative renewal and extensive modernization at

the current stage of development. In the current era of digitalization, there is an unprecedented surge of interest in machine learning and artificial intelligence (AI) technologies, which are becoming key tools for solving complex engineering problems. This article addresses one of the most pressing issues in modern power engineering: improving the accuracy of forecasting power transmission losses in the national power grid of the Republic of Kazakhstan, managed by JSC "KEGOC". Traditional statistical calculation methods used in current practice often exhibit significant margins of error. This is due to the inability of classical models to fully account for non-linear dependencies, dynamic changes in meteorological conditions, and the complex nature of load processes in high-voltage networks. As an innovative solution, the article proposes a methodology based on the use of recurrent neural networks with Long Short-Term Memory (LSTM) architecture. Unlike standard algorithms, LSTM is capable of effectively processing time series by considering long-term dependencies and cyclic trends. The work includes a detailed description of the intelligent data preprocessing stage and a comparative analysis (benchmarking) of LSTM, ARIMA, and gradient boosting models. The results demonstrate that the implementation of AI reduces the forecasting error to less than 5%, which is critical for optimizing the operating modes of the power system.

Keywords: power consumption forecasting, electrical losses, artificial intelligence (AI), machine learning, deep learning, LSTM, neural networks, digital energy.

References

1. Ministerstvo energetiki RK. Itogi raboty toplivno-energeticheskogo kompleksa za 2025 god. – Astana, 2026.
2. AO «KEGOC». Analiticheskii otchet o rabote Edinoi elektroenergeticheskoi sistemi Kazahstana. [Elektronnyi resurs].
3. Nature Scientific Reports. Deep learning for electricity loss forecasting using LSTM networks. - 2023. - Vol. 13.
4. S&P Global Research. Energizing innovation: Exploring AI's impact on the energy industry. - 2024. <https://www.spglobal.com/en/research-insights/special-reports/look-forward/energizing-innovation-exploring-ai-s-impact-on-the-energy-industry>
5. Sepp Hochreiter & Jürgen Schmidhuber (1997) - «Long Short-Term Memory». <https://www.bioinf.jku.at/publications/older/2604.pdf>
6. Sudić I., Mesar M., Franc B., Capuder T., Ivanković T., Pavić K., Pavić I. Short-Term Transmission System Losses Forecast Based on Supervised Machine Learning // IEEE Conference Publication. – 2020.
7. Manusov V.Z., Zaigraeva Yu.B. Model' prognozirovaniya poter' moshchnosti v vysokovol'tnykh elektricheskikh setyakh na osnove iskusstvennykh neironnykh setei // Nauchnyi vestnik NGTU. – Novosibirsk, 2008. – No. 1(30). – P. 131–146.
8. Kurbatskii V.G., Tomin N.V. Analiz poter' elektricheskoi energii na baze sovremennykh algoritmov iskusstvennogo intellekta // Elektrichestvo. – 2007. – No. 4. – P. 5–12.
9. Zhelezko Yu.S., Artem'ev A.V., Savchenko O.V. Raschet, analiz i normirovanie poter' elektroenergii v elektricheskikh setyakh: Rukovodstvo dlya prakticheskikh raschetov. –

- Moscow: Izd-vo NTs ENAS, 2002. – 280 p. 10–16.
10. Navani J.P., Sharma N.K., Sapra S. Technical and non-technical losses in power system and its economic consequence in Indian economy // International Journal of Electronics and Computer Science Engineering. – 2016. – Vol. 1, № 2. – P. 757–761.
 11. Schuster M., Paliwal K.K. Bidirectional recurrent neural networks // IEEE Transactions on Signal Processing. – 1997. – Vol. 45, № 11. – P. 2673–2681.
 12. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // Journal of Machine Learning Research. – 2014. – Vol. 15, № 56. – P. 1929–1958.
 13. Prokhorenkova L., Gusev G., Vorobev A., Dorogush A.V., Gulin A. CatBoost: unbiased boosting with categorical features // Advances in Neural Information Processing Systems 31 (NeurIPS 2018). – 2018. – P. 6639–6649.
 14. Elsaraiti M., Ali G., Musbah H., Merabet A., Little T. Time series analysis of electricity consumption forecasting using ARIMA model // 2021 IEEE Green Technologies Conference (GreenTech). – 2021. – P. 259–262.
 15. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. – 2015. – Vol. 521, № 7553. – P. 436–444.
 16. Balamurugan M., Narayanan K., Raghu N., Arjun Kumar G.B., Trupti V.N. Role of artificial intelligence in smart grid – a mini review // Frontiers in Artificial Intelligence. – 2025. – Vol. 8. – Art. 1551661.

Информация об авторах:

Косыбаев Ж.З. – кандидат педагогических наук, доцент кафедры электроэнергетики, Евразийский национальный университет им. Л.Н. Гумилева, К. Сатпаева

Жакишев Б.А. – кандидат технических наук, доцент кафедры электроэнергетики, Евразийский национальный университет им. Л.Н. Гумилева

Мұстафа Ә.Т. – автор для корреспонденции, магистрант кафедры электроэнергетики, Евразийский национальный университет им. Л.Н. Гумилева, К. Сатпаева, 2

Kosybayev Zh.Z. – Candidate of Pedagogical Sciences, Associate Professor, Department of "Electric Power Engineering", L.N. Gumilyov Eurasian National University, 2 Satpayev St

Zhakishev B.A. - Candidate of Technical Sciences, Associate Professor, Department of "Electric Power Engineering", L.N. Gumilyov Eurasian National University, 2 Satpayev St

Mustafa A.T. – corresponding author, Master's student, Department of "Electric Power Engineering", L.N. Gumilyov Eurasian National University, 2 Satpayev St



Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY NC) license (<https://creativecommons.org/licenses/by-nc/4.0/>).