

DOI: 10.12731/2227-930X-2024-14-4-322

EDN: YQIADQ

УДК 004.8:697.922



Научная статья |
Системный анализ, управление и обработка информации, статистика

МАШИННОЕ ОБУЧЕНИЕ В ПРОГНОЗИРОВАНИИ ТЕПЛОПOTЕРЬ В СИСТЕМАХ ТЕПЛОСНАБЖЕНИЯ (НА ПРИМЕРЕ ДАННЫХ ГОРОДА КАЗАНЬ ЗА ПЕРИОД 2020-2023 ГГ.)

А.А. Шакиров, А.И. Хабибрахманова

Аннотация

Обоснование. В исследовании представлено применение методов машинного обучения для прогнозирования теплопотерь в системе теплоснабжения города Казань на основе данных за период 2020–2023 годы. Прогнозирование теплопотерь позволяет повысить эффективность работы системы теплоснабжения, снизить затраты на производство и транспортировку тепла. В работе рассматриваются различные модели машинного обучения, такие как линейная регрессия, ансамблевые методы (случайный лес, градиентный бустинг) и нейронные сети, а также проводится оценка их точности и применимости в контексте городской инфраструктуры.

Цель – повышение точности прогнозирования теплопотерь в системе теплоснабжения города Казань с целью оптимизации работы и снижения эксплуатационных затрат.

Материалы и методы. Исследование базируется на операционных данных системы теплоснабжения, погодных данных, а также инфраструктурных характеристиках трубопроводов. Основные методы исследования включают линейную регрессию, методы регуляризации (Лассо, гребневая регрессия), ансамблевое обучение (случайный лес и градиентный бустинг) и многослойный перцептрон (MLP). Для оценки моделей использовались метрики MSE, MAPE и R2, а также кросс-валидация.

Результаты. Проведенный анализ показал, что методы машинного обучения, особенно градиентный бустинг и нейронные сети, позволяют достичь высокой точности прогнозирования теплопотерь ($R^2 = 0,89$). Применение данных методов способствует повышению энергоэффективности и снижению эксплуатационных затрат в теплоснабжающих системах.

Ключевые слова: теплопотери; прогнозирование; система теплоснабжения; машинное обучение; линейная регрессия; ансамблевые методы; нейронные сети; градиентный бустинг; энергоэффективность

Для цитирования. Шакиров А.А., Хабибрахманова А.И. Машинное обучение в прогнозировании теплопотерь в системах теплоснабжения (на примере данных города Казань за период 2020-2023 гг.) // International Journal of Advanced Studies. 2024. Т. 14, № 4. С. 113-133. DOI: 10.12731/2227-930X-2024-14-4-322

Original article |
System Analysis, Management and Information Processing, Statistics

MACHINE LEARNING IN PREDICTING HEAT LOSS IN HEAT SUPPLY SYSTEMS (USING THE EXAMPLE OF DATA FROM THE CITY OF KAZAN FOR THE PERIOD 2020-2023)

A.A. Shakirov, A.I. Khabibrakhmanova

Abstract

Background. The study presents the application of machine learning methods to predict heat loss in the heat supply system of the city of Kazan based on data for the period 2020-2023. Forecasting heat loss allows you to increase the efficiency of the heat supply system, reduce the cost of heat production and transportation. The paper examines various machine learning models, such as linear regression, ensemble methods (random forest, gradient boosting) and neural networks, and evaluates their accuracy and applicability in the context of urban infrastructure.

Purpose. Improving the accuracy of forecasting heat loss in the Kazan city heat supply system in order to optimize operation and reduce operating costs.

Materials and methods. The study is based on operational data of the heat supply system, weather data, as well as infrastructure characteristics of pipelines. The main research methods include linear regression, regularization methods (Lasso, ridge regression), ensemble learning (random forest and gradient boosting) and multilayer perceptron (MLP). The MSE, MAPE and R2 metrics, as well as cross-validation, were used to evaluate the models.

Results. The analysis showed that machine learning methods, especially gradient boosting and neural networks, make it possible to achieve high accuracy in predicting heat loss ($R^2 = 0,89$). The use of these methods helps to increase energy efficiency and reduce operating costs in heat supply systems.

Keywords: heat loss; forecasting; heat supply system; machine learning; linear regression; ensemble methods; neural networks; gradient boosting; energy efficiency

For citation. Shakirov A.A., Khabibrakhmanova A.I. Machine Learning in Predicting Heat Loss in Heat Supply Systems (using the Example of Data from the City of Kazan for the Period 2020-2023). *International Journal of Advanced Studies*, 2024, vol. 14, no. 4, pp. 113-133. DOI: 10.12731/2227-930X-2024-14-4-322

Введение

Эффективное управление системами теплоснабжения является важной задачей для городов, особенно в условиях роста энергозатрат и необходимости повышения энергоэффективности. Одним из ключевых аспектов управления теплоснабжением является минимизация теплопотерь, которые составляют значительную часть общих потерь энергии в тепловых сетях. Теплопотери в системах теплоснабжения могут быть обусловлены различными факторами, такими как изношенность инфраструктуры, климатические условия и недостаточная оперативность управления. Точное прогнозирование теплопотерь позволяет оптимизировать работу системы теплоснабжения, снижая затраты на производ-

ство и транспортировку тепла и, соответственно, повышая надежность и эффективность теплоснабжения [1].

Использование методов машинного обучения для прогнозирования теплопотерь в системах теплоснабжения является сравнительно новым направлением, которое может существенно повысить качество управления такими системами. Методы машинного обучения обладают способностью анализировать большие объемы данных и выявлять скрытые закономерности [2], что делает их перспективными для решения задач прогнозирования теплопотерь. В данном исследовании рассматривается применение методов машинного обучения к прогнозированию теплопотерь в системе теплоснабжения города Казань на основе данных за период с 2020 по 2023 годы. Новизна работы заключается в применении современных подходов к анализу данных для повышения точности прогнозирования теплопотерь с учетом специфики городской теплоснабжающей инфраструктуры.

Обзор отечественной и зарубежной литературы показывает, что вопросы прогнозирования теплопотерь исследуются в различных аспектах [3-6], однако работы, ориентированные на использование методов машинного обучения в контексте теплоснабжения, практически отсутствуют. Зарубежные исследования в этой области часто фокусируются на моделировании тепловых процессов в масштабах небольших населенных пунктов или районов с использованием традиционных методов статистического анализа [7-10]. В то же время отечественные исследования сосредоточены на анализе технического состояния тепловых сетей и подходах к оптимизации их работы [3-6]. В контексте данной работы особое внимание уделяется интеграции подходов машинного обучения и специфике локальных условий, что позволяет получить более точные прогнозы для городских систем теплоснабжения.

Целью настоящего исследования является разработка и апробация моделей машинного обучения для прогнозирования теплопотерь в системе теплоснабжения города Казань. Для достиже-

ния поставленной цели необходимо решить следующие задачи: сбор и предобработка данных о теплопотерях, выбор и настройка моделей машинного обучения, оценка их точности и применимость для практического использования. Гипотеза исследования состоит в том, что использование методов машинного обучения позволит значительно повысить точность прогнозирования теплопотерь по сравнению с традиционными методами.

Материалы и методы

Исследование базируется на данных о теплопотерях в системе теплоснабжения города Казань за период с 2020 по 2023 годы. Источниками данных являются:

- операционные данные системы теплоснабжения. Они включают в себя параметры температуры теплоносителя на входе и выходе, давление в системе, скорость потока, а также потребление тепла в различных сегментах сети;
- погодные данные, такие как температура окружающей среды, влажность воздуха, скорость и направление ветра за период 2020-2023 годов. Эти данные собирались из метеорологических источников для учета влияния климатических факторов на теплопотери;
- инфраструктурные данные, которые включают информацию о характеристиках трубопроводов, таких как диаметр, материал, толщина изоляции, возраст трубопровода и протяженность сети в различных районах города.

Перед началом построения моделей машинного обучения все собранные данные были подвергнуты тщательной предобработке, включающей следующие этапы:

- Очистка данных. Она включает в себя удаление отсутствующих значений, а также выбросов, которые могли возникнуть из-за ошибок в измерениях или сбоя в оборудовании [11]. Для удаления выбросов использовались методы межквартильного размаха (IQR) и z-оценка.

– Интеграция данных. Все данные были объединены в единую таблицу, где каждому наблюдению соответствует временной интервал и связанные с ним погодные и операционные параметры [11]. Для этого использовались временные метки, что позволяло синхронизировать данные из различных источников.

– Нормализация данных. Для моделей машинного обучения были нормализованы количественные признаки (такие как температура, давление и скорость потока) с целью улучшения сходимости алгоритмов и повышения их точности [11].

Для прогнозирования тепловпотерь были использованы различные методы машинного обучения, которые разделяются на две основные группы: регрессионные методы и методы ансамблевого обучения.

1. Регрессионные модели:

– линейная регрессия использовалась для базовой оценки точности прогнозирования, а также для установления основных зависимостей между переменными;

– лассо-регрессия и гребневая регрессия применялись для борьбы с многоколлинеарностью и улучшения обобщающей способности моделей [12].

2. Методы ансамблевого обучения:

– случайный лес использовался для учета нелинейных зависимостей между параметрами и повышения устойчивости модели к выбросам;

– градиентный бустинг применялся для повышения точности модели за счет последовательного обучения слабых моделей с использованием библиотеки XGBoost [12].

Для более сложного анализа использовалась нейронная сеть типа MLP (многослойный перцептрон). Данный подход был направлен на моделирование сложных нелинейных зависимостей в данных и позволяет учитывать временные взаимодействия между параметрами системы [9].

Для оценки точности и устойчивости каждой модели использовалась кросс-валидация с десятикратным разбиением данных.

Такой подход позволил уменьшить влияние случайного выбора обучающей и тестовой выборки и обеспечивал более объективную оценку точности моделей.

Основными метриками для оценки качества прогнозирования теплотер были выбраны [11]:

- среднеквадратическая ошибка (MSE) – для оценки отклонения прогнозируемых значений от фактических;
- средняя абсолютная процентная ошибка (MAPE) – для оценки точности моделей в процентах, что упрощает интерпретацию результатов для практического применения;
- коэффициент детерминации (R^2) – для оценки доли объясненной вариативности в данных.

Выбор наилучшей модели осуществлялся на основе значений метрик MSE, MAPE и R^2 [13]. Дополнительно учитывалась интерпретируемость модели и время её обучения. В ходе анализа проводился подбор гиперпараметров моделей с использованием методов случайного поиска и сеточного поиска для достижения наилучших показателей качества.

Основная часть

На первом этапе исследования был проведен предварительный анализ данных с целью выявления основных характеристик и особенностей исследуемых показателей. Для анализа использовались временные ряды данных о теплотерях, а также связанные с ними погодные и операционные параметры за период с 2020 по 2023 годы. Результаты анализа показали наличие сезонных колебаний теплотер, что объясняется изменениями климатических условий, характерными для региона.

Для оценки базовой зависимости между параметрами была выбрана модель линейной регрессии. Линейная регрессия использовалась в качестве начальной модели, позволив оценить влияние различных факторов на теплотери и определить базовый уровень точности прогнозирования. Формула линейной регрессии имеет вид [14]:

$$Y = \beta_0 + \sum_{i=1}^n \beta_i X_i + \tau,$$

где Y – прогнозируемое значение теплотер, X_i – входные параметры, такие как температура, давление и скорость потока, β_i – коэффициенты регрессии, τ – случайная ошибка [14].

По результатам построения линейной модели была установлена точность прогноза, которая составила около 72% (коэффициент детерминации $R^2 = 0,72$). Для повышения качества прогнозирования применялись методы регуляризации, такие как Лассо-регрессия и гребневая регрессия [14]:

$$L(\beta) = \sum_{i=1}^m (y_i - \beta_0 - \sum_{j=1}^n \beta_j x_{ij})^2 + \lambda \sum_{j=1}^n |\beta_j|,$$

где λ – параметр регуляризации, определяющий степень штрафа. Лассо-регрессия помогла исключить незначимые переменные, что снизило переобучение модели [14].

Гребневая регрессия использует другой подход к регуляризации, минимизируя квадраты коэффициентов [15]:

$$L(\beta) = \sum_{i=1}^m (y_i - \beta_0 - \sum_{j=1}^n \beta_j x_{ij})^2 + \lambda \sum_{j=1}^n \beta_j^2,$$

где λ – параметр регуляризации, определяющий степень штрафа. Лассо-регрессия помогла исключить незначимые переменные, что снизило переобучение модели.

Эти методы позволили уменьшить влияние многоколлинеарности, обеспечить лучшую обобщающую способность моделей, а также улучшить точность модели до коэффициента детерминации $R^2 = 0,75$. Результаты применения регуляризованных моделей представлены в таблице 1.

Таблица 1.

Результаты регуляризации линейной модели

Модель	Среднеквадратическая ошибка (MSE)	Коэффициент детерминации (R^2)
Линейная регрессия	3,45	0,72
Лассо-регрессия	3,32	0,74
Гребневая регрессия	3,29	0,75

Следующим этапом стало применение ансамблевых методов, таких как случайный лес и градиентный бустинг. Случайный лес состоит из множества деревьев решений, каждое из которых обучается на случайной выборке из исходных данных. Прогноз теплотер (Y) в модели случайного леса вычисляется как среднее значение прогнозов всех деревьев [16]:

$$Y_{forest} = \frac{1}{k} \sum_{i=1}^k Y_{tree_i},$$

где k – количество деревьев в лесу, а Y_{tree_i} – прогноз i -го дерева.

Модель градиентного бустинга использует последовательный подход к обучению, корректируя ошибки предыдущих моделей. Основная идея заключается в минимизации функции потерь путем добавления нового дерева, направленного на уменьшение ошибки [16]:

$$y_i^{(t)} = y_i^{(t-1)} + \eta f_t(X_i),$$

где $y_i^{(t)}$ – значение прогноза на t -й итерации, η – коэффициент обучения, $f_t(X_i)$ – функция ошибки текущей модели.

Градиентный бустинг продемонстрировал наилучшую точность среди всех ансамблевых методов, среднеквадратическая ошибка (MSE) составила 2.15, а коэффициент детерминации достиг 0,89. Результаты ансамблевых моделей представлены в таблице 2.

Таблица 2.

Результаты применения ансамблевых методов

Модель	Среднеквадратическая ошибка (MSE)	Коэффициент детерминации (R ²)
Случайный лес	2,25	0,87
Градиентный бустинг	2,15	0,89

В ходе исследования также использовалась модель нейронной сети типа многослойного перцептрона (MLP). Нейронная сеть включала три скрытых слоя по 128 нейронов в каждом, использующих функцию активации ReLU [17]:

$$f(x) = \max(0, x),$$

что позволяло эффективно моделировать сложные нелинейные зависимости. Выходной слой нейронной сети имел линейную

функцию активации для предсказания теплотерь. Обучение модели проводилось методом обратного распространения ошибки с использованием оптимизатора Adam, что обеспечило быструю сходимость модели.

Таблица 3.

Результаты применения ансамблевых методов

Модель	Среднеквадратическая ошибка (MSE)	Коэффициент детерминации (R^2)
Нейронная сеть (MLP)	2,18	0,88

Рисунок 1 показывает сравнение фактических и прогнозируемых значений теплотерь для различных моделей, иллюстрируя точность предсказаний. На графике видно, что ансамблевые модели и нейронная сеть обеспечивают более точное соответствие фактическим значениям теплотерь по сравнению с линейной регрессией.




Рис. 1. Сравнение фактических и прогнозируемых значений теплотерь

Анализ точности моделей

Результаты моделирования показали, что использование современных методов машинного обучения позволяет достичь вы-

сокой точности прогнозирования теплопотерь. Таблица 4 представляет сравнительный анализ ключевых метрик для линейной регрессии, случайного леса, градиентного бустинга и нейронной сети (MLP).

Таблица 4.

Сравнение показателей качества моделей

Модель	Среднеквадратическая ошибка (MSE)	Средняя абсолютная процентная ошибка (MAPE, %)	Коэффициент детерминации (R^2)
Линейная регрессия	3,45	8,2	0,72
Случайный лес	2,25	5,1	0,87
Градиентный бустинг	2,15	4,9	0,89
Нейронная сеть	2,18	5,0	0,88

Как видно из таблицы, модели ансамблевого обучения и нейронная сеть продемонстрировали значительно лучшие результаты по сравнению с линейной регрессией. Модель градиентного бустинга показала наилучшие показатели точности, с наименьшей среднеквадратической ошибкой ($MSE = 2,15$) и высоким коэффициентом детерминации ($R^2 = 0,89$), что свидетельствует о высокой способности модели предсказывать теплопотери [17]. Нейронная сеть также показала точные результаты, сопоставимые с ансамблевыми методами [17].

Обсуждение результатов

Основным достижением данного исследования стало выявление высокоэффективных моделей для прогнозирования теплопотерь в системах теплоснабжения, использующих методы машинного обучения. Линейная регрессия показала наихудшие результаты, что объясняется её ограниченной способностью учитывать сложные нелинейные зависимости между переменными [15]. Модели Лассо и гребневой регрессии с регуляризацией обеспечили небольшое улучшение, но по-прежнему оставались менее точными, чем ансамблевые методы [17].

Ансамблевые методы, такие как случайный лес и градиентный бустинг, продемонстрировали значительное улучшение точности [17]. Это связано с тем, что ансамблевые методы позволяют учитывать сложные зависимости между факторами, что особенно важно для прогнозирования теплопотерь в условиях изменчивых климатических и эксплуатационных условий. Случайный лес показал хорошую устойчивость к шуму и выбросам в данных, что делает его подходящим для практического применения в теплоснабжении, особенно когда качество данных может варьироваться.

Модель градиентного бустинга показала наилучшие результаты по метрике средней абсолютной процентной ошибки (MAPE = 4,9%), что подтверждает её эффективность в условиях значительной изменчивости данных. Сравнение прогнозируемых и фактических значений теплопотерь, представленное на графике 1, также демонстрирует близость этих значений для градиентного бустинга, что подтверждает его высокую предсказательную способность.

Нейронная сеть также показала высокую точность, что связано с её способностью учитывать сложные нелинейные зависимости и работать с большим количеством входных параметров. Однако обучение нейронной сети требует большего времени и вычислительных ресурсов по сравнению с ансамблевыми методами, что может ограничивать её применение на практике [18]. Тем не менее, использование нейронных сетей перспективно в условиях, когда точность прогнозов является критически важной.

Сравнение с предыдущими исследованиями

Результаты настоящего исследования сопоставимы с результатами, полученными в других работах, посвященных применению методов машинного обучения для прогнозирования теплопотерь. Так, в исследованиях, проведенных на основе использования линейных регрессионных моделей, была достигнута точность прогнозирования на уровне R^2 от 0,65 до 0,75, что соответствует результатам линейной регрессии в данном исследовании. Однако

применение методов ансамблевого обучения и нейронных сетей позволило значительно превзойти указанные показатели.

В зарубежных исследованиях, посвященных моделированию теплопотерь в системах теплоснабжения с использованием методов случайного леса и градиентного бустинга, сообщается о значении коэффициента детерминации R^2 в диапазоне от 0,85 до 0,90 [9-10]. Настоящее исследование подтверждает эти результаты, что свидетельствует о высокой применимости [17] указанных методов для прогнозирования теплопотерь в российских условиях.

Интерпретация результатов и практическое применение

Прогнозирование теплопотерь в системах теплоснабжения является важной задачей для повышения энергоэффективности и снижения затрат на эксплуатацию. Полученные результаты показывают, что применение методов ансамблевого обучения, таких как градиентный бустинг, позволяет получить высокую точность прогнозов, что обеспечивает надежное управление системой теплоснабжения города Казань. Эти методы могут быть интегрированы в существующие системы управления для автоматического прогнозирования и планирования ресурсов.

Кроме того, применение нейронных сетей позволяет учитывать широкий спектр параметров, влияющих на теплопотери, что делает их перспективным инструментом для дальнейшего повышения точности моделей. Однако требуется проведение дополнительных исследований, направленных на оптимизацию структуры нейронных сетей и снижение вычислительной сложности для обеспечения их практического применения.

Заключение

В данном исследовании была проведена разработка и анализ моделей машинного обучения для прогнозирования теплопотерь в системе теплоснабжения города Казань на основе данных за 2020-2023 годы. Основной целью работы являлось повышение

точности прогнозирования тепловпотерь, что, в свою очередь, способствует оптимизации работы системы теплоснабжения и снижению эксплуатационных затрат.

Результаты исследования показали, что использование современных методов машинного обучения, таких как ансамблевые методы (случайный лес и градиентный бустинг) и нейронные сети (многослойный перцептрон, MLP), позволяет достичь высокой точности прогнозирования тепловпотерь. Среди рассмотренных моделей наилучшие результаты продемонстрировал градиентный бустинг, который обеспечил наименьшую среднеквадратическую ошибку ($MSE = 2,15$) и высокий коэффициент детерминации ($R^2 = 0,89$). Нейронная сеть также показала хорошую точность, однако требует большего времени на обучение, что ограничивает её использование в некоторых практических ситуациях [19].

Полученные результаты согласуются с предыдущими исследованиями [8-10] в области прогнозирования тепловпотерь и подтверждают высокую эффективность методов ансамблевого обучения и нейронных сетей для решения этой задачи. Линейная регрессия, примененная для оценки базового уровня точности, продемонстрировала более низкие показатели качества, что указывает на её недостаточную способность моделировать сложные зависимости в данных.

Выводы исследования заключаются в следующем:

- методы машинного обучения могут быть успешно применены для повышения точности прогнозирования тепловпотерь в системах теплоснабжения, что способствует улучшению управления этими системами;
- градиентный бустинг показал наилучшие результаты среди рассмотренных моделей, обеспечивая высокую точность и устойчивость к изменчивости данных;
- нейронные сети обладают высокой предсказательной способностью, однако требуют значительных вычислительных ресурсов для обучения;

– линейная регрессия и методы регуляризации обеспечивают ограниченную точность прогнозирования и могут быть использованы только в качестве простых ориентировочных моделей.

Практическая значимость проведенного исследования заключается в том, что предложенные модели могут быть интегрированы в системы управления теплоснабжением города Казань для автоматического прогнозирования теплопотерь и оптимизации процессов транспортировки и распределения тепла. Внедрение таких моделей способствует снижению энергозатрат и повышению общей эффективности эксплуатации системы теплоснабжения.

В дальнейшем планируется провести исследования, направленные на улучшение структуры нейронных сетей, уменьшение вычислительной сложности моделей и их адаптацию для других городских систем теплоснабжения, что позволит более широко применять предложенные методы на практике.

Список литературы

1. Алтынбаев А.Р. Искусственный интеллект. Использование интеллектуальных систем учета энергоресурсов в системе электроснабжения предприятия // Вестник науки. 2024. Т. 2, № 6(75). С. 2180-2191.
2. Натальсон А.В. Разработка моделей машинного обучения для прогнозирования экономической эффективности бизнес-процессов // Экономика и управление: проблемы, решения. 2024. Т. 5, № 4(145). С. 164-170. <https://doi.org/10.36871/ek.up.p.r.2024.04.05.021>
3. Куценко С.М. Оптимизация производства в энергетической отрасли при использовании искусственного интеллекта // Экономика и предпринимательство. 2024. № 6(167). С. 391-394. <https://doi.org/10.34925/EIP.2024.167.6.081>
4. Обайди А.А.Х. Управление жизненным циклом объектов капитального строительства нейросетевым прогнозированием теплопотерь здания: диссертация на соискание ученой степени кандидата технических наук. 2024. 191 с.

5. Мельников Д.С. Разработка метода выявления теплопотерь на теплосетях города Архангельска на основе цифровых данных // Вестник науки. 2023. Т. 4, № 8(65). С. 302-306.
6. Сибгатов А.Р. Влияние температурного графика тепловых сетей на Тепловые потери трубопроводов / А. Р. Сибгатов, Г. М. Ахмерова // Актуальные проблемы энергетики АПК: Материалы XIII Национальной научно-практической конференции с международным участием, Саратов, 29–30 апреля 2022 года. Саратов: Амирит, 2022. С. 147-150.
7. Minimization of Heat Losses in District Heating Networks by Optimizing their Configuration / V. Skochko, V. Solonnikov, O. Pohosov [et al.] // Problems of the Regional Energetics. 2024. No. 3(63). P. 182-195. <https://doi.org/10.52254/1857-0070.2024.3-63.15>
8. Жамалов А. Батарейның автономды резервуарының жылу шығынын есептеу әдісі / А. Жамалов, А. О. Бердіғожа // Л.Н. Гумилев атындағы Еуразия ұлттық университетінің хабаршысы. Физика. Астрономия сериясы. 2021. No. 1(134). P. 79-85. <https://doi.org/10.32523/2616-6836-2021-134-1-79-85>
9. Evaluating different artificial neural network forecasting approaches for optimizing district heating network operation / L. Frison, S. Götzhäuser, M. Bitterling, W. Kramer // Energy. 2024. Vol. 307. P. 132745. <https://doi.org/10.1016/j.energy.2024.132745>
10. Improved day ahead heating demand forecasting by online correction methods / F. Bünning, P. Heer, R. S. Smith, J. Lygeros // Energy and Buildings. 2020. Vol. 211. P. 109821. <https://doi.org/10.1016/j.enbuild.2020.109821>
11. Салтанаева Е.А. Сравнение традиционных методов машинного обучения и глубокого обучения / Е. А. Салтанаева, А. А. Шакиров, А. Р. Гимаева // Научно-технический вестник Поволжья. 2023. № 12. С. 379-381.
12. Садриев Р.Р. Применение искусственного интеллекта для оптимизации энергопотребления в многоквартирных домах / Р. Р. Садриев, А. И. Кушакова, Р. С. Зарипова // Приборостроение и автоматизи-

- рованный электропривод в топливно-энергетическом комплексе и жилищно-коммунальном хозяйстве: материалы IX Национальной научно-практической конференции, посвященной 55-летию КГЭУ, Казань, 07–08 декабря 2023 года. Казань: Казанский государственный энергетический университет, 2024. С. 223-225.
13. Моделирование потребления невозобновляемой энергии в мире / Л. А. Шильдт, Н. Г. Бикеева, К. В. Байдуганова, Г. В. Шильдт // Вестник УГНТУ. Наука, образование, экономика. Серия: Экономика. 2024. № 3(49). С. 35-47. <https://doi.org/10.17122/2541-8904-2024-3-49-35-47>
 14. Rakhimov Z. Linear regression with data missing not at random: bootstrap approach / Z. Rakhimov, N. Rahimova // Economic Development and Analysis. 2024. Vol. 2, No. 4. P. 492-502. <https://doi.org/10.60078/2992-877X-2024-vol2-iss4-pp492-502>
 15. Cui K. Classification accuracy analysis using a random forest model // Актуальные проблемы авиации и космонавтики, 10–14 апреля 2023 года, 2023. С. 123-125.
 16. Цвенгер И.Г. Машинное обучение с управляемой регрессией в электроэнергетике // Наука, инновации, общество: актуальные вопросы и современные аспекты. Пенза: Наука и Просвещение, 2024. С. 196-215.
 17. Разработка моделей среднесрочного прогнозирования электропотребления в изолированно работающих энергосистемах на основе ансамблевых методов машинного обучения / С. М. Асанова, Д. С. Ахьеев, С. А. Дмитриев [и др.] // Известия НТЦ Единой энергетической системы. 2021. № 1(84). С. 32-39.
 18. Натальсон А.В. Цифровые двойники в промышленности: достижения и основные ошибки внедрения // Экономика и предпринимательство. 2024. № 9(170). С. 1138-1141. <https://doi.org/10.34925/EIP.2024.170.9.212>
 19. Хамитов Р.М. Оптимизация сервисного обслуживания в электросетевом комплексе методами машинного обучения / Р. М. Хамитов, Н. Д. Новоселов // Вестник НЦБЖД. 2024. № 3(61). С. 95-103.

References

1. Altynbaev A.R. Artificial intelligence. Utilization of intellectual systems of energy resources accounting in the enterprise power supply system. *Vestnik nauki*, 2024, vol. 2, no. 6(75), pp. 2180-2191.
2. Natalson A.V. Development of machine learning models for predicting the economic efficiency of business processes. *Economics and Management: Problems, Solutions*, 2024, vol. 5, no. 4(145), pp. 164-170. <https://doi.org/10.36871/ek.up.p.r.2024.04.05.021>
3. Kutsenko S.M. Optimization of production in the energy industry using artificial intelligence. *Economics and Entrepreneurship*, 2024, no. 6(167), pp. 391-394. <https://doi.org/10.34925/EIP.2024.167.6.081>
4. Obaidi A.A.H. *Life cycle management of capital construction objects by neural network prediction of building heat loss*: thesis for the degree of Candidate of Technical Sciences. 2024, 191 p.
5. Melnikov D.S. Development of the method of the heat loss detection on the heat networks of the Arkhangelsk city on the basis of the digital data. *Vestnik nauki*, 2023, vol. 4, no. 8(65), pp. 302-306.
6. Sibgatov A.R. Influence of the temperature schedule of heat networks on the heat losses of pipelines / A.R. Sibgatov, G.M. Akhmerova. *Actual problems of energy of the agroindustrial complex: Proceedings of the XIII National Scientific and Practical Conference with international participation, Saratov, April 29-30, 2022*. Saratov: Amirit, 2022, pp. 147-150.
7. Minimization of Heat Losses in District Heating Networks by Optimizing their Configuration / V. Skochko, V. Solon. Skochko, V. Solonnikov, O. Pohosov [et al.]. *Problems of the Regional Energetics*, 2024, no. 3(63), pp. 182-195. <https://doi.org/10.52254/1857-0070.2024.3-63.15>
8. Zhamalov A. Battery autonomous reservoirs are used for power supply / A. Zhamalov, A. O. Berdigozha. *L.N. Gumilev atyndagy Eurasia University of Science and Technology. Physics. Astronomy series*, 2021, no. 1(134), pp. 79-85. <https://doi.org/10.32523/2616-6836-2021-134-1-79-85>

9. Evaluating different artificial neural network forecasting approaches for optimizing district heating network operation / L. Frison, S. Götzhäuser, M. Bitterling, W. Kramer. *Energy*, 2024, vol. 307, pp. 132745. <https://doi.org/10.1016/j.energy.2024.132745>
10. Improved day ahead heating demand forecasting by online correction methods / F. Bünnig. Bünnig, P. Heer, R. S. Smith, J. Lygeros. *Energy and Buildings*, 2020, vol. 211, p. 109821. <https://doi.org/10.1016/j.enbuild.2020.109821>
11. Saltanaeva E. A. Comparison of traditional methods of machine learning and deep learning / E. A. Saltanaeva, A. A. Shakirov, A. R. Gimaeva. *Scientific and Technical Bulletin of the Volga Region*, 2023, no. 12, pp. 379-381.
12. Sadriev R.R. Application of artificial intelligence to optimize energy consumption in apartment buildings / R.R. Sadriev, A.I. Kushakova, R.S. Zaripova. *Instrumentation and automated electric drive in fuel and energy complex and housing and communal services: proceedings of the IX National Scientific and Practical Conference dedicated to the 55th anniversary of KSEU, Kazan, December 07-08, 2023*. Kazan: Kazan State Energy University, 2024, pp. 223-225.
13. Modeling of non-renewable energy consumption in the world / L. A. Shildt, N. G. Bikeeva, K. V. Baiduganova, G. V. Shildt. *Bulletin of UGNTU. Science, Education, Economics. Series: Economics*, 2024, no. 3(49), pp. 35-47. <https://doi.org/10.17122/2541-8904-2024-3-49-35-47>
14. Rakhimov Z. Linear regression with data missing not at random: bootstrap approach / Z. Rakhimov. Rakhimov, N. Rahimova. *Economic Development and Analysis*, 2024, vol. 2, no. 4, pp. 492-502. <https://doi.org/10.60078/2992-877X-2024-vol2-iss4-pp492-502>
15. Cui K. Classification accuracy analysis using a random forest model. *Actual problems of aviation and astronautics, April 10-14, 2023*, 2023, pp. 123-125.
16. Zvenger, I.G. Machine learning with controlled regression in the electric power industry. *Science, innovations, society: topical issues and modern aspects*. Penza: Science and Education, 2024, pp. 196-215.

17. Development of models for medium-term forecasting of power consumption in isolated power systems based on ensemble methods of machine learning / S. M. Asanova, D. S. Akhieev, S. A. Dmitriev [et al.]. *Izvestia NTC of the Unified Energy System*, 2021, no. 1(84), pp. 32-39.
18. Natalson A.V. Digital twins in industry: achievements and main mistakes of implementation. *Economics and Entrepreneurship*, 2024, no. 9(170), pp. 1138-1141. <https://doi.org/10.34925/EIP.2024.170.9.212>
19. Khamitov R.M. Optimization of the service maintenance in the electric grid complex by the machine learning methods / R.M. Khamitov, N.D. Novoselov. *Vestnik of NCBZhD*, 2024, no. 3(61), pp. 95-103.

ДАННЫЕ ОБ АВТОРАХ

Шакиров Арслан Айнурович, преподаватель кафедры «Информационные технологии и интеллектуальные системы»
Казанский государственный энергетический университет
ул. Красносельская, 51, г. Казань, 420066, Российская Федерация
shakirov.aa@bk.ru

Хабибрахманова Алсу Ильгамовна, кандидат технических наук, доцент кафедры «Информационные технологии и интеллектуальные системы»
Казанский государственный энергетический университет
ул. Красносельская, 51, г. Казань, 420066, Российская Федерация
alsu_khisa@mail.ru

DATA ABOUT THE AUTHORS

Arslan A. Shakirov, Lecturer of the Department of Information Technologies and Intelligent Systems
Kazan State Power Engineering University
51, Krasnoselskaya Str., Kazan, 420066, Russian Federation
shakirov.aa@bk.ru

SPIN-code: 6508-3780

ORCID: <https://orcid.org/0000-0003-0477-3660>

ResearcherID: T-3490-2018

Alsu I. Khabibrakhmanova, Candidate of Technical Sciences, Associate Professor of the Department of Information Technologies and Intelligent Systems

Kazan State Power Engineering University

51, Krasnoselskaya Str., Kazan, 420066, Russian Federation

alsu_khisa@mail.ru

SPIN-code: 3130-8620

ORCID: <https://orcid.org/0009-0005-3751-3082>

Scopus Author ID: 57196030218

Поступила 13.10.2024

После рецензирования 20.11.2024

Принята 28.11.2024

Received 13.10.2024

Revised 20.11.2024

Accepted 28.11.2024