



SNT va AGHO usullaridan foydalangan holda tarmoqlarda elektr energiya isroflarini qiyosiy baholash

Kaxramon R. Allaev^{1, a)}, Xilola Z. Nazirova¹

^{1, a)} akademik, prof., Toshkent davlat texnika universiteti, Toshkent, 100095, O'zbekiston; tstu_energy@mail.ru <https://orcid.org/0000-0001-6018-8912>

¹ katta o'qituvchi. Toshkent davlat texnika universiteti, Toshkent, 100095, O'zbekiston; tstu_energy@mail.ru <https://orcid.org/0009-0002-7735-4862>

Dolzarbli: texnologiya jadal rivojlanayotgan zamonaviy dunyoda sun'iy intellekt (SI) nafaqat mashhur tendentsiya, balki deyarli har qanday sohani o'zgartirishga qodir kuchli vositaga aylanmoqda. Elektr energetikasi iqtisodiyotning boshqa tarmoqlari kabi bu inqilobdan chetda qolmadi. Sun'iy intellektga asoslangan yechimlar kundalik vazifalarni avtomatlashtirishga yordam beradi, jumladan, uskunaning holatini kuzatish, energiya isrofini prognozlash, quvvat taqsimotini boshqarish va elektr tarmoqlarini optimallashtirish. Intellektual neyron tarmoqlari (INT) sun'iy intellekt sohasidagi asosiy texnologiyalardan biridir. SI katta hajmdagi ma'lumotlarni qayta ishlaydi, bu yashirin qatlamlarni aniqlashga va resurslardan foydalanishni yaxshilashga yordam beradi. Bu energiya sarfini optimallashtirish va tarmoqlardagi isroflarni kamaytirishni o'z ichiga olishi mumkin, bu esa o'z navbatida elektr stantsiyalarining samaradorligini oshiradi va elektr energiyasini ishlab chiqarish xarajatlarini kamaytiradi. Shuningdek, u ob-havo sharoiti, mavsumiy o'zgarishlar, quvvatga bo'lgan talab va boshqa omillar haqidagi ma'lumotlarni tahlil qilib, prognoz qilish va energiya ishlab chiqarishni optimallashtirishga qodir. Bu ta'minotdagi uzilishlarning oldini oladi va energiya ta'minoti barqarorligini kafolatlaydi.

Maqsad: elektr energiyasi isroflarini prognozlash energiya sotish tashkilotlari ishidagi ng muhim vazifalardan biridir. Neyron tarmoqlar katta hajmdagi ma'lumotlarni tahlil qilishni talab qiladigan muammolarni hal qilish uchun ishlatiladi. SNT yordamida elektr isroflarini bashorat qilishda asosiy muammo - ularni o'qitish uchun statistik ma'lumotlarning etishmasligi. Ushbu muammoni hal qilish uchun ma'lum hisoblash davrlari uchun elektr tarmog'ining ishlashini matematik modellashtirish natijasida olingan ma'lumotlarga asoslangan SNTni o'qitish taklif etiladi. Model tarmoq faoliyatining ma'lum umumlashtirilgan parametrlarini va uning uzoq vaqt davomida yuklanishini hisobga olgan holda yaratilgan.

Usullari: Sun'iy neyron tarmoqlardan, ayniqsa, ko'p qatlamli perseptrondan (MLP) foydalanish tarqatish tarmoqlarida elektr energiyasini isroflarni bashorat qilish muammosini hal qilishda yangi cho'qqilarni ochadi.

Natijalar: tadqiqot shuni ko'rsatdiki, ko'p qatlamli perseptronlar modelni tanlash va parametrlarni o'rnatishda vakolatli yondashuvdan foydalanish sharti bilan elektrenergija isroflarini prognoz qilish muammolarini hal qilish uchun kuchli vositadir.

Kalit so'zlari: prognoz, elektr energiyasini isroflari, 0,4 kV elektr taqsimlash tarmoqlari, sun'iy neyron tarmoqlar, matematik modellashtirish, ko'p qatlamli perseptron, faollashtirish funktsiyasi, mashinani o'rganish, neyronlar, model.

For citation: Allaev K.R., Nazirova X.Z. Comparative assessment of electricity losses in electrical networks using ANN and GMDH methods. Scientific and technical journal of Problems of Energy and Sources Saving, 2024, no. 3, pp. 1–10.

<https://doi.org/10.5281/zenodo.14032>

515

Received: 10.09.2024

Revised: 20.09.2024

Accepted: 21.10.2024

Published: 02.11.2024

Copyright: © Kaxramon R. Allaev, Xilola Z. Nazirova, 2024. Submitted to Problems of Energy and Sources Saving for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Сравнительная оценка потерь электроэнергии в электрических сетях методами ИНС и МГУА

Кахрамон Р. Аллаев^{1, a)}, Хилола З. Назирова¹

^{1, a)} академик, проф., Ташкентский государственный технический университет, Ташкент, 100095, Узбекистан; tstu_energy@mail.ru <https://orcid.org/0000-0001-6018-8912>

¹ старший преподаватель, Ташкентский государственный технический университет, Ташкент, 100095, Узбекистан; tstu_energy@mail.ru <https://orcid.org/0009-0002-7735-4862>

Актуальность: в современном мире, где технологии развиваются стремительно, искусственный интеллект (ИИ) превращается не просто в популярное направление, а в мощный инструмент способный преобразовать практически любую отрасль. Электроэнергетика, как и другие секторы экономики, не остается в стороне от этой революции. Решения на основе искусственного интеллекта помогают автоматизировать повседневные задачи, включая мониторинг состояния оборудования, прогнозирование потребления энергии, управление распределением электроэнергии и оптимизацию работы электросетей. Интеллектуальные нейронные сети (ИНС) являются одной из ключевых технологий в области искусственного интеллекта. ИИ обрабатывает большие объемы данных, что помогает выявлять скрытые закономерности и улучшать использование ресурсов. Это может включать как оптимизацию потребления энергии, так и сокращение потерь в сетях, что в свою очередь повышает эффективность работы электростанций и снижает затраты на производство электроэнергии. Он также способен анализировать данные о погодных условиях, сезонных изменениях, спросе на электроэнергию и других факторах, чтобы предсказывать потребности и оптимизировать производство электроэнергии. Это позволяет избежать перебоев в поставках и гарантировать стабильность энергоснабжения.



Цель: прогнозирование потерь электрической энергии является одной из важнейших задач в работе энергосбытовых организаций. Нейронные сети используются для решения задач, требующих анализа больших объемов данных. Основной проблемой при прогнозировании потерь электроэнергии с использованием ИНС является нехватка статистических данных для их обучения. Для решения этой проблемы, предлагается обучать ИНС на основе данных, полученных в результате математического моделирования работы электрической сети за определенные расчетные периоды. Модель создается с учетом известных обобщенных параметров функционирования сети и ее нагрузок на протяжении длительного времени.

Методы: применение искусственных нейронных сетей, особенно многослойного перцептрона (MLP), открывает новые горизонты в решении проблемы прогнозирования потерь электроэнергии в распределительных сетях.

Результаты: исследование показало, что многослойные перцептроны являются мощным инструментом для решения задач прогнозирования потерь электроэнергии при условии грамотного подхода к выбору модели и настройке параметров.

Ключевые слова: прогноз, потеря электроэнергии, распределительные электрические сети напряжением 0,4 кВ, искусственные нейронные сети, математическое моделирование, многослойный перцептрон, функция активации, машинное обучение, нейроны, модель.

Comparative assessment of electricity losses in electrical networks using ANN and GMDH methods

Kaxramon R. Allaev^{1, a)}, Xilola Z. Nazirova¹

^{1, a)} academician, prof., Tashkent State Technical University, Tashkent, 100095, Uzbekistan; tstu_energy@mail.ru <https://orcid.org/0000-0001-6018-8912>

¹ Senior Lecturer, Tashkent State Technical University, Tashkent, 100095, Uzbekistan; tstu_energy@mail.ru <https://orcid.org/0009-0002-7735-4862>

Relevance: in the modern world, where technology is developing rapidly, artificial intelligence (AI) is becoming not just a popular trend, but a powerful tool capable of transforming almost any industry. The electric power industry, like other sectors of the economy, does not remain aloof from this revolution. AI-based solutions help automate everyday tasks, including equipment health monitoring, energy consumption forecasting, power distribution management, and power grid optimization. Intelligent neural networks (ANN) are one of the key technologies in the field of artificial intelligence. AI processes large volumes of data, which helps identify hidden patterns and improve the use of resources. This can include both optimizing energy consumption and reducing losses in networks, which in turn increases the efficiency of power plants and reduces the cost of electricity production. It is also capable of analyzing data on weather conditions, seasonal changes, power demand and other factors to predict demand and optimize power production. This avoids supply interruptions and guarantees the stability of energy supply.

Aim: forecasting electrical energy losses is one of the most important tasks in the work of energy sales organizations. Neural networks are used to solve problems that require analyzing large amounts of data. The main problem when predicting electricity losses using ANNs is the lack of statistical data for their training. To solve this problem, it is proposed to train an ANN based on data obtained as a result of mathematical modeling of the operation of the electrical network for certain calculation periods. The model is created taking into account the known generalized parameters of the functioning of the network and its loads over a long period of time.

Methods: The use of artificial neural networks, especially the multilayer perceptron (MLP), opens up new horizons in solving the problem of predicting electricity losses in distribution networks.

Results: The study showed that multilayer perceptron's are a powerful tool for solving problems of predicting electricity losses, provided that a competent approach to choosing a model and setting parameters is used.

Key words: forecast, loss of electricity, 0.4 kV electrical distribution networks, artificial neural networks, mathematical modeling, multilayer perceptron, activation function, machine learning, neurons, model.

1. Введение (Introduction)

С развитием теории искусственного интеллекта и увеличением вычислительных мощностей, его применение в сфере энергетики становится все более разнообразным. Применение искусственного интеллекта в сфере энергетики открывает множество возможностей для повышения эффективности, надежности и устойчивости энергосистем. Системы на основе ИИ помогают точно прогнозировать потребление и выработку энергии, что позволяет оптимизировать работу энергосистем и снизить затраты; ИИ позволяют в реальном времени отслеживать состояние электрических сетей и оборудования, что помогает предотвратить аварии и минимизировать время простоя; используются для оптимизации работы генераторов и других элементов энергосистемы, что повышает их эффективность и продлевает срок службы. ИИ позволяет проводить предиктивное обслуживание оборудования, что помогает выявлять потенциальные проблемы до их возникновения и снижать затраты на ремонт. Эти технологии продолжают развиваться, и их внедрение становится все более актуальным в условиях растущих требований



к надежности и устойчивости энергосистем. Внедрение этих систем проводится согласно постановлению Президента Республики Узбекистан от 17 февраля 2021 года № ПП-4996 «О мерах по созданию условий для ускоренного внедрения технологий искусственного интеллекта».

Являясь одной из ключевых технологий в области искусственного интеллекта, искусственные нейронные сети представляет собой одно из наиболее перспективных направлений в области электроэнергетики. В условиях растущих требований к эффективности и надежности энергосистем, использование ИНС позволяют значительно улучшить точность прогнозов и оптимизировать управление энергопотоками, обладают способностью анализировать большие объемы данных и выявлять скрытые закономерности, что делает их идеальным инструментом для решения задач прогнозирования. В отличие от традиционных методов, ИНС могут учитывать множество факторов, влияющих на потери электроэнергии, таких как изменения нагрузки, погодные условия и техническое состояние оборудования. Это позволяет не только повысить точность прогнозов, но и своевременно выявлять потенциальные проблемы, что способствует снижению эксплуатационных затрат и повышению надежности энергосистемы.

В данной статье рассматриваются основные подходы к применению ИНС для прогнозирования потерь электроэнергии в распределительных сетях на примере многослойного перцептрона (MLP), анализируются преимущества и недостатки модели.

2. Методы и материалы (Methods and materials)

Для прогнозирования потерь электроэнергии наиболее подходящими методами искусственных нейронных сетей (ИНС) являются: Обобщенно-регрессионные нейронные сети (GRNN), рекуррентные нейронные сети (RNN), многослойные перцептроны (MLP). GRNN широко используются благодаря своей гибкости и способности моделировать сложные нелинейные зависимости, RNN особенно полезны для временных рядов, так как учитывают зависимость данных во времени. Каждый из этих методов имеет свои преимущества и может быть выбран в зависимости от конкретных условий и требований задачи. MLP обладает рядом преимуществ по сравнению с GRNN и RNN: являясь одним из самых популярных искусственных нейросетей, относится к классу ИНС прямого распространения, которая позволяет моделировать сложные нелинейные зависимости между входными и выходными данными [], относительно прост в реализации и обучении по сравнению с GRNN и RNN, которые требуют более сложных алгоритмов для учета временных зависимостей, широко используется в различных областях благодаря своей универсальности, поддерживает онлайн-обучение, что позволяет обновлять модель в реальном времени по мере поступления новых данных. Основными компонентами его архитектуры являются входной, скрытый и выходной слои, связи и веса нейронов, алгоритм обратного распространения ошибки. Входной слой принимает входные данные. В этом слое количество нейронов соответствует количеству входных признаков. Скрытый слой состоит из одного или нескольких слоев, которые находятся между входным и выходным слоями. Эти слои выполняют основную часть вычислений. Каждый нейрон в скрытом слое связан со всеми нейронами предыдущего и следующего слоев. Скрытые слои используют нелинейные функции активации, такие как ReLU (Rectified Linear Unit), сигмоида или гиперболический тангенс, чтобы моделировать сложные зависимости. Выходной слой выдает окончательный результат. Количество нейронов в выходном слое зависит от решаемой задачи. Все нейроны одного слоя связаны с нейронами следующего слоя через взвешенные связи. Веса этих связей настраиваются в процессе обучения, чтобы минимизировать ошибку прогноза. Алгоритм, используемый для обучения MLP, корректирует веса связей на основе ошибки прогноза, распространяя её обратно от выходного слоя к входному. На рисунке 1 представлена структура MLP, состоящего из 4-х скрытых слоев.

Эта структура позволяет улавливать разнообразные закономерности. При выборе структуры ИНС важно учитывать ее размерность, т.е. число скрытых слоев и число нейронов в этих слоях. При недостаточном размере сети для решения поставленной задачи ИНС будет плохо обучаться и неправильно работать, а при размере сети, превышающем сложность решаемой задачи, процесс обучения ИНС будет очень длительным или сеть вообще может быть непригодна для решения данной задачи.

Функции активации играют ключевую роль в MLP, так как они вводят нелинейность в модель, позволяя ей обучаться сложным зависимостям. Основные функции активации, используемые в MLP:

Сигмоида (Sigmoid)

$$\sigma(x) = \frac{1}{1+e^{-x}}; \quad (1)$$

Гиперболический тангенс (Tanh)

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}; \quad (2)$$

ReLU (Rectified Linear Unit)

$$\text{ReLU}(x) = \max(0, x); \quad (3)$$

Для задачи прогнозирования потерь электроэнергии наиболее подходящей функцией активации является ReLU. Это объясняется: простой в вычислении и ускорении процесса обучения, что особенно важно при работе с большими объемами данных; в отличие от сигмоиды и гиперболического тангенса, ReLU помогает избежать проблемы исчезающего градиента, что позволяет более эффективно обучать глубокие нейронные сети; эта функция хорошо справляется с задачами, где требуется моделирование сложных нелинейных зависимостей, что часто встречается в задачах прогнозирования.

Процесс обучения MLP включает несколько основных этапов: инициализация весов, прямое распространение (Forward Propagation), вычисление ошибки (Loss Calculation), обратное распространение ошибки (Backpropagation), обновление весов (Weight Update), повторение процесса прямого и обратного распространения ошибки для каждого батча данных в наборе данных. Обучение продолжается до тех пор, пока ошибка не станет достаточно малой или не будет достигнуто заданное количество эпох (итераций).

3. Результаты (Results)

На начальном этапе разработки модели количество скрытых слоев с наименьшей ошибкой в процессе лабораторной работы определилось на уровне от 1 до 5. Из графика, приведенного на рис.1 видно, что 4-слойная конфигурация скрытого слоя (10, 20, 10, 10) имеет наименьшую ошибку MAPE, равную 0,0206.

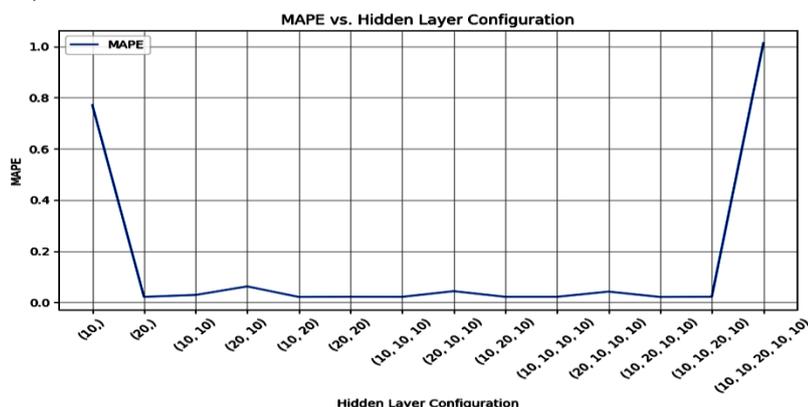


Рис.1. Конфигурация скрытого слоя

Fig.1. Hidden Layer Configuration

В результате была выбрана шестислойная структура MLP, состоящая из входного, четырех скрытых и выходного слоев (рис.2).

1-слой 2-слой 3-слой 4-слой

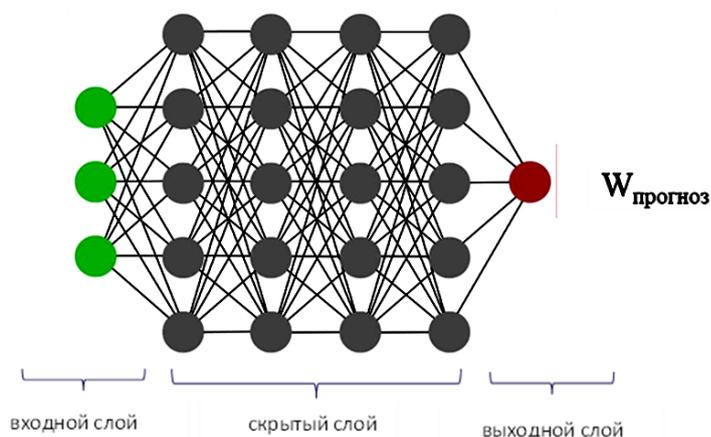


Рис.2. Структура MLP

Fig.2. MLP structure

В процессе обучения нейронная сеть проходит через несколько эпох. Зная конфигурацию скрытого слоя, изменяя количество эпох от 1 до 500, лабораторным путем определено опти-

мальное число эпох. Из графика, приведенного на рисунке 3, видно, что число эпох с наименьшей ошибкой равно 21.

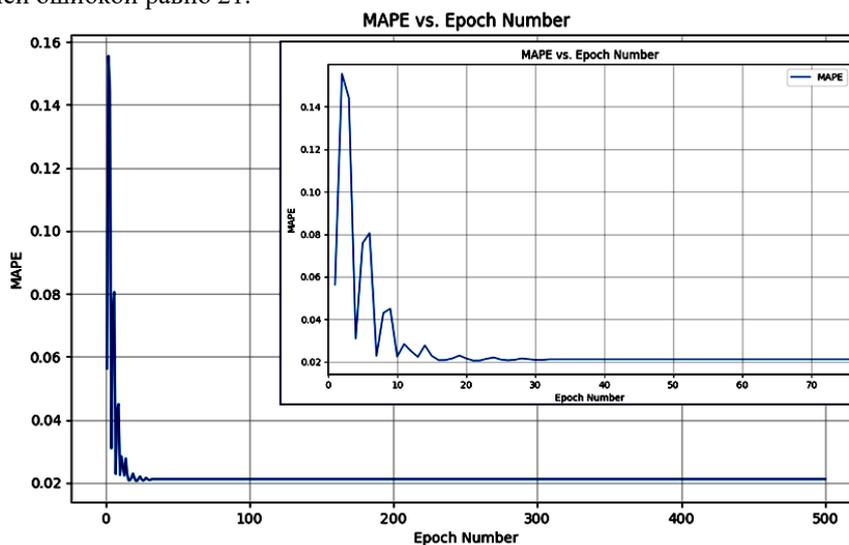


Рис.3. Определение оптимального числа эпох
Fig.3. Determining the optimal number of epochs

На каждой эпохе все данные из обучающего набора проходят через нейронную сеть один раз. Это включает в себя подачу данных на вход сети, вычисление выходных значений, оценку ошибки и коррекцию весов.

Определение количества нейронов в 4-х скрытых слоях является важным шагом при проектировании и настройке нейронной сети. Это влияет на сложность модели, её способность к обучению и обобщению, а также на скорость обучения и ресурсы, необходимые для работы сети. Выбор оптимального количества нейронов в 4-х скрытых слоях происходит на основе эмпирических экспериментов и кросс-валидации, согласно которому, изменяя количество нейронов в каждом слое от 1 до 100, с наименьшей ошибкой определяется количество нейронов, формирующих модель.

Важно найти баланс между сложностью модели (количество нейронов) и её способностью к обобщению на новые данные. На основе проведенных лабораторных экспериментов (Рис № 4-7), при MAPE 0.0206 были получены оптимальные количества нейронов в скрытых слоях соответственно:

- в первом скрытом слое составляет 68;
- во втором скрытом слое составляет 78;
- в третьем скрытом слое составляет 96;
- в четвертом скрытом слое составляет 77.

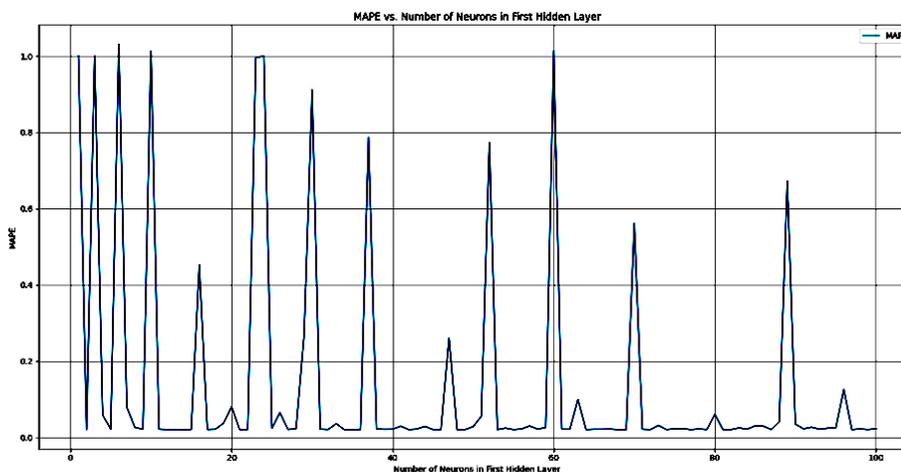


Рис.4. Определение оптимального количества нейронов в первом скрытом слое
Fig.4. Determining the optimal number of neurons in the first hidden layer

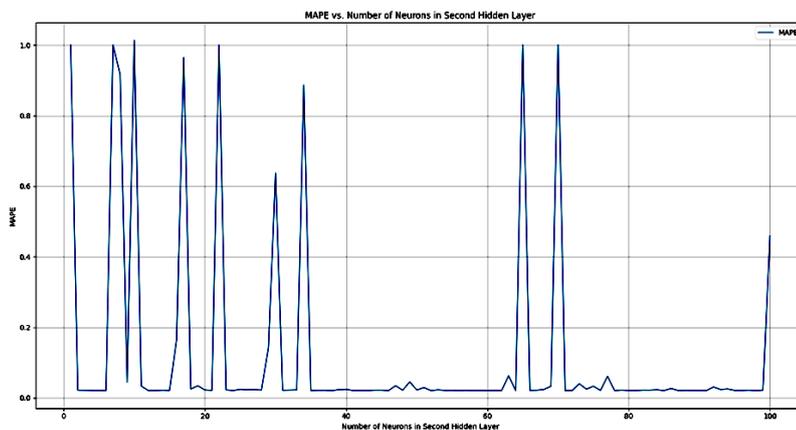


Рис.5. Определение оптимального количества нейронов во втором скрытом слое
Fig.5. Determining the optimal number of neurons in the second hidden layer

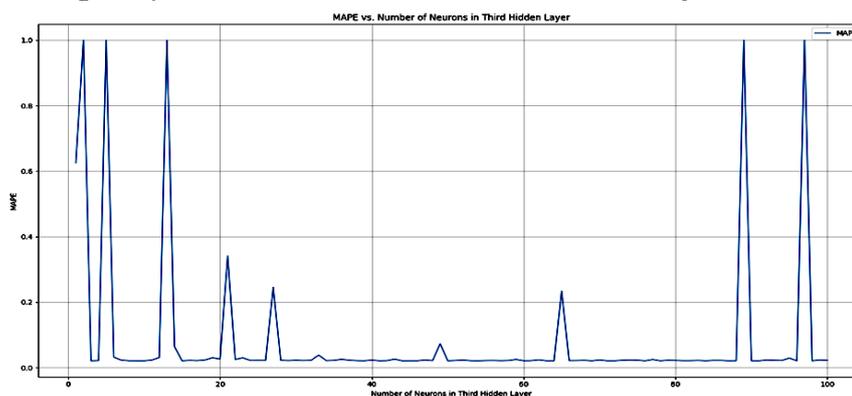


Рис.6. Определение оптимального количества нейронов в третьем скрытом слое
Fig.6. Determining the optimal number of neurons in the third hidden layer

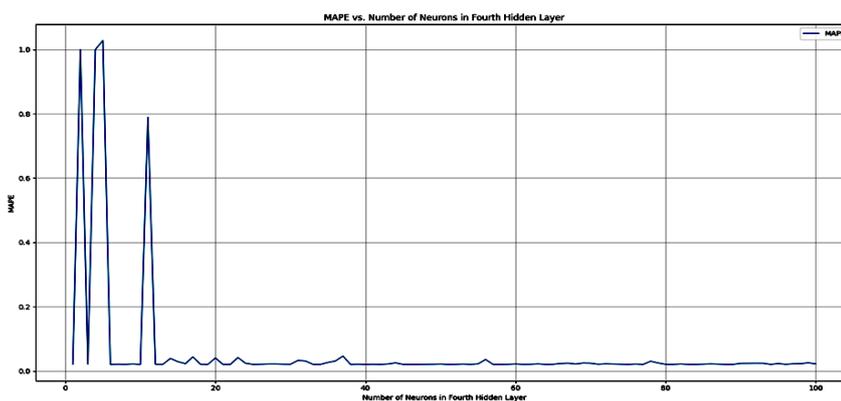


Рис.7. Определение оптимального количества нейронов в четвертом скрытом слое.
Fig.7. Determining the optimal number of neurons in the fourth hidden layer.

Таким образом, параметры, представленные в табл.1, являются лучшим исследуемым вариантом модификации модели MLP.

Таблица 1. Параметры модификации MLP
Table 1. MLP modification parameters

| | |
|--|------------------------------|
| Модель | MLP |
| Количество эпох | 21 |
| Количество слоев | 1/4/1 |
| Количество нейронов в слоях соответственно | 3/68/78/96/77/1 |
| Функция активации | ReLU (rectified linear unit) |

Графическая оценка обоснованности модели MLP, путем сравнения фактических и прогнозных данных на стадии обучения, валидации и тестирования представлена на рис.8. Небольшие отличия между фактическими и прогнозными данными подтверждают адекватность модели, что позволяет использовать её для прогнозирования потерь электроэнергии в электрических сетях.

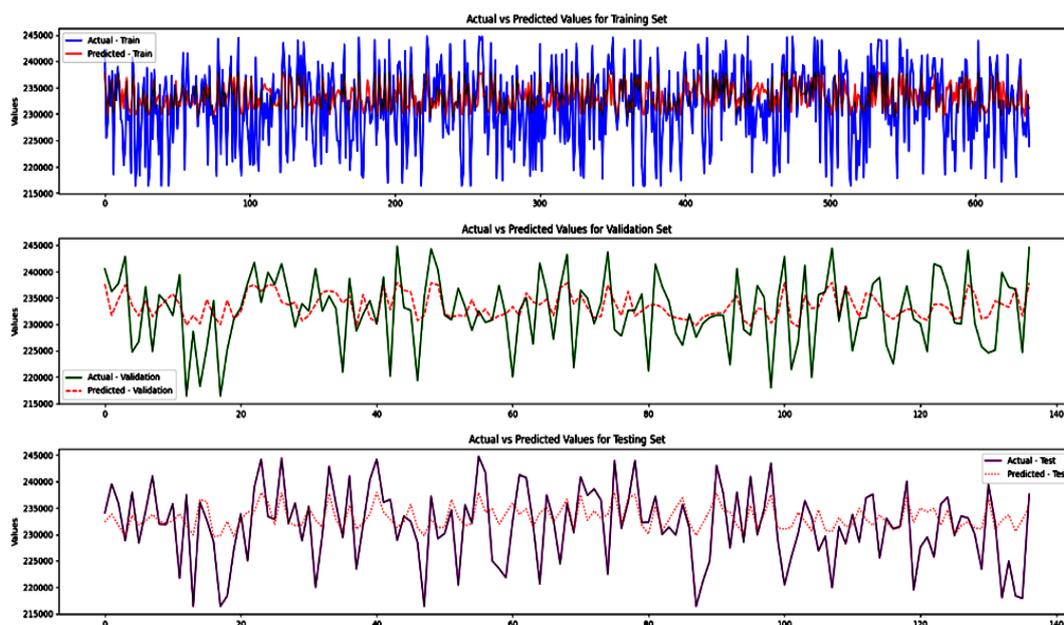


Рис.8. Графики оценки обоснованности модели MLP на стадии обучения, валидации и тестирования

Fig.8. Graphs for assessing the validity of the MLP model at the training, validation and testing stages

В совокупности все три графика дают полную картину о точности и надежности модели на обучающей, валидационной и тестовой выборках.

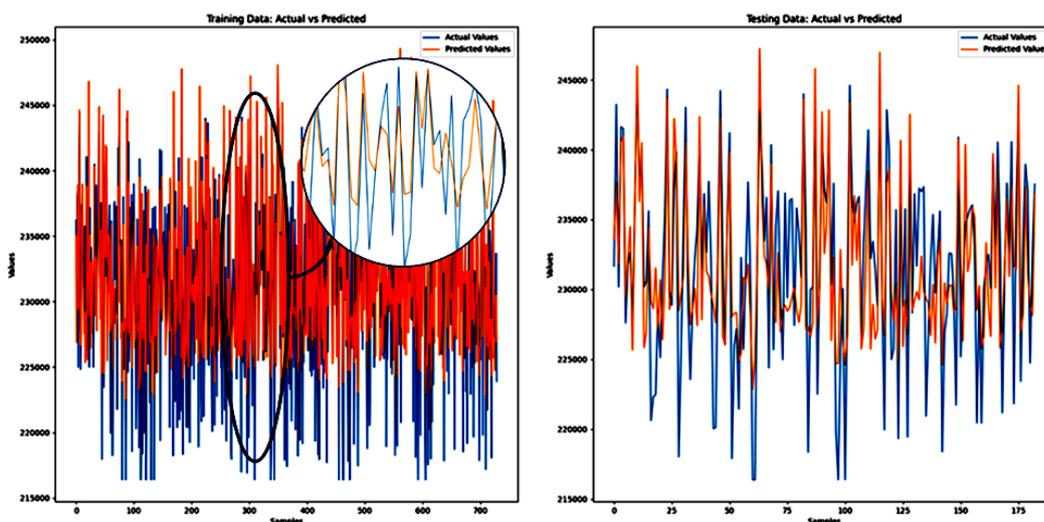


Рис.9. Графики оценки обоснованности модели МГУА на стадии обучения и тестирования

Fig.9. Graphs for assessing the validity of the GMDH model at the training and testing stage

Сравнительный анализ приведенных выше графиков оценки обоснованности моделей MLP и МГУА позволяет понять, насколько хорошо модель MLP справляется с прогнозом данных, как хорошо она обобщает новые данные, и насколько точен ее прогноз для новых данных в сравнении с МГУА.

Исследование показало, что многослойные перцептроны являются мощным инструментом для решения задач прогнозирования потерь электроэнергии.



4. Обсуждение (Discussion)

В данной статье была представлена модель многослойного персептрона для прогнозирования потерь электроэнергии в распределительных сетях. Полученные результаты демонстрируют высокую точность прогноза модели. При средней абсолютной ошибке в 2% была получена полная картина о точности и надежности модели, что свидетельствует о способности модели эффективно прогнозировать потери электроэнергии. Необходимо также отметить ряд перспектив дальнейших исследований. Дальнейшие исследования могут быть направлены на увеличение объема данных для повышения точности модели. Исследования могут включать анализ более сложных архитектур MLP в сочетании с архитектурами других ИНС, таких как рекуррентные нейронные сети (RNN), исследование других функций активации, таких как Sigmoid или Tanh, может привести к улучшению точности прогнозирования. Модель может быть использована для разработки системы раннего оповещения о потенциальных проблемах с потерями электроэнергии, что позволит своевременно принимать меры по их предотвращению.

В целом, представленная модель MLP демонстрирует перспективность использования нейронных сетей для прогнозирования потерь электроэнергии в распределительных сетях. Дальнейшие исследования, направленные на преодоление существующих ограничений и реализацию перечисленных перспектив, могут привести к созданию высокоэффективных систем управления потерями электроэнергии.

5. Заключение (Conclusion)

В ходе исследования была разработана и протестирована модель MLP для прогнозирования потерь электроэнергии в распределительных сетях. Архитектура модели включала один входной слой с 3 нейронами, четыре скрытых слоя с 68, 78, 96 и 77 нейронами соответственно, и один выходной слой с 1 нейроном. Для активации нейронов использовалась функция ReLU, а обучение модели проводилось на протяжении 21 эпохи. После завершения обучения модель показала высокую точность прогнозирования. Средняя абсолютная ошибка (MAPE) на тестовой выборке составила 0.02, что свидетельствует о высокой точности модели прогнозирования. График сходимости обучения показал, что модель достигла стабильного уровня ошибки уже к 21-й эпохе, после чего улучшения были минимальными. Это указывает на эффективное обучение модели и отсутствие переобучения. Анализ важности признаков показал, что наиболее значимыми факторами для прогнозирования потерь электроэнергии являются активная мощность, температура окружающей среды и влажность воздуха. Эти факторы оказали наибольшее влияние на выходные значения модели. Сравнение с традиционными методами прогнозирования, такими как полиномиальная регрессия, ARIMA и метод группового учета аргументов показало, что модель MLP превосходит их по точности и стабильности прогнозов.

Модель MLP, представленная в исследовании, демонстрирует значительный потенциал применения нейронных сетей для прогнозирования потерь электроэнергии в распределительных сетях. Это открытие открывает новые возможности для оптимизации энергопотребления и повышения эффективности работы энергетических систем.

СПИСОК ЛИТЕРАТУРЫ

1. Постановление Президента Республики Узбекистан от 17 февраля 2021 года № ПП-4996 «О мерах по созданию условий для ускоренного внедрения технологий искусственного интеллекта».
2. Постановление Президента Республики Узбекистан от 13 июля 2016 года № ПП-2559 «О мерах по дальнейшему совершенствованию научно-технической деятельности в сфере электроэнергетики».
3. Указ Президента Республики Узбекистан от 1 февраля 2019 г. № УП-5646 «О мерах по коренному совершенствованию системы управления топливно-энергетической отраслью Республики Узбекистан».
4. СТРАТЕГИЯ развития распределительных электрических сетей в Республике Узбекистан до 2025 года
5. Аллаев К.Р. “Электроэнергетика Узбекистана и мира” –Т.:Fan va texnologiya. 2009.-464 с.
6. Аллаев К.Р. Современная энергетика и перспективы ее развития. – Т.: Fan va texnologiyalar nashriyot-matbaa uyi. 2021. 952 с.
7. Kh.Z.Nazirova. E3S Web of Conferences 384, 01046 (2023) <https://doi.org/10.1051/e3sconf/202338401046> RSES 2022.
8. Nazirova Khilola. E3S Web of Conferences 497, 01005 (2024) <https://doi.org/10.1051/e3sconf/202449701005> .



9. Hilola Nazirova AIP Conf. Proc. 3152, 030013 (2024) <https://doi.org/10.1063/5.0218854>.
10. Худаяров М. Б., Сухенёв Р.А. Структура потерь электроэнергии в электрических сетях узбекистана. <https://doi.org/10.5281/zenodo.6702360>.
11. Назирова Х.З. Искусственные нейронные сети для оценки потерь активной мощности в распределительных сетях 6-10 кв. Журнал «Интернаука» № 22 (245), 2022 г. –С.8.
12. Назирова Х.З., Бадалова Д.А. Прогнозирование пикового потребления электроэнергии с помощью подходов ARIMA, LSTM, GRU, ARIMA-LSTM и ARIMA-GRU.
13. Х.З. Назирова, О.З. Назирова. Оценка потерь электроэнергии в распределительных сетях 10/0,4 кВ. //Проблемы энерго- и ресурсосбережения .2023 г 4выпуск. –С. 189.
14. Х.З.Назирова. Методы прогнозирования в энергетике энергоэффективность и энергосбережение. –С.193.
15. X.Z.Nazirova., O.Z.Nazirova., Sh.A.Abdunazarov.. A novel probabilistic method for energy loss estimation using minimal line current information. <https://t.me/openscholar> Multidisciplinary Scientific Journal April, 2023.
16. Multi-Layer Perceptron-Based Classification with Application to Outlier Detection in Saudi Arabia Stock Returns Khudhayr A. Rashedi 1,* , Mohd Tahir Ismail 2 , Sadam Al Wadi 3, Abdeslam Serroukh 4, Tariq S. Alshammari 1 and Jamil J. Jaber 3,5 Journal of Risk and Financial Management
17. Чернецов В.И., Казаковский Е.Н. Прогнозирование потребления электрической энергии с использованием нейронных сетей.
18. Can Ding Yiyuan Zhou* Qingchang Ding Zhenyi Wang. Loss Prediction of Ultrahigh Voltage Transmission Lines Based on EEMD–LSTM–SVR Algorithm Volume 10 - 2022 | <https://doi.org/10.3389/fenrg.2022.811745>.
19. Рахмонов И.У., Курбонов Н.Н. Прогнозирование электропотребления промышленных предприятий с помощью модели авторегрессии проинтегрированного скользящего среднего // Вестник МЭИ. 2021. № 6. С. 11—19. DOI: 10.24160/1993-6982 2021-6-11-19.
20. <https://wiki.loginom.ru/articles/multilayered-perceptron.html>.
21. <https://minenergy.uz/en/lists/view/22>.

REFERENCES

1. Resolution of the President of the Republic of Uzbekistan dated February 17, 2021 No. PP-4996 “On measures to create conditions for the accelerated implementation of artificial intelligence technologies.
2. Resolution of the President of the Republic of Uzbekistan dated July 13, 2016 No. PP-2559 “On measures to further improve scientific and technical activities in the field of electric power industry.
3. Decree of the President of the Republic of Uzbekistan dated February 1, 2019 No. UP-5646 “On measures to radically improve the management system of the fuel and energy industry of the Republic of Uzbekistan.
4. STRATEGY for the development of electrical distribution networks in the Republic of Uzbekistan until 2025.
5. K.R. Allaev “Electric power industry of Uzbekistan and the world” - T.: “Fan va texnologiya” 2009.-464 p.
6. K.R. Allaev “Modern energy and prospects for its development” – T.: “Fan va texnologiyalar nashriyot-matbaa uyi” 2021. 952 pp.
7. Kh.Z.Nazirova. E3S Web of Conferences 384, 01046 (2023) <https://doi.org/10.1051/e3sconf/202338401046> RSES 2022.
8. Nazirova Khilola. E3S Web of Conferences 497, 01005 (2024) <https://doi.org/10.1051/e3sconf/202449701005>.
9. Hilola Nazirova AIP Conf. Proc. 3152, 030013 (2024) <https://doi.org/10.1063/5.0218854>
10. Khudayarov M. B., Sukhenev R. Structure of electricity losses in electric networks of Uzbekistan a. <https://doi.org/10.5281/zenodo.6702360>.
11. Nazirova Kh.Z Artificial neural networks for assessing active power losses in 6-10 kV distribution networks. Journal "Interscience" No. 22 (245), 2022 Page 8.
12. Nazirova Kh.Z., Badalova D.A. Forecasting peak electricity demand using ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU approaches.
13. H.Z. Nazirova, O.Z. Nazirova. Assessment of electric energy losses in 10/0.4 kv distribution networks problems of energy and resource saving .2023, 4th issue p. 189.
14. H.Z. Nazirova. Methods of forecasting in energy energy efficiency and energy saving p.193.
15. X.Z.Nazirova., O.Z.Nazirova., Sh.A.Abdunazarov. A novel probabilistic method for energy loss estimation using minimal line current information. <https://t.me/openscholar> Multidisciplinary Scientific Journal April, 2023.



16. Khudhayr A. Rashedi 1,* , Multi-Layer Perceptron-Based Classification with Application to Outlier Detection in Saudi Arabia Stock Returns Mohd Tahir Ismail 2 , Sadam Al Wadi 3, Abdeslam Ser-roukh 4, Tariq S. Alshammari 1 and Jamil J. Jaber 3.5 *Journal of Risk and Financial Management*.
17. Chernetsov V.I., Kazakovsky E.N. Forecasting electrical energy consumption using neural networks.
18. Can DingYiyuan Zhou* Qingchang Ding Zhenyi Wang. Loss Prediction of Ultrahigh Voltage Transmission Lines Based on EEMD–LSTM–SVR Algorithm Volume 10 - 2022 | <https://doi.org/10.3389/fenrg.2022.811745>.
19. Rakhmonov I.U., Kurbonov N.N. Forecasting power consumption of industrial enterprises using an autoregressive integrated moving average model //Bulletin of MPEI. 2021. No. 6. P. 11-19. DOI: 10.24160/1993-6982 2021-6-11-19.
20. <https://wiki.loginom.ru/articles/multilayered-perceptron.html>.
21. <https://minenergy.uz/en/lists/view/22>.