

УДК 621.316.13:621.3.016.3

EDN GVYJCK

## КРАТКОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ ГРАФИКА ЭЛЕКТРИЧЕСКОЙ НАГРУЗКИ В МИКРОЭНЕРГОСИСТЕМЕ

**А.А. Лоскутов**

ORCID: 0000-0003-2228-596X e-mail: loskutov\_aa@nntu.ru

Нижегородский государственный технический университет им. Р.Е. Алексеева  
*Нижний Новгород, Россия*

**С.А. Жаренков**

ORCID: 0009-0000-5166-6580 e-mail: sema.661@mail.ru

Нижегородский государственный технический университет им. Р.Е. Алексеева  
*Нижний Новгород, Россия*

**А.С. Симанов**

ORCID: 0009-0000-2710-7674 e-mail: simadex@yandex.ru

Нижегородский государственный технический университет им. Р.Е. Алексеева  
*Нижний Новгород, Россия*

Современные автономные гибридные электроэнергетические комплексы, основанные на возобновляемых энергоресурсах (ветер, солнце), составляют основу интенсивно развивающейся распределенной генерации. Для таких микроэнергосистем характерна неравномерность выработки электроэнергии из-за влияния внешних факторов (скорость ветра, сила солнечного излучения). Для обеспечения системного баланса производства и потребления электрической энергии, эффективности управления мощностью, экономии энергии, снижения издержек производства, оптимизации тарифной политики важно прогнозирование потребления электроэнергии и моделирование графиков изменения нагрузки. Прогнозные данные способствуют повышению экономических и социальных показателей микроэнергосистемы, обеспечив более надежное и бесперебойное энергоснабжение потребителей. В статье рассмотрен один из наиболее распространенных и эффективных методов прогнозирования электрической нагрузки с учетом различных факторов (время суток, дни недели и праздники) – нейронная сеть с обратным распространением ошибки, обучающаяся на исторических данных. В ходе исследования был использован программный комплекс *Matlab*, включающий возможности визуализации данных, моделирования и работы с нейронными сетями. Произведена оценка эффективности различных видов прогнозов электрической нагрузки.

**Ключевые слова:** искусственная нейронная сеть, микроэнергосистема, прогнозирование графика нагрузки, электропотребление, электроснабжение, *Matlab*.

Для цитирования: Лоскутов А.А., Жаренков С.А., Симанов А.С. Краткосрочное прогнозирование графика электрической нагрузки в микроэнергосистеме // Интеллектуальная Электротехника. 2024. № 3. С. 34-55. EDN GVYJCK

## SHORT-TERM FORECASTING OF ELECTRIC LOAD SCHEDULE IN MICROGRID

**A.A. Loskutov**

ORCID: 0000-0003-2228-596X e-mail: loskutov.nnov@gmail.com

Nizhny Novgorod State Technical University n.a. R.E. Alekseev  
*Nizhny Novgorod, Russia*

**S.A. Zharenkov**

ORCID: 0009-0000-5166-6580 e-mail: sema.661@mail.ru

Nizhny Novgorod State Technical University n.a. R.E. Alekseev  
*Nizhny Novgorod, Russia*

**A.S. Simanov**

ORCID: 0009-0000-2710-7674 e-mail: simadex@yandex.ru

Nizhny Novgorod State Technical University n.a. R.E. Alekseev  
*Nizhny Novgorod, Russia*

**Abstract.** Modern autonomous hybrid power complexes based on renewable energy resources (wind, solar) form the basis of intensively developing distributed generation. Such micro-power systems are characterized by uneven power generation due to the influence of external factors (wind speed, solar radiation strength). To ensure a system balance of electricity production and consumption, efficiency of capacity management, energy saving, reduction of production costs, and optimization of tariff policy, it is important to forecast electricity consumption and model load change schedules. Forecast data contribute to improving the economic and social performance of the microgrid, providing a more reliable and uninterrupted power supply to consumers. The article considers one of the most common and effective methods of forecasting electric load taking into account various factors (weather, time of day, days of the week and holidays) – a neural network with back propagation of error trained on historical data. Matlab software package was used during the research, which includes data visualization, modeling and neural network capabilities. The efficiency of different types of electric load forecasts was evaluated.

**Keywords:** artificial neural network, load schedule forecasting, Matlab, microgrid, power consumption, power supply.

**For citation:** A.A. Loskutov, S.A. Zharenkov and A.S. Simanov, “Short-term forecasting of electric load schedule in microgrid”, *Smart Electrical Engineering*, no. 3, pp. 34-55, 2024. EDN GVYJCK

## 1. Введение

Прогнозирование потребления электроэнергии и моделирование точного графика нагрузки играют важную роль для электроснабжения потребителей в микроэнергосистемах с объектами распределенной генерации, а повышение точности прогнозов нагрузки не только позволяет более эффективно управлять мощностью, но также способствует экономии энергии и снижению издержек производства [1-4]. Эти улучшения, в свою очередь, могут значительно повысить как экономические, так и социальные показатели энергосистемы, обеспечив более надежное и бесперебойное энергоснабжение потребителей.

Искусственные нейронные сети являются мощным инструментом для моделирования нелинейных зависимостей с высокой точностью [5-8]. Они способны адаптироваться к большому объему неструктурированных данных и извлекать полезную информацию методом самообучения. Это делает их эффективным инструментом для прогнозирования электрической нагрузки с учетом различных влияющих факторов. В частности, нейронные сети могут учитывать погодные условия, время суток, дни недели, праздники и другие переменные, влияющие на потребление электроэнергии. Такой подход позволяет получать более точные прогнозы нагрузки по сравнению с традиционными статистическими методами. Это, в свою очередь, имеет важное значение для оптимизации процессов в энергосистемах.

С ускоренным развитием возобновляемых источников энергии, таких как солнечные и ветровые электростанции, актуальность точных прогнозов электрической нагрузки возрастает, особенно в контексте микроэнергосистем. Это связано с нестабильностью генерации электроэнергии из-за изменчивости первичных источников энергии – солнца и ветра. Надежные прогнозы нагрузки играют ключевую роль в оптимизации процессов в таких энергосистемах [9-12].

Для исследования прогнозирования электропотребления в микроэнергосистеме использован инструментальный программного комплекса *Matlab* с встроенной функцией *Neural Network Training (nntraintool)*, включающий возможности визуализации данных, моделирования и работы с нейронными сетями, что позволило оценить ее эффективность для различных видов прогнозов электрической нагрузки [1].

## II. Сравнение различных методов прогнозирования

Методы прогнозирования нагрузки делятся на три категории: традиционные, модифицированные и основанные на мягких вычислениях [13].

*Традиционные методы прогнозирования.*

1. Подход «похожий день» [14] идентифицирует исторические дни с аналогичными характеристиками (погода, день недели) для прогнозируемого дня. Прогноз нагрузки осуществляется путем линейной комбинации

или регрессионного анализа этих похожих дней. Анализ тенденций предыдущих лет также используется для прогнозирования.

2. Методы регрессии устанавливают математические зависимости между электрической нагрузкой и влияющими параметрами (погода, праздничные дни, температура, влажность, тип потребителя). Различные регрессионные модели описаны в литературе [15].

3. Экспоненциальное сглаживание, широко применяемое благодаря своей надежности и точности, использует предыдущие данные для прогнозирования будущей нагрузки. В [16] разработана модель экспоненциального сглаживания для почасового прогноза нагрузки на интервале в одну неделю вместо отдельной модели для будних и выходных дней.

*Модифицированные методы прогнозирования.*

1. Адаптивное прогнозирование нагрузки. Параметры модели прогнозирования нагрузки автоматически корректируются в зависимости от меняющихся погодных условий, что делает ее адаптивной. Литература содержит множество моделей, основанных на адаптивном прогнозировании спроса [17].

2. Машины опорных векторов (*SVM*) – это самый мощный и новейший метод решения задач классификации и регрессии. Этот подход был представлен статистической теорией обучения Вапника. *SVM* преобразует входное пространство в многомерное пространство признаков посредством нелинейного отображения, а затем решает задачу линейной разделимой классификации в этом пространственном признаке. Предлагается ряд моделей на основе *SVM* [18].

*Методы прогнозирования на основе мягких вычислений.*

Появление методов искусственного интеллекта привело к появлению концепции прогнозирования нагрузки на основе мягких вычислений. Для прогнозирования электрической нагрузки предложены нечеткая логика, экспертные системы и нейронные сети.

1. Нечеткая логика не требует математического выражения входных и выходных данных. В прогнозе нечеткой логики данные прошлой нагрузки используются для обучения входных данных, а выходной шаблон генерируется после дефазификации. Применения нечеткой логики для прогнозирования электрической нагрузки описаны в [19].

2. Искусственные нейронные сети (ИНС) применяются для прогнозирования электрических нагрузок с 1992 г. [20]. ИНС имеют линейную или нелинейную математическую функцию между входной и выходной переменной. Они обычно состоят из взаимосвязанных слоев, а временная обратная связь используется для повышения точности модели.

3. Экспертные системы, основанные на знаниях, заменяют правила и процедуры, используемые людьми-экспертами, программным обеспечением

нием в конкретной области для прогнозирования нагрузки. Экспертная система была введена в 1960-х гг. Это методы, основанные на правилах, в которых правила разрабатываются экспертами людьми. Этот подход был впервые разработан Рахманом и Бхатнагаром.

Модели на основе ИНС является наиболее популярным и перспективным для прогнозирования нагрузки из-за его адаптируемого характера и контролируемого метода обучения по набору данных. Недостаток состоит в том, что он не может определить математическое выражение между зависимыми и независимыми переменными. Модель ИНС имеет лучшую точность по сравнению с традиционными методами прогнозирования.

### **III. Прогнозирование потребления электрической энергии методом ИНС**

#### *Обучение искусственной нейронной сети*

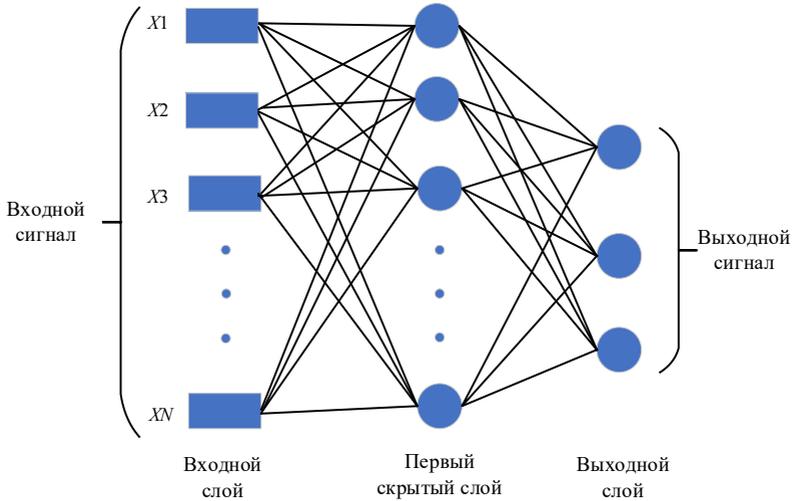
Обратная передача ошибки относится к методам обучения с учителем, что на практике означает необходимость наличия целевых значений в обучающих наборах данных. Данный подход является одним из самых популярных. Суть метода заключается в реализации двух этапов:

- 1) прямой этап – выходные сигналы движутся вперед, в результате получаем выходной сигнал, на основе которого затем считается величина ошибки;
- 2) обратный этап – обратная передача ошибки: величина ошибки движется назад, в результате происходит корректировка весовых коэффициентов связей сети [2].

Многослойный перцептрон (МП) является примером ИНС, которая активно применяется при решении различных задач, включая обнаружение и классификацию образов. Он представляет собой развитие идеи однослойного перцептрона и успешно преодолевает его ограничения (рис. 1).

Скрытые нейроны играют значительную роль в работе многослойного перцептрона, осуществляя нелинейное преобразование входных данных в новое пространство.

Особенностью МП является отсутствие доступа к ошибке на выходе скрытых нейронов, что представляет основную трудность. Разработка эффективного алгоритма обучения, способного настраивать веса синапсов со скрытыми нейронами, является важным аспектом. Эта проблема эффективно решается с использованием алгоритма обратного распространения ошибки, который обеспечивает эффективный метод обучения для многослойного перцептрона.



**Рис. 1. Иллюстрация многослойного перцептрона**

**Fig. 1. Illustration of a multilayer perceptron**

*Алгоритм обратного распространения ошибки*

Алгоритм можно обобщить в виде следующих шагов (напомним, что необходимо предварительно определить топологию сети):

- 1) начальная установка, когда синаптические веса выбираются случайным образом;
- 2) использование обучающей выборки данных, прямое распространение обучающего набора и вычисление ошибки на выходе сети;
- 3) обратное распространение ошибки от выходного слоя к первому, с получением локального градиента для каждого нейрона;
- 4) обновление всех весов с использованием формулы коррекции ошибки:

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} = \eta \delta_j^j(n) \times V_i^j(n), \quad (1)$$

где  $\eta$  – скорость обучения;  $\frac{\partial E(n)}{\partial w_{ji}(n)}$  – градиент функции стоимости  $E(n)$  с учетом синаптического веса  $w_{ij}(n)$ .

- 5) повторение процесса с шага 2 до достижения требуемого качества.

Представленный выше алгоритм описывает обновление весов от выборки к выборке, но нейронная сеть может использовать алгоритм пакетного обучения. При пакетном обучении все обучающие выборки распространяются вперед, а затем вычисляется средняя квадратичная ошибка по всем обучающим выборкам. Затем эта ошибка распространяется назад и используется для обновления весов для определенного периода обучения. Таким образом, с помощью алгоритма пакетного обучения веса обновляются от периода к периоду. Прямое и обратное распространение через сеть во время работы алгоритма показано на рис. 2.

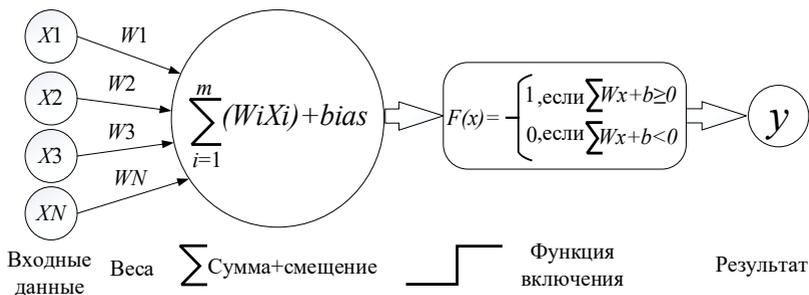


Рис. 2. Модель нейронной сети с обратным распространением

Fig. 2. Neural network model with back propagation

Алгоритм обратного распространения является управляемым методом обучения, который передает ошибки выхода обратно на скрытые нейроны, позволяя регулировать веса во всей многослойной нейронной сети с фиксированной архитектурой, с целью минимизации соответствующей функции стоимости. Для передачи ошибок на скрытые нейроны применяется градиентный метод, что требует дифференцируемости функций активации нейронов.

Чтобы обеспечить дифференцируемость, часто используют семейство непрерывных функций, приближающих ступенчатую функцию. Одним из популярных представителей таких функций является семейство сигмоидных функций. Примером сигмоидной функции является логистическая функция (рис. 3).

Логистическая функция имеет вид:

$$f(x) = \frac{1}{1 + e^{-ax}}, \quad (2)$$

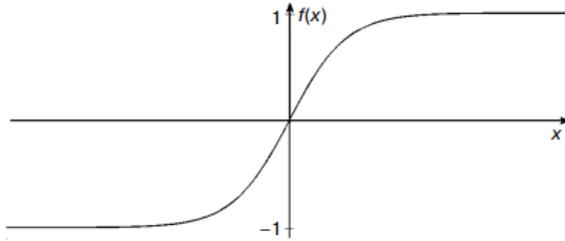


Рис. 3. Функция гиперболического тангенса

Fig. 3. Hyperbolic tangent function

Она хорошо подходит для роли функции активации благодаря своим свойствам:

- 1) принимает значения от 0 до 1, что удобно для интерпретации как вероятности;
- 2) дифференцируема, что важно для алгоритма обратной передачи ошибки;
- 3) монотонно возрастает, обеспечивая желательную нелинейность между слоями.

Использование логистической функции позволяет эффективно настраивать веса сети с помощью алгоритма обратной передачи ошибки и достигать хороших результатов при решении различных задач классификации и прогнозирования [6].

#### *Настраиваемые параметры ИНС*

1. Количество нейронов в каждом сетевом слое.

Количество узлов на входе и выходе тесно связано с набором данных.

Экспериментальным путем было выявлено оптимальное число элементов на входе, равное 24 и соответствующее количеству часов в сутках, а на выходе – 1, дающее прогноз на каждый час.

На практике можно определить количество нейронов в скрытом слое с помощью следующей эмпирической формулы:

$$i = \sqrt{(n + m) + a}, \quad (3)$$

где  $i$  – это количество нейронов в скрытом слое,  $n$  – количество нейронов входного слоя,  $m$  – количество нейронов в выходном слое,  $a$  – постоянная величина и она находится в пределах  $1 < a < 10$ .

Подобный подход позволяет получить приблизительное, но достаточное для большинства задач количество нейронов в промежуточном скрытом слое нейронной сети.

2. Настройка весов между скрытым слоем  $J$  и выходным слоем  $P$ .

В алгоритме обратного распространения регулирования и выход весов относится к частному дифференциалу, который выражается следующей формулой [2]:

$$\frac{fE(n)}{fw_{ji}(n)} = e_{kp}(n) \times f(u_p^p(n)) \times v_j^j(n), \quad (4)$$

Локальный градиент определяется как:

$$\delta_p^p(n) = -\frac{fE(n)}{fu_p^p(n)} = e_{kp}(n) \times f(u_p^p(n)), \quad (5)$$

Значение итерации  $w_{jp}(n)$  между скрытым слоем  $J$  и выходным слоем  $P$  рассчитывается по следующей формуле:

$$w_{jp}(n+1) = w_{jp}(n) + \Delta w_{jp}(n), \quad (6)$$

### 3. Настройка весов между скрытым слоем $I$ и скрытым слоем $J$ .

Подобно вышеизложенному, регулирование весов между скрытым слоем  $I$  и скрытым слоем  $J$  также осуществляется с помощью движения вдоль градиента (градиентный спуск). Значение этого регулирования равно следующей формуле:

$$\Delta w_{jp}(n) = -\eta \frac{\partial E(n)}{\partial w_{ij}(n)} = \eta \delta_j^j(n) \times V_i^i(n), \quad (7)$$

Локальный градиент определяется как:

$$\delta_j^j(n) = -\frac{fE(n)}{fu_j^j(n)} = -\frac{fE(n)}{fV_j^j(n)} \times \frac{fV_j^j(n)}{fu_j^j(n)} = \frac{fE(n)}{fV_j^j(n)} \times f(u_j^j(n)), \quad (8)$$

Значение итерации между скрытым слоем  $I$  и скрытым слоем  $P$  рассчитывается по следующей формуле:

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n), \quad (9)$$

$$\Delta w_{mi}(n) = \eta \delta_i^i(n) \times x_{im}(n), \quad (10)$$

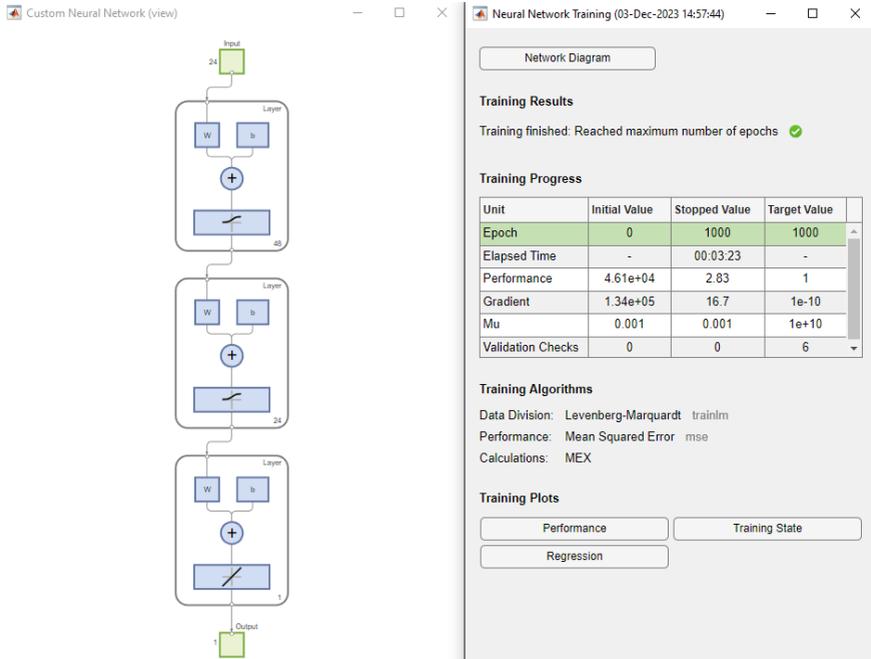
Локальный градиент определяется [1]:

$$\delta_i^l(n) = f(u_i^l(n)) \times a_{j=1}^{oJ} \delta_j^J(n) w_m(n). \quad (11)$$

*Использование инструментария Matlab для обучения ИНС с алгоритмом обратного распространения ошибки*

На рис. 4 изображено интерфейсное меню *Neural Network Training*, а также диаграмма нейронной сети с внутренними слоями. Значение отображаемых параметров обучения представлено в табл. 1.

Конфигурация ИНС содержит два скрытых слоя, в первом из которых 48 нейронов, а во втором 24 нейрона, что было определено методом эмпирической оптимизации путем тестирования различных вариантов архитектуры ИНС с целью достижения наилучших результатов обучения и для обеспечения баланса между вычислительной сложностью модели и качеством регрессии.



**Рис. 4. Интерфейсное меню Neural Network Training**

**Fig. 4. Neural Network Training interface menu**

Таблица 1.  
Значения отображаемых параметров в Neural Network Training

Table 1.  
Values of displayed parameters in Neural Network Training

№	Параметр	Значение
1	<i>Epoch</i>	количество итераций
2	<i>Elapsed time</i>	пройденное время обучения
3	<i>Perfomance</i>	величина ошибки обучения
4	<i>Gradient</i>	отвечает за корректировку весов связей между нейронами
5	<i>Mu</i>	отвечает за скорость обучения ИНС
6	<i>Validation Cheks</i>	отвечают за контроль переобучения и оценку генерализации модели
7	<i>Data Division</i>	метод тренировки ИНС
8	<i>Calculations</i>	отвечает за обратное распространение ошибки

*Подготовка и обработка экспериментальных данных для обучения*

Количество узлов на входе, выходе и в скрытом слое нейронной сети зависит от сложности объекта, который необходимо описать моделью. В рамках данной исследовательской задачи для тестовой выборки данных можно использовать модель потребления электроэнергии, построенную в среде *Matlab*, либо воспользоваться уже существующей базой статистических данных о потреблении в микроэнергосистеме. Это позволит обеспечить необходимый объем информации для обучения и тестирования нейронной сети, а также оценки качества построенной модели прогнозирования электрической нагрузки.

Исходные данные потребления активной мощности ( $P$ , кВт) в микроэнергосистеме за выбранные дни недели (например, понедельники одного месяца) с характерным и схожим режимом потребления представлены в табл. 2. В *Matlab*, исходные данные представляются в виде *Excel*-таблицы, содержащей данные за предыдущие 7 дней (Н1-Н7), чтобы обеспечить удобство для дальнейшей обработки и анализа. Объем полученной таким образом обучающей выборки равен 168 значений.

Задачей исследования является прогнозирование потребления на восьмой характерный день (Н0), (на следующий понедельник) и валидация полученных результатов с данными реального потребления за этот день, отраженными в табл. 2.

Исходные данные были взяты с модели микроэнергосистемы с объектом распределенной генерации одного из промышленных предприятий.

Таблица 2.  
Исходные данные, почасовая нагрузка за пять характерных дней

Table 2.  
Initial data, hourly load for four typical days

	H7	H6	H5	H4	H3	H2	H1	H0
	Данные для обучения и тестирования							Данные реальной нагрузки
Время, ч	P, кВт							
0:00	206,2	213,4	191,6	178,1	182,3	186,0	176,9	206,2
1:00	203,3	208,8	186,9	174,3	179,3	180,3	171,7	203,3
2:00	197,4	208,1	185,3	169,8	177,0	181,3	170,7	197,4
3:00	197,7	206,1	185,5	175,7	176,6	179,2	171,8	197,7
4:00	201,6	207,5	189,1	178,8	178,5	177,4	173,5	201,6
5:00	209,3	216,6	193,9	188,2	185,5	188,6	178,1	209,3
6:00	223,2	232,7	208,1	200,3	200,7	203,5	194,0	223,2
7:00	236,0	248,8	224,3	214,8	217,6	222,0	207,9	236,0
8:00	251,8	263,8	238,6	231,6	231,9	239,6	223,4	251,8
9:00	257,3	272,1	243,1	237,7	229,1	246,1	229,5	257,3
10:00	256,2	272,5	240,9	239,3	233,9	244,5	229,0	256,2
11:00	251,4	261,3	235,1	234,3	232,9	241,2	227,3	251,4
12:00	255,3	248,2	234,4	234,7	229,9	238,7	228,0	255,3
13:00	256,5	247,0	235,1	234,5	231,8	234,7	228,7	256,5
14:00	258,3	241,7	233,7	231,4	231,7	236,9	226,7	258,3
15:00	255,1	233,7	229,7	227,1	225,4	231,7	223,3	255,1
16:00	251,2	235,7	222,8	222,1	219,5	223,1	215,0	251,2
17:00	253,0	244,0	222,1	219,0	220,5	219,4	212,3	253,0
18:00	248,9	242,3	225,1	227,9	223,4	222,1	208,5	248,9
19:00	244,6	237,9	230,1	221,6	226,3	228,1	215,5	244,6
20:00	240,8	233,5	227,4	220,2	223,3	226,0	214,0	240,8
21:00	236,5	230,1	221,6	216,2	217,0	222,8	208,4	236,5
22:00	227,6	220,0	211,7	206,1	205,4	210,6	197,9	227,6
23:00	218,5	213,9	199,1	192,7	196,9	201,4	187,5	218,5

В программном виде *Matlab*-модель запуска процесса обучения имеет вид фрагмента *m*-файла. Исходный код на модель обучения и прогнозирования содержится в репозитории [21]. Диаграмма обучения нейронной сети представлена на рис. 6. Здесь *Train* – тренировочный процесс; *Best* – наименьшая ошибка; *Goal* – искомое значение ошибки.

#### Процесс обучения ИНС

Процесс обучения ИНС представлен в виде блок-схемы, изображенной на рис. 5.

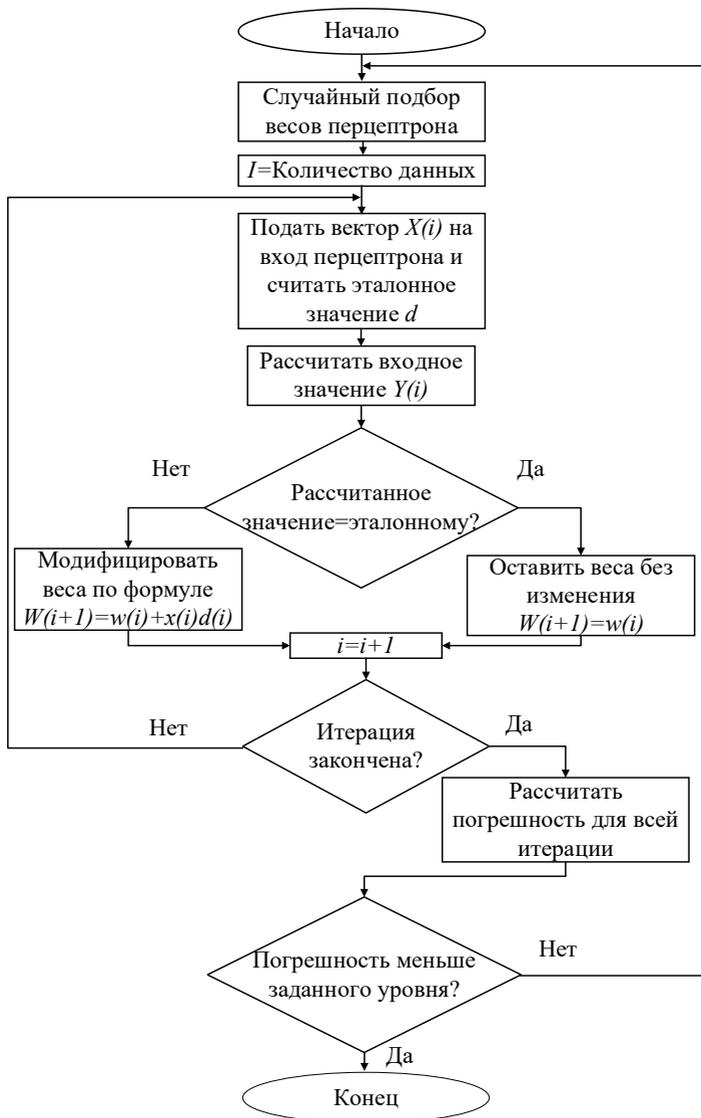


Рис. 5. Блок-схема процесса обучения ИНС

Fig. 5. Flowchart of the ANN training process

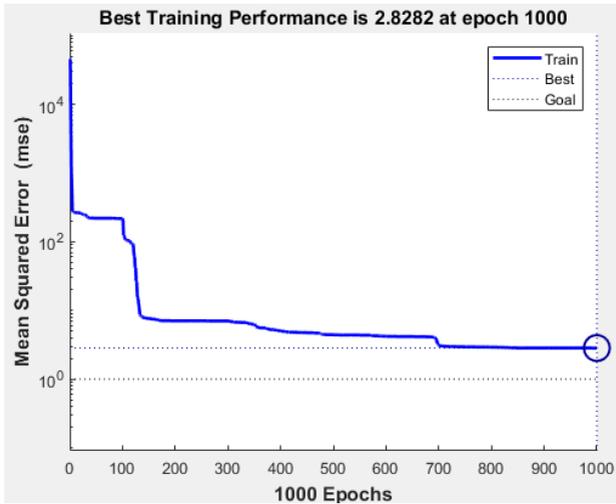


Рис. 6. Обучающая диаграмма нейронной сети

Fig. 6. Neural network training diagram

На диаграмме видно, что среднеквадратичная ошибка снижается после 100 итераций, производительность нейронной сети стремится к искомой величине ошибки обучения, но останавливается по причине достижения значения других параметров.

#### IV. Методы прогнозирования на основе регрессии и средних нагрузок

Регрессионные методы часто применяются для решения задач прогнозирования, так как они позволяют учитывать многочисленные внешние факторы, влияющие на целевую переменную. Предсказание в модели множественной линейной регрессии формализуется математической формулой, основанной на линейной зависимости между целевой переменной и объясняющими переменными.

$$y_t = \beta_0 + \beta_1 x_{1,t} + \dots + \beta_m x_{m,t}, \quad (12)$$

где  $y_t$  – спрогнозированное значение зависимой переменной в момент времени  $t$ ,  $x_{1,t}$ ,  $x_{2,t}$ , ...,  $x_{m,t}$  –  $m$  независимых переменных, а  $\beta = \{\beta_0, \beta_1, \dots, \beta_m\}$  вектор из  $m+1$  параметров, получаемых на этапе обучения с помощью метода наименьших квадратов.

Метод средних нагрузок считается по формуле:

$$y_i = \frac{\sum_1^n x_n}{n}, \quad (13)$$

где  $x_n$  – энергопотребление в течение аналогичных временных интервалов в предшествующем периоде нагрузки.

#### VI. Анализ результатов исследования

Первые 24 значения из табл. 2 за Н1 использовались как исходные данные для последовательного вычисления остальных, рекуррентным алгоритмом, основанным на 24 предыдущих значениях.

Степень схожести прогнозного и реального графиков, можно оценить коэффициентом корреляции:

$$r_{xy} = \frac{\sum (x_i - x_{\text{средн}})(y_i - y_{\text{средн}})}{\sqrt{\sum (x_i - x_{\text{средн}})^2 \cdot \sum (y_i - y_{\text{средн}})^2}}. \quad (14)$$

Спрогнозированное электропотребление в микроэнергосистеме методом ИНС, методом регрессии и средних нагрузок на 24 часа представлено в табл. 3. Визуальное представление спрогнозированного графика представлено на рис. 7.

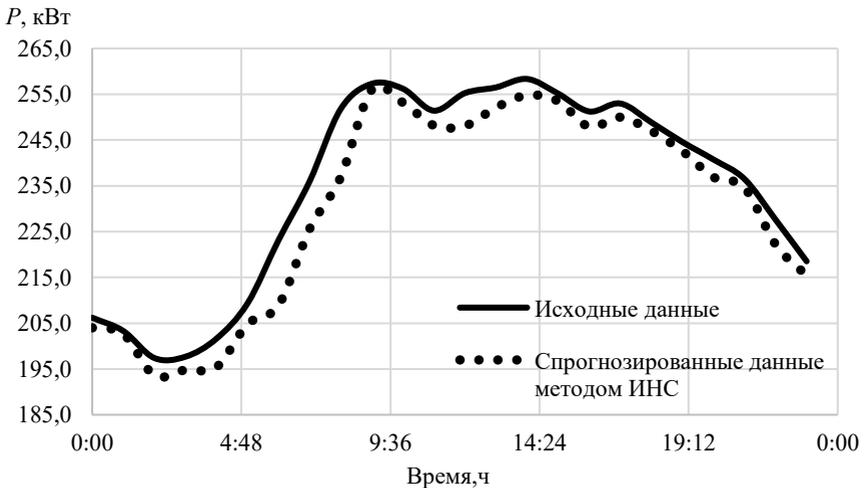


Рис. 7. Спрогнозированное потребление методом ИНС и реальное потребление электроэнергии на Н0

Fig. 7. Predicted consumption by ANN method and real electricity consumption at H0

**Таблица 3.**  
**Спрогнозированные данные по потреблению на Н0**

**Table 3.**  
**Predicted consumption data at Н0**

Время, ч	Спрогнозированные данные			Реальные данные Н0	Ошибка метода ИНС, %
	Метод регрессии Н0	Метод средних нагрузок Н0	Метод ИНС Н0		
0:00	181,5	190,6	204,0	206,2	-0,01072
1:00	181,0	186,4	202,7	203,3	-0,00300
2:00	178,8	184,2	193,6	197,4	-0,01925
3:00	178,2	184,7	194,8	197,7	-0,01454
4:00	176,6	186,6	195,4	201,6	-0,03086
5:00	176,6	194,3	204,8	209,3	-0,02157
6:00	190,4	208,9	208,9	223,2	-0,06387
7:00	206,5	224,5	225,6	236,0	-0,04399
8:00	221,5	240,1	236,9	251,8	-0,05912
9:00	225,9	245,0	256,0	257,3	-0,00503
10:00	224,1	245,2	253,2	256,2	-0,01182
11:00	220,3	240,5	248,2	251,4	-0,01280
12:00	219,3	238,4	248,1	255,3	-0,02805
13:00	220,6	238,3	252,1	256,5	-0,01716
14:00	217,9	237,2	254,8	258,3	-0,01372
15:00	219,3	232,3	253,5	255,1	-0,00643
16:00	215,1	227,1	247,9	251,2	-0,01332
17:00	214,2	227,2	250,0	253,0	-0,01181
18:00	212,8	228,3	247,0	248,9	-0,00752
19:00	219,8	229,2	242,6	244,6	-0,00806
20:00	218,8	226,5	236,9	240,8	-0,01600
21:00	213,5	221,8	234,6	236,5	-0,00799
22:00	204,5	211,4	222,2	227,6	-0,02377
23:00	194,5	201,4	215,4	218,5	-0,01429

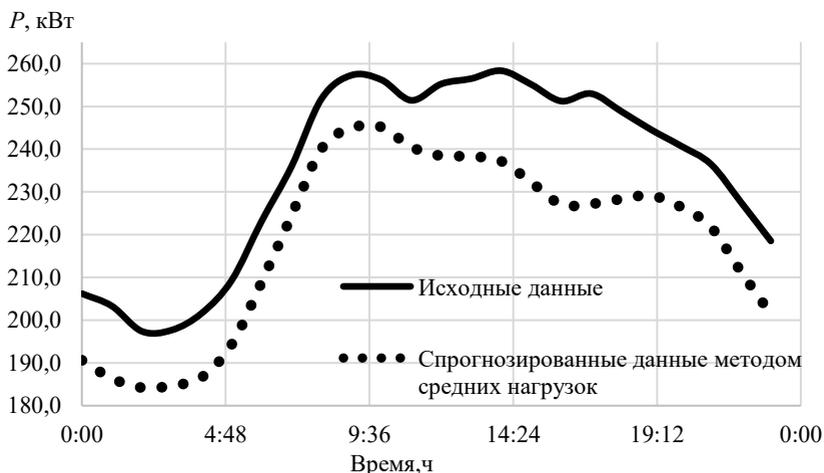
Значение коэффициента корреляции между фактическими и прогнозными данными активной мощности за Н0 составило 0,995774, что близко к 1. Это указывает на высокую степень линейной корреляции и соответствия прогнозных значений реальным наблюдениям потребляемой активной мощности. Небольшие отклонения прогноза от фактических данных могут быть обусловлены ограниченным объемом исходной выборки, использованной для обучения ИНС. Увеличение тренировочного набора данных может повысить точность прогноза за счет более точного отражения тенденций в модели.

В табл. 4 представлено сравнение коэффициентов корреляции, полученные для разных методов прогнозирования потребления на день  $H_0$ .

**Таблица 4.**  
**Коэффициенты корреляции**  
**Table 4.**  
**Correlation coefficients**

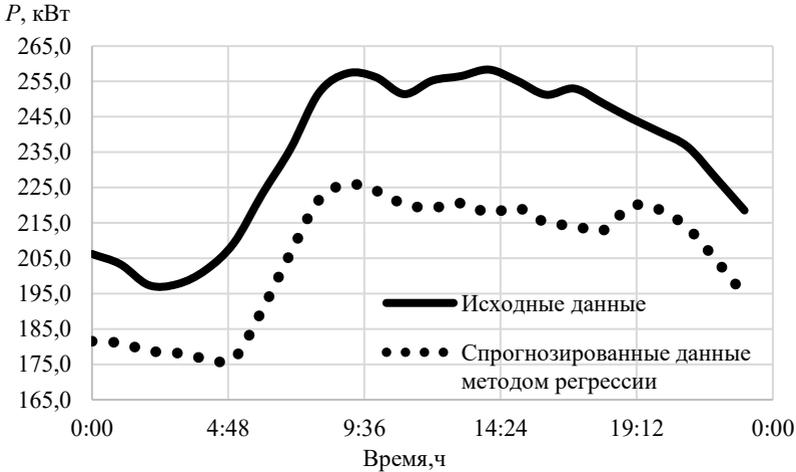
Методы прогнозирования	Коэффициент корреляции
Метод регрессии	0,968791
Средних нагрузок	0,982268
ИНС	0,995774

На рис. 8 и рис. 9 показано визуальное представление спрогнозированных графиков по методам средних нагрузок и регрессии соответственно.



**Рис. 8. Спрогнозированное потребление методом средних нагрузок и реальное потребление электроэнергии на  $H_0$**   
**Fig. 8. Predicted consumption by the method of average loads and the actual electricity consumption at  $H_0$**

Полученные результаты свидетельствуют о том, что метод на основе ИНС осуществляет лучшее прогнозирование потребления электрической энергии. Результаты оценки эффективности нейронной сети с рекуррентным алгоритмом обратного распространения погрешности и сравнение ее с другими методами показали применимость данного подхода для решения задачи.



**Рис. 9. Спрогнозированное потребление методом регрессии и реальное потребление электроэнергии на Н0**

**Fig. 9. Predicted consumption by regression method and actual electricity consumption at Н0**

Процесс обучения нейронной сети включает многочисленные параметры и настройки. Определяющим в результате обучения ИНС является не только величина среднеквадратичной ошибки, но и число итераций, определяющих степень адаптации модели к входным данным. Чрезмерное или недостаточное количество обучающих циклов может привести к неоптимальным результатам вследствие переобучения или недообучения. Следовательно, важно тщательно настраивать параметры обучения, для достижения оптимального баланса между минимизацией ошибки и обучением модели, влияющего на ее способность к обобщению и прогнозированию.

## VII. Заключение

Исследуемая нейронная сеть с обратным распространением ошибки обучения является одной из самых популярных и практически востребованных моделей в задачах регрессии. В результате исследования получено, что разработанная модель ИНС прогнозирует график потребления активной мощности в рассматриваемой микроэнергосистеме с коэффициентом корреляции 0,995774. Для достижения более точных прогнозов часто необходимо использовать большое количество обучающих выборок, что подчеркивает важность объема и качества данных.

При этом важно отметить, что при использовании набора инструментов для нейронной сети в среде *Matlab*, значительно снижается необходи-

мость в сложной программной работе, что способствует более эффективному и быстрому процессу обучения. В результате исследования выявлено, что количество проведенных итераций обучения оказывает намного большее воздействие на точность предсказаний, чем строгое достижение целевой ошибки обучения. Это подчеркивает необходимость в оптимальном подборе количества итераций обучения, чтобы достичь наилучших результатов в обучении нейронных сетей.

*Исследование выполнено в рамках государственного задания в сфере научной деятельности (тема №FSWE-2025-0001).*

© Лоскутов А.А., 2025

© Жаренков С.А., 2025

© Симанов А.С., 2025

*Поступила в редакцию 29.12.2023*

*Принята к публикации 26.02.2024*

*Received 29.12.2023*

*Accepted 26.02.2024*

### Библиографический список

- [1] Брейдо И.В., Хомченко В.Г., Булатбаева Ю.Ф., Оразгалеева Г.Д. Создание модели прогнозирования энергопотребления на основе адаптивной нейро-нечеткой системы вывода в Matlab // Вестник КазАТК. 2021. № 116 (1). С. 331–338. DOI: 10.52167/1609-1817-2021-116-1-331-338
- [2] Куликов А.Л., Лоскутов А.А., Совина А.Н. Использование машинного обучения и искусственных нейронных сетей для распознавания витковых замыканий в силовых трансформаторах // Электричество. 2022. № 10. С. 34-44. DOI: 10.24160/0013-5380-2022-10-34-44
- [3] Куликов А.Л., Лоскутов А.А., Бездушный Д.И. Повышение распознаваемости аварийных режимов релейной защитой методами деревьев решений // Электричество. 2023. № 7. С. 20-34. DOI: 10.24160/0013-5380-2023-7-20-34
- [4] Кугучева Д.К., Харитонов М.С. Некоторые аспекты оптимизационных задач при расчете автономных систем микрогрид // Вестник Северо-Кавказского федерального университета. 2020. № 6 (81). С. 7-16. DOI: 10.37493/2307-907X.2020.6.1
- [5] Рибейро П.Ф., Дуке К.А., да Силвейра П.М., Серкейра А.С. Обработка сигналов в интеллектуальных сетях энергосистем. Техносфера, 2020. – 496 с.
- [6] Ordóñez D., Dafonte C., Arcay B., Manteiga M. A framework for the definition and generation of artificial neural networks // proc. 6th WSEAS International Conference on Applied Computer Science, Dec. 16-18, 2006, Tenerife, Canary Islands, Spain. Stevens Point, Wisconsin, USA: WSEAS, 2007. С. 280–284.
- [7] Khalid Z., Abbas G., Awais M., Alquthami T., Rasheed M.B. A novel load scheduling mechanism using artificial neural network based customer profiles in smart grid // Energies. 2020. Т. 16. № 5. Art. no. 1062. DOI: 10.3390/en13051062

- [8] Nabiullin D.I., Balobanov R.N. Prediction of the electrical load of the power system using neural networks // E3S Web of Conferences. 2019. № 124. Art. no. 05026. DOI: 10.1051/e3sconf/201912405026
- [9] Ahmad N., Ghadi Y., Adnan M, Ali M. Load forecasting techniques for power system: Research challenges and survey // IEEE Access. 2022. Т. 10. С. 71054-71090. DOI: 10.1109/ACCESS.2022.3187839
- [10] Суворов А.А., Аскарлов А.Б., Рудник В.Е., Разживин И.А., Андреев М.В., Бай Ю.Д. Верификация численных расчетов электромеханических переходных процессов при оценке устойчивости электроэнергетических систем с генерирующими объектами, использующими ВИЭ // Электрические станции. 2022. № 1. С. 25-37. DOI: 10.34831/EP.2022.1086.1.004
- [11] Разживин И.А., Суворов А.А., Андреев М.В., Рудник В.Е., Гусев А.С. Исследование влияния синтетической инерции на динамическую устойчивость электроэнергетических систем // Электричество. 2022. № 8. С. 16-26. DOI: 10.24160/0013-5380-2022-8-16-26
- [12] Тимшина Д.В., Работва Ю.Ю. Нечеткая логика и анализ эффективности инвестиционных проектов в среде MatLab, Fuzzy Logic Toolbox // Вестник Академии знаний. 2014. № 1 (8). С. 50-60.
- [13] Hammad M.A., Jereb B., Rosi B., Dragan D. Methods and models for electric load forecasting: A comprehensive review // Logistics & Sustainable Transport. 2020. Т. 11. № 1. С. 51-76. DOI: 10.2478/jlst-2020-0004
- [14] Zeng W., Li J., Sun C., Cao L., Tang X., Shu S., Zheng J. Ultra short-term power load forecasting based on similar day clustering and ensemble empirical mode decomposition // Energies. 2023. Т. 16. № 4. Art. no. 1989. DOI: 10.3390/en16041989
- [15] Habbak H., Mahmoud M., Metwally K., Fouda M.M., Ibrahim M.I. Load forecasting techniques and their applications in smart grids // Energies. 2023. Т. 16. № 3. Art. no. 1480. DOI: 10.3390/en16031480
- [16] Sulandaria W., Subanar S., Suhartono S., Utami H. Forecasting electricity load demand using hybrid exponential smoothing-artificial neural network model // International Journal of Advances in Intelligent Informatics. 2016. Т. 2. № 3. С. 131-139. DOI: 10.26555/ijain.v2i3.69
- [17] Krstonijevic S. Adaptive load forecasting methodology based on generalized additive model with automatic variable selection // Sensors. 2022. Т. 22. № 19. Art. no. 7247. DOI: 10.3390/s22197247
- [18] Zhang S., Liu J., Wang J. High-resolution load forecasting on multiple time scales using long short-term memory and support vector machine // Energies. 2023. № 16. № 4. Art. no. 1806. DOI: 10.3390/en16041806
- [19] M. Shah, R. Agrawal, S. Gade. Short-term load forecasting using fuzzy logic based model: a case study of South Malwa plateau // Нечеткие системы и мягкие вычисления. 2023. Т. 18. № 1. С. 111–127. DOI: 10.26456/fssc105
- [20] Lee K.Y., Cha Y.T., Park J.H. Short-term load forecasting using an artificial neural network // IEEE Transactions on Power Systems. 1992. № 7 (1). С. 124-132. DOI: 10.1109/59.141695
- [21] Жаренков С.А. Репозиторий “1” // Github. [Электронный ресурс]. URL: <https://github.com/Semsan6/1> (дата обращения 23.04.2024).

## References

- [1] J.V. Breido, V.G. Homchenko, J.F. Bulatbayeva and G.D. Orazgaleyeva, "Creation of an energy consumption forecast model based on adaptive neuro-fuzzy output system in matlab", *The Bulletin of KazATC*, vol. 116, no. 1, pp. 331-338, 2021. DOI: 10.52167/1609-1817-2021-116-1-331-338
- [2] A.L. Kulikov, A.A. Loskutov and A.N. Sovina, "Using machine learning and artificial neural networks to recognize inter-turn faults in power transformers", *Electricity*, no. 10, pp. 34-44, 2022. DOI: 10.24160/0013-5380-2022-10-34-44
- [3] A.L. Kulikov, A.A. Loskutov and D.I. Bezdushny, "Improving the recognition of emergency modes by relay protection using decision tree methods", *Electricity*, no. 7, pp. 20-34, 2023. DOI: 10.24160/0013-5380-2023-7-20-34
- [4] D.K. Kugucheva and M.S. Kharitonov, "Some aspects of optimization problems in calculation of autonomous microgrid systems", *Newsletter of North-Caucasus Federal University*, vol. 6, no. 81, pp. 7-16, 2020. DOI: 10.37493/2307-907X.2020.6.1
- [5] P.F. Ribeiro, C.A. Duque, P.M. da Silveira and A.S. Cerqueira, *Power systems signal processing for smart grids*. John Wiley & Sons, Ltd, 2014.
- [6] D. Ordóñez, C. Dafonte, B. Arcay and M. Manteiga, "A framework for the definition and generation of artificial neural network", in proc. *6th WSEAS International Conference on Applied Computer Science*, Dec. 16-18, 2006, Tenerife, Canary Islands, Spain, pp. 280-284.
- [7] Z. Khalid, G. Abbas, M. Awais, T. Alquthami and M.B. Rasheed, "A novel load scheduling mechanism using artificial neural network based customer profiles in smart grid", *Energies*, vol. 13, no. 5, art. no. 1062, 2020. DOI: 10.3390/en13051062
- [8] D.I. Nabiullin and R.N. Balobanov, "Prediction of the electrical load of the power system using neural networks", *E3S Web of Conferences*, vol. 124, art. no. 05026, 2019. DOI: 10.1051/e3sconf/201912405026
- [9] N. Ahmad, Y. Ghadi, M. Adnan and M. Ali, "Load forecasting techniques for power system: Research challenges and survey," *IEEE Access*, vol. 10, pp. 71054-71090, July 2022. DOI: 10.1109/ACCESS.2022.3187839.
- [10] A. Suvorov, A. Askarov, V. Rudnik, I. Razzhivin, M. Andreev and Yu. Bai, "Validation of numerical calculations of electromechanical transients in assessing the stability of electric power systems with generating facilities using renewable sources of energy", *Electric stations*, no. 1, pp. 25-37, 2022. DOI: 10.34831/EP.2022.1086.1.004
- [11] I.A. Razzhivin, A.A. Suvorov, M.V. Andreev, V.E. Rudnik, A.S. Gusev, "Studying the influence of synthetic inertia on electric power system transient stability", *Electricity*, no. 8, pp. 16-26, 2022. DOI: 10.24160/0013-5380-2022-8-16-26
- [12] D.V. Timshina and Y.Y. Rabota, "Fuzzy logic and analysis of investment projects in the environment MatLab, Fuzzy Logic]", *Bulletin of the Academy of Knowledge*, vol. 1, no. 8, pp. 50-60, Jan.-March 2014.
- [13] M.A. Hammad, B. Jereb, B. Rosi and D. Dragan, "Methods and models for electric load forecasting: A comprehensive review", *Logistics & Sustainable Transport*, vol. 11, no. 1, pp. 51-76, Feb. 2020. DOI: 10.2478/jlst-2020-0004
- [14] W. Zeng, J. Li, C. Sun, L. Cao, X. Tang, S. Shu and J. Zheng, "Ultra short-term power load forecasting based on similar day clustering and ensemble empirical mode decomposition", *Energies*, vol. 16, no. 4, art. no. 1989, 2023. DOI: 10.3390/en16041989

- [15] H. Habbak, M. Mahmoud, K. Metwally, M.M. Fouda and M.I. Ibrahim, "Load forecasting techniques and their applications in smart grids", *Energies*, vol. 16, no. 3, art. no. 1480, 2023. DOI: 10.3390/en16031480
- [16] W. Sulandaria, S. Subanar, S. Suhartono and H. Utami, "Forecasting electricity load demand using hybrid exponential smoothing-artificial neural network model", *International Journal of Advances in Intelligent Informatics*, vol. 2, no. 3, pp. 131-139, Nov. 2016. DOI: 10.26555/ijain.v2i3.69
- [17] S. Krstonijevic, "Adaptive load forecasting methodology based on generalized additive model with automatic variable selection", *Sensors*, vol. 22, no. 19, art. no. 7247, 2022. DOI: 10.3390/s22197247
- [18] S. Zhang, J. Liu, and J. Wang, "High-resolution load forecasting on multiple time scales using long short-term memory and support vector machine", *Energies*, vol. 16, no. 4, art. no. 1806, 2023. DOI: 10.3390/en16041806
- [19] M. Shah, R. Agrawal and S. Gade, "Short-term electrical load forecasting using a fuzzy logic model: a case study of the South Malwa plateau", *Fuzzy Systems and Soft Computing*, vol. 18, is. 1, pp. 111–127, Aug. 2023. DOI: 10.26456/fssc105
- [20] K.Y. Lee, Y.T. Cha and J.H. Park, "Short-term load forecasting using an artificial neural network", *IEEE Transactions on Power Systems*, vol. 7, no. 1, pp. 124-132, Feb. 1992. DOI: 10.1109/59.141695
- [21] S.A. Zharenkov, Repository "1" // Gitgub. [Online]. Available at: <https://github.com/Semsan6/1> [Accessed: Apr. 23, 2024].

### ИНФОРМАЦИЯ ОБ АВТОРАХ INFORMATION ABOUT THE AUTHORS

**Лоскутов Антон Алексеевич**, кандидат технических наук, доцент Нижегородского государственного технического университета им. Р.Е. Алексеева, г. Нижний Новгород, Российская Федерация.

**Anton A. Loskutov**, Cand. Sci. (Eng.), associate professor of the Nizhny Novgorod State Technical University n.a. R.E. Alekseev, Nizhny Novgorod, Russian Federation.

**Жаренков Семен Андреевич**, студент Нижегородского государственного технического университета им. Р.Е. Алексеева, г. Нижний Новгород, Российская Федерация.

**Semyon A. Zharenkov**, student of the Nizhny Novgorod State Technical University n.a. R.E. Alekseev, Nizhny Novgorod, Russian Federation.

**Симанов Александр Сергеевич**, студент Нижегородского государственного технического университета им. Р.Е. Алексеева, г. Нижний Новгород, Российская Федерация.

**Alexander S. Simanov**, student of the Nizhny Novgorod State Technical University n.a. R.E. Alekseeva, Nizhny Novgorod, Russian Federation.