

УДК 004.896+517.977.5; 621.311.1

DOI: 10.18799/29495407/2025/1/85

Шифр специальности ВАК: 1.2.1; 2.3.1; 2.4.5

## Нейросетевые технологии прогнозирования и управления электропотреблением в энергетических системах с использованием генетического метода

Н.К. Полюянович<sup>1</sup>✉, О.В. Качелаев<sup>1</sup>, М.Н. Дубяго<sup>1</sup>, Т. Фалькон<sup>2</sup>

<sup>1</sup> Южный федеральный университет, Россия, г. Таганрог

<sup>2</sup> Университет Камагуэя «Игнасио Аграмонте», Куба, г. Камагуэй

✉ nik1-58@mail.ru

**Аннотация.** Рассматриваются нейросетевые технологии прогнозирования в задачах управления электропотреблением в энергетических системах с использованием генетического метода. Доказано, что с целью реализации системы технологического управления региональной сетевой компании можно применять техническую и информационную платформу иерархической автоматизированной информационно-измерительной системы контроля и учета электроэнергии. Рассматривается задача повышения точности краткосрочного прогнозирования потребления электроэнергии с использованием методов глубокого машинного обучения. Новизна работы заключается в использовании разработанного генетического алгоритма для подбора гиперпараметров нейронной сети, которые влияют на качество ее работы, но не определяются в процессе обучения. Разработаны модели нейронных сетей, проведено исследование по поиску оптимальной структуры нейронной сети и влияния задаваемых гиперпараметров нейронных сетей на погрешность прогнозирования электропотребления. Проработанная методика и технологии управления применены в структуре программно-моделирующей системы, чтобы управлять региональной энергосистемой автономных потребителей. По итогам обучения и тестирования генетический алгоритм подтвердил возможность автоматизации подбора оптимальных гиперпараметров и получения прогнозов большей точности.

**Ключевые слова:** управление, прогнозирование электропотребления, искусственный интеллект, генетические нейронные сети, машинное обучение

**Для цитирования:** Нейросетевые технологии прогнозирования и управления электропотреблением в энергетических системах с использованием генетического метода / Н.К. Полюянович, О.В. Качелаев, М.Н. Дубяго, Т. Фалькон // Известия Томского политехнического университета. Промышленная кибернетика. – 2025. – Т. 3. – № 1. – С. 29–36. DOI: 10.18799/29495407/2025/1/85

---

UDC 004.896+517.977.5; 621.311.1

DOI: 10.18799/29495407/2025/1/85

## Neural network technologies for forecasting and controlling electricity consumption in energy systems by the genetic method

N.K. Poluyanovich<sup>1</sup>✉, O.V. Kachelaev<sup>1</sup>, M.N. Dubyago<sup>1</sup>, T. Falcon<sup>2</sup>

<sup>1</sup> Southern Federal University, Taganrog, Russian Federation

<sup>2</sup> University of Camagüey "Ignacio Agramonte", Camaguey, Cuba

✉ nik1-58@mail.ru

**Abstract.** The paper considers the neural network forecasting technologies in controlling power consumption in energy systems using the genetic method. It is proved that in order to implement the technological management system of a regional grid company, it is possible to use the technical and information platform of a hierarchical automated information and measurement system for monitoring and metering electricity. We consider the task of improving the accuracy of short-term forecasting of electricity consumption using deep machine learning methods. The novelty of the work lies in the use of a devel-

oped genetic algorithm to select hyperparameters of a neural network that affect the quality of its work, but are not determined in the learning process. The authors have developed the neural network models and carried out the study to find the optimal structure of a neural network, and the influence of specified neural networks hyperparameters on the error in predicting power consumption. The developed management methodology and technologies are applied in the structure of the software modeling system to manage the regional energy system of autonomous consumers. Based on the results of training and testing, the genetic algorithm confirmed the possibility of automating the selection of optimal hyperparameters and obtaining forecasts of greater accuracy and the possibility.

**Keywords:** control, forecasting of power consumption, artificial intelligence, genetic neural networks, machine learning

**For citation:** Poluyanovich N.K., Kachelaev O.V., Dubyago M.N., Falcon T. Neural network technologies for forecasting and controlling electricity consumption in energy systems by the genetic method. *Bulletin of the Tomsk Polytechnic University. Industrial Cybernetics*, 2025, vol. 3, no. 1, pp. 29–36. DOI: 10.18799/29495407/2025/1/85

## Введение

Значимость стратегических приоритетов и целей государственной политики в контексте реализации комплексной программы Российской Федерации для современных предприятий была обозначена в постановлении Правительства РФ от 9 сентября 2023 года № 1473 «Об утверждении комплексной государственной программы Российской Федерации "Энергосбережение и повышение энергетической эффективности"». В частности, в документе подчеркиваются требования законодательства к прогнозированию потребления электроэнергии, что необходимо для обеспечения баланса мощностей между производителями и потребителями электрической энергии [1]. В рамках модернизации предприятий, занимающихся генерацией электрической энергии, внедряются интеллектуальные системы учета. Прогнозирование объемов потребления электроэнергии стало одной из ключевых мер по оптимизации энергетических затрат, играя важную роль в повседневной деятельности организаций [2]. С введением реформ на рынке электроэнергии вопрос планирования и прогнозирования потребления энергии становится особенно актуальным. Главная сложность в прогнозировании потребления электроэнергии заключается в необходимости учитывать множество факторов, влияющих на колебания энергопотребления [3]. Согласно оценкам российских экспертов, каждая ошибка в ежегодном прогнозе потребления электроэнергии на уровне 1 % может обернуться дополнительными инвестициями в размере 4 миллиардов долларов на строительство новых генерационных мощностей [4]. Таким образом, создание эффективной системы прогнозирования и соответствующей математической модели становится крайне важным. Реализация этой модели позволит улучшить точность прогнозов потребления электроэнергии, что, в свою очередь, поможет снизить затраты предприятий на закупку. Главной задачей прогнозирования потребления электроэнергии выступает оценка диаграмм мощности ( $P$ ,  $Q$ ) и нагрузки для совершенствования эффективного управления электропотреблением [5].

Наиболее популярным методом прогнозирования, который основан на корреляционно-регрессионном анализе, является использование удельных норм расхода электроэнергии с последующей экспертной коррекцией. Полиномиальные разложения также могут эффективно применяться в качестве модели для аппроксимации графиков нагрузки и их прогнозирования. Для долгосрочных прогнозов целесообразно задействовать авторегрессионные методы [2]. Среди недостатков этих методов можно выделить следующие: высокая сложность вычислений, необходимость привлечения аналитиков, ограниченность применения для определенных типов прогнозов, недостаточная точность предсказаний, высокая чувствительность к исходным данным. Современные подходы к прогнозированию электрической нагрузки основываются на нейросетевом (НС) моделировании, что позволяет значительно сократить вмешательство в работу системы управления на этапе сбора данных о рассматриваемом объекте [2].

Задача – разработать систему управления и прогнозирования электропотребления (ПЭ) с применением искусственного интеллекта (нейронных сетей).

## Общие подходы и методика моделирования

Необходимость ряда ученых заниматься проблемами прогнозирования потребления электроэнергии вызвана технологическими и экономическими факторами. Например, И.В. Воронов предложил подход к прогнозированию электропотребления предприятий, основанный на нейронных сетях [6]. Б.И. Кудрин и А.В. Мозгалин предложили методику обеспечения почасового прогнозирования электропотребления предприятий с учетом погодных факторов [7]. Д.И. Клеопатров разработал метод прогнозирования с применением экспоненциального сглаживания [8], в то время как В.И. Гнатюк и О.Е. Лагуткин представили методику, основанную на техноценнозе [9]. В исследовании [10] анализируется влияние точности прогнозов потребления на технологические и экономические



Планово-упреждающее управление требует вариативности данных. То есть прогнозируемое потребление электроэнергии должно выполняться на различные временные интервалы. Для этого в систему управления встраиваются такие системы, как: система поддержки принятия решений (СППР) а также подсистема прогнозирования (рис. 1). Изображенные блоки означают: ЗЦК – заданные цели и критерии эффективного управления; РЭС – распределительные электрические сети; ПЭ – потребители электроэнергии; УСПД – устройство сбора и передачи данных; БД НС – база данных нейросетей; БД ДП – база данных диспетчерского пункта. Применение НС-подсистемы прогнозирования ЭП на нижнем уровне автоматизированных систем коммерческого учета электроэнергии (АСКУЭ) [2] позволит: предотвратить потерю данных при передаче на верхние уровни АСКУЭ; сформировать управляющие сигналы с целью обеспечения оптимальных режимов работы РЭС; расположить НС-подсистему локально, что дает возможность настройки на конкретного потребителя (циклический или аддитивный характер).

### Метод обратного распространения ошибки. Математическая модель

После первоначальной настройки и установки основных параметров, таких как базовые веса, объем обучающих образцов ( $n_p$ ), кроме этого, характеристики нейронной сети ( $\eta$ ) и ( $\alpha$ ) и заданного небольшого значения ( $\varepsilon$ ), влияющего на точность прогнозирования, начинается сбор информации о дате, погодных условиях и статусе дня (рабочий/выходной) для Р1–Р8. Эти данные затем нормализуются, преобразуясь в относительные величины  $Y_i$ , которые находятся в диапазоне от 0 до 1, где  $1 \leq i \leq 8$  [3]. Далее выполняется сглаживание входных данных с помощью метода вычисления среднего значения.

Теперь запишем систему расчетов сигналов (1) для входов ( $net_j$ ,  $net_k$ ) и выходов ( $Y_j$ ,  $Y_k$ ) нейронов скрытого слоя  $j$  и выходного слоя  $k$ :

$$\begin{cases} net_j = \sum_{i=1}^8 w_{ji} \cdot Y_i, j = 1, 2, \dots, n; \\ Y_i = \frac{1}{1 + e^{-(net_j + \theta_j)}}; \\ net_k = \sum_{j=1}^n w_{kj} \cdot Y_j, k = 1; \\ Y_k = \frac{1}{1 + e^{-(net_k)}}. \end{cases} \quad (1)$$

Здесь  $w_{ji}$  и  $w_{kj}$  – весовые коэффициенты соответственно между нейронами  $j$ -го и  $i$ -го слоя и  $k$ -го и  $j$ -го слоя. Для ограничения пространства поиска при обучении минимизируется целевая функция ошибки, которая находится по методу наименьших квадратов (2):

$$E_p = \frac{1}{2} \sum_{k=1}^{KN} (d_k - Y_k)^2, \quad (2)$$

где  $d_k$  – желаемое значение нагрузки на выходе;  $Y_k$  – расчетное значение;  $KN$  – число нейронов в выходном слое. Поскольку в выходном слое один нейрон, ошибка:  $E_p = \frac{1}{2} (d_k - Y_k)^2$  для каждого обучаемого образца  $p$ .

Алгоритм обратного распространения ошибки состоит в коррекции синоптического веса  $w_{ij}(n)$  на величину  $\Delta w_{ij}(n)$ , которая пропорциональна градиенту функции стоимости  $\frac{\partial J(n)}{\partial w_{ij}(n)}$ .

Далее рассчитываются изменения весов  $w_{ji}$  и  $w_{kj}$ , и на их основании производится корректировка весов по следующим формулам (3):

$$\begin{cases} \Delta w_{kj}(p) = \eta \delta_k Y_j + \alpha \Delta w_{kj}(p-1); \\ \Delta w_{ji}(p) = \eta \delta_k Y_i + \alpha \Delta w_{ji}(p-1); \\ \delta_k = (d_k - Y_k) Y_k (1 - Y_k); \\ \delta_j = Y_j (1 - Y_j) \sum_k \delta_k w_{kj}; \\ w_{ji}^{нов} = w_{ji}^{стар} + \Delta w_{ji}(p); \\ w_{kj}^{нов} = w_{kj}^{стар} + \Delta w_{kj}(p). \end{cases} \quad (3)$$

В этих соотношениях:  $p$  – номер образца;  $\eta$  – коэффициент скорости обучения, значение которого, как правило, выбирают в интервале  $[0, 1]$ ;  $\alpha$  – момент, определяющий ускорение обучения, который также выбирается в интервале  $[0, 1]$ . Параметры устанавливаются:  $\eta=0,3$ ;  $\alpha=0,7$ ;  $\varepsilon=10^{-6}$  (исходя из минимизации ошибок). Далее проверяется, были ли использованы все образцы. Если все образцы задействованы, вычисляется общая ошибка по всем образцам, и проверяется условие завершения обучения. Данный алгоритм имеет несколько преимуществ: высокую скорость вычисления градиента; возможность применения любых дифференцируемых функций активации и потерь, а также для любой конфигурации слоев; поддержку динамического (поточного) обучения; возможность распараллеливания процессов [16].

### Эволюционное проектирование архитектуры НС

Генетический алгоритм применен для решения задачи подбора архитектуры полносвязной НС прямого распространения. Он базируется на методе обратного обучения и осуществляет только поиск общей архитектуры НС (рис. 2). Одновременно с базой знаний в топологической конфигурации алгоритма основополагающими считаются блоки, позволяющие образовывать новые особи, а также осуществлять обучение НС, их анализ и генерацию. Необходимо, чтобы блок оценки эффективности нейросетевой модели работал автономно. На начальном этапе создания наборов и на всех последующих шагах генератор особей действует. Для оценки эффективности обучения нейронной сети используем следующую целевую функцию (4):

$$GF = \sum_{j=1}^m \frac{\sum_{i=1}^k |y_i^j - \hat{y}_i^j|}{k \cdot m}, \quad (4)$$

где  $k$  – размер входного слоя НС;  $m$  – объем образцов в валидационной выборке;  $y$  – необходимая величина на выходе;  $\hat{y}$  – объективная величина на выходе.

Критерием достоверности прогнозирования потребляемой мощности электроэнергии выбран средний модуль процента ошибки (MAPE – mean average percentage error) (5):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i^* - y_i}{y_i} \right| \cdot 100\%. \quad (5)$$

Основными строительными блоками генетического алгоритма являются операторы. Основными генетическими операторами являются:

- оператор мутации. Влияет на основную хромосому и дочернюю, определяющую количество нейронов;
- оператор скрещивания (кроссинговера). Взаимодействует исключительно с основной хромо-

сомой, позволяя создавать новые модели (потомков), на основе наиболее приспособленных особей.

Оператор инверсии работает как с основной хромосомой, так и с дочерними, которые отвечают за входные и выходные параметры. Таким образом, лишь генератор новых особей и база знаний несут ответственность за входные и выходные данные. Создание популяции особей  $x^k$ , оценка их приспособляемости  $E_{val}(V_i)$ , селекция  $v(ch_i)$  и выбор наилучшей хромосомы  $f_k(x)$  в ходе работы генетического алгоритма подбора гиперпараметров описываются уравнением (6)

$$\begin{cases} X^k = (x_1^k, x_2^k, \dots, x_n^k), x_i^k \in X; \\ Eval(V_i) = f_i' / \sum_{j=1}^{pop\_size} f_j', i = 1, 2, \dots, pop\_size; \\ v(ch_i) = p_s(ch_i) * 100\%; \\ p_s(ch_i) = \frac{F(ch_i)}{\sum_{i=1}^N F(ch_i)}; \\ f_k(x) = f_k(x_1^k, x_2^k, \dots, x_n^k). \end{cases} \quad (6)$$

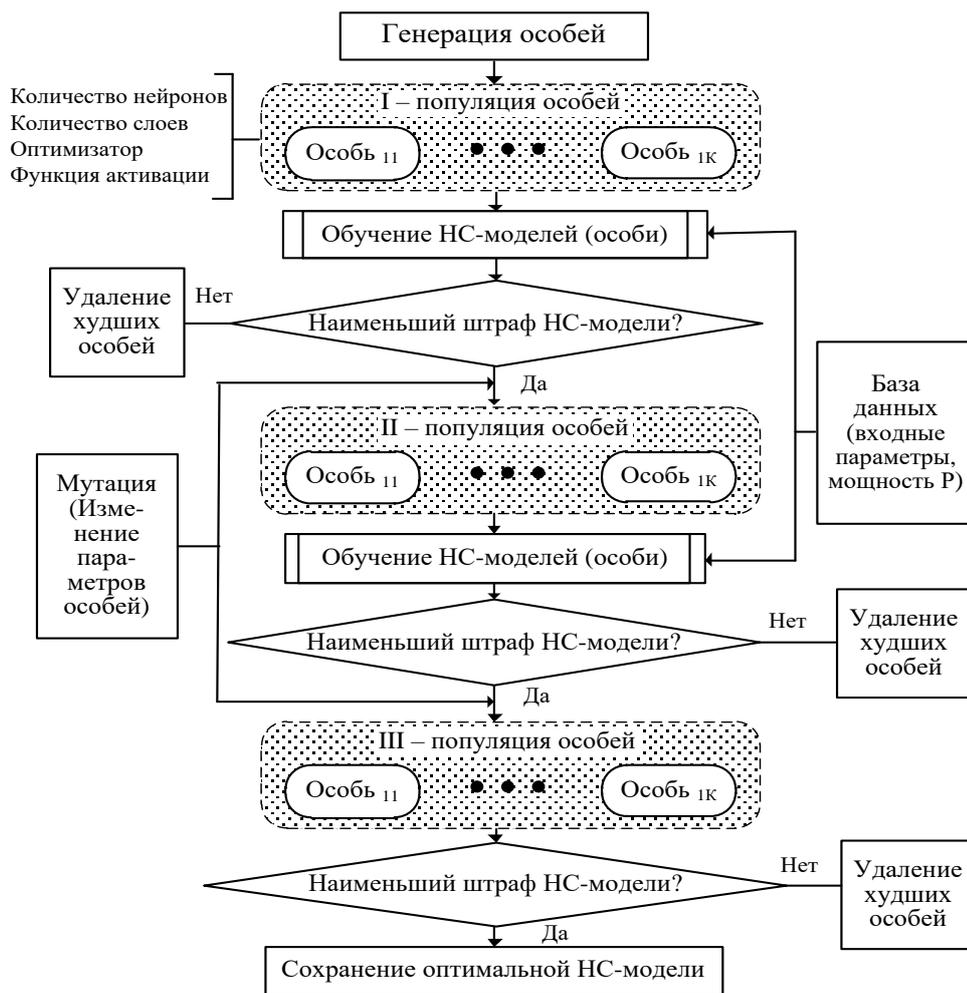


Рис. 2. Генетический алгоритм подбора гиперпараметров НС-модели  
 Fig. 2. Genetic algorithm for selecting hyperparameters of the NN model

**Таблица.** Сравнение точности прогнозов НС для различных промежутков времени

**Table.** Comparison of the accuracy of NN forecasts for different time periods

Характер потребителя электроэнергии Nature of the electricity consumer	Период прогноза Forecast period	Средняя абсолютная погрешность прогноза НС от фактических данных ПЭ, % Average absolute error of the neural network forecast from the actual data of electricity consumers, %	
		Со скользящим окном With sliding window	Без скользящего окна Without sliding window
Циклический (ЮЗЭС) Cyclic (SWEPCO)	Месяц/Month	3,107	0,194
	Неделя/Week	3,676	0,458
	День/Day	0,15	0,135
Аддитивный (МАКр) Additive (Krasnodar IA)	Месяц/Month	1,379	1,15
	Неделя/Week	1,986	0,118
	День/Day	0,128	0,331

### Экспериментальные исследования

Сравнительные результаты точности прогнозов нейросети и фактических данных на разные промежутки времени прогноза сведены в таблицу.

### Заключение

Определено, что методы прогнозирования электрической нагрузки плохо работают с «зашумленными» и неполными данными. Предлагается очищать данные перед подачей на вход НС при помощи встроенного инструмента (Wavelet analyzer) MatLab. Анализ влияния входных данных показал, что нейросеть с большим количеством слоев обучается быстрее и ее предсказания точнее. Анализ результатов расчета погрешности прогнозов электропотребления для различных промежутков времени показал, что точность прогнозов зависит от периода прогнозирования. Результаты исследования НС-модели со скользящим окном

показали, что обучать нейронную сеть с скользящим окном несколько труднее. Скользящее окно в значительной степени влияет на точность прогнозов НС, улучшает результаты прогнозов для аддитивных данных. Прогнозы нейросети, обученной на аддитивных данных, гораздо более чувствительны к изменениям структуры входных воздействий. Разработан генетический алгоритм подбора гиперпараметров НС-модели. Данный алгоритм обеспечивает снижение времени работы благодаря исключению оператора скрещивания. Использование данного алгоритма для подбора гиперпараметров НС-модели позволяет освободить оператора от необходимости подбирать параметры вручную. По итогам обучения и тестирования, ГА подтвердил возможность получения прогнозов большей точности для потребителей с аддитивным характером ЭП.

### СПИСОК ЛИТЕРАТУРЫ

1. Постановление Правительства РФ от 9 сентября 2023 г. N 1473 «Об утверждении комплексной государственной программы Российской Федерации "Энергосбережение и повышение энергетической эффективности"» // Консультант Плюс. URL: <https://base.garant.ru/407632842/> (дата обращения 02.12.2024).
2. Полуянович Н.К., Дубяго М.Н., Бурьков Д.В. Нейросетевой метод прогнозирования электропотребления и его инструментальная реализация. Монография. – Ростов-на-Дону; Таганрог: Изд-во ЮФУ, 2023. – 183 с.
3. Полуянович Н.К., Дубяго М.Н. Оценка воздействующих факторов и прогнозирование электропотребления в региональной энергосистеме с учетом режима ее эксплуатации // Известия ЮФУ. Технические науки. – 2022. – № 2 (226). – С. 31–46. DOI: 10.18522/2311-3103-2022-2-31-46 EDN: VGXNGT
4. Цена расточительности / Е. Рудаков, Ю. Саакян, Б. Нигматулин, Н. Прохорова // Эксперт. – 2008. – № 24. – С. 106–110.
5. Бидалова А.И. Прогнозирование потребления электрической энергии электротехническим комплексом городской электрической сети: дисс. ... канд. тех. наук. – Ульяновск, 2019. – 166 с.
6. Воронов И.В. Прогнозирование электропотребления промышленных предприятий с помощью искусственных нейронных сетей: дисс. ... канд. техн. наук. – Кемерово, 2010. – 154 с.
7. Кудрин Б.И., Мозгалин А.В. Методика обеспечения почасового прогнозирования электропотребления предприятий с учетом погодных факторов // Вестник Московского энергетического института. – 2007. – № 2. – С. 105–108. EDN: IALBBX
8. Клеопатров, Д.И. Прогнозирование экономических показателей с помощью метода простого экспоненциального сглаживания. Статистический анализ экономических временных рядов и прогнозирование. – М.: Наука, 1973. – 298 с.
9. Гнатюк В.И., Лагуткин О.Е. Ранговый анализ техноценозов. – Калининград: БНЦ РАЕН – КВИ ФПС РФ, 2000. – 86 с.
10. Доманов В.И., Бидалова А.И. Прогнозирование объемов энергопотребления в зависимости от исходной информации // Вестник ЮУрГУ. Серия «Энергетика». – 2016. – Т. 16. – № 2. – С. 59–65. DOI: 10.14529/power160208
11. Статистический анализ данных, моделирование и исследование вероятностных закономерностей. Компьютерный подход: монография / Б.Ю. Лемешко, С.Б. Лемешко, С.Н., Постовалов Е.В. Чимитова. – Новосибирск: Изд-во НГТУ, 2011. – 888 с.
12. Спиридонова О.И. Структура рынка электроэнергии: рынок форвардных контрактов и стимулы к молчаливому сговору // Современная конкуренция. – 2010. – № 5 (23). – С. 15–24. EDN: OPZUPF

13. Многослойная нейронная сеть: пат. 115098 РФ: МПК G06N 5/00. № 2011139784/08; за-явл. 29.09.2011; опубл. 20.04.2012, Бюл. № 11.
14. Устройство прогнозирования электропотребления на основе многослойной нейронной сети: пат. 169425 РФ: МПК G06Q 10/06, G06N 5/00, 2016145339; заявл. 18.11.2016; опубл. 17.03.2016.
15. Устройство мониторинга и прогнозирования электропотребления в электроэнергетических системах на основе нейронных структур: пат. 222420 РФ: МПК G06N 5/00, G06Q 10/06, 2023126166; заявл. 12.10.2023; опубл. 25.12.2023.
16. Оптимизация структуры системы прогнозирования энергопотребления с атипичным характером энергопотребления / Н.К. Полюянович, О.В. Качелаев, М. Дубяго Н., С.Б. Мальков // Известия ЮФУ. Технические науки. – 2024. – № 3 (239). – С. 207–219. DOI: 10.18522/2311-3103-2024-3-207-219 EDN: BLQNMG

### Информация об авторах

**Николай Константинович Полюянович**, кандидат технических наук, доцент кафедры электротехники и мехатроники, Институт нанотехнологий, электроники и приборостроения Южного федерального университета, Россия, 347922, г. Таганрог, ул. Шевченко 2; nik1-58@mail.ru, <https://orcid.org/0000-0001-5941-1355>

**Олег Вадимович Качелаев**, аспирант Института нанотехнологий, электроники и приборостроения Южного федерального университета, Россия, 347922, г. Таганрог, ул. Шевченко 2; 22.olezhka@mail.ru;

**Марина Николаевна Дубяго**, кандидат технических наук, доцент кафедры электротехники и мехатроники, Институт нанотехнологий, электроники и приборостроения Южного федерального университета, Россия, 347922, г. Таганрог, ул. Шевченко, 2; w\_m88@mail.ru, <https://orcid.org/0000-0002-0582-2340>

**Талия Хернандез Фалькон**, технический ассистент преподавателя, Инженерно-электромеханический факультет, Университет Камагуэя «Игнасио Аграмонте», Куба, 74650, г. Камагуэй, Северная кольцевая автодорога 5 км, 1; thaliahernandezf@gmail.com

Поступила в редакцию: 23.12.2024

Поступила после рецензирования: 19.02.2025

Принята к публикации: 15.03.2025

### REFERENCES

1. Decree of the Government of the Russian Federation No. 1473 dated September 9, 2023 "On Approval of the Comprehensive State Program of the Russian Federation "Energy Saving and Energy Efficiency Improvement". *Consultant Plus*. (In Russ.) Available at: <https://base.garant.ru/407632842/> (accessed 22 December 2024).
2. Poluyanovich N.K., Dubyago M.N., Burkov D.V. *Neural network method of forecasting power consumption and its instrumental implementation: monograph*. Rostov-on-Don, Taganrog, SFU Publ. House, 2023. 183 p. (In Russ.)
3. Poluyanovich N.K., Dubyago M.N. Assessment of influencing factors and forecasting of electricity consumption in the regional energy system, taking into account its operating mode. *Izvestiya SFU. Technical sciences*, 2022, no. 2 (226), pp. 31–46. DOI: 10.18522/2311-3103-2022-2-31-46 EDN: VGXNGT
4. Rudakov E., Sahakyan Y., B. Nigmatulin, Prokhorova N. The price of extravagance. *Expert*, 2008, no. 24, pp. 106–110.
5. Bilalova A.I. *Forecasting the consumption of electric energy by the electrotechnical complex of the urban electric grid*. Cand. Diss. Ulyanovsk, 2019. 166 p. (In Russ.)
6. Voronov I.V. *Forecasting the power consumption of industrial enterprises using artificial neural networks*. Cand. Diss. Kemerovo, 2010. p. 153 p. (In Russ.)
7. Kudrin B.I., Mozgalin A.V. Methodology for hourly forecasting of power consumption of enterprises, taking into account weather factors. *Bulletin of the Moscow Power Engineering Institute*, 2007, no. 2, pp. 105–108. (In Russ.) EDN: IALBBX
8. Kleopatrov D.I. *Forecasting economic indicators using the method of simple exponential smoothing. Statistical analysis of economic time series and forecasting*. Moscow, Nauka Publ., 1973. 298 p. (In Russ.)
9. Gnatyuk V.I., Lagutkin O.E. *Rank analysis of technocenoses*. Kaliningrad, BNC Russian Academy of Medical Sciences, FPS RF Publ., 2000. 86 p. (In Russ.)
10. Domanov V.I., Bilalova A.I. Forecasting the volume of energy consumption depending on the initial information. *Bulletin of SUSU. The Energy series*, 2016, vol. 16, no. 2, pp. 59–65. (In Russ.) DOI: 10.14529/power160208
11. Lemeshko B.Y., Lemeshko S.B., Postovalov S.N., Chimitova E.V. *Statistical data analysis, modeling and probabilistic patterns research. The computer approach: a monograph*. Novosibirsk, NSTU Publ. House, 2011. 888 p. (In Russ.)
12. Spiridonova O.I. The structure of the electricity market: the market of forward contracts and incentives for tacit agreement. *Modern competition*, 2010, no. 5 (23), pp. 15–24. (In Russ.) EDN: OPZUPF
13. Belov K.D. *Multilayer neural network*. Patent RF no. 2011139784/08, 2012. (In Russ.)
14. Khamitov R.N. *Power consumption forecasting device based on a multilayer neural network*. Patent RF no. 2016145339, 2016. (In Russ.)
15. Kachelaev O.V., Poluyanovich N.K., Dyago M. *Device for monitoring and forecasting power consumption in electric power systems based on neural structures*. Patent RF no. 2023126166, 2023. (In Russ.)
16. Poluyanovich N.K., Kachelaev O.V., Dubyago M. N., Malkov S.B. Optimization of the structure of the energy consumption forecasting system with an atypical nature of energy consumption. *Izvestiya SFU. Technical sciences*, 2024, no. 3 (239), pp. 207–219. (In Russ.) DOI: 10.18522/2311-3103-2024-3-207-219 EDN: BLQNMG

**Information about the authors**

**Nikolay K. Poluyanovich**, Cand. Sc., Associate Professor, Institute of Nanotechnology, Electronics and Instrumentation, Southern Federal University, 2, Shevchenko street, Taganrog, 347922, Russian Federation; nik1-58@mail.ru; <https://orcid.org/0000-0001-5941-1355>

**Oleg V. Kachelaev**, Postgraduate Student, Institute of Nanotechnology, Electronics and Instrumentation, Southern Federal University, 2, Shevchenko street, Taganrog, 347922, Russian Federation; 22.olezhka@mail.ru

**Marina N. Dubyago**, Cand. Sc., Associate Professor, Institute of Nanotechnology, Electronics and Instrumentation, Southern Federal University, 2, Shevchenko street, Taganrog, 347922, Russian Federation; w\_m88@mail.ru; <https://orcid.org/0000-0002-0582-2340>

**Talia Hernandez Falcón**, Teacher Technical Assistant, Electromechanical engineering faculty, University of Camagüey "Ignacio Agramonte", 1, Carretera de circunvalación Norte 5 km, Camagüey, 74650, Cuba; thaliahernandezf@gmail.com

Received: 23.12.2024

Revised: 19.02.2025

Accepted: 15.03.2025