

Рубрика 2. НАУЧНЫЕ И ПРАКТИЧЕСКИЕ РАЗРАБОТКИ

Направление – Электротехника

УДК [UDC] 621.316.72

DOI 10.17816/transsyst20206180-91

© С. О. Хомутов, Н. А. Серебряков

Алтайский государственный технический университет им. И. И. Ползунова  
(Барнаул, Россия)

## СОЗДАНИЕ НЕЙРОСЕТЕВОЙ МАТЕМАТИЧЕСКОЙ МОДЕЛИ КРАТКОСРОЧНОГО ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ ЭЛЕКТРОТЕХНИЧЕСКОГО КОМПЛЕКСА УЧАСТКА РАЙОННЫХ ЭЛЕКТРИЧЕСКИХ СЕТЕЙ 6-35 кВ

**Цель:** Разработать математическую модель краткосрочного прогнозирования электропотребления электротехнического комплекса участка районных электрических сетей 6-35 кВ с помощью аппарата искусственных нейронных сетей.

**Методы:** В работе использованы инструменты регрессионного анализа и аппарата глубокого машинного обучения.

**Результаты:** Получена нейросетевая модель краткосрочного прогнозирования электропотребления электротехнического комплекса участка районных электрических сетей 6-35 кВ, учитывающая факторы времени, метеорологических условий, отключений отдельных питающих линий электропередач, режима работы потребителей электроэнергии с мощностью свыше 670 кВт, факта наличия центрального отопления и водоснабжения.

**Заключение:** Разработанная нейросетевая математическая модель сводит задачу краткосрочного прогнозирования электропотребления к поиску матрицы свободных коэффициентов посредством обучения на имеющихся статистических данных.

**Ключевые слова:** прогнозирование электропотребления, факторы, оптовый рынок электроэнергии и мощности, машинное обучение, районная электрическая сеть.

Rubric 2. SCIENTIFIC AND PRACTICAL DEVELOPMENTS

Field – Electrical Engineering

© S. O. Khomutov, N. A. Serebryakov

Polzunov Altai State Technical University  
(Barnaul, Russia)

## CREATION OF A SHORT-TERM LOAD FORECASTING NEURAL NETWORK MODEL OF ELECTRICAL ENGINEERING COMPLEX OF SECTION REGIONAL ELECTRIC GRID 6-35 kV

**Aim:** Is developing of short-term load forecasting math model of the electrical engineering complex of the district regional electric grid 6-35 kV with the use of artificial neural networks.

**Methods:** The tools of regression analysis and deep machine learning were used in the work.

**Results:** The neural network model for short-term load forecasting of the electrical engineering complex of section regional electric grid 6-35 kV, which considered factors of time, meteorological conditions, disconnections of individual power transmission lines, the operation mode of electricity consumers with a capacity of over 670 kW, the fact of the availability of central heating and water supply, has been obtained.

**Conclusion:** The developed neural network math model reduces the problem of short-term load forecasting to the search of matrix free coefficients through training on the available statistical data.

**Keywords:** load forecasting, factors, wholesale electricity market, machine learning, regional electric grid.

## ВВЕДЕНИЕ

В настоящее время, огромное количество энергоресурсов потребляется на пуски и остановки генерирующего оборудования. Для минимизации числа необоснованных изменений режима работы генерирующего оборудования, Системный оператор Единой энергетической системы (ЕЭС) составляет диспетчерский график функционирования ЕЭС. При составлении данного диспетчерского графика учитываются краткосрочные прогнозы электропотребления крупных потребителей электроэнергии на оптовом рынке электроэнергии и мощности (ОРЭМ). Следовательно, в условиях функционирования рынка электроэнергии точность прогнозов потребления существенно влияет на технологические и экономические показатели энергосистемы [1]. Как участники рынка, каждый поставщик и потребитель хочет получить наибольшую выгоду от оборота электроэнергии [2]. Ценовая конъюнктура на ОРЭМ складывается так, чтобы стимулировать крупных покупателей электроэнергии придерживаться собственных прогнозов.

Основными покупателями электроэнергии на ОРЭМ являются гарантирующие поставщики электроэнергии (ГП), которые подразделяются на:

- гарантирующие поставщики первого уровня – крупные энергосбытовые компании, которые покупают электроэнергию по одной группе точек поставки электроэнергии (ГТП). Как правило, на долю покупки электроэнергии ГП первого уровня приходится большая часть электропотребления региона Российской Федерации;
- гарантирующие поставщики второго уровня – энергосбытовые компании, которые осуществляют покупку электроэнергии по одной или нескольким группам точек поставки электроэнергии (ГТП), соответствующие определенному участку районных электрических сетей территориальной сетевой организации.

Задачи краткосрочного прогнозирования электропотребления (short-term load forecasting – STLF) гарантирующего поставщика первого уровня и энергосистемы региона в целом схожи. В то же время, задача STLF ГТП гарантирующего поставщика второго уровня сводится к задаче прогнозирования электропотребления более мелкого электротехнического комплекса участка районных электрических сетей, от которого питается один или несколько районов субъекта страны или крупного города.

Временной ряд почасового электропотребления электротехнического комплекса участка районных электрических сетей зависит от множества факторов, часть из которых несут недетерминированный характер [3]. Данное обстоятельство делает задачу STLF для данного временного ряда слабоформализуемой.

В литературе хорошо освещен вопрос прогнозирования электрических нагрузок на разные временные горизонты. Методы повышения точности STLF можно подразделить на: методы математической статистики, методы искусственного интеллекта и гибридные методы [4, 5]. Однако, в условиях неопределенности, традиционные методы математической статистики или имитационного моделирования не позволяют строить адекватные модели объектов [6].

В настоящее время наблюдается стремительное развитие таких областей информационных технологий, как искусственный интеллект, системы обработки больших объемов данных (Big Data) и глубокое машинное обучение. Рассмотренные информационные технологии являются высокоэффективным инструментом для решения широкого перечня задач, которые относятся к слабоформализуемым или неформализуемым [7].

За прошедшее десятилетие ученые разработали множество методов повышения точности STLF на основе алгоритмов машинного обучения. Невзирая на их огромное количество, ни один из методов не может быть назван универсальным. В работах [8, 9] применены устаревшие алгоритмы машинного обучения, такие как метод опорных векторов и метод главных компонент. В настоящее время, передовые позиции в машинном обучении занимают алгоритмы глубоких нейронных сетей: многослойные персептроны, сверточные нейронные сети и рекуррентные нейронные сети. Данные алгоритмы показывают лучшие результаты при решении практических задач распознавания образов, прогнозирования временных рядов, аппроксимации функций и т.д.

Также, точность краткосрочного прогнозирования зависит от качества выборки связанных статистических данных [10]. Существующие математические модели электропотребления энергосистем или отдельных зданий [1, 5, 8–14] не учитывают ряд факторов, которые оказывают значительное влияние на временной ряд электропотребления

электротехнического комплекса участка районных электрических сетей 6–35 кВ, такие как:

- отключения отдельных питающих линий электропередач 6–35 кВ;
- режим работы потребителей электроэнергии с мощностью свыше 670 кВт;
- наличие центрального отопления и горячего (холодного) водоснабжения в отдельном населенном пункте.

В связи с учетом дополнительных факторов при STLF, остаются открытыми вопросы выбора оптимальной архитектуры и конфигурации нейросетевой модели, при которых достигается максимальная точность прогнозирования. В то же время, до сих пор не существует формализованных методов проектирования и настройки параметров искусственных нейронных сетей (ИНС). Под каждую конкретную задачу необходимо разрабатывать собственную нейронную сеть, для которой оптимальное значение всех гиперпараметров подбирается на основе многочисленных опытов с обучающей и тестовой выборкой.

### МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ЭЛЕКТРОПОТРЕБЛЕНИЯ ЭЛЕКТРОТЕХНИЧЕСКОГО КОМПЛЕКСА УЧАСТКА РАЙОННОЙ ЭЛЕКТРИЧЕСКОЙ СЕТИ

На основании анализа, проведенного в [3], почасовое электропотребление электротехнического комплекса участка районной электрической сети можно представить в виде функции влияющих факторов:

$$y = f_1(x_1, x_2, \dots, x_c) + f_2(x_{c+1}, x_{c+2}, \dots, x_l) + \varepsilon, \quad (1)$$

где  $y$  – почасовое электропотребление электротехнического комплекса участка районной электрической сети;

$f_1, f_2$  – функциональные зависимости, устанавливающие взаимосвязь между влияющими факторами и почасовым электропотреблением;

$x_1, x_2, \dots, x_c$  – набор эндогенных факторов;

$x_{c+1}, x_{c+2}, \dots, x_l$  – набор экзогенных факторов;

$l$  – общее количество влияющих факторов.

$\varepsilon$  – шумовая составляющая.

К эндогенным воздействиям можно отнести временные факторы (порядковый номер дня в году, день недели, признак праздничного и предпраздничного дня т.д.). К экзогенным факторам можно отнести метеорологические условия [15], плановые отключения электросетевого оборудования, факт наличия центрального отопления и водоснабжения и

т.д. На шумовую составляющую приходятся факторы аварийных отключений электросетевого оборудования, центрального отопления и водоснабжения, поломки основного оборудования крупных потребителей электроэнергии ГТП [3].

Так как системы электро-, водо- и теплоснабжения достаточно надежны, то можно посчитать, что шумовая составляющая  $\varepsilon$  пренебрежительно мала. Следовательно, при STLF участка районной электросети необходимо восстановить функциональные зависимости  $f_1, f_2$ , соответствующие эндогенным и экзогенным факторам.

Задача STLF электротехнического комплекса участка районных электрических сетей усложняется тем, что необходимо спрогнозировать суточный график электрической нагрузки, а не только его отдельные значения. Следовательно, выражение (1) необходимо представить в векторном виде:

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_h \end{bmatrix} = f_1(\overline{x_1}, \overline{x_2}, \dots, \overline{x_c}) + f_2(\overline{x_{c+1}}, \overline{x_{c+2}}, \dots, \overline{x_l}), \quad (2)$$

где  $Y$  – вектор суточного электропотребления электротехнического комплекса участка районной электрической сети;

$h = 24$  – количество часов в сутках;

$$\overline{x_i} = \begin{bmatrix} x_{i1} \\ x_{i2} \\ \dots \\ x_{i24} \end{bmatrix} \text{ – вектор суточных значений } i\text{-го влияющего фактора.}$$

Так как, стандартные метода математической статистики, такие как корреляционный и регрессионный анализ, малопригодны для прогнозирования поведения такой сложной функциональной зависимости, как временной ряд электропотребления электротехнического комплекса участка районной электрической сети, необходимо прибегнуть к инструментам нейросетевого анализа. Для представления выражения (2) в виде нейросетевой математической модели, рассмотрим принцип функционирования одного искусственного нейрона в первом скрытом слое. На Рис. 1 представлена функциональная схема искусственного нейрона.

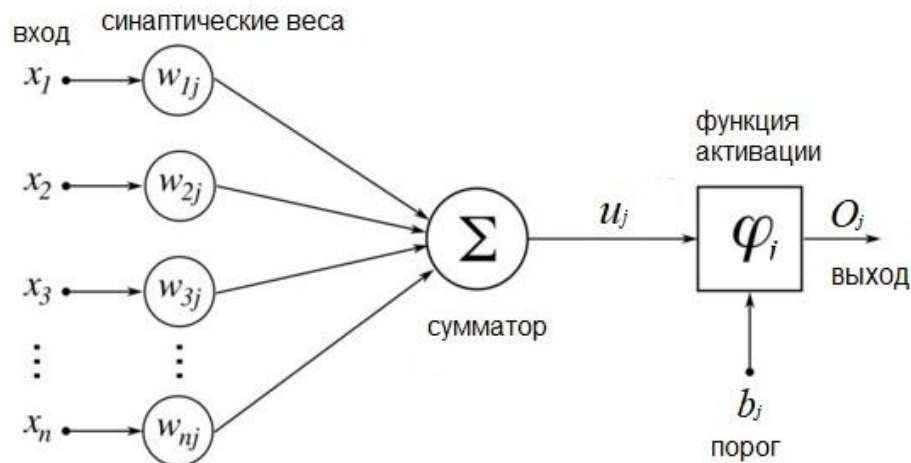


Рис.1. Функциональная схема искусственного нейрона

Схема, представленная на Рис. 1 состоит из следующих основных элементов:

- входных воздействий – характеризуются уровнем сигнала  $x_i$ ;
- набора синаптических связей – характеризуются весовым коэффициентом  $w_i$ ;
- сумматора – складывает входные сигналы, взвешенные на веса соответствующих синаптических связей;
- порога – увеличивает или уменьшает амплитуду сигнала, подаваемого на вход функции активации;
- функция активации – ограничивает амплитуду выходного сигнала нейрона. Обычно диапазон амплитуд лежит в интервале  $[0;1]$  или  $[-1;1]$  в зависимости от вида функции активации.

Математически функционирование нейрона можно представить следующей системой уравнений:

$$\begin{cases} u_j = \sum_{i=1}^n w_{ij} x_i \\ v_j = u_j + b_j \\ O_j = \varphi(v_j) \end{cases}, \quad (3)$$

где  $u_j$  – линейная комбинация входных воздействий на нейрон  $j$ ;

$w_{ij}$  – вес синаптической связи соединяющей вход  $i$  и нейрон  $j$ ;

$x_i$  – входной сигнал нейрона;

$v_j$  – индуцированное локальное поле нейрона;

$b_j$  – порог активации нейрона;

$O_j$  – выходной сигнал нейрона;

$\varphi(v_j)$  – функция активации нейрона.



Для удобства выкладок, выразим порог активации через дополнительную синаптическую связь с весом  $w_0$  и фиксированным входным сигналом  $x_0=1$ :

$$O_j = \varphi(v_j) = \sum_{i=0}^n w_{ij} x_i \quad (4)$$

На Рис. 2 представлена структурная схема нейронной сети с произвольным количеством слоев.

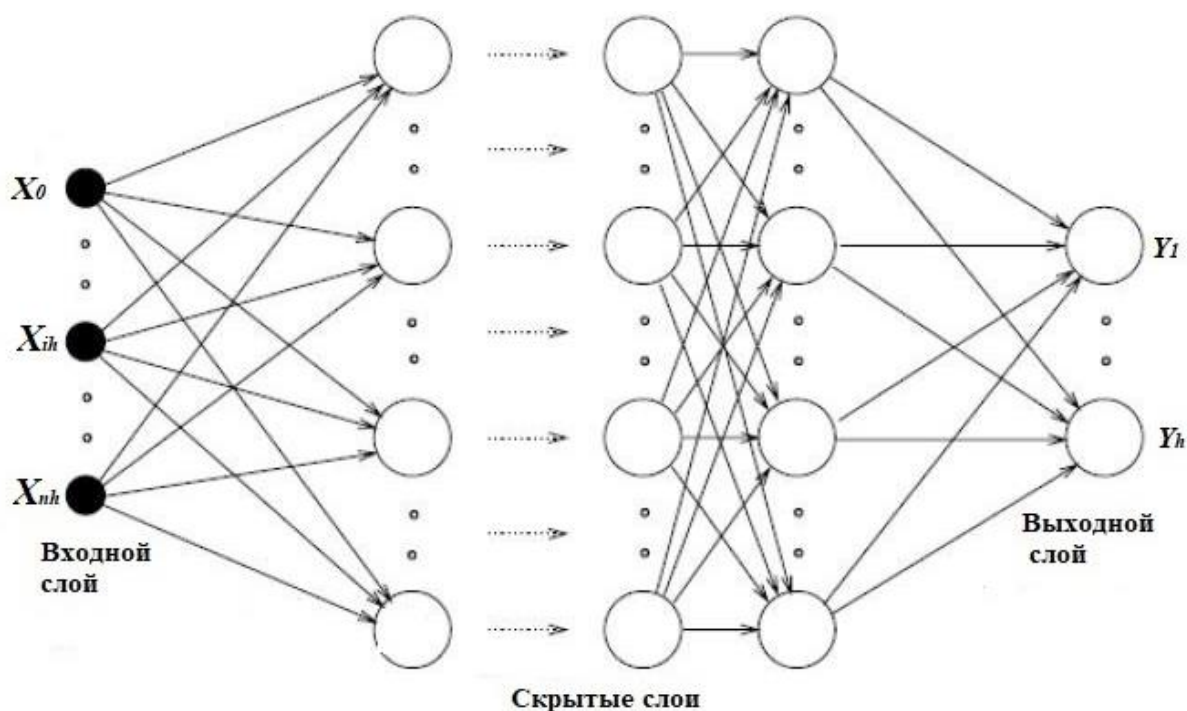


Рис. 2. Структурная схема нейронной сети с произвольным количеством слоев

Нейронная сеть, представленная на Рис. 2, состоит из:

- входного слоя сенсорных элементов, которые получают информацию непосредственно из «внешней среды»;
- скрытых слоев, в которых происходят основные вычисления ИНС;
- выходного слоя, формирующего итоговый отклик нейронной сети.

Расположение нейронов послойно очень важно с вычислительной точки зрения, так как появляется возможность векторизовать процесс обработки данных в ИНС. Другими словами, все операции в ИНС производятся с помощью матричных операций сложения, скалярного произведения и т.д.

По своей сути, выражение (4) представляет собой скалярное произведение векторов весовых коэффициентов  $w$  на вектор входных

сигналов  $x$ . Если на вход нейронной сети подается вектор суточных значений факторов, влияющих на электропотребление ГТП гарантирующего поставщика второго уровня, размером  $n=24 \cdot l$ , то выражение (4) можно записать в виде:

$$O_j = \varphi_j \left( \begin{bmatrix} w_1 \\ w_2 \\ \dots \\ w_n \end{bmatrix}^T \cdot \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{bmatrix} \right), \quad (5)$$

Тогда, общий отклик скрытого слоя ИНС, состоящего из  $k$  нейронов, можно представить в виде:

$$O_1 = f(W_{01}, X) = \begin{bmatrix} O_1 \\ O_2 \\ \dots \\ O_k \end{bmatrix} = \varphi_k \left( \begin{bmatrix} w_{01} & w_{02} & \dots & w_{0n} \\ w_{11} & w_{12} & \dots & w_{1n} \\ \dots & \dots & \dots & \dots \\ w_{k1} & w_{k2} & \dots & w_{kn} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{bmatrix} \right), \quad (6)$$

где  $O_1$  – вектор отклика слоя первого скрытого слоя ИНС;

$W_{01}$  – матрица весовых коэффициентов между входным и первым скрытым слоем нейронной сети размером  $n \times k$ ;

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{bmatrix} \text{ – массив суточных значений влияющих факторов;}$$

$w_{kn}$  – весовой коэффициент соединяющий  $n$ -ый входной узел и  $k$ -ый нейрон скрытого слоя;

Далее, отклик  $O_1$  становится входным сигналом для следующего слоя скрытого слоя нейронной сети, и, на основании выражения (6), рассчитывается отклик следующего слоя, и т.д. Итоговой отклик нейронной сети, который является почасовым прогнозом электропотребления ГТП ГП второго уровня, формируется на основании выражения:

$$Y = \varphi(W_{mh} O_m), \quad (7)$$

где  $W_{mh}$  – матрица весовых коэффициентов между последним скрытым слоем  $m$  и выходным слоем  $h$ ;

$O_m$  – отклик последнего скрытого слоя  $m$ .



На основании выражения (6) и выражения (7) можно сделать вывод о том, что задача краткосрочного прогнозирования электропотребления электротехнического комплекса участка районных электрических сетей сводится к подбору всех свободных параметров нейросетевой модели. Свободные параметры нейронных сетей определяются посредством обучения на имеющихся статистических данных. База статистических данных формируется на основании информации о величине всех факторов, влияющих на поведение временного ряда электропотребления в краткосрочной перспективе.

## ЗАКЛЮЧЕНИЕ

Полученная математическая модель электропотребления электротехнического комплекса участка районных электрических сетей 6-35 кВ учитывает, помимо стандартных эндогенных (временных) и метеорологических факторов, экзогенные факторы отключений фидеров 6-110 кВ, режима работы потребителей электроэнергии мощностью свыше 670 кВт, факта наличия водоснабжения и центрального отопления в отдельных населенных пунктах. Электропотребление электротехнических комплексов других номиналов напряжения, в том числе, свойственных транспортным системам, будет характеризоваться другим набором влияющих факторов. Это, в свою очередь, повлияет на размер матрицы весовых коэффициентов (выражение 6), но принцип вычислений останется тем же. В связи с тем, что стандартные методы регрессионного анализа не позволяют строить адекватные модели прогнозирования такой сложной функциональной зависимости, как временной ряд электропотребления участка районных электрических сетей, необходимо прибегнуть к инструментам машинного обучения. Разработанная нейросетевая математическая модель сводит задачу краткосрочного прогнозирования электропотребления к поиску матрицы свободных коэффициентов посредством обучения на имеющихся статистических данных.

### Авторы заявляют что:

1. У них нет конфликта интересов;
2. Настоящая статья не содержит каких-либо исследований с участием людей в качестве объектов исследований.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК / References

1. Доманов В.И., Билалова А.И. Прогнозирование объемов энергопотребления в зависимости от исходной информации // Вестник ЮУрГУ. Серия «Энергетика». – 2016. – Т. 16, – № 2. – С. 59–65. [Domanov VI, Bilalova AI. Forecasting power consumption based on source information. Bulletin of the South Ural State University. Series “Power Engineering”. 2016;16(2):59-65. (In Russ.)]. doi: 10.14529/power160208

2. Gao G, Lo K, Lu JF, et al. A short-term electricity price forecasting scheme for power market. *World Journal of Engineering and Technology*. 2016;4:58-65. doi: 10.4236/wjet.2016.43D008
3. Серебряков Н.А., Хомутов С.О. Анализ случайной составляющей временного ряда электрической нагрузки группы точек поставки электроэнергии сельхозпроизводителей // Вестник Алтайского государственного аграрного университета. – 2019. – № 5 (175). – С. 153 -158 [Serebriakov NA, Homutov SO. Analysis of the random component of electric load time series of delivery point cluster agricultural producers. *Vestnik Altaiskogo gosudarstvennogo agrarnogo universiteta*. 2019;5(175):153-158 (In Russ.)] Доступно по: <http://www.asau.ru/vestnik/2019/5/>
4. Zheng H, Yuan J, Chen L. Short-term load forecasting using EMD-LSTM neural networks with a XGBOOST algorithm for feature importance evaluation. *Energies*. 2017;10:1-20. doi:10.3390/en10081168
5. López M, Sans C, Valero S, et al. Empirical comparison of neural network and auto-regressive models in short-term load forecasting. *Energies*. 2018;11:1-19. doi:10.3390/en11082080
6. Катасёв А. С. Нейронечеткая модель формирования нечетких правил для оценки состояния объектов в условиях неопределенности // Компьютерные исследования и моделирование. – 2019. – Т. 11 – No 3. – С. 477–492. [Katasev AS. Neuro-fuzzy model of fuzzy rules formation for objects state evaluation in conditions of uncertainty. *Komp'yuternye issledovaniia i modelirovanie*. 2019;11(3):477-492. (In Russ.)]. doi: 10.20537/2076-7633-2019-11-3-477-492
7. Станкевич Т.С. Разработка метода оперативного прогнозирования динамики развития лесного пожара посредством искусственного интеллекта и глубокого машинного обучения // Вестник Иркутского государственного технического университета. – 2018. – Т. 22. – № 9. – С. 111–120. [Stankevich TS. Development of operational prediction method of forest fire dynamics based on artificial intelligence and deep machine learning *Proceedings of Irkutsk State Technical University*. 2018;22(9):111-120. (In Russ.)]. doi: 10.21285/1814-3520-2018-9-111-120
8. Кирпичникова, И.М. Прогнозирование объемов потребления электроэнергии // Вестник ЮУрГУ. Серия «Энергетика». – 2014. – Т. 14. – № 2. – С. 16–21. [Kirpichnikova, IM. Energy consumption forecasting. *Bulletin of the South Ural State University. Series "Power Engineering"*. 2014;14(2):16-22. (In Russ.)]. Доступно по: <https://www.elibrary.ru/item.asp?id=21682908>
9. Надтока И.И., Аль Зихери Б.М. Краткосрочное прогнозирование электропотребления региона с учетом метеофакторов на основе метода опорных векторов и алгоритма роя частиц // Изв. вузов. Электромеханика. – 2014. – № 3. – С. 44–48. [Nadtoka II, Al' Zikheri BM. Kratkosrochnoe prognozirovanie elektropotrebleniia regiona s uchetom meteofaktorov na osnove metoda opornykh vektorov i algoritma roia chastits. *Izv. vuzov. Elektromekhanika*. 2014;3:44-48. (In Russ.)] Доступно по: <http://electromeh.npi-tu.ru/ru/archive/2014/issue3/nadtoka>
10. Li MW, Geng J, Hong WC, et al. Hybridizing chaotic and quantum mechanisms and fruit fly optimization algorithm with least square support vector regression model in electric load forecasting. *Energies*. 2018;11(2226):1-22. doi:10.3390/en11092226
11. Wang Z, Srinivasan R. A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single and ensemble prediction models.

- Renewable and Sustainable Energy Reviews. 2017;75:796-808. doi: 10.1016/j.rser.2016.10.079
12. Торопов А.С., Туликов А.Н. Прогнозирование почасового электропотребления региональной энергосистемы с использованием искусственных нейронных сетей // Вестник Иркутского государственного технического университета. – 2017. – Т. 21. – № 5. – С. 143–151. [Toropov AS, Tulikov AN. Forecasting of regional power supply system power consumption per hour using artificial neural networks. Proceedings of Irkutsk State Technical University. 2017;21(5):143-151]. doi: 10.21285/1814-3520-2017-5-143-151
  13. Иванин О. А., Директор Л. Б. Применение искусственных нейронных сетей для прогнозирования энергетических нагрузок обособленных потребителей // Теплоэнергетика. – 2018. – № 5. – С. 17–26. Primenenie iskusstvennykh neironnykh setei dlia prognozirovaniia energeticheskikh nagruzok obosoblennykh potrebitelei [Ivanin OA, Direktor LB. Application of artificial neural networks to predict energy loads of isolated consumers. Teploenergetika. 2018;5:17-26]. doi: 10.1134/S0040363618050041
  14. Mocanu E. Nguyen PH, Gibescu M, et al. Deep learning for estimating building energy consumption. Sustainable Energy. Grids and Networks. 2016;6:91-99. doi: 10.1016/j.segan.2016.02.005
  15. Rajan DV, Sourav M, Thakur SS. An efficient approach for short-term load forecasting using historical data. International Journal of Engineering Research & Technology. 2012;3:1-9. Режим доступа: <https://www.ijert.org/research/an-efficient-approach-for-short-term-load-forecasting-using-historical-data-IJERTV1IS3193.pdf>

**Сведения об авторах:**

**Хомутов Станислав Олегович**, д.т.н., профессор;

eLibrary SPIN: 8613-0404; ORCID: 0000-0001-7428-7364; Scopus ID: 57193488394;

E-mail: homutov.so@yandex.ru

**Серебряков Николай Александрович**, аспирант;

eLibrary SPIN: 8639-6888; ORCID: 0000-0002-8430-9384;

E-mail: na\_serebryakov@altke.ru

**Information about the authors:**

**Stanislav O. Khomutov**, Dr. Sc., professor;

eLibrary SPIN: 8613-0404; ORCID: 0000-0001-7428-7364; Scopus ID: 57193488394;

E-mail: homutov.so@yandex.ru

**Nikolay A. Serebryakov**, postgraduate student;

eLibrary SPIN: 8639-6888; ORCID: 0000-0002-8430-9384;

E-mail: na\_serebryakov@altke.ru

**Цитировать:**

Хомутов С.О., Серебряков Н.А. Создание нейросетевой математической модели краткосрочного прогнозирования электропотребления электротехнического комплекса участка районных электрических сетей // Транспортные системы и технологии. – 2020. – Т. 6. – № 1. – С. 80–91. doi: 10.17816/transsyst20206180-91

**To cite this article:**

Khomutov SO, Serebryakov NA. Creation of a Short-Term Load Forecasting Neural Network Model of Electrical Engineering Complex of Section Regional Electric Grid. *Transportation Systems and Technology*. 2020;6(1):80-91. doi: 10.17816/transsyst20206180-91