

УДК 621.31

ББК 31.2

Д.В. БОРТНИК, А.И. ОРЛОВ

## СРАВНЕНИЕ АРХИТЕКТУР НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧЕ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ ПРЕДПРИЯТИЕМ

**Ключевые слова:** нейронная сеть, рекуррентные нейронные сети, WaveNet, прогнозирование, одномерные сверточные сети.

Прогнозирование потребления электроэнергии является ключевым инструментом для предприятий, энергоснабжающих и электросетевых организаций. Точное прогнозирование позволяет планировать распределение ограниченных ресурсов электросетевого хозяйства, а также управлять спросом на электроэнергию. Повышение точности прогнозирования электропотребления становится особенно важным в условиях распространения технологий управления спросом.

**Целью исследования** является повышение точности прогнозирования электропотребления объектом электроснабжения при использовании нейронных сетей.

**Материалы и методы.** В работе использован набор данных, содержащий профиль мощности предприятия за трехмесячный период, а также дополнительные данные, такие как время суток, день недели, выходные и праздничные дни, месяц. Набор данных разделен на тренировочную и контрольную части. Произведены предварительная обработка данных, проектирование архитектуры нейронной сети, обучение и тестирование. Критериями качества обучения выбраны средняя абсолютная ошибка, среднеквадратическая ошибка и коэффициент детерминации.

**Результаты исследования.** В работе выполнен сравнительный анализ трех архитектур нейронных сетей: одномерной сверточной сети, рекуррентной нейронной сети с долговременной и краткосрочной памятью и WaveNet, на основе которого были оценены их показатели качества прогнозирования электропотребления. Показано, что все рассматриваемые архитектуры нейронных сетей подходят для применения в задаче прогнозирования электропотребления. Сети с долговременной и краткосрочной памятью показали хорошие результаты в прогнозировании мощности, благодаря их способности обрабатывать долгосрочные временные зависимости. Архитектура WaveNet превзошла как рекуррентные нейронные сети на основе модели с долговременной и краткосрочной памятью, так и одномерные сверточные сети по выбранным критериям.

**Выводы.** Исследование позволило сделать вывод о том, что использование нейронных сетей, особенно архитектур с долговременной и краткосрочной памятью и WaveNet, эффективно для прогнозирования электропотребления. Качество прогнозирования существенно зависит от выбора гиперпараметров и предварительной обработки исходных данных. Перспективу дальнейших исследований в данной области составляет изучение влияния различных факторов на точность прогнозирования, а также оптимизация процесса обучения нейронных сетей.

**Введение.** Нейронные сети широко применяются для моделирования сложных процессов, классификации и прогнозирования различных процессов, в том числе в электроэнергетике. Так, прогнозирование энергопотребления позволяет предприятиям планировать распределение ресурсов. Для сетевых организаций прогнозирование потребления позволяет обеспечить стабильность сети и более эффективно управлять спросом на энергию.

Для решения задач прогнозирования временных рядов существует несколько методов, включая регрессионный анализ и использование нейронных

сетей [1]. Метод регрессии основан на статистическом анализе связи между зависимой переменной и одной или несколькими независимыми переменными. В контексте прогнозирования временных рядов это означает использование прошлых значений временного ряда в качестве независимых переменных для прогнозирования будущих значений.

К типам нейронных сетей, применяемых для анализа временных рядов, относятся рекуррентные нейронные сети (RNN), сверточные нейронные сети (CNN) [6] и нейронные сети типа WaveNet [7]. Возможность предсказания последовательностей в рекуррентных нейронных сетях связана с сохранением текущего состояния и передачей его в следующую итерацию. К наиболее распространенным типам таких сетей относятся простая рекуррентная нейронная сеть (Simple RNN) и нейронная сеть с долгой кратковременной памятью (LSTM) [13]. Сверточные нейронные сети (CNN), обычно используемые при анализе изображений, могут применяться также для прогнозирования временных рядов [10]. Одна из возможных архитектур CNN для такой задачи – это 1D сверточная нейронная сеть, описанная в работе [12]. Архитектура нейронной сети WaveNet предполагает использование длинных сверточных фильтров, которые позволяют запоминать длительные зависимости во временном ряду. В отличие от сверточных нейронных сетей, которые используют фильтры фиксированной длины, WaveNet использует фильтры с переменной длиной.

Известно большое количество работ, в которых нейронные сети применяются для прогнозирования временных рядов. Так, в статьях [3, 4] авторы описывают результаты исследований, направленные на повышение точности краткосрочного прогнозирования суточных графиков активной мощности. В работе использовались четыре прогнозные модели, включая сингулярный спектральный анализ (SSA), метод наименьших квадратов, тригонометрическую интерполяцию, а также нейронные и нечеткие нейронные сети (ННС). Настоящая работа посвящена исследованию новых архитектур нейронных сетей в задаче прогнозирования электропотребления.

К проблемам, с которыми обычно сталкиваются при прогнозировании энергопотребления, относятся:

1. Игнорирование значимых факторов, влияющих на энергопотребление. Так, некоторые модели учитывают только временные зависимости без учета сезонности, погодных условий, дневного ритма и других факторов.

2. Отсутствие точных данных. Например, информация о погодных условиях или об изменении потребления может быть неполной или неточной, что может привести к неточным прогнозам.

3. Изменения в потреблении электроэнергии со временем из-за различных факторов, таких как изменение образа жизни людей, изменение технических характеристик оборудования и совершенствование производственных процессов. Нейросетевые модели не всегда способны адаптироваться к таким динамическим изменениям, что приводит к неточности прогнозов.

4. Взаимосвязь потребления электроэнергии с экономическими показателями, например, ценами на энергоносители [8].

Решение этих проблем предполагает создание более точных и гибких моделей прогнозирования, использование более широкого набора исходных

данных, а также учет неопределенности и непредсказуемости в моделях прогнозирования [13].

**Целью исследования** является сравнение точности работы трех различных архитектур нейронных сетей – одномерной сверточной сети, WaveNet и рекуррентной нейронной сети с моделью LSTM – при прогнозировании энергопотребления.

Новизна заключается в применении архитектуры WaveNet, изначально разработанной для моделирования звуковых сигналов, прогнозирования энергопотребления с использованием причинно-следственных сверток, что позволяет сети фиксировать долгосрочные зависимости в данных.

**Материалы и методы.** В работе приводится сравнение качества прогнозирования энергопотребления при использовании нейронных сетей различных архитектур: одномерной сверточной нейронной сети CNN, сети типа WaveNet и рекуррентной нейронной сети на основе модели LSTM.

В качестве критериев качества обучения нейронной сети обычно применяются метрики MSE, MAE,  $R^2$  [9]. Средняя квадратичная ошибка (MSE) определяется как среднее значение квадратов разностей между прогнозами модели и фактическими значениями. Средняя абсолютная ошибка (MAE) рассчитывается как среднее значение разностей абсолютных значений между прогнозируемыми и фактическими значениями. Метрики MSE и MAE показывают, насколько близки в среднем прогнозные значения к фактическим. Для качественной модели данные метрики близки к нулю. Коэффициент детерминации ( $R^2$ ) применительно к задаче прогнозирования определяется как  $1 - D(e)/D(y)$ , где  $D(e)$  – дисперсия разностей прогнозных и фактических значений;  $D(y)$  – дисперсия прогнозных значений. Значение метрики  $R^2$  находится в диапазоне от 0 до 1, где 1 означает идеальное соответствие модели данным, а 0 означает, что модель не соответствует данным лучше, чем простое среднее значение.

В качестве набора данных использовался трехмесячный профиль потребления мощности предприятием, включающий 2210 значений. В качестве дополнительных факторов использовались такие параметры, как время суток, день недели, месяц. Из 2210 часов профиля мощности 1000 часов использовалось для обучения модели, 1210 для валидации. На вход модели подавался 300-часовой фрагмент профиля мощности, на выходе получали 200 часов прогнозного профиля мощности, после чего выполнялось сравнение прогнозных и истинных значений.

Использованы такие методы исследования, как сбор данных, предварительная обработка данных, проектирование архитектуры нейронной сети, обучение и тестирование, оценка производительности, статистический анализ. Расчеты проводились с использованием модулей Tensorflow и Keras [2] для языка программирования Python [11].

**Результаты исследования.** Рассмотрим результат работы рекуррентной нейронной сети (RNN) с долговременной кратковременной памятью (LSTM), которые обычно применяются для задач последовательной обработки данных, включая прогнозирование временных рядов. Использование RNN с LSTM для прогнозирования энергопотребления включает следующие этапы:

1. Предварительная подготовка данных для использования при обучении и тестировании RNN: сбор данных, их нормализация, добавление информации

о таких параметрах, влияющих на потребление электроэнергии, как время суток, день недели, выходные и праздничные дни, месяц [5].

2. Разработка модели: определение архитектуры нейронной сети, точная настройка таких гиперпараметров, как количество скрытых слоев, скорость обучения и размер пакета, для оптимизации производительности модели и точности прогнозирования [15].

3. Обучение и проверка RNN на предварительно обработанных данных [10].

4. Оценка качества обучения нейронной сети: после обучения RNN с LSTM производится оценка точности прогнозирования. Для этого применялись следующие метрики: среднеквадратическая ошибка (MSE), средняя абсолютная ошибка MAE и коэффициент детерминации ( $R^2$ ).

В качестве альтернативы RNN с LSTM рассматривалась одномерная сверточная сеть (CNN) [14], которая имеет только одну входную переменную. Архитектура CNN состоит из сверточного слоя, принимающего входные данные временных рядов, за которым следуют один или несколько полносвязных слоев, преобразующих выходные данные сверточного слоя в окончательные выходные данные. Сверточный слой выполняет серию сверток входных данных (временных рядов), используя набор обучаемых фильтров или ядер. В результате CNN фиксирует закономерности и тенденции в данных временных рядов. Сверточный слой способен обнаруживать локальные закономерности в исходных временных рядах, в то время как полносвязные слои могут захватывать более глобальные закономерности.

В работе также рассматривалась архитектура глубокой нейронной сети типа WaveNet. Сеть составлена из 3 расширенных сверточных слоев, которые позволяют фиксировать долгосрочные временные зависимости в данных. Каждый сверточный слой использует набор обучаемых фильтров или ядер для извлечения признаков из входных данных временных рядов.

Изменение метрики потерь нейронных сетей типов LSTM, CNN и WaveNet при обучении в зависимости от номера эпохи показана на рис. 1. Результаты обучения представлены на рис. 2. Метрика потерь (loss) является числовой оценкой разницы между прогнозируемыми значениями модели и фактическими значениями (целевыми данными) во время обучения. Она представляет собой меру того, насколько хорошо модель справляется с задачей прогнозирования. Обычно метрика потерь вычисляется как функция от разницы между прогнозируемыми и целевыми значениями. В случае регрессии распространенной метрикой потерь является среднеквадратическая ошибка (mean squared error, MSE). Низкое значение метрики потерь обычно указывает на более точную модель. В контексте прогнозирования энергопотребления, минимальное значение метрики потерь 0,04 может указывать на то, что модель достаточно обучена.

Результаты расчета значений метрик MSE, MAE,  $R^2$  для нейронных сетей типов LSTM, CNN и WaveNet в рассматриваемой задаче прогнозирования представлены в таблице.




Рис. 1. Метрика потерь  $loss(MSE)$  нейронных сетей типов LSTM (а), CNN (б), WaveNet (в) при обучении в зависимости от номера эпохи  $e$ :

1 – тренировочный набор данных; 2 – контрольный набор данных




Рис. 2. Результаты предсказания профиля мощности нейронных сетей типов LSTM (а), CNN (б), WaveNet (в):  $P^*$  – мощность, усредненная на интервале в 1 ч, о.е.;  $t$  – время, сут.; 1 – фрагмент профиля мощности, используемого в качестве тренировочного; 2 – фактические значения профиля мощности; 3 – результат предсказания

#### Метрики качества работы нейронной сети на контрольном наборе данных

Тип нейронной сети	MSE	MAE	R <sup>2</sup>
RNN с LSTM-ячейками	0,043	0,116	0,126
CNN	0,046	0,163	0,065
WaveNet	0,033	0,146	0,337

Оценивая результаты предсказания профилей мощности, представленные на рис. 2, и метрики качества, можно отметить, что RNN с LSTM в целом удовлетворительно справляются с задачей прогнозирования, но с увеличением глубины прогноза точность значительно падает. Как показывают результаты

моделирования, архитектура WaveNet по сравнению с архитектурами LSTM и CNN позволяет фиксировать сложные закономерности в данных, включая нелинейные отношения и сезонность при прогнозировании как на краткосрочном, так и на долгосрочном интервале. Недостатком WaveNet является ее вычислительная сложность.

С точки зрения практической значимости для прогнозирования профиля мощности выбор оптимальной архитектуры нейронной сети зависит от конкретного объекта электроснабжения. Важно отметить, что качество прогнозирования зависит не только от архитектуры нейронной сети, но и от выбора гиперпараметров, наличия дополнительных рядов данных, связанных с потреблением электроэнергии, а также от качества предварительной подготовки исходных данных в целом. Учет типа потребителя электроэнергии, корректный выбор дополнительных наборов данных, коррелирующих с целевым профилем мощности, требует дополнительных экспериментов с более длительными профилями мощности, что может составлять перспективу дальнейших исследований по теме работы.

**Вывод.** 1. Рекуррентные нейронные сети (RNN) и их варианты: сети с долговременной кратковременной памятью (LSTM), сверточные нейронные сети (CNN) и WaveNets могут применяться для прогнозирования профилей мощности.

2. Показано, что LSTM хорошо работают в задачах прогнозирования мощности, поскольку они могут обрабатывать долгосрочные зависимости и иметь память о прошлых событиях. CNN и WaveNets также могут подходить для задач прогнозирования мощности, где важны локальные временные закономерности и долгосрочные зависимости, соответственно.

3. Точность прогнозирования с использованием рассмотренных архитектур нейронных сетей зависит от длины обучающей выборки и количества дополнительных параметров, сложности модели и выбора гиперпараметров. Не самая высокая точность валидации в рассматриваемых примерах объясняется случайным характером потребления электроэнергии с периодом 2–3 ч с практически равномерной плотностью вероятности.

#### Литература

1. Алексеева И. Ю. Краткосрочное прогнозирование электропотребления в электроэнергетических системах с использованием искусственных нейронных сетей: автореф. дис. ... канд. техн. наук. Иваново, 2014. 20 с.

2. Арзамасцев А.А., Крючин О.В., Азарова П.А., Зенкова Н.А. Универсальный программный комплекс для компьютерного моделирования на основе искусственной нейронной сети с самоорганизацией структуры // Вестник Тамбовского университета. Сер. Естественные и технические науки. 2006. Т. 11, вып. 5. С. 372–375.

3. Вялкова С.А., Корнюкова О.А., Надтока И.И. Разработка моделей краткосрочного прогнозирования суточных графиков активной мощности г. Москвы // Проблемы машиноведения: материалы V Междунар. науч.-техн. конф. Омск: Изд-во ОмГТУ, 2021. С. 166–173.

4. Вялкова С.А., Надтока И.И. Прогнозирование суточных графиков активной мощности мегаполиса с учетом прогнозных данных естественной освещенности // Известия высших учебных заведений. Электромеханика. 2020. Т. 63, № 5. С. 67–71.

5. Мультипликативная модель сезонного энергопотребления предприятий / П.Р. Ахметьянов, Л.А. Делегодина, Н.П. Копылова и др. // Автометрия. 2008. Т. 44, № 3. С. 106–118.

6. Надтока И.И., Аль Зихери Б. М. Байесовская нейросетевая модель для краткосрочного прогнозирования электропотребления региона // Студенческая научная весна: материалы регион. науч.-практ. конф. студ., аспирантов и молодых ученых вузов Ростов. обл. Новочеркасск: ЮРГПУ (НПИ), 2012. С. 136–138.

7. Орельен Ж. Прикладное машинное обучение с помощью Scikit-Learn, Keras и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем. 2-е изд.: пер. с англ. СПб.: ООО «Диалектика», 2020. 1040 с.

8. Соловьева И.А., Дзюба А.П. Прогнозирование электропотребления с учетом факторов технологической и рыночной среды // Научный диалог. 2013. № 7(19). С. 97–111.

9. Aileen N. Practical Time Series Analysis: Prediction with Statistics and Machine Learning, O'Reilly Media; 1st edition (November 5, 2019), 504 p.

10. Chollet F. Deep Learning with Python. 2<sup>nd</sup> ed. Manning Publications, 2021, 384 p.

11. Hyndman R.J., Athanasopoulos G. Forecasting: principles and practice. Publisher: OTexts, 2013. 291 p.

12. Lazzari F. Machine Learning for Time Series Forecasting with Python. 1<sup>st</sup> ed. Wiley, 2020, 224 p.

13. Ruey S.T. Multivariate Time Series Analysis: With R and Financial Applications. 1<sup>st</sup> ed. Wiley, 2013, 520 p.

14. Shayeghi H. STLF Based on Optimized Neural Network Using PSO // International Journal of Electrical and Computer Engineering. 2009. 4:10. P. 1190–1199.

15. Zelinka I., Chen G., Rössler O.E., Snášel V., Abraham A. Nostradamus 2013: Prediction, Modeling and Analysis of Complex Systems. Springer International Publishing, Switzerland, 2013, 550 p.

---

**БОРТНИК ДЕНИС ВАЛЕРЬЕВИЧ** – аспирант кафедры электроснабжения и технической диагностики, Марийский государственный университет, Россия, Йошкар-Ола (bortnik\_denis16@mail.ru; ORCID: <https://orcid.org/0009-0002-7010-8271>).

**ОРЛОВ АЛЕКСАНДР ИГОРЕВИЧ** – кандидат технических наук, заведующий кафедрой электромеханики, Марийский государственный университет, Россия, Йошкар-Ола (a.i.orlov@yandex.ru; ORCID: <https://orcid.org/0000-0003-1152-6668>).

---

Denis V. BORTNIK, Aleksandr I. ORLOV

#### COMPARISON OF NEURAL NETWORK ARCHITECTURES TO PREDICTING ELECTRICITY CONSUMPTION BY ENTERPRISE

**Key words:** neural network, recurrent neural networks, WaveNet, prediction, one-dimensional convolutional networks.

*Forecasting of electricity consumption is a key tool for enterprises, energy supply and power grid organizations. Accurate forecasting enables to plan the distribution of limited resources of the power grid facilities, as well as to manage the demand for electricity. In the context of modern demand management technologies, improving the accuracy of forecasting of electricity consumption becomes especially important.*

**The purpose of the study** is to improve the accuracy of predicting power consumption by the power supply object using neural networks.

**Materials and methods.** The work used a data set containing a profile of the enterprise's capacity for a three-month period, as well as additional data, such as time of day, day of the week, weekends and holidays, month. The data set is divided into training and control parts. Preliminary data processing, neural network architecture design, training and testing were carried out. The criteria for the quality of training are the mean absolute error, the mean square error and the coefficient of determination.

**Research results.** In the work, a comparative analysis of three neural network architectures was performed: a one-dimensional convolutional network, a recurrent neural

network with long-term and short-term memory, and WaveNet, on the basis of which their indicators of the quality of power consumption forecasting were evaluated. It was shown that all considered architectures of neural networks are suitable for the use in the issue of predicting power consumption. Long-term and short-term memory networks have shown good results in power prediction due to their ability to handle long-term time dependencies. The WaveNet architecture outperformed both long-term and short-term memory model-based recurrent neural networks and one-dimensional convolutional networks by selected criteria.

**Conclusions.** The study led to the conclusion that the use of neural networks, especially architectures with long-term and short-term memory and WaveNet, is an effective approach for predicting power consumption. The quality of forecasting significantly depends on the choice of hyperparameters and preliminary processing of the initial data. Prospect for further research in this area is studying the influence of various factors on the accuracy of forecasting and optimization of the learning process of neural networks.

### References

1. Alekseeva I.Yu. *Kratkosrochnoe prognozirovanie elektropotrebleniia v elektroenergeticheskikh sistemakh s ispol'zovaniem iskusstvennykh neironnykh setei: avtoref. dis. ... kand. tekhn. nauk* [Short-term forecasting of energy consumption in the electrical systems using artificial neural networks. Abstract of Cand. Diss.]. Ivanovo, 2014. P. 9–10.
2. Arzamastsev A.A., Kriuchin O.V., Azarova P.A., Zenkova N.A. *Universal'nyi programmnyi kompleks dlia komp'iuternogo modelirovaniia na osnove iskusstvennoi neironnoi seti s samoorganizatsiei struktury g. Tambov* [Universal software complex for computer modeling based on artificial neural network with self-organizational structure in Tambov]. *Vestnik Tambovskogo universiteta. Ser. Estestvennye nauki i tekhnicheskie nauki*, 2006, vol. 11, iss. 5, pp. 372–375.
3. Vyalkova S.A., Kornukova O.A., Nadtoka I.I. *Razrabotka modelei kratkosrochnogo prognozirovaniya sutochnykh grafikov aktivnoi moshchnosti g. Moscow*. [Development of models for short-term forecasting of daily schedules of active power in Moscow.]. In: *Problemy mashinovedeniya: materialy V Mezhdunar. nauch.-tekhn. konf.* [Proc. of the V Int. Sci. and Tech. Conf. «Problems of machine science»]. Omsk, 2021, pp. 166–173.
4. Vyalkova S.A., Nadtoka I.I. *Prognozirovanie sutochnykh grafikov aktivnoi moshchnosti megapolisa s uchetom prognoznnykh dannykh estestvennoi osveshchennosti* [Forecasting daily schedules of the active power of the metropolis, taking into account the predictive data of natural illumination]. *Izvestiya vysshikh uchebnykh zavedenii. Elektromekhanika*, 2020, vol. 63, no. 5, pp. 67–71.
5. Akhmet'ianov R.R., Delegodina L.A., Kopylova N.P. et al. *Mul'tiplikativnaia model' sezonogo energopotrebleniia predpriatii* [Multiplicative model of seasonal energy consumption at enterprises]. *Avtometriya*, 2008, vol. 44, no. 3, pp. 106–118.
6. Nadtoka I.I., Al' Zikheri B.M. *Baiesovskaia neurosetevaia model' dlia kratkosrochnogo prognozirovaniia elektropotrebleniia regiona g. Novocherkassk* [Bayes neural network model for short-term forecasting energy consumption in the region in Novocherkassk]. In: *Studencheskaia nauchnaia vesna: Materialy regional'noi nauchno-prakticheskoi konferentsii studentov, aspirantov i molodykh uchenykh vuzov Rostovskoi oblasti* [Proc. of Sci. Conf. «Student Scientific Spring»]. Novocherkassk, 2012, pp. 136–138.
7. Aurélien G. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* Beijing [etc.]: O'Reilly, cop. 2020, 856 p. (Russ. ed.: *Prikladnoe mashinnoe obuchenie s pomoshch'yu Scikit-Learn, Keras i TensorFlow: kontseptsii, instrumenty i tekhniki dlia sozdaniya intellektual'nykh system. 2-e izd.* St. Petersburg, Dialektika Publ., 2020, 1040 p.).
8. Solov'eva I.A., Dziuba A.P. *Prognozirovanie elektropotrebleniia s uchetom faktorov tekhnologicheskoi i rynochnoi sredy* [Energy consumption forecasting with the factors of technological and market environment]. *Nauchnyi dialog*, 2013, no. 7 (19), pp. 97–111.
9. Aileen N. *Practical Time Series Analysis: Prediction with Statistics and Machine Learning*, O'Reilly Media; 1<sup>st</sup> ed. (November 5, 2019), 504 p.
10. Chollet F. *Deep Learning with Python*. 2<sup>nd</sup> ed. Manning Publications, 2021, 384 p.



11. Hyndman R.J., Athanasopoulos G. Forecasting: principles and practice. Publisher: OTexts, 2013. 291 p.
12. Lazerri F. Machine Learning for Time Series Forecasting with Python. 1<sup>st</sup> ed. Wiley, 2020, 224 p.
13. Ruey S.T. Multivariate Time Series Analysis: With R and Financial Applications. 1<sup>st</sup> ed. Wiley, 2013, 520 p.
14. Shayeghi H. STLF Based on Optimized Neural Network Using PSO // International Journal of Electrical and Computer Engineering. 2009. 4:10. P. 1190–1199.
15. Zelinka I., Chen G., Rössler O.E., Snášel V., Abraham A. Nostradamus 2013: Prediction, Modeling and Analysis of Complex Systems. Springer International Publishing, Switzerland, 2013. 550 p.

---

**DENIS V. BORTNIK** – Post-Graduate Student, Department of Power Supply and Technical Diagnostics, Mari State University, Russia, Yoshkar-Ola ([bortnik\\_denis16@mail.ru](mailto:bortnik_denis16@mail.ru); ORCID: <https://orcid.org/0009-0002-7010-8271>).

**ALEKSANDR I. ORLOV** – Candidate of Technical Sciences, Head of the Department of Electromechanics, Mari State University, Russia, Yoshkar-Ola ([karlorlov@gmail.com](mailto:karlorlov@gmail.com); ORCID: <https://orcid.org/0000-0003-1152-6668>).

---

**Формат цитирования:** *Бортник Д.В., Орлов А.И.* Сравнение архитектур нейронных сетей в задаче прогнозирования потребления электроэнергии предприятием // Вестник Чувашского университета. – 2023. – № 4. – С. 57–65. DOI: 10.47026/1810-1909-2023-4-57-65.