УДК 621.315.611 DOI 10.18522/2311-3103-2024-4-64-79

Н.К. Полуянович, О.В. Качелаев, Т.Э. Фалькон

ОЦЕНКА ВЛИЯНИЯ ГИПЕРПАРАМЕТРОВ НЕЙРОСЕТИ НА ТОЧНОСТЬ ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ

Работа посвящена проблеме повышения точности краткосрочного прогнозирования потребления электроэнергии с помощью инструментов глубокого машинного обучения. Исследовано влияние задаваемых гиберпараметров нейронной сети (НС) на погрешность прогнозирования электропотребления, таких как: размер пакета данных – Bs; количество слоев НС – j; функции активации нейронов – Fa; оптимизаторы – O. Определены оптимальные гиперпараметры НС-модели для прогнозирования электропотребления (ЭП) для потребителя аддитивного и циклического типа. Проведенный анализ влияния размера пакета (BatchSize) на точность прогноза показал повышение эффективности обучения НС с ростом пакета входных данных. Проведенный анализ влияние количества слоев показал, что с увеличением количества слоев НС время обучения сокращается, а ее предсказания становятся точнее. Проведенное исследование различных оптимизаторов на скорость обучения показало, что наилучшие результаты демонстрируют оптимизаторы "Adam" и "RMSprop". Показано, что от выбора функции активации зависит, то насколько быстро будет обучаться НС и насколько точными будут ее прогнозы. Использование различных методов регуляризации позволяет НС достичь лучших результатов на практике, улучшая их способность к обобщению и увеличивая точность предсказаний. Показано, что для достижения минимальной погрешности прогнозирования, следует индивидуально настраивать параметры сети для каждого потребителя, учитывая значительные различия в характере энергопотребления. Проведено обучение и тестирование созданной сети с подобранными параметрами на обучающей и тестовой выборке, содержащей данные об электропотреблении за 2 года (17520 часов). Анализ входных данных по электропотреблению показал, что оптимальными параметрами прогностической нейросетевой модели в ручном режиме являются: размер пакета 250 (подобрано эмпирически), 5 слоев, функция активации "ReLU", оптимизатор "Adam". Рассмотрены различные способы подбора гиперпараметров (вручную и посредством генетического алгоритма (ГА)).

Прогнозирование электропотребления; нейронная сеть; атипичный характер электропотребления; надежность систем энергоснабжения.

N.K. Poluyanovich, O.V. Kachelaev, T.H. Falcón

ASSESSMENT OF THE INFLUENCE OF NEURAL NETWORK HYPERPARAMETERS ON THE ACCURACY OF FORECASTING ENERGY CONSUMPTION

The work is devoted to the problem of improving the accuracy of short-term forecasting of electricity consumption using deep machine learning tools. The influence of the specified neural network NN hyperparameters on the error in predicting power consumption, such as: data packet size – Bs; number of NN layers – j; neuron activation functions – Fa; optimizers – O. The optimal hyperparameters of the NN model for predicting electrical consumption (EC) for consumers of additive and cyclic types have been determined. The analysis of the impact of the batch size on the accuracy of the forecast showed an increase in the effectiveness of NN training with the growth of the input data package. The analysis of the influence of the number of layers showed that with an increase in the number of layers of the NN, the learning time decreases and its predictions become more accurate. A study of various optimizers for learning speed has shown that the best results are demonstrated by the optimizers "Adam" and "RMSProp". It is shown that the choice of the activation function determines how quickly the NN will be trained and how accurate its forecasts will be. The use of various regularization methods allows NS to achieve better results in practice, improving their generalization ability and increasing the accuracy of predictions. It is shown that in order to achieve the minimum forecasting error, it is necessary to individually configure the network parameters for each consumer, taking into account significant differences in the nature of energy consumption. The training and testing of the created network with selected parameters was carried out on a training and test sample containing data on electricity consumption for 2 years (17520 hours). The analysis of input data on power consumption showed that the optimal parameters of

the predictive neural network model in manual mode are: package size 250 (selected empirically), 5 layers, activation function "ReLU", optimizer "Adam". Various ways of selecting hyperparameters (manually and by means of genetic algorithm (GA)) are considered.

Cyber-physical system; neural network; atypical nature of power consumption; reliability of power supply systems.

Введение. Текущая ситуация в сфере электроснабжения характеризуется значительным физическим износом оборудования, высокими показателями удельных расходов топлива и потерь в сетях. Для решения задачи поддержания баланса мощностей между генерирующей стороной и потреблением электрической энергии используется прогнозирование ресурса линий электропередач [1–3], состояния ее электроизоляционных свойств [4], влияния электромагнитных полей [5–7], термофлуктуационных воздействий [8–10] и многое другое. Актуальность данной работы обусловлена требованиями законодательства к прогнозированию электропотребления для решения задачи поддержания баланса мощностей между генерирующей стороной и потреблением электрической энергии [11]. Наиболее распространен метод прогноза, основанный на удельных нормах расхода электроэнергии с экспертной корректировкой (корреляционно-регрессионный анализ). В качестве модели для аппроксимации графика нагрузки и его прогноза могут успешно использоваться также полиномиальные разложения. Если необходим прогноз на длительный интервал времени можно использовать авторегрессионные методы. Недостатками этих методов являются: сложность вычислений; применение требует участия аналитиков; применяются только к определенному типу прогноза; – недостаточная точность прогноза; чувствительны к входным данным. Новые подходы к прогнозированию электрической нагрузки базируются на нейросетевом моделировании, позволяющем минимизировать вмешательство в работу системы управления на этапе сбора данных об исследуемом объекте.

Проблема прогнозирования электропотребления заключается в том, что необходимо учесть огромное количество факторов, имеющих влияние на изменение энергопотребления. По оценкам российских специалистов, каждая оплошность в ежегодном прогнозе электропотребления на 1% – это 4 млрд. долларов дополнительных инвестиций на возведение генерирующих мощностей.

Целью прогнозирования электропотребления является обеспечение баланса между выработанной и потребленной электроэнергией.

Постановка задачи. Разработка оптимальной структуры системы прогнозирования для потребителей с различным характером электропотребления т.е. не повторяющимся значением (активная мощность P, реактивная мощность Q) за рассматриваемые периоды времени, а также математической модели прогнозируемого объема электропотребления, включающей в себя кроме целевых параметров электросети учет воздействующих факторов: социально-экономических; технологических и метеорологических.

1. Обзор литературных источников. В настоящее время создано большое количество архитектур нейронных сетей (НС) и методов их обучения. Наиболее распространенной является связка – многослойный персептрон (МП) и алгоритм обратного распространения ошибки [15], но точные значения градиента, в данном методе, не всегда доступны и, кроме того, решение задачи оптимизации в условиях большой размерности требует значительных вычислительных, а, следовательно, и временных затрат.

В работе [16] предлагается модель краткосрочного прогнозирования суточных графиков активной мощности с учетом прогнозных данных естественной освещенности. Указывается на необходимость проведения дополнительные исследования по совершенствованию структуры и подбору экспериментально настраиваемых параметров использованной LSTM сети с целью уменьшения ошибки прогноза.

Другим направлением исследований являются ансамблевые методы [17], чаще других используются рекуррентные сети [18] (Recurrent neural networks, RNN), поскольку они созданы для обработки последовательных данных, в частности временных рядов.

Сравнение глубоких нейронных сетей с классическим многослойным перцептроном, ARIMA и сезонной моделью Хольта-Уинтерса для прогноза электропотребления промышленных предприятий приведено в работе [19]. Недостатками глубоких нейронных сетей являются необходимость обучения на очень большой выборке данных, высо-

кая вычислительная трудоемкость обучения [20], кроме того, высокая трудоемкость выбора архитектуры сети. При этом существует проблема переиспользования обученной сети. Например, если для прогноза электропотребления модель в качестве входа использовала метеорологические данные (температура, скорость ветра, давление, облачность), то без них модель уже не будет работать. И может намного хуже работать в другой климатической зоне.

В исследовании [21] было выяснено, что математическая модель почасового электропотребления должна учитывать помимо стандартных факторов времени, температуры наружного воздуха и освещенности факторы отключения на электрических сетях; производственный режим потребителей электроэнергии; наличие центрального отопления и горячего (холодного) водоснабжения в отдельных населенных пунктах; инерционности изменения режима электропотребления в связи с перепадами температуры воздуха. В связи с учетом вышеперечисленных факторов при краткосрочном прогнозировании потребления электроэнергии необходимо рассмотреть вопросы выбора оптимальной конфигурации нейронной сети, которая позволяет достичь максимальной точности прогноза электропотребления.

Также вышеперечисленные методы прогнозирования потребления электроэнергии основаны на устаревших методах машинного обучения, таких как метод опорных векторов, метод главных компонент, персептроны различной конфигурации и т.п. В настоящее время НС и генетические алгоритмы перешли из перспективных методов решения задач в доступные и широко применяемые методы.

2. Структура НС-модели. Для решения задачи НС прогноза аддитивного потребления электроэнергии разработана модель нейронной сети, представленной на рис. 1. Многофакторная НС-модель содержит во входном слое: X_1–X_8 – входные нейроны для влияющих факторов (дата, метеоусловия, социально-экономические и др.), нейроны X_9–Xnn – являются входами для данных о потребленной мощности за предыдущие nn часов. Ретроспективные данные, подаваемые на вход НС-модели, дают возможность реализовать метод скользящего окна (СО), что позволяет уменьшить ошибку прогнозирования.

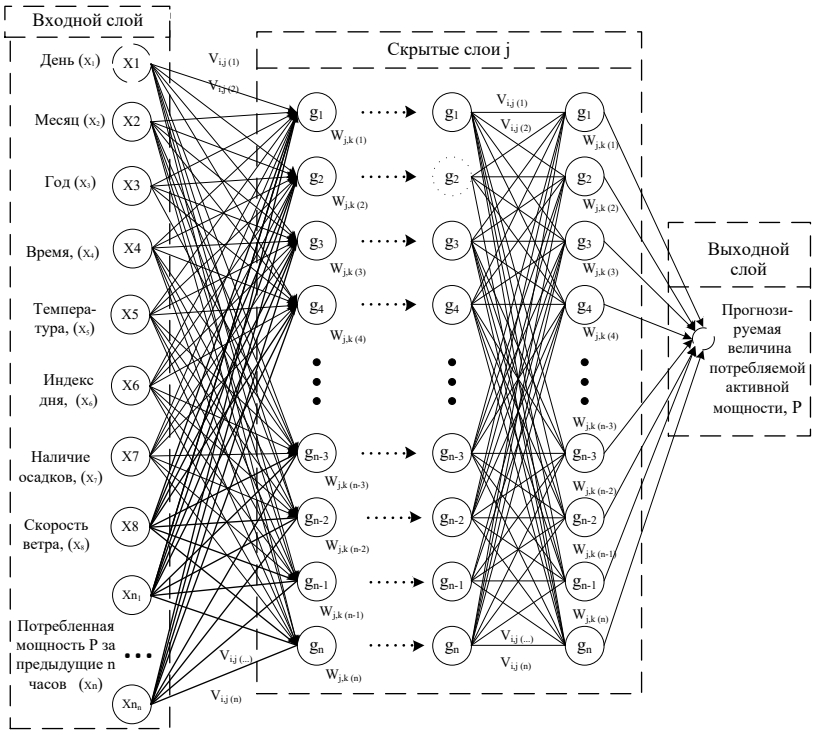

Рис. 1. Структура НС-модели прогнозирования

Предлагаемая топология сети с произвольным количеством слоев и нейронов на слой позволяет применять генетический алгоритм для подбора гиперпараметров НС-модели для конкретного потребителя. А именно: количество скрытых слоев j, количество нейронов N на слой, функция активации нейронов Fa, оптимизатор O. Выходной слой содержит 1 нейрон, соответствующий прогнозным значениям потребленной мощности P. Тип линейной НС с обучением при помощи алгоритма обратного распространения ошибки выбран по причине простоты реализации, и приемлемой точности работы с аддитивными данными о потребленной мощности.

3. Исследование влияния гиперпараметров. Алгоритмы обучения глубоких нейронных сетей, предназначенных для краткосрочного прогнозирования электропотребления, включают оптимизацию в различных контекстах. Так, основная задача оптимизации в машинном обучении заключается в подборе параметров нейронной сети, значительно уменьшающих величину функции стоимости J(n). Часть параметров, которые называются свободными параметрами нейронной сети, определяются в процессе обучения на обучающей выборке данных. Однако существует набор параметров, называемых гиперпараметрами, которые невозможно определить и уточнить в процессе обучения. В список основных параметров архитектур для нейронных сетей входят следующие:

- количество скрытых слоев сети;
- количество нейронов в каждом скрытом слое;
- функция активации нейронов скрытых и выходного слоев;
- оптимизаторы функции потерь.

Показателем точности прогноза выбран средний модуль процента ошибки (MAPE):

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i^* - y_i}{y_i}\right| \cdot 100\%,$$

где n – число часов в выборке; y^*_i – прогноз электропотребления в i-й час; y_i – истинное значение электропотребления в i-й час.

Выбор MAPE обусловлен тем, что именно этот показатель используется предприятиями как главная метрика точности прогноза электропотребления при работе на оптовом и розничном рынках электроэнергии и мощности.

3.1. Влияние размера пакета (BatchSize). Скорость обучения нейросети зависит от различных факторов, которые влияют на эффективность процесса обучения и время, необходимое для достижения конвергенции модели. На рис. 2 приведена зависимость эффективности обучения (отклонения прогнозирования НС) от задаваемого при обучении размера пакета (Batch size).

Рис. 2. Зависимость отклонения прогнозирования НС, от задаваемого размера пакета

Эффективность обучения (Данный показатель является безразмерным) НС рассчитывается следующим образом:

$$E = \frac{\Delta l}{t} * 100,$$

где E – эффективность обучения, Δl – дельта ошибки. $\Delta l = l_{нач}/l_{кон}$, t – время затраченное на обучение.

Анализ графика на рис. 2 показал, что чем больше пакет входных данных, тем эффективнее обучается НС. Однако, чем больше пакет входных данных, тем больше требуется оперативной памяти для процесса обучения. Поэтому все последующие тесты будут проводится с размером пакета входных данных равным 250, что является оптимальным размером для 8Гб оперативной памяти.

3.2. Влияние количества слоев. Для случая аддитивных входных параметров (данные МАКР) исследовано влияние количества слоев на скорость обучения НС приведено на рис. 3.

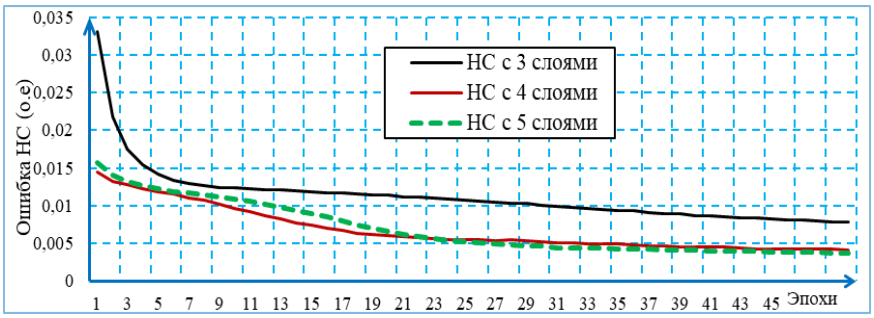

Рис. 3. Влияние количества слоев на скорость обучения НС

Наблюдается понижение ошибки НС прогнозирования с разным количеством слоев. Результаты погрешностей НС-модели с разным количеством слоев, в случае аддитивного характера электропотребления, представлены в табл. 1.

Таблица 1

Влияние количества слоев на точность предсказаний НС

Количество слоев в НС	Количество эпох	Среднее отклонение предсказаний НС, %
3	47	17,10
4	24	13,72
5	24	0,79

Таким образом, анализируя рис. 3 и погрешность НС (табл. 3) видим, что с большим количеством слоев НС обучается быстрее и ее предсказания точнее. Большое значение ошибки является результатом быстрого обучения НС (цель – получение информации о влиянии на отклонение прогнозирования количества скрытых слоев в структуре нейросети).

3.3. Влияние оптимизатора. Оптимизатор – это метод достижения лучших результатов, помощь в ускорении обучения. Другими словами, это алгоритм, используемый для незначительного изменения параметров, таких как веса и скорость обучения, чтобы модель работала правильно и быстро. Для обучения прогностической НС-модели, наиболее распространены следующие оптимизаторы:

Стохастический градиентный спуск (SGD) – это мини-пакетный градиентный спуск стремится сбалансировать устойчивость стохастического градиентного спуска и эффективность пакетного градиентного спуска. Это наиболее распространенная реализация градиентного спуска, используемая в области глубокого обучения. SGD имеет ряд преимуществ перед стандартным градиентным спуском, таких как более быстрая конвергенция и меньшие требования к памяти, особенно для больших наборов данных. Он также более устойчив к зашумленным и нестационарным данным и может выходить за пределы локальных минимумов. Однако для конвергенции может потребоваться больше итераций, чем для градиентного спуска, и скорость обучения должна быть тщательно настроена для обеспечения конвергенции.

Momentum – это метод оптимизации, используемый в машинном обучении и глубоком обучении для ускорения обучения нейронных сетей. Он основан на идее добавления части предыдущего обновления к текущему обновлению весов в процессе оптимизации. При импульсной оптимизации градиент функции затрат вычисляется относительно каждого веса в нейронной сети. В целом, momentum – это мощный метод оптимизации, который может помочь ускорить обучение глубоких нейронных сетей и повысить их производительность.

Среднеквадратичное распространение корня (RMSprop) – это алгоритм оптимизации, используемый в машинном обучении и глубоком обучении для оптимизации обучения нейронных сетей. В целом, RMSProp – это мощный алгоритм оптимизации, который может помочь ускорить обучение глубоких нейронных сетей и повысить их производительность, особенно в ситуациях, когда целевая функция нестационарна.

Адаптивная оценка момента (Adam) – один из самых эффективных алгоритмов оптимизации в обучении нейронных сетей. Adam сочетает в себе идеи RMSProp и оптимизатора импульса. Вместо того чтобы адаптировать скорость обучения параметров на основе среднего первого момента (среднего значения), как в RMSProp, Adam также использует среднее значение вторых моментов градиентов. Adam также включает этап коррекции смещения для корректировки скользящих средних, поскольку в начале процесса оптимизации они смещены к нулю. Это помогает улучшить производительность алгоритма оптимизации на ранних стадиях обучения.

$$\begin{cases} V_{dW} = \beta_1 V_{dW} + (1-\beta_1) dW; \\ S_{dW} = \beta_2 S_{dW} + (1-\beta_2) dW^2; \\ V_{dW}^{corr} = V_{dw}(1-\beta_1^t); \\ S_{dW}^{corr} = S_{dw}(1-\beta_2^t); \\ W = W - \alpha V_{dW}^{corr}\left(\sqrt{S_{dW}^{corr}+\varepsilon}\right)^{-1}, \end{cases} \quad (1)$$

где V_{dw} – матрица, характеризующая инерционные свойства параметров ИНС, по сути, матрица скорости изменения параметров; β_1 – параметр, задающий баланс между учетом предыдущего направления градиента и направления градиента, полученного на очередной эпохе обучения и на очередном пакете, обычно значение этого параметра близко к 1 (~0,9); dW – матрица градиентов, задающих направление повышения ошибки, $\partial E/\partial W$; β_2 – параметр, задающий баланс между учетом предыдущей энергии изменения направления градиента и направления градиента, полученного на очередной эпохе обучения и на очередном пакете, обычно значение этого параметра близко к 1 (~0,999); S_{dw} – матрица, характеризующая степень («энергию», так как градиент возведен в квадрат) изменения параметров ИНС, без учета направления изменения; t – номер пакета при обучении; W – матрица весов; α – величина шага обучения; ε – близкое к нулю положительное число для предотвращения деления на ноль [22].

Сравнение скорости падения ошибки НС, в зависимости от оптимизатора применяемого в процессе обучения приведено на рис. 4.

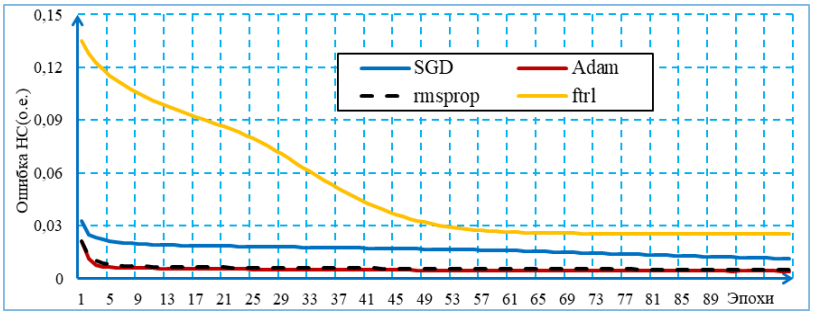

Рис. 4. Сравнение скорости обучения оптимизатора Adam и SGD

Таким образом, анализируя скорость обучения различных оптимизаторов, замечено, что наилучшие результаты демонстрируют оптимизаторы “Adam” и “RMSprop”.

Влияние функции активации. Для нейронов нейронной сети можно использовать любую функцию активации (2), однако есть те, которые принято считать наиболее оптимальными [22].

$$\begin{cases} f(x) = \dfrac{1}{1+e^{-x}}, & Y \in [-1;1] \quad (Sigmoid) \\ Tanh(x) = \dfrac{e^{x}-e^{-x}}{e^{x}+e^{-x}}, & Y \in [-1;1] \quad (Tansig) \\ f(x) = \max(0,x), & Y \in [0;\ +\infty)\ (ReLU) \\ f(x) = \mathrm{x}, & Y \in (-\infty;\ +\infty) \quad (Linear) \\ f(x)_i = \dfrac{e^{x_i}}{\sum_{j=1}^{K} e^{x_i}}, & Y \in [0;\ +\infty) \quad (Softmax) \end{cases} \tag{2}$$

Для выбора оптимальной функции активации нейронной сети проведено сравнение скорости падения ошибки НС, в зависимости от функции активации, рис. 5.

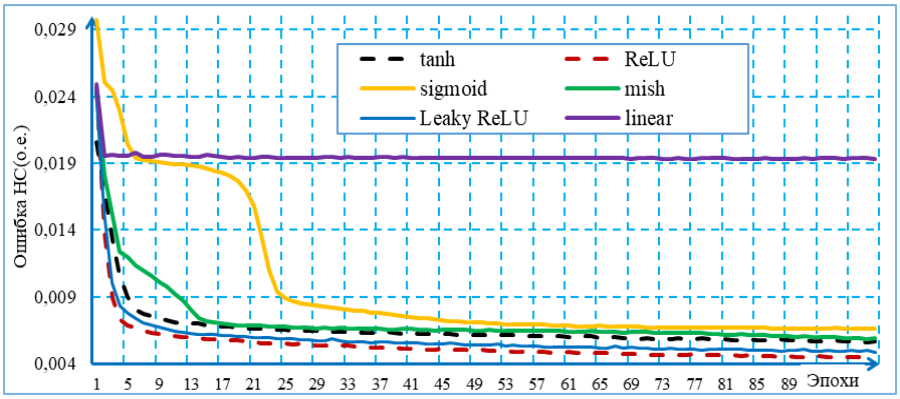

Рис. 5. Сравнение ошибки с разными функциями активации нейронов

Анализируя рис. 5 наблюдаем, что функция активации “ReLU” превосходит остальные функции активации. Так же хорошо себя показали функции активации “Leaky ReLU” и “tanh”.

Таким образом, от выбора функции активации зависит, то насколько быстро будет обучаться нейронная сеть и насколько точными будут ее прогнозы. Так же при выборе функции активации важно нормировать входные данные таким образом, чтобы область определения функции активации совпадала с областью определения данных. Если входные данные будут иметь отрицательные значения, то функция активации должна иметь отрицательные значения в своей области определения, иначе НС будет терять часть информации.

Методы регуляризации. Для борьбы с переобучением можно использовать методы регуляризации [23]. Преимущество регуляризации заключается в том, что она позволяет уменьшить размер весов модели и сделать их более равномерными, тем самым повышая устойчивость модели к малым изменениям данных.

При выборе метода регуляризации важно учитывать, что слишком сильная регуляризация может привести к недообучению, тогда как недостаточная регуляризация может привести к переобучению. Регуляризация нейронных сетей – это мощный инструмент, который помогает контролировать переобучение и повышать обобщающие способности моделей. Путем применения различных методов регуляризации и их оптимального настройки, можно достичь более стабильных и надежных результатов в задачах машинного обучения.

L1-регуляризацию часто называют регрессией лассо или Манхэттенской. Суть данного метода заключается в добавлении к функции потерь суммы абсолютных значений весовых коэффициентов.

$$L_{L1}(Y, Y', W) = L(Y, Y') + \lambda \sum_{i=1}^{n} |w_i|,$$

где $L_{L1}(Y,Y',W)$ – функция потерь с L1-регуляризацией; $L(Y,Y')$ – одна из рассмотренных ранее функций потерь; λ – коэффициент регуляризации (штраф); w_i – i-ый весовой коэффициент.

L2-регуляризация. L2, или гребневая, регуляризация, как и L1-регуляризация, вводит в функцию потерь штраф за большие весовые коэффициенты. Но при этом используется L2-норма — сумма квадратов весовых коэффициентов. В результате функция потерь будет иметь следующий вид.

$$L_{L2}(Y, Y', W) = L(Y, Y') + \lambda \sum_{i=1}^{n} w_i^2$$

L2-регуляризация вводит штраф за большие веса, тем самым усиливает влияние важных признаков и снижает, но не исключает, влияние случайного шума на конечный результат.

Регуляризация нейросетей с помощью dropout. Одной из самых эффективных и широко применяемых техник регуляризации нейронных сетей является dropout. Dropout – это метод, который случайным образом удаляет (отключает) некоторые нейроны в процессе обучения, чтобы уменьшить переобучение. Dropout является эффективным методом борьбы с переобучением и может значительно улучшить обобщающую способность нейросетей. Преимуществом использования dropout является: – уменьшение переобучения; –улучшение обобщающей способности; – эффективность. Dropout может быть вычислен параллельно и не требовать дополнительные вычислительные ресурсы. Dropout – это мощный инструмент для улучшения обобщающей способности и предотвращения переобучения нейросетей.

Таким образом, регуляризация играет важную роль в улучшении обобщающей способности нейронных сетей. Она помогает избежать переобучения и сделать модель более устойчивой к новым данным. Использование различных методов регуляризации позволяет нейронным сетям достичь лучших результатов на практике, улучшая их способность к обобщению и увеличивая точность предсказаний.

4. Экспериментальные исследования

4.1. Многофакторное моделирование электропотребления. Для обучения и тестирования алгоритмов краткосрочного прогнозирования электропотребления, необходимо произвести выборку и описание входных параметров. Кроме целевых данных (основных), которыми являются прогнозные значения потребленной активной P(t), и реактивной Q(t) мощности, необходимы следующие значимые факторы:

- Социально-экономические (Время, (t – час, сутки, неделя, месяц); Дата (D – день, M – месяц, Y – год); Статус дня (S; 1– рабочий, 0 – выходной))
- Метеорологические (Температура среды (T); Наличие осадков (R; 1 – осадки есть, 0 – осадков нет); Скорость ветра (W))

Обучение и тестирование НС проводилось для потребителей с различным характером электропотребления (циклическим, и аддитивным). Размер выборки составил данные о потреблённой ЭЭ и влияющих факторах (табл. 3) за два года по каждому из потребителей. Частота снятия данных P(t), и Q(t) составляет не менее, чем раз в 1 час.

4.2. Настройка НС. Алгоритмы обучения глубоких нейронных сетей, предназначенных для краткосрочного прогнозирования электропотребления, включают оптимизацию в различных контекстах. Так, основная задача оптимизации в машинном обучении заключается в подборе параметров нейронной сети, значительно уменьшающих величину функции стоимости J(n). Часть параметров, которые называются свободными параметрами нейронной сети, определяются в процессе обучения на обучающей выборке данных.

Однако существует набор параметров, называемых гиперпараметрами, которые невозможно определить и уточнить в процессе обучения. В список основных параметров архитектур для нейронных сетей входят следующие: – количество скрытых слоев сети; – количество нейронов в каждом скрытом слое; – функция активации нейронов скрытых и выходного слоев. Некоторые варианты (комбинаций параметров НС) для потребителей с различным характером электропотребления, приведены в табл. 4.

Таблица 4

Комбинации параметров НС

Номер комбинации параметров НС	Количество слоев НС, j	Число нейронов в слое, n	Скорость обучения, Lr	Функция активации, Fa	Тип ошибки
Комбинации параметров НС-модели для потребителя МАКР					
1	1	[10]	0.01	[Tansig]	MSE
2	1	[10]	0.01	[Tansig]	SSE
3	1	[10]	0.0001	[Tansig]	MSE
Комбинации параметров НС-модели для потребителя ЮЗЭС					
1	2	[10;10]	0.01	[Tansig, Tansig]	MSE
2	1	[25]		[Tansig]	MSE
3	1	[30]		[Tansig]	MSE
Комбинации параметров НС-модели для потребителя МАКР со скользящим окном					
1	1	[10]	0.0001	[Tansig]	MSE
2	1	[10]	0.001	[Tansig]	MSE
3	1	[10]	0.00001	[Tansig]	MSE

4.3. Тестирование нейросети

4.3.1. Оценка влияния гиперпараметров НС на погрешность прогноза. Рассматривались такие гиперпараметры НС как: тип распространения ошибки, скорость обучения и обучающая функция. Погрешность прогнозирования ЭП с различными вариантами гиперпараметров НС, приведены в табл. 5.

Таблица 5

Оценка влияния гиперпараметров НС на погрешность прогноза

Параметр	Значение	Погрешность прогнозирования %	
		Средняя по часам	Средняя за период
Обучающая функция	trainbr	31,79	15,79
	trainlm	259,79	244,38
Тип ошибки	MSE	30,28	6,14
	SSE	26,31	14,38
Скорость обучения, о.е.	0,00001	25,19	15,95
	0,0001	30,28	6,14
	0,01	31,12	20,91

Проведена оценка влияния гиперпараметров НС на погрешность прогноза. Рассчитаны погрешности прогнозирования ЭП при различных комбинациях параметров НС-модели приведены в табл. 6.

Таблица 6

Результаты прогнозирования электропотребления

Способ измерения погрешности	Номер комбинации параметров НС-модели	Погрешность прогнозирования %
Средний по часам	1	30.76
	2	26.80
	3	26.31
Средний за период	1	12.81
	2	15.59
	3	14.38

Проведено исследование для двух различных типов потребителей ЭЭ (аддитивного, и имеющего циклический характер). Прогнозирование потребителя электроэнергии с аддитивным характером ЭП (МАКР) [15], для трех вариантов настройки НС-модели (табл. 4), приведено на рис. 6.

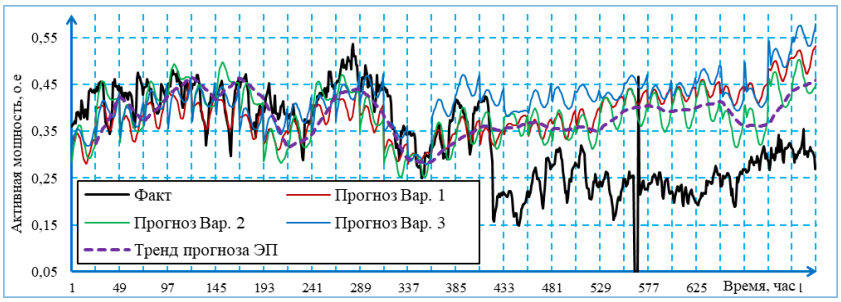

Рис. 6. График сравнения фактических и прогнозных значений (Вариант 1-3)

Анализ полученных зависимостей (рис. 6) прогнозирования электропотребления, с использованием НС-модели типа «многослойный персептрон» со скользящим окном показал, что в момент резкого скачка фактического ЭП (18 числа) (более чем в 2-2.5 раза) погрешность используемой НС-модели существенно увеличилась, что говорит о некорректной работе данной НС-модели. НС-модель небольшого размера (табл. 4) не обеспечивает требуемой точности. Использование метода СО при прогнозировании ЭП должно уменьшить погрешность прогнозирования на подобных участках кривой электропотребления.

4.3.2. НС-модель со скользящим окном. Для выбора оптимальной нейросети проведено исследование влияния использования метода скользящего окна на точность прогнозирования электропотребления аддитивного характера. Параметры некоторых НС-моделей, обученных с методом СО приведены в табл. 4. Прогнозирование потребителя электроэнергии с аддитивным характером ЭП с использованием СО, для трех вариантов настройки НС-модели (табл. 4), приведено на рис. 7.

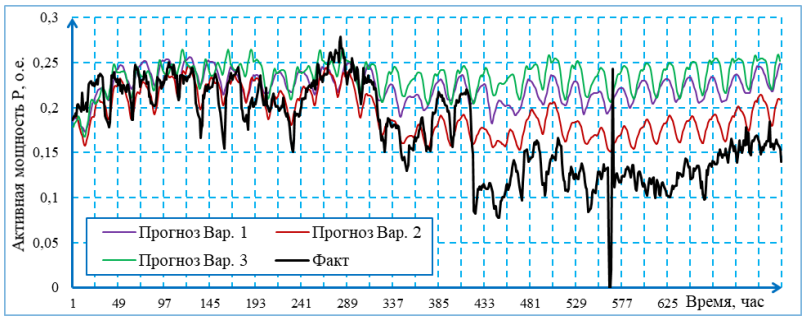

Рис. 7. Графики сравнения фактических и прогнозных значений ЭП при использовании скользящего окна

Анализ графиков прогнозирования ЭП при помощи НС-модели со скользящим окном показал, что 2 вариант комбинаций параметров НС-модели дает наиболее приближенную к фактической кривую электропотребления. Это говорит о целесообразности использования данного метода и возможности подбора гпиперпараметров НС-модели. Результаты расчетов погрешности прогнозирования электропотребления при использовании скользящего окна сведены в табл. 7.

Таблица 7

Результаты прогнозирования электропотребления со скользящим окном

Способ измерения погрешности	Номер комбинации параметров НС-модели	Погрешность прогнозирования, %
Средний по часам	1	39.85
	2	47,69
	3	23.18
Средний за период	1	27.33
	2	33.42
	3	10.79

Расчеты погрешностей (табл. 9) показали, что:

- Расчет погрешности в виде среднего отклонения по каждому часу имеет смысл применять при оперативном или краткосрочном прогнозировании. Использование метода скользящего окна показало снижение ошибки прогнозирования в среднем на 2% при использовании подобного способа расчета.
- Расчет погрешности в виде среднего значения сумм потребленной и спрогнозированной электроэнергии за прогнозный период имеет смысл использовать при среднесрочном и долгосрочном прогнозировании. Использование метода скользящего окна показало снижение ошибки прогнозирования в среднем на 17% при использовании подобного способа расчета.

Таким образом, результаты проведенных экспериментальных исследований позволили установить оптимальную комбинацию параметров для аддитивного потребителя электроэнергии: – кол-во скрытых слоев (1); количество нейронов на слой [10]; функция активации Tansig, а в выходном слое Purelin; тип распространения ошибки (MSE); скорость обучения (0,001); обучающая функция (TrainBR - Байесовская регуляризация), использование метода СО.

4.3.3. Прогнозирования, с циклическим характером ЭП. Графики прогнозирования, с циклическим характером ЭП (ЮЗЭС), для трех вариантов настройки НС-модели (табл. 4), приведены на рис. 8-10, где на оси времени откладываются интервалы равные 0.5 часа.

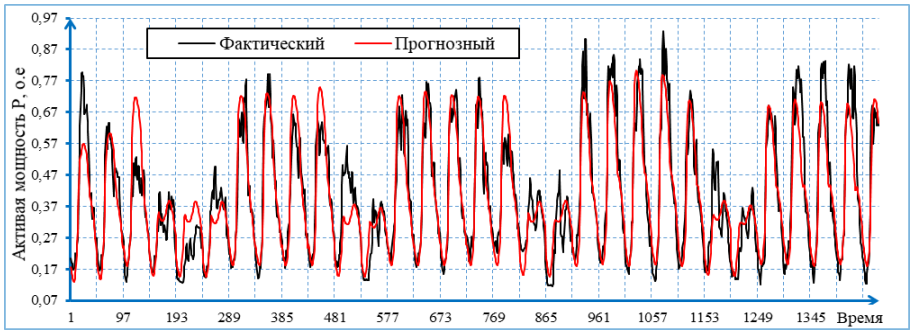

Рис. 8. График сравнения фактических и прогнозных значений (Вариант 1)

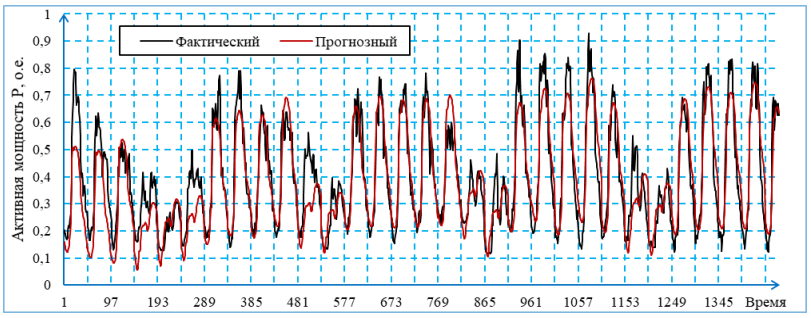

Рис. 9. График сравнения фактических и прогнозных значений (Вариант 2)

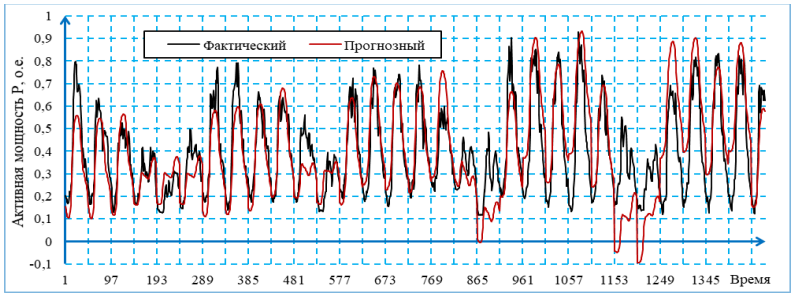

Рис. 10. График сравнения фактических и прогнозных значений (Вариант 3)

Результаты погрешностей при различных комбинациях параметров НС-модели приведены в табл. 8

Таблица 8

Результаты прогнозирования электропотребления

Способ измерения погрешности	Номер комбинации параметров НС-модели	Ошибка прогнозирования ε, %
Средняя по часам	1	15,84
	2	18,17
	3	30,30
Средняя за период	1	1,36
	2	3,81
	3	0,04

Проведена оценка влияния гиперпараметров НС на погрешность прогноза. Рассматривались такие гиперпараметры как: тип распространения ошибки, скорость обучения и обучающая функция. Погрешность прогнозирования с различными гиперпараметрами приведены в табл. 9.

Таблица 9

Оценка влияния гиперпараметров НС на погрешность прогноза

Параметр НС	Значение параметра	Погрешность прогнозирования %	
		Средняя по часам	Средняя за период
Тип ошибки	MSE	18,13	4,81
	SSE	18,48	6,29
Скорость обучения, о.е.	0,00001	17,44	1,16
	0,0001	18,7	0,76
	0,01	19,23	5,92
Обучающая функция	trainbr	16,31	8,87
	trainlm	152,72	81,95

Таким образом, по результатам проведенных экспериментальных исследований выявлена оптимальная комбинация параметров НС-модели для прогнозирования электропотребления с циклическим характером: кол-во скрытых слоев (2); количество нейронов на слой [10 10]; функция активации Tansig-Tansig, а в выходно слое Purelin); тип распространения ошибки (MSE); – скорость обучения (0,0001); обучающая функция (TrainBR - Байесовская регуляризация).

Заключение. Проведено исследование влияния различных параметров и структуры нейросети на точность прогнозирования энергопотребления с целью нахождения оптимальных ее настроек (наименьшая погрешность). Определены наиболее соответствующие гиперпараметры НС-модели для прогнозирования ЭП для потребителей аддитивного и циклического типа. При прогнозировании электропотребления с циклическим характером оптимальные параметры НС: кол-во скрытых слоев (2); количество нейронов на слой [10 10]; функция активации Tansig-Tansig, а в выходно слое Purelin); тип распространения ошибки (MSE); скорость обучения (0,0001); обучающая функция (TrainBR - Байесовская регуляризация). В случае аддитивного потребителя электроэнергии подобраны оптимальные параметры: – кол-во скрытых слоев (1); количество нейронов на слой [10]; функция активации Tansig, а в выходном слое Purelin; тип распространения ошибки (MSE); скорость обучения (0,001); обучающая функция (TrainBR - Байесовская регуляризация), предпочтительно использование метода СО. Выявлено, что для обеспечения наименьшей погрешности прогнозирования, необходима индивидуальная настройка параметров нейросети для каждого потребителя в отдельности с учётом его характера энергопотребления.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Полуянович Н.К., Дубяго М.Н.* Алгоритм обучения искусственной нейронной сети факторного прогнозирования ресурса изоляционных материалов силовых кабельных линий // Известия ЮФУ. Технические науки. – 2021. – № 2. – С. 59-73.
2. *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.
3. *Полуянович Н.К., Дубяго М.Н., Бурьков Д.В*. Термофлуктуационная теория разрушения и оценка долговечности электрической изоляции СПЭ кабелей // Известия ЮФУ. Технические науки. – 2021. – № 6. – С. 180-194.
4. *Poluyanovich N.K., Dubyago M.N*. Book Chapter. Structural Changes During Electrical Aging of Insulation Materials of Cable Networks // Studies in Systems, Decision and Control. – 2023. – 477. – P. 245-256. – https://doi.org/10.1007/978-3-031-33159-6_19.
5. *Poluyanovich N.K., Sharykin A.A., Dubyago M.N., Kachelaev O.V*. Conference Paper. Analysis of the Electro-magnetic Field on Cable Systems with Insulation Made of Polymer Materials // Proceedings - 2023 5th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency, SUMMA 2023. – 2023. – P. 977-982.
6. *Shiyan Ren; Siwei Guo; Xiaojun Liu; Qingxin Liu*. Shielding Effectiveness of Double-layer Magnetic Shield of Current Comparator Under Radial Disturbing Magnetic Field // IEEE Transactions on Magnetics. – 2016. – Vol. PP, Issue 99. – P. 1.
7. IEE Guide for Field Testing of Shielded Power Cable Systems Using Very Low Frequency (VLF) (less than 1 Hz). IEE.400.2. – 2013.
8. *Ukil A*., *Braendle H., Krippner P.* Distributed temperature sensing: review of technology and applications // Sensors Journal, IEEE. – 2012. – Vol. 12, No. 5. – P. 885-892.
9. *Diaz-Aguilo M., De Leon F*. Introducing Mutual Heating Effects in the Lad-der-Type Soil Model for Dynamic Thermal Rating of Underground Cables // IEEE Tran. on Power Delivery. – 2015. – Vol. 30 (4). – P. 1958-1964.
10. *Poluyanovich N.K., Dubyago M.N., Azarov N.V., Ogrenichev A.V., Sharykin A.A.* Multifactor Model for Forecasting Thermal Processes in the Insulating Materials of Cable Lines // Conference proceedings // 2020 International Multi-Conference on Indus-trial Engineering and Modern Technologies, FarEastCon. – 2020. – P. 9271367. – ISBN: 978-172816951-4. – DOI: 10.1109/FarEastCon50210.2020.9271367.
11. Постановление Правительства РФ от 9 сентября 2023 г. N 1473 "Об утверждении ком-плексной государственной программы Российской Федерации "Энергосбережение и повышение энергетической эффективности" // Размещен в СПС "Консультант Плюс". – https://base.garant.ru/407632842/.
12. *Дубяго М.Н., Полуянович Н.К*. Совершенствование методов диагностики и прогнозирования электроизоляционных материалов систем энергоснабжения: монография. – Ростов-на-Дону; Таганрог: Изд-во ЮФУ, 2019. – 192 с.

13. *Sergeev N.N., Matrenin P.V.* Enhancing Efficiency of Ensemble Machine Learning Models for Short-Term Load Forecasting through Feature Selection // 2022 IEEE 23rd International Conference of Young Professionals in Electron Devices and Materials (EDM): Proc., Altai, 30 June – 04 July 2022. – Altai: IEEE, 2022. – P. 368-371.
14. *Rafi S.H., Nahid-Al-Masood, Deeba S.R., Hossain E.* A short-term power load forecasting method using integrated CNN and LSTM network // IEEE Access. – 2021. – Vol. 9. – P. 32436-32448.
15. *Deng Z., Wang B., Xu Y. [et al.].* Multi-scale convolutional neural network with time-cognition for multi-step short- term power load forecasting // IEEE Access. – 2019. – Vol. 7. – P. 88058-88071.
16. *Вялкова С.А., Надтока И.И., Корнюкова О.А.* Применение нейронных сетей для прогнозирования электропотребления мегаполиса // Russian Internet Journal of Industrial Engineering. – 2023. – Vol. 10, No. 4.
17. *Поляхов Н.Д., Приходько И.А., Ван Ефэн*. Прогнозирование электропотребления на основе метода опорных векторов с использованием эволюционных алгоритмов оптимизации // Современные проблемы науки и образования. – 2013. – № 2.
18. *Qiu X., Zhang L., Ren Y., Suganthan P., Amaratunga G.* Ensemble deep learning for regression and time series forecasting // Symposium on Computational Intelligence in Ensemble Learning. – IEEE, 2014. – P. 21-26. – DOI: 10.1109/CIEL.2014.7015739.
19. *Kong W., Dong Z., Jia Y., Hill D., Xu Y., Zhang Y.* Short-term residential load forecasting based on LSTM recurrent neural network // IEEE Transactions on Smart Grid. – 2019. – Vol. 10, No. 1. – P. 841-851. – DOI: 10.1109/TSG.2017.2753802.
20. *Ryu S., Noh J., Kim H.* Deep neural network based demand side short term load forecasting // Energies. – 2016. – Vol. 10, No. 1. – P. 1-20. – DOI: 10.3390/en10010003.
21. *Chen K., Wang Q., He Z., Hu J., He J.* Short-Term Load Forecasting with Deep Residual Networks // IEEE Trans. Smart Grid. – 2019. – Vol. 10, No. 4. – P. 3943-3952. – DOI: 10.1109/TSG.2018.2844307.
22. *Хомутов С.О., Серебряков Н.А.* Создание нейросетевой математической модели краткосрочного прогнозирования электропотребления электротехнического комплекса участка районных электрических сетей 6–35 кВ // Транспортные системы и технологии. – 2020. – Т. 6, № 1. – С. 80-91. – DOI: 10.17816/ transsyst20206180-91.
23. Основные функции активации в нейронных сетях // Статьи по программированию. – URL: https://www.yourtodo.ru/posts/osnovnyie-funktsii-aktivatsii-v-nejronnyih-setyah/ (04.07.2024).
24. Приемы повышения сходимости нейронных сетей. Регуляризация // MQL5; трейдинг, автоматические торговые системы, тестирование стратегий и технические индикаторы на MetaTrader. – URL: https://www.mql5.com/ru/neurobook/index/about_ai/improvement/regularization/ (04.07.2024).

REFERENCES

1. *Poluyanovich N.K., Dubyago M.N.* Algoritm obucheniya iskusstvennoy neyronnoy seti faktornogo prognozirovaniya resursa izolyatsionnykh materialov silovykh kabel'nykh liniy [Algorithm for processing an artificial neural network for factor forecasting of the resource of insulating materials of power cable lines], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2021, No. 2, pp. 59-73.
2. *Poluyanovich N.K., Dubyago M.N.* Otsenka vozdeystvuyushchikh faktorov i prognozirovanie elektropotrebleniya v regional'noy energosisteme s uchetom rezhima ee ekspluatatsii [Assessment of the current factors and forecasting of power consumption in the regional power system, taking into account its operating mode], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2022, No. 2 (226), pp. 31-46.
3. *Poluyanovich N.K., Dubyago M.N., Bur'kov D.V.* Termofluktuatsionnaya teoriya razrusheniya i otsenka dolgovechnosti elektricheskoy izolyatsii SPE kabeley [Thermal fluctuation theory of destruction and durability assessment-news of electrical insulation of SPE cables], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2021, No. 6, pp. 180-194.
4. *Poluyanovich N.K., Dubyago M.N.* Book Chapter. Structural Changes During Electrical Aging of Insulation Materials of Cable Networks, *Studies in Systems, Decision and Control,* 2023, 477, pp 245-256. Available at: https://doi.org/10.1007/978-3-031-33159-6_19.
5. *Poluyanovich N.K., Sharykin A.A., Dubyago M.N., Kachelaev O.V*. Conference Paper. Analysis of the Electro-magnetic Field on Cable Systems with Insulation Made of Polymer Materials, *Proceedings - 2023 5th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency, SUMMA 2023,* 2023, pp. 977-982.
6. *Shiyan Ren; Siwei Guo; Xiaojun Liu; Qingxin Liu.* Shielding Effectiveness of Double-layer Magnetic Shield of Current Comparator Under Radial Disturbing Magnetic Field, *IEEE Transactions on Magnetics,* 2016, Vol. PP, Issue 99, pp. 1.
7. IEE Guide for Field Testing of Shielded Power Cable Systems Using Very Low Frequency (VLF) (less than 1 Hz). IEE.400.2, 2013.

8. *Ukil A*., *Braendle H., Krippner P.* Distributed temperature sensing: review of technology and applications, *Sensors Journal, IEEE,* 2012, Vol. 12, No. 5, pp. 885-892.
9. *Diaz-Aguilo M., De Leon F*. Introducing Mutual Heating Effects in the Lad-der-Type Soil Model for Dynamic Thermal Rating of Underground Cables, *IEEE Tran. on Power Delivery,* 2015, Vol. 30 (4), pp. 1958-1964.
10. *Poluyanovich N.K., Dubyago M.N., Azarov N.V., Ogrenichev A.V., Sharykin A.A.* Multifactor Model for Forecasting Thermal Processes in the Insulating Materials of Cable Lines // Conference proceedings // 2020 International Multi-Conference on Indus-trial Engineering and Modern Technologies, FarEastCon. – 2020. – P. 9271367. – ISBN: 978-172816951-4. – DOI: 10.1109/FarEastCon50210.2020.9271367.
11. Postanovlenie Pravitel'stva RF ot 9 sentyabrya 2023 g. N 1473 "Ob utverzhdenii kompleksnoy gosudarstvennoy programmy Rossiyskoy Federatsii "Energosberezhenie i povyshenie energeticheskoy effektivnosti" [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"], *Razmeshchen v SPS "Konsul'tant Plyus"* [Posted in the SPS Consultant Plus]. Available at: https://base.garant.ru/407632842/.
12. *Dubyago M.N., Poluyanovich N.K.* Sovershenstvovanie metodov diagnostiki i prognozirovaniya elektroizolyatsionnykh materialov sistem energosnabzheniya: monografiya [Improvement of methods of diagnostics and forecasting of electrical insulating materials of power supply systems: monograph]. Rostov-on-Don; Taganrog: Izd-vo YuFU, 2019, 192 p.
13. *Sergeev N.N., Matrenin P.V.* Enhancing Efficiency of Ensemble Machine Learning Models for Short-Term Load Forecasting through Feature Selection, *2022 IEEE 23rd International Conference of Young Professionals in Electron Devices and Materials (EDM): Proc., Altai, 30 June – 04 July 2022*. Altai: IEEE, 2022, pp. 368-371.
14. *Rafi S.H., Nahid-Al-Masood, Deeba S.R., Hossain E.* A short-term power load forecasting method using integrated CNN and LSTM network, *IEEE Access,* 2021, Vol. 9, pp. 32436-32448.
15. *Deng Z., Wang B., Xu Y. [et al.]*. Multi-scale convolutional neural network with time-cognition for multi-step short- term power load forecasting, *IEEE Access,* 2019, Vol. 7, pp. 88058-88071.
16. *Vyalkova S.A., Nadtoka I.I., Kornyukova O.A*. Primenenie neyronnykh setey dlya prognozirovaniya elektropotrebleniya megapolisa [Application of neural networks for forecasting the power consumption of a megalopolis], *Russian Internet Journal of Industrial Engineering,* 2023, Vol. 10, No. 4.
17. *Polyakhov N.D., Prikhod'ko I.A., Van Efen.* Prognozirovanie elektropotrebleniya na osnove metoda opornykh vektorov s ispol'zovaniem evolyutsionnykh algoritmov optimizatsii [Forecasting of power consumption based on the method of support vectors using evolutionary optimization algorithms], *Sovremennye problemy nauki i obrazovaniya* [Modern problems of science and education], 2013, No. 2.
18. *Qiu X., Zhang L., Ren Y., Suganthan P., Amaratunga G.* Ensemble deep learning for regression and time series forecasting, *Symposium on Computational Intelligence in Ensemble Learning*. IEEE, 2014, pp. 21-26. DOI: 10.1109/CIEL.2014.7015739.
19. *Kong W., Dong Z., Jia Y., Hill D., Xu Y., Zhang Y.* Short-term residential load forecasting based on LSTM recurrent neural network, *IEEE Transactions on Smart Grid,* 2019, Vol. 10, No. 1, pp. 841-851. DOI: 10.1109/TSG.2017.2753802.
20. *Ryu S., Noh J., Kim H.* Deep neural network based demand side short term load forecasting, *Energies,* 2016, Vol. 10, No. 1, pp. 1-20. DOI: 10.3390/en10010003.
21. *Chen K., Wang Q., He Z., Hu J., He J.* Short-Term Load Forecasting with Deep Residual Networks, *IEEE Trans. Smart Grid,* 2019, Vol. 10, No. 4, pp. 3943-3952. DOI: 10.1109/TSG.2018.2844307.
22. *Khomutov S.O., Serebryakov N.A.* Sozdanie neyrosetevoy matematicheskoy modeli kratkosrochnogo prognozirovaniya elektropotrebleniya elektrotekhnicheskogo kompleksa uchastka rayonnykh elektricheskikh setey 6–35 kV [Creation of a neural network mathematical model for short-term forecasting of electrical consumption of an electrotechnical complex of a section of district electric networks 6-35 kV], *Transportnye sistemy i tekhnologii* [Transport systems and technologies], 2020, Vol. 6, No. 1, pp. 80-91. DOI: 10.17816/ transsyst20206180-91.
23. Osnovnye funktsii aktivatsii v neyronnykh setyakh [Basic activation functions in neural networks], *Stat'i po programmirovaniyu* [Articles on programming]. Available at: https://www.yourtodo.ru/posts/osnovnyie-funktsii-aktivatsii-v-nejronnyih-setyah/ (04 July 2024).
24. Priemy povysheniya skhodimosti neyronnykh setey. Regulyarizatsiya [Techniques for increasing the convergence of neural networks. Regularization], *MQL5; treyding, avtomaticheskie torgovye sistemy, testirovanie strategiy i tekhnicheskie indikatory na MetaTrader* [MQL5; trading, automatic trading systems, strategy testing and technical indicators on MetaTrader]. Available at: https://www.mql5.com/ru/neurobook/index/about_ai/improvement/regularization/ (04 July 2024).

Статью рекомендовал к опубликованию д.т.н., профессор Н.Е. Сергеев.

Полуянович Николай Константинович – Южный федеральный университет; e-mail: nik1-58@mail.ru; г. Таганрог, Россия; тел.: 89508609983; кафедра электротехники и мехатроники; к.т.н.; доцент.

Качелаев Олег Вадимович. – e-mail: 22.olezhka@mail.ru; тел.: 89281163960; кафедра техносферной безопасности и химии; аспирант.

Фалькон Талия Эрнандез – Университет Камагуэя "Игнасио Аграмонте"; e-mail: thaliahernandezf@gmail.com; Камагуэй, Куба; phone: +5355439090; Электротехнический факультет. Инженерно-электромеханический факультет; технический ассистент преподавателя.

Poluyanovich Nikolay Konstantinovich. – Southern Federal University; e-mail: nik1-58@mail.ru; Taganrog, Russia; phone: +79508609983; the department of Electric Technics and Mechatronics; cand. of eng. sc.; associate professor.

Kachelaev Oleg Vadimovich – e-mail: 22.olezhka@mail.ru; phone: +79281163960; the department of Techno-sphere Safety and Chemistry; postgraduate student.

Falcón Talia Hernandez – The University of Camagüey "Ignacio Agramonte"; e-mail: thaliahernandezf@gmail.com; Camagüey, Cube; phone: +5355439090; Electrical department. Electromechanical engineering faculty; teacher technical assistant.