

УДК 620.424.1

Выбор метода для задач краткосрочного прогнозирования электропотребления собственных нужд ТЭЦ

А.С. Ведерников, Е.А. Ярыгина, А.В. Гофман
ФГБОУВО «Самарский государственный технический университет», г. Самара, Российская Федерация
E-mail: balukova_e@mail.ru

Аннотация

Состояние вопроса. Научная проблема исследования заключается в необходимости прогнозирования электропотребления собственных нужд электростанций с минимальной ошибкой. Решением задач краткосрочного прогнозирования ранее занимались на уровне электроэнергетических систем и промышленных предприятий. Что касается прогнозирования электропотребления собственных нужд электростанций, то в качестве прогнозных значений использовались ретроспективные данные по электропотреблению. Данная проблема сохраняет свою актуальность согласно Постановлению Правительства РФ от 27 декабря 2010 г. № 1172, в котором отмечено, что электростанции берут на себя ответственность за потребление электроэнергии, объем которого вышел за рамки установленного. Отклонение в электропотреблении на 2 % и более от установленного значения приводит к дополнительным финансовым расходам. В связи с этим актуальным является выбор метода прогнозирования электропотребления собственных нужд ТЭЦ с низкой погрешностью.

Материалы и методы. Для решения задач краткосрочного прогнозирования выбран метод, основанный на искусственных нейронных сетях, и проведено обучение данных сетей с помощью методов численной оптимизации: алгоритма обучения Бройдена–Флетчера–Гольдфарба–Шанно; метода сопряженных градиентов; метода градиентного спуска, которые практически использовались для решения различных задач в электроэнергетике. Для определения почасовых значений электрической нагрузки собственных нужд ТЭЦ использован программный пакет Statistica Neural Networks.

Результаты. Выбран метод, основанный на искусственных нейронных сетях «многослойный перцептрон» и определен алгоритм его обучения Бройдена–Флетчера–Гольдфарба–Шанно, с помощью которого на ТЭЦ появляется возможность прогнозировать электропотребление системой собственных нужд со средней абсолютной погрешностью 0,43 %.

Выводы. Предложенная методика краткосрочного прогнозирования электропотребления СН ТЭЦ протестирована и утверждена в Филиале АО «СО ЕЭС» ОДУ Средней Волги для оценки прогнозных значений электропотребления электростанций в процессе планирования баланса электроэнергии.

Ключевые слова: прогнозирование электропотребления, собственные нужды ТЭЦ, искусственные нейронные сети, алгоритмы обучения, ошибка прогноза

Choice of the method for solving problems of short-term forecasting of CHPP auxiliary power consumption

A.S. Vedernikov, E.A. Yarygina, A.V. Gofman
Samara State Technical University, Samara, Russian Federation
E-mail: balukova_e@mail.ru

Abstract

Background. The scientific problem of this research is prediction of power consumption of power plant auxiliary supply with a minimum error. Short-term forecasting problems have been previously solved at the level of electric power systems and industrial enterprises. As for forecasting auxiliary power consumption, retrospective data on power consumption have been used as forecast values. This problem remains relevant in accordance with RF Government Decree No. 1172 of December 27, 2010, which states that power plants assume responsibility for the consumed electricity exceeding the established limits. A 2 or more % deviation in consumption from the set value leads to additional costs. The aim of the study is, therefore, to select a method of predicting values of CHPP auxiliary power consumption with a low error.

Materials and methods. To solve the problems of short-range forecasting, we have chosen a method based on artificial neural networks and trained these networks by using numerical optimization methods: the Broyden-Fletcher-Goldfarb-Shanno learning algorithm, Conjugate gradient method, Gradient descent method which have been earlier used for solving various practical problems in the electric power industry. The software package Statistica Neural Networks has been used by us to determine the hourly values of the electric load of CHPP auxiliary needs.

Results. We have chosen the method based on the artificial neural networks «multilayer perceptron» and the Broyden-Fletcher-Goldfarb-Shanno algorithm for its training, which allows CHPPs to predict auxiliary power consumption with the mean absolute error of 0,43 %.

Conclusions. The proposed method of short-term prediction of auxiliary power consumption at CHPP has been tested and approved at the Branch of JSC «SO UES» of the Interregional Dispatching Office of the Middle Volga for estimating predicted power consumption values of power plants in the process of electricity balance planning.

Key words: power consumption forecasting, CHPP auxiliary power, artificial neural networks, learning algorithms, forecast error

DOI: 10.17588/2072-2672.2018.6.032-038

Введение. Прогнозирование электропотребления системой собственных нужд (СН) является основой для принятия решений при управлении электрическими станциями в процессе планирования их нормальных электрических режимов. Потребление электрической энергии и мощности на собственные нужды электростанций определяется как потребление электрической энергии и мощности, необходимое для функционирования электростанций в технологическом процессе выработки, преобразования, распределения и потребления электрической энергии. Необходимость в прогнозировании остается актуальной задачей на сегодняшний день, так как для крупных потребителей электроэнергии главной задачей является повышение точности прогноза электропотребления, на основе которого формируется заявка. Электростанции должны направлять системному оператору в соответствии с графиком прогнозные значения генерации и потребления электроэнергии и мощности, в том числе расходы на собственные нужды электростанции для формирования балансов электроэнергии и мощности по субъектам РФ. Участники *оптового рынка электроэнергии и мощности (ОРЭМ)* берут на себя ответственность за потребление электроэнергии, объем которого вышел за рамки установленного в соответствии с прогнозом. Отклонение в потреблении на 2 % и более от установленного значения влечет дополнительные финансовые издержки. Точность прогнозирования электропотребления непосредственно связана с методом прогнозирования и разработанной математической моделью. Искусственные нейронные сети (ИНС) являются одним из способов моделирования, позволяющим воспроизводить чрезвычайно сложные зависимости. В задачах, где линейные модели работают неудовлетворительно, необходимо выбирать методы, работающие с нелинейными зависимостями, в том числе ИНС [1, 2].

На основе анализа методов искусственного интеллекта, предназначенных для решения задач краткосрочного прогнозирования, установлено следующее:

– линейная нейронная сеть представляет собой сеть без скрытых слоев и в выходном слое содержит только элементы с линейной функцией активации. Использование данной нейронной сети для прогнозирования СН ТЭЦ не актуально, так как между расходом активной мощности на СН ТЭЦ и влияющими на него факторами выявлена нелинейная зависимость;

– вероятностная нейронная сеть предназначена для задач классификации. Ниже будут решаться задачи регрессии, так как необходимо предсказать значение переменной, принимаю-

щей непрерывные числовые значения. В данном случае расход активной мощности на механизмы СН ТЭЦ будет являться единственной выходной переменной, поэтому применение вероятностной нейронной сети не актуально;

– искусственные нейронные сети на основе радиально-базисных функций могут использоваться для решения широкого круга задач, среди которых наиболее частые – аппроксимация, классификация и кластеризация данных;

– нейронная сеть «многослойный персептрон» состоит из множества входных узлов, которые образуют входной слой, одного или нескольких скрытых слоев и одного выходного слоя нейронов. Каждый нейрон сети имеет нелинейную функцию активации.

Вышеперечисленные методы использовались для решения других задач в электроэнергетике, например для прогнозирования электропотребления комплексной нагрузки энергосистем [3]. Ниже решается задача точного прогнозирования электропотребления системами собственных нужд тепловых электростанций, в отличие от других работ, связанных с задачами прогнозирования на уровне больших энергосистем [3] и промышленных предприятий [4].

Математическая модель. Для обучения нейронных сетей применяются алгоритмы двух типов: управляемые («обучение с учителем») и неуправляемые («без учителя»).

Для решения задач краткосрочного прогнозирования электропотребления принято обучение за управляемое, то есть обучение «с учителем» [5, 6]. Суть данного обучения заключается в подаче на вход нейронной сети данных, содержащих известные значения выходных переменных, а корректировка весов сети производится по результатам сравнения фактических выходных значений с целевыми.

При проведении корреляционного анализа в целях определения входных величин для построения нейронной сети годовой период был разбит на четыре периода [7]. В качестве входных данных были выявлены почасовые значения шести переменных: выработанной активной мощности, тепловой энергии, расхода условного топлива, ретроспективные данные электропотребления СН, число работающих генераторов и коэффициент установленной мощности электростанции. При составлении прогнозных моделей СН ТЭЦ значения тепловой энергии будут учитываться только в отопительный период [8].

Для каждого из выделенных периодов эмпирическим путем в программе ST Neural Networks выбрана наилучшая архитектура

ИНС [9]. Количество нейронов в скрытом слое N_c может определяться из условия

$$N_c \leq \frac{(N_p - 1)N_{out}}{N_{in} + N_{out} + 1},$$

где N_{in} и N_{out} – количества нейронов во входном и выходном слоях соответственно; N_p – количество обучающих примеров (объем выборки).

Применение эмпирических формул для определения числа скрытых слоев и нейронов в каждом из слоев считается недостаточным. На основании обучающей выборки достаточно сложно определить, сколько слоев и нейронов необходимо. В связи с этим необходимо обучать сеть со структурой, предлагаемой программой-нейроимитатором по «умолчанию». В дальнейшем, если сеть не может обучиться, пробуют обучить сеть большего или меньшего размера.

Для отопительного периода смоделирована сеть *MLP 6-7-1* («многослойный персептрон»), которая состоит из трех слоев, выполняющих различные функции. Входной слой состоит из 6 элементов, которые связывают сеть с внешней средой. Второй слой является единственным скрытым слоем сети. Скрытый слой состоит из 7 нейронов. Он выполняет нелинейное преобразование входных параметров в параметры скрытого слоя, за которым следует нелинейное отображение скрытого слоя в выходные значения (рис. 1).

Для периода без отопления смоделирована сеть *MLP 5-5-1*, которая состоит из трех слоев, выполняющих различные функции.

Для периодов включения и отключения отопления смоделирована сеть *MLP 5-6-1*, которая состоит из трех слоев, выполняющих различные функции.

Математическая модель ИНС «многослойный персептрон» для отопительного периода описывается следующим выражением:

$$Y = P_{\text{прог}} = \sum_{j=1}^7 \omega_{jk} Y_j,$$

где Y – выходной сигнал сети; $P_{\text{прог}}$ – прогнозное значение электропотребления; ω_{jk} – весовые коэффициенты выхода сети; $j = 1 \div 7$ – количество нейронов в скрытом слое сети; y_j – выходы нейронов скрытого слоя:

$$y_j = \varphi(\text{net}_j) = \varphi(\omega_{1j}P_{\text{ген.прог}} + \omega_{2j}Q_{\text{отп.прог}} + \omega_{3j}T.U.T + \omega_{4j}P_{\text{С.Н}} + \omega_{5j}KIUM + \omega_{6j}K_{\text{раб.ген}}),$$

где $\varphi(\text{net}_j)$ – функция активации нейронов скрытого слоя; ω_{ij} – начальные весовые коэффициенты между входным слоем и скрытым слоем сети; $i = 1, 2, \dots, 6$ – количество нейронов входного слоя; $P_{\text{ген.прог}}$ – прогнозное значение выработанной активной мощности; $Q_{\text{отп.прог}}$ – прогнозное значение отпуска тепловой энергии; $T.U.T$ – прогнозное значение условного расхода топлива; $P_{\text{С.Н}}$ – ретроспективное значение активной мощности, расходуемой на СН ТЭЦ; $KIUM$ – коэффициент использования установленной мощности электростанции; $K_{\text{раб.ген}}$ – процент работающих генераторов.

После того как для каждой ИНС определено число слоев и число элементов, необходимо найти значения весов и порогов сети, с помощью которых ошибка прогноза будет минимальной. Именно для этого служат алгоритмы обучения [10, 11].

Разработанная авторами математическая модель, основанная на ИНС, отличается от ранее научно-обоснованных моделей количеством нейронов во входном и скрытом слоях, параметрами, подаваемыми на вход сети, и алгоритмом обучения [12].

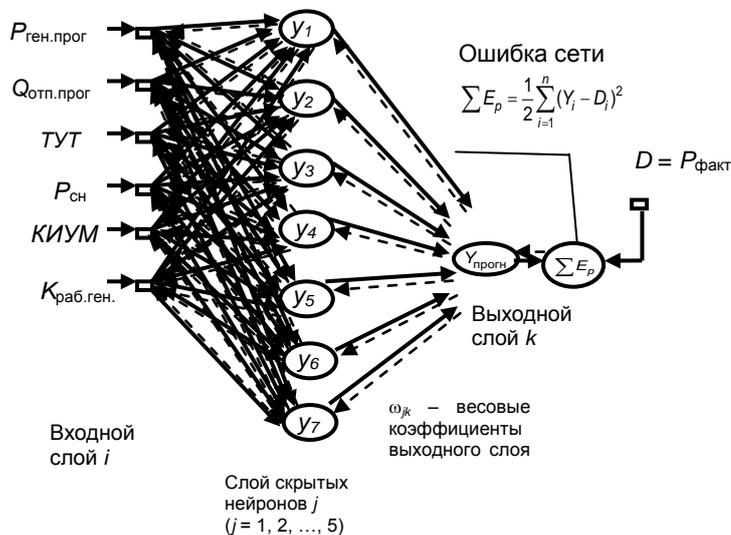


Рис. 1. Нейронная сеть «многослойный персептрон» для периода отопления

По результатам анализа источников литературы произведен сравнительный анализ абсолютной средней ошибки методов краткосрочного прогнозирования потребления электроэнергии и результаты приведены в таблице.

Результаты методов краткосрочного прогнозирования электропотребления

Методы краткосрочного прогнозирования электропотребления	Средняя абсолютная ошибка, %
Методы экспоненциального сглаживания	8,4–9,0
Методы временных рядов	3,54
Методы регрессии	4,12
ИНС метод самоорганизующих карт	4,5–6,3
ИНС метод роя частиц	3,5–5,0
ИНС метод градиентного спуска	4,5–9,0
ИНС метод сопряженных градиентов	2,7–7,5

Анализ полученных данных (см. таблицу) показывает, что ошибки прогноза каждой модели не соответствует требованиям ОРЭМ, согласно которым отклонение ошибки прогноза потребления электроэнергии потребителем не должно превышать 2 %³.

Краткосрочное прогнозирование электропотребления СН ТЭЦ и обучение данной сети методами численной оптимизации по Новокуйбышевской ТЭЦ за 2014 год осуществляется с помощью искусственной нейронной сети «многослойный персептрон» [13, 14].

Вычислительный эксперимент. Были исследованы алгоритмы обучения данных нейронных сетей, которые максимально минимизировали ошибку прогноза, выдаваемого сетью. Обучение нейронных сетей осуществлялось с помощью методов численной оптимизации: алгоритма обучения Бройдена–Флетчера–Гольдфарба–Шанно; метода Сопряженных градиентов; метода градиентного спуска.

По построенным нейронным сетям, согласно методу наименьших квадратов была рассчитана абсолютная средняя ошибка функционирования каждой сети, которая определяется по следующему выражению:

$$\sum E_p = \frac{1}{2} \sum_{i=1}^n (Y_i - D_i)^2,$$

где Y_i – выход сети; D_i – фактические значения электропотребления; p – индекс образца в обучающей выборке.

³ Об утверждении правил оптового рынка электрической энергии и мощности и о внесении изменений в некоторые акты Правительства Российской Федерации по вопросам организации функционирования оптового рынка электрической энергии и мощности: Постановление от 27 декабря 2010 г. № 1172//Собрание законодательства РФ-2011.

Цель исследования заключается в нахождении таких значений весовых коэффициентов, при которых ошибка функционирования сети была бы минимальной: $\sum E_p \rightarrow \min$ [15].

Результаты. На основании рассмотренных методов обучения ИНС и построенных графиков абсолютных средних ошибок прогноза электропотребления на сутки вперед можно сделать вывод, что ИНС с алгоритмом обучения Бройдена–Флетчера–Гольдфарба–Шанно в отопительном периоде имеет минимальную среднюю абсолютную ошибку прогноза $\varepsilon = 0,48\%$, а максимальное отклонение от фактического значения составляет $\varepsilon = 1,9\%$ (рис. 2).

ИНС с алгоритмом обучения Бройдена–Флетчера–Гольдфарба–Шанно в период без отопления имеет минимальную среднюю абсолютную ошибку прогноза $\varepsilon = 0,44\%$, а максимальное отклонение от фактического значения составляет $\varepsilon = 0,98\%$ (рис. 3).

ИНС с алгоритмом обучения Бройдена–Флетчера–Гольдфарба–Шанно в период отключения отопления и в период включения отопления имеет минимальную среднюю абсолютную ошибку прогноза $\varepsilon = 0,38\%$, а максимальное отклонение от фактического значения составляет $\varepsilon = 1,7\%$ (рис. 4).

Выводы. Разработанная математическая модель дает возможность более точно прогнозировать электропотребление системой собственных нужд ТЭЦ, что, в свою очередь, уменьшит вероятность получения штрафных санкций на ТЭЦ.

На основании рассмотренных методов обучения ИНС и построенных графиков ошибок прогноза электропотребления на сутки вперед можно сделать вывод, что ИНС с алгоритмом обучения Бройдена–Флетчера–Гольдфарба–Шанно в отопительный период, период без отопления и в периоды включения и отключения отопления имеет наименьшую ошибку прогноза и ее среднее годовое значение составляет $\varepsilon = 0,43\%$, что на 2,27 % меньше уже имеющих полученных минимальных ошибок ИНС, используемых для задач краткосрочного прогнозирования электропотребления.

В Филиале АО «СО ЕЭС» ОДУ Средней Волги методика краткосрочного прогнозирования электропотребления СН ТЭЦ [16] протестирована и утверждена для решения практических задач:

1) оценки прогнозных значений электропотребления электростанций для планирования баланса электроэнергии;

2) планирования оптимальных энергетических режимов и режимов работы генерирующих и энергопотребляющих объектов.

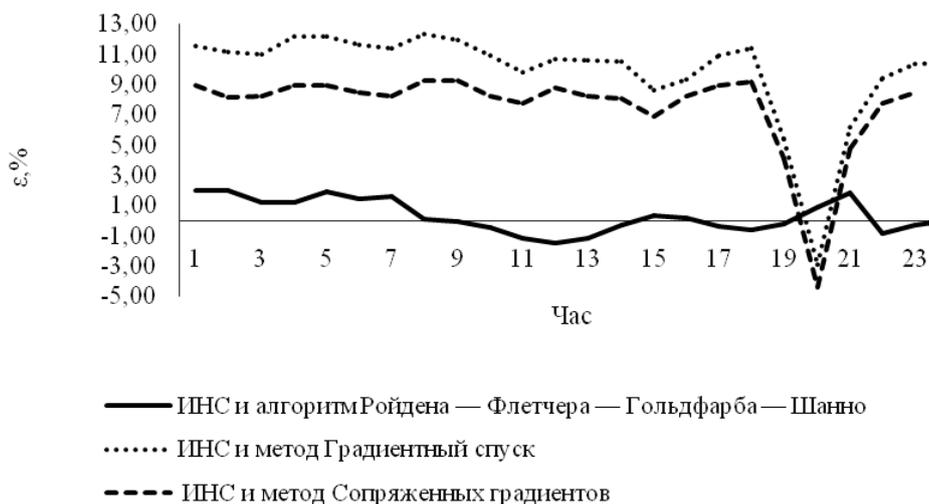


Рис. 2. Ошибки прогнозирования ИНС в отопительный период

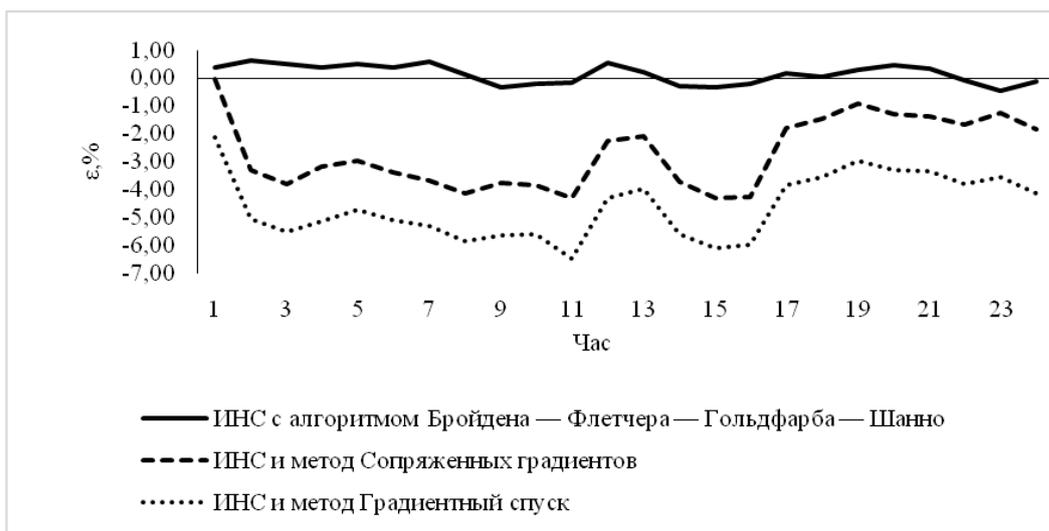


Рис. 3. Ошибки прогнозирования ИНС в период без отопления



Рис. 4. Ошибки прогнозирования ИНС в период отключения отопления и в период включения отопления

Список литературы

1. **Осовский С.** Нейронные сети для обработки информации / пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.
2. **Barron A.R.** Statistical properties of artificial neural networks. Proceedings of the IEEE International Conference on Decision and Control. – NewYork, 1989. – P. 280–285.
3. **Алексеева И.Ю., Ведерников А.С., Скрипачев М.О.** Прогнозирование электропотребления с использованием метода искусственных нейронных сетей // Вестник СамГТУ. Сер. Технические науки. – 2010. – С. 135 – 138.
4. **Гофман А.В.** Усовершенствование методики прогнозирования многономенклатурного предприятия с учетом производственной деятельности // Электроэнергетика глазами молод ежи: сборник научных трудов Междунар. науч.-техн. конф. – Самара: СамГТУ, 2011. – Т. 2. – С. 153–157.
5. **Barron A.R.** Complexity regularization with applications to artificial neural networks. In G. Roussas (ed.) Nonparametric Functional Estimation. – Boston, MA and Dordrecht, the Netherlands: Kluwer Academic Publishers, 1990. – P. 561–576.
6. **Соловьева И.А., Дзюба А.П.** Прогнозирование электропотребления с учетом факторов технологической и рыночной среды // Научный диалог. – 2013. – № 7(19): Экономика. Право. Политология. – С. 97–113.
7. **Ведерников А.С., Балукова Е.А.** Определение корреляционных зависимостей между факторами, влияющими на электропотребление собственных нужд ТЭЦ // Изв. вузов. Электромеханика. – 2016. – № 6. – С. 110–113.
8. **Галушкин А.И.** Теория нейронных сетей. Кн. 1: учеб. пособие для вузов. – М.: ИПРЖР, 2001. – 385 с.
9. **Ведерников А.С., Балукова Е.А., Комасова Е.А.** Построение нейронных сетей для прогнозирования электропотребления собственных нужд ТЭЦ // Электроэнергетика глазами молодежи: материалы VIII Междунар. науч.-техн. конф., 2–6 октября 2017, Самара. В 3 т. Т. 3. – Самара: Самар. гос. техн. ун-т, 2017. – С. 72–78.
10. **Бэнн Д.В., Фармер Е.Д.** Сравнительные модели прогнозирования электрической нагрузки. – М.: Энергоатомиздат, 1987. – 200 с.
11. **Субенко Г.** Approximations by superpositions of a sigmoidal function. Mathematics of Control, Signals, and Systems. – 1989. – 2. – P. 303–314.
12. **Курбацкий В.Г., Томин Н.В.** Прогнозирование электрической нагрузки с использованием искусственных нейронных сетей // Электрика. – 2006. – № 7. – С. 26–32.
13. **Барский А.Б.** Нейронные сети: распознавание, управление, принятие решений. – М.: Финансы и статистика, 2004. – 176 с. (Прикладные информационные технологии).
14. **Боровиков В.П.** Нейронные сети. Statistica Neural Networks. Методология и технологии современного анализа данных. – 2-е изд. – М.: Горячая линия – Телеком, 2008. – 392 с.
15. **Халафян А.А.** STATISTICA 6. Статистический анализ данных. – 3-е изд. учеб. – М.: Бином-Пресс, 2007. – 512 с.
16. **Свидетельство 23603** Российская Федерация. Свидетельство о регистрации электронного

ресурса. Программа «Прогнозирование электропотребления собственных нужд ТЭЦ на основе нейронной сети» (программа для ЭВМ) / А.С. Ведерников, Е.А. Ярыгина, Р.Н. Хамитов. – М.: ОФЭРНИО, 2018.

Reference

1. **Osovskiy, S.** *Neyronnye seti dlya obrabotki informatsii* [Neural networks for information processing]. Moscow: Finansy i statistika, 2002. 344 p.
2. **Barron, A.R.** Statistical properties of artificial neural networks. Proceedings of the IEEE International Conference on Decision and Control. NewYork, 1989, pp. 280–285.
3. **Alekseeva, I.Yu., Vedernikov, A.S., Skripachev, M.O.** Prognozirovanie elektropotrebleniya s ispolzovaniem metoda iskusstvennykh neyronnykh setey [Forecasting of power consumption using the method of artificial neural networks]. *Vestnik SamGTU. Seriya Tekhnicheskie nauki*, 2010, pp. 135–138.
4. **Gofman, A.V.** Usovershenstvovanie metodiki prognozirovaniya mnogonomenklturnogo predpriyatiya s uchetom proizvodstvennoy deyatelnosti [Improvement of the methods of forecasting a multiproduct enterprise taking into account its production activity]. *Sbornik nauchnykh trudov Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii «Elektroenergetika glazami molodezhi»* [Collected scientific works of the International scientific and technical conference “Electric Power Engineering in the Youth’s Eyes”. Samara: SamGTU, 2011, vol. 2, pp. 153–157.
5. **Barron, A.R.** Complexity regularization with applications to artificial neural networks. In G. Roussas (ed.) Nonparametric Functional Estimation. Boston, MA and Dordrecht, the Netherlands: Kluwer Academic Publishers, 1990, pp. 561–576.
6. **Solov'eva, I.A., Dzyuba, A.P.** Prognozirovanie elektropotrebleniya s uchetom faktorov tekhnologicheskoy i rynochnoy sredy [Prediction of power consumption taking into account factors of the technological and market environment]. *Nauchnyy dialog*, 2013, no. 7(19), pp. 97–113.
7. **Vedernikov, A.S., Balukova, E.A.** Opredelenie korrelyatsionnykh zavisimostey mezhdru faktorami, vliyayushchimi na elektropotreblenie sobstvennykh nuzhd TETs [Determination of correlation dependences between factors influencing CHPP electric power consumption]. *Izvestiya vuzov. Elektromekhanika*, 2016, no. 6, pp. 110–113.
8. **Galushkin, A.I.** *Teoriya neyronnykh setey. Kn. 1* [Theory of neural networks. Book 1]. Moscow: IPRZhR, 2001. 385 p.
9. **Vedernikov, A.S., Balukova, E.A., Komasova, E.A.** Postroenie neyronnykh setey dlya prognozirovaniya elektropotrebleniya sobstvennykh nuzhd TETs [Construction of neural networks for forecasting CHPP auxiliary power consumption]. *Materialy VIII Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii: «Elektroenergetika glazami molodezhi». V 3 t., t. 3* [Proceedings of the VIII International Scientific and Technical Conference: “Electric Power Engineering in the Youth’s Eyes”. In 3 vol., vol. 3]. Samara: Samarskiy gosudarstvennyy tekhnicheskiy universitet, 2017, pp. 72–78.
10. **Benn, D.V., Farmer, E.D.** *Sravnitel'nye modeli prognozirovaniya elektricheskoy nagruzki*

[Comparative models of electric load forecasting]. Moscow: Energoatomizdat, 1987. 200 p.

11. Cybenko, G. Approximations by superpositions of a sigmoidal function. Mathematics of Control, Signals, and Systems, 1989, no. 2, pp. 303–314.

12. Kurbatskiy, V.G., Tomin, N.V. Prognozirovaniye elektricheskoy nagruzki s ispol'zovaniem iskusstvennykh neyronnykh setey [Forecasting of electric load using artificial neural networks]. *Elektrika*, 2006, no. 7, pp. 26–32.

13. Barskiy, A.B. *Neyronnyye seti: raspoznavanie, upravlenie, prinyatie resheniy* [Neural networks: recognition, management, decision-making]. Moscow: Finansy i statistika, 2004. 176 p. (Prikladnyye informatsionnyye tekhnologii).

14. Borovikov, V.P. *Neyronnyye seti. Statistika Neural Networks. Metodologiya i tekhnologii*

sovremennogo analiza dannykh [Neural networks. Statistica Neural Networks. Methodology and technologies of modern data analysis]. Moscow: Goryachaya liniya – Telekom, 2008. 392 p.

15. Khalafyan, A.A. *STATISTICA 6. Statisticheskiy analiz dannykh* [STATISTICA 6. Statistical analysis of data]. Moscow: Binom-Press, 2007. 512 p.

16. Vedernikov, A.S., Yarygina, E.A., Khamitov, R.N. Programma «Prognozirovaniye elektropotrebleniya sobstvennykh nuzhd TETs na osnove neyronnoy seti» [Computer program «Forecasting of thermal power plant auxiliary power consumption based on neural networks»]. *Svidetel'stvo o registratsii elektronnoy resursa № 23603* [Certificate of registration of digital resource No. 23603]. Moscow: OFERNIO, 2018.

Ведерников Александр Сергеевич,

Самарский государственный технический университет,

кандидат технических наук, доцент, декан электротехнического факультета, зав. кафедрой электрических станций,

телефоны: (846) 278-44-93, 242-37-89;

e-mail: es@samgtu.ru

Vedernikov Aleksandr Sergeevich,

Samara State Technical University,

Candidate of Engineering Sciences (PhD), Associate Professor, Dean of the Electrical Engineering Faculty, Head of the Electric Stations Department,

telephone: (846) 278-44-93, 242-37-89;

e-mail: es@samgtu.ru

Ярыгина Екатерина Александровна,

Самарский государственный технический университет,

аспирантка электротехнического факультета, ассистент кафедры электрических станций,

e-mail: balukova_e@mail.ru

Yarygina Ekaterina Aleksandrovna,

Samara State Technical University,

Post-Graduate Student of the Electrical Engineering Faculty, Assistant of the Electric Stations Department,

e-mail: balukova_e@mail.ru

Гофман Андрей Владимирович,

Самарский государственный технический университет,

кандидат технических наук, доцент кафедры электрических станций,

e-mail: gofman-av@fsk-ees.ru

Gofman Andrei Vladimirovich,

Samara State Technical University,

Candidate of Engineering Sciences (PhD), Associate Professor of the Electric Stations Department,

e-mail: gofman-av@fsk-ees.ru

УДК 621.316.91

Сопrotивление низковольтной электрической дуги для расчета коротких замыканий в расширенном диапазоне токов

Ю.П. Гусев, Е.В. Шелковой

ФГБОУВО «Национальный исследовательский университет «МЭИ»»,

г. Москва, Российская Федерация

E-mail: GusevYP@mpei.ru; ShelkovoyYV@mpei.ru

Авторское резюме

Состояние вопроса. Рост мощностей трансформаторов в низковольтных электроустановках переменного тока свыше 2500 кВА и необходимость обеспечивать быстрое отключение удаленных дуговых коротких замыканий требуют уточнения расчета сопротивления электрической дуги в области больших и малых токов. Исследования