

**Розенберг Игорь Наумович** – Научно-исследовательский институт автоматизации, информатизации и связи на железнодорожном транспорте (АО «НИИАС»); e-mail: avb@itt.net.ru; г. Москва, Россия; научный руководитель АО «НИИАС»; д.т.н.; профессор.

**Knyazeva Margarita Vladimirovna** – Southern Federal University; e-mail: mknyazeva@sfnu.ru; Taganrog, Russia; phone: +78634371743; cand. of eng. sc.; associate professor.

**Bozhenyuk Aleksander Vitalievich** – e-mail: avb002@yandex.ru; dr. of eng. sc.; professor.

**Rozenberg Igor Naumovich** – Public corporation “Research and development institute of railway engineers”; e-mail: avb@itt.net.ru; Moscow, Russia; dr. of eng. sc.; professor.

УДК 621.315.611

DOI 10.18522/2311-3103-2022-2-31-46

**Н.К. Полуянович, М.Н. Дубяго**

### **ОЦЕНКА ВОЗДЕЙСТВУЮЩИХ ФАКТОРОВ И ПРОГНОЗИРОВАНИЕ ЭЛЕКТРОПОТРЕБЛЕНИЯ В РЕГИОНАЛЬНОЙ ЭНЕРГОСИСТЕМЕ С УЧЕТОМ РЕЖИМА ЕЕ ЭКСПЛУАТАЦИИ**

*Статья посвящена исследованиям вопросов оценки воздействующих факторов и прогнозирования электропотребления в региональной энергосистеме с учетом режимов ее эксплуатации. Проведен анализ существующих методов прогнозирования энергопотребления. Обоснован выбор метода прогнозирования с использованием искусственной нейронной сети. Рассмотрен алгоритм создания нейросети для краткосрочного прогноза электрической нагрузки. Актуальность работы обусловлена требованиями действующего законодательства к прогнозированию электропотребления для решения задачи поддержания баланса мощностей между генерирующей стороной и потреблением электрической энергии. При этом одной из основных задач, связанных с генерацией электрической энергии и ее потреблением, является задача поддержания баланса мощностей. С одной стороны, при увеличении плановой нагрузки могут возникнуть перебои в поставке электроэнергии, с другой стороны, уменьшение электропотребления приведет так же к уменьшению КПД электростанций, и в конечном счете – к повышению стоимости на электроэнергию как для субъекта оптового рынка электроэнергии, так и для конечного потребителя. Разработанная нейросетевая модель (НС) модель сводит задачу краткосрочного прогнозирования электропотребления к поиску матрицы свободных коэффициентов посредством обучения на имеющихся статистических данных (активная и реактивная мощность, температура окружающей среды, дата и индекс дня). Полученная НС модель краткосрочного прогнозирования электропотребления участка районной электрической сети 10 кВ, учитывает факторы: – времени, – метеорологических условий, – отключений отдельных питающих линий электропередач, – режима работы потребителей электроэнергии. Получены прогнозные оценки электропотребления энергосистемы по данным потребляемой электроэнергии наружной температуры, типу дня и т.д. Модель прогнозирования величины, потребляемой активной и реактивной мощности вполне работоспособна, однако на данном этапе все еще имеет довольно высокий уровень погрешности прогнозирования. Для повышения точности прогнозирования необходимо увеличить базу данных, составляющих обучающую выборку, т.к. на данный момент имеющиеся данные охватывают временной промежуток длиной лишь 3–4 месяца. Результаты анализа показали, что наибольшие трудности вызывает прогнозирование потребления реактивной мощности.*

*Анализ данных; искусственные нейронные сети; прогнозирование электропотребления; набор факторов; надежность систем энергоснабжения; методы прогноза; архитектура нейронной сети.*

N.K. Poluyanovich, M.N. Dubyago

**ASSESSMENT OF INFLUENCING FACTORS AND FORECASTING OF POWER CONSUMPTION IN THE REGIONAL POWER SYSTEM, TAKING INTO ACCOUNT ITS OPERATING MODE**

*The article is devoted to the research of the assessment of influencing factors and forecasting of power consumption in the regional power system, taking into account its operating modes. The analysis of existing methods of forecasting energy consumption is carried out. The choice of a forecasting method using an artificial neural network is justified. An algorithm for creating a neural network for short-term prediction of electrical load is considered. The relevance of the work is due to the requirements of the current legislation for forecasting electricity consumption in order to solve the problem of maintaining a balance of power between the generating side and the consumption of electric energy. At the same time, one of the main tasks related to the generation of electric energy and its consumption is the task of maintaining a balance of capacities. On the one hand, with an increase in the planned load, interruptions in the supply of electricity may occur, on the other hand, a decrease in electricity consumption will also lead to a decrease in the efficiency of power plants, and ultimately to an increase in the cost of electricity both for the wholesale electricity market and for the end user. The developed neural network model reduces the task of short-term forecasting of power consumption to the search for a matrix of free coefficients by training on available statistical data (active and re-active power, ambient temperature, date and index of the day). The received NS model of short-term forecasting of power consumption of a section of the district 10 kV electric grid takes into account the factors: – time, - meteorological conditions, – disconnections of individual power supply lines of cottages, – operating mode of electricity consumers. Predictive estimates of the power consumption of the power system have been obtained based on the data of the electricity consumed by the outdoor temperature, the type of day, etc. The model for predicting the magnitude of the consumed active and reactive power is quite workable, but at this stage still has a fairly high level of forecasting error. To improve the accuracy of forecasting, it is necessary to increase the database that makes up the training sample, because at the moment the available data cover a time period of only 3–4 months. The results of the analysis showed that forecasting reactive power consumption causes the greatest difficulties.*

*Data analysis; artificial neural networks; power consumption forecasting; set of factors; reliability of power supply systems; forecasting methods; neural network architecture.*

**Введение и актуальность работы.** Электроэнергетика является ключевой отраслью российской экономики и многих стран мира. Основную информацию для планирования развития электроэнергетических систем составляют прогнозные оценки электропотребления. В зависимости от времени упреждения прогнозы делятся на прогнозирование долгосрочное, среднесрочное, краткосрочное и оперативное. Прогнозирование потребления электроэнергии является на сегодняшний день одной из важных научных и практических задач в электроэнергетике. Повышение точности прогнозирования обеспечивает экономию энергетических ресурсов, определяет эффективность управления электроснабжением и соответствующее увеличение прибыли энергетических предприятий. Если у крупных промышленных предприятий реальные показания потребления будут отличаться от заявленных в энергоснабжающую организацию объемов электроэнергии больше чем на 5%, на предприятие будут наложены штрафы [1]. По оценкам российских специалистов, каждая оплошность в ежегодном прогнозе электропотребления на 1% – это 4 млрд. долларов дополнительных инвестиций на возведение генерирующих мощностей [2]. Электрическая энергия в себестоимости продукции крупных предприятий, например, в металлургическом производстве, составляет 11% – 30%.

Проблема прогнозирования электропотребления заключается в том, что необходимо учесть огромное количество факторов, имеющих влияние на изменение энергопотребления. Задача составления заявки в энергоснабжающую организацию на объем электроэнергии обусловлен:

- ◆ своевременное получение информации о предстоящей нагрузке позволяет выбрать оптимальный режим работы системы электроснабжения;
- ◆ закупка электроэнергии осуществляется на основании прогнозирования собственного потребления;
- ◆ огромным количеством энергоресурсов затрачиваемым на пуски и остановки генерирующего оборудования.

Если реальные показания потребления будут отличаться от заявленных сумм больше чем на 5 %, на предприятие будут наложены штрафы [1].

Временной ряд почасового электропотребления электротехнического комплекса участка районных электрических сетей зависит от множества факторов, часть из которых несут недетерминированный характер [3]. Данное обстоятельство делает задачу краткосрочного прогнозирования электропотребления (short-term load forecasting – STLF) для данного временного ряда слабоформализуемой.

В электроэнергетических системах осуществляется непрерывное круглосуточное регулирование технологического режима работы объектов диспетчеризации по мощности, обеспечивающее [1]:

- ◆ поддержание частоты электрического тока в установленных пределах;
- ◆ поддержание потоков мощности в объектах электросетевого хозяйства, в пределах допустимых значений;
- ◆ изменение заданных режимов работы энергосистемы при изменении фактического электроэнергетического режима энергосистемы.

Суточный диспетчерский график является основным инструментом управления энергосистемой [4]. Для выполнения регулирования технологического режима необходим диспетчерский график электрической нагрузки, получаемый с помощью прогнозирования. Прогнозирование электроэнергетических режимов энергосистемы осуществляется для следующих периодов времени: один час, 2 и более часа, одни сутки, один месяц, один квартал, один год, 5 лет. Краткосрочное прогнозирование электроэнергетических режимов энергосистем и технологических режимов работы объектов электроэнергетики осуществляется на предстоящие сутки и выполняется диспетчерскими центрами всех уровней [5].

В условиях функционирования рынка электроэнергии точность прогнозов потребления существенно влияет на технологические и экономические показатели энергосистемы [6–8]. С развитием автоматизированных информационно-измерительных систем коммерческого учета электроэнергии (далее – АИИС КУЭ) на предприятии появляется возможность осуществлять учет потребленной электроэнергии не только по предприятию в целом, но и по его отдельным участкам, цехам, производственным линиям.

Таким образом, для обеспечения устойчивой работы электроэнергетической системы актуальной и имеющей большое практическое значение научно-технической задачей является разработка методики прогнозирования потребления электрической энергии с заданной дискретностью на основе изучения системных свойств и связей в электротехническом комплексе и составления моделей статистических данных.

Отсюда целью данного исследования является:

- ◆ разработка математической модели краткосрочного прогнозирования электропотребления электротехнического комплекса участка районных электрических сетей 10 кВ с помощью аппарата искусственных нейронных сетей;
- ◆ повышение энергоэффективности прогнозирования потребления электрической энергии обеспечивающей снижение погрешности прогнозирования относительно применяемого метода прогнозирования;

◆ увеличение точности предсказания предполагаемого потребления электроэнергии с целью оптимального использования энергоресурсов.

Для достижения поставленной цели необходимо разработать нейросетевую модель прогнозирования электропотребления, включающую обработку данных обучающей выборки, индикацию времени суток, оптимизацию числа нейронов в слоях и переобучение сети на основе текущих фактических значений электропотребления.

**Выбор метода прогнозирования.** В литературе хорошо освещен вопрос прогнозирования электрических нагрузок на разные временные горизонты. Методы повышения точности STLF можно подразделить на: методы математической статистики, методы искусственного интеллекта и гибридные методы [9]. Однако, в условиях неопределенности, традиционные методы математической статистики или имитационного моделирования не позволяют строить адекватные модели объектов [14]. Прогнозирование почасового потребления с упреждением «на сутки вперед» должно осуществляться с погрешностью ~ 5%.

В настоящее время наблюдается стремительное развитие таких областей информационных технологий, как искусственный интеллект, системы обработки больших объемов данных (Big Data) и глубокое машинное обучение. Анализ публикаций по рассматриваемой теме показал, что при прогнозировании электропотребления главным образом используются методы на основе искусственных нейронных сетей [18]. Гораздо реже используются другие методы: регрессионные модели [10], метод анализа главных компонент [12], статистические методы [13], метод максимального правдоподобия [6]. При краткосрочном прогнозировании чаще используются искусственные нейронные сети с нелинейными функциями активации. Прогнозирование выполняется как с учетом, так и без учета дополнительных факторов: температуры, типа дня (рабочий выходной, праздничный) и др. Конфигурация искусственной нейронной сети зависит от графика электропотребления, который определяется объектом прогнозирования (энергосистема, город, предприятие и т.д.). В некоторых работах (например, [11]) используется разбиение исходных данных по электропотреблению на кластеры по дням недели.

Важным достоинством искусственных нейронных сетей (ИНС) – математических моделей, является возможность факторного прогнозирования. При этом сеть имеет  $N$  входов, каждый из которых соответствует какому-либо фактору, оказывающему влияние на прогнозный параметр. Подача на вход сети вместе с предысторией электропотребления значимых факторов (температура, тип дня и др.) способствует повышению точности прогноза. При этом сеть сама определяет зависимости между факторами, корректируя свои параметры при обучении. Таким образом могут быть смоделированы достаточно сложные регрессионные зависимости. Многослойный персептрон может формировать на выходе произвольную многомерную функцию при соответствующем выборе количества слоев, диапазона изменения сигналов и параметров нейронов.

Для прогнозирования были применены рассмотренные выше типы ИНС. Размерность ИНС (число скрытых слоев и число нейронов в этих слоях) в каждом конкретном случае определялась экспериментальным путем. Прогнозирование потребления электроэнергии представляет собой многоэтапный и многоуровневый процесс.

В работе использованы методы математического моделирования, обработки данных и прогнозирования временных рядов; статистический и регрессионный анализ; теория искусственных нейронных сетей; математические пакеты MatLab (Neural Networks Toolbox).

На основании анализа, проведенного в [10], почасовое электропотребление электротехнического комплекса участка районной электрической сети можно представить в виде функции влияющих факторов:

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

где  $y$  – почасовое электропотребление электротехнического комплекса участка районной электрической сети;  $f_1, f_2$  – функциональные зависимости, устанавливающие взаимосвязь между влияющими факторами и почасовым электропотреблением;  $x_1, x_2, x_c$  – набор эндогенных факторов;  $x_{c+1}, x_{c+2}, \dots, x_1$  – набор экзогенных факторов;  $l$  – общее количество влияющих факторов;  $\varepsilon$  – шумовая составляющая.

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_h \end{bmatrix} = f_1(\bar{x}_1, \bar{x}_2, \dots, \bar{x}_c) + f_2(\bar{x}_{c+1}, \bar{x}_{c+2}, \dots, \bar{x}_1), \bar{x}_i = \begin{bmatrix} x_{i1} \\ x_{i2} \\ \dots \\ x_{i24} \end{bmatrix}, \quad (2)$$

где  $Y$  – вектор суточного электропотребления электротехнического комплекса участка районной электрической сети;  $h=24$  – количество часов в сутках;

Так как, стандартные метода математической статистики, такие как корреляционный и регрессионный анализ, мало пригодны для прогнозирования поведения такой сложной функциональной зависимости, как временной ряд электропотребления участка районной электрической сети, необходимо прибегнуть к инструментам нейросетевого анализа. Для представления выражения (2) в виде нейросетевой математической модели, рассмотрим принцип функционирования одного искусственного нейрона.

**Синтез нейросети.** В качестве выходных параметров выбраны показания отдельных счетчиков, а в качестве входных – наборы определяющих и влияющих параметров. В этом случае возможны две основных концепции построения структуры ИНС:

- ◆ использование полносвязного скрытого слоя, когда нейроны соединены по принципу «каждый с каждым» рис.1;

- ◆ настройка структуры связей скрытого слоя в соответствии с реальной структурой производства. При этом увеличиваются затраты на построение сети, но вместе с тем и возрастает точность прогноза [15].

При построение внутренней структуры прогнозной модели, определяющей зависимость выходных параметров от входных была выбрана ИНС типа «многослойный персептрон» содержала во входном слое 5 нейронов, в выходном – 2 нейрона.

Математически функционирование нейрона можно представить следующей системой уравнений:

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

где  $u_j$  – линейная комбинация входных воздействий на нейрон  $j$ ;  $w_{ij}$  – вес синаптической связи соединяющей вход  $i$  и нейрон  $j$ ;  $x_i$  – входной сигнал нейрона;  $v_j$  – индуцированное локальное поле нейрона;  $b_j$  – порог активации нейрона;  $O_j$  – выходной сигнал нейрона;  $\varphi(v_j)$  – функция активации нейрона.

Структура ИНС определялась опытным путем. Число промежуточных слоев равнялось одному. Количество нейронов в промежуточном слое составило 10 нейронов. Как показали эксперименты, увеличение числа скрытых слоев не привело к лучшим результатам, а лишь усложнило процесс обучения.

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

$$O_j = \varphi(v_j) = \sum_{i=1}^n w_{ij}x_i. \quad (4)$$

Для настройки весов нейронной сети используется алгоритм обучения с учителем, известный как алгоритм обратного распространения ошибки. Метод определения количества нейронов скрытого слоя рассмотрен в [7].

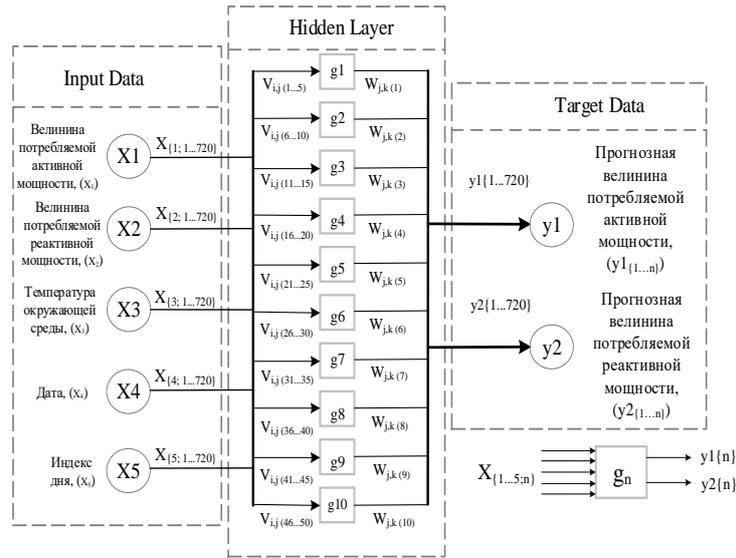


Рис. 1. Структура НС для прогнозирования величины потребляемой активной и реактивной мощности

Нейронная сеть, представленная на рис. 1, состоит из:

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

Расположение нейронов послойно очень важно с вычислительной точки зрения, так как появляется возможность векторизовать процесс обработки данных в ИНС. Другими словами, все операции в ИНС производятся с помощью матричных операций сложения, скалярного произведения и т.д. По своей сути, выражение (4) представляет собой скалярное произведение векторов весовых коэффициентов  $w$  на вектор входных сигналов  $x$ . Если на вход нейронной сети подается вектор точных значений факторов, влияющих на электропотребление ГТП гарантирующего поставщика второго уровня, размером  $n = 24 * 1$ , то выражение (4) можно записать в виде:

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

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

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

где  $O_1$  – вектор отклика слоя первого скрытого слоя ИНС;  $W_{01}$  – матрица весовых коэффициентов между входным и первым скрытым слоем нейронной сети размером  $n * k$ ;

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{bmatrix}.$$

- ♦ массив суточных значений влияющих факторов.

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

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

где  $W_{mh}$  – матрица весовых коэффициентов между последним скрытым слоем  $m$  и выходным слоем  $h$ ;  $O_m$  – отклик последнего скрытого слоя  $m$ .

В качестве основных входных данных используется 4 нейрона:

- ♦ использование самого прогнозируемого параметра – величина потребляемой активной и реактивной мощности 1 и 2 входы;
- ♦ использование набора определяющих параметров как основы для получения прогноза, с дополнительным учетом влияющих параметров – температура окружающей среды – 3 вход,
- ♦ текущая дата, служит для уточнения месяца и дня недели при прогнозе - 4 вход, 5 вход был введен для определения рабочих и выходных дней недели.

Дополнительно был введен параметр «индекс дня», для определения рабочих или выходных дней недели. Так, например, рабочим будням соответствует индекс – 1, для выходных – 0, для предпраздничных дней индекс – 0.5, т. к. это не выходные, но рабочий день несколько сокращен. Это работает следующим образом: в будние дни величина потребляемой мощности держится в одном диапазоне, а в праздничные дни или выходные сеть может видеть некоторое снижение потребляемой мощности. Введение данных индексов позволяет сети понять, что в выходные или праздничные дни потребление несколько уменьшается.

Для определения входных переменных нейронной сети при решении задач прогнозирования нагрузки была использована модель, описывающая изменения во времени фактических значений электропотребления, которая в общем виде представляется нелинейной функцией:

$$W_t = f(W_{t-n}, T_{t-n}, N_t) + \varepsilon_t, \quad (7)$$

где  $W_t$  – фактическое электропотребление энергосистемы в момент времени  $t$ ;  $t$  – текущее время;  $W_{t-n}$  – предшествующие наблюдения электропотребления;  $T_{t-n}$  – предшествующие наблюдения температуры окружающей среды;  $n$  – индекс ретроспективы данных;  $N_t$  – тип дня недели (рабочий, выходной, праздничный);  $\varepsilon_t$  – случайная составляющая, представляющая ненаблюдаемые факторы, влияющие на электропотребление.

Оценка точности прогноза ИНС на тестовом множестве размерностью  $P$  оценивается по среднему абсолютная ошибка в процентах (MAPE):

$$MAPE = \frac{1}{p} \sum_{i=1}^p \frac{|y_i - \hat{y}_i|}{y_i} \times 100, \quad (8)$$

где  $y_i$  – фактическое значение нагрузки,  $\hat{y}_i$  – результат прогноза,  $p$  – количество данных.

Из анализа публикаций, приемлемой является ошибка прогноза не более 5%.

Были получены прогнозные оценки электропотребления энергосистемы по данным потребляемой электроэнергии, наружной температуры и типу дня. Данные были предварительно подготовлены – разделены на обучающее, контрольное и тестовое подмножества.

Обычно при обучении ИНС начальные веса связей задаются случайным образом. При использовании методики анализа электропотребления [8], имеется возможность жестко установить первоначальный вес связей, относящихся к входным нейронам сети в зависимости от того, определяющий это параметр, или влияющий. Благодаря этому сокращается время обучения сети, уменьшается вероятность попадания ИНС в локальные минимумы в процессе обучения.

**Разработка модели прогнозирования.** При разработке модели прогнозирования, целесообразно сгруппировать дни не дели, схожие по ЭП. В работе [19] был предложен подход, позволяющий выделить следующие типы дней в неделе:

- ◆ рабочий день;
- ◆ выходной день;
- ◆ праздничный день.

Такой подход оправдан, поскольку характер ЭП по этим дням различается. Так, например, в рабочие дни ЭП в большей степени зависит от технологических процессов промышленных предприятий, планов выпуска продукции, графика рабочего времени, в то время как в выходные и праздничные дни больший вес имеют социальные явления, период светового дня и другие факторы.

Предложенная математическая модель прогнозируемого объема электропотребления (ЭП) – это функция от следующих переменных:

$$V_2(t) = \{M, N, T_{cp}, t, h, V_1, T_n\}, \quad (9)$$

где  $V_2(t)$  – прогнозируемая величина объемов потребляемой электроэнергии;  $V_1(t)$  – текущая величина объемов потребляемой электроэнергии;  $M$  – порядковый номер месяца в году;  $N$  – порядковый номер дня в месяце;  $T_{cp}$  – среднесуточная температура окружающего воздуха;  $h$  – флаг для рабочего или выходного дня (1 – рабочий, 0 – выходной);  $T_n$  – тариф на электроэнергию;  $t$  – часовой интервал времени.

При создании обучающей выборки входные сигналы нейронной сети представляются параметрами  $t$ ,  $V_1$ ,  $N$ ,  $T_{cp}$ ,  $n$ ,  $h$ , а эталонные значения – параметром  $V_2$ .

**Постановка задачи.** Рассмотрим пример помесячного прогнозирования электропотребления предприятием.

С применением ИНС. В качестве исходных данных использованы следующие величины:

- ◆ максимальное почасовое электропотребление энергосистемы (рис. 1–6, синий график);
- ◆ средние по энергосистеме почасовые значения температуры за один месяц;
- ◆ количество выходных в месяце;
- ◆ продолжительность дня;
- ◆ плановые объемы производства на месяц;
- ◆ максимальное и минимальное месячные значения потребления за предыдущий год.

Была проанализирована динамика изменения электропотребления региональной энергосистемы [20–22] в зависимости от температуры окружающей среды. Влияние температуры на электропотребление промышленности связано с изменением мощности, потребляемой на обогрев помещений и вентиляцию. Сезонные колебания электропотребления имеют явно выраженную регулярную компоненту, на которую накладываются нерегулярные колебания, вызванные изменением погодных условий, в первую очередь температуры и освещенности, а также влиянием других нерегулярных факторов. Нейросетевое моделирование в полной мере учитывает сезонность и нелинейность процесса. Для адекватного описания сезонного процесса электропотребления для некоторых моделей ИНС достаточно двух полных периодов массива предыстории. На основе анализа данных был сделан вывод, что электропотребление реагирует на изменения температуры с запаздыванием на 12 часов. Таким образом, для прогнозирования с использованием погодных условий прогноз температуры окружающего воздуха на следующие 12 часов не требуется, что позволяет повысить точность прогнозирования электропотребления. Прогнозирование электропотребления с помощью ИНС дает хорошие результаты [9].

Фрагмент ретроспективных данных Ростовской энергосбытовой компании о потребляемой электроэнергии ЭП, представлен в табл. 1.

Таблица 1

**Ретроспективные данные об электропотреблении в Ростовской области**

Дата	Час суток	Ср. температура	Потребление энергии (Активная)	Потребление энергии (Реактивная)
9/1/2018	1	2.8 С	2095,91	569,56
	2		2062,43	540,85
	3		2029,15	582,20

При создании обучающей выборки входные сигналы нейронной сети представляются параметрами  $t$ ,  $T_n$ ,  $V1_{ээ}$ ,  $N$ ,  $T_{ср}$ ,  $h$ . Фрагмент обучающей выборки данных об ЭП Ростовской энергосбытовой компании показан в табл. 2.

Таблица 2

**Фрагмент обучающей выборки нейросети**

Дата	Входы нейросети						Выходы нейросети		
	$t$	$T_n$	$V1$		$N$	$T_{ср}$	$h$	$V2$	
9/01/2018	1	2.55	1938,84	504,10	9	2.8	1	1908,14	496,12
	2	2.55	1908,14	496,12				1875,52	487,63
	3	2.55	1875,52	487,63				1813,05	471,39
	4	2.55	1813,05	471,39				1859,34	483,43
	5	2.55	1859,34	483,43				1907,25	495,89

Фрагмент общей базы данных обучающей выборки нейросети представлен в табл. 3.

День	Месяц	Год	P	Q	час	Тариф	Температура	Тип
9,00	1,0	2018	1908,14	496,12	2,0	2,55	0,0	1,0
9,00	1,0	2018	1875,52	487,63	3,0	2,55	-1,0	1,0
9,00	1,0	2018	1813,05	471,39	4,0	2,55	-1,0	1,0

9,00	1,0	2018	1859,34	483,43	5,0	2,55	0,0	1,0
9,00	1,0	2018	1907,25	495,89	6,0	2,55	1,0	1,0
9,00	1,0	2018	2056,75	534,76	7,0	5,53	1,5	1,0
9,00	1,0	2018	2207,18	573,87	8,0	5,53	2,0	1,0

**Результаты исследований.** Прогнозирование электропотребления осуществлялось при длине интервала предыстории 30 суток, так как опытным путем было установлено, что для этих интервалов характерны меньшие ошибки прогнозных оценок. На рис. 1, 2 представлен месячный ряд почасовых значений потребляемой электрической энергии энергосистемы (счетчик AP-202 – аэропорт) Краснодарского края в весенний период, на котором видна суточная периодичность электропотребления и заметна характерная особенность месячного цикла – снижение потребления электрической энергии в выходные дни. Выбор функции масштабирования зависит сугубо от начальных зависимостей в данных. Все входные параметры необходимо нормализовать на отрезке значений от 0 до 1. Нормализация достигается за счет деления каждой компоненты входного вектора на длину самого вектора. Длина вектора находится извлечением квадратного корня из суммы квадратов всех компонент вектора:

$$X_i^x = \frac{X_i}{\sqrt{x_1^2 + x_2^2 + \dots + x_n^2}}$$

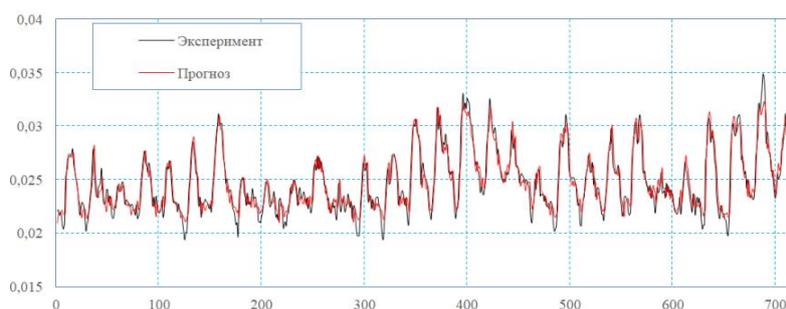


Рис. 1. Фактическое и прогнозируемые значения потребляемой активной мощности AP-202 за май 2019 г.

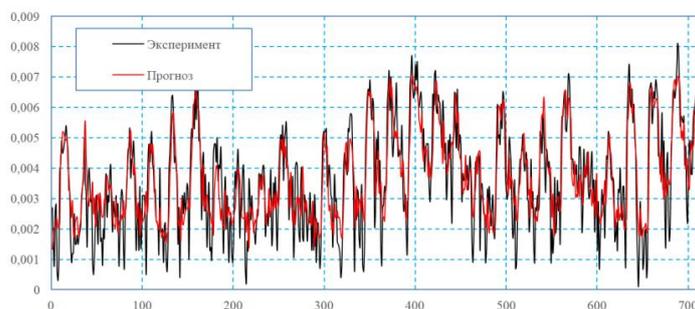


Рис. 2. Фактическое и прогнозируемые значения потребляемой реактивной мощности AP-202 за май 2019 г.

Цель процесса обучения заключается в нахождении оптимальных значений весовых коэффициентов, при которых нейронная сеть выдаёт значение в пределах заданной погрешности для всех обучающих выборок. Для реализации нейронносетевых концепций разработано большое количество специализированных программных средств. Пакет фирмы «The MathWorks» MATLAB также предоставляет пользователям возможность работы с нейронными сетями. Использование «Neural Network Toolbox» совместно с другими средствами MATLAB открывает широкий простор для эффективного комплексного использования современных математических методов для решения самых разных задач прикладного и научного характера [10]. Для построения нейронной сети использовался встроенный функционал Matlab.

Анализ данных показал, что форма графиков носит циклический характер, электропотребление обладает сезонностью. Одной из циклических составляющих графика потребления является суточный цикл. Вечерний максимум суточных графиков нагрузки выше утреннего. Выходные дни характеризуются более медленным нарастанием нагрузки в дневной части суток по сравнению с рабочими днями.

Погрешность			
Активная мощность		Реактивная мощность	
Ср. значение %	3.2 %	Ср. значение %	12.3 %
Макс. значение %	17.1 %	Макс. значение %	21.4 %

На рис. 3, 4 представлен недельный ряд почасовых значений потребляемой электрической энергии энергосистемы (счетчик AP-103) Краснодарского края в весенний период.

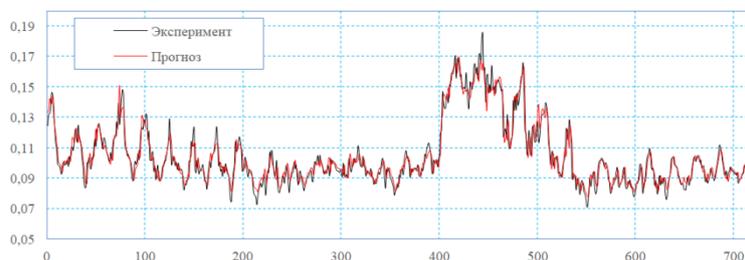


Рис. 3. Фактическое и прогнозируемые значения потребляемой активной мощности AP-103 за апрель 2019 г.

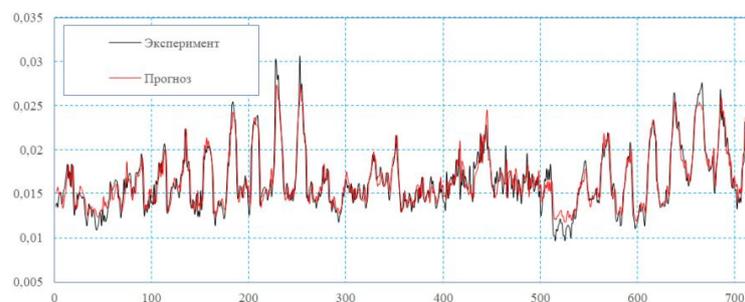


Рис. 4. Фактическое и прогнозируемые значения потребляемой реактивной мощности AP-103 за апрель 2019 г.

Погрешность			
Активная мощность		Реактивная мощность	
Ср. значение %	4.08 %	Ср. значение %	6.64 %
Макс. значение %	16.51 %	Макс. значение %	27.56 %

На рис. 5, 6 представлен недельный ряд почасовых значений потребляемой электрической энергии энергосистемы (счетчик AP-103) Краснодарского края в весенний период

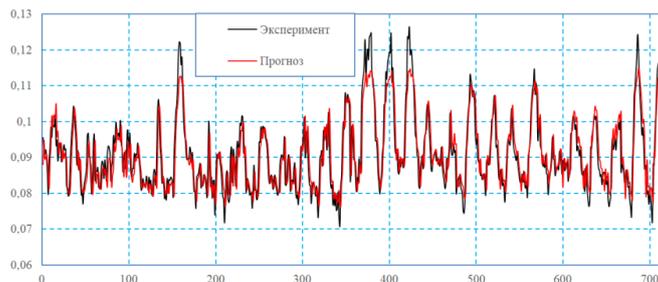


Рис. 5. Фактическое и прогнозируемые значения потребляемой активной мощности AP-103 за май 2019 г.

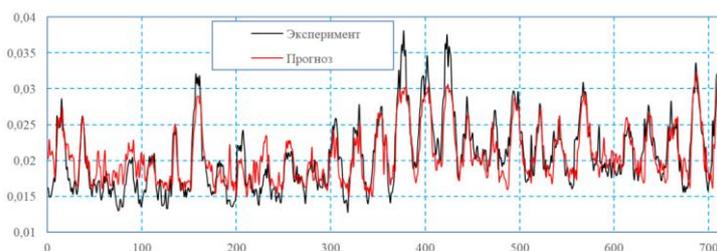


Рис. 6. Фактическое и прогнозируемые значения потребляемой реактивной мощности AP-103 за май 2019 г.

Погрешность			
Активная мощность		Реактивная мощность	
Ср. значение %	4.15 %	Ср. значение %	10.21 %
Макс. значение %	18.11 %	Макс. значение %	34.47 %

#### Заключение:

1. Разработанная НС математическая модель сводит задачу краткосрочного прогнозирования электропотребления к поиску матрицы свободных коэффициентов посредством обучения на имеющихся статистических данных.

2. Получена НС модель краткосрочного прогнозирования электропотребления аэропорта участка районной электрической сети 10 кВ, учитывающая факторы: – времени, – метеорологических условий, – отключений отдельных питающих линий электропередач, – режима работы потребителей электроэнергии.

3. Получены прогнозные оценки электропотребления энергосистемы по данным потребляемой электроэнергии наружной температуры, типу дня и т.д. Модель прогнозирования величины, потребляемой активной и реактивной мощности вполне работоспособна, однако на данном этапе все еще имеет довольно высокий уровень погрешности прогнозирования.

4. Для повышения точности прогнозирования необходимо увеличить базу данных, составляющих обучающую выборку, т.к. на данный момент имеющиеся данные охватывают временной промежуток длиной лишь 3-4 месяца.

5. Из полученных результатов можно заметить, что наибольшие трудности вызывает прогнозирование потребления реактивной мощности.

6. Влияние температуры на электропотребление. Известно, что электропотребление растет в холодные и жаркие дни. Однако при краткосрочном прогнозировании (сутки вперед) учет температуры не приводит к улучшению точности прогноза.

#### БИБЛИОГРАФИЧЕСКИЙ СПИСОК:

1. Об электроэнергетике: Федеральный закон РФ от 26.03.2003 № 35-ФЗ // Российская газета. – 1 апр. 2003. – С. 1.
2. Рудаков Е., Саакян Ю., Нигматулин Б., Прохорова Н. Цена расточительности // Эксперт. – № 24 / июня 2008.
3. Серебряков Н.А., Хомутов С.О. Анализ случайной составляющей временного ряда электрической нагрузки группы точек поставки электроэнергии сельхозпроизводителей // Вестник Алтайского государственного аграрного университета. – 2019. – № 5 (175). – С. 153-158.
4. Планирование электроэнергетических режимов работы энергообъектов и энергосистем // Сайт АО «Системный оператор Единой энергетической системы». – URL: [http://so-ups.ru/index.php?id=regime\\_plan](http://so-ups.ru/index.php?id=regime_plan) (14.06.2016).
5. Dubyago M., Polyuyanovich N., Azarov N., Ogrenichev A. Development and research of the forecasting methods of the cable lines throughput using artificial neural networks // Proceedings – ICOECS 2020: 2020 International Conference on Electrotechnical Complexes and Systems. – 2020. – P. 9278503.
6. Доманов В.И., Билалова А.И. Прогнозирование объемов энергопотребления в зависимости от исходной информации // Вестник ЮУрГУ. Серия «Энергетика». – 2016. – Т. 16, № 2. – С. 59-65.
7. Полуянович Н.К., Азаров Н.В., Огреничев А.В., Дубяго М.Н. Многоэтапный метод краткосрочного прогнозирования температурных режимов в силовом кабеле // Известия ЮФУ. Технические науки. – 2020. – № 2 (212). – С. 38-51.
8. Полуянович Н.К., Дубяго М.Н. Анализ и выбор методики в решении задач интеллектуализации систем прогнозирования термофлуктуационных процессов в кабельных сетях // Известия ЮФУ. Технические науки. – 2020. – № 2 (212). – С. 52-66.
9. Zheng H., Yuan J., Chen L. Short-term load forecasting using EMD-LSTM neural networks with a XGBOOST algorithm for feature importance evaluation // Energies. – 2017; 10:1-20. – DOI: 10.3390/en10081168.
10. Шарифуллин В.Н., Шарифуллина А.В. Нейросетевое прогнозирование потребления электроэнергии промышленным предприятием // Вестник Казанского государственного энергетического университета. – 2012. – № 2 (13). – С. 6-11.
11. Доманов В.И., Билалова А.И. Анализ прогнозирования энергопотребления с различными информационными базами // Известия Самарского научного центра Российской академии наук. – 2014. – Т. 16, № 4-3. – С. 535-537.
12. Киртичникова И.М., Саплин Л.А., Соломахо К.Л. Прогнозирование объемов потребления электроэнергии // Вестник Южно-Уральского государственного университета. Серия: Энергетика. – 2014. – Т. 14, № 2. – С. 16-22.
13. Варфоломеева А.А. Локальные методы прогнозирования с выбором метрики // Машинное обучение и анализ данных. – 2012. – Т. 1, № 3. – С. 367-375.
14. Сунагатов И.М. Анализ и модификация метода прогнозирования энергопотребления с помощью экстраполяции выборки максимального подобия // Вестник Самарского государственного технического университета. Серия: Технические науки. – 2013. – № 1 (37). – С. 223-226.
15. Хайкин С. Нейронные сети: полный курс. – 2-изд.: пер. с англ. – М.: Издательский дом «Вильямс», 2006. – 1104 с.

16. *Полуянович Н.К., Дубяго М.Н.* Прогнозирование ресурса кабельных линий с использованием метода искусственных нейронных сетей // Известия ЮФУ. Технические науки. – 2019. – № 3 (205). – С. 51-62.
17. *Полуянович Н.К., Дубяго М.Н., Азаров Н.В., Огреничев А.В.* Нейросетевой метод в задачах прогнозирования электропотребления в электроэнергетической системе // Математические методы в технологиях и технике. – 2022. – № 1. – С. 114-118.
18. *Кулбараков М.А.* К задаче прогнозирования энергопотребления с помощью нейронных сетей // Молодой ученый. – 2014. – № 11 (70). – С. 22-25. – URL: <https://moluch.ru/archive/70/12122/> (дата обращения: 05.12.2021).
19. *Poluyanovich N.K., Burkov D.V., Dubyago M.N., Shurykin A.A., Kosenko E.Y.* The influence of the electromagnetic field on the neural network monitoring of insulation materials for electric cable networks // International Conference on Electrical, Computer, Communications and Mechatronics Engineering, ICECCME 2021. – 2021. – P. 9590839.
20. *Пилюхов В.Х., Гайдук А.Р., Медведев М.Ю., Беляев В.Е., Полуянович Н.К., Волощенко Ю.П.* Энергосберегающее управление тяговыми приводами электроподвижного состава // Известия ЮФУ. Технические науки. – 2013. – № 2 (139). – С. 192-200.
21. *Полуянович Н.К., Тибейко И.А.* Эксплуатация и ремонт систем электроснабжения промышленных предприятий. – Таганрог, 2014.
22. *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.

## REFERENCE

1. Ob elektroenergetike: Federal'nyy zakon RF ot 26.03.2003 № 35-F3 [About the electric power industry: Federal Law of the Russian Federation No. 35-F3 of 26.03.2003], *Rossiyskaya Gazeta* [Russian newspaper], 1 Apr. 2003, pp. 1.
2. *Rudakov E., Saakyan Yu., Nigmatulin B., Prokhorova N.* Tsena rastochitel'nosti [The price of wastefulness], *Ekspert* [Expert], No. 24 / June iyunya 2008.
3. *Serebryakov N.A., Khomutov S.O.* Analiz sluchaynoy sostavlyayushchey vremennogo ryada elektricheskoy nagruzki gruppy toчек postavki elektroenergii sel'khozproizvoditeley [Analysis of the random component of the time series of the electric load of the group of points of electricity supply of agricultural producers], *Vestnik Altayskogo gosudarstvennogo agrarnogo universiteta* [Bulletin of the Altai State Agrarian University], 2019, No. 5 (175), pp. 153 -158.
4. Planirovanie elektroenergeticheskikh rezhimov raboty energoob"ektov i energosistem [Planning of electric power modes of operation of power facilities and power systems], *Sayt AO «Sistemnyy operator Edinoy energeticheskoy sistemy»* [Website of JSC "System Operator of the Unified Energy System"]. Available at: [http://so-ups.ru/index.php?id=regime\\_plan](http://so-ups.ru/index.php?id=regime_plan) (14.06.2016).
5. *Dubyago M., Polyuyanovich N., Azarov N., Ogrenichev A.* Development and research of the forecasting methods of the cable lines throughput using artificial neural networks, *Proceedings – ICOECS 2020: 2020 International Conference on Electrotechnical Complexes and Systems*, 2020, pp. 9278503.
6. *Domanov V.I., Bilalova A.I.* Prognozirovaniye ob"emov energopotrebleniya v zavisimosti ot iskhodnoy informatsii [Forecasting the volume of energy consumption depending on the initial information], *Vestnik YuUrGU. Seriya «Energetika»* [Bulletin of SUSU. The series "Energy"], 2016, Vol. 16, No. 2, pp. 59-65.
7. *Poluyanovich N.K., Azarov N.V., Ogrenichev A.V., Dubyago M.N.* Mnogoetapnyy metod kratkosrochnogo prognozirovaniya temperaturnykh rezhimov v silovom kabele [Multi-stage method of short-term forecasting of temperature regimes in a power cable], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2020, No. 2 (212), pp. 38-51.
8. *Poluyanovich N.K., Dubyago M.N.* Analiz i vybor metodiki v reshenii zadach intellektualizatsii sistem prognozirovaniya termoflukuatsionnykh protsessov v kabel'nykh setyakh [Analysis and choice of methodology in solving problems of intellectualization of forecasting systems of thermal fluctuation processes in cable networks], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2020, No. 2 (212), pp. 52-66.

9. Zheng H., Yuan J., Chen L. Short-term load forecasting using EMD-LSTM neural networks with a XGBOOST algorithm for feature importance evaluation, *Energies*, 2017; 10:1-20. DOI: 10.3390/en10081168.
10. Sharifullin V.N., Sharifullina A.V. Neyrosetevoye prognozirovanie potrebleniya elektroenergii promyshlennym predpriyatiem [Neural network forecasting of electricity consumption by an industrial enterprise], *Vestnik Kazanskogo gosudarstvennogo energeticheskogo universiteta* [Bulletin of the Kazan State Energy University], 2012, No. 2 (13), pp. 6-11.
11. Domanov V.I., Bilalova A.I. Analiz prognozirovaniya energopotrebleniya s razlichnymi informatsionnymi bazami [Analysis of energy consumption forecasting with various information bases], *Izvestiya Samarskogo nauchnogo tsentra Rossiyskoy akademii nauk* [Izvestiya Samara Scientific Center of the Russian Academy of Sciences], 2014, Vol. 16, No. 4-3, pp. 535-537.
12. Kirpichnikova I.M., Saplin L.A., Solomakho K.L. Prognozirovanie ob'emov potrebleniya elektroenergii [Forecasting the volume of electricity consumption], *Vestnik YUzhno-Ural'skogo gosudarstvennogo universiteta. Seriya: Energetika* [Bulletin of the South Ural State University. Series: Energy], 2014, Vol. 14, No. 2, pp. 16-22.
13. Varfolomeeva A.A. Lokal'nye metody prognozirovaniya s vyborom metriki [Local forecasting methods with a choice of metrics], *Mashinnoe obuchenie i analiz dannykh* [Machine learning and data analysis], 2012, Vol. 1, No. 3, pp. 367-375.
14. Sunagatov I.M. Analiz i modifikatsiya metoda prognozirovaniya energopotrebleniya s pomoshch'yu ekstrapolyatsii vyborki maksimal'nogo podobiya [Analysis and modification of the method of forecasting energy consumption using the extrapolation of the maximum similarity sample], *Vestnik Samarskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Tekhnicheskie nauki* [Bulletin of the Samara State Technical University. Series: Technical Sciences], 2013, No. 1 (37), pp. 223-226.
15. Khaykin S. Neyronnye seti: polnyy kurs [Neural networks: a complete course]. 2nd. ed.: transl. from engl. Moscow: Izdatel'skiy dom «Vil'yams», 2006, 1104 p.
16. Poluyanovich N.K., Dubyago M.N. Prognozirovanie resursa kabel'nykh liniy s ispol'zovaniem metoda iskusstvennykh neyronnykh setey [Forecasting the resource of cable lines using the method of artificial neural networks], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2019, No. 3 (205), pp. 51-62.
17. Poluyanovich N.K., Dubyago M.N., Azarov N.V., Ogrenichev A.V. Neyrosetevoy metod v zada-chakh prognozirovaniya elektropotrebleniya v elektroenergeticheskoy sisteme [Neural network method in the tasks of forecasting electricity consumption in the electric power system], *Matematicheskie metody v tekhnologiyakh i tekhnike* [Mathematical methods in technology and engineering], 2022, No. 1, pp. 114-118.
18. Kulbarakov M.A. K zadache prognozirovaniya energopotrebleniya s pomoshch'yu neyronnykh setey [On the problem of forecasting energy consumption using neural networks], *Molodoy uchenyy* [Young scientist], 2014, No. 11 (70), pp. 22-25. Available at: <https://moluch.ru/archive/70/12122/> (accessed: 05 December 2021).
19. Poluyanovich N.K., Burkov D.V., Dubyago M.N., Shurykin A.A., Kosenko E.Y. The influence of the electromagnetic field on the neural network monitoring of insulation materials for electric cable networks, *International Conference on Electrical, Computer, Communications and Mechatronics Engineering, ICECCME 2021*, 2021, pp. 9590839.
20. Pshikhopov V.Kh., Gayduk A.R., Medvedev M.Yu., Belyaev V.E., Poluyanovich N.K., Voloshchenko Yu.P. Energoberegayushchee upravlenie tyagovymi privodami elektropodvizhnogo sostava [Energy-saving control of traction drives of electric rolling stock], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2013, No. 2 (139), pp. 192-200.
21. Poluyanovich N.K., Tibeyko I.A. Ekspluatatsiya i remont sistem elektrosnabzheniya promyshlennykh predpriyatiy [Operation and repair of power supply systems of industrial enterprises]. Taganrog, 2014.
22. 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 insulation materials of power supply systems: monograph]. Rostov-on-Don; Taganrog: Izd-vo YuFU, 2019, 192 p.

Статью рекомендовала к опубликованию к.т.н., доцент М.Г. Левина.

**Полуянович Николай Константинович** – Южный федеральный университет; e-mail: nik1-58@mail.ru; г. Таганрог, Россия; тел.: 89185693365; кафедра электротехники и мехатроники.

**Дубяго Марина Николаевна** – e-mail: w\_m88@mail.ru; тел.: 89281758225; кафедра электротехники и мехатроники; аспирант.

**Poluyanovich Nikolay Konstantinovich** – Southern Federal University; e-mail: w\_m88@mail.ru; Taganrog, Russia; phone: +79185693365; the department of electric technics and mechatronics.

**Dubyago Marina Nikolaevna** – e-mail: w\_m88@mail.ru; phone: +79281758225; the department of electrical engineering and mechatronics; graduate student.

УДК 621.372.83.001.24

DOI 10.18522/2311-3103-2022-2-46-56

**В.С. Мараев**

### **АВТОМАТИЗАЦИЯ МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ ТЕХНОЛОГИЧЕСКОГО ПРОЦЕССА ИНДУКЦИОННОЙ ПАЙКИ**

*Работа посвящена исследованию и автоматизации математического моделирования процесса нагрева элементов тонкостенного алюминиевого волноводного тракта при отработке технологической процедуры индукционной пайки. В статье проводится обзор метода математического моделирования технологического процесса индукционной пайки. В качестве математической модели нагрева волноводного тракта с целью отработки технологического процесса индукционной пайки используется мгновенный источник нагрева в плоском стержне. В рамках данной работы была спроектирована и реализована функциональная автоматизированная подсистема математического моделирования технологического процесса индукционной пайки тонкостенных металлических волноводов космических летательных аппаратов. Функционал приложения позволяет производить автоматизированное построение математической модели технологического процесса индукционной пайки с заданными параметрами, выполняя расчёты температурных значений деталей-компонентов участвующих в процессе индукционной пайки в зависимости от заданных типоразмеров, структурных-физических и термодинамических характеристик, мощности индуктора и положения фланца/муфты относительно индуктора. Полученный программный продукт является оптимальным решением для интеграции с системой, производящей управление технологическим процессом индукционной пайки волноводных трактов космических аппаратов в качестве генератора математических моделей процесса индукционной пайки для обучения алгоритма. Проведены сравнительные исследования моделей индукционной пайки волноводных трактов, которые строит математический модуль программы на предмет их соответствия реальному процессу в допустимых пределах. Эксперименты проводились на программно-аппаратном комплексе по управлению процессом индукционной пайки волноводных трактов, включающего генератор индукционного нагрева, индуктор, манипулятор-позиционер, промышленный компьютер IPPC-9171G-07BTO с консолью управления. Выполнена экспериментальная проверка корректности выбранной математической модели технологического процесса индукционной пайки и правильности её реализации в разработанном программном приложении. Рассчитаны значения среднеквадратичных отклонений результатов моделирования и реальных технологических процессов индукционной пайки волноводных трактов. В результате натурных и модельных экспериментов установлено, что реализованные приложением модели индукционного нагрева элементов сборки тонкостенных алюминиевых волноводных трактов космических летательных аппаратов с достаточной высокой степенью точности моделируют данный технологический процесс.*

*Волноводный тракт; индукционная пайка; моделирование процесса; разработка приложения; математическая модель; автоматизация процесса; верификация модели; автоматизированное управление.*