

Самех Али КАССЕМ<sup>1</sup>  
Абдулла Хайдар Абдо ИБРАГИМ<sup>2</sup>  
Абдулла Мохаммед ХАСАН<sup>3</sup>  
Алла Григорьевна ЛОГАЧЕВА<sup>4</sup>

УДК 519.6, 004.421

## ПРОГНОЗИРОВАНИЕ ЭЛЕКТРОПОТРЕБЛЕНИЯ ПРЕДПРИЯТИЯ С ПРИМЕНЕНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

- <sup>1</sup> аспирант кафедры приборостроения и мехатроники,  
Институт цифровых технологий и экономики,  
Казанский государственный энергетический университет  
ali20105@mail.ru; ORCID: 0000-0002-4587-6730
- <sup>2</sup> аспирант кафедры прикладной и технической физики,  
Физико-технический институт,  
Тюменский государственный университет  
abdulla.ybragim@mail.ru; ORCID: 0000-0002-1709-9882
- <sup>3</sup> аспирант факультета информатики и вычислительной техники,  
Институт информационных технологий и интеллектуальных систем,  
Казанский федеральный университет  
alii.hasaa@gmail.com; ORCID: 0000-0002-1988-8869
- <sup>4</sup> кандидат технических наук,  
доцент кафедры электроснабжения промышленных предприятий,  
Институт электроэнергетики и электроники,  
Казанский государственный энергетический университет  
logacheva.alla@yandex.ru; ORCID: 0000-0002-0371-7985

### Аннотация

За последнее столетие потребление энергии резко возросло из-за многих факторов: технологических, социальных, экономических. Поэтому прогнозирование энергопотребления

---

**Цитирование:** Кассем С. А. Прогнозирование электропотребления предприятия с применением искусственных нейронных сетей / С. А. Кассем, А. Х. А. Ибрагим, А. М. Хасан, А. Г. Логачева // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2021. Том 7. № 1 (25). С. 177-193.  
DOI: 10.21684/2411-7978-2021-7-1-177-193

---

имеет большое значение для множества процессов, включая планирование работы генерирующего оборудования, управление и оптимизацию режимов работы энергетических систем, а также сохранение энергетических ресурсов. За последние несколько десятилетий модели на основе данных для прогнозирования энергопотребления значительно улучшились благодаря их повышенной производительности, надежности и простоте развертывания. На сегодняшний день среди множества различных типов моделей искусственные нейронные сети входят в число наиболее популярных подходов на основе данных. В этой статье рассмотрена возможность применения искусственных нейронных сетей для среднесрочного прогнозирования электропотребления предприятия. Реализована задача построения искусственной нейронной сети с использованием алгоритма с обратной связью для обучения сети на базе математического пакета MATLAB. Нами были проанализированы такие характеристики, как настройка параметров, сложность реализации, скорость обучения, сходимость результата, точность прогнозирования и стабильность результата. Полученные результаты позволили сделать вывод, что алгоритм с обратной связью хорошо подходит для среднесрочного прогнозирования электропотребления.

#### **Ключевые слова**

Искусственные нейронные сети, алгоритм обучения, прогнозирование электропотребления, обратное распространение ошибки, среднеквадратичная ошибка, активационная функция.

**DOI: 10.21684/2411-7978-2021-7-1-177-193**

#### **Введение**

В последние годы прогнозирование электропотребления стало одним из основных направлений исследований в электроэнергетике. Оно играет важную роль в планировании режимов и эксплуатации энергосистемы. При управлении энергетическим оборудованием стоят основные задачи, такие как подача заявок на включение оборудования и предоставления резерва мощности в условиях работы.

Планирование расхода топлива и технического обслуживания агрегата в рамках эксплуатации генерирующего оборудования могут выполняться достаточно эффективно при наличии точного прогноза [1]. В масштабах энергосистемы в текущих рыночных условиях точность прогнозирования потребления влияет на решение задачи экономической диспетчеризации и повышения благосостояния всех участников рынка. Прогнозирование величины и объемов электропотребления также актуально для промышленных предприятий. Для этого имеются как технические, так и экономические предпосылки. С одной стороны, сегодня в России у потребителей появляется все больше возможностей оптимизировать свое электропотребление и получать экономическую выгоду. Например, предприятия могут участвовать в механизме ценозависимого потребления или снижать счет за электроэнергию и мощность путем подстройки графика нагрузки под уровень равновесных цен и пиковых часов энергосистемы. С другой стороны, развитие техники позволяет создавать высоко автоматизированные системы с применением систем хранения

энергии. Такие системы позволяют снижать потери в сетях и электрооборудовании предприятий при оптимальном планировании режима. Прогнозирование электропотребления требуется для успешной реализации данных возможностей. И чем выше его точность, тем больше экономическая и техническая выгода для предприятия. Следовательно, развитие и применение методов и алгоритмов прогнозирования электропотребления повышенной точности особенно важно в текущих условиях. Среди методов прогнозирования выделяют классические и интеллектуальные. К классическим методам относятся регрессионные, авторегрессионные и вероятностные методы. К интеллектуальным — экспертные системы, искусственные нейронные сети, клеточные автоматы, хаотические процессы и т. п.

Сейчас много промышленных предприятий делают прогнозы по электропотреблению методом оценок экспертами. Но этот метод не всегда точен и не отвечает требованиям ситуации. Средняя квадратичная ошибка прогнозирования с помощью этого метода достаточно большая: 11,37 [9] и 15,77% [6].

При этом благодаря тренду автоматизации и телемеханизации систем электроснабжения их наблюдаемость повышается. В распоряжении специалистов появляется большой объем данных, которые могут быть использованы в режиме реального времени [2].

В общем, прогнозирование электропотребления в зависимости от временного периода, на который составляется прогноз, можно разделить на следующие виды: краткосрочное, среднесрочное и долгосрочное [4]. Краткосрочное прогнозирование обычно подразумевает составление прогноза на один или несколько часов (в некоторых случаях период может быть увеличен до недели). Среднесрочное прогнозирование электропотребления осуществляется на период от одной недели до одного года. Долгосрочное прогнозирование делается на срок более одного года. Каждый вид имеет важное значение в экономической и технической сфере, а именно — в надежной эксплуатации электрических сетей и систем электроснабжения. Сегодня особенно часто для прогнозирования каких-либо параметров используются искусственные нейронные сети (ИНС), которые состоят из большого количества взаимосвязанных нейронов. Это своего рода управляемая модель нелинейного отображения, созданная по подобию биологической нейронной сети. В целом искусственная нейронная сеть позволяет моделировать и предсказывать результаты какой-либо задачи путем обучения на заданном количестве примеров [3-5].

Математическая модель нейрона описывается двумя уравнениями:

$$u_k = \sum_{j=1}^m \omega_{kj} x_j, \quad (1)$$

$$y_k = \varphi(u_k + b_k), \quad (2)$$

где  $u_k$  — линейная комбинация входных воздействий,  $\omega_{kj}$  — синоптические веса нейрона,  $x_j$  — входные сигналы,  $\varphi(u_k + b_k)$  — функция активации,  $y_k$  — выходной сигнал нейрона,  $m$  — количество нейронов во входном слое.

Функция  $\varphi(v)$  является кусочно-линейной и определяется следующими выражениями:

$$\varphi(v) = \{1, v \geq +0,5; |v|, 0,5 > v > -0,5; 0, v \leq -0,5. \quad (3)$$

Чтобы создать искусственную нейронную сеть, используется сигмоидная функция. Это быстрорастущая функция, которая поддерживает баланс между нелинейными и линейными курсами. Примером сигмоидной функции является логистическая функция, определяемая выражением:

$$\varphi(v) = \frac{1}{1 + e^{-\alpha v}}, \quad (4)$$

где  $\alpha$  — параметр наклона сигмоидальной функции,  $e$  — сигнал ошибки (error signal),  $v$  — индуцированная локальная поля.

Для реализации метода прогнозирования нейронной сети необходимо выбрать программное обеспечение, на основе которого будет строиться ИНС, а также определить такие параметры нейронной сети, как архитектура, метод обучения и т. д. Кроме того, важным компонентом в реализации данного метода прогнозирования электропотребления является наличие набора данных для обучения сети, а также набора данных для анализа точности прогнозирования [3, 7].

Перечисленные выше задачи могут быть решены по-разному. Далее рассмотрим выбранный нами набор параметров для реализации нейронной сети.

## Методы

### *Выбор архитектуры нейронной сети*

Архитектура нейронной сети построена на основе структуры и функциях биологической нейронной сети. Подобно нейронам в головном мозге, ИНС также состоит из нейронов, расположенных в различных слоях. Нейронная сеть прямого распространения — это популярная нейронная сеть, которая состоит из нескольких слоев: входного слоя для приема внешних данных для распознавания образов, выходного слоя, который дает решение проблемы, и скрытого слоя — промежуточного слоя, который разделяет другие слои. Соседние нейроны от входного слоя к выходному слою соединены ациклическими дугами. ИНС использует алгоритм обучения для изучения наборов данных, который изменяет вес нейронов в зависимости от частоты ошибок между целевым и фактическим выходными данными. Как правило, для обучения ИНС использует алгоритм обратного распространения ошибки с использованием предварительно размеченных наборов данных.

Для получения точного прогноза энергопотребления необходимо определить входные переменные и структуру сети, обеспечивающую приемлемую точность прогноза и время обучения сети [3, 8]. На первом этапе исследования сеть обратной связи использовалась для прогнозирования энергопотребления. На рис. 1 показана схема этой сети.

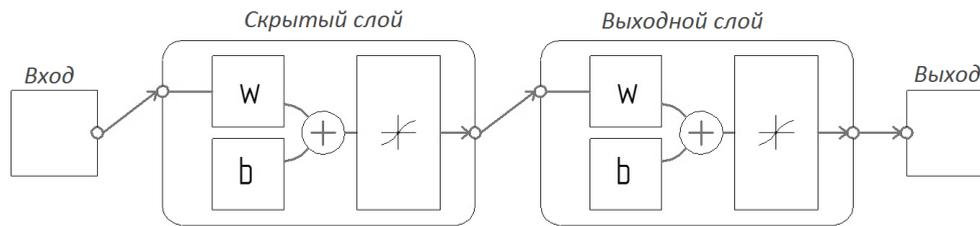


Рис. 1. Схема ИНС прямого распространения данных и обратного распространения ошибки (feed-forward backprop)

Fig. 1. ANN scheme of data forward propagation and error backpropagation (feed-forward backprop)

#### Выбор алгоритма обучения нейронной сети

На сегодняшний день не существует установленного стандартизованного метода выбора архитектуры ИНС, близкой к оптимальной. Проект оптимальной архитектуры ИНС можно сформулировать как задачу поиска. Для выбора подходящей архитектуры нейронной сети обычно используются четыре основных подхода: эвристика, каскад-корреляция, эволюционный алгоритм (ЕА) и новый подход, автоматизированный подход.

Алгоритм обратного распространения ошибки (ВР) для обучения нейронных сетей с прямой связью оказался надежным даже для сложных задач. Однако его высокие результаты достигаются за счет длительного времени обучения для настройки параметров сети, что может негативно сказаться во многих реальных приложениях. Даже в относительно простых задачах стандартный ВР часто требует длительного процесса обучения, в котором полный набор обучающих примеров обрабатывается десятки, сотни или тысячи раз. Обработка, например, 40 тренировочных циклов происходит за 0,001 с [15].

Далее представлен универсальный метод ускорения для алгоритма ВР, основанный на экстраполяции веса каждого отдельного соединения. Эту процедуру экстраполяции легко реализовать, и она активируется только несколько раз между итерациями обычного алгоритма ВР. Эта процедура, в отличие от более ранних процедур ускорения, минимально изменяет вычислительную структуру алгоритма ВР. Жизнеспособность этого нового подхода продемонстрирована на трех примерах. Результаты показывают, что это приводит к значительной экономии времени вычисления стандартного алгоритма ВР. Более того, решение, вычисленное с помощью предлагаемого подхода, всегда находится в непосредственной близости от решения, полученного с помощью традиционной процедуры ВР, следовательно, предлагаемый метод обеспечивает реальное ускорение алгоритма ВР без снижения полезности его решений. Производительность нового метода также сравнивается с производительностью алгоритма сопряженного градиента, который является улучшенной и более быстрой версией алгоритма ВР. Алгоритм предполагает два прохода через все уровни сети: прямой и обратный [9]. Принципиальная схема алгоритма обратного распространения представлена на рис. 2.

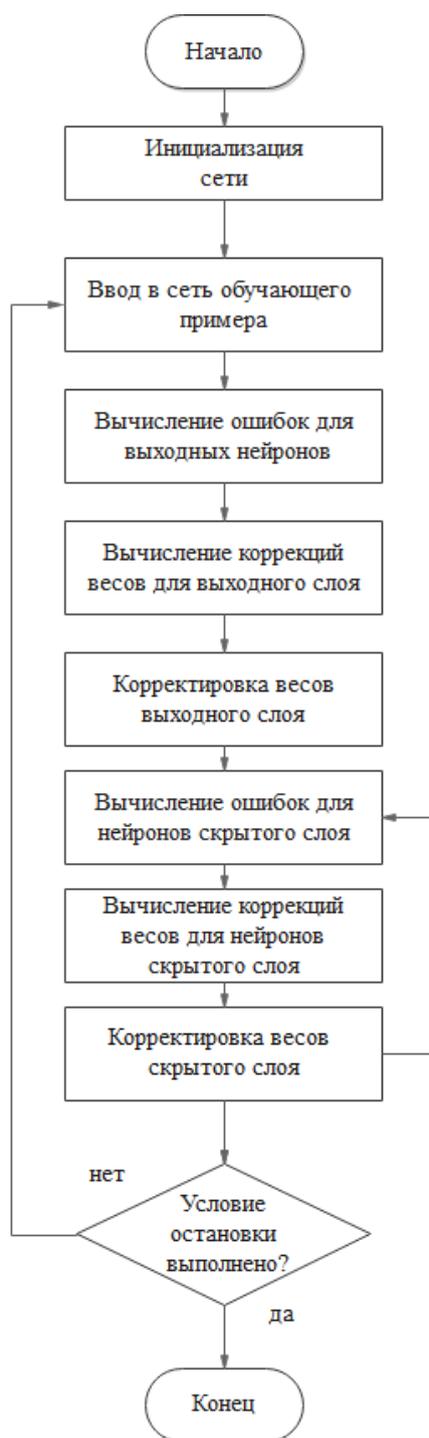


Рис. 2. Принципиальная схема алгоритма обратного распространения

Fig. 2. A schematic diagram of the backpropagation algorithm

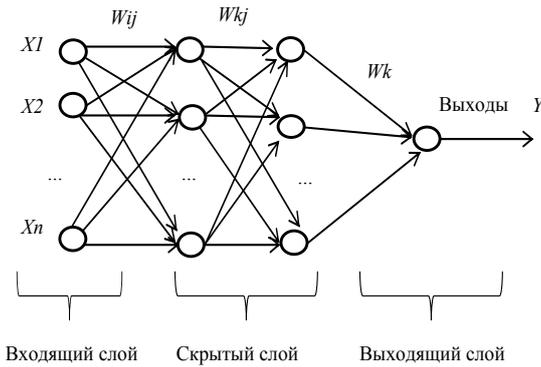


Рис. 3. Вид нейросети с реализацией метода обратного распространения ошибки

Fig 3. The view of the backpropagation neural network

В нашей работе обучение сети происходит по алгоритму обратного распространения ошибки (“error backpropagation”), сама нейронная сеть была создана с использованием программного пакета MATLAB [7, 8, 9].

На рис. 3 показан вид нейросети с реализацией метода обратного распространения ошибки.

Выходной сигнал нейронной сети определяется функцией

$$Y_t = W_0 + \sum_{j=1}^n W_j F\left(\sum_{i=1}^m W_{ij} Y_{t-1} + W_{0j}\right) + \delta_t, \quad (5)$$

где  $m$  — число нейронов во входном слое,  $n$  — число скрытых слоев,  $Y_t$  — выходной сигнал,  $W_0, W_j$  — вес 0-го нейрона и  $j$ -го нейрона,  $W_{0j}$  — вес связи между 0- и  $j$ -нейронами,  $F$  — вектор матрицы  $f$ ;  $\delta_t$  — ошибка, определяемая разницей между желаемым и реальным выходными значениями сигнала.

*Обучение нейронной сети*

Задача обучения нейронной сети — это баланс между изучением набора обучающих данных и обобщением на новые примеры за пределами набора обучающих данных [10].

Имеются восемь специальных приемов, которые можно использовать для более быстрого обучения качественных моделей нейронных сетей. При обучении сети предоставляются как входы, так и выходы. Затем сеть обрабатывает входы и сравнивает полученные выходы с желаемыми выходами. Затем ошибки распространяются обратно по системе, заставляя систему корректировать вес, которые управляют сетью. В нашем случае при обучении нейронного веса входного и скрытого слоя. На рис. 4 представлен алгоритм обучения нейронной сети, на котором четко видно, что слои меняются на каждой итерации в обратном порядке.

Распространение ошибки [11] представлена следующими выражениями:

$$W_{new} = W_{old} + ERROR \cdot X, \quad (6)$$

$$ERROR = T - Y, \quad (7)$$



Рис. 4. Алгоритм обучения нейронной сети

Fig. 4. An algorithm for teaching a neural network

где  $W_{new}$  — новый вес,  $W_{old}$  — старый вес,  $\eta$  — параметр, отвечающий за скорость обучения нейросети,  $T$  — реальное и  $Y$  — желаемое значения сигнала на выходе нейросети.

Сигмоида как функция активации представлена следующим уравнением:

$$f(x) = \frac{1}{1 + e^{-x}}, \tag{8}$$

где  $e^{-x}$  — выходная ошибка сети.

Для оценки величины ошибки в нейронных сетях чаще всего применяют уравнение средней квадратичной ошибки [7]:

$$MSE = \frac{1}{N} \sum_{i=1}^N e_i^2, \tag{9}$$

где  $MSE$  (mean squared error) — среднеквадратическая ошибка прогноза,  $N$  — количество точек данных,  $e_i = y_i - t_i$ ;  $t_i$  — фактическое значение и  $y_i$  — желаемое значение сигнала на выходе первого нейрона.

### Результаты моделирования и их обсуждение

Для структуры нейронной сети методом итераций были выбраны следующие параметры [11, 12] (таблица 1).

Структура моделируемой искусственной нейронной сети представлена на рис. 5.

Из таблицы 1 следует, что метод ускорения для алгоритма ВР позволил за 0,001 с обработать 3 000 тренировочных циклов. При этом с помощью стандартного алгоритма ВР за это же время обработано всего лишь 40 циклов [15].

Таблица 1

Основные параметры структуры нейронной сети методом итераций

Доля обучающих данных	Доля тестовых данных	Скорость обучения	Число скрытых слоев	Число нейронов в скрытом слое	Максимальное количество тренировочных циклов
70%	30%	0,001	1	10	3 000

Table 1

The basic parameters of the neural network's structure by the iteration method

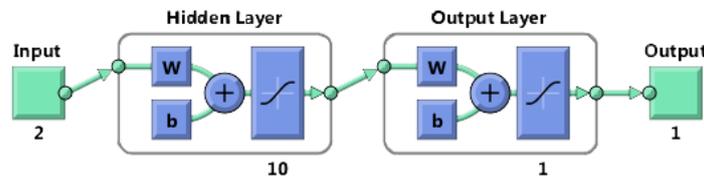


Рис. 5. Структура моделируемой искусственной нейронной сети

Fig. 5. The structure of the simulated artificial neural network

На рис. 6 показаны полученные результаты обучения и тестирования сети.

После обучения сети для проверки правильности модели был сделан прогноз энергопотребления на период с 01.04.2017 по 30.04.2017. Полученные результаты представлены в таблице 2.

На рис. 7 представлен график прогноза электропотребления.

На рис. 8 представлен фактический и прогнозный графики электропотребления.

При сравнении данных, полученных системой с реальными данными, выясняется, что ИНС действительно выполняет прогнозы, близкие к реальности (рис. 8).

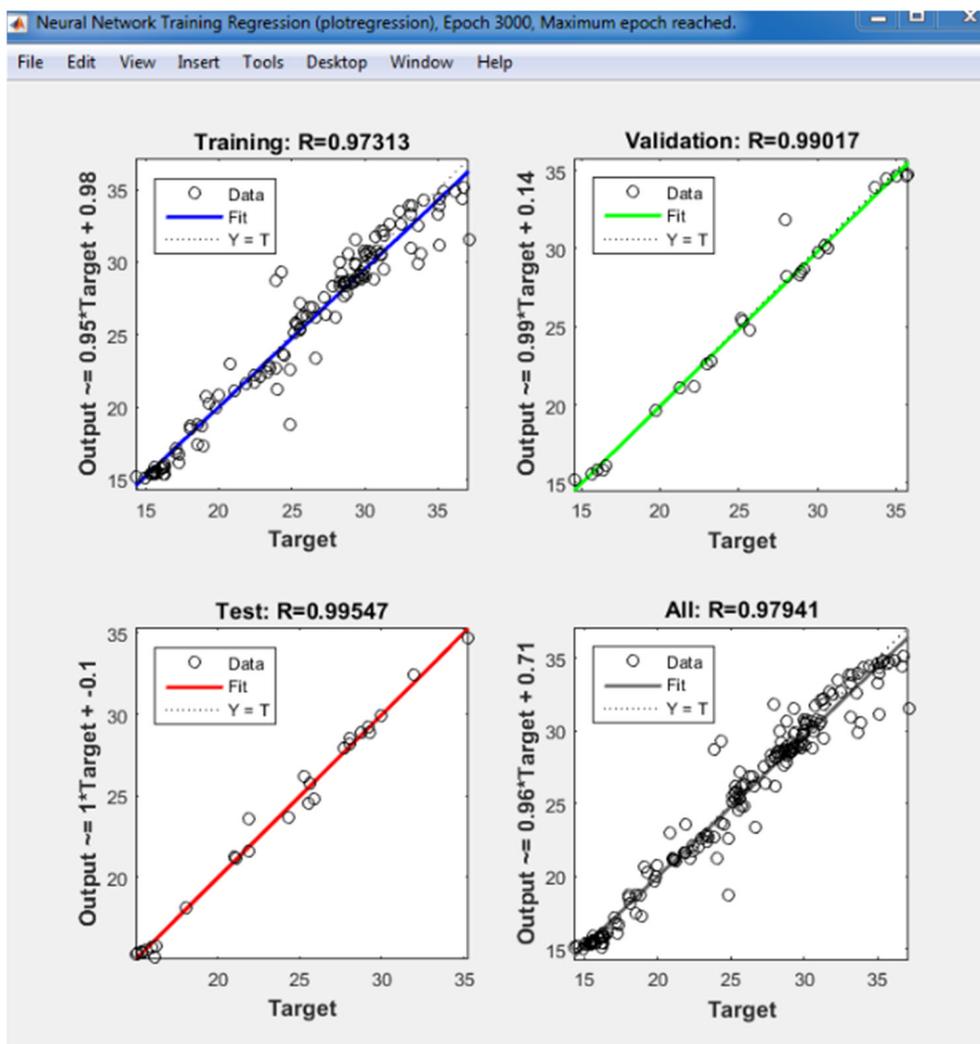


Рис. 6. Результаты обучения и тестирования сети

Fig. 6. The results of training and network testing

Таблица 2

Полученные результаты обучения  
и тестирования сети

Table 2

The results obtained for training  
and network testing

Дата	Прогнозирование	Фактически	Среднеквадратическая ошибка
01.04.2017	30,07	30	0,25
02.04.2017	25,28	24,91	1,48
03.04.2017	25,28	25,77	-1,9
04.04.2017	21,06	20,94	0,57
05.04.2017	20,82	21,13	-1,47
06.04.2017	18,08	18,56	-2,37
07.04.2017	18,56	19,01	-2,19
08.04.2017	15,16	15,50	-2,12
09.04.2017	15,59	15,88	-1,12
10.04.2017	14,30	14,64	-2,32
11.04.2017	14,53	14,12	-2,9
12.04.2017	16	16,66	-3,96
13.04.2017	15,65	16,13	-2,97
14.04.2017	16,27	16,34	-0,37
15.04.2017	16,27	15,81	-3,04
16.04.2017	15,61	15,81	-1,3
17.04.2017	16,21	16,67	-2,87
18.04.2017	15,62	15,91	-1,81
19.04.2017	16,08	16,72	-3,82
20.04.2017	18,90	19,33	-2,22
21.04.2017	18,79	18,61	0,97
22.04.2017	19,84	19,58	1,33
23.04.2017	19,74	19,22	2,7
24.04.2017	22,40	22,94	-2,35
25.04.2017	21,87	21,64	1,06

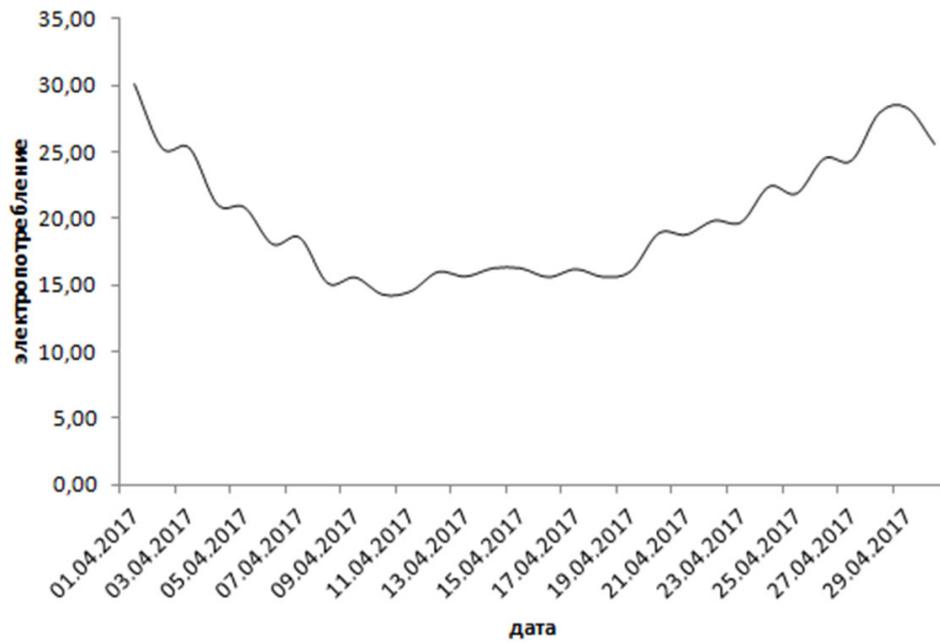


Рис. 7. График прогноза электропотребления

Fig. 7. A forecast graph of the electricity consumption

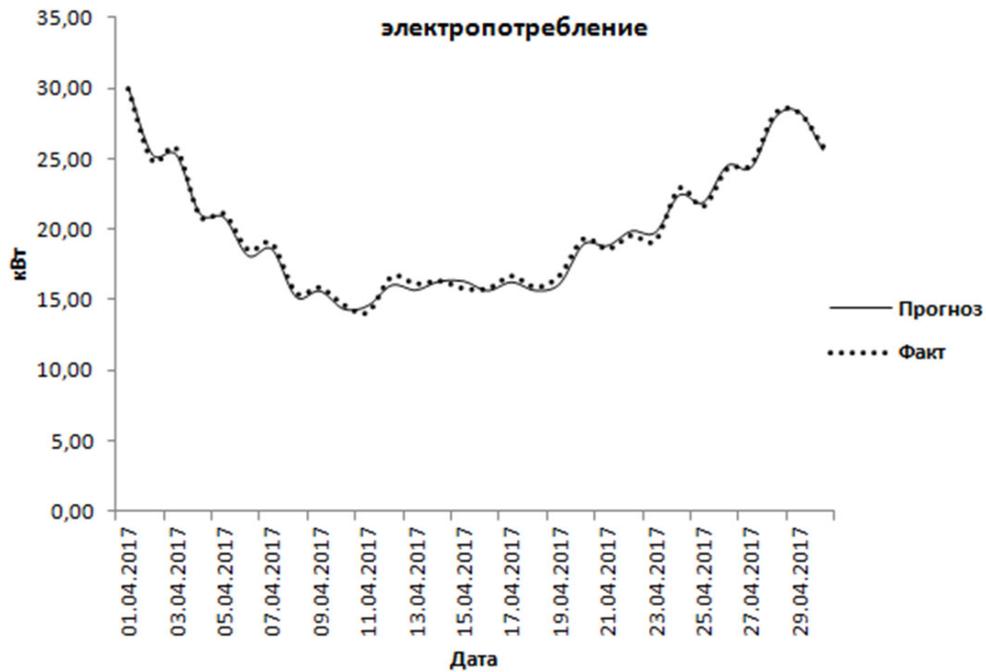


Рис. 8. Фактический и прогнозный графики электропотребления

Fig. 8. Actual and projected power consumption graphs

### Заключение

В качестве альтернативы наиболее распространенному на сегодняшний день методу прогнозирования электропотребления по принципу экспертных оценок нами был рассмотрен перспективный метод прогнозирования с помощью искусственных нейронных сетей.

Реализация нейронной сети осуществлена с помощью пакета программ MATLAB. В ходе исследования была построена архитектура в виде сетки с прямым распространением данных и обратным распространением ошибок. Обратное распространение ошибок было использовано как алгоритм обучения сети. Обучение проводилось методом градиентного спуска.

Представлены принципиальная схема алгоритма обратного распространения ошибок и универсальный метод ускорения стандартного алгоритма, который приводит к значительной экономии времени вычислений.

Тестирование построенной сети и сравнение результатов для двух выборок данных показало высокую точность прогнозирования. Средняя квадратичная ошибка прогнозирования не превышает значения 3,82%. Тогда как метод прогнозирования электропотребления по принципу экспертных оценок дает эту ошибку на уровне 11,37-15,77%.

### СПИСОК ЛИТЕРАТУРЫ

1. Воронов И. В. Определение параметров, влияющих на электропотребление промышленного предприятия, с помощью метода экспертных оценок / И. В. Воронов // Вестник Кузбасского государственного технического университета. 2009. № 5. С. 61-64.
2. Вороновский Г. К. Генетические алгоритмы, искусственные нейронные сети и проблемы виртуальной реальности / Г. К. Вороновский, К. В. Махотило, С. Н. Петрашев, С. А. Сергеев. Харьков: ОСНОВА, 1997. 107 с.
3. Галушка В. В. Формирование обучающей выборки при использовании искусственных нейронных сетей в задачах поиска ошибок баз данных / В. В. Галушка, В. А. Фатхи // Инженерный вестник Дона. 2013. № 2. URL: <http://www.ivdon.ru/magazine/archive/n2y2013/1597>
4. Головкин В. А. Нейронные сети: обучение, организация и применение / В. А. Головкин. М.: ИПРЖР, 2001. 256 с.
5. Кирпичникова И. М. Исследование методов прогнозирования электропотребления сбытового предприятия / И. М. Кирпичникова, К. Л. Соломаха // Электротехнические системы и комплексы. 2014. № 3 (24). С. 39-43.
6. Лисичкин В. А. Стратегический менеджмент: учебно-методический комплекс / В. А. Лисичкин, М. В. Лисичкина. М.: ЕАОИ, 2007. 329 с.
7. Манусов В. З. Краткосрочное прогнозирование электрической нагрузки на основе нечеткой нейронной сети и ее сравнение с другими методами / В. З. Манусов, Е. В. Бирюков // Известия Томского политехнического университета. 2006. Том 309. № 6. С. 153-158.

8. Матюшкин И. Моделирование и визуализация средствами MATLAB физики наноструктур. / И. Матюшкин. М.: Техносфера, 2011. 188 с.
9. Осипов Г. В. Моделирование социальных явлений и процессов с применением математических методов: учебное пособие / Г. В. Осипов М: НОРМА: ИНФРА-М, 2014. 191 с.
10. Федосин С. А. Особенности обучения построению моделей перемещения сложных объектов, обладающих искусственным интеллектом на базе нейронной сети / С. А. Федосин, Н. П. Плотникова, Е. А. Немчинова, Н. В. Макарова // Образовательные технологии и общество. 2018. Том 21. № 3. С. 290-297.
11. Хайкин С. Нейронные сети: полный курс. / С. Хайкин // Пер. с англ. Н. Н. Куссуль, А. Ю. Шелестова. М.: Вильямс, 2008. 1103 с.
12. Черных И. В. Моделирование электротехнических устройств в MATLAB, SimPowerSystems и Simulink / И. В. Черных. М.: ДМК Пресс, 2011. 288 с.
13. Lean Y. U., Shouyang .W. A., Kin. K. L. Basic Learning Principles of Artificial Neural Networks / Y. U. Lean, W. A. Shouyang, K. L. Kin. // Foreign-Exchange-Rate Forecasting with Artificial Neural Networks. Boston, MA: Springer, 2007. Pp. 27-37.
14. Rumelhart D. E., Hinton G. E., Williams R. J. Learning Internal Representations by Error Propagation / D. E. Rumelhart, G. E. Hinton, R. J. Williams // Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1: Foundations. Cambridge, MA: A Bradford Book, 1986. Pp. 318-362.
15. Neighborhood based modified backpropagation algorithm using adaptive learning parameters for training feedforward neural networks / T. Kathirvalavakumar, S. Jeyaseeli Subavathi // Neurocomputing. 2009. Vol. 72. Pp. 3915-3921. DOI: 10.1016/j.neucom.2009.04.010

**Sameh A. KASSEM<sup>1</sup>**  
**Abdulla H. A. EBRAHIM<sup>2</sup>**  
**Abdulla M. KHASAN<sup>3</sup>**  
**Alla G. LOGACHEVA<sup>4</sup>**

UDC 519.6, 004.421

## **FORECASTING ELECTRIC CONSUMPTION OF THE ENTERPRISE USING ARTIFICIAL NEURAL NETWORKS**

<sup>1</sup> Postgraduate Student,  
Institute of Digital Technologies and Economics,  
Kazan State Power Engineering University  
ali20105@mail.ru; ORCID: 0000-0002-4587-6730

<sup>2</sup> Postgraduate Student,  
Department of Applied and Technical Physics,  
University of Tyumen  
abdulla.ybragim@mail.ru; ORCID: 0000-0002-1709-9882

<sup>3</sup> Postgraduate Student,  
Institute of Information Technologies and Intelligent Systems,  
Kazan Federal University  
alii.hasaa@gmail.com; ORCID: 0000-0002-1988-8869

<sup>4</sup> Cand. Sci. (Tech.),  
Department of Power Supply of Industrial Enterprises,  
Institute of Electrical Power Engineering and Electronics,  
Kazan State Power Engineering University  
logacheva.alla@yandex.ru; ORCID: 0000-0002-0371-7985

### **Abstract**

Energy consumption has increased dramatically over the past century due to many factors, including both technological, social and economic factors. Therefore, predicting energy consumption is of great importance for many parameters, including planning, management,

---

**Citation:** Kassem S. A., Ebrahim A. H. A., Khasan A. M., Logacheva A. G. 2021. "Forecasting electric consumption of the enterprise using artificial neural networks". Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy, vol. 7, no. 1 (25), pp. 177-193. DOI: 10.21684/2411-7978-2021-7-1-177-193

---

optimization and conservation. Data-driven models for predicting energy consumption have grown significantly over the past several decades due to their improved performance, reliability, and ease of deployment. Artificial neural networks are among the most popular data-driven approaches among the many different types of models today.

This article discusses the possibility of using artificial neural networks for medium-term forecasting of the power consumption of an enterprise. The task of constructing an artificial neural network using a feedback algorithm for training a network based on the Matlab mathematical package has been implemented.

The authors have analyzed such characteristics as parameter setting, implementation complexity, learning rate, convergence of the result, forecasting accuracy, and stability. The results obtained led to the conclusion that the feedback algorithm is well suited for medium-term forecasting of power consumption.

### **Keywords**

Artificial neural networks, training algorithm, power consumption forecasting, back propagation of error, mean square error, activation function.

**DOI: 10.21684/2411-7978-2021-7-1-177-193**

### **REFERENCES**

1. Voronov I. V. 2009. "Determination of parameters affecting the power consumption of an industrial enterprise using the method of expert assessments". Herald of the Kuzbass State Technical University, no. 5, pp. 61-64. [In Russian]
2. Voronovsky G. K., Makhotilo K. V., Petrashev S. N., Sergeev S.A. 1997. Genetic Algorithms, Artificial Neural Networks, and Virtual Reality Problems. Kharkiv: OSNOVA. 107 pp. [In Russian]
3. Galushka V. V. 2013. "Formation of a training sample when using artificial neural networks in problems of finding errors in databases". Engineering Herald of the Don, no. 2. <http://www.ivdon.ru/magazine/archive/n2y2013/1597> [In Russian]
4. Golovko V. A. 2001. Neural Networks: Learning, Organization and Application. 4<sup>th</sup> edition. Moscow: IPRZhR. 256 pp. [In Russian]
5. Kirpichnikova I. M., Solomakho K. L. 2014. "Research of methods for forecasting power consumption of a sales enterprise". Electrotechnical Systems and Complexes, no. 3 (24), pp. 39-43. [In Russian]
6. Lisichkin V. A., Lisichkina M. V. 2007. Strategic Management: educational materials. Moscow: EAOI. 329 pp. [In Russian]
7. Manusov V. Z., Biryukov E. V. 2006. "Short-term prediction of electrical load based on a fuzzy neural network and its comparison with other methods". Bulletin of the Tomsk Polytechnic University, vol. 309, no. 6, pp. 153-158. [In Russian]
8. Matyushkin I. 2011. Modeling and Visualization by Means of MATLAB Physics of Nanostructures. Moscow: Tekhnosfera. 188 pp. [In Russian].
9. Osipov G. V. 2014. Modeling Social Phenomena and Processes Using Mathematical Methods: a tutorial. Moscow.: NORMA: INFRA-M, 191 pp. [In Russian]

10. Fedosin S. A., Plotnikova N. P., Nemchinova E. A., Makarova N.V. 2018. "Features of teaching the construction of models for the movement of complex objects with artificial intelligence based on a neural network". *Educational Technologies and Society*, vol. 21, no. 3, pp. 290-297. [In Russian]
11. Haykin S. 2008. *Neural Networks: Complete Course*. Translated from English by N. N. Kussul and A. Yu. Shelestova. 2<sup>nd</sup> edition, revised. Moscow: Williams Publishing House. 1103 pp. [In Russian]
12. Chernykh I. V. 2011. *Modeling of electrical devices in MATLAB, SimPowerSystems, and Simulink*. Moscow: DMK Press. 288 pp. [In Russian]
13. Lean Y. U., Shouyang W. A., Kin K. L. 2007. *Basic Learning Principles of Artificial Neural Networks*. Boston, MA: Springer. 323 pp.
14. Rumelhart D. E., Hinton G. E., Williams R. J. 1986. "Learning internal representations by error propagation". In: *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. Vol. 1: Foundations, pp. 318-62. Cambridge, MA: A Bradford Book.
15. Kathirvalavakumar T, Jeyaseeli Subavathi S. 2009. "Neighborhood based modified backpropagation algorithm using adaptive learning parameters for training feedforward neural networks". *Neurocomputing*, vol. 72, pp. 3915-3921. DOI: 10.1016/j.neucom.2009.04.010