

АНАЛИЗ МЕТОДОВ ПРЕДСТАВЛЕНИЯ ДАННЫХ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ ДЛЯ УПРАВЛЕНИЯ ЭЛЕКТРОЭНЕРГЕТИЧЕСКИМИ СИСТЕМАМИ

**В. Ф. Калинин, Н. М. Зяблов, С. В. Кочергин,
А. В. Кобелев, Д. А. Джапарова**

*Кафедра «Электроэнергетика», ФГБОУ ВО «ТГТУ»,
г. Тамбов, Россия; vladimirka@gmail.com*

Ключевые слова: моделирование и электроэнергетические системы; нейронные сети; прогнозирование и управление электрической нагрузкой; электрические сети; электроэнергетика.

Аннотация: Приведены методы представления данных искусственной нейронной сети для моделирования и управления электроэнергетическими системами. В программе MATLAB реализован алгоритм прогнозирования потребления электрической нагрузки и выполнено моделирование. На основании полученных результатов выбран наиболее эффективный метод представления первичных данных нейронной сети.

Единая энергетическая система (ЕЭС) России является уникальным организационно-техническим объектом. Однако централизованная система организации и управления ЕЭС в условиях современной России нуждается в коренной модернизации. Для решения существующих проблем необходим переход отечественной электроэнергетики на новое качество управления путем формирования целостной многоуровневой системы управления с увеличением объемов автоматизации и повышением надежности всей системы, включая самые слабые и уязвимые звенья.

Использование искусственных нейронных сетей (НС) давно находит место в системах управления электроэнергетической отрасли. Причиной является то, что НС дает достаточно высокую точность предсказания, что очень важно в системах управления электроснабжением, при правильном прогнозе потребление энергии повышает энергоэффективность электрических сетей и снижает расход энергоносителей. В данной статье проведены исследования НС прогнозирования потребления электроэнергии для одного из районов г. Тамбова. Используются три метода представления данных – помесечное, подневное и почасовое. Проведена работа с векторами и матрицами. Установлено, что наибольшую точность предсказания дало почасовое представление данных НС, несколько меньшую точность – помесечное, а подневное оказалось бессмысленным для небольших выборок.

В качестве объекта исследования использовались сведения по потреблению электрической энергии одного из районов г. Тамбов.

Для исследований и сравнительного анализа различных способов представления исходных данных НС выбрано три способа представления данных – помес- сячные в течение одного года, подневные – одного месяца и почасовые – 12 меся- цев. Причем первые два способа реализуются в виде векторов, а последний – в виде матрицы, так как для корректной работы нейронных сетей с матричными данными матрицы должны быть квадратными, прямоугольные – не поддержива- ются. В случае с почасовыми данными за счет выбора временного интервала в два часа можно получить матрицу 12×12, которая будет успешно принята системой.

Выдвинуто предположение, что точность предсказания с использованием НС зависит от степени девиации данных, используемых для обучения: чем меньше девиация значений, тем больше точность. Для исследования и анализа первых двух способов использовалась НС со структурой, представленной на рис. 1.

Конфигурация НС выбрана в связи с проведением анализа различных конфи- гураций нейронной сети для выполнения задачи прогнозирования потребления электрической энергии, в котором подобная сеть показала наиболее высокий ре- зультат [1]. Ошибка прогноза определялась с помощью MAPE – средней абсо- лютной ошибки прогноза. Алгоритм наиболее подходит для сравнения результа- тов, полученных из одного массива данных. Формула имеет вид

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t}, \quad (1)$$

где Y_t, \hat{Y}_t – данные из контрольной выборки и полученные в результате прогнози- рования соответственно.

В первом исследуемом способе представления данные за каждый месяц формируют вектор размерностью 1×12, который является элементом для обуче- ния НС. Имеются данные потребления электрической энергии за пять лет, четыре года из которых – для обучения нейронной сети, а данные последнего года ис- пользуются для сравнения со спрогнозированными данными. Данные брались в первый день месяца в 18.00. Время выбрано как наиболее наглядное. Использо- ванные величины изображены на рис. 2.

Данные за разные годы относительно схожи, что в теории даст более высо- кую точность предсказания (см. рис. 2). Один из векторов, используемых для обу- чения, показан в табл. 1. После проведения обучения нейронной сети, выполнения моделирования и подсчета средней абсолютной ошибки прогноза, получен вектор с погрешностями прогноза (табл. 2). Результаты в виде средней абсолютной ошибки прогноза за каждый месяц показаны на рис. 3. Наибольшая ошибка про- гноза присутствует в мае и августе, что связано со многими факторами, в том числе со скачками температуры в один и тот же месяц разных лет. Усредненная абсолютная ошибка прогноза составила 6,25 %, что является достаточно точным предсказанием.




Рис. 1. Нейронные сети для работы с векторными данными, имеющие 10 нейронов с функцией активации logsig в скрытом слое и два нейрона с линейной функцией активации purelin в выходном слое




Рис. 2. Данные, использованные для прогнозирования
 месячного потребления энергии $W_{п}$, годы:
 1 – 2012; 2 – 2013; 3 – 2014; 4 – 2015

Таблица 1

**Пример вектора потребления энергии (МВт·ч),
 использовавшегося для обучения**

Месяц	Январь	Февраль	Март	Апрель	Май	Июнь
$W_{п}$	165,19	227,31	173,83	153,48	108,97	120,69
Месяц	Июль	Август	Сентябрь	Октябрь	Ноябрь	Декабрь
$W_{п}$	109,29	133,07	120,38	154,44	202,96	197,51

Таблица 2

Вектор погрешности прогноза потребления энергии (МВт·ч)

Месяц	Январь	Февраль	Март	Апрель	Май	Июнь
$W_{п}$	1,71	0,57	1,01	6,26	19,15	9,74
Месяц	Июль	Август	Сентябрь	Октябрь	Ноябрь	Декабрь
$W_{п}$	2,83	15,69	2,07	4,30	5,38	6,29




Рис. 3. Средняя абсолютная ошибка $\bar{\Delta}$ прогноза за каждый месяц

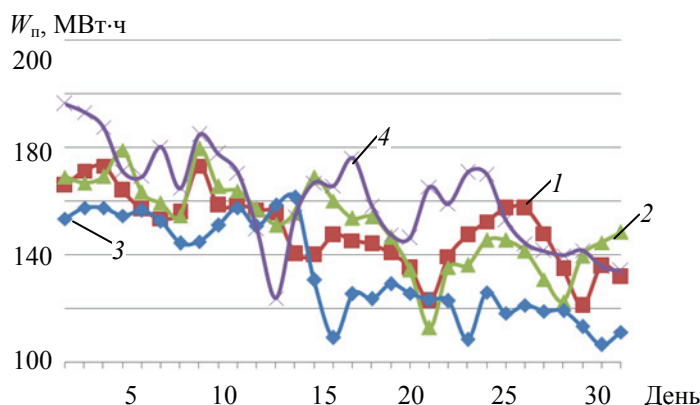


Рис. 4. Данные для исследования подневногo способа предсказания, годы:
1 – 2013; 2 – 2014; 3 – 2012; 4 – 2015

После исследования помесечного предсказания потребления электроэнергрии, проведем исследование подневногo предсказания. Исходный массив данных в виде векторов показан на рис. 4. Данные более хаотичные, чем помесечные, что в теории дает более высокую среднюю абсолютную ошибку прогноза, несмотря на увеличение объема данных в виде 30 значений в одном векторе. Вектор для обучения имеет размерность 1×30 , данные взяты за апрель в 18.00, образец такого вектора показан в табл. 3.

Результат моделирования электрической нагрузки с описанными параметрами изображен на рис. 5. Из рисунка видно, что ошибка прогноза стала больше, чем в случае прогнозирования помесечно, что связано с большей хаотичностью первичных данных, использованных для обучения. Для наглядности, на рисунке помимо данных моделирования НС присутствует результат прогноза с помощью усреднения первичных данных. Очевидно, что графики схожи, причем усредненная ошибка прогнозирования при помощи нейронной сети составила 9,1 %, тогда как ошибка прогноза усреднением составила 8,7 %. Вывод: при небольшой выборке использование нейронных сетей для подневногo прогнозирования потребления электрической нагрузки не имеет смысла, поскольку уступает даже простейшему методу усреднения данных.

Таблица 3

Пример вектора потребления энергии (МВт·ч) с подневными данными, использовавшийся для обучения

День	1	2	3	4	5	6	7	8	9	10
$W_{п}$	153,4	157,4	157,5	154,5	156,4	152,3	144,4	144,9	150,9	157,5
День	11	12	13	14	15	16	17	18	19	20
$W_{п}$	150,5	158,3	161,3	130,5	109,1	125,4	123,5	129,1	125,6	123,1
День	21	22	23	24	25	26	27	28	29	30
$W_{п}$	122,8	108,4	126,0	118,2	121,1	118,9	119,0	113,1	106,4	111,1




Рис. 5. Результат подневногo прогнозирования потребления энергии:
1 – нейронные сети; 2 – усреднение




Рис. 6. Нейронные сети для работы с матрицей размером 12×12

После исследования двух векторных методов прогнозирования, а именно, месячного и подневногo, исследуем матричный почасовой метод прогнозирования потребления электрической энергии. Для работы НС с матрицами они должны быть квадратными, то есть размером $N \times N$. В случае с почасовым прогнозированием имеем матрицу с 12-ю месяцами года и 12-ю временными отрезками, что соответствует размерности 12×12 .

Помимо правильного формирования исходных данных необходимо изменить конфигурацию нейронной сети для работы с матрицами, что заключается в увеличении числа нейронов в выходном слое до размерности матрицы, другими словами в выходном слое будет 12 нейронов с линейной функцией активации. Такая НС изображена на рис. 6.

Одна из матриц с данными, использованная для обучения, показана табл. 4. Хаотичность данных прогноза находится на уровне хаотичности исходных данных, поэтому можно говорить о том, что подобный подход должен дать высокую точность предсказания, не более 6,25 %, полученных в месячном прогнозировании. В результате обучения нейронной сети, моделирования и подсчета ошибки прогноза получена табл. 5.

Согласно проведенным исследованиям, наиболее эффективным для прогнозирования потребления электрической энергии являются месячный и почасовой способы. Наиболее перспективным является почасовой, но он требует большого массива данных (одна итерация для обучения требует 144 показания), в то время как месячный – всего 12. Применение того или иного способа должно быть обосновано требованиями по необходимым данным прогноза – месячным или почасовым.

Таблица 4

Пример матрицы потребления энергии (МВт·ч) для обучения

Время	Месяц					
	Январь	Февраль	Март	Апрель	Май	Июнь
0:00	130,0	154,0	128,2	112,2	91,6	105,8
2:00	112,0	138,3	114,4	97,2	78,0	86,6
4:00	104,9	134,1	110,5	93,7	73,9	79,5
6:00	116,6	167,4	143,5	94,3	93,1	96,0
8:00	138,2	210,1	173,7	108,2	127,8	129,6
10:00	154,4	221,2	184,4	111,1	136,6	146,5
12:00	157,2	214,9	177,3	107,3	136,2	146,1
14:00	157,7	207,9	173,9	104,7	138,6	145,1
16:00	162,3	198,8	167,4	104,7	133,9	139,0
18:00	189,5	209,4	166,0	109,1	125,7	130,8
20:00	189,8	222,2	197,9	133,5	126,2	127,7
22:00	164,8	191,0	167,6	132,0	136,7	138,6
	Июль	Август	Сентябрь	Октябрь	Ноябрь	Декабрь
0:00	100,1	95,1	100,4	115,8	128,4	150,9
2:00	83,6	81,2	86,8	101,7	113,5	130,8
4:00	75,9	76,6	80,9	97,3	109,7	124,9
6:00	77,6	90,0	93,8	133,1	144,1	144,9
8:00	98,0	121,9	118,2	175,5	189,3	185,9
10:00	116,7	137,5	130,7	192,6	195,3	198,5
12:00	119,7	138,0	128,8	188,9	190,7	194,2
14:00	119,2	137,5	126,7	188,5	188,6	189,2
16:00	118,2	134,1	122,6	187,4	189,6	191,0
18:00	116,3	126,0	125,4	197,7	211,4	223,3
20:00	117,8	129,5	157,5	201,9	196,6	215,6
22:00	133,6	133,2	135,1	165,9	164,2	188,6

Таблица 5

Средняя абсолютная ошибка прогноза при использовании почасового метода в процентах

Время	Месяц											
	1	2	3	4	5	6	7	8	9	10	11	12
0:00	2	6	8	14	3	0	2	2	2	2	3	13
2:00		5	7	15	2	1	4	1	4	5	6	
4:00	1	4	6	13	1	4	9	3	3	2	2	10
6:00		10	3	8	18	3	12	13	12	3	4	3
8:00		14	10	6	21		11	11	16	2	1	2
10:00	2	8	6	8	11	2	7	9	13	6	0	0
12:00		5	3	10	6	3	5	10	12	5	2	1
14:00	0	4			4	5	4	9	11	6	1	
16:00	3	2	0	11	3	6	2	4		11	3	7
18:00	1	1	5	18	10	5	7	0	15	3	0	4
20:00		2	1	9	3		5	11	8	1	6	5
22:00		4	3	11	1	7	4	5	5	0	6	1
Среднее	5	5	7		4		6	6	9	4	3	6

Список литературы

1. Зяблов, Н. М. Прогнозирование бытовой электрической нагрузки с применением нейронных сетей / Н. М. Зяблов, Т. И. Чернышова, А. В. Кобелев, С. В. Кочергин // Модели, системы, сети в экономике, технике, природе и обществе. – 2017 – № 1 (21). – С. 181 – 190.
2. Зяблов, Н. М. Прогнозирование потребления электрической энергии / Н. М. Зяблов, Д. А. Джапарова, С. В. Кочергин // Энергосбережение и эффективность в технических системах / М-во образования и науки Рос. Федерации, ФГБОУ «Тамб. гос. техн. ун-т». – Тамбов, 2017. – 284 с.
3. Кочергин, С. В. Нейронные сети и фрактальное моделирование электроэнергетических систем / С. В. Кочергин, А. В. Кобелев, Н. А. Хребтов // Fractal Simulation. – 2012. – № 1 (3). – С. 6 – 15.
4. Зыбин, А. А. Современные проблемы высших гармоник в городских системах электроснабжения / А. А. Зыбин, А. В. Кобелев // Вестн. Тамб. гос. техн. ун-та. – 2011 – № 1 (17). – С. 187 – 191.

The Analysis of Methods of Data Presentation of Artificial Neuron Networks for Electric Power Systems Control

V. F. Kalinin, N. M. Zyablov, S. V. Kochergin,
A. V. Kobelev, D. A. Dzhaparova

*Department of Electrical Power Engineering, TSTU, Tambov, Russia;
vlladimirka@gmail.com*

Keywords: electric networks; electric power industry; forecasting and control of electrical load; modeling and electric power systems; neural networks.

Abstract: Methods for representing data of an artificial neural network for modeling and control of electric power systems are presented. The MathLAB software implemented an algorithm for predicting the consumption of electrical load; simulation was performed. The most effective method of presenting the primary data of a neural network is chosen on the basis of the results obtained.

References

1. Zyablov N.M., Chernyshova T.I., Kobelev A.V., Kochergin S.V. [Forecasting household electrical load with the use of neural networks], *Modeli, sistemy, seti v ekonomike, tekhnike, prirode i obshchestve* [Models, Systems, Networks in Economics, Technology, Nature and Society], 2017, no. 1 (21), pp. 181-190. (In Russ., abstract in Eng.)
2. Zyablov N.M., Dzhaparova D.A., Kochergin S.V. [Forecasting the consumption of electrical energy], *Energoberezhenie i effektivnost' v tekhnicheskikh sistemakh* [Prognostirovanie Potrebleniya Ehlektricheskoy Ehnergii Energy Saving and Efficiency in Technical Systems], Tambov, 2017, 284 p. (In Russ.)
3. Kochergin S.V., Kobelev A.V., Hrebtov N.A. [Neural networks and fractal modeling of electric power systems], *Fraktal'noe modelirovanie* [Fractal Simulation], 2012, no. 1 (3), pp. 6-15. (In Russ., abstract in Eng.)
4. Zybin A.A., Kobelev A.V. [Modern Problems of Higher Harmonics in Urban Power Supply Systems], *Transactions of the Tambov State Technical University*, 2011, no. 1 (17), pp. 187-191. (In Russ., abstract in Eng.)

Analyse der Techniken zur Darstellung der Daten des künstlichen neuronalen Netzwerks für elektroenergetische Systeme

Zusammenfassung: Es sind die Methoden der Darstellung der Daten des künstlichen neuronalen Netzes zur Modellierung und Steuerung von elektrischen Energiesystemen vorgestellt. Im Programm MathLAB ist der Algorithmus zur Vorhersage des Stromverbrauchs der elektrischen Belastung implementiert und die Simulation durchgeführt. Auf der Grundlage der erhaltenen Ergebnisse ist die effektivste Methode zur Darstellung der Primärdaten des neuronalen Netzes ausgewählt.

Analyse des méthodes de la présentation des données du réseau artificiel des neurones pour la gestion des systèmes électroénergétiques

Résumé: Sont mentionnées les méthodes de la présentation des données du réseau artificiel des neurones pour la modélisation et la gestion des systèmes électroénergétiques. Dans le programme de MathLAB est mis en œuvre l'algorithme de la prévision de la consommation de la charge électrique; est effectuée la simulation. A la base des résultats obtenus, est choisie la méthode la plus efficace de la présentation des données primaires du réseau de neurones.

Авторы: *Калинин Вячеслав Федорович* – доктор технических наук, профессор кафедры «Электроэнергетика»; *Зяблов Никита Михайлович* – магистрант; *Кочергин Сергей Валерьевич* – кандидат технических наук, доцент кафедры «Электроэнергетика»; *Кобелев Александр Викторович* – кандидат технических наук, заведующий кафедрой «Электроэнергетика»; *Джапарова Динара Амангельдиевна* – аспирант кафедры «Электроэнергетика», ФГБОУ ВО «ТГТУ», г. Тамбов, Россия.

Рецензент: *Шувалов Анатолий Михайлович* – доктор технических наук, профессор, заведующий лабораторией «Альтернативные источники энергии взамен жидкого топлива», ФГБНУ «Всероссийский научно-исследовательский институт использования техники и нефтепродуктов в сельском хозяйстве» (ФГБНУ ВНИИТиН), г. Тамбов, Россия.