

# Алгоритм обучения искусственной нейронной сети для факторного прогнозирования электропотребления бытового сектора

ТАВАРОВ С.Ш.

ТГУ, Душанбе, Республика Таджикистан

*Анализ известных методов прогнозирования электропотребления в городских распределительных электрических сетях показал, что все они учитывают источники как электрической, так и тепловой энергии. Сокращение или отсутствие источников тепловой энергии приводит к значительным погрешностям прогноза, что снижает энергоэффективность городских электрических сетей и надёжность отдельных элементов систем электроснабжения. Предлагаются расчетная, компьютерная и нейросетевая модели, позволяющие повысить точность прогноза электропотребления бытового сектора. На основе разработанной математической модели с учётом факторных коэффициентов, полученных за 2020 г. для девяти городов Республики Таджикистан, были проведены расчёты ежемесячных значений коэффициента, характеризующего условия местности. Результаты математического моделирования сравнивались с данными компьютерной и нейросетевой моделей. Предложен метод, позволяющий повысить точность прогнозирования электропотребления бытового сектора. С целью автоматизации контроля и управления электроэнергией, вырабатываемой возобновляемыми источниками электроэнергии, предложен алгоритм обучения искусственной нейронной сети для факторного прогнозирования электропотребления, применение которого (за счёт возможности постоянного обучения) позволит повысить точность прогноза. Подтверждением эффективности алгоритма является высокая сходимость результатов, полученных как с помощью предложенных моделей, так и по показаниям счётчиков электроэнергии.*

*К л ю ч е в ы е с л о в а:* прогнозируемое электропотребление, факторы, алгоритм, искусственная нейронная сеть

Вопросы обеспечения энергоэффективности распределительных электрических сетей, в первую очередь городских, приобретают особое значение, если в энергетике страны преобладают источники электрической энергии, имеющие сезонную зависимость (гидравлические электростанции на реках с неравномерным стоком воды, ветровые и солнечные электростанции).

В свою очередь, сезонные колебания в потреблении электроэнергии, неравномерность нагрузки питающих линий снижают не только энергоэффективность электрических сетей, но и способствуют сокращению сроков службы элементов систем электроснабжения потребителей. Выявление закономерностей сезонных колебаний выработки и потребления электрической энергии позволяет построить модели электропотребления и спрогнозировать его динамику, что в целом решит проблему обеспечения энергоэффективности городских электрических сетей и надёжности систем электроснабжения.

Рост электропотребления бытового сектора при отсутствии газо- и теплоснабжения делает неопределённым точное прогнозирование электрической нагрузки, создавая проблему обеспечения баланса мощностей. Известные методы прогнозирования бытового элек-

тропотребления [1–6] учитывают источники как электрической, так и тепловой энергии. Однако в труднодоступных районах (горной местности) подвод газа и тепловых сетей неэффективен как с позиций экономичности, так и технической реализации. Такая проблема характерна и для бытовых потребителей, расположенных в городах, лишённых этих источников по ряду причин [7–9]. Предлагаемые решения проблемы обеспечения энергией бытовых потребителей труднодоступных районов опираются либо на гибридное электроснабжение (централизованное и от автономных источников), либо только на автономное электроснабжение на основе возобновляемых источников энергии (ВИЭ). Проблема теплоснабжения и горячего водоснабжения в этом случае решается путём преобразования электрической энергии в тепловую.

Известно, что ошибочный прогноз электрической нагрузки снижает эффективность использования как автономных энергоустановок на основе ВИЭ (из-за сложности регулирования вырабатываемой мощности), так и комбинированных источников электроэнергии (связано с необходимостью синхронизации двух и более автономных энергоустановок с централизованным источником).

Предлагаемые способы повышения энергоэффективности, основанные на современных технологиях (полупроводниковые преобразователи для повышения качества электроэнергии [10–16]) и методах корректного прогнозирования, применимы при близких метеорологических условиях [17]. Однако при этом не учитываются дополнительные факторы, например перепады высоты (расположение электропотребителей над уровнем моря) и благосостояние пользователей электроэнергии (возможность использования более современных электроприемников).

Таким образом, для повышения точности прогноза необходим учёт как основных, так и выявленных дополнительных факторов (факторное прогнозирование). Факторное прогнозирование электропотребления бытового сектора предлагается реализовать с помощью нейронной сети, позволяющей повысить точность прогнозирования за счёт своевременного выявления весовых переменных факторов.

**Методы и средства исследования.** Для разработки алгоритма обучения нейронной сети для факторного прогнозирования бытового электропотребления предлагается:

создать математическую модель дополнительных переменных факторов, характеризующих условия местности и влияющих на точность прогноза: труднодоступность (перепады высоты над уровнем моря), отсутствие газо- и теплоснабжения и благосостояние потребителей;

разработать метод прогнозирования электропотребления с использованием коэффициента, характеризующего условия местности;

построить *MATLAB*-модель прогнозирования электропотребления;

обосновать выбор алгоритма обучения искусственной нейронной сети (ИНС) для факторного прогнозирования электропотребления;

определить погрешность результатов прогнозирования электропотребления, полученных расчетным методом, на *MATLAB*-модели и с помощью ИНС, путём сравнения с экспериментальными данными.

**Математическая модель факторных переменных.** К основным переменным факторам, влияющим на электропотребление, можно отнести температуру окружающей среды (метеорологические), количество работающих электроприемников (в часы максимума нагрузки и другое время суток) и режимы работы. При прогнозировании бытового электропотребления в труднодоступных районах учёт только основных факторов приводит к значительным расхождениям между расчётными и экспериментальными данными. Объясняется это тем, что с возвышением над уровнем моря при одинаковой температуре на высоте и внизу субъективное ощущение холода возрастает. Это, в свою очередь, приводит к неопределенности (например невозможности использования разработанных типовых

графиков нагрузки для прогнозов), связанной с тем, что в труднодоступной местности, несмотря на малую плотность населения, из-за резкого изменения температуры окружающего воздуха потребление электроэнергии имеет существенное различие.

Следовательно, необходима разработка математической модели основных и дополнительных факторных переменных, учёт которых позволил бы повысить точность прогнозирования бытового электропотребления.

На основе проведенных исследований [18] выявлены имеющие наибольшую значимость дополнительные факторы, учитывающие перепад высоты над уровнем моря, конструктивное исполнение зданий и помещений, благосостояние потребителя (аналог дохода в функции Торнквиста) и динамику и сезонные колебания благосостояния потребителя. В [18] подробно описан физический смысл каждого фактора и обоснована необходимость учёта значимых факторов, обобщение которых позволило предложить математическую модель, описывающую коэффициент, характеризующий условия местности:

$$\alpha_i = \frac{((t_i h + c)s)}{s + k}, \quad (1)$$

где  $t_i$  – температурный коэффициент;  $h$  – перепад высоты над уровнем моря;  $c$  – конструктивное исполнение зданий и помещений;  $s$  – благосостояние потребителя;  $k$  – коэффициент, учитывающий динамику и сезонные колебания благосостояния потребителя.

При этом температурный коэффициент  $t_i$  определяется в зависимости от температуры окружающего воздуха в месте расположения потребителя  $t_1$ , °C:

при  $t_1 \geq -3$  °C и выше

$$t_i = \frac{|t_1| + |t_2|}{t_3}, \quad (2)$$

где  $t_2$  – добавочная температура, учитывающая разность температур снаружи дома и внутри помещения, °C;  $t_3$  – температура окружающего воздуха в точке 0 над уровнем моря, °C;

при  $-6 \leq t_1 \leq -4$  °C

$$t_i = \frac{|t_1|}{t_3}; \quad (3)$$

при  $t_1 \leq -7$  °C

$$t_i = \frac{|t_1| - |t_2|}{t_3}. \quad (4)$$

При температуре окружающего воздуха от  $-4$  до  $-6$  °C в случае конструкции жилого дома из железобетона добавочная температура не учитывается, так как при данной температуре конструкция жилого дома не влияет на температуру внутри помещения. При использовании других теплоизоляционных материалов зависимость  $t_i$  от температуры окружающего воздуха следует определять либо по (2), либо по (4).

Коэффициент учёта перепада высоты над уровнем моря определяется:

$$h = \frac{t_1}{t_2}, \quad (5)$$

Коэффициент конструктивного исполнения зданий и помещений:

$$c = \frac{t_1}{t_4}, \quad (6)$$

где  $t_4$  – температура внутри помещения (квартиры), °С.

Благополучие потребителя  $s$  и коэффициент  $k$ , учитывающий его динамику и сезонные колебания, определяются с применением матриц нулевого и единичного числа (0 – соответствие минимальной возможности потребителя использовать электроприемники при минимальной и максимальной температурах окружающей среды, а 1 – соответствие максимальной возможности потребителя использовать электроприемники при минимальной и максимальной температурах окружающей среды).

**Метод прогнозирования электропотребления бытового сектора с учётом  $\alpha_i$ .** Известно, что колебания суточного и сезонного электропотребления бытового сектора представляют собой параболу, тогда как месячное и годовое электропотребление подчиняется линейному закону.

Следовательно, зависимость электропотребления бытового сектора с учётом коэффициента, характеризующего условия местности, можно представить в виде функции:

$$f(\alpha_i, W) = W(1 - \alpha_i). \quad (7)$$

Из (7) следует, что получаемый результат зависит от коэффициента  $\alpha_i$ .

С учетом вышеизложенного прогнозирование электропотребления предлагается описывать выражением

$$W_{\text{прогноз}} = W_{\text{факт}} (1 - \alpha_i), \quad (8)$$

где  $W_{\text{факт}}$  – фактическое электропотребление, кВт·ч.

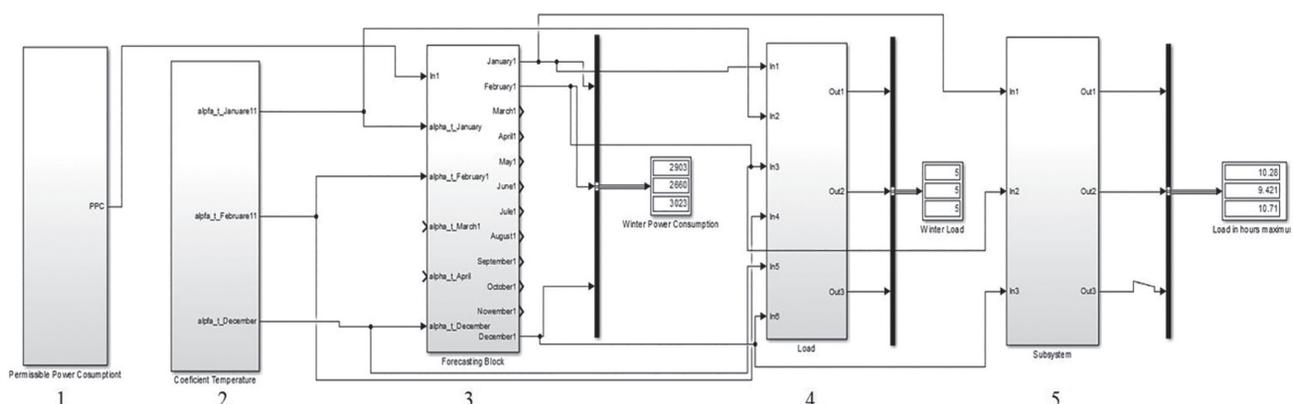
Большая часть потребителей электроэнергии, расположенных в труднодоступных местах, получают электроэнергию от автономных источников, которые в связи с их ограниченной мощностью (изменение инсоляции солнца в течение суток, заморозки в горах и уменьшение притока воды, а также изменение скорости ветра) не могут поддерживать неизменной выработку электроэнергии. В Республике Таджикистан большая часть населения проживает в высокогорных районах на высоте 700 и более метров над уровнем моря и лишена иных (кроме электрической) источников энергии.

**Компьютерная модель прогнозирования электропотребления.** В программе *MATLAB* с использованием (1) была создана компьютерная модель, позволяющая при задании необходимых значений коэффициентов  $t_p, h, c, s, k$  рассчитывать коэффициент, характеризующий условия местности  $\alpha_i$ . Полученные результаты представляются в виде блоков прогнозирования электропотребления (рис. 1).

Рассчитанные значения коэффициентов  $\alpha_i$  передаются в *MATLAB*-уравнение (8) и представляются в виде блока управления. В свою очередь, (8) состоит из двух членов: первый – фактический расход электроэнергии за время подключения электроприемников, второй – разность  $(1 - \alpha_i)$ .

Для дальнейшего анализа получаемых результатов в построенной компьютерной модели выполнялось ежемесячное прогнозирование электропотребления в течение года.

**Выбор алгоритма обучения искусственной нейронной сети для факторного прогнозирования электропотребления.** Для решения задач прогнозирования применяют следующие типы ИНС: линейную сеть, многослойный персептрон, сеть на радиальных базисных функциях, обобщенно-регрессионную сеть.



**Рис. 1.** Блоки прогнозирования электропотребления бытового сектора: 1 – блок электропотребления; 2 – блок моделирования коэффициентов  $t_p, h, c, s, k$ ; 3 – блок прогнозирования электропотребления; 4 – блок допустимой электрической нагрузки; 5 – блок прогнозируемой электрической нагрузки в часы ее максимума

**Fig. 1.** Household consumer power consumption forecasting units: 1 – power consumption unit; 2 – block of modeling coefficients  $t_p, h, c, s, k$ ; 3 – block of forecasting power consumption; 4 – block of permissible electrical load; 5 – block of predicted electrical load during its maximum hours

Достоинством ИНС является возможность факторного прогнозирования [19–22]. При этом сеть имеет  $X$  входов, каждый из которых соответствует какому-либо фактору, влияющему на прогнозный параметр. При этом сеть сама определяет зависимости между факторами, корректируя свои параметры при обучении. Таким образом могут быть смоделированы достаточно сложные регрессионные зависимости.

Для эффективного решения задачи факторного прогнозирования необходимо выбрать подходящую структуру ИНС. Анализ методов искусственного интеллекта для решения задач факторного прогнозирования показал, что многослойный персептрон может формировать на выходе произвольную многомерную функцию при соответствующем выборе количества слоев, диапазона изменения сигналов и параметров нейронов. Для решения задачи с помощью ИНС, кроме выбора конфигурации ИНС, необходимо сформировать окружение, в котором будет работать данная нейронная сеть.

Проведенный анализ [19–23] позволил установить, что для решения задачи с объемом исходных данных более 100 нейронов (в случае прогнозирования электропотребления с применением ИНС использованы трехлетние ежемесячные данные для девяти городов с более 500 нейронов) в среде *MATLAB* была выбрана нелинейная авторегрессионная нейронная сеть *NAR*, которая позволяет при задании на входе обобщенного показателя (в нашем случае состоящая из двух членов: коэффициента  $\alpha_i$  и единичной или суммарной мощности электроприемника с временем его подключения) на выходе после выбора количества слоев и алгоритма обучения получить прогнозируемое электропотребление. На рис. 2 приведена архитектура нелинейной авторегрессионной нейронной сети *NAR*.

Из трёх алгоритмов обучения (Левенберга–Марквардта, Байесова регуляризация, метод сопряженных градиентов) наиболее эффективным для решения по-

ставленных задач оказался первый алгоритм, показавший наивысшую сходимость полученных результатов по обучаемости (рис. 3).

Как видно из рис. 3, степень обучаемости искусственной нейронной сети находится в пределах  $10^{-2} - 10^{-4}$ , что подтверждает достаточно высокую эффективность.

**Сравнение результатов, полученных с помощью нейросетевой модели.** На основе разработанной математической модели с учётом факторных коэффициентов  $t_p, h, c, s, k$  за 2020 г. для девяти городов Республики Таджикистан были проведены расчёты ежемесячных коэффициентов, характеризующих условия местности,  $\alpha_i$ .

Исходные данные вычисляемых коэффициентов определялись следующим образом: температурные коэффициенты  $t_i$  были взяты по данным Агентства по гидрометеорологии; коэффициент  $h$  – по данным Агентства статистики; коэффициент  $c$  – по данным Агентства строительства.

Результаты расчётов приведены на рис. 4 в виде зависимости коэффициента  $\alpha_i$  от суммарного числа месяцев для девяти городов ( $12 \cdot 9 = 10^8$ ).

Для проверки адекватности предложенных моделей результаты моделирования сравнивались с экспериментальными. За экспериментальные данные были приняты показания средств учёта электроэнергии для групп бытовых потребителей [23]. Результаты сравнения представлены в таблице.

Полученные результаты (таблица) показывают высокую сходимость (погрешность ниже 5 %). Таким образом, можно говорить о высокой точности прогноза при использовании предложенного метода (8).

Для сравнения же результатов, полученных на основе (8), с результатами выбранной и обученной нейросетевой модели были построены зависимости электропотребления от рассматриваемого числа городов за 2020 г. (рис. 5 и 6).

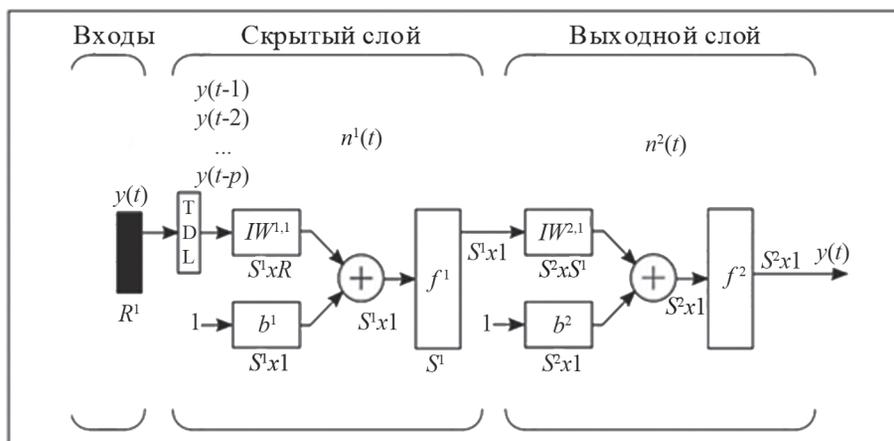


Рис. 2. Архитектура нелинейной авторегрессионной нейронной сети *NAR*

Fig. 2. Nonlinear autoregressive neural network *NAR* architecture

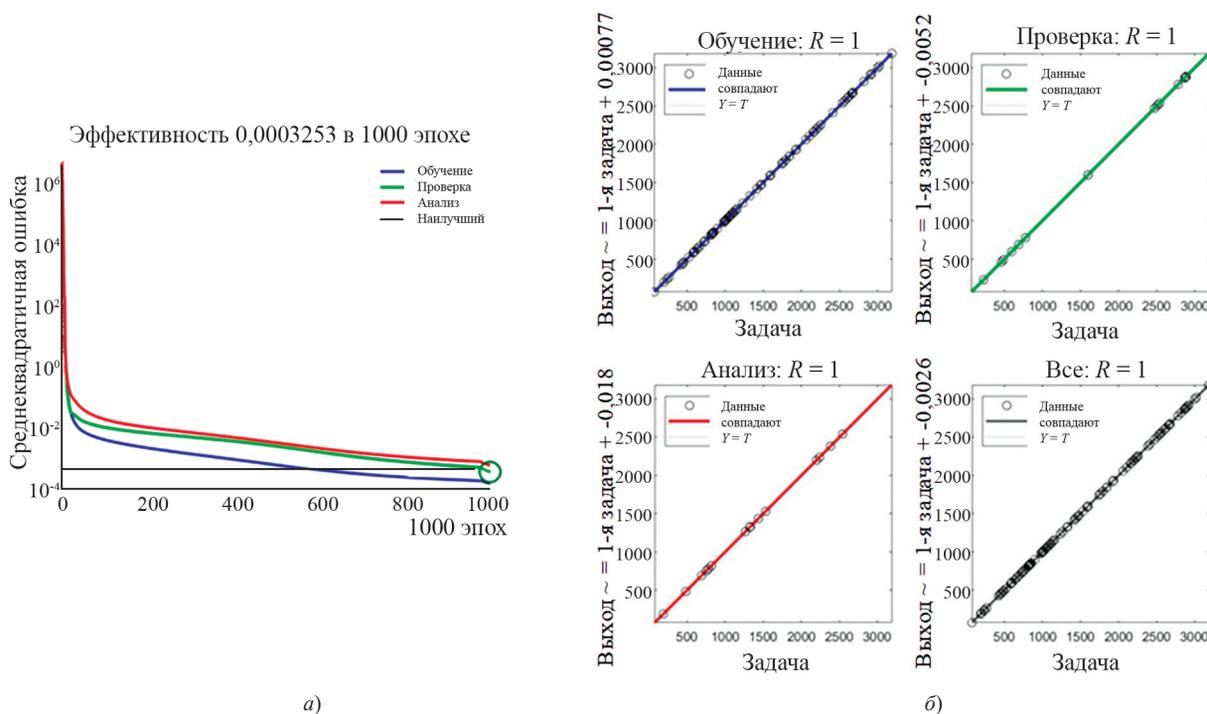


Рис. 3. Результаты обученной нейронной сети (а), нелинейная авторегрессионность обученной нейронной сети (б)  
Fig. 3. Results of a trained neural network (a), nonlinear autoregressiveness of a trained neural network (b)

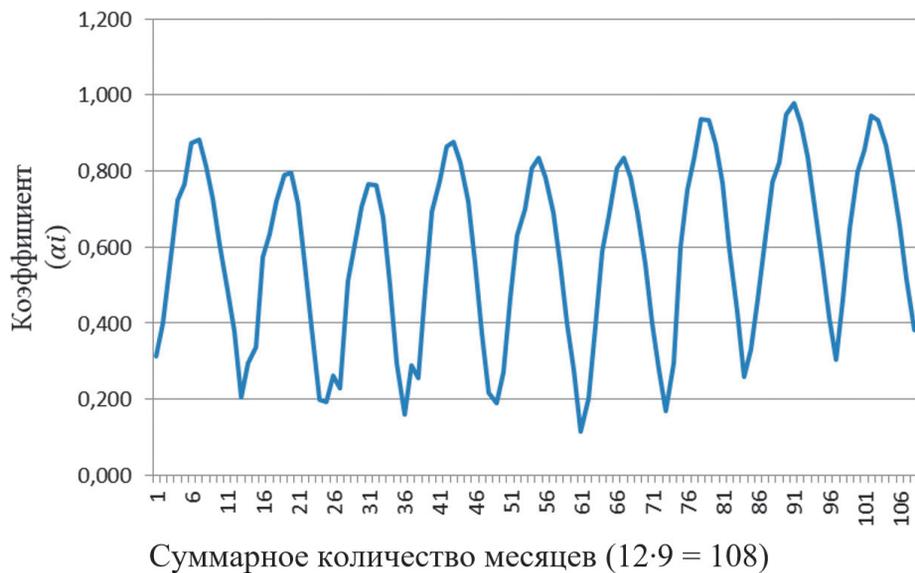


Рис. 4. Результаты моделирования коэффициента  $\alpha$ , для 9 городов за 2020 г.  
Fig. 4. Results of modeling the coefficient  $\alpha$ , for 9 cities for 2020

Сравнение фактического расхода электроэнергии с результатами моделирования, кВт·ч  
Comparison of real results with simulation results, kWh

Декабрь			Январь			Февраль		
Матем. модель	MATLAB-модель	Факт.	Матем. модель	MATLAB-модель	Факт.	Матем. модель	MATLAB-модель	Факт.
2950	3023	3000	2880	2903	2850	2580	2660	2700
Погрешность, %								
1,7	0,8	–	1	1,8	–	4	1,4	–

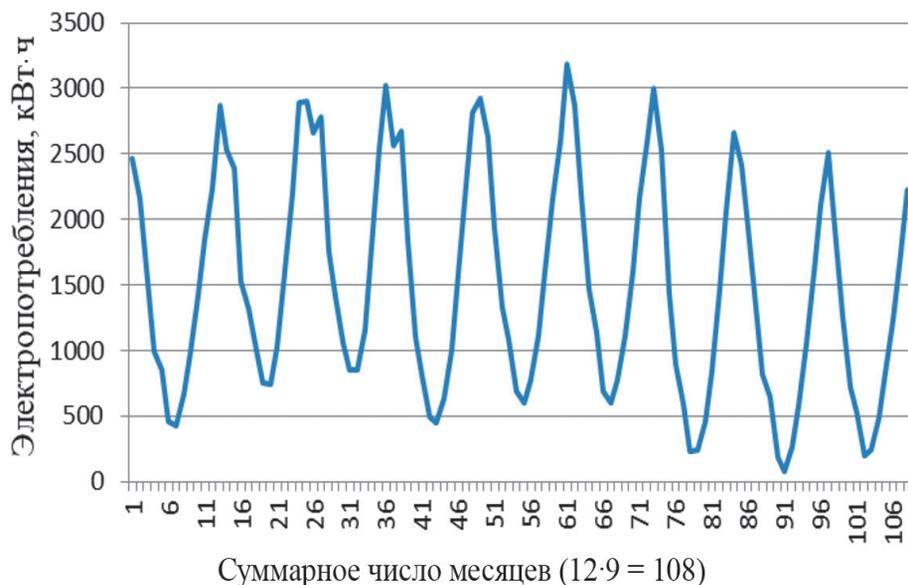


Рис. 5. Результаты моделирование предложенным методом

Fig. 5. Results of modeling by the proposed method

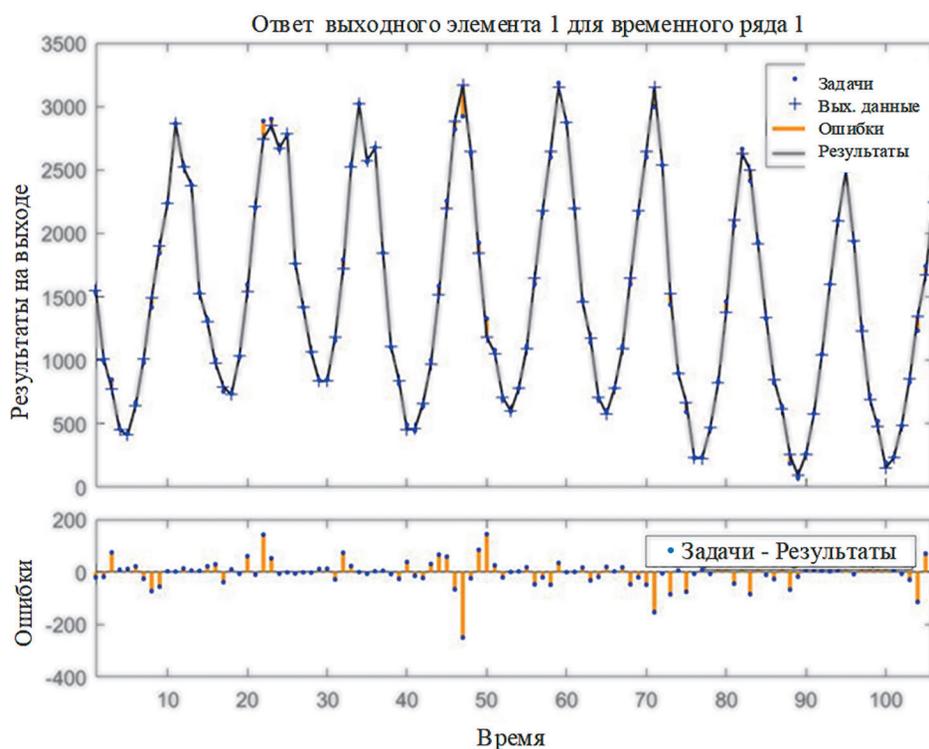


Рис. 6. Результаты нейросетевого моделирования

Fig. 6. Results of modeling in a neural network model

Результаты нейросетевого моделирования (рис. 6) показали высокую сходимость с результатами, полученными предложенным методом (8).

Таким образом, после сравнения результатов компьютерной, нейросетевой моделей и реальных данных с результатами, полученными предложенным методом, можно утверждать о его высокой точности прогноза

электропотребления. Однако, учитывая переход к полностью автоматизированному контролю и управлению автономными источниками энергии, при внедрении нейросетевой модели предлагается алгоритм, позволяющий за счёт высокой точности прогноза снизить потери электроэнергии и повысить срок службы ВИЭ. На рис. 7 приведен алгоритм обучения искусственной

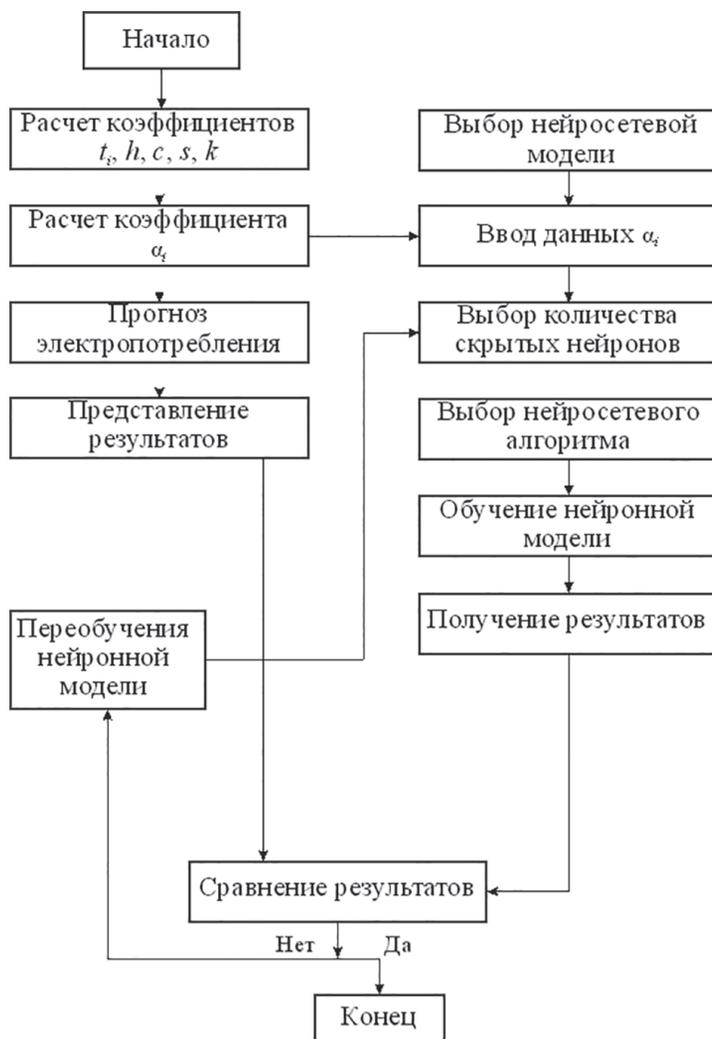


Рис. 7. Алгоритм обучения искусственной нейронной сети для факторного прогнозирования электропотребления бытового сектора

Fig. 7. Algorithm for training an artificial neural network for factorial forecasting of electricity consumption by household consumers

нейронной сети для факторного прогнозирования электропотребления.

Из рис. 7 видно, что алгоритм, построенный на основе предложенного метода прогнозирования, применим в ИНС в среде *MATLAB*. При этом возможность непрерывного переобучения позволяет повышать точность прогнозирования. В свою очередь, количество скрытых слоев определяется заданной точностью.

**Выводы.** Предложены модели и метод, позволяющие повысить точность прогнозирования электропотребления бытового сектора. С целью автоматизации контроля и управления выработкой электроэнергии ВИЭ предложен алгоритм обучения искусственной нейронной сети для факторного прогнозирования электропотребления. Применение данного алгоритма (за счёт возможности постоянного обучения) позволяет повысить точность прогноза. Подтверждением этого является высокая сходимость полученных различными способами результатов.

#### СПИСОК ЛИТЕРАТУРЫ

1. Макоклюев Б.И. и др. Краткосрочное прогнозирование электропотребления энергосистем. – Электрические станции, 2018, № 4, с. 24–35.
2. Макоклюев Б.И. и др. Оперативная коррекция графиков потребления электрической мощности в цикле планирования балансирующего рынка. – Электрические станции, 2019, № 5, с. 36–44.
3. Репкина Н.Г. Исследование факторов, влияющих на точность прогнозирования суточного электропотребления. – Известия высших учебных заведений. Электромеханика, 2015, № 2, с. 41–43.
4. Валеев Г.С., Дзюба М.А., Валеев Р.Г. Моделирование суточных графиков нагрузок участков распределительных сетей напряжением 6–10 кВ городов и населенных пунктов в условиях ограниченного объема исходной информации. – Вестник ЮУрГУ. Серия Энергетика, 2016, т. 16, № 2, с. 23–29.
5. Карпенко С.М., Карпенко Н.В. Эконометрическое моделирование энергопотребления с учетом влияния производственных факторов. – Энергобезопасность и энергосбережение, 2020, № 1, с. 14–17.
6. Карпенко С.М., Карпенко Н.В. Анализ динамики и прогнозирование электропотребления на основе эконометрического моделирования. – Энергобезопасность и энергосбережение, 2020, № 2, с. 20–25.

7. **Таваров С.Ш.** Рекомендации норм электропотребления для городов на основе разработанного метода прогнозирования на примере Республики Таджикистан. – Энергобезопасность и энергосбережение, 2021, № 1, с. 32–39.

8. **Таваров С.Ш.** Удельное электропотребление бытового сектора с учётом температуры окружающего воздуха и территориального расположения Республики Таджикистан. – Промышленная энергетика, 2019, № 7, с.19–22.

9. **Таваров С.Ш.** Метод прогнозирования электропотребления бытовыми потребителями в условиях Республики Таджикистан. – Вестник ЮУрГУ. Серия «Энергетика», 2020, т. 20, № 2. с. 28–35.

10. **Issi F., Kaplan O.** The Determination of Load Profiles and Power Consumptions of Home Appliances. – Energies, 2018, 11(3), 607, DOI: 10.3390/en11030607.

11. **Angrisani L., et al.** Smart Power Meters in Augmented Reality Environment for Electricity Consumption Awareness. – Energies, 2018, 11(9), 2303, DOI:10.3390/en11092303.

12. **Yan K., et al.** Multi-Step Short-Term Power Consumption Forecasting with a Hybrid Deep Learning Strategy. – Energies, 2018, 11(11), 3089, DOI:10.3390/en11113089.

13. **Vojtovic S., Stundziene A., Kontautiene R.** The Impact of Socio-Economic Indicators on Sustainable Consumption of Domestic Electricity in Lithuania. – Sustainability, 2018, 10(2), 162, DOI: 10.3390/su10020162.

14. **Ziel F.** Load Nowcasting: Predicting Actuals with Limited Data. – Energies, 2020, 13(6), 1443, DOI: 10.3390/en13061443.

15. **Naz A., et al. and Khurshed A.** Short-Term Electric Load and Price Forecasting Using Enhanced Extreme Learning Machine Optimization in Smart Grids. – Energies, 2019, 12(5), 866, DOI: 10.3390/en12050866.

16. **To W.M., et al.** Modeling of Monthly Residential and Commercial Electricity Consumption Using Nonlinear Seasonal Models – The Case of Hong Kong. – Energies, 2017, 10(7), 885, DOI: 10.3390/en10070885.

17. **Хомутов С.О., Серебряков Н.А.** Применение сверточной нейронной сети для повышения точности краткосрочного прогнозирования электропотребления электротехнического комплекса районной электрической сети. – Актуальные вопросы энергетики, 2020, т. 2, № 1, с. 44–47.

18. **Tavarov S.Sh., Sidorov A.I., Kalegina Y.V.** Model and Algorithm of Electricity Consumption Management for Household Consumers in the Republic of Tajikistan. – Mathematical Modelling of Engineering Problems, 2020, vol. 7, No. 4, pp. 520–526, DOI:10.18280/mmp.070403.

19. **Алексеева И.Ю., Ведерников А.С., Скрипачев М.О.** Прогнозирование электропотребления с использованием метода искусственных нейронных сетей. – Вестник Самарского государственного технического университета. Серия: Технические науки, 2010, № 2 (27), с. 135–138.

20. **Староверов Б.А., Гнатюк Б.А.** Определение наиболее перспективных нейронных сетей и способов их обучения для прогнозирования электропотребления. – Вестник Ивановского государственного энергетического университета, 2015, № 6, с. 59–64.

21. **Mokhov V.G., Tsimbol V.I.** Electrical Energy Consumption Prediction of the Federal District of Russia on the Basis of the Recurrent Neural Network. – Journal of Computational and Engineering Mathematics, 2018, vol. 5, No. 2, pp. 3–15.

22. **Симонов Н., Ивнев Н.** Опыт и перспективы применения искусственных нейронных сетей в электроэнергетике. – Электроэнергия. Передача и распределение, 2019, № S4 (15), с. 42–48.

23. **Солуянов Ю.И. и др.** Актуализация нормативных значений удельной электрической нагрузки многоквартирных домов в Республике Татарстан. – Электричество, 2021, № 6, с. 62–71.

[12.08.2021]



Автор: **Таваров Саиджон Ширалиевич** – кандидат техн. наук, доцент кафедры «Электро-снабжение» Таджикского технического университета им. акад. М.С. Осими, Душанбе, Республика Таджикистан.

*Elektrichestvo*, 2022, No. 3, pp. 30–38

DOI:10.24160/0013-5380-2022-3-30-38

## Artificial Neural Network Training Algorithm for Factor-Based Prediction of Electricity Consumption in the Household Sector

**TAVAROV Saidjon Sh.** (*Tajik Technical University named after Academician M.S. Osimi, Dushanbe, Tajikistan*) – Associate Professor of the Power Supply Dept., Cand. Sci. (Eng.).

*An analysis of the known methods for forecasting electricity consumption in urban distribution electric networks has shown that they are all based on the availability of sources of both electric and thermal energy. Reduction or complete absence of heat sources leads to significant forecast errors, which entails a drop in the energy efficiency of urban electrical networks and degraded reliability of power supply system individual components. Theoretical, computer, and neural network models that help achieve more accurate forecasting of electricity consumption in the household sector are proposed. Based on the developed mathematical model and taking into account the factor coefficients obtained for 2020 for nine cities of the Republic of Tajikistan, monthly values of the coefficient characterizing the terrain conditions were calculated. The results obtained using the proposed mathematical model were compared with the data of computer and neural network models. A method that helps obtain more accurate forecasting of electricity consumption in the household sector is proposed. To automate the monitoring and control of electricity*

generated by renewable energy sources, an algorithm for training an artificial neural network for factor-based forecasting of electricity consumption is proposed, the use of which will help improve the forecasting accuracy owing to the possibility of constantly training the neural network. The algorithm efficiency is confirmed by good agreement between the results obtained both using the proposed models and based on the readings of electricity meters.

**К е у о р д с:** predicted electricity consumption, factors, algorithm, artificial neural network

#### REFERENCES

1. **Makoklyuev B.I., et al.** *Elektricheskie stantsii – in Russ. (Electrical power plants)*, 2018, No. 4, pp. 24–35.
2. **Makoklyuev B.I., et al.** *Elektricheskie stantsii – in Russ. (Electrical power plants)*, 2019, No. 5, pp. 36–44.
3. **Repkina N.G.** *Izvestiya vysshih uchebnyh zavedeniy. Elektromekhanika – in Russ. (News of Higher Educational Institutions. Electromechanics)*, 2015, No. 2, pp. 41–43.
4. **Valeev G.S., Dzyuba M.A., Valeev R.G.** *Vestnik YuUrGU. Seriya Energetika – in Russ. (Bulletin of SUSU. Energy Series)*, 2016, vol. 16, No. 2, pp. 23–29.
5. **Karpenko S.M., Karpenko N.V.** *Energobezопасnost' i energosberezhenie – in Russ. (Energy security and energy conservation)*, 2020, No. 1, pp. 14–17.
6. **Karpenko S.M., Karpenko N.V.** *Energobezопасnost' i energosberezhenie – in Russ. (Energy security and energy conservation)*, 2020, No. 2, pp. 20–25.
7. **Tavarov S.Sh.** *Energobezопасnost' i energosberezhenie – in Russ. (Energy security and energy conservation)*, 2021, No. 1, pp. 32–39.
8. **Tavarov S.Sh.** *Promyshlennaya energetika – in Russ. (Industrial Power Engineering)*, 2019, No. 7, pp. 19–22.
9. **Tavarov S.Sh.** *Vestnik YuUrGU. Seriya Energetika – in Russ. (Bulletin of SUSU. Energy Series)*, 2020, vol. 20, No. 2, pp. 28–35.
10. **Issi F., Kaplan O.** The Determination of Load Profiles and Power Consumptions of Home Appliances. – *Energies*, 2018, 11(3), 607, DOI: 10.3390/en11030607.
11. **Angrisani L., et al.** Smart Power Meters in Augmented Reality Environment for Electricity Consumption Awareness. – *Energies*, 2018, 11(9), 2303, DOI:10.3390/en11092303.
12. **Yan K., et al.** Multi-Step Short-Term Power Consumption Forecasting with a Hybrid Deep Learning Strategy. – *Energies*, 2018, 11(11), 3089, DOI:10.3390/en11113089.
13. **Vojtovic S., Stundziene A., Kontautiene R.** The Impact of Socio-Economic Indicators on Sustainable Consumption of Domestic Electricity in Lithuania. – *Sustainability*, 2018, 10(2), 162, DOI: 10.3390/su10020162.
14. **Ziel F.** Load Nowcasting: Predicting Actuals with Limited Data. – *Energies*, 2020, 13(6), 1443, DOI: 10.3390/en13061443.
15. **Naz A., et al. and Khurshed A.** Short-Term Electric Load and Price Forecasting Using Enhanced Extreme Learning Machine Optimization in Smart Grids. – *Energies*, 2019, 12(5), 866, DOI: 10.3390/en12050866.
16. **To W.M., et al.** Modeling of Monthly Residential and Commercial Electricity Consumption Using Nonlinear Seasonal Models – The Case of Hong Kong. – *Energies*, 2017, 10(7), 885, DOI:10.3390/en10070885.
17. **Homutov S.O., Serebryakov N.A.** *Aktual'nye voprosy energetiki – in Russ. (Current Energy Issues)*, 2020, vol. 2, No. 1, pp. 44–47.
18. **Tavarov S.Sh., Sidorov A.I., Kalegina Y.V.** Model and Algorithm of Electricity Consumption Management for Household Consumers in the Republic of Tajikistan. – *Mathematical Modelling of Engineering Problems*, 2020, vol. 7, No. 4, pp. 520–526, DOI:10.18280/mnep.070403.
19. **Alekseeva I.YU., Vedernikov A.S., Skripachev M.O.** *Vestnik Samarskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Tekhnicheskie nauki – in Russ. (Bulletin of Samara State Technical University. Series: Technical Sciences)*, 2010, No. 2 (27), pp. 135–138.
20. **Staroverov B.A., Gnatyuk B.A.** *Vestnik Ivanovskogo gosudarstvennogo energeticheskogo universiteta – in Russ. (Bulletin of the Ivanovo State Power Engineering University)*, 2015, No. 6, pp. 59–64.
21. **Mokhov V.G., Tsimbol V.I.** Electrical Energy Consumption Prediction of the Federal District of Russia on the Based of the Recurrent Neural Network. – *Journal of Computational and Engineering Mathematics*, 2018, vol. 5, No. 2, pp. 3–15.
22. **Simonov N., Ivnev N.** *Elektroenergiya. Peredacha i raspredelenie – in Russ. (Electricity. Transmission and distribution)*, 2019, No. S4 (15), pp. 42–48.
23. **Soluyanov Yu.I., et al.** *Elektrichestvo – in Russ. (Electricity)*, 2021, No. 6, pp. 62–71.

[12.08.2021]