

УДК 519.6, 004.421

DOI: 10.18799/24131830/2023/12/4407

Шифр специальности ВАК: 05.14.01

Прогнозирование электропотребления с помощью нейронных сетей с LSTM

И.У. Рахмонов^{1✉}, В.Я. Ушаков², Н.Н. Ниёзов¹, Н.Н. Курбонов¹

¹ Ташкентский государственный технический университет, Узбекистан, г. Ташкент

² Национальный исследовательский Томский политехнический университет, Россия, г. Томск

✉ ilider1987@yandex.ru

Аннотация

Актуальность работы обусловлена необходимостью улучшения точности прогнозирования электропотребления для повышения его эффективности и, как следствие, для улучшения конкурентоспособности производимой продукции за счёт сокращения доли затрат на оплату электроэнергии в ее себестоимости. При определении прогнозных показателей потребления электроэнергии промышленными предприятиями с высокой точностью целесообразно использовать современные апробированные методы прогнозирования. Из существующих в настоящее время приблизительно 150 методов прогнозирования только 20–30 активно используются на практике. Анализ существующих методов прогнозирования, применяемых на промышленных предприятиях, показывает, что они преимущественно основаны либо на экспертной оценке объёмов электропотребления, либо на учёте удельного расхода электроэнергии (на единицу производимой продукции). **Цель:** повысить точность прогнозирования электропотребления промышленными предприятиями с использованием метода искусственного интеллекта, в частности метода искусственной нейронной сети, в том числе метода Long-short Time Memory (LSTM). **Методы:** При разработке модели прогнозирования были использованы методы искусственной нейронной сети, в том числе метод Long-short Time Memory (LSTM). При обработке первичных данных были использованы методы нормального закона распределения Гаусса, нормирование/масштабирование. **Результаты** подтверждены расчетным путем с применением предлагаемой модели на основе метода искусственной нейронной сети для прогнозирования электропотребления промышленных предприятий. Важное достоинство метода – наличие возможности его обучения и адаптивирования к процессу прогнозирования. Реальными расчетами показано, что их удастся успешно завершить за счет правильного подбора состава входящих слоёв и исключения случайностей.

Ключевые слова: прогнозирование, электропотребление, ошибка прогнозирования, адекватность модели, одно-слойная нейронная сеть, функция активации, нейроны, обучение, тестирование, валидация, алгоритм, ошибка, входной слой, выходной слой, весовые коэффициенты, среднеквадратичная ошибка.

Для цитирования: Прогнозирование электропотребления с помощью нейронных сетей с LSTM / И.У. Рахмонов, В.Я. Ушаков, Н.Н. Ниёзов, Н.Н. Курбонов // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2023. – Т. 334. – № 12. – С. 125–133. DOI: 10.18799/24131830/2023/12/4407

UDC 519.6, 004.421

DOI: 10.18799/24131830/2023/12/4407

Forecasting electricity consumption by LSTM neural network

I.U. Rakhmonov^{1✉}, V.Ya. Ushakov², N.N. Niyozov¹, N.N. Kurbonov¹

¹ Tashkent State Technical University, Tashkent, Uzbekistan

² National Research Tomsk Polytechnic University, Tomsk, Russian Federation

✉ ilider1987@asu.ru

Abstract

Relevance. The need to enhance the precision of electricity consumption forecasting for improving energy efficiency and, consequently, enhancing the competitiveness of manufactured products by reducing the proportion of electricity costs in their total cost. When determining forecast indicators of electricity consumption by industrial enterprises, it is important to apply contemporary high-precision forecasting methods. Only 20–30 forecasting methods of the 150 existing ones are actively implemented in practice. An examination of prevailing forecasting methodologies used by industrial enterprises reveals that they are mainly based either on expert assessments of electricity volumes or on accounting for specific electricity consumption (per unit of product manufactured). **Aim.** To elevate the accuracy of electricity consumption forecasting at industrial enterprises by using artificial intelligence methods, specifically, artificial neural network techniques, including the Long-Short Term Memory approach. **Methods.** When developing the forecasting model, artificial neural network techniques were adopted, with a particular emphasis on the Long-Short Term Memory method. For primary data processing, Gaussian distribution principles and normalization/scaling techniques were applied. **Results.** Substantiated computationally by applying the proposed model based on the artificial neural network technique for forecasting electricity consumption of industrial enterprises. A significant advantage of this method is its capability for learning and adaptability to forecasting. Real-time computations demonstrate its successful implementation, attributed primarily to appropriate selection of input layers and mitigation of random variables.

Keywords: forecasting, power consumption, forecasting error, model adequacy, single-layer neural network, activation function, neurons, training, testing, validation, algorithm, error, input layer, output layer, weighting coefficients, root mean square error.

For citation: Rakhmonov I.U., Ushakov V.Ya., Niyozov N.N., Kurbonov N.N. Forecasting electricity consumption by LSTM neural network. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2023, vol. 334, no. 2, pp. 125–133. DOI: 10.18799/24131830/2023/12/4407

Введение

Правильный выбор методов прогнозирования электропотребления, учитывающих характер объекта, способствует достижению высокой точности выбора показателей прогноза. В настоящее время методы искусственного интеллекта широко используются при прогнозировании параметров объектов энергетики. Использование этих методов позволяет подбирать наиболее точные параметры на основе многоступенчатого процесса обучения. В частности, использование метода искусственных нейронных сетей (ИНС) с Long-Short Term Memory (LSTM) при прогнозировании потребления электроэнергии позволяет с высокой точностью определять показатели прогноза [1–5].

Результаты исследования

При разработке прогнозных моделей метод ИНС с LSTM имеет ряд преимуществ в сравнении с другими методами [6–9]:

- осуществлять обучение и самообучение до выполнения условий, установленных в процессе прогнозирования, и даже при изменении состава и объёма исходных данных;
- получать высокоточные показатели прогноза, естественно, при правильном выборе состава и объёма исходных данных;
- применяться для решения широкого круга задач в области прогнозирования благодаря высокой адаптируемости метода.

При прогнозировании энергопотребления с использованием метода ИНС применяется регулиру-

емое локальное линейное прогнозирование авторегрессии [5]:

$$x_{n+1}^f = a_0'x_n + a_1'x_{n-1} + \dots + a_{m-1}'x_{n-(m-1)} + a_m'. \quad (1)$$

Коэффициенты в выражении (1) определяются методом наименьших квадратов (МНК), который является классическим методом определения постоянных коэффициентов.

При применении МНК условием наилучшего приближения является:

$$\sum_{r=1}^k (x_{ir+1} - a_0'x_{ir-1} - \dots - a_{m-1}'x_{ir-(m-1)} - a_m')^2 \rightarrow \min. \quad (2)$$

Коэффициенты a_i' являются значениями a_i ; фиксированные значения этих коэффициентов определяются на основе минимизации выражения (2).

В целях установки однослойной нейронной сети в m -хронологию (x_n^m, y_n^m) можно выбрать ближайшую точку k , которая максимизирует следующее выражение:

$$p(x_t^m, x_n^m) + p(y_t^m, y_n^m), i = m, m+1, \dots, n \rightarrow \max. \quad (3)$$

Выражение (3) при максимизации даёт возможность получить набор k одновременной m – хронологии в обоих рядах:

$$\begin{matrix} x_{i1}^m, & y_{i1}^m \\ x_{i2}^m, & y_{i2}^m \\ \dots\dots\dots & \\ x_{ik}^m, & y_{ik}^m \end{matrix}.$$

С применением классического МНК определяем прогнозные значения для x_{n+1} и y_{n+1} :

$$x_{n+1}^f = a_0'x_n + a_1'x_{n-1} + \dots + a_{m-1}'x_{n-(m-1)} + a_m',$$

$$y_{n+1}^f = b_0'y_n + b_1'y_{n-1} + \dots + b_{m-1}'y_{n-(m-1)} + b_m'.$$

Известно, что на временных рядах x_t – линейная регрессия x_{ir+1} к

$$x_{ir}^m = (x_{ir}^m = (x_{ir}, x_{ir-1}, \dots, x_{ir-(m-1)} (r = 1, \dots, k)) :$$

$$\sum_{r=1}^k (x_{ir+1} - a_0x_{ir-1} - \dots - a_{m-1}x_{ir-(m-1)} - a_m)^2,$$

$$\sum_{r=1}^k (y_{ir+1} - b_0y_{ir-1} - \dots - b_{m-1}y_{ir-(m-1)} - b_m)^2.$$

Известно, что в зависимости от характера прогнозируемого объекта нейронная сеть может быть одно- или многослойной. В нашем исследовании в процессе прогнозирования используется метод однослойной нейронной сети.

Однослойная структура нейронной сети означает, что нейроны связаны таким образом, что сигнал входящего слоя передается непосредственно сигналу выходящего слоя. То есть в этом случае нейронные сигналы входящего слоя позволяют одновременно выполнять необходимые вычисления между входящим и выходящим слоями и получать искомый результат [10].

Однослойный нейрон способен выполнять простые вычисления, а основной функцией нейронной сети является выполнение вычислений в результате взаимодействия друг с другом нейронов нескольких входящих слоев. При прогнозировании потребления электроэнергии с использованием метода искусственного нейрона однослойный перцептрон представляет собой простую сеть, состоящую из

группы нейронов, составляющих этот слой. Каждые новые исходные данные, поступающие на входящий слой, кодируются с использованием вектора значений и передаются нейрону следующего слоя. В свою очередь, нейроны вычисляют и выходят независимо друг от друга.

Известно, что потребление электроэнергии промышленными предприятиями, в том числе металлургическими, работающими в непрерывном режиме, является относительно стабильным, и в силу особенностей технологического процесса эти показатели во времени изменяются в узких пределах. Это означает, что закономерности изменения потребления электроэнергии при любом объеме производства сохраняются. Именно данная особенность таких предприятий позволяет с высокой точностью определять прогнозные показатели потребления электроэнергии. Однако в силу особенностей технологического процесса в некоторых случаях наблюдаются резкие изменения объемов потребления электроэнергии. Для этих случаев при выборе состава и количества исходных данных при прогнозировании потребления электроэнергии требуется их углубленный анализ во избежание чрезмерно резких изменений показателей. Это, в свою очередь, обеспечивает качественный процесс обучения нейронной сети.

ИНС с LSTM является энергоэффективной благодаря своей способности изучать долгосрочные корреляции, эффективно обрабатывать данные временных рядов, автоматически изучать функции сложных последовательностей и адаптироваться к изменяющимся входным данным. Архитектура LSTM включает три основные составляющие: “forget gate”, “input gate” и “output gate” (рис. 1) [10–12].




Рис. 1. Архитектура LSTM

Fig. 1. LSTM architecture

Известно, что в процессе LSTM-обучения данные выходящего слоя сначала сортируются. В этом процессе используется сигма-функция. В процессе сортировки нестационарные исходные данные исключаются, а оставшиеся данные перемещаются на следующий шаг. Сортировка данных выполняется с использованием следующего выражения [10]:

$$f_t = \sigma(W_f[h_{t-1}, \alpha_t] + b_f),$$

где W_f – входной весовой коэффициент; h_t – выходной вектор; b_f – порог входного слоя.

В следующем процессе обучаются выбранные исходные данные для определения показателя прогноза и определяются допустимые их значения. В этом процессе используются сигма- и тангенсная функции:

$$\begin{aligned} i_t &= \sigma(W_i[h_{t-1}, x_t] + b_i), \\ \tilde{C}_t &= \tan(W_c[h_{t-1}, x_t] + b_c), \end{aligned}$$

где x_t – входящий слой временного ряда; b_i и b_c – пороги нейрона.

На основе выбранных данных в результате исследования сети нейроны в выходящем слое идентифицируются путём систематического комбинирования сигма- и тангенсной функций. То есть в этом процессе определяется результат прогноза:

$$\begin{cases} O_t = \sigma(W_o[h_{t-1}, x_t] + b_o); \\ h_t = O_t \cdot \tan(C_t), \end{cases}$$

где O_t – выбранные с помощью функции сигма исходные данные; h_t – выходящий слой нейрона.

При прогнозировании потребления электроэнергии методом ИНС важно сначала выбрать структуру нейронной сети, т. е. определить количество входящих и выходящих слоев в выбранной структуре и количество нейронов в каждом слое.

В качестве первичных данных приняты 100 случайно выбранных из 1000 трехлетних данных о расходе электроэнергии в протокольных процессах плавки стали. При этом выбранные данные проверялись по закону распределения Гаусса, а случайные выборки повторялись с помощью оператора цикла до тех пор, пока значение эксцесса не стало близким к трем, а значение асимметрии – близким к нулю.

Таким образом, в качестве первичных данных параметров входящего слоя вводятся данные расхода электроэнергии в процессе 100 протокольных плавки стали. Это характеризует количество выходящих и входящих нейронов, т.е. потребление электроэнергии прогнозируется на основе показателей 100 выходящих нейронов, соответствующих 100 входящим нейронам.

Обучения нейронной сети при прогнозировании электропотребления промышленными предприятиями, в частности металлургическим предприятием,

осуществляется «учителем» по алгоритму обратного распространения ошибок. Процесс обучения нейронной сети состоит из двух этапов, в которых характер обучения зависит от состава и количества данных, изначально находящихся во входящем слое.

На первом этапе периодичность поступления исходных данных в базу данных составляет годы. На втором этапе исследования в базе данных периодичность исходных данных соответствует дням и месяцам. На всех этапах длительность процесса изучения зависит от количества данных в исходной базе данных [13].

Во время обучения нейронной сети осуществляется ее настройка на эталонные значения. Этот процесс выполняется путём корректировки весовых коэффициентов, которая, в свою очередь, осуществляется на основе минимизации функциональных ошибок.

Функциональная ошибка характеризует разницу между эталонным значением и значениями выходного сигнала и определяется с помощью следующего выражения [14]:

$$E = \frac{1}{2} \sum_p (y_0^{(p)} - t_0^{(p)})^2,$$

где p – номер входного слоя; $y_0^{(p)}$ – значение выходного слоя; $t_0^{(p)}$ – эталонное значение.

Процесс обучения продолжается до тех пор, пока выходящие значения сигналов из нейронной сети не приблизятся к эталонным значениям.

Корректировка весов – один из наиболее важных процессов при обучении с использованием ИНС. Он обычно выполняется не для каждого входного параметра, а для небольших групп входных параметров. Такая корректировка весовых коэффициентов ускоряет процесс обучения. Для определения весовых коэффициентов рекомендуется выполнять около сотни итераций, обеспечивающих уменьшение ошибки прогнозирования [14–16].

На рис. 2 приведена блок-схема алгоритма построения прогнозных моделей электропотребления с использованием метода ИНС с LSTM, где подробно представлены этапы разработки моделей с применением реализованного на актуальном и наиболее востребованном в настоящее время языке программирования Python 3.9 [17].

Из блок-схемы (рис. 3) видно, что при прогнозировании с применением метода ИНС с LSTM основным условием успешности процесса является правильный выбор показателей Ерощ и среднеквадратичная ошибка. Данная блок-схема составлена на основе универсального алгоритма построения модели прогнозирования электропотребления с использованием метода ИНС с LSTM. Он пригоден для прогнозирования электропотребления не только исследуемым предприятием, но и другими промышленными предприятиями.




Рис. 2. Блок-схема алгоритма построения модели прогнозирования электропотребления с использованием метода ИНС LSTM

Fig. 2. Flowchart of the algorithm for constructing an electricity power consumption forecasting model using Artificial neural network (ANN) by the LSTM method

Таблица. Фактические и прогнозные величины электропотребления
Table. Actual and forecast values of electrical consumption

№ процесса плавки Melting process no.	$W_{ф}/W_{ас}$	$W_{прог}/W_{for}$	MAD	MAPE	SA	AMSE	BIAS	MAE	RMSE	MSE
	кВт·с kW·h	кВт·с kW·h								
1	32748	33154,75	406,75	1,24	0,460080368	1,543	0,36351493	0,001257361	0,002366204	0,749637955
5	33452	33749,07	297,07	0,89		0,789				
10	35050	35204,47	154,46	0,44		0,194				
15	35218	35363,07	145,07	0,41		0,170				
20	35492	35622,98	130,98	0,37		0,136				
25	35526	35655,33	129,33	0,36		0,133				
30	35980	36088,18	108,18	0,30		0,090				
35	36152	36252,40	100,40	0,28		0,077				
40	37790	37796,09	6,09	0,02		0,000				
45	38008	37995,94	12,06	0,03		0,001				
50	36928	36990,59	62,59	0,17		0,029				
55	36654	36730,80	76,80	0,21		0,044				
60	35848	35962,19	114,19	0,32		0,101				
65	36176	36275,31	99,31	0,27		0,075				
70	36262	36388,31	126,31	0,35		0,121				
75	36788	36840,32	52,32	0,14		0,020				
80	36838	36819,58	18,42	0,05		0,002				
85	37850	37827,43	22,57	0,06		0,004				
90	37946	37914,94	31,06	0,08		0,007				
95	40008	39684,62	323,38	0,81		0,653				
100	41388	41300,00	88,00	0,21		0,045				

Результаты прогнозной модели приведены в таблице, где сравниваются фактические и прогнозные значения расхода электроэнергии в процессах плавки стали. Расчеты были осуществлены для всех 100 точек прогнозирования. В таблице применен шаг в 5 единиц, также при оценке прогнозной модели ошибки прогнозирования были определены по 100 точкам прогнозирования.

Известно, что для получения модели прогнозирования с наименьшей погрешностью прогнозные и фактические значения сравниваются несколько раз, и на этом основании выбирается модель для

прогнозирования. Исходя из этого, результат модели с наименьшей погрешностью приведен на рис. 3.

Для более глубокого исследования адекватности разработанной модели прогнозирования электропотребления осуществлены расчеты погрешности моделей по ошибкам MAD, MAPE, SA, AMSE, BIAS, MAE, RMSE, MSE. Результаты приведены в таблице. Результаты приведенных ошибок показывают, что разработанная модель имеет минимальные значения. Это подтверждает целесообразность применения прогнозных моделей электропотребления, разработанных на основе ИНС с LSTM.




Рис. 3. Сравнение фактической и прогнозной величин электропотребления по разработанной модели по методу LSTM
Fig. 3. Comparison of actual and forecasted electricity power consumption values using the developed model based on LSTM

На рис. 3 представлены графики прогнозных и фактических объёмов электроэнергии, потребленной металлургическим предприятием за отчётный период, определенные на основе модели прогнозирования, разработанной, в свою очередь, с использованием метода ИНС с LSTM. Почти полное совпадение кривых свидетельствует о высокой точности разработанной модели.

С целью оценки адекватности модели прогнозирования были сопоставлены полученные при этом результаты с фактическими данными о расходе электроэнергии для 100 протокольных плавок. Результаты приведены в графическом виде (рис. 3). Ошибки зна-

чений, оцененных с помощью этой модели, были разделены для обучающих (train) и тестовых (test) значений, как показано на рис. 4. Чтобы уловить основные характеристики и изменчивость данных временных рядов, важно правильно разделить их на тестовую (test) и обучающую (train) части. Для эффективного обучения набора данных временных рядов значения обучающего (train) ряда были выбраны равными 67 %, а тестовые (test) значения – 33 %. Такое разделение обеспечивает хорошее понимание ключевых входных данных модели и имеет достаточное количество тестовых значений для оценки ее прогнозирующей способности [18–21].




Рис. 4. Зависимость относительной ошибки от порядкового номера для прогнозирования

Fig. 4. Dependence of a relative error on the order number for forecasting

При выборе параметра *epoch* модели был принят минимальный предел ошибки RMSE для значения *epoch* (рис. 5). В данном случае ошибка вычислялась путем изменения значения *epoch* в диапазоне от 0 до 110 с помощью оператора цикла.




Рис. 5. График изменения среднеквадратичной ошибки при обучении LSTM

Fig. 5. Graph of Root Mean Square Error changes during LSTM training

Анализ графика, представленного на рис. 5, показывает, что из выбранных в процессе окончательного и проверочного обучения 100 выборок нейронная сеть была насыщена уже в периоде 90; процесс обучения был остановлен на этом этапе.

Заключение

На основании результатов вышеприведённых расчётов можно сделать вывод о том, что использование метода ИНС с LSTM при прогнозировании потребления электроэнергии даёт возможность рассчитывать показатели прогноза с высокой точностью. Это обеспечивается прежде всего тем, что этот метод имеет возможность обучения и адаптации к процессу прогнозирования потребления электроэнергии. Разработка моделей прогнозирования с использованием этого метода – более сложный процесс по сравнению с рассмотренными выше методами. Правильный подбор состава входных слоёв и исключение различных возможных случаев обеспечивает успешное завершение расчётов. Это также следует из анализа графиков погрешностей показателей, определённых с помощью

данной методики (рис. 4). Кроме этого, ИНС с LSTM имеет способность изучать долгосрочные корреляции и лучше осваивать корреляцию между данными во временных рядах прогнозирования. Известно, что показатели электропотребления

имеют сложный закон изменения. ИНС с LSTM способна автоматически учитывать особенности таких больших объемов сложных временных рядов и обрабатывать их, одновременно управляя несколькими переменными.

СПИСОК ЛИТЕРАТУРЫ/REFERENCES

1. Hinton G.E., Salakhutdinov R.R. Reducing the dimensionality of data with neural networks. *Science*, 2006, vol. 313, no. 5786, pp. 504–507.
2. Graves A., Mohamed A., Hinton G. Speech recognition with deep recurrent neural networks. *Proc. IEEE Int. Conf. on Acoustics, Speech and Signal Processing*, 2013. pp. 6645–6649.
3. Tao L., Zhang P., Wang Z., AlSkaif A., Zeiler W. Deep learning for household load forecasting – a novel pooling deep RNN. *IEEE Transactions on Smart Grid*, 2019, vol. 10, no. 5, pp. 5371–5380.
4. Jyoti M., Saswat D. Forecasting energy consumption using hybrid CNN and LSTM auto-encoder network with hyperband optimization. *International Journal for Research in Applied Science and Engineering Technology*, 2022, vol. 10, pp. 1041–1055. DOI: 10.22214/ijraset.2022.47136.
5. Shariff S. Autoregressive Integrated Moving Average (ARIMA) and Long Short-Term Memory (LSTM) network models for forecasting energy consumptions. *European Journal of Electrical Engineering and Computer Science*, 2022, vol. 6, pp. 7–10. DOI: 10.24018/ejece.2022.6.3.435.
6. Yan Ke, Li Wei, Ji Zhiwei, Qi Meng, Du Yang. A hybrid LSTM neural network for energy consumption forecasting of individual households. *IEEE Access*, 2019, vol. 7, pp. 1. DOI: 10.1109/ACCESS.2019.2949065
7. Jiang C., Qin Z., Zhou M., Sichitiu Y.L. Deep solar learning: integrating solar and meteorological big data archives with deep neural networks for probabilistic solar power forecasting. *IEEE Access*, 2018, vol. 6, pp. 76711–76724.
8. Amjady S., Keynia H. Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm. *Energy*, 2009, vol. 34, no. 1, pp. 46–57.
9. Zhang H., Zhang J., Zhang W. A review on deep learning applications in prognostics and health management. *IEEE Access*, 2019, vol. 7, pp. 142600–142611.
10. Kong W., Dong Z. Y., Jia Y., Hill D.J., Xu Y., Zhang Y. Short-term residential load forecasting based on LSTM recurrent neural network. *IEEE Transactions on Smart Grid*, 2017, vol. 10 (1), pp. 841–851. Available at: <https://doi.org/10.1109/TSG.2017.2753803> (accessed 15 September 2023).
11. Varsha S., Abhishek K., Sharik G., Shashwat M., Shubhendra K., Uma Shanker T. *Household power consumption analysis and prediction using LSTM*. 2023 Available at: https://books.google.ru/books?id=2HbkEAAQBAJ&pg=PA145&lpg=PA145&dq=10.1007/978-981-99-6702-5_12&source=bl&ots=SPB7bhbybJ&sig=ACfU3U2OQ_imfOzg5KJDg0HvqLAqCox4eA&hl=ru&sa=X&ved=2ahUKEwjMxbb rv4GDAXWhPhAIHWYEAkYQ6AF6BAgJEAM#v=onepage&q=10.1007%2F978-981-99-6702-5_12&f=false (accessed 15 September 2023).
12. Zhang C., Wu J., Zhou Y., Cheng M., Long C. A hybrid method for short-term power load prediction using LSTM network and stacked autoencoder. *IEEE Transactions on Sustainable Energy*, 2018, vol. 9 (4), pp. 1683–1691. Available at: <https://doi.org/10.1109/TSTE.2018.2811486> (accessed 15 September 2023).
13. Liyana Nur, Dhanasegaran Jeeva, Alkawsu Gamal, Alkahtani Ammar, Chai Chen, Mohamed Yahia, Capretz Luiz, Al-Shetwi Ali, Tiong Sieh. *Investigating the Power of LSTM-Based Models in Solar Energy Forecasting*, 2023, vol. 11, 2382. DOI: 10.3390/pr11051382
14. Gridin V.N., Doenin V.V., Panishchev V.S., Bysov I.D. Neural network for predicting the load of energy consumption of the sorting unit. *World of transport*, 2019, vol. 17, no. 3, pp. 6–15.
15. Liang X., Hu Z., Zhang Z. Deep learning for peak demand forecasting in smart grids. *IEEE Transactions on Industrial Informatics*, 2019, vol. 15, no. 10, pp. 5708–5716.
16. Mazinani M., Vahidinasab M., Vahidinasab A. Multi-step ahead electricity price forecasting using a hybrid model based on 2D convolutional neural networks and bidirectional LSTM. *Applied Energy*, 2020, vol. 268, pp. 114920–11924.
17. Wang F., Liang J., Zhang Y. Load forecasting with long short-term memory based recurrent neural network: a case study of ERCOT energy market. *IEEE Transactions on Industrial Electronics*, 2020, vol. 67, no. 2, pp. 1577–1586.
18. Dudek G., Pelka P., Smyl S. *3ETS+RD-LSTM: A new hybrid model for electrical energy consumption forecasting*, 2020. DOI: 10.1007/978-3-030-63836-8_43
19. Bişkin O.T., Çifci A. Forecasting of Turkey's electrical energy consumption using LSTM and GRU Networks. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 2021, vol. 8, pp. 656–667. DOI: 10.35193/bseufbd.935824.
20. Rakhmonov I.U., Reymov K.M. Regularities of change of energy indicators of the basic technological equipment of the cotton-cleaning industry. *Journal of Physics: Conference Series. APITECH-2019*, 2019. DOI: 10.1088/1742-6596/1399/5/055038.
21. Taslimov A.D., Rakhmonov I.U. Optimization of complex parameters of urban distribution electric networks. *Journal of Physics: Conference Series. APITECH-2019*, 2019. DOI: 10.1088/1742-6596/1399/5/055046.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Икромжон Усмонович Рахмонов, доктор технических наук, профессор, заведующий кафедрой электроснабжения Ташкентского государственного технического университета, Узбекистан, 100095, г. Ташкент, ул. Университетская, 2. ilider1987@yandex.ru; <http://orcid.org/0000-0003-2076-5919>

Василий Яковлевич Ушаков, заслуженный деятель науки и техники РФ, доктор технических наук, профессор Инженерной школы энергетики Национального исследовательского Томского политехнического университета, Россия, 634050, г. Томск, пр. Ленина, 30. vyush@tpu.ru

Нуъмон Низомиддинович Ниёзов, доктор философии по техническим наукам, доцент кафедры электроснабжения Ташкентского государственного технического университета, Узбекистан, 100095, г. Ташкент, ул. Университетская, 2. nomon.niyozov_2422@mail.ru; <http://orcid.org/0000-0002-1031-3460>

Нурбек Нурулло угли Курбонов, доктор философии по техническим наукам, доцент кафедры электроснабжения Ташкентского государственного технического университета, Узбекистан, 100095, г. Ташкент, ул. Университетская, 2. nurbek.kurbonov.96@gmail.com; <http://orcid.org/0009-0006-5400-3532>

Поступила в редакцию: 25.09.2023

Поступила после рецензирования: 08.11.2023

Принята к публикации: 30.11.2023

INFORMATION ABOUT THE AUTHORS

Ikromjon U. Rakhmonov, Dr. Sc., Professor, Tashkent State Technical University, 2, Universitetskaya street, Tashkent, 100095, Uzbekistan. ilider1987@yandex.ru; <http://orcid.org/0000-0003-2076-5919>

Vasily Ya. Ushakov, Dr. Sc., Professor, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation. vyush@tpu.ru

Numon N. Niyozov, PhD, Associate Professor, Tashkent State Technical University, 2, Universitetskaya street, Tashkent, 100095, Uzbekistan. nomon.niyozov_2422@mail.ru; <http://orcid.org/0000-0002-1031-3460>

Nurbek N. Kurbonov, PhD, Associate Professor, Tashkent State Technical University, 2, Universitetskaya street, Tashkent, 100095, Uzbekistan. nurbek.kurbonov.96@gmail.com; <http://orcid.org/0009-0006-5400-3532>

Received: 25.09.2023

Revised: 08.11.2023

Accepted: 30.11.2023