

<https://doi.org/10.21122/1029-7448-2023-66-1-18-29>

УДК 621.311

## Оперативное прогнозирование скорости ветра для автономной энергетической установки тяговой железнодорожной подстанции

П. В. Матренин<sup>1, 2)</sup>, А. И. Хальясмаа<sup>1, 2)</sup>, А. Г. Русина<sup>1)</sup>, С. А. Ерошенко<sup>1, 2)</sup>,  
Н. А. Попкова<sup>3)</sup>, Д. А. Секацкий<sup>3)</sup>

<sup>1)</sup>Новосибирский государственный технический университет (Новосибирск, Российская Федерация),

<sup>2)</sup>Уральский федеральный университет имени первого Президента России Б. Н. Ельцина (Екатеринбург, Российская Федерация),

<sup>3)</sup>Белорусский национальный технический университет (Минск, Республика Беларусь)

© Белорусский национальный технический университет, 2023  
Belarusian National Technical University, 2023

**Реферат.** В настоящее время рассматриваются перспективы создания гибридных энергетических установок с использованием возобновляемых источников энергии, в том числе энергии ветра, и систем накопления энергии на базе технологий водородной энергетики. Для управления такой системой накопления энергии необходимо оперативное прогнозирование генерации от возобновляемых источников, в частности ветровых энергетических установок. Их выработка зависит от скорости и направления ветра. В статье представлены результаты решения задачи оперативного прогнозирования скорости ветра для проекта гибридной энергетической установки, направленной на повышение пропускной способности железнодорожного участка между станциями Яя и Ижморская (Кемеровская область Российской Федерации). Проанализированы почасовые данные скоростей и направлений ветра за 15 лет, построена нейросетевая модель и предложена компактная архитектура многослойного перцептрона для краткосрочного прогнозирования скорости и направления ветра на 1 и 6 ч вперед. Разработанная модель позволяет минимизировать риски переобучения и потери точности прогнозирования из-за изменения условий работы модели со временем. Особенность данной статьи заключается в исследовании устойчивости модели, обученной на данных многолетних наблюдений, к долгосрочным изменениям, а также анализе возможностей повышения точности прогнозирования за счет регулярного дообучения модели на вновь поступающих данных. Установлен характер влияния размера обучающей выборки и самоадаптации модели на точность прогнозирования и устойчивость ее работы на горизонте в несколько лет. Показано, что для обеспечения высокой точности и устойчивости нейросетевой модели прогнозирования скорости ветра необходимы данные многолетних метеорологических наблюдений.

**Ключевые слова:** прогнозирование скорости ветра, ветроэнергетика, система электрификации железных дорог, нейронные сети

**Для цитирования:** Оперативное прогнозирование скорости ветра для автономной энергетической установки тяговой железнодорожной подстанции / П. В. Матренин [и др.] // *Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ*. 2023. Т. 66, № 1. С. 18–29. <https://doi.org/10.21122/1029-7448-2023-66-1-18-29>

---

### Адрес для переписки

Секацкий Дмитрий Александрович  
Белорусский национальный технический университет  
просп. Независимости, 65/2,  
220013, г. Минск, Республика Беларусь  
Тел.: +375 17 292-65-82  
dsekatski@gmail.com

### Address for correspondence

Sekatski Dzmitry A.  
Belarusian National Technical University  
65/2, Nezavisimosty Ave.,  
220013, Minsk, Republic of Belarus  
Tel.: +375 17 292-65-82  
dsekatski@gmail.com

---

## Operational Forecasting of Wind Speed for an Self-Contained Power Assembly of a Traction Substation

P. V. Matrenin<sup>1,2)</sup>, A. I. Khalyasmaa<sup>1,2)</sup>, A. G. Rusina<sup>1)</sup>, S. A. Eroshenko<sup>1,2)</sup>,  
N. A. Papkova<sup>3)</sup>, D. A. Sekatski<sup>3)</sup>

<sup>1)</sup>Novosibirsk State Technical University (Novosibirsk, Russian Federation),

<sup>2)</sup>Ural Federal University named after the first President of Russia B. N. Yeltsin  
(Ekaterinburg, Russian Federation),

<sup>3)</sup>Belarusian National Technical University (Minsk, Republic of Belarus)

**Abstract.** Currently, the prospects of creating hybrid power assemblies using renewable energy sources, including wind energy, and energy storage systems based on hydrogen energy technologies are being considered. To control such an energy storage system, it is necessary to perform operational renewable sources generation forecasting, particularly forecasting of wind power assemblies. Their production depends on the speed and direction of the wind. The article presents the results of solving the problem of operational forecasting of wind speed for a hybrid power assembly project aimed at increasing the capacity of the railway section between Yaya and Izhmorskaya stations (Kemerovo region of the Russian Federation). Hourly data of wind speeds and directions for 15 years have been analyzed, a neural network model has been built, and a compact architecture of a multilayer perceptron has been proposed for short-term forecasting of wind speed and direction for 1 and 6 hours ahead. The model that has been developed allows minimizing the risks of overfitting and loss of forecasting accuracy due to changes in the operating conditions of the model over time. A specific feature of this work is the stability investigation of the model trained on the data of long-term observations to long-term changes, as well as the analysis of the possibilities of improving the accuracy of forecasting due to regular further training of the model on newly available data. The nature of the influence of the size of the training sample and the self-adaptation of the model on the accuracy of forecasting and the stability of its work on the horizon of several years has been established. It is shown that in order to ensure high accuracy and stability of the neural network model of wind speed forecasting, long-term meteorological observations data are required.

**Keywords:** wind speed forecasting, wind power, railway electrification system, neural networks

**For citation:** Matrenin P. V., Khalyasmaa A. I., Rusina A. G., Eroshenko S. A., Papkova N. A., Sekatski D. A. (2023) Operational Forecasting of Wind Speed for an Self-Contained Power Assembly of a Traction Substation. *Energetika. Proc. CIS Higher Educ. Inst. and Power Eng. Assoc.* 66 (1), 18–29. <https://doi.org/10.21122/1029-7448-2023-66-1-18-29> (in Russian)

### Введение

Технические ограничения, накладываемые максимальной пропускной способностью линий электропередачи и трансформаторного оборудования тяговых подстанций, вследствие большей распределенности точек потребления электроэнергии кардинально отличаются от технических ограничений, учитываемых в системах электроснабжения крупных промышленных предприятий или населенных пунктов. Основное отличие заключается в большой протяженности участков электрической сети между тяговыми подстанциями. Тяжелые железнодорожные составы являются мощными потребителями электрической энергии, ограничивающими пропускную способность линий электропередачи, максимальную потребляемую мощность и электроэнергию, что выражается в падении напряжения и снижении скорости движения состава.

Использование автономных энергетических установок, в том числе на возобновляемых источниках энергии, позволяет системам электроснабжения железнодорожного транспорта не только минимизировать провалы напряжения, но и повысить экологичность, снизив углеродный след. Особенно это актуально для протяженных межподстанционных участков, где существенны потери электроэнергии при ее передаче от подстанций к локомотиву. Провалы напряжения приводят к снижению скорости движения состава и отставанию от графика [1]. По этим причинам возникает необходимость разработки и внедрения дополнительной силовой энергетической установки, способной компенсировать провалы напряжения [2, 3]. В качестве такого источника питания обычно используют энергию солнца [3–6] и ветра [6–8], что в сочетании с аккумулирующими электроустановками [9, 10] позволяет решать задачу снижения углеродного следа, поставленную в Стратегии научно-технического развития холдинга «Российские железные дороги» на период до 2020 г. и перспективу до 2025 г. [11].

Так, например, если просадка напряжения не приводит к критичному отставанию состава средней тяжести, для ее компенсации можно направить электроэнергию автономных гибридных энергетических установок (АГУЭ). Они генерируют электроэнергию за счет энергии ветра или солнца, запасаемой в накопитель, чтобы использовать в электрической сети для минимизации просадок напряжения. Но если в накопителе объем запасенной энергии мал, в ближайший час скорость ветра ожидается низкой и по графику будет двигаться тяжелый состав, накопленную энергию следует оставить для обеспечения его прохождения. В другом случае может оказаться, что накопитель энергии заполнен, а в ближайший час скорость ветра будет высокой. Следовательно, можно использовать накопленную энергию, даже если не возникает провалов напряжения, для снижения электропотребления от внешней сети.

### **Основная часть**

Оперативное прогнозирование скорости ветра – нетривиальная задача, поскольку в каждом конкретном случае ее решение зависит не только от климатических особенностей местности, абсолютной и относительной высоты, формы рельефа и экспозиции склона по отношению к ветровому потоку, но и от доступности различных метеорологических данных и требуемого горизонта прогнозирования.

Для прогнозирования скорости ветра применяют несколько основных групп методов [12, 13]:

- построение физических метеорологических моделей. Этот подход может обеспечить необходимую точность прогноза, но предъявляет высокие требования к метеорологическим данным и отличается высокой вычислительной сложностью;
- статистические методы обработки временных рядов, достоинствами которых являются низкая вычислительная сложность и низкий риск переобучения модели, но их точность не всегда удовлетворительна;

• методы машинного обучения [13–15], позволяющие достичь высокой точности в лабораторных условиях для определенной выборки данных. Однако при их использовании возникают проблемы переобучения и снижения надежности [13, 16].

Объект исследования – протяженный участок железной дороги между станциями Яя и Ижморская в Кемеровской области (Российская Федерация). На рис. 1, 2 представлены диаграммы распределения ветра по скорости и направлениям за 2020–2022 гг. Анализ показывает, что скорость ветра относительно небольшая, а его направление отличается стабильностью.

В задачах прогнозирования временных рядов в электроэнергетике важна адаптация моделей к новым условиям функционирования, обусловленным изменением климатического состояния окружающей среды или режима работы объекта [16, 17]. Для повышения возможностей и точности прогнозирования за счет регулярного дообучения модели на поступающих данных проводится исследование устойчивости модели, обученной на данных многолетних наблюдений, к долгосрочным изменениям. Необходимо выполнять настройку на длительных интервалах, поскольку достижение высокой точности на коротком тестовом сроке (не более одного года) не является достаточным основанием полагать, что модель можно эксплуатировать и в последующие годы.

Для обучения и валидации прогнозной модели использована выборка 131472 почасовых значений скорости ветра за 2007–2021 гг. [18]. Данные для населенного пункта Яя приведены на рис. 1. Хотя установка АГЭУ предполагается между станциями [2], скорость ветра с допустимой погрешностью можно считать одинаковой в середине участка и его крайних точках.




Рис. 1. Диаграмма повторяемости скорости ветра

Fig. 1. Wind speed repeatability histogram

Выбранный авторами подход к построению нейросетевой модели прогнозирования скорости ветра на час вперед описан в [13]. Архитектура нейронной сети, полученная в процессе ее настройки на решаемую задачу, включает: входные значения, вектор из 12 ретроспективных скоростей ветра; первый входной слой из 16 нейронов; второй скрытый слой из 8 нейронов; третий скрытый слой из 4 нейронов; выходной нейрон. Нейроны первого – третьего слоев используют функцию активации ReLU [19, 20], выходной – сигмоидальную функцию. Для эффективной оптимизации в обучении нейронной сети применяется метод Adam. Кроме того, для предотвращения переобучения используется L2-регуляризация. Программная реализация выполнена на языке Python 3, нейронная сеть создана на основе библиотеки Keras.




Рис. 2. Роза ветров

Fig. 2. Wind rose

Использованы следующие показатели, характеризующие точность прогнозирования:

- среднеквадратичное отклонение (root mean squared error – RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^*(y_{[i-w:i-1]}))^2}; \quad (1)$$

- среднее значение модулей отклонения (mean absolute error – MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_i^*(y_{[i-w:i-1]})|; \quad (2)$$

- нормализованное среднее значение модулей отклонения (normalized mean absolute error –  $nMAE$ )

$$nMAE = \frac{\sum_{i=1}^n |y_i - y_i^*(y_{[i-w:i-1]})|}{\sum_{i=1}^n y_i} \cdot 100 \% \quad (3)$$

где  $y$  – истинное значение скорости ветра в  $i$ -й час;  $y^*$  – прогнозное значение скорости ветра на  $i$ -й час;  $y_{[i-w:i-1]}$  – вектор истинных почасовых значений скорости ветра за предыдущие  $w$  часов;  $w$  – количество часов, длительность временного ряда, который используется для модели;  $n$  – размер выборки для вычисления ошибки.

Вычислительные эксперименты выполняли по приведенному ниже алгоритму.

1. Создание нейросетевой модели для прогнозирования скорости ветра на 1 ч вперед: обучение модели на данных за 10 лет (2007–2016 гг.), валидация для настройки гиперпараметров на данных 2017–2018 гг. Длительность обучения 200 итераций (эпох). Модель обозначена как  $ANN_0$  (artificial neural network – искусственная нейронная сеть).

2. Тестирование обученной модели на данных 2019–2021 гг. с сохранением результатов, метрик точности в соответствии с выражениями (1)–(3) за каждый месяц.

3. Адаптация модели в режиме дообучения ( $ANN_U$ ) на данных предыдущих трех лет (200 эпох), затем тестирование на данных за один месяц. Таким образом, модель учитывает новые данные каждый месяц. Например, для тестирования модели на информации за май 2019 г. она дообучалась на данных с апреля 2016 г. по апрель 2019 г. включительно.

4. Работа модели в режиме обучения с нуля на скользящем окне ( $ANN_R$ ). Тестовый период 2019–2021 гг. Обучение на данных предыдущих трех лет (200 эпох), затем тестирование на данных за один месяц. Аналогично пункту 3, но в режиме обучения с нуля для каждого следующего месяца.

5. Применение интегрированной модели Бокса – Дженкинса (autoregressive integrated moving average – ARIMA) на данных 2019–2021 гг. для сопоставления результатов. ARIMA выбрана, так как является моделью статистического анализа, а не машинного обучения, и широко используется в прогнозировании в энергетике [21].

6. Повторение пунктов 1–5 для прогноза на 6 ч вперед.

Результаты экспериментов для прогнозирования скорости ветра, приведенные в табл. 1–3 и на рис. 3–5, позволяют сделать следующие выводы:

- точность краткосрочного прогнозирования скорости ветра на 1 ч достаточна для оперативного управления автономной энергетической установкой, так как средняя ошибка менее 6 %;
- нейросетевая модель может использоваться длительный период (для данных последующих трех лет) после обучения даже без адаптации, по-

скольку модель, обученная на данных 2007–2016 гг., показала практически одинаковую точность на валидационной (2017–2018 гг.) и тестовой (2019–2021) выборках;

- дообучение нейросетевой модели на новых данных снижает ошибку прогнозирования. Снижение является небольшим, но для его достижения достаточно лишь раз в месяц запускать дообучение модели на новых данных;

- обучение модели с нуля на относительно небольшом количестве новых данных (три года) оказалось наименее эффективным вариантом. Это показывает, что длительность обучающей выборки в рассматриваемой задаче – более важный фактор, чем новизна используемой информации.

Таблица 1

**Результаты прогнозирования скорости ветра на валидационной выборке (2017–2018 гг.)**

**The results of wind speed forecasting on the validation set (2017–2018)**

Модель	Гиперпараметры		
	Среднее значение модулей отклонения MAE, m/s	Нормализованное среднее значение модулей отклонения $n$ MAE, %	Среднеквадратичное отклонение RMSE, m/s
ANN <sub>0</sub> , 1 ч вперед	0,421	5,26	0,650
ANN <sub>0</sub> , 6 ч вперед	1,841	23,03	2,423

Таблица 2

**Результаты прогнозирования скорости ветра на 1 ч вперед на тестовой выборке (2019–2021 гг.)**

**The results of 1-hour wind speed forecasting on the test sampling of the set (2019–2021)**

Модель	Гиперпараметры		
	Среднее значение модулей отклонения MAE, м/с	Нормализованное среднее значение модулей отклонения $n$ MAE, %	Среднеквадратичное отклонение RMSE, м/с
ANN <sub>0</sub>	0,419	5,78	0,650
ANN <sub>U</sub>	0,397	5,41	0,612
ANN <sub>R</sub>	0,618	8,45	0,867
ARIMA	0,440	6,16	0,716

Таблица 3

**Результаты прогнозирования скорости ветра на 6 ч вперед на тестовой выборке (2019–2021 гг.)**

**The results of 6-hour wind speed forecasting on the test sampling of the set (2019–2021)**

Модель	Гиперпараметры		
	Среднее значение модулей отклонения MAE, м/с	Нормализованное среднее значение модулей отклонения $n$ MAE, %	Среднеквадратичное отклонение RMSE, м/с
ANN <sub>0</sub>	1,823	24,260	2,356
ANN <sub>U</sub>	1,795	23,780	2,311
ANN <sub>R</sub>	1,886	24,851	2,417
ARIMA	2,310	30,560	2,352




Рис. 3. Изменение среднемесячной ошибки прогнозирования на 1 ч вперед на тестовой выборке

Fig. 3. The change in the average monthly forecasting error for 1 hour ahead on the test sampling




Рис. 4. Изменение среднемесячной ошибки прогнозирования на 6 ч вперед на тестовой выборке

Fig. 4. The change in the average monthly forecasting error for 6 hour ahead on the test sampling

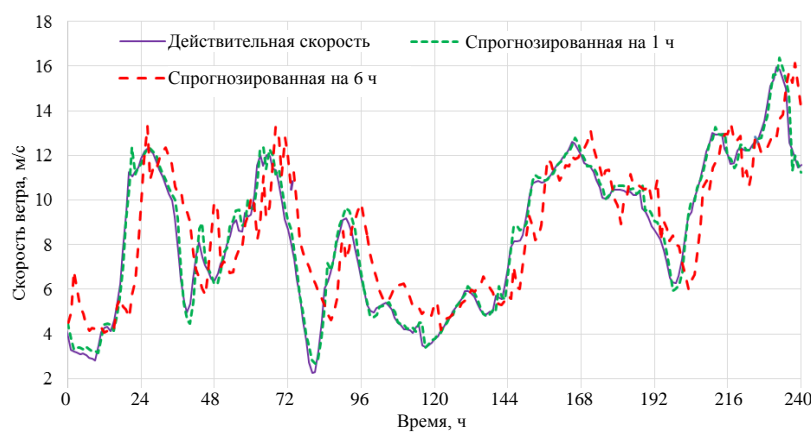


Рис. 5. Сопоставление скорости ветра и прогнозов, полученных нейросетевой моделью с дообучением (показаны последние 10 сут. тестовой выборки)

Fig. 5. Comparison of wind speed and forecasts obtained by a neural network model with additional training (the last 10 days of the test sampling of the set are shown)



Дополнительно выполнено прогнозирование направления ветра на 1 ч вперед нейросетевой моделью в режимах обучения на данных 2007–2018 гг. и тестирования на данных 2019–2021 гг., результаты тестирования приведены в табл. 4. Точность прогнозирования оказалась достаточно высокой, полученная информация может применяться в том числе и для управления поворотами гондолы ветроустановки. Такой подход позволяет снизить погрешность прогнозирования выработки электроэнергии.

Таблица 4

**Результаты прогнозирования скорости ветра на 6 ч вперед  
на тестовой выборке (2019–2021 гг.)**

**The results of 6-hour wind speed forecasting on the test sampling of the set (2019–2021)**

Горизонт прогнозирования, ч	Гиперпараметры		
	Среднее значение модулей отклонения MAE, град.	Нормализованное среднее значение модулей отклонения $n$ MAE, %	Среднеквадратичное отклонение RMSE, град.
1	4,00	2,970	15,47
6	14,28	10,600	25,45

### ВЫВОДЫ

1. Рассмотрена задача краткосрочного прогнозирования скорости и направления ветра для эффективного применения ветроэнергетической установки в составе автономной энергетической установки тяговой железнодорожной подстанции.

2. Исследовано влияние различных режимов адаптации на точность прогнозирования скорости ветра на выборке данных за 15 лет для Кемеровской области. В работе использована компактная многослойная архитектура нейронной сети, что позволило получить высокую точность прогноза с низким риском переобучения и реализовать автоматическое регулярное дообучение нейронной сети в процессе ее эксплуатации (адаптацию модели к долгосрочным изменениям климатических условий).

3. Полученные результаты показывают, что более эффективно дообучение модели на вновь поступающих данных, а не обучение с нуля на новых данных за три последних года. Это говорит о необходимости обучения моделей на длительных выборках, но с постепенной адаптацией к новым данным.

4. Средняя ошибка прогнозирования скорости ветра на 1 ч вперед на тестовой выборке за два года составила 0,4 м/с (5,4 %), направления – 4° (3 %). Такая ошибка позволяет применять ветроэнергетические установки в составе автономной энергетической установки тяговой железнодорожной подстанции, в которой необходимы краткосрочные прогнозы генерации для управления процессом компенсации провалов напряжений при движении тяжелых составов на протяженных участках между подстанциями.

Исследование выполнено при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках Программы развития Уральского федерального университета имени первого Президента России Б. Н. Ельцина в соответствии с программой стратегического академического лидерства «Приоритет-2030».

#### ЛИТЕРАТУРА

1. Power Electronic Transformer-Based Railway Traction Systems: Challenges and Opportunities / J. Feng [et al.] // *IEEE Journal of Emerging and Selected Topics in Power Electronics*. 2017. Vol. 5, Iss. 3. P. 1237–1253. <https://doi.org/10.1109/JESTPE.2017.2685464>.
2. Mitrofanov, S. V. Analysis of the Impact of Autonomous Hybrid Power Plants on the Railways Capacity / S. V. Mitrofanov, D. V. Armeev, E. A. Domahin // *XV International Scientific-Technical Conference on Actual Problems Of Electronic Instrument Engineering (APEIE)*. 2021. P. 161–165. <https://doi.org/10.1109/APEIE52976.2021.9647596>.
3. Energetic Simulation of DC Railway Micro-Grid Interconnecting with PV Solar Panels, EV Charger Infrastructures and Electrical Railway Network / J. Pouget [et al.] // *IEEE Vehicle Power and Propulsion Conference (VPPC)*. 2020. P. 1–7. <https://doi.org/10.1109/VPPC49601.2020.9330829>.
4. Energy Management of a Smart Railway Station Considering Regenerative Braking and Stochastic Behaviour of ESS and PV Generation / İ. Şengör [et al.] // *IEEE Transactions on Sustainable Energy*. 2018. Vol. 9, Iss. 3. P. 1041–1050. <https://doi.org/10.1109/TSTE.2017.2759105>.
5. The Potential of Photovoltaics to Power the Railway System in China / L. Ji [et al.] // *Energies*. 2020. Vol. 13, Iss. 15. P. 3844. <https://doi.org/10.3390/en13153844>.
6. Mitrofanov, S. V. Stationary Hybrid Renewable Energy Systems for Railway Electrification: A Review / S. V. Mitrofanov, N. G. Kiryanova, A. M. Gorlova // *Energies*. 2021. Vol. 14, Iss. 18. P. 5946. <https://doi.org/10.3390/en14185946>.
7. Aguado, J. A. Optimal Operation of Electric Railways With Renewable Energy and Electric Storage Systems / J. A. Aguado, A. J. Sanchez Racero, S. de la Torre // *IEEE Transactions on Smart Grid*. 2018. Vol. 9, Iss. 2. P. 993–1001. <https://doi.org/10.1109/TSG.2016.2574200>.
8. Evaluation of the Influence of Electrified Railway on Wind Farm / F. Ding [et al.] // *IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific)*. 2017. P. 1–6. <https://doi.org/10.1109/ITEC-AP.2017.8080804>.
9. Гринчик, Н. Н. Об измерении электрического сопротивления жидких электролитов аккумуляторных батарей / Н. Н. Гринчик, К. В. Доброго, М. А. Чумаченко // *Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ*. 2018. Т. 61, № 6. С. 494–507. <https://doi.org/10.21122/1029-7448-2018-61-6-494-507>.
10. Доброго, К. В. Моделирование аккумуляторных батарей и их сборок с учетом деградации параметров / К. В. Доброго, Ю. В. Бладыко // *Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ*. 2021. Т. 64, № 1. С. 27–39. <https://doi.org/10.21122/1029-7448-2021-64-1-27-39>.
11. Стратегия научно-технологического развития холдинга «Российские железные дороги» на период до 2025 года и на перспективу до 2030 года (Белая книга) [Электронный ресурс] // *Инновационный дайджест РЖД*. М., 2018. Режим доступа: <https://zszd.rzd.ru/api/media/resources/c/17/121/18071?action=download>. Дата доступа: 21.03.2022.
12. Zhou, Q. Hybrid Forecasting System Based on an Optimal Model Selection Strategy for Different Wind Speed Forecasting Problems / Q. Zhou, C. Wang, G. Zhang // *Applied Energy*. 2019. Vol. 250. С. 1559–1580. <https://doi.org/10.1016/j.apenergy.2019.05.016>.
13. Матренин, П. В. Устойчивое краткосрочное прогнозирование скорости ветра с помощью адаптивных компактных нейронных сетей / П. В. Матренин, В. З. Манусов, Е. А. Игумнова // *Problemele Energeticii Regionale*. 2020. No 3. P. 69–80. <https://doi.org/10.5281/zenodo.4018960>.
14. Current Methods and Advances in Forecasting of Wind Power Generation / A. M. Foley [et al.] // *Renewable Energy*. 2012. Vol. 37, Iss. 1. P. 1–8. <https://doi.org/10.1016/j.renene.2011.05.033>.

15. Zhang, L. Wind Speed Forecasting Using a Two-Stage Forecasting System with an Error Correcting and Nonlinear Ensemble Strategy / L. Zhang, Y. Dong, J. Wang // *IEEE Access*. 2019. Vol. 7. P. 176000–176023. <https://doi.org/10.1109/ACCESS.2019.2957174>.
16. Оптимизация топологии сети с ВИЭ-генерацией на основе модифицированного адаптированного генетического алгоритма / А. М. Брамм [и др.] // *Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ*. 2022. Т. 65, № 4. С. 341–354. <https://doi.org/10.21122/1029-7448-2022-65-4-341-354>.
17. Meteoblue, Weather Close to You [Electronic Resource]. Mode of access: <https://www.meteoblue.com/en/weather>. Date of access: 21.03.2022.
18. Adaptive Ensemble Models for Medium-Term Forecasting of Water Inflow When Planning Electricity Generation under Climate Change / P. Matrenin [et al.] // *Energy Reports*. 2022. Vol. 8. P. 439–447. <https://doi.org/10.1016/j.egyr.2021.11.112>.
19. Brownlee, J. A Gentle Introduction to the Rectified Linear Unit (ReLU) [Electronic Resource] / J. Brownlee // *Machine Learning Mastery*. 2019. Mode of access: <https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/>. Date of access: 08.04.2021.
20. Liu, Danqing. A Practical Guide to ReLU [Electronic Resource] / Danqing Liu // *Medium*. 2017. Mode of access: <https://medium.com/@danqing/a-practical-guide-to-relu-b83ca804f1f7>. Date of access: 08.04.2021.
21. Amini, M. H. ARIMA-Based Decoupled Time Series Forecasting of Electric Vehicle Charging Demand for Stochastic Power System Operation / M. H. Amini, A. Kargarian, O. Karabasoglu // *Electric Power Systems Research*. 2016. Vol. 140. P. 378–390. <https://doi.org/10.1016/j.epsr.2016.06.003>.

Поступила 05.10.2022    Подписана в печать 07.12.2022    Опубликована онлайн 31.01.2023

#### REFERENCES

1. Feng J., Chu W. Q., Zhang Z., Zhu Z. Q. (2017) Power Electronic Transformer-Based Railway Traction Systems: Challenges and Opportunities. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 5 (3), 1237–1253. <https://doi.org/10.1109/JESTPE.2017.2685464>.
2. Mitrofanov S. V., Armeev D. V., Domahin E. A. (2021) Analysis of the Impact of Autonomous Hybrid Power Plants on the Railways Capacity. *XV International Scientific-Technical Conference on Actual Problems of Electronic Instrument Engineering (APEIE)*, 161–165, <https://doi.org/10.1109/APEIE52976.2021.9647596>.
3. Pouget J., Guo B., Bossoney L., Coppex J., Roggo D., Ellert C. (2020) Energetic Simulation of DC Railway Micro-Grid Interconnecting with PV Solar Panels, EV Charger Infrastructures and Electrical Railway Network. *IEEE Vehicle Power and Propulsion Conference (VPPC)*, 1–7. <https://doi.org/10.1109/VPPC49601.2020.9330829>.
4. Şengör İ., Kılıçkiran H. C., Akdemir H., Kekezoglu B., Erdinç O., Catalão J. P. S. (2018) Energy Management of a Smart Railway Station Considering Regenerative Braking and Stochastic Behaviour of ESS and PV Generation. *IEEE Transactions on Sustainable Energy*, 9 (3), 1041–1050. <https://doi.org/10.1109/TSTE.2017.2759105>.
5. Ji L., Yu Z., Ma J., Jia L., Ning F. (2020) The Potential of Photovoltaics to Power the Railway System in China. *Energies*, 13 (15), 3844. <https://doi.org/10.3390/en13153844>.
6. Mitrofanov S. V., Kiryanova N. G., Gorlova A. M. (2021) Stationary Hybrid Renewable Energy Systems for Railway Electrification: A Review. *Energies*, 14 (18), 5946. <https://doi.org/10.3390/en14185946>.
7. Aguado J. A., Sánchez Racero A. J., Torre de la S. (2018) Optimal Operation of Electric Railways with Renewable Energy and Electric Storage Systems. *IEEE Transactions on Smart Grid*, 9 (2), 993–1001. <https://doi.org/10.1109/TSG.2016.2574200>.
8. Ding F., Zhang D., He J., Liu H., Li Y. (2017) Evaluation of the Influence of Electrified Railway on Wind Farm. *2017 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific)*, 1–6. <https://doi.org/10.1109/ITEC-AP.2017.8080804>.

9. Grinchik N. N., Dobrego K. V., Chumachenko M. A. (2018) On the Measurement of Electric Resistance of Liquid Electrolytes of Accumulator Battery. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 61 (6), 494–507. <https://doi.org/10.21122/1029-7448-2018-61-6-494-507> (in Russian).
10. Dobrego K. V., Bladyko Y. V. (2021) Modeling of Batteries and their Assemblies Taking Into Account the Degradation of Parameters. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 64 (1), 27–39. <https://doi.org/10.21122/1029-7448-2021-64-1-27-39> (in Russian).
11. Strategy for Scientific and Technological Development of Russian Railways Holding for the Period until 2025 and for the Perspective until 2030: White Book. Moscow, 2018. *Innovative Digest of RR*. Available at: <https://zszd.rzd.ru/api/media/resources/c/17/121/18071?action=download> (accessed 21 March 2022) (in Russian).
12. Zhou Q., Wang C., Zhang G. (2019) Hybrid Forecasting System Based on an Optimal Model Selection Strategy for Different Wind Speed Forecasting Problems. *Applied Energy*, 250, 1559–1580. <https://doi.org/10.1016/j.apenergy.2019.05.016>.
13. Matrenin P. V., Manusov V. Z., Igumnova E. A. (2020) Robust Short-Term Wind Speed Forecasting Using Adaptive Shallow Neural Networks. *Problemele Energeticii Regionale*, 3 (47), 69–80. <https://doi.org/10.5281/zenodo.4018960> (in Russian).
14. Foley A. M., Leahy P. G., Marvuglia A., McKeogh E. J. (2012) Current Methods and Advances in Forecasting of Wind Power Generation. *Renewable Energy*, 37 (1), 1–8. <https://doi.org/10.1016/j.renene.2011.05.033>.
15. Zhang L., Dong Y., Wang J. (2019) Wind Speed Forecasting Using a Two-Stage Forecasting System with an Error Correcting and Nonlinear Ensemble Strategy. *IEEE Access*, 7, 176000–176023. <https://doi.org/10.1109/ACCESS.2019.2957174>.
16. Bramm A. M., Khalyasmaa A. I., Eroshenko S. A., Matrenin P. V., Papkova N. A., Sekatki D. A. (2022) Topology Optimization of the Network with Renewable Energy Sources Generation Based on a Modified Adapted Genetic Algorithm. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 65 (4), 341–354. <https://doi.org/10.21122/1029-7448-2022-65-4-341-354> (in Russian).
17. *Meteoblue, Weather Close to You*. Available at <https://www.meteoblue.com/en/weather> (accessed 1 March 2022).
18. Matrenin P., Safaraliev M., Dmitriev S., Kokin S., Eshchanov B., Rusina A. (2022) Adaptive Ensemble Models for Medium-Term Forecasting of Water Inflow When Planning Electricity Generation under Climate Change. *Energy Reports*, 8, Supl. 1, 439–447. <https://doi.org/10.1016/j.egy.2021.11.112>.
19. Brownlee J. (2019) A Gentle Introduction to the Rectified Linear Unit (ReLU). *Machine Learning Mastery*. Available at: <https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks> (accessed 8 April 2021).
20. Danqing Liu (2017) A Practical Guide to ReLU. *Medium*. Available at: <https://medium.com/@danqing/a-practical-guide-to-relu-b83ca804f1f7> (accessed 8 April 2021).
21. Amini M. H., Kargarian A., Karabasoglu O. (2016) ARIMA-Based Decoupled Time Series Forecasting of Electric Vehicle Charging Demand for Stochastic Power System Operation. *Electric Power Systems Research*, 140, 378–390. <https://doi.org/10.1016/j.epsr.2016.06.003>.