



Обзорная статья

УДК 621.311

<https://elibrary.ru/msowuy><https://doi.org/10.21285/1814-3520-2023-2-354-369>

## Обзор международного опыта в прогнозировании генерации возобновляемых источников энергии с помощью методов машинного обучения

Н.Н. Сергеев<sup>1✉</sup>, П.В. Матренин<sup>2</sup><sup>1,2</sup>Новосибирский государственный технический университет, г. Новосибирск, Россия

**Резюме.** Цель – проведение аналитического обзора и систематизация современных подходов к прогнозированию генерации электроэнергии на базе возобновляемых источников энергии в мировой практике, а также анализ актуальных проблем и перспективных решений в данном направлении. Классификация методов прогнозирования генерации электроэнергии возобновляемыми источниками выполнена на основе анализа литературных источников, посвященных разработке моделей прогнозирования, которые включают в себя физические модели, использование статистических методов и методов на базе машинного обучения. Проведен анализ использования наиболее распространенных методов (физических, статистических и методов машинного обучения) прогнозирования генерации электроэнергии возобновляемыми источниками, выделены преимущества и недостатки данных методов. Установлено, что в большинстве случаев – в особенности в задачах краткосрочного прогнозирования генерации – методы прогнозирования на базе машинного обучения показывают более высокие результаты по сравнению с физическими и статистическими методами. По результатам анализа актуальных проблем в области систем сбора метаданных установлено, что основными препятствиями для широкого применения алгоритмов машинного обучения на практике являются неполнота и неопределенность исходных данных, а также высокая вычислительная сложность таких алгоритмов. Показано, что с целью повышения эффективности моделей машинного обучения в задаче прогнозирования генерации возобновляемых источников энергии можно применять различные методы предварительной обработки данных, такие как нормализация, определение аномалий и восстановление пропущенных значений, аугментация и кластеризация, корреляционный анализ. Принято решение о необходимости разработки методов предварительной обработки данных, направленных на оптимизацию и общее повышение эффективности моделей машинного обучения для прогнозирования генерации возобновляемых источников энергии. Ведение исследований в данном направлении при учете всех перечисленных проблем имеет высокую значимость для реализации программ по интеграции возобновляемых источников энергии в электроэнергетическую систему и развития в области безуглеродной энергетики.

**Ключевые слова:** возобновляемые источники энергии, прогнозирование, машинное обучение, нейронные сети, регрессионные модели, анализ данных

**Финансирование:** Исследование выполнено за счет гранта Российского научного фонда (проект № 22-79-00181).

**Для цитирования:** Сергеев Н.Н., Матренин П.В. Обзор международного опыта в прогнозировании генерации возобновляемых источников энергии с помощью методов машинного обучения // iPolytech Journal. 2023. Т. 27. № 2. С. 354-369. EDN: MSOWUY, <https://doi.org/10.21285/1814-3520-2023-2-354-369>.

## A review of international experience in forecasting renewable energy generation using machine learning methods

Nikita N. Sergeev<sup>1✉</sup>, Pavel V. Matrenin<sup>2</sup>

<sup>1,2</sup>Novosibirsk State Technical University, Novosibirsk, Russia

**Abstract.** In this work, we conduct an analytical review of contemporary international approaches to forecasting the volume of electricity generated by renewable energy sources, as well as to investigate current problems and prospective solutions in this field. The existing forecasting methods were classified following an analysis of published literature on the development of forecasting models, including those based on physical, statistical and machine learning principles. The application practice of these methods was investigated to determine the advantages and disadvantages of each method. In the majority of cases, particularly when carrying out short-term forecasting of renewable electricity generation, machine learning methods outperform physical and statistical methods. An analysis of the current problems in the field of weather data collection systems allowed the major obstacles to a wide application of machine learning algorithms to be determined, which comprise incompleteness and uncertainty of input data, as well as the high computational complexity of such algorithms. An increased efficiency of machine learning models in the task of forecasting renewable energy generation can be achieved using data preprocessing methods, such as normalization, anomaly detection, missing value recovery, augmentation, clustering and correlation analysis. The need to develop data preprocessing methods aimed at optimizing and improving the overall efficiency of machine learning models for forecasting renewable energy generation was justified. Research in this direction, while taking into account the above problems, is highly relevant for the implementation of programs for the integration of renewable energy sources into power systems and the development of carbon-free energy.

**Keywords:** renewable energy sources, forecasting, machine learning, neural networks, regression models, data analysis

**Funding:** The research was funded by the grant of the Russian Science Foundation (project No. 22-79-00181).

**For citation:** Sergeev N.N., Matrenin P.V. A review of international experience in forecasting renewable energy generation using machine learning methods. *iPolytech Journal*. 2023;27(2):354-369. (In Russ.). EDN: MSOWUY, <https://doi.org/10.21285/1814-3520-2023-2-354-369>.

### ВВЕДЕНИЕ

В последние годы наблюдается тенденция к росту доли возобновляемых источников энергии (ВИЭ) в составе современных электроэнергетических систем (ЭЭС). Так, на конец 2021 г. глобальная установленная мощность ВИЭ достигла отметки в 3 ТВт с рекордным приростом мощности в 295 ГВт за этот год, а доля ВИЭ в энергобалансе составила 28,7%; вводимые генерирующие мощности ВИЭ сосредоточены в основном в секторе гидроэнергетики (40%), солнечной энергетики (28%) и ветроэнергетики (27%)<sup>3</sup>. К 2030 г. в Европейском Союзе предполагается дальнейший рост доли вырабатываемой ВИЭ мощности вплоть до 60%<sup>4</sup>.

Развитие ВИЭ в России происходит через заключение договоров о предоставлении мощности (ДПМ) ВИЭ, гарантирующих инвесторам возврат инвестиций за счет специальных надбавок к цене на мощность для покупателей оптового рынка электроэнергии и мощности. Программы ДПМ ВИЭ 1.0 и 2.0 направлены на развитие именно ветроэнергетики и солнечной энергетики: по итогам реализации этих программ до конца 2024 г. должны быть введены в эксплуатацию солнечные и ветровые электростанции суммарной установленной мощностью 5,28 ГВт (доля ВИЭ в ЭЭС России при этом будет составлять 2% от суммарной установленной мощности), а к 2035 г. – еще 6,7 ГВт [1].

<sup>3</sup>Renewable Energy Statistics 2022 // IRENA. [Электронный ресурс]. URL: <https://www.irena.org/publications/2022/Jul/Renewable-Energy-Statistics-2022> (22.02.2023).

<sup>4</sup>Renewable Electricity // IEA [Электронный ресурс]. URL: <https://www.iea.org/reports/renewable-electricity> (22.02.2023).

Несмотря на очевидную привлекательность возобновляемой энергетики в виде теоретической неисчерпаемости и высокой экологичности [2–4], необходимо в то же время принимать во внимание сложности, возникающие при интеграции ВИЭ в состав ЭЭС. Основными проблемами в данном случае являются сильная зависимость от погоды, стохастичный характер выработки и, как следствие, неустойчивое и ненадежное электроснабжение [5]. В связи с этим особенно большое значение приобретает решение широкого ряда задач проектирования и оперативно-диспетчерского управления ЭЭС с высокой долей ВИЭ. В этот ряд задач входит долгосрочное, среднесрочное, краткосрочное и оперативное планирования электроэнергетических режимов, а также сбор, обработка и применение метеорологических данных для прогнозирования генерации ВИЭ.

Планирование электроэнергетических режимов энергосистем производится на период от каждого получаса внутри суток до нескольких лет вперед. При планировании электроэнергетического режима ЭЭС на любой период выполняется прогнозирование балансов мощности энергосистемы, что может быть затруднено при наличии значительной доли ВИЭ в составе генерирующего оборудования энергосистемы, поскольку необходимо учитывать зависимость выработки ВИЭ от метеорологических условий. В зависимости от временного горизонта выделяют долгосрочное, среднесрочное, краткосрочное и оперативное прогнозирования [6, 8, 9]. На рисунке приведена классификация видов прогнозирования по временному горизонту и

соответствующие им области применения.

Методы прогнозирования генерации электроэнергии от ВИЭ в общем случае можно разделить на физические модели [10, 11, 13], статистические [12] и модели с применением машинного обучения, в том числе нейронные сети (адаптивные модели) [11, 14–16]. Все виды моделей имеют свои сильные и слабые стороны и находят применение в различных ситуациях. Настоящая работа включает обзор всех вышеупомянутых методов, однако большее внимание уделено моделям на базе методов машинного обучения как наиболее перспективным инструментам в вопросе интеграции ВИЭ в ЭЭС.

Важным моментом при разработке любых моделей прогнозирования являются сбор, обработка и применение необходимых исходных данных. При прогнозировании генерации электроэнергии на основе ВИЭ в качестве исходных данных используются как метеорологические данные (температура, скорость и направление ветра, солнечная радиация, облачность и др.), так и ретроспективные данные фактической выработки электроэнергии конкретными электростанциями на базе ВИЭ. Основными источниками метеоданных являются, как правило, географическая информационная система (ГИС) и специальные средства измерения [17, 18]. Объединение систем сбора метеоданных и систем прогнозирования выработки электроэнергии ВИЭ также представляет собой отдельную задачу, решение которой необходимо для функционирования ЭЭС с высокой долей ВИЭ.



**Классификация видов прогнозирования и их области применения**  
*Classification of forecasting types and their application areas*

## ОСНОВНЫЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ ГЕНЕРАЦИИ ВОЗОБНОВЛЯЕМЫХ ИСТОЧНИКОВ ЭНЕРГИИ

Для прогнозирования генерации электроэнергии на основе ВИЭ применяются различные подходы: физические модели, статистические методы и методы машинного обучения. Эффективность каждого метода может изменяться от случая к случаю и существенно зависит от временного горизонта прогнозирования, выбранных метрик качества и объема доступных данных и вычислительных ресурсов.

**Физические модели** строятся, как правило, на основе методов численного прогнозирования погоды. Численные прогнозы погоды основываются на данных о состоянии рельефа земной поверхности, океанов и нижних слоев атмосферы, собираемых метеорологическими организациями по всему миру. Современные методики объединения и обработки данных позволяют посредством численного прогнозирования погоды строить симуляции атмосферных процессов в режиме реального времени [19].

С помощью данных численного прогнозирования погоды можно выводить прогноз климатических условий на длительный период – более чем на 15 дней вперед. В работах [20, 21] предложены методики краткосрочного прогнозирования выработки электроэнергии ветряных и солнечных электростанций с применением численного прогнозирования погодных условий в пределах нескольких суток.

Несмотря на то, что такие модели способны строить прогноз выработки электроэнергии ВИЭ с высокой точностью, их высокая вычислительная сложность и необходимость доступа (часто дорогостоящего) к данным метеорологических организаций затрудняет их применение на практике.

**Статистические подходы** используют данные предшествующих наблюдений, с помощью которых выводится зависимость между входными переменными и прогнозируемыми величинами. Они более эффективны для краткосрочного прогнозирования и обладают, как правило, сравнительно не-

большим количеством параметров, благодаря чему требуют значительно меньше вычислительных ресурсов по сравнению с физическими моделями и методами на основе машинного обучения [9]. Наиболее часто из этой категории применяются итерационные методы, авторегрессионные модели и модели экспоненциального сглаживания.

*Инерционный метод* часто используется для оперативного прогнозирования мощности, вырабатываемой СЭС или ВЭС, на время упреждения от 15 до 30 мин. Этот подход основывается на предположении, что погодные условия (солнечная радиация, скорость ветра) в определенный день будут такими же, как и условия в предшествующий день. Данная модель описывается уравнением:

$$P(t + k|t) = \frac{1}{T} \sum_{i=0}^{n-1} P(t - i\Delta t), \quad (1)$$

где  $k$  – время упреждения, ч;  $P(t + k|t)$  – прогноз мощности на время  $t + k$ , построенный в момент времени  $t$ , Вт;  $T$  – длина прогнозного интервала, ч;  $n$  – количество предшествующих измерений;  $P(t - i\Delta t)$  – действительная мощность в момент времени  $t$  и предыдущих  $i$ -х временных шагов в пределах  $T$ , Вт;  $\Delta t$  – длина шага по времени, ч.

Основными преимуществами данной модели являются ее очень низкая вычислительная сложность и удовлетворительная точность на близких временных горизонтах [22]. Однако ее применение ограничивается тем, что чем больше удалено время начала прогноза от текущего момента времени, тем сильнее снижается ее точность.

На практике часто используются методы, объединяющие простые модели временных рядов – *авторегрессии* AR (от англ. autoregressive) и *скользящего среднего* MA (от англ. moving average). *Модель авторегрессии – скользящего среднего* ARMA – одна из наиболее популярных моделей прогнозирования временных рядов благодаря своей простоте и способности представлять различные типы временных рядов с помощью подбора различных порядков. Модель ARMA( $p, q$ ), где  $p$  и  $q$  – целые числа, задающие порядки составляющих моделей AR( $p$ ) и

MA( $q$ ), описывается следующим выражением:

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j}, \quad (2)$$

где  $X_t$  – прогнозируемое значение в момент времени  $t$ ;  $c$  – константа;  $\varepsilon_t$  – белый шум (независимая переменная, последовательность случайных величин с нулевым средним и постоянной дисперсией);  $\varphi_i$  и  $\theta_j$  – коэффициенты моделей AR( $p$ ) и MA( $q$ ), соответственно.

ARMA-модель демонстрирует высокую эффективность в прогнозировании стационарных временных рядов с наличием явной линейной зависимости, что может встречаться в задачах прогнозирования выработки ВИЭ [22, 24]. В работе [22] представлена ARMA-модель для прогнозирования генерации электроэнергии ветроустановками, а также показано, что точность модели достаточно высока при оперативном прогнозировании и снижается по мере увеличения временного горизонта. В работе [24] показано, что ARMA-модель для прогнозирования почасовой выработки электроэнергии солнечными батареями дает на 15% лучший результат в рассматриваемой задаче по сравнению с моделью, построенной по инерционному методу.

Основным ограничением применения ARMA-моделей является требование стационарности рассматриваемого временного ряда, т.е. его числовые характеристики должны оставаться неизменными во времени. Для работы с нестационарными временными рядами применяется модель ARIMA – интегрированная ARMA (модель Бокса – Дженкинса). При использовании такого подхода нестационарный временной ряд приводится к стационарному путем его дифференцирования, т.е. вместо исходного временного ряда необходимо рассматривать его приращение за один или несколько периодов. Формально модель ARIMA для нестационарного временного ряда представляется в виде

$$(1 - \sum_{i=1}^p \varphi_i L^i)(1 - L)^d X_t = (1 + \sum_{j=1}^q \theta_j L^j) \varepsilon_t, \quad (3)$$

где  $L$  – лаговый оператор, определяемый как

$L(X_t) = X_{t-1}$ ;  $d$  – порядок интегрированности временного ряда, при  $d = 0$  модель ARIMA( $p, d, q$ ) сводится к обычной модели ARMA( $p, q$ ).

Модель ARIMA является наиболее распространенной модификацией авторегрессии со скользящим средним и в некоторых случаях может иметь точность прогнозирования, достаточно близкую к точности нейронных сетей, как показано в работе [25], где рассмотрена задача оперативного прогнозирования скорости ветра.

Модель ARMA( $p, q$ ) может быть дополнена учетом экзогенных факторов и преобразована в модель ARMAX( $p, q, b$ ), где  $b$  – порядок временного ряда экзогенной переменной. Такая модель может быть представлена как

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{k=1}^b \eta_k \beta_{k-1}, \quad (4)$$

где  $\eta_k$  – коэффициенты ряда экзогенной переменной  $\beta_k$ .

В задаче прогнозирования генерации электроэнергии ВИЭ в роли экзогенных факторов могут выступать различные метеорологические условия: скорость и направление ветра [27], солнечная радиация [28].

Модель экспоненциального сглаживания относится к адаптивным методам прогнозирования, особенность которых заключается в способности подстраиваться под динамические изменения рассматриваемого процесса, придавая большее значение наиболее близким к текущему моменту времени наблюдениям. В общем случае это выполняется за счет присвоения различных весов предшествующим значениям временного ряда: чем дальше точка от текущего наблюдения, тем меньший вес ей присваивается. Простейший вид экспоненциального сглаживания описывается выражением:

$$\hat{X}_{t+1} = \alpha X_t + (1 - \alpha) \hat{X}_t = \hat{X}_t + \alpha(X_t - \hat{X}_t), \quad (5)$$

где  $X_t$  – наблюдение в момент времени  $t$ ;  $\hat{X}_t$  – прогнозное значение предсказываемой величины на момент  $t$ ;  $\alpha$  – параметр сглаживания,  $0 < \alpha < 1$ .

Для учета трендовых и сезонных состав-

ляющих в модель вводятся соответствующие дополнительные параметры. В работе [29] используется трехпараметрическое экспоненциальное сглаживание (метод Хольта – Винтера) для оперативного прогнозирования солнечного излучения с временным горизонтом до 20 мин, который показал более высокую точность по сравнению с другими статистическими методами. В [30] разработан алгоритм выравнивания колебаний мощности ветроустановки на базе гибридной системы накопления энергии и краткосрочного прогнозирования с помощью модели нелинейного экспоненциального сглаживания.

Данный метод является достаточно робастным и часто может давать более высокий результат по сравнению с более сложными статистическими моделями (ARIMA, ARMAX и др.), которые в некоторых случаях могут оказаться слишком чувствительными и неустойчивыми.

**Модели машинного обучения**, или **адаптивные модели**, нашли свое применение в задачах прогнозирования потребления и генерации электроэнергии сравнительно недавно, но уже активно рассматриваются в научно-прикладных исследованиях и являются перспективным решением в вопросе управления энергосистемами с высокой долей ВИЭ [14]. Обучение в контексте данных моделей заключается в итерационном подборе параметров для аппроксимации зависимостей, описывающих какой-либо изменяющийся во времени процесс. Такой подход позволяет адаптивным моделям извлекать сложные нелинейные зависимости на длительных интервалах, за счет чего они, как правило, по сравнению с моделями на основе статистических подходов показывают более высокий результат при прогнозировании временных рядов на достаточно сильно удаленные от текущего момента промежутки времени. На данный момент существует большое разнообразие моделей на основе машинного обучения, в том числе нейронные сети и метод опорных векторов, которые будут рассмотрены в дальнейшем.

**Искусственные нейронные сети** (ИНС) приобрели широкое распространение в решении задач как краткосрочного прогнози-

рования генерации ВИЭ, так и средне- и долгосрочного. Правильный выбор архитектуры ИНС сильно зависит от условий конкретной задачи. Многослойные ИНС теоретически являются универсальными аппроксиматорами и обладают способностью восстанавливать любые нелинейные зависимости со сколь угодно высокой точностью. Однако для получения хорошей обобщающей способности модели – высокой точности на новых данных – необходимо ответственно подходить к выбору архитектуры и гиперпараметров ИНС.

Стандартной архитектурой ИНС является архитектура *прямого распространения* (от англ. Feedforward neural network). Такие ИНС в общем случае могут быть представлены в виде совокупности связанных между собой одного входного, нескольких скрытых и одного выходного слоев, состоящих из нейронов, каждый из которых является совокупностью вектора входных значений, вектора весов и функции активации.

При обучении ИНС на ее вход подается вектор входных значений  $[x_1, x_2, \dots, x_n]$  и соответствующая каждому входному параметру целевая переменная  $y$  либо вектор целевых переменных  $[y_1, y_2, \dots, y_m]$ . Выходное значение  $j$ -го нейрона  $Z_j$  определяется выражением:

$$Z_j = g\left(\sum_{i=1}^N w_{ij}x_i + b_j\right), \quad (6)$$

где  $g(\cdot)$  – нелинейная функция активации;  $N$  – количество нейронов в предыдущем слое;  $w_{ij}$  – весовые коэффициенты, связывающие нейроны текущего слоя с нейронами предыдущего слоя;  $x_i$  – входное значение ИНС либо выходное значение нейрона предыдущего слоя;  $b_j$  – свободный коэффициент слоя.

В работе [31] рассмотрено несколько различных методов обучения многослойного перцептрона для долгосрочного прогнозирования средней ежемесячной скорости ветра на основе данных по атмосферному давлению, температуре и влажности. В результате был сделан вывод, что с помощью нейронной сети можно достичь приемлемой точности прогнозирования даже в условиях ограниченного набора исходных данных: средняя

точность лучшей модели с интервалом в один год составила 95,2%.

В [32] предлагается модель ИНС для прогнозирования мощности ветроустановки с усовершенствованным алгоритмом обратного распространения ошибки, в котором вместо стандартной квадратичной функции потерь используется критерий максимальной коррентропии. Это позволило увеличить корреляцию между прогнозируемой и действительной мощностями, а главное – повысить точность прогнозирования.

В работе [33] приводится сравнение ИНС прямого распространения для почасового прогнозирования выработки солнечной электроэнергии на месяц вперед со статистическими моделями: множественной линейной регрессией и инерционной моделью. На вход модели подается 12 независимых переменных, характеризующих погодные условия в области: уровень солнечной радиации, атмосферное давление, облачность, количество осадков и др. Показано, что в рассмотренной задаче ИНС по точности прогнозирования превосходит другие модели.

Даже у простейших ИНС результат во многом зависит от правильного выбора гиперпараметров. В [34] предложен алгоритм подбора гиперпараметров модели прогнозирования скорости ветра на основе многослойного перцептрона. Гиперпараметрами являются количество нейронов в скрытом слое, шаг и способ обучения, количество циклов обучения и функции активации. Для обучения модели используются только ретроспективные данные скорости ветра. Результаты показывают, что при оптимальном выборе гиперпараметров возможно значительно повысить точность прогнозирования даже при отсутствии других метеорологических данных, таких как направление ветра, температура, влажность и давление.

*Сверточные нейронные сети* (СНС) чаще всего применяются в обработке двух- и трехмерных массивов – изображений и распознавании образов, в связи с чем при их использовании особенно выражено проявляется необходимость в объемных наборах исходных данных и вычислительных ресурсах [14]. Модели прогнозирования, основанные

на СНС, используют сверточные слои для извлечения информации из входных данных, а задача регрессии – прогнозирование временного ряда – выполняется с помощью последнего полносвязного слоя, схожего с теми, которые используются в ИНС прямого распространения.

Способность СНС извлекать информацию из изображений также может применяться для прогнозирования погодных условий и генерации электроэнергии ВИЭ. Так, в [35] представлена система оперативного прогнозирования уровня солнечной радиации на 1 ч вперед, главной особенностью которой является использование в качестве входных данных только изображений неба, без каких-либо численных измерений и дополнительной информации. Разработанная модель по показателям превзошла другие модели машинного обучения: нормализованная среднеквадратическая ошибка составила 8,85%.

Другим направлением применения СНС является прогнозирование скорости ветра на основе пространственно-временной корреляции, позволяющей в любой момент времени моделировать поведение воздушных потоков на определенной территории в зависимости от влияния неровностей земной поверхности и геострофического ветра [36]. В специализированном источнике [36] авторы предлагают модель прогнозирования скорости ветра в пределах ветропарка, состоящего из 100 ветроустановок, расположенных в виде сетки 10x10. Скорости ветра у каждой ветроустановки представлены в виде такой же сетки, где каждая ячейка соответствует определенной ветроустановке; чем глубже цвет, тем выше скорость ветра. Такое представление данных позволило эффективно применить СНС в данной задаче. Прогнозирование скорости ветра выполнялось на временные горизонты от 5 до 60 мин, средняя ошибка прогнозирования предложенной модели изменялась, соответственно, от 4,4 до 9,3%, что является лучшим результатом среди сравниваемых моделей.

Самой распространенной современной моделью прогнозирования генерации электроэнергии ВИЭ являются *рекуррентные нейронные сети* (РНС), не считая гибридные

модели [37]. Популярность РНС в задаче прогнозирования объясняется тем, что их идея заключается в обработке последовательных данных, каждый элемент которых записан через определенный шаг по времени. Модель РНС имеет простую структуру, в которой выход рассматриваемого слоя суммируется со следующим вектором входных сигналов и снова подается на вход этого же слоя, который является, в сущности, единственным скрытым слоем всей сети. Кроме стандартной РНС, часто используются ее более сложные усовершенствованные варианты: с блоками долгой краткосрочной памяти LSTM (от англ. Long Short-Term Memory) и с управляемыми рекуррентными блоками GRU (от англ. Gated Recurrent Unit), способными моделировать временные ряды, в которых имеются неопределенные временные границы между наблюдениями, и отслеживать связи между событиями, достаточно сильно удаленными друг от друга во времени.

Благодаря тому, что РНС способны запоминать связи между элементами последовательных данных на длительных интервалах времени, они достаточно эффективно проявляют себя при построении почасовых прогнозов с достаточно большими (по сравнению со статистическими моделями) временными горизонтами – на 24 и более часов вперед. В работе [38] приведена модель нелинейной РНС с учетом внешних факторов для прогнозирования уровня солнечной радиации на сутки вперед. В качестве внешних факторов используются численные измерения климатических условий: температуры, скорости ветра и влажности.

В [39] описывается модель прогнозирования вырабатываемой ветропарком мощности с временными горизонтами от 1 до 24 ч вперед на базе РНС с блоками LSTM. Предложенная модель в качестве входных сигналов использует исторические данные генерации мощности и метеоданные, полученные с помощью численного прогноза погоды: температура, атмосферное давление, скорость и направление ветра на различных высотах. Результаты показали, что точность модели зависит от выбранного временного горизонта: при прогнозировании на 1 ч вперед сред-

няя ошибка прогноза составляет 3,01%, а при прогнозировании на 24 ч вперед – 7,65%.

В работе [40] авторы сравнивают оба ранее упомянутых варианта архитектуры РНС для оперативного прогнозирования скорости ветра: на базе блоков LSTM и GRU. В рассмотренной задаче модель на основе GRU имеет более высокую точность по сравнению с моделью LSTM, демонстрируя при этом меньшие требования к вычислительным ресурсам, меньшую длительность обучения и высокую устойчивость к шуму в исходных данных.

*Метод опорных векторов SVM* (от англ. Support Vector Machine) также имеет широкое распространение в задачах прогнозирования генерации ВИЭ [41]. Основная идея этого подхода заключается в нелинейном отображении входных данных в многомерное пространство для поиска такой гиперплоскости, лучше всего разделяющей исходные данные. В общем случае метод SVM характеризуется высокой устойчивостью, возможностью моделировать сложные нелинейные зависимости и хорошей обобщающей способностью.

В работе [42] авторами предлагается методика подбора оптимальных параметров SVM для краткосрочного прогнозирования мощности ветропарка на следующие 48 ч. Рассмотрено несколько вариантов SVM, ошибка лучшей модели составила 8,64%, при этом ошибка других сравниваемых моделей была значительно выше: например, для ИНС прямого распространения ошибка при тех же условиях составила 17,58%.

В [43] описан алгоритм извлечения информации из спутниковых изображений – вектора циркуляции атмосферы – для прогнозирования облачности и уровня солнечной радиации в рассматриваемом регионе, что, в свою очередь, используется для прогнозирования выработки солнечной электростанции. Основной моделью прогнозирования является SVM, для сравнения также рассмотрены ИНС и инерционная модель. В данном случае средняя ошибка прогноза SVM составила 7,73%, что является лучшим результатом среди сопоставляемых моделей.

Общая сравнительная характеристика рассмотренных методов приведена в таблице.

Сравнительная характеристика методов прогнозирования  
Comparative characteristics of forecasting methods

Класс методов прогнозирования	Преимущества	Недостатки
Физические методы	1) высокая эффективность для долгосрочного прогнозирования; 2) предоставляют подробную картину состояния атмосферы	1) неприменимы для краткосрочного прогнозирования из-за высокой вычислительной сложности; 2) высокая стоимость доступа к данным
Статистические методы	1) простота выбора и построения моделей; 2) низкие требования к вычислительным ресурсам; 3) подходят для прогнозов с малым временным горизонтом и для прогнозирования средних значений на длительных интервалах	1) резкое снижение точности при увеличении горизонта прогнозирования; 2) низкая эффективность при прогнозировании временных рядов со сложными нелинейными зависимостями
Методы машинного обучения	1) гибкость, модели могут быть настроены под любую задачу; 2) способны восстанавливать резко нелинейные зависимости; 3) широкий выбор способов оптимизации моделей	1) значительные требования к качеству и объему исходных данных; 2) высокая вычислительная сложность; 3) сложный процесс подбора архитектуры и гиперпараметров моделей

### **АКТУАЛЬНЫЕ ПРОБЛЕМЫ И ПЕРСПЕКТИВНЫЕ РЕШЕНИЯ В ОБЛАСТИ ПРОГНОЗИРОВАНИЯ ГЕНЕРАЦИИ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ**

Как уже было отмечено, нейронные сети и другие модели на основе машинного обучения приобретают все большее распространение в решении прикладных задач прогнозирования, оптимизации и управления ЭЭС с высокой долей ВИЭ. Однако в силу своих особенностей разработка подобных моделей может сталкиваться с рядом проблем, которые способны препятствовать реализации моделей на практике и требуют отдельного внимания. Далее будут рассмотрены наиболее значимые из таких проблем.

**Обеспечение нужного объема данных.** Высокая точность прогнозирования при использовании методов машинного обучения достижима только при условии, что для обучения моделей доступны большие объемы качественных данных [44]. При этом нужны как текущие данные генерации ВИЭ и данные за прошлые периоды, так и данные широкого ряда метеорологических условий, используемых для построения прогнозов. Метеорологические данные собираются с помощью датчиков и спутниковых систем; оперативное и краткосрочное прогнозирование, как правило, должно выполняться автоматически в режиме реального времени, необходимо организовывать связь между системами сбора

метеоданных и системами прогнозирования. Здесь основная проблема чаще всего заключается в удаленности метеорологических вышек от электрических станций на базе ВИЭ [45]. Кроме того, все данные должны обрабатываться и приводиться к определенному виду для их успешного применения в моделях машинного обучения, и разработка методов обработки данных также требует времени и ресурсов.

**Неопределенность в данных.** Объединение систем сбора метеоданных и систем прогнозирования генерации электроэнергии на основе ВИЭ может быть замедлено из-за ряда технических проблем и ограничений. Воздействие помех или некачественное соединение ведет к искажению и потере данных при их передаче, что, в свою очередь, может привести к снижению точности прогноза и нарушению работы всей системы в целом [14]. Другими источниками неопределенности могут являться следующие: ошибки измерения погодных условий; присутствие физическим процессам изменчивость и стохастичность, влияющие на состояние прогнозируемой величины; погрешность, вызванная выбором параметров самой модели и данных для обучения [46].

**Высокая вычислительная сложность новых методов прогнозирования.** Современным интеллектуальным системам на основе машинного обучения не присуще свойство

эффективного использования вычислительных ресурсов, особенно при использовании большого объема данных высокой размерности [47]. Основной причиной высоких вычислительных затрат являются лишние функциональные возможности и обработка повторяющихся избыточных данных. В связи с этим внедрение новых моделей на базе машинного обучения в существующие системы может быть не оправдано экономически, несмотря на их высокие результаты в лабораторных условиях.

Для преодоления ранее упомянутых проблем многие авторы предлагают различные подходы к обработке данных, оценке неопределенности и оптимизации предлагаемых моделей прогнозирования. В этом разделе приведены наиболее распространенные в исследованиях методики, позволяющие повышать потенциал и эффективность моделей машинного обучения при решении задач прогнозирования генерации электроэнергии на основе ВИЭ.

*Предварительная обработка данных.* Предварительная обработка данных является необходимым шагом при построении моделей на базе машинного обучения, поскольку это позволяет подготовить данные к анализу и привести к виду, соответствующему требованиям решаемой задачи. Методы предварительной обработки данных чрезвычайно разнообразны и включают в себя:

- нормализацию данных;
- определение аномалий и восстановление пропущенных значений;
- аугментацию и кластеризацию данных;
- корреляционный анализ для отбора наиболее важных данных и др. [37].

Нормализация данных – основная операция при работе с численными данными, значения которых изменяются в больших диапазонах и отличаются между собой на порядки. Работа с такими необработанными, «сырыми» данными может нарушать устойчивость модели, замедлять процесс обучения и приводить к непредсказуемым результатам. Нормализация позволяет привести все числовые значения в данных к одному диапазону, например, от 0 до 1 [48].

В наборах используемых данных часто

встречаются пропущенные и лишние информационного смысла значения, появившиеся в результате неправильной работы программного обеспечения, сбоя или износа средств измерений [49]. Пропущенные значения могут заменяться значениями за прошлые ближайшие моменты времени, средними значениями за весь рассматриваемый временной промежуток или с применением методов интерполяции [50, 51]. Определение и устранение значений, не имеющих смысла, также необходимо для построения адекватной модели: ночные часы при прогнозировании выработки солнечной электростанции или период планово-предупредительного ремонта ветроустановок.

Аугментация и кластеризация данных также дают возможность существенно повысить эффективность разрабатываемых систем прогнозирования. Аугментация – это процесс искусственного увеличения объема данных при помощи модификации и комбинации имеющихся данных: геометрические преобразования, легкое зашумление, корректировка цвета и яркости. Такой прием часто используется в случаях, когда рассматриваемыми исходными данными являются наборы изображений, например, изображений неба для краткосрочного прогнозирования генерации электроэнергии солнечными батареями [52]. Кластеризация (группировка) данных используется в основном для разделения набора данных по дням и сезонам, схожих по погодным характеристикам. Это позволяет построить вместо одной модели для всех режимов несколько разных моделей для каждого кластера. Дни со схожими погодными характеристиками, как правило, имеют схожие профили мощности ВИЭ. Что можно использовать для построения разных моделей прогнозирования, каждая из которых настроена под работу в одной из групп погодных условий, и при соответствующем корректном использовании будет выдавать более точные результаты, чем одна общая модель [53].

Корреляционный анализ является одним из способов отбора наиболее значимых входных данных для обучения моделей. Использование избыточных данных часто ведет

как к лишнему усложнению модели прогнозирования, так и к снижению ее точности. В [54] представлен расчет коэффициента корреляции Пирсона между выработкой солнечной электростанции и различными метеорологическими факторами. Это позволило выделить наиболее значимые данные для прогноза выработки электроэнергии – уровень солнечной радиации, температуру и влажность, и на основе этих данных была построена модель прогнозирования.

## **ЗАКЛЮЧЕНИЕ**

Интеграция ВИЭ в современные ЭЭС требует преодоления ряда проблем, связанных с решением задач по снижению влияния изменчивых и стохастических природных процессов, от которых напрямую зависит выработка электроэнергии на базе ВИЭ и устойчивость ЭЭС. Подобные задачи должны решаться как в условиях оперативно-диспетчерского управления, так и в рамках проектирования ЭЭС с высокой долей ВИЭ.

Для повышения надежности электроснабжения и эффективного управления энергосистемой необходимо точное прогнозирование генерации электроэнергии на основе ВИЭ. Методы прогнозирования чрезвычайно разнообразны и в зависимости от специфики решаемой задачи могут применяться в раз-

личных областях. В современных исследованиях большое внимание уделено разработке систем прогнозирования на основе методов машинного обучения, показывающих высокие результаты для всех видов прогнозирования и особенно для краткосрочного прогнозирования генерации, необходимого для обеспечения стабильного функционирования электроэнергетического рынка.

Однако следует принимать во внимание сложности, возникающие при использовании моделей на базе машинного обучения в практических условиях, заключающихся преимущественно в высоких требованиях таких моделей к вычислительным ресурсам и в поиске необходимого объема качественных данных для обучения. Преодоление перечисленных проблем может быть возможно за счет разработки методов предварительной обработки данных, направленных на оптимизацию и общее повышение эффективности моделей машинного обучения.

Таким образом, учет перечисленных обстоятельств совместно с исследованиями и разработками в указанных направлениях помогут в успешной реализации проектов по интеграции ВИЭ в ЭЭС для развития направления безуглеродной энергетики и реализации программ ДПМ ВИЭ.

## **Список источников**

1. Илюшин П.В. Интеграция электростанций на основе возобновляемых источников энергии в Единую энергетическую систему России: обзор проблемных вопросов и подходов к их решению // Вестник Московского энергетического института. Вестник МЭИ. 2022. № 4. С. 98–107. <https://doi.org/10.24160/1993-6982-2022-4-98-107>.
2. Kolosok S., Bilan Yu., Vasylieva T., Wojciechowski A., Morawski M. A scoping review of renewable energy, sustainability and the environment // *Energies*. 2021. Vol. 14. Iss. 15. P. 4490. <https://doi.org/10.3390/en14154490>.
3. Qazi A., Hussain F., Rahim N. A., Hardaker G., Alghazzawi D., Shaban K., et al. Towards sustainable energy: a systematic review of renewable energy sources, technologies, and public opinions // *IEEE Access*. 2019. Vol. 7. P. 63837–63851. <https://doi.org/10.1109/ACCESS.2019.2906402>.
4. Sinsel S.R., Riemke R.L., Hoffmann V.H. Challenges and solution technologies for the integration of variable renewable energy sources—a review // *Renewable Energy*. 2020. Vol. 145. P. 2271–2285. <https://doi.org/10.1016/j.renene.2019.06.147>.
5. Yang Yuqing, Bremner Stephen, Menictas Chris, Kay Merlinde. Battery energy storage system size determination in renewable energy systems: a review // *Renewable and Sustainable Energy Reviews*. 2018. Vol. 91. P. 109–125. <https://doi.org/10.1016/j.rser.2018.03.047>.
6. Wan Can, Zhao Jian, Song Yonghua, Xu Zhao, Lin Jin, Hu Zechun. Photovoltaic and solar power forecasting for smart grid energy management // *CSEE Journal of Power and Energy Systems*. 2015. Vol. 1. Iss. 4. P. 38–46. <https://doi.org/10.17775/CSEEPES.2015.00046>.
7. Santhosh M., Venkaiah C., Kumar D.M.V. Current advances and approaches in wind speed and wind power forecasting for improved renewable energy integration: a review // *Engineering Reports*. 2020. Vol. 2. Iss. 6. P. e12178. <https://doi.org/10.1002/eng2.12178>.
8. Azad H.B., Mekhilef S., Ganapathy V.G. Long-term wind speed forecasting and general pattern recognition using neural networks // *IEEE Transactions on Sustainable Energy*. 2014. Vol. 5. Iss. 2. P. 546–553.

<https://doi.org/10.1109/TSTE.2014.2300150>.

9. Ahmed R., Sreeram V., Mishra Y., Arif M.D. A review and evaluation of the state-of-the-art in PV solar power forecasting: techniques and optimization // *Renewable and Sustainable Energy Reviews*. 2020. Vol. 124. P. 109792. <https://doi.org/10.1016/j.rser.2020.109792>.
10. Mehmood F., Ghani M.U., Asim M.N., Shahzadi R., Mehmood A., Mahmood W. MPF-Net: a computational multi-regional solar power forecasting framework // *Renewable and Sustainable Energy Reviews*. 2021. Vol. 151. P. 111559. <https://doi.org/10.1016/j.rser.2021.111559>.
11. Wang Xiaochen, Guo Peng, Huang Xiaobin. A review of wind power forecasting models // *Energy Procedia*. 2011. Vol. 12. P. 770–778. <https://doi.org/10.1016/j.egypro.2011.10.103>.
12. Varanasi J., Tripathi M.M. A comparative study of wind power forecasting techniques – A review article // *3rd International Conference on Computing for Sustainable Global Development (New Delhi, 16–18 March 2016)*. New Delhi: IEEE, 2016. P. 3649–3655.
13. Sweeney C., Bessa R.J., Browell J., Pinson P. The future of forecasting for renewable energy // *Wiley Interdisciplinary Reviews: Energy and Environment*. 2020. Vol. 9. Iss. 2. P. e365. <https://doi.org/10.1002/wene.365>.
14. Aslam S., Herodotou H., Mohsin S.M. Javaid N. Ashraf N., Aslam S. A survey on deep learning methods for power load and renewable energy forecasting in smart microgrids // *Renewable and Sustainable Energy Reviews*. 2021. Vol. 144. P. 110992. <https://doi.org/10.1016/j.rser.2021.110992>.
15. Hanifi S., Liu Xiaolei, Lin Zi, Lotfian S. A critical review of wind power forecasting methods—past, present and future // *Energies*. 2020. Vol. 13. Iss. 15. P. 3764. <https://doi.org/10.3390/en13153764>.
16. Voyant C., Notton G., Kalogirou S., Nivet M.-L., Paoli C., Motte F., et al. Machine learning methods for solar radiation forecasting: a review // *Renewable Energy*. 2017. Vol. 105. P. 569–582. <https://doi.org/10.1016/j.renene.2016.12.095>.
17. Zhou Kaile, Fu Chao, Yang Shanlin. Big data driven smart energy management: from big data to big insights // *Renewable and Sustainable Energy Reviews*. 2016. Vol. 56. P. 215–225. <https://doi.org/10.1016/j.rser.2015.11.050>.
18. Yeom Jong-Min, Deo R.C., Adamowski J.F., Chae Taebyeong, Kim Dong-Su, Han Kyung-Soo, et al. Exploring solar and wind energy resources in North Korea with COMS MI geostationary satellite data coupled with numerical weather prediction reanalysis variables // *Renewable and Sustainable Energy Reviews*. 2020. Vol. 119. P. 109570. <https://doi.org/10.1016/j.rser.2019.109570>.
19. Schultz M.G., Betancourt C., Gong B., Kleinert F., Langguth M., Leufen L.H. et al. Can deep learning beat numerical weather prediction? // *Philosophical Transactions of the Royal Society A*. 2021. Vol. 379. Iss. 2194. P. 20200097. <https://doi.org/10.1098/rsta.2020.0097>.
20. Andrade J.R., Bessa R.J. Improving renewable energy forecasting with a grid of numerical weather predictions // *IEEE Transactions on Sustainable Energy*. 2017. Vol. 8. Iss. 4. P. 1571–1580. <https://doi.org/10.1109/TSTE.2017.2694340>.
21. Aguiar L.M., Pereira B., Lauret P., Díaz F., David M. Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting // *Renewable Energy*. 2016. Vol. 97. P. 599–610. <https://doi.org/10.1016/j.renene.2016.06.018>.
22. Dutta S., Li Yanling, Venkataraman A., Costa L.M., Jiang Tianxiang, Plana R. et al. Load and renewable energy forecasting for a microgrid using persistence technique // *Energy Procedia*. 2017. Vol. 143. P. 617–622. <https://doi.org/10.1016/j.egypro.2017.12.736>.
23. Wang Jingmin, Zhou Qingwei, Zhang Xueting. Wind power forecasting based on time series ARMA model // *Earth and Environmental Science: IOP Conference series*. 2018. Vol. 199. Iss. 2. P. 022015. <https://doi.org/10.1088/1755-1315/199/2/022015>.
24. Singh B., Pozo D. A guide to solar power forecasting using ARMA models // *IEEE PES Innovative Smart Grid Technologies Europe ISGT-Europe*. 2019. <https://doi.org/10.1109/ISGTEurope.2019.8905430>.
25. Cadenas E., Rivera W., Campos-Amezcuea R., Heard C. Wind speed prediction using a univariate ARIMA model and a multivariate NARX model // *Energies*. 2016. Vol. 9. Iss. 2. P. 109. <https://doi.org/10.3390/en9020109>.
26. Grigonytė E., Butkeviciūtė E. Short-term wind speed forecasting using ARIMA model // *Energetika*. 2016. Vol. 62. Iss. 1-2. P. 3313. <https://doi.org/10.6001/energetika.v62i1-2.3313>.
27. Robles-Rodriguez C.E., Dochain D. Decomposed Threshold ARMAX Models for short-to medium-term wind power forecasting // *IFAC-PapersOnLine*. 2018. Vol. 51. Iss. 13. P. 49–54. <https://doi.org/10.1016/j.ifacol.2018.07.253>.
28. Li Yanting, Su Yan, Shu Lianjie. An ARMAX model for forecasting the power output of a grid connected photovoltaic system // *Renewable Energy*. 2014. Vol. 66. P. 78–89. <https://doi.org/10.1016/j.renene.2013.11.067>.
29. Dev S., AlSkaif T., Hossari M., Godina R., Louwen A., Sark W. Solar irradiance forecasting using triple exponential smoothing // *International Conference on Smart Energy Systems and Technologies SEST*. 2018. <https://doi.org/10.1109/SEST.2018.8495816>.
30. Zheng Xidong, Jin Tao. A reliable method of wind power fluctuation smoothing strategy based on multidimensional non-linear exponential smoothing short-term forecasting // *IET Renewable Power Generation*. 2022. Vol. 16. Iss. 16. P. 3573–3586. <https://doi.org/10.1049/rpg2.12395>.
31. Bulut M., Hakan T., Buaisa M. Comparison of three different learning methods of multilayer Perceptron neural network for wind speed forecasting // *Gazi University Journal of Science*. 2021. Vol. 34. Iss. 2. P. 439–454. <https://doi.org/10.35378/gujs.764533>.

32. Wang Zheng, Wang Bo, Liu Chun, Wang Wei-sheng. Improved BP neural network algorithm to wind power forecast // The Journal of Engineering. 2017. Vol. 2017. Iss. 13. P. 940–943. <https://doi.org/10.1049/joe.2017.0469>.
33. Abuella M., Chowdhury B. Solar power forecasting using artificial neural networks // North American Power Symposium NAPS. 2015. <https://doi.org/10.1109/NAPS.2015.7335176>.
34. Manusov V., Matrenin P., Nazarov M., Beryozkina S., Safaraliev M., Zicmane I., et al. Short-term prediction of the wind speed based on a learning process control algorithm in isolated power systems // Sustainability. 2023. Vol. 15. Iss. 2. P. 1730. <https://doi.org/10.3390/su15021730>.
35. Feng Cong, Zhang Jie. SolarNet: a sky image-based deep convolutional neural network for intra-hour solar forecasting // Solar Energy. 2020. Vol. 204. P. 71–78. <https://doi.org/10.1016/j.solener.2020.03.083>.
36. Zhu Qiaomu, Chen Jinfu, Zhu Lin, Duan Xianzhong, Liu Yilu, et al. Wind speed prediction with spatio-temporal correlation: a deep learning approach // Energies. 2018. Vol. 11. Iss. 4. P. 705. <https://doi.org/10.3390/en11040705>.
37. Alkhayat G., Mehmood R. A review and taxonomy of wind and solar energy forecasting methods based on deep learning // Energy and AI. 2021. Vol. 4. P. 100060. <https://doi.org/10.1016/j.egyai.2021.100060>.
38. Al-Sbou Y.A., Alawasa K.M. Nonlinear autoregressive recurrent neural network model for solar radiation prediction // International Journal of Applied Engineering Research. 2017. Vol. 12. Iss. 14. P. 4518–4527.
39. Cali U., Sharma V. Short-term wind power forecasting using long-short term memory based recurrent neural network model and variable selection // International Journal of Smart Grid and Clean Energy. 2019. Vol. 8. Iss. 2. P. 103–110. <http://doi.org/10.12720/sgce.8.2.103-110>.
40. Kisvari A., Lin Zi, Liu Xiaolei. Wind power forecasting – a data-driven method along with gated recurrent neural network // Renewable Energy. 2021. Vol. 163. P. 1895–1909. <https://doi.org/10.1016/j.renene.2020.10.119>.
41. Zendehboudi A., Baseer M.A., Saidur R. Application of support vector machine models for forecasting solar and wind energy resources: a review // Journal of Cleaner Production. 2018. Vol. 199. P. 272–285. <https://doi.org/10.1016/j.jclepro.2018.07.164>.
42. Li Ling-Ling, Zhao Xue, Tseng Ming-Lang, Tan Raymond R. Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm // Journal of Cleaner Production. 2020. Vol. 242. P. 118447. <https://doi.org/10.1016/j.jclepro.2019.118447>.
43. Jang Han Seung, Bae Kuk Yeol, Park Hong-Shik, Sung Dan Keun. Solar power prediction based on satellite images and support vector machine // IEEE Transactions on Sustainable Energy. 2016. Vol. 7. Iss. 3. P. 1255–1263. <https://doi.org/10.1109/TSTE.2016.2535466>.
44. Zhou Kaile, Fu Chao, Yang Shanlin. Big data driven smart energy management: from big data to big insights // Renewable and Sustainable Energy Reviews. 2016. Vol. 56. P. 215–225. <https://doi.org/10.1016/j.rser.2015.11.050>.
45. Matrenin P.V., Atabaeva L.S., Sergeev N.N. Limitations and perspectives of short-term renewable energy generation forecasting methods // IEEE International Multi-Conference on Engineering, Computer and Information Sciences SIBIRCON. 2022. <https://doi.org/10.1109/SIBIRCON56155.2022.10017051>.
46. Al-Dahidi S., Ayadi O., Alrbai M., Adeeb J. Ensemble approach of optimized artificial neural networks for solar photovoltaic power prediction // IEEE Access. 2019. Vol. 7. P. 81741–81758. <https://doi.org/10.1109/ACCESS.2019.2923905>.
47. Al-Jarrah O.Y., Yoo P.D., Muhaidat S., Karagiannidis G.K., Taha K. Efficient machine learning for big data: a review // Big Data Research. 2015. Vol. 2. Iss. 3. P. 87–93. <https://doi.org/10.1016/j.bdr.2015.04.001>.
48. Suresh V., Janik P., Rezmier J., Leonowicz Z. Forecasting solar PV output using convolutional neural networks with a sliding window algorithm // Energies. 2020. Vol. 13. Iss. 3. P. 723. <https://doi.org/10.3390/en13030723>.
49. Ziegler L., Gonzalez E., Rubert T., Smolka U., Melero J.J. Lifetime extension of onshore wind turbines: a review covering Germany, Spain, Denmark, and the UK // Renewable and Sustainable Energy Reviews. 2018. Vol. 82. Part 1. P. 1261–1271. <https://doi.org/10.1016/j.rser.2017.09.100>.
50. Kim Taeyoung, Ko Woong, Kim Jinho. Analysis and impact evaluation of missing data imputation in day-ahead PV generation forecasting // Applied Sciences. 2019. Vol. 9. Iss. 1. P. 204. <https://doi.org/10.3390/app9010204>.
51. Yen Chih-Feng, Hsieh He-Yen, Su Kuan-Wu, Yu Min-Chieh, Leu Jenq-Shiou. Solar power prediction via support vector machine and random forest // International Conference Green Energy and Smart Grids: E3S Web of Conferences. 2018. Vol. 69. P. 01004. <https://doi.org/10.1051/e3sconf/20186901004>.
52. Nie Yuhao, Zamzam A.S., Brandt A. Resampling and data augmentation for short-term PV output prediction based on an imbalanced sky images dataset using convolutional neural networks // Solar Energy. 2021. Vol. 224. P. 341–354. <https://doi.org/10.1016/j.solener.2021.05.095>.
53. Wang Zheng, Koprinska I., Rana M. Clustering based methods for solar power forecasting // International Joint Conference on Neural Networks IJCNN (Vancouver, 24–29 July 2016). Vancouver: IEEE, 2016. P. 1487–1494. <https://doi.org/10.1109/IJCNN.2016.7727374>.
54. Chen Hailang, Chang Xianfa. Photovoltaic power prediction of LSTM model based on Pearson feature selection // Energy Reports. 2021. Vol. 7. P. 1047–1054. <https://doi.org/10.1016/j.egypr.2021.09.167>.

## References

1. Ilyushin P.V. Integration of RES-based power plants into the unified energy system of Russia: problematic issues and approaches to solving them. *Vestnik Moskovskogo ehnergeticheskogo institute = Bulletin of Moscow Power Engineering Institute*. 2022;4:98-107. <https://doi.org/10.24160/1993-6982-2022-4-98-107>.
2. Kolosok S., Bilan Yu., Vasylieva T., Wojciechowski A., Morawski M. A scoping review of renewable energy, sustainability and the environment. *Energies*. 2021;14(15):4490. <https://doi.org/10.3390/en14154490>.
3. Qazi A., Hussain F., Rahim N. A., Hardaker G., Alghazzawi D., Shaban K., et al. Towards sustainable energy: a systematic review of renewable energy sources, technologies, and public opinions. *IEEE Access*. 2019;7:63837-63851. <https://doi.org/10.1109/ACCESS.2019.2906402>.
4. Sinsel S.R., Riemke R.L., Hoffmann V.H. Challenges and solution technologies for the integration of variable renewable energy sources – a review. *Renewable Energy*. 2020;145:2271-2285. <https://doi.org/10.1016/j.renene.2019.06.147>.
5. Yang Yuqing, Bremner Stephen, Menictas Chris, Kay Merlinde. Battery energy storage system size de-termination in renewable energy systems: a review. *Renewable and Sustainable Energy Reviews*. 2018;91:109-125. <https://doi.org/10.1016/j.rser.2018.03.047>.
6. Wan Can, Zhao Jian, Song Yonghua, Xu Zhao, Lin Jin, Hu Zechun. Photovoltaic and solar power forecasting for smart grid energy management. *CSEE Journal of Power and Energy Systems*. 2015;1(4):38-46. <https://doi.org/10.17775/CSEJEPES.2015.00046>.
7. Santhosh M., Venkaiah C., Kumar D.M.V. Current advances and approaches in wind speed and wind power forecasting for improved renewable energy integration: a review. *Engineering Reports*. 2020;2(6):e12178. <https://doi.org/10.1002/eng2.12178>.
8. Azad H.B., Mekhilef S., Ganapathy V.G. Long-term wind speed forecasting and general pattern recognition using neural networks. *IEEE Transactions on Sustainable Energy*. 2014;5(2):546-553. <https://doi.org/10.1109/TSTE.2014.2300150>.
9. Ahmed R., Sreeram V., Mishra Y., Arif M.D. A review and evaluation of the state-of-the-art in PV solar power forecasting: techniques and optimization. *Renewable and Sustainable Energy Reviews*. 2020;124:109792. <https://doi.org/10.1016/j.rser.2020.109792>.
10. Mehmood F., Ghani M.U., Asim M.N., Shahzadi R., Mehmood A., Mahmood W. MPF-Net: a computational multi-regional solar power forecasting framework. *Renewable and Sustainable Energy Reviews*. 2021;151:111559. <https://doi.org/10.1016/j.rser.2021.111559>.
11. Wang Xiaochen, Guo Peng, Huang Xiaobin. A review of wind power forecasting models. *Energy Procedia*. 2011;12:770-778. <https://doi.org/10.1016/j.egypro.2011.10.103>.
12. Varanasi J., Tripathi M.M. A comparative study of wind power forecasting techniques – A review article. In: *3rd International Conference on Computing for Sustainable Global Development*. 16–18 March 2016, New Delhi. New Delhi: IEEE; 2016, p. 3649-3655.
13. Sweeney C., Bessa R.J., Browell J., Pinson P. The future of forecasting for renewable energy. *Wiley Interdisciplinary Reviews: Energy and Environment*. 2020;9(2):e365. <https://doi.org/10.1002/wene.365>.
14. Aslam S., Herodotou H., Mohsin S.M., Javaid N., Ashraf N., Aslam S. A survey on deep learning methods for power load and renewable energy forecasting in smart microgrids. *Renewable and Sustainable Energy Reviews*. 2021;144:110992. <https://doi.org/10.1016/j.rser.2021.110992>.
15. Hanifi S., Liu Xiaolei, Lin Zi, Lotfian S. A critical review of wind power forecasting methods—past, present and future. *Energies*. 2020;13(15):3764. <https://doi.org/10.3390/en13153764>.
16. Voyant C., Notton G., Kalogirou S., Nivet M.-L., Paoli C., Motte F., et al. Machine learning methods for solar radiation forecasting: a review. *Renewable Energy*. 2017;105:569-582. <https://doi.org/10.1016/j.renene.2016.12.095>.
17. Zhou Kaile, Fu Chao, Yang Shanlin. Big data driven smart energy management: from big data to big insights. *Renewable and Sustainable Energy Reviews*. 2016;56:215-225. <https://doi.org/10.1016/j.rser.2015.11.050>.
18. Yeom Jong-Min, Deo R.C., Adamowski J.F., Chae Taebyeong, Kim Dong-Su, Han Kyung-Soo, et al. Exploring solar and wind energy resources in North Korea with COMS MI geostationary satellite data coupled with numerical weather prediction reanalysis variables. *Renewable and Sustainable Energy Reviews*. 2020;119:109570. <https://doi.org/10.1016/j.rser.2019.109570>.
19. Schultz M.G., Betancourt C., Gong B., Kleinert F., Langguth M., Leufen L.H. et al. Can deep learning beat numerical weather prediction? *Philosophical Transactions of the Royal Society A*. 2021;379(2194):20200097. <https://doi.org/10.1098/rsta.2020.0097>.
20. Andrade J.R., Bessa R.J. Improving renewable energy forecasting with a grid of numerical weather pre-dictions. *IEEE Transactions on Sustainable Energy*. 2017;8(4):1571-1580. <https://doi.org/10.1109/TSTE.2017.2694340>.
21. Aguiar L.M., Pereira B., Lauret P., Díaz F., David M. Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting. *Renewable Energy*. 2016;97:599-610. <https://doi.org/10.1016/j.renene.2016.06.018>.
22. Dutta S., Li Yanling, Venkataraman A., Costa L.M., Jiang Tianxiang, Plana R. et al. Load and renewable energy forecasting for a microgrid using persistence technique. *Energy Procedia*. 2017;143:617-622. <https://doi.org/10.1016/j.egypro.2017.12.736>.
23. Wang Jingmin, Zhou Qingwei, Zhang Xueting. Wind power forecasting based on time series ARMA model.

- In: *Earth and Environmental Science: IOP Conference series*. 2018;199(2):022015. <https://doi.org/10.1088/1755-1315/199/2/022015>.
24. Singh B., Pozo D. A guide to solar power forecasting using ARMA models. In: *IEEE PES Innovative Smart Grid Technologies Europe ISGT-Europe*. 2019. <https://doi.org/10.1109/ISGTEurope.2019.8905430>.
25. Cadenas E., Rivera W., Campos-Amezcuca R., Heard C. Wind speed prediction using a univariate ARIMA model and a multivariate NARX model. *Energies*. 2016;9(2):109. <https://doi.org/10.3390/en9020109>.
26. Grigonytė E., Butkeviciūtė E. Short-term wind speed forecasting using ARIMA model. *Energetika*. 2016;62(1-2):3313. <https://doi.org/10.6001/energetika.v62i1-2.3313>.
27. Robles-Rodriguez C.E., Dochain D. Decomposed Threshold ARMAX Models for short-to medium-term wind power forecasting. *IFAC-PapersOnLine*. 2018;51(13):49-54. <https://doi.org/10.1016/j.ifacol.2018.07.253>.
28. Li Yanting, Su Yan, Shu Lianjie. An ARMAX model for forecasting the power output of a grid connected photovoltaic system. *Renewable Energy*. 2014;66:78-89. <https://doi.org/10.1016/j.renene.2013.11.067>.
29. Dev S., AISkaif T., Hossari M., Godina R., Louwen A., Sark W. Solar irradiance forecasting using triple exponential smoothing. In: *International Conference on Smart Energy Systems and Technologies SEST*. 2018. <https://doi.org/10.1109/SEST.2018.8495816>.
30. Zheng Xidong, Jin Tao. A reliable method of wind power fluctuation smoothing strategy based on multi-dimensional non-linear exponential smoothing short-term forecasting. *IET Renewable Power Generation*. 2022;16(16):3573-3586. <https://doi.org/10.1049/rpg2.12395>.
31. Bulut M., Hakan T., Buaisha M. Comparison of three different learning methods of multilayer Perceptron neural network for wind speed forecasting. *Gazi University Journal of Science*. 2021;34(2):439-454. <https://doi.org/10.35378/gujs.764533>.
32. Wang Zheng, Wang Bo, Liu Chun, Wang Wei-sheng. Improved BP neural network algorithm to wind power forecast. *The Journal of Engineering*. 2017;2017(13):940-943. <https://doi.org/10.1049/joe.2017.0469>.
33. Abuella M., Chowdhury B. Solar power forecasting using artificial neural networks. In: *North American Power Symposium NAPS*. 2015. <https://doi.org/10.1109/NAPS.2015.7335176>.
34. Manusov V., Matrenin P., Nazarov M., Beryozkina S., Safaraliev M., Zicmane I., et al. Short-term prediction of the wind speed based on a learning process control algorithm in isolated power systems. *Sustainability*. 2023;15(2):1730. <https://doi.org/10.3390/su15021730>.
35. Feng Cong, Zhang Jie. SolarNet: a sky image-based deep convolutional neural network for intra-hour solar forecasting. *Solar Energy*. 2020;204:71-78. <https://doi.org/10.1016/j.solener.2020.03.083>.
36. Zhu Qiaomu, Chen Jinfu, Zhu Lin, Duan Xianzhong, Liu Yilu, et al. Wind speed prediction with spatio-temporal correlation: a deep learning approach. *Energies*. 2018;11(4):705. <https://doi.org/10.3390/en11040705>.
37. Alkhatay G., Mehmood R. A review and taxonomy of wind and solar energy forecasting methods based on deep learning. *Energy and AI*. 2021;4:100060. <https://doi.org/10.1016/j.egyai.2021.100060>.
38. Al-Sbou Y.A., Alawasa K.M. Nonlinear autoregressive recurrent neural network model for solar radiation prediction. *International Journal of Applied Engineering Research*. 2017;12(14):4518-4527.
39. Cali U., Sharma V. Short-term wind power forecasting using long-short term memory based recurrent neural network model and variable selection. *International Journal of Smart Grid and Clean Energy*. 2019;8(2):103-110. <http://doi.org/10.12720/sgce.8.2.103-110>.
40. Kisvari A., Lin Zi, Liu Xiaolei. Wind power forecasting – a data-driven method along with gated recurrent neural network. *Renewable Energy*. 2021;163:1895-1909. <https://doi.org/10.1016/j.renene.2020.10.119>.
41. Zendejboudi A., Baseer M.A., Saidur R. Application of support vector machine models for forecasting solar and wind energy resources: a review. *Journal of Cleaner Production*. 2018;199:272-285. <https://doi.org/10.1016/j.jclepro.2018.07.164>.
42. Li Ling-Ling, Zhao Xue, Tseng Ming-Lang, Tan Raymond R. Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm. *Journal of Cleaner Production*. 2020;242:118447. <https://doi.org/10.1016/j.jclepro.2019.118447>.
43. Jang Han Seung, Bae Kuk Yeol, Park Hong-Shik, Sung Dan Keun. Solar power prediction based on sat-ellite images and support vector machine. *IEEE Transactions on Sustainable Energy*. 2016;7(3):1255-1263. <https://doi.org/10.1109/TSTE.2016.2535466>.
44. Zhou Kaile, Fu Chao, Yang Shanlin. Big data driven smart energy management: from big data to big insights. *Renewable and Sustainable Energy Reviews*. 2016;56:215-225. <https://doi.org/10.1016/j.rser.2015.11.050>.
45. Matrenin P.V., Atabaeva L.S., Sergeev N.N. Limitations and perspectives of short-term renewable energy generation forecasting methods. In: *IEEE International Multi-Conference on Engineering, Computer and Information Sciences SIBIRCON*. 2022. <https://doi.org/10.1109/SIBIRCON56155.2022.10017051>.
46. Al-Dahidi S., Ayadi O., Alrbai M., Adeeb J. Ensemble approach of optimized artificial neural networks for solar photovoltaic power prediction. *IEEE Access*. 2019;7:81741-81758. <https://doi.org/10.1109/ACCESS.2019.2923905>.
47. Al-Jarrah O.Y., Yoo P.D., Muhaidat S., Karagiannidis G.K., Taha K. Efficient machine learning for big data: a review. *Big Data Research*. 2015;2(3):87-93. <https://doi.org/10.1016/j.bdr.2015.04.001>.
48. Suresh V., Janik P., Rezmer J., Leonowicz Z. Forecasting solar PV output using convolutional neural networks with a

sliding window algorithm. *Energies*. 2020;13(3):723. <https://doi.org/10.3390/en13030723>.

49. Ziegler L., Gonzalez E., Rubert T., Smolka U., Melero J.J. Lifetime extension of onshore wind turbines: a review covering Germany, Spain, Denmark, and the UK. *Renewable and Sustainable Energy Reviews*. 2018;82(1):1261-1271. <https://doi.org/10.1016/j.rser.2017.09.100>.

50. Kim Taeyoung, Ko Woong, Kim Jinho. Analysis and impact evaluation of missing data imputation in day-ahead PV generation forecasting. *Applied Sciences*. 2019;9(1):204. <https://doi.org/10.3390/app9010204>.

51. Yen Chih-Feng, Hsieh He-Yen, Su Kuan-Wu, Yu Min-Chieh, Leu Jenq-Shiou. Solar power prediction via support vector machine and random forest. In: *International Conference Green Energy and Smart Grids: E3S Web of Conferences*. 2018;69:01004. <https://doi.org/10.1051/e3sconf/20186901004>.

52. Nie Yuhao, Zamzam A.S., Brandt A. Resampling and data augmentation for short-term PV output prediction based on an imbalanced sky images dataset using convolutional neural networks. *Solar Energy*. 2021;224:341-354. <https://doi.org/10.1016/j.solener.2021.05.095>.

53. Wang Zheng, Koprinska I., Rana M. Clustering based methods for solar power forecasting. In: *International Joint Conference on Neural Networks IJCNN*. 24–29 July 2016, Vancouver. Vancouver: IEEE; 2016, p. 1487-1494. <https://doi.org/10.1109/IJCNN.2016.7727374>.

54. Chen Hailang, Chang Xianfa. Photovoltaic power prediction of LSTM model based on Pearson feature selection. *Energy Reports*. 2021;7:1047-1054. <https://doi.org/10.1016/j.egy.2021.09.167>.

### ИНФОРМАЦИЯ ОБ АВТОРАХ

#### Сергеев Никита Николаевич,

лаборант  
межкафедральной Научно-исследовательской  
лаборатории обработки, анализа и представления  
данных в электроэнергетических системах,  
Новосибирский государственный технический  
университет,  
630073, г. Новосибирск, пр-т К. Маркса, 20, Россия  
✉ [veegresatikin3102@gmail.com](mailto:veegresatikin3102@gmail.com)  
<https://orcid.org/0000-0003-1534-9072>

#### Матренин Павел Викторович,

к.т.н.,  
с.н.с. межкафедральной Научно-исследовательской  
лаборатории обработки, анализа и представления  
данных в электроэнергетических системах,  
Новосибирский государственный технический  
университет,  
630073, г. Новосибирск, пр-т К. Маркса, 20, Россия  
[matrenin.2012@corp.nstu.ru](mailto:matrenin.2012@corp.nstu.ru)  
<https://orcid.org/0000-0001-5704-0976>

### Вклад авторов

Все авторы сделали эквивалентный вклад в подготовку публикации.

### Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

*Все авторы прочитали и одобрили окончательный вариант рукописи.*

### Информация о статье

Статья поступила в редакцию 31.03.2023; одобрена после рецензирования 03.03.2023; принята к публикации 28.04.2023.

### INFORMATION ABOUT THE AUTHORS

#### Nikita N. Sergeev,

Laboratory Assistant of the  
Interdepartmental Research Laboratory  
for Processing, Analysis and Presentation of Data in  
Power Systems,  
Novosibirsk State Technical University,  
20, K. Marks pr., Novosibirsk 630073, Russia  
✉ [veegresatikin3102@gmail.com](mailto:veegresatikin3102@gmail.com)  
<https://orcid.org/0000-0003-1534-9072>

#### Pavel V. Matrenin,

Cand. Sci. (Eng.),  
Senior Researcher of the  
Interdepartmental Research Laboratory  
for Processing, Analysis and Presentation of Data in  
Power Systems,  
Novosibirsk State Technical University,  
20, K. Marks pr., Novosibirsk 630073, Russia  
[matrenin.2012@corp.nstu.ru](mailto:matrenin.2012@corp.nstu.ru)  
<https://orcid.org/0000-0001-5704-0976>

### Contribution of the authors

The authors contributed equally to the preparation of the article.

### Conflict of interests

The authors declare no conflicts of interests.

*The final manuscript has been read and approved by all the co-authors.*

### Information about the article

The article was submitted 31.03.2023; approved after reviewing 03.03.2023; accepted for publication 28.04.2023.