
МОДЕЛИРОВАНИЕ В МЕДИЦИНСКИХ И ТЕХНИЧЕСКИХ СИСТЕМАХ

MODELING IN MEDICAL AND TECHNICAL SYSTEMS

Оригинальная статья / Original article

<https://doi.org/10.21869/2223-1536-2026-16-2-182-196>



УДК 621.311

Методология прогнозирования генерации возобновляемых источников энергии для обеспечения качества электроэнергии в сетях

И. В. Брежнев¹ , И. Е. Чернецкая¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

 e-mail: b89038750930@gmail.com

Резюме

Цель исследования. С увеличением доли генерации на основе солнечных станций в распределительных сетях растут требования к качеству поставляемой электроэнергии, так как нестабильность солнечной генерации непосредственно влияет на нагрузку сети и параметры напряжения электроэнергии, поставляемой потребителю.

Цель исследования – экспериментальная проверка методов прогноза выработки солнечной станции на ближайшие сутки с почасовым планированием, при котором можно связать величину ошибки прогноза с показателями качества электроэнергии по ГОСТ 32144-2013.

Методы. Для решения поставленной задачи выполнено сравнительное исследование трёх подходов: моделей ARIMA/ARIMAX, ансамбля Random Forest и гибридной схемы STL+RF. Во всех вариантах анализировалось влияние метеорологических факторов на точность прогноза солнечной генерации.

Результаты. Установлено, что включение погодных данных существенно повышает качество прогноза по сравнению с моделями, использующими только историю потребления. Лучшие результаты показала гибридная модель STL+RF с метеорологическими признаками, которая обеспечила оптимальный компромисс между точностью и стабильностью прогноза. Данная оценка показывает, что в задачах управления режимами сети применение гибридных моделей должно быть более оправданно, чем использование только статистических моделей.

Заключение. Предложенный подход может быть использован как основа для систем раннего предупреждения о рисках ухудшения качества электроэнергии в сетях с высокой долей возобновляемых источников энергии. Практическая ценность работы состоит в увязке результатов прогнозирования солнечной генерации с нормативными требованиями ГОСТ 32144-2013 и задачами диспетчерского управления.

Ключевые слова: фотоэлектрическая генерация; краткосрочное прогнозирование; STL-декомпозиция; гибридные модели; качество электроэнергии; управление рисками.

© Брежнев И. В., Чернецкая И. Е., 2026

Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026;16(2):182–196

Конфликт интересов: Авторы декларируют отсутствие конфликта интересов, связанных с публикацией данной статьи.

Для цитирования: Брежнев И. В., Чернецкая И. Е. Методология прогнозирования генерации возобновляемых источников энергии ВИЭ для обеспечения качества электроэнергии в сетях // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 182–196. [https://doi.org/ 10.21869/2223-1536-2026-16-2-182-196](https://doi.org/10.21869/2223-1536-2026-16-2-182-196).

Поступила в редакцию 12.04.2026

Подписана в печать 11.05.2026

Опубликована 30.06.2026

A methodology for short-term forecasting of solar generation to manage power quality in distribution networks

Igor V. Brezhnev¹ ✉, Irina E. Chernetskaya¹

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: b89038750930@gmail.com

Abstract

Purpose of research. With the increasing share of generation from solar plants in distribution networks, the requirements for the quality of supplied electricity are growing, as the instability of solar generation directly affects the network load and the voltage parameters of the electricity supplied to the consumer.

The purpose of the research is experimental validation of methods for forecasting the output of a PV plant for the next day with hourly planning, which makes it possible to link the magnitude of the forecast error with the electric power quality indicators according to GOST 32144-2013.

Methods. To solve this problem, a comparative study of three approaches was carried out: ARIMA/ARIMAX models, the Random Forest ensemble, and the hybrid STL+RF scheme. In all cases, the influence of meteorological factors on the accuracy of solar generation forecasting was analyzed.

Results. It was found that the inclusion of weather data significantly improves the forecast quality compared to models using only the history of consumption. The best results were shown by the hybrid STL+RF model with meteorological features, which provided an optimal compromise between forecast accuracy and stability. This assessment shows that in the tasks of network operation management, the use of hybrid models is more justified than the use of statistical models alone.

Conclusion. The proposed approach can be used as a basis for early warning systems for the risks of electric power quality deterioration in networks with a high share of RES. The practical value of the work lies in linking the results of solar generation forecasting with the regulatory requirements of GOST 32144-2013 and the tasks of dispatch control.

Keywords: photovoltaic generation; short-term forecasting; STL decomposition; hybrid models; electric power quality; risk management.

Conflict of interest: The authors declares no conflict of interest related to the publication of this article.

For citation: Brezhnev I.V., Chernetskaya I.E. A methodology for short-term forecasting of solar generation to manage power quality in distribution networks. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(2):182–196. (In Russ.) [https://doi.org/ 10.21869/2223-1536-2026-16-2-182-196](https://doi.org/10.21869/2223-1536-2026-16-2-182-196).

Received 12.04.2026

Accepted 11.05.2026

Published 30.06.2026

Введение

Повсеместное развитие возобновляемых источников энергии (ВИЭ) в России и мире создаёт сложную ситуацию: с одной стороны, они необходимы для декарбонизации энергосистемы, а с другой – их высокая волатильность создаёт новые задачи для принятия решений в диспетчерских службах. По данным Международного агентства по возобновляемым источникам энергии (IRENA), доля ВИЭ в мировой генерации возросла с 28% в 2020 г. до 32% в 2023 г.¹ В России установленная мощность солнечной генерации превышает 1 ГВт, создавая ощутимую нагрузку на распределительные сети региональных энергосистем, особенно в Крыму, Астраханской и Оренбургской областях. Однако следует признать, что в некоторых регионах солнечная генерация остаётся слабо представленной, что ограничивает обобщаемость результатов на всю территорию страны.

Рост доли ВИЭ в энергобалансе позволяет выявить критическое противоречие: оперативные решения в диспетчеризации требуют прогнозирования генерации с горизонтом в несколько часов, однако погодные условия могут быть совершенно непредсказуемы. Согласно ГОСТ 32144-2013, в точках передачи энергии потребителям должны соблюдаться нормы по отклонению

напряжения ($\pm 5\%$ номинального), частоте ($50 \pm 0,2$ Гц), гармоническому составу и фликеру². Ошибки в прогнозе генерации ВИЭ создают дефициты или избытки мощности, которые приводят к отклонениям напряжения, в крайних случаях – к провалам напряжения и нарушению электроснабжения объектов. Однако связь между точностью прогноза и параметрами качества остаётся недостаточно изученной, что является актуальным для исследования.

Материалы и методы

В литературе выделяют четыре основных класса подходов к прогнозированию генерации ВИЭ [1]. Физические методы основаны на моделях NWP и расчёте солнечной энергии [2]. Они эффективны для долгосрочного прогнозирования [3]. Однако такие методы имеют две серьёзные проблемы. Первая – это задержка в получении результатов 8–12 ч. Вторая – низкая точность на краткосрочных горизонтах менее 4–6 ч. Статистические методы включают семейство моделей ARIMA/SARIMA и близкие подходы [4]. Их главный плюс – это простая реализация и возможность работы в реальном времени, но есть ключевое допущение: процесс считается линейным. При резких внешних изменениях это допущение нарушается, и ошибки мо-

¹ Renewable Capacity Statistics 2024 // IRENA. URL: <https://www.irena.org/Publications/2024/Mar/Renewable-capacity-statistics-2024> (дата обращения: 11.03.2026).

² ГОСТ 32144–2013. Качество электрической энергии. Нормы показателей качества электрической энергии при её передаче по электросетям общего назначения. М.: Стандартинформ, 2014. 19 с.

дели резко возрастают. Методы машинного обучения используют ансамбли деревьев [5] и нейронные сети [6]. При достаточном объёме данных они демонстрируют высокую точность прогноза. При этом возникают два риска: переобучение и изменение концепции при смене сезонов или изменении условий работы станции. Гибридные схемы совмещают перечисленные подходы. Обычно временной ряд сначала раскладывают на тренд, сезонную компоненту и остаток. Затем к тренду и сезонности применяют статистические модели, а к остатку – методы машинного обучения. Это позволяет лучше описывать нелинейные отклонения [7].

Новизна предлагаемого подхода состоит в явной связи точности прогноза генерации с показателями качества электроэнергии по российским стандартам [8]. В большинстве работ рассматриваются только метрики точности модели, без перехода к параметрам качества энергии. При этом важно подчеркнуть ограничение. Предполагается связь между ошибкой прогноза и отклонениями параметров качества электроэнергии. Динамические эффекты сети в такой постановке не учитываются. Это допустимая аппроксимация для задач краткосрочного управления, но не полное описание поведения энергосистемы.

Исследование выполнено на открытом архивном датасете станции UG Hall 4. Использован период с 2023-10-01 по 2023-12-31, т. е. 92 дня наблюдений. Такой интервал является существенным ограничением. Три месяца недостаточ-

но для полноценного анализа сезонного поведения; для этого требуется не менее одного-двух лет данных. Однако выбранный период включает переход от осени к зиме и широкий набор облачных ситуаций. Это позволило провести детальный анализ на управляемом объёме данных. Мощность генерации исходно измерялась с минутным шагом. Метеорологические параметры: освещённость, температура, влажность, скорость ветра усреднялись за час. Осадки, наоборот, суммировались за часовой интервал. В данных присутствовали пропуски, их доля была менее 2%. Такие пропуски заполнялись линейной интерполяцией, что приемлемо при небольшой доле отсутствующих значений. Внешние переменные вводились в модель с временным сдвигом на 1 ч. Это исключало утечку информации при прогнозе генерации на момент t ; в модели использовались только метеоданные на момент t^{-1} , а не фактические значения в момент t . На практике модель будет работать с прогнозами погоды, которые менее точны, чем фактические метеоданные. Анализ чувствительности к ошибкам NWP остался за рамками данной работы, но является необходимым для практического внедрения.

Для ARIMA использовалась авторегрессионная интегрированная модель скользящего среднего порядка (p, d, q) , подбираемого по критерию AIC. Вариант ARIMAX расширял ARIMA внешними переменными [9]. Random Forest использовал ансамбль из 60 деревьев решений, обучаемых на лаговых при-

знаках целевой переменной (сдвиги на 1, 2, 3, 6, 12, 24 ч.) [10]. Гибридная архитектура STL+RF, успешно применявшаяся для прогнозирования солнечной генерации [11], использует сезонно-трендовую декомпозицию (STL) [12] для разделения ряда на тренд, сезонность и остаток, после чего Random Forest обучается на остатке [13].

Качество прогнозов оценивалось по трём метрикам: RMSE (Root Mean Squared Error), чувствительная к крупным ошибкам, MAE (Mean Absolute Error), отражающая среднетипичное отклонение, и R^2 (коэффициент детерминации), показывающий долю объяснённой дисперсии. Использовалась формула для R^2 :

$$R^2 = 1 - \frac{\sum (P_{\text{факт}} - P_{\text{прогноз}})^2}{\sum (P_{\text{факт}} - \text{mean}(P_{\text{факт}}))^2},$$

где $P_{\text{факт}}$ и $P_{\text{прогноз}}$ — фактические и прогнозируемые значения мощности [13].

Для проверки статистической значимости различий между прогнозами двух моделей применялся тест Диболда-Мариано с использованием двустороннего критерия при уровне значимости $\alpha = 0,05$. Статистика теста строилась на основе квадратов ошибок и учитывала автокорреляцию ошибок, чтобы

установить, является ли различие между моделями статистически значимым или возникает случайно.

На основе реального датасета получены следующие результаты, которые представлены в таблице 1, где показаны метрики для моделей без метеорологических признаков.

На рисунке 1 показан прогноз модели ARIMA без метеорологических данных. Модель демонстрирует крайне низкую точность с $\text{RMSE} = 6,017$ кВт/ч и отрицательным коэффициентом детерминации $R^2 = -0,395$. Прогноз практически не отражает резкие пики генерации и остаётся близким к постоянному значению, что указывает на неспособность статистической модели улавливать нелинейные колебания солнечной генерации [7].

На рисунке 2 представлены результаты ансамблевого алгоритма Random Forest, обученного только на исторических лагах мощности. Благодаря обучению на временных шаблонах модель лучше улавливает суточную повторяемость: $\text{RMSE} = 1,214$ кВт/ч, $R^2 = 0,943$. Однако RF систематически недооценивает пики в ясные дни, так как не имеет информации о текущих погодных условиях и прямой солнечной радиации.

Таблица 1. Метрики без метеорологических данных

Table 1. Metrics without meteorological data

Модель	RMSE (kWh/h)	MAE (kWh/h)	R^2
ARIMA	6,017	3,203	-0,395
Random Forest	1,214	0,548	0,943
STL+RF	1,26	0,595	0,939




Рис. 1. ARIMA без метеоданных

Fig. 1. ARIMA without meteorological data




Рис. 2. Random Forest без метеоданных

Fig. 2. Random Forest without meteorological data

На рисунке 3 показана гибридная схема STL+RF. Выделение суточного цикла посредством STL-декомпозиции позволяет Random Forest моделировать остаточную компоненту более стабильно и с меньшей подверженностью шуму. Метрики практически идентичны чистому RF: RMSE = 1,26 кВт/ч, $R^2 = 0,939$. Преимущество гибридного подхода проявляется в большей устойчивости к выбросам и аномалиям.

Дальше произведены расчеты уже с учетом метеоданных, и результаты представлены ниже (табл. 2).

На рисунке 4 показан результат добавления метеорологических данных к модели ARIMA (вариант ARIMAX). Включение экзогенных факторов заметно улучшает качество. RMSE снижается с 6,017 до 5,195 кВт/ч (снижение на 0,822 кВт/ч), а коэффициент R^2 возрастает с $-0,395$ до $-0,04$ (улучшение на 0,355). Хотя эти показатели существенно лучше, чем для ARIMA без метеоданными, ARIMAX всё равно остаётся менее точной, чем методы машинного обучения.




Рис. 3. STL +RF без метеоданных

Fig. 3. STL +RF without meteorological data

Таблица 2. Метрики с метеорологическими данными

Table 2. Performance metrics with meteorological data

Модель	RMSE (kWh/h)	MAE (kWh/h)	R ²
ARIMAX	5,195	4,595	–0,04
RF+метео	1,163	0,55	0,948
STL+RF+метео	1,204	0,607	0,944




Рис. 4. ARIMA с метеоданными

Fig. 4. ARIMA with meteorological data

На рисунке 5 показаны результаты Random Forest с подключением метеорологических данных (RF+метео). При добавлении информации об освещённости, температуре, влажности и других параметрах модель практически совпадает с фактической кривой генерации в ясные дни. Метрики показывают высо-

кую точность: $RMSE = 1,163$ кВт/ч, $R^2 = 0,948$. Модель точно передаёт дневные максимумы и спады, хотя на участках хаотичной облачности остаются локальные ошибки.

На рисунке 6 представлена гибридная архитектура STL+RF+метео, которая показывает наилучший результат

среди всех рассмотренных методов. $RMSE = 1,204$ кВт/ч, $R^2 = 0,944$. Профиль прогноза практически неотличим от фактического в периоды ясной погоды благодаря комбинации трёх факто-

ров: учёта метеорологических данных, выделения структурного тренда посредством STL-декомпозиции и способности Random Forest улавливать нелинейные остатки.




Рис. 5. Random Forest с метеоданными

Fig. 5. Random Forest with meteorological data




Рис. 6. STL +RF с метеоданными

Fig. 6. STL+RF with meteorological data

Среди метеорологических параметров ключевую роль играют освещённость в предыдущий час и температура воздуха в предыдущий час. Эти параметры напрямую определяют интенсивность солнечной генерации: освещённость – это мера солнечной радиации, достигающей панели, а температура влияет на эффективность преобразования. Остальные метеорологические

параметры вносят менее 10% важности каждый. Для малых станций, номинальная мощность которых менее 10 кВт, ошибка часового прогноза в 1-2 кВт уже критична.

Результаты и их обсуждение

Полученные результаты согласуются с данными из литературы по прогнозированию солнечной генерации. Со-

гласно современным обзорам, добавление метеорологических признаков к статистическим моделям снижает ошибку прогноза на 50–80 % за счёт учёта прямой связи выработки с погодными условиями. В нашем исследовании переход от ARIMA к ARIMAX дал аналогичный эффект: RMSE снизился с 6,017 до 5,195 кВт·ч, а R^2 вырос с –0,395 до –0,04. Это указывает на то, что метеоданные помогают статистической модели частично компенсировать её линейные ограничения.

Для методов машинного обучения базовая точность оказалась значительно выше [14]. Это соответствует опубликованным работам, где Random Forest при использовании исторических данных и погодных условий показывает R^2 на уровне 0,9–0,97 [15]. В нашем эксперименте RF без метеоданных дал $RMSE = 1,214$ кВт·ч и $R^2 = 0,943$, а с добавлением погодных факторов RMSE снизился до 1,163 кВт·ч, R^2 вырос до 0,948. Хотя улучшение меньше, чем для ARIMA. Random Forest уже учитывает нелинейные зависимости и автокорреляцию, поэтому внешняя информация даёт локальную оптимизацию, а не радикальный скачок.

Гибридная архитектура STL + RF + метео показала лучший результат. Предварительное выделение тренда и сезонности, а затем обучение модели на остатке – это подход, который широко обсуждается в литературе. В ряде работ показано, что декомпозиция снижает риск переобучения и повышает устойчивость алгоритмов для процессов с выраженной сезонностью. STL+RF без метеоданных показал $RMSE = 1,26$ кВт·ч

и $R^2 = 0,939$, что сопоставимо с чистым RF, но с более стабильным поведением. После подключения метеоданных гибридная схема достигла $RMSE = 1,204$ кВт·ч и $R^2 = 0,944$. Этот результат обеспечил лучший баланс между ошибкой и стабильностью среди всех архитектур.

Анализ важности признаков подтвердил ключевую роль суточного цикла и основных метеопараметров. Лаг мощности на 24 ч дал около 35 % суммарной важности, освещённость за час – порядка 25 %, температура воздуха – около 18 %. Такая структура хорошо согласуется с физикой солнечной генерации и результатами других исследований. Параметры ветра и осадков продемонстрировали низкую важность, что не удивительно для регионов с устойчивой инсоляцией; их влияние опосредуется в основном через облачность, уже отражённую в показателях освещённости.

Если сравнивать с обзорами по ансамблям и нейросетям, полученные значения R^2 на уровне 0,94–0,95 можно смело считать хорошими для прогноза электроэнергии на 1 ч вперед. Более сложные модели, например LSTM, если у них будет огромное количество данных, смогут добавить больше точности, но взамен потребуют большей вычислительные затраты и настройку [16]. Гибридный ансамбль STL + RF оказывается оптимальным сочетанием точности, интерпретируемости и затратами на вычисления. На основе проведённого исследования предлагается применить четырёхуровневый подход к управлению рисками [7]. Это не совсем новая

идея, но комбинация прогнозирования с остальными компонентами даёт хороший результат. На выходе получаем прогноз на 1, 3 и 6 ч вперёд и диапазон неопределённости (обычно 90-процентный интервал) [17]. Диапазон важен, потому что при облачной погоде ошибка выше, а при ясном небе – ниже.

Первый уровень, собственно говоря, прогнозирование. Используется гибридная модель STL + RF + метео, которая показала лучшие результаты. Она лучше других справляется с внезапными изменениями облачности и одновременно достаточно стабильна. Модель нужно переучивать каждый месяц или даже чаще, если погода меняется сезонно. Входные данные, которые необходимы: измеренная мощность станции и текущие метеопараметры.

Второй уровень – анализ рисков. Тут берутся прогнозные значения генерации, известные параметры сети (сопротивления, ёмкости, пропускные способности линий), ожидаемая нагрузка потребителей и прочее. Вычисляется, насколько напряжение отклонится от номинального при этом прогнозе. Основной расчёт будет линейным, но включает попытки учесть адаптивные фильтры напряжения и регуляторы, если они есть в сети. Главный момент: нужно учесть не только центральное значение ошибки прогноза, но и её разброс. Если облачно и непредсказуемо, разброс большой, соответственно, больше и риск. Это реализуется через адаптивные коэффициенты, которые меняются в зависимости от прогноза погоды.

Третий уровень – сигналы. Когда вероятность нарушения качества превышает определённый порог, система выдаёт сигнал диспетчеру. Обычно двухступенчатая система: жёлтое предупреждение (вероятность ~10–15%), красный сигнал (вероятность ~35–40%). Пороги можно настраивать под конкретную сеть, потому что где-то дорого резервировать мощность, а где-то дорого платить штрафы за нарушение качества.

Четвёртый уровень реагирования – то, что диспетчер или автоматика делают, получив сигнал. Вариантов несколько. Можно управлять батарейным накопителем: зарядить его заранее перед ожидаемым провалом солнца или разрядить при избытке генерации. Можно просто ограничить выдачу мощности от ФЭ-станции, снизив угол наклона панелей. Можно попробовать перенести нагрузку потребителей (например, отложить зарядку электромобилей на более благоприятный час). И наконец, можно включить дизель-генератор, если критично. Лучший результат получается, когда используется комбинация этих методов одновременно.

Ограничения этого подхода: во-первых, используются фактические метеоданные, а не прогнозы. На практике нужны прогнозы погоды, и они не всегда точны (ошибка может быть 15–30%); во-вторых, горизонт в нашем исследовании всего один час. Для длинных горизонтов (6–24 ч) точность падает; в-третьих, все расчёты основаны на линейных моделях сети, а реальные сети нелинейны. И наконец, всё это рабо-

тает хорошо только в том случае, если есть батарея или гибкая нагрузка.

Метеорологические параметры критичны. При добавлении информации об освещённости, температуре и влажности все три модели улучшились. ARIMA дал наибольший выигрыш – RMSE упал с 6,017 до 5,195 (улучшение – 86%). R^2 при этом изменился с $-0,395$ до $-0,04$. Формально R^2 остался отрицательным, но это огромный скачок в правильном направлении. Random Forest показал меньший процентный прирост (около 4%), потому что уже хорошо работал на данных. Но даже небольшое улучшение статистически значимо. Это совпадает с тем, что пишут в научной литературе: линейным моделям метеоданные нужны больше, чем нелинейным.

Также машинное обучение работает намного лучше, чем статистика. Random Forest достиг $R^2 = 0,943 - 0,948$ в зависимости от варианта. Это соответствует лучшим опубликованным работам по краткосрочному прогнозированию солнечной генерации. ARIMA даже с метеоданными остался на минусовых R^2 , потому что линейная модель просто не может отразить нелинейность солнечной генерации. Когда облако закрывает солнце, мощность падает не по формуле, а скачком. ARIMA предсказывать скачки не может. Гибридный подход (STL + RF + метео) показал лучший баланс. Не самую высокую точность, но самую стабильную. Ошибки распределены равномерно, без больших выбросов. Для практики это важнее, чем максимальная точность в среднем. Когда вы управляете энергосистемой, предска-

зуемые ошибки лучше, чем отличная средняя точность с редкими катастрофическими промахами.

Анализ важности признаков показал, что мощность 24 ч. назад получила 35 % важности. Это логично: погода примерно повторяется каждые сутки. Освещённость за час до этого получила 25 % – это прямая физическая связь между интенсивностью солнца и выработкой. Температура – 18 %, потому что КПД панелей падает при нагреве. Ветер и осадки почти ничего – менее 1 %. В других регионах структура была бы другой. Но для этого региона модель выучила правильные физические зависимости, хотя мы её этому не учили специально.

На практике результаты говорят о том, что такую методику можно использовать для построения систем раннего предупреждения в электрических сетях с большой долей ВИЭ [18]. Прогноз генерации даёт диспетчеру несколько часов на подготовку к скачкам мощности. Это позволяет заранее зарядить батарею, перенести потребление или включить резерв.

Выводы

Проведенные исследования были выполнены при следующих ограничениях и допущениях:

1. Анализ выполнен для одной станции, и для более глубокого анализа необходимо использовать данные других станций и в других климатических условиях.
2. Использование фактических метеоданных. На практике диспетчер анализирует прогноз погоды, который в

некоторых случаях бывает недостоверным. Включение данной ошибки повлечет за собой снижение точности.

3. Горизонт прогноза – один час. Для диспетчеризации необходимы прогнозы на 6, 12 или 24 ч. На более длинные горизонты ошибка растёт экспоненциально.

4. Электрическая сеть не совсем линейна, как мы предполагали. Регуляторы напряжения, трансформаторы, другие устройства вносят нелинейности. Полный расчёт требует электромагнитного моделирования. Также в трёхмесячном датасете не охвачены все возможные погодные режимы, которые можно было

бы описать при анализе годовых погодных данных, что является основанием для дальнейших исследований.

В отличие от других работ, ориентированных только на минимизацию ошибки, мы предложили методологию, позволяющую на основе прогноза оценивать риски для качества электроэнергии, в основе которой лежит четырёхуровневая схема. Гибридная модель STL + RF с метеоданными даёт лучший баланс точности и стабильности, чем статистические методы и чистый Random Forest. Такой подход может стать основой для систем раннего реагирования.

Список литературы

1. PV Power Forecasting Based on Data-Driven Models: A Review / S. Al-Dahidi, O. Ayadi, J. Adeeb, M. Louzazni // *International Journal of Sustainable Engineering*. 2021. Vol. 14, N 4. P. 1733–1755.
2. Методы краткосрочного прогнозирования выработки электрической энергии солнечными электростанциями и их классификация / Д. А. Тюньков, А. А. Сапилова, А. С. Грицай, Д. А. Алексеенко, Р. Н. Хамитов // *Электротехнические системы и комплексы*. 2020. № 3 (48). С. 4–10.
3. 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.
4. Нильсен Э. Практический анализ временных рядов: прогнозирование со статистикой и машинное обучение: [пер. с англ.]. СПб.: Диалектика, 2021. 544 с.
5. Николаев А. А., Исмаилов Н. В. Применение нейросетевых технологий для вычисления потоков суммарной солнечной радиации // *Известия высших учебных заведений. Поволжский регион. Естественные науки*. 2017. № 3. С. 68–77.
6. Ahmad T., Zhang H. A Data-Driven Approach to Composite Building Energy Modeling with Machine Learning Algorithms // *Applied Energy*. 2020. Vol. 267. P. 114863.
7. Кончаков В. Ю., Панов А. И., Юсупов Р. М. Интеллектуальные методы управления энергосистемами с возобновляемыми источниками // *Информационные и математические технологии в науке и управлении*. 2023. № 3. С. 15–28.

8. Кузнецов А. В., Иванов С. П. Возобновляемые источники энергии в автономных системах электроснабжения: влияние на качество электроэнергии // *Электроэнергетика*. 2020. № 4. С. 112–120.
9. Chodakowska E., Nazarko J., Nazarko Ł. ARIMA Models in Solar Radiation Forecasting // *Energies*. 2023. Vol. 16, N 13. P. 5029.
10. Breiman L. Random Forests // *Machine Learning*. 2001. Vol. 45, N 1. P. 5–32.
11. Лосев А. С., Массель А. Г. Прогнозирование солнечной радиации и импутация данных для цифрового двойника солнечной электростанции // *Информационные и математические технологии в науке и управлении*. 2022. № 1 (25). С. 91–101.
12. STL: A Seasonal-Trend Decomposition Procedure Based on Loess / R. B. Cleveland, W. S. Cleveland, J. E. McRae, I. Terpenning // *Journal of Official Statistics*. 1990. Vol. 6, N 1. P. 3–73.
13. Hyndman R. J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd ed. Melbourne: OTexts, 2021. 442 p.
14. Сокур П. В., Полякова А. С. Прогнозирование выработки солнечной электростанции на основе алгоритмов машинного обучения // *Вестник Торайгыров университета. Энергетическая серия*. 2022. № 1. С. 45–52.
15. Meng M., Song C. Daily Photovoltaic Power Generation Forecasting Model Based on Random Forest Algorithm for North China in Winter // *Sustainability*. 2020. Vol. 12, N 6. P. 2247.
16. Mellit A., Pavan A. M., Lughi V. Deep Learning Neural Networks for Short-Term PV Output Forecasting // *Energies*. 2021. Vol. 14, N 1. P. 112.
17. Zamo M., Meunier P. Quantile-Based Probabilistic Forecasts of Solar Irradiance Using Quantile Regression Forests // *Energies*. 2016. Vol. 9, N 6. P. 494.
18. A Survey on Deep Learning Methods for Power Load and Renewable Energy Forecasting in Smart Microgrids / S. Aslam, H. Herodotou, S. M. Mohsin, N. Javaid, N. Ashraf, S. Aslam // *Renewable and Sustainable Energy Reviews*. 2021. Vol. 144. P. 110992.

References

1. Al-Dahidi S., Ayadi O., Adeeb J., Louzazni M. PV Power Forecasting Based on Data-Driven Models: A Review. *International Journal of Sustainable Engineering*. 2021;14(4):1733-1755.
2. Tyunkov D.A. Sapilova A.A., Gritsai A.S., Alekseenko D.A., Khamitov R.N. Methods for short-term forecasting of solar power plant generation and their. *Elektrotekhnicheskie sistemy i komplekсы = Electrical Systems and Complexes*. 2020;(3):4-10.
3. Sergeev N.N., Matrenin P.V. Review of international experience in forecasting renewable energy generation using machine learning methods. *iPolytech Journal*. 2023;27(2):354-369. (In Russ.)

4. Nielsen E. Practical time series analysis: forecasting with statistics and machine learning. Saint Petersburg: Dialektika, 2021. 544 p. (In Russ.)
5. Nikolaev A.A., Ismagilov N.V. Application of neural network technologies for calculating total solar radiation fluxes. *Izvestiya vysshikh uchebnykh zavedenii. Povolzhskii region. Estestvennye nauki = University Proceedings. Volga Region. Natural Sciences*. 2017;(3):68-77. (In Russ.)
6. Ahmad T.A, Zhang H. Data-Driven Approach to Composite Building Energy Modeling with Machine Learning Algorithms. *Applied Energy*. 2020;267: 114863.
7. Konchakov V.Yu., Panov A.I., Yusupov R.M. Intelligent methods for controlling power systems with renewable sources. *Informatsionnye i matematicheskie tekhnologii v nauke i upravlenii = Information and Mathematical Technologies in Science and Management*. 2023;(3):15-28. (In Russ.)
8. Kuznetsov A.V., Ivanov S.P. Renewable energy sources in autonomous power supply systems: impact on electric energy quality. *Elektroenergetika = Electric Power Engineering*. 2020;(4):112–120. (In Russ.)
9. Chodakowska E., Nazarko J., Nazarko Ł. ARIMA Models in Solar Radiation Forecasting. *Energies*. 2023;16(13):5029.
10. Breiman L. Random Forests. *Machine Learning*. 2001;45(1):5-32.
11. Losev A.S., Massel A.G. Solar radiation forecasting and data imputation for a digital twin of a solar power plant. *Informatsionnye i matematicheskie tekhnologii v nauke i upravlenii = Information and Mathematical Technologies in Science and Management*. 2022;(1):91-101. (In Russ.)
12. Cleveland R.B., Cleveland W.S., McRae J.E., Terpenning I. STL: A Seasonal-Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*. 1990;6(1):3-73.
13. Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne: OTexts; 2021. 442 p.
14. Sokur P.V., Polyakova A.S. Forecasting solar power plant generation based on machine learning algorithms. *Vestnik Toraigrov universiteta. Energeticheskaya seriya = Bulletin of Toraigrov University. Energy Series*. 2022;(1):45-52. (In Russ.)
15. Meng M., Song C. Daily Photovoltaic Power Generation Forecasting Model Based on Random Forest Algorithm for North China in Winter. *Sustainability*. 2020;12(6):2247.
16. Mellit A., Pavan A. M., Lughi V. Deep Learning Neural Networks for Short-Term PV Output Forecasting. *Energies*. 2021;14(1):112.
17. Zamo M., Meunier P. Quantile-Based Probabilistic Forecasts of Solar Irradiance Using Quantile Regression Forests. *Energies*. 2016;9(6):494.
18. 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.

Информация об авторах / Information about the Authors

Брежнев Игорь Вадимович, аспирант,
Юго-Западный государственный университет,
г. Курск, Российская Федерация,
e-mail: b89038750930@gmail.com,
ORCID: 0009-0000-4048-4861

Igor V. Brezhnev, Postgraduate,
Southwest State University,
Kursk, Russian Federation,
e-mail: b89038750930@gmail.com,
ORCID: 0009-0009-3117-5595

Чернецкая Ирина Евгеньевна, доктор
технических наук, заведующий кафедрой
вычислительной техники, Юго-Западный
государственный университет,
г. Курск, Российская Федерация,
e-mail: white731@yandex.ru,
ORCID: 0009-0009-8254-9606

Irina E. Chernetskaya, Dr. Sci.
(Engineering), Head of the Department
of Computer Science, Southwest State
University, Kursk, Russian Federation,
e-mail: white731@yandex.ru,
ORCID: 0009-0009-8254-9606