

ПРОГНОЗИРОВАНИЕ ВЫРАБОТКИ ЭЛЕКТРОЭНЕРГИИ ФОТОЭЛЕКТРИЧЕСКОЙ СТАНЦИИ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

Зацаринная Ю.Н.¹, Реутин Г. В.¹, Курилов С.С.¹, Исаева О.В.¹, Ковалев Г.С.²

¹Казанский государственный энергетический университет, г. Казань, Россия

²Казанский федеральный университет, г. Казань, Россия

Резюме: *АКТУАЛЬНОСТЬ.* Сегодня степень интеграции ВИЭ в энергосистему является показателем технологического и промышленного развития государства. Возобновляемая энергетика является драйвером развития экономики, науки и образования. В России самый большой технический потенциал из возобновляемых источников энергии у Солнца (в млн. тоннах условного топлива) составляет $2,3 \cdot 10^3$, второе место занимает энергия ветра - $2 \cdot 10^3$. Но при использовании энергии Солнца, как и многих других возобновляемых источников энергии, возникают большие сложности с прогнозированием выработки электроэнергии из-за зависимости их от метеоусловий. Авторами статьи решается актуальная задача прогнозирования генерации энергии от солнечных электрических станций с использованием систем машинного обучения. **ЦЕЛЬ.** Целью данной работы является исследование производительности современных методов искусственного интеллекта для создания платформы прогнозирования вырабатываемой мощности от солнечной станции в существующую сеть. Разработать архитектуру информационно-коммуникационной системы распределительной сети и модель прогнозирования фотоэлектрической мощности электрической станции на основе методов машинного обучения. **МЕТОДЫ.** Одним из подходов к решению этой задачи является использование алгоритмов машинного обучения. Такие алгоритмы при правильно выбранной модели обучения способны с высокой точностью до 95% предсказывать объем генерации электроэнергии на сутки вперед. **РЕЗУЛЬТАТЫ.** Проведено сравнение значений реальной генерации и предсказанной генерации пятью алгоритмами машинного обучения, такие как нейронные сети, линейная регрессия, дерево решений, случайный лес, адаптивный бустинг. Наименьшую среднеквадратическую ошибку на проверочных данных имеет алгоритм случайного леса. Решена задача оптимизации радиальной топологии сети, которая минимизирует совокупные потери активной мощности. **ЗАКЛЮЧЕНИЕ.** Анализ построения рабочей модели машинного обучения, продемонстрировал, что для построения оптимальной модели, необходима только история выработки электроэнергии этой станции, сопоставленная с рассчитанными и измеренными данными погоды. Стабильность модели была проверена путем применения метода перекрестной проверки в различных условиях обучения и тестирования. Полученные результаты показали, что модель надежно работает, поскольку среднеквадратическая ошибка самой точной модели находится в районе $600 \text{ кВт} \cdot \text{ч}$ (4 %).

Ключевые слова: *распределенная генерация; возобновляемая энергетика; солнечная электростанция; прогнозирование выработки солнечной энергии; искусственный интеллект; машинное обучение.*

Для цитирования: Зацаринная Ю. Н., Реутин Г. В., Курилов С.С., Исаева О.В., Ковалев Г.С. Прогнозирование выработки электроэнергии от ВИЭ методами машинного обучения // Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2023. Т.25. № 3. С.81-92. doi:10.30724/1998-9903-2023-25-3-81-92

PREDICTION OF ELECTRICITY GENERATION FROM RES BY MACHINE LEARNING METHODS

YUN. Zacarinnaya¹, GV. Reutin¹, SS. Kurilov¹, OV. Isaeva¹, GS. Kovalev²

¹Kazan State Power Engineering University, Russia

²Kazan Federal University, Russia

Abstract: *RELEVANCE.* Today, the degree of integration of renewable energy sources into the energy system is an indicator of the technological and industrial development of the state. Renewable energy is a driver for the development of the economy, science and education. In Russia, the largest technical potential from renewable energy sources in the Sun (in million tons of standard fuel) is $2.3 \cdot 10^3$, the second place is occupied by wind energy - $2 \cdot 10^3$. However, the use of solar energy is associated with great difficulties in predicting the generation of electricity due to its dependence on meteorological conditions, and there is an acute issue of forecasting the generation.

In this article, the authors propose a solution to the urgent problem of predicting energy generation from solar power plants using machine learning systems. TARGET. The purpose of this work is to study the performance of modern artificial intelligence methods to create a platform for predicting the power generated from a solar station to an existing network. Develop the architecture of the information and communication system of the distribution network and the model for predicting the photovoltaic power of the power plant based on machine learning methods. *METHODS.* One approach to solving this problem is to use machine learning algorithms. Such algorithms, with a correctly chosen training model, are capable of predicting the volume of electricity generation a day ahead with a high accuracy of up to 95%. *RESULTS.* The values of real generation and predicted generation were compared by five machine learning algorithms, such as neural networks, linear regression, decision tree, random forest, adaptive boosting. The random forest algorithm has the smallest mean square error on the test data. The problem of optimization of the radial topology of the network, which minimizes the total loss of active power, is solved. *CONCLUSION.* An analysis of the construction of a working machine learning model showed that in order to build an optimal model, only the history of the power generation of this plant, compared with the calculated and measured weather data, is needed. The stability of the model was tested by applying the cross-validation method under various training and testing conditions. The results obtained showed that the model works reliably, since the root-mean-square error of the most accurate model is in the region of 600 kWh (4%).

Key words: *distributed generation; renewable energy; solar power plant; forecasting the generation of solar energy; artificial intelligence; machine learning.*

For citation: Zatsarinnaya YuN, Reutin GV, Kurilov S S, Isaeva OV, Kovalev GS Forecasting electricity generation from renewable energy using machine learning methods. *Power engineering: research, equipment, technology.* 2023;25(3):81-92. doi:10.30724/1998-9903-2023-25-3-81-92.

Введение (Introduction)

В современном мире наблюдается новое направление развития глобальной энергетики: мир вступает в этап 4-го энергетического перехода, характеризующегося широким использованием ВИЭ и постепенным вытеснением углеводородного топлива. Использование возобновляемых источников энергии становится приоритетной задачей для многих стран. Существует ряд приоритетных сфер применения возобновляемых источников энергии, формирующих наибольшие секторы внутреннего рынка и обеспечивающих достижение наибольшего эффекта для экономики. К ним относятся системы распределенной энергетики, микрогриды, смартгриды. Применение возобновляемых источников в качестве источников энергии для микрогридов актуально из-за удаленности большого количества районов от топливных магистралей и централизованного энергоснабжения [1]. Главным образом, централизованного электроснабжения не имеют сельские населенные пункты районов Севера, Дальнего Востока и Сибири. Всего таких изолированных энергоузлов насчитывается около 30 000, а проживают в них суммарно около 11 млн. человек. Обеспечение электроэнергией таких районов возможно либо за счет

строительства станции внутри децентрализованной зоны, либо за счет централизованного энергоснабжения [2]. Чаще всего электроснабжение таких районов может осуществляться дизельными электростанциями с высокими операционными затратами (ОРЕХ) из-за дороговизны привозного топлива. Использование ВИЭ в качестве источника энергии имеет низкий ОРЕХ и целесообразность их применения в микрогридах подтверждается рядом исследований [2,3]. Согласно энергетической стратегии России в период до 2030 года вовлечение объектов возобновляемых источников энергии (ВИЭ) в топливно-энергетический комплекс нашей страны будет оставаться актуальной задачей. Об этом свидетельствует принятие федерального закона № 471 27 декабря 2019 года Государственная Дума Российской Федерации приняла Федеральный закон «О внесении изменений в Федеральный закон «Об электроэнергетике» в части развития микрогенерации». Данный закон позволит объектам микрогенерации, максимальная мощность которых не будет превышать 15 кВт стать из сторон купли-продажи электроэнергии. Данный закон позволит объектам микрогенерации, максимальная мощность которых не будет превышать 15 кВт стать из сторон купли-продажи электроэнергии. Основные источники таких мини-электростанций – это ВИЭ, в особенности солнечная и ветровая энергия. Таким образом, данный закон будет способствовать созданию объектов микрогенерации и повышению доли ВИЭ в энергобалансе России. По данным Международного энергетического агентства (МЭА) солнечная фотоэлектрическая энергия и находится на третьем месте в мире среди ВИЭ, но начиная с 2016 года среди вводимых мощностей на основе ВИЭ, первое место по объему занимают солнечные панели [3]. Данные института Энергетической стратегии свидетельствуют, что в России самый большой технический потенциал из возобновляемых источников энергии у Солнца (в млн. тоннах условного топлива) составляет $2,3 \cdot 10^3$, второе место занимает энергия ветра - $2 \cdot 10^3$. Солнечная радиация, которая поступает из космоса составляет примерно 7,5 кВтч/год, что превышает потенциал всех возобновляемых и невозобновляемых источников энергии, преобразование которых позволит удовлетворить все энергетические потребности человечества. Кроме того, основным из факторов развития ВИЭ можно назвать снижение вредных воздействий на экологическую среду при переходе к возобновляемой генерации. В 2022 году в России выработка энергии на тепловых электростанциях (ТЭС) составляет 611,9 млрд кВт ч (62,9%) [4]. При сжигании углеводородного топлива происходит выброс в атмосферу парниковых газов, что ведет к изменению климата и негативно сказывается на окружающей среде и, как следствие, на благополучии людей [5,6]. Однако развитие энергетического сектора, а особенно освоение ВИЭ связано с большими финансовыми вложениями во всех странах осуществляется при особой законодательной и политической поддержке правительства. Основными возобновляемыми источниками во всем мире стали солнечная и ветровая энергии. Последние десятилетия наблюдается тенденция снижения затрат на оборудование, используемое для получения энергии с использованием солнечной и ветровой энергии [7]. Данную тенденцию можно проследить на примере стоимости солнечных панелей. Она стремительно снижается за счет снижения удешевления комплектующих и расходов на установку, а также благодаря политике и маркетинговым усилиям компаний. В будущем эта тенденция будет усиливаться, и новые технологии будут использоваться для снижения затрат на строительство, эксплуатацию и интеграцию объектов на возобновляемых источниках энергии в существующие энергосистемы, что может способствовать ускорению перехода к возобновляемым источникам энергии в России.

Широкое распространение фотоэлектрических систем и растущая мощность солнечных электростанций приводит к возникновению двух основных проблемы этих источников генерации – это изменчивость и неопределенность выработки, а следовательно, мощность фотоэлектрических модулей изменчива во всех временных масштабах и эту изменчивость нужно учиться прогнозировать для экономически эффективной работы энергосистем. Точный прогноз располагаемыми генерируемыми мощностями имеет значение для системного оператора, осуществляющего баланс мощности в энергосистеме. Для получения максимального дохода от солнечных станций необходимо разработать алгоритм прогнозирования выработки электроэнергии с учетом погодных условий, вероятностного характера прогнозных значений в краткосрочном и долгосрочном планировании.

Задача поиска оптимального потока мощности формулируется со всеми ограничениями системы и впоследствии решается для получения оптимальной реконфигурации сети. Реконфигурация сети сводится к изменению топологической структуры путем изменения состояния выключателей, что является эффективным способом

балансировки нагрузки и повышения надежности работы энергосистемы и снижения потерь мощности. Сеть может состоять из генераторов на традиционных, а также возобновляемых источниках энергии, таких как солнечные электростанции. Классический поиск оптимального потока мощности представляет собой решение системы уравнений с нелинейными ограничениями. Учет прерывистой природы солнечной энергии усложняет проблему поиска оптимума, поэтому прогнозирование выработки возобновляемых источников в настоящее время является крайне актуальным и перспективным направлением. Машинное обучение расширяет возможности для обработки и анализа данных. Поэтому, платформы прогнозирования генерации энергии с помощью искусственного интеллекта облегчат планирование покрытия графика на сутки вперед и оптимальной загрузки всех станций, тем самым минимизируя затраты на производство электроэнергии в энергосистеме в целом.

Авторами статьи поставлена цель исследовать производительность современных методов искусственного интеллекта для создания платформы прогнозирования вырабатываемой мощности от солнечной станции, разработать архитектуру информационно-коммуникационной системы распределительной сети и разработать модель прогнозирования фотоэлектрической мощности электрической станции на основе методов машинного обучения. Эти платформы с ростом генерации электроэнергии от фотоэлектрических станций энергии окажутся ценными в ближайшей перспективе.

Литературный обзор (Literature Review)

Существует множество различных методов, позволяющих прогнозировать выработку электроэнергии фотоэлектрическими установками. Например, существуют математические модели, которые принимают на вход параметры температуры окружающей среды, интенсивность излучения и скорость ветра и выдают в качестве выходного параметра генерируемую мощность. Такие модели относятся к косвенным методам прогнозирования выработки солнечной энергии, но они хороши для первоначального проектирования станции, но они могут быть неэффективны для реального прогнозирования выработки, поскольку в них используются приблизительные данные процессов, происходящих на реальной электростанции. [8]

Также распространение получили статистические методы, включающие в себя модель авторегрессии скользящего среднего и экспоненциальное сглаживание. Такие модели являются довольно популярными для прогнозирования выработки энергии, но не учитывают прогноз фотоэлектрического излучения.

Методы машинного обучения используют алгоритмы машинного обучения, такие как нейронные сети, линейная регрессия, дерево решений, случайный лес, адаптивный бустинг использовались для прогнозирования выходной мощности фотоэлектрических батарей. Идея использования машинного обучения заключается в полном игнорировании физической взаимосвязи между входными и выходными данными и самостоятельном поиске компьютером наиболее удобного соотношения между ними. Точность такого метода зависит от размера базы данных, выбранной методологии и правдивости исходных данных.

Гибридные методы обычно объединяют метеорологические модели с искусственным интеллектом и статистическими моделями. [9]

Материалы и метод (Materials and Methods)

Предлагаемый в работе подход в прогнозировании выработки солнечной энергии предполагает использование нескольких моделей машинного обучения: линейная регрессия, дерево решений, случайный лес, адаптивный бустинг. Эти алгоритмы оптимизации используются для задач поиска взаимосвязей с метеоданными. Также авторы использовали нейронные сети, поскольку они довольно часто встречаются в аналогичных исследованиях.

А. Нейронные сети

Нейронные сети – это большие системы взаимосвязанных элементов, совместно работающих над решением конкретных задач. Вдохновением к их созданию послужили биологические системы и то, как такие системы обрабатывают информацию.

На вход нейронной сети подаются исходные данные, составляющие первый слой сети. Последний слой сети – это выходные данные – значение генерации. Между первым и последним слоем существуют так называемые скрытые слои.

Суть нейросети, как механизма обработки информации, состоит в активации нейронами из предыдущего слоя нейронов в следующем слое с целью обнаружить какой-нибудь шаблон. Для этого каждому соединению между нейронами назначают веса и считают взвешенную сумму весов для каждого нейрона. В результате может получиться любое число. Для активации нейронов в следующем слое при определенном значении необходимо к

взвешенной сумме добавить константу, называемую сдвигом и передать это число в функцию активации, которая чаще всего является сигмоидой.

В результате нейронная сеть содержит тысячи весов и сдвигов, которые можно менять чтобы настраивать поведение сети. Поэтому когда мы говорим об машинном обучении, имеется в виду – заставить компьютер найти такие значения для всех этих чисел так, чтобы это решило поставленную задачу.

Для математического представления всех весов и сдвигов, необходимо представить все веса в виде матрицы, данные первого слоя сети в виде вектора- столбца и произвести матричное произведение этих матриц, а затем добавить к матричному произведению сдвиги, представленные в виде вектора-столбца и применить к получившейся матрице сигмоидную функцию активации. [10]

$$a^{(2)} = \sigma(Wa^{(1)} + b),$$

где $a^{(1)}$ – активации нейронов из предыдущего слоя

$$\begin{pmatrix} a_1^{(1)} \\ a_2^{(1)} \\ \vdots \\ a_n^{(1)} \end{pmatrix}$$

$a^{(2)}$ - активации нейронов последующего слоя, σ - сигмоидная функция активации, W - матрица весов

$$\begin{pmatrix} \omega_{11} & \dots & \omega_{1n} \\ \vdots & \ddots & \vdots \\ \omega_{k1} & \dots & \omega_{kn} \end{pmatrix},$$

b - матрица сдвигов

$$\begin{pmatrix} b_1^{(1)} \\ b_2^{(1)} \\ \vdots \\ b_n^{(1)} \end{pmatrix}.$$

В работе авторы использовали нейронную сеть с 10 скрытыми слоями из 7 нейронов, сигмоидальную функцию активации и использовали функцию байесовской регуляризации для обучения сети.

В. Линейная регрессия

Является базовой разновидностью регрессии. Простая линейная регрессия позволяет понять взаимосвязь между двумя непрерывными переменными [11] Линейная регрессия описывается следующим уравнением:

$$\gamma = \beta_0 + \beta_1 X + \dots + \beta_k X_k + \varepsilon,$$

где β - коэффициенты регрессии, ε - ошибка регрессии.

С. Дерево решений

Древовидная структура, напоминающая блок-схему, которая использует метод ветвления, иллюстрируя каждый возможный результат принятия решения. Каждый узел дерева соответствует одной проверке условия по определенной переменной, а каждая ветвь является результатом этой проверки.

Задача максимизации полученной информации при каждом разделении, сводится к задаче определения целевой функции, которую необходимо оптимизировать с помощью алгоритма дерева решений. Целевая функция в данном случае описывается следующим уравнением.

$$IG(D_p, f) = I(D_p) - \left(\frac{N_{left}}{N_p} I(D_{left}) + \frac{N_{right}}{N_p} I(D_{right}) \right),$$

где f – функция разделения, D_p, D_{left}, D_{right} – наборы данных родительского и дочерних узлов, I – мера примеси, N_p – общее количество выборок в родительском узле, а N_{left} и N_{right} – количество выборок в дочерних узлах. [12]

D. Случайный лес

Случайный лес состоит из большого количества отдельных деревьев решений, которые работают как ансамбль методов. Каждое дерево в случайном лесу возвращает прогноз класса, и класс с наибольшим количеством голосов становится прогнозом леса. Случайный лес описывается следующим уравнением [13]

$$F(x) = \frac{1}{N} \sum_{i=1}^N b_i(x),$$

где N – число деревьев решений случайного леса, $b_i(x)$ – дерево решений.

E. Адаптивный бустинг

Адаптивный бустинг – это частный случай градиентного бустинга. Это техника машинного обучения для задач классификации и регрессии, которая строит модель предсказания в форме ансамбля слабых предсказывающих моделей, обычно деревьев решений. Адаптивный бустинг описывается следующим уравнением [14]:

$$F(x) = \sum_{i=1}^m \gamma_i h_i(x),$$

где h_m – базовая функция, дерево решений.

Модель машинного обучения

F. Исходные данные

Для прогнозирования генерации от СЭС использовалась следующая исходная информация:

1. Метеорологические данные, взятые из открытых источников. В частности, были использованы параметры влажности, прозрачности и температуры окружающей среды;
2. Измеренные данные – почасовая выработка электроэнергии солнечной электростанцией, данные солнечного излучения
3. Рассчитанные данные солнечного угла, длительность солнечного дня.

Корреляция параметров исходных данных с величиной генерации электроэнергии изображена на рисунке 1. Из рисунка видно, что наибольшую корреляцию с выработкой электроэнергии имеет величина солнечного потока.

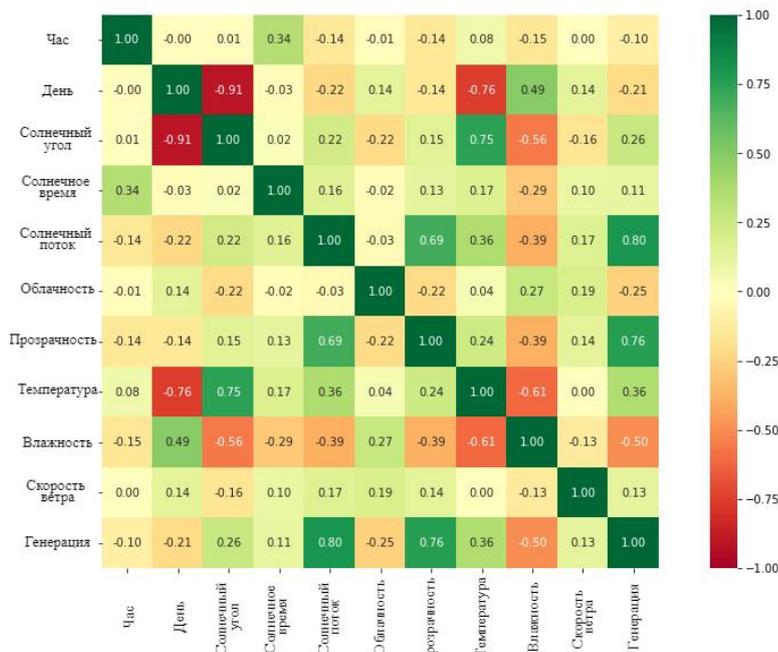


Рис. 1. Матрица коэффициентов корреляций параметров. Fig. 1. Matrix of correlation coefficients of parameters.

*Источник: составлено автором. Source: compiled by the author

Однако, построить модель машинного обучения высокой точности, исходя только из величины солнечного потока невозможно из-за высокого разброса зависимости одной величины от другой (рис. 2). Для получения высокоточной модели необходимо учитывать все параметры, оказывающие влияние на значение величины генерации.

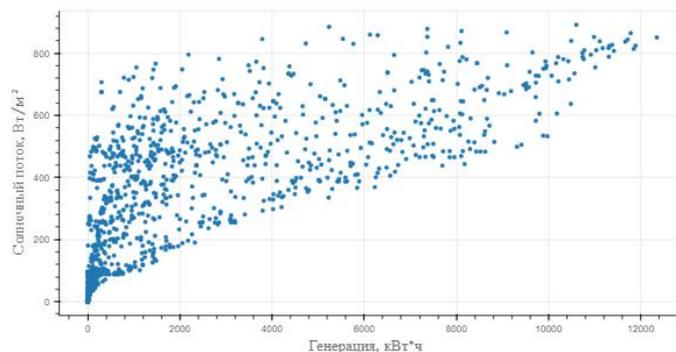


Рис. 2. Диаграмма рассеяния, соответствующая массивам пар данных генерации и солнечного излучения. Fig. 2. Scattering diagram corresponding to arrays of generation and solar radiation data pairs.

*Источник: составлено автором. Source: compiled by the author.

Г. Сбор информации на СЭС

Для создания эффективной модели прогнозирования выработки электроэнергии, необходима автоматизированный сбор данных станции, включающие в себя историю выработки, данные солнечного излучения, а также необходимы фактические метеорологические данные, данные метеорологического прогнозирования. Однако все они могут быть получены от оборудования совершенно различных производителей, поэтому может возникнуть вопрос о совместимости этого оборудования. [15]

Стандарт IEC 61850 отвечает за совместимость устройств, предоставляет единый протокол обмена данными, необходимыми для функционирования станции.

На рисунке 3 представлена схема информационных и коммуникационных технологий станции. Она состоит из трех основных уровней. [16]

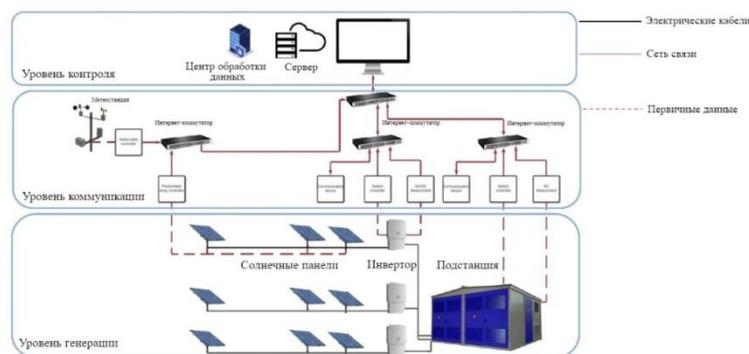


Рис. 3. Информационные и коммуникационные технологии на солнечной электростанции Fig. 3. Information and communication technologies of a solar power plant

*Источник: составлено автором. Source: compiled by the author.

На нижнем уровне – уровне генерации установлены датчики, контролирующие состояние солнечных панелей, в инверторах со встроенными выключателями нагрузки установлены датчики положения выключателей, а также амперметры и вольтметры. Также первичными данными в некотором роде являются метеорологические данные, полученные с устройств и датчиков, установленных на метеорологической башне.

Информация от контроллера выключателя и контроллера постоянного и переменного тока поступает в устройство связи. Устройство связи управляет работой контроллеров, собирает данные и передает их на верхний уровень схемы, в дата центр, где эти данные хранятся. Впоследствии эти данные уже могут быть использованы алгоритмами машинного обучения для предсказания выработки электроэнергии солнечной электростанцией [17].

Результаты и обсуждение (Results and discussions)

На рисунке 4 изображено сравнение значений реальной генерации и предсказанной генерации разными алгоритмами машинного обучения. Сравнение было сделано для 9-ти дней октября 2019 года. Из рисунка видно, что все алгоритмы, за исключением линейной регрессии, в ночное время показывают нулевую генерацию, а в дневное время генерация представляет из себя кривую линию. Для сравнения между собой разных моделей машинного обучения, была использована перекрестная проверка данных, смысл которой заключается в том, что обучающий набор делится на K подвыборок, одна подвыборка сохраняется в качестве данных для модели верификации, а другие выборки используются для обучения. Перекрестная проверка повторяется K раз, и каждый подвыбор проверяется один раз. По полученным результатам высчитывается среднее для получения достоверной оценки точности модели. [14] При перекрестной проверке среднеквадратическая ошибка рассчитывалась по формуле:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{P(i) - P_m(i)}{P_n(i)} \right)^2} \cdot 100$$

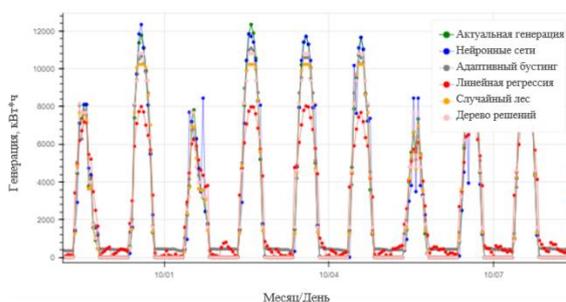


Рис. 4. Сравнение текущих и прогнозных значений генерации разными алгоритмами машинного обучения для солнечной электростанции установленной мощностью 15 МВт

Fig. 4. Comparison of current and forecast generation values by different machine learning algorithms for a solar power plant with an installed capacity of 15 MW

Источник: составлено автором. Source: compiled by the author

Среднеквадратическая ошибка была посчитана для проверочных и тренировочных данных. Это сделано для того, чтобы проверить, насколько хорошо были подобраны параметры модели. Высокая разница между тренировочными и проверочными данными свидетельствовала бы о переобучении, а высокое значение среднеквадратической ошибки при почти минимальной разнице между тренировочными и проверочными данными свидетельствовала бы о недообучении модели. В результате расчетов были получены данные, представленные на рисунке 5. Из рисунка видно, что наименьшую среднеквадратическую ошибку на проверочных данных имеет алгоритм случайного леса.

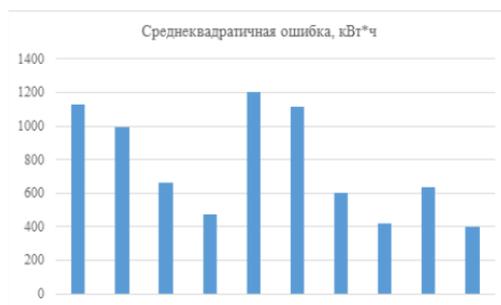


Рис. 5. Среднеквадратичные ошибки, полученные при перекрестной проверке моделей при сравнении текущих и прогнозных значений генерации разными алгоритмами машинного обучения

Fig. 5. The root-mean-square errors obtained during cross-validation of models when comparing current and predicted generation values by different machine learning algorithms. *

*Источник: составлено автором. Source: compiled by the author.

Для оптимизации необходимо осуществить реконфигурацию системы электроснабжения с распределенной генерацией. Топологию сети можно изменить, изменив состояние линейных выключателей. Задачей оптимизации является нахождение оптимальной радиальной топологии сети, которая минимизирует совокупные потери активной мощности.

Сформулированная проблема может быть описана следующим уравнением: [15]

$$\min \left(P_{loss} = \sum_{h=1}^{N_H} P_{loss}^h = \sum_{h=1}^{N_H} \sum_{i=1}^{N_i} R_i \frac{(P_i^h)^2 + (Q_i^h)^2}{(U_i^h)^2} \right)$$

При следующих ограничениях:

- Соблюдение баланса активной и реактивной мощности;
- Уровни напряжения в схеме находятся в допустимом диапазоне;
- Реконфигурация распределительной сети радиальная.

Существует множество способов, с помощью которых можно оптимизировать конфигурацию распределительной сети. Одним из способов является применения алгоритма брутфорса (от английского выражения «brute force»). Идея использования алгоритма состоит в том, чтобы по очереди перебирать положения всех возможных выключателей с целью поиска оптимального положения реконфигурации сети.

В качестве исходной схемы была выбрана схема с 15-ю шинами, представленная на рисунке 6.

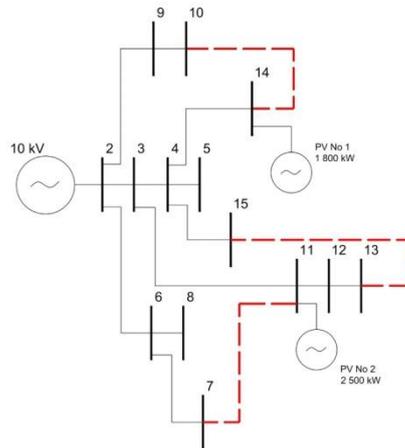


Рисунок 6. Исходная схема для оптимизации

Fig. 6. Original circuit for optimization

*Источник: составлено автором. Source: compiled by the author.

Для этой схемы была составлена модель в программном обеспечении *MathWorks Matlab & Simulink*. Эта модель задавала графики нагрузок для каждой из шин и график выработки электроэнергии солнечными электростанциями. Затем модель поочередно перебирала положение всех выключателей в схеме.

Результат работы этого алгоритма представлен на рисунке 7.

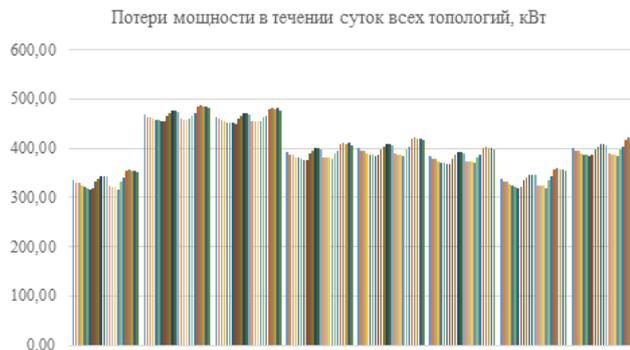


Рис. 7. Потери активной мощности для разных топологий исходной схемы

Fig. 7. Active power losses for different topologies of the original circuit

*Источник: составлено автором. Source: compiled by the author.

Рассмотренный способ оптимизации подходит только для небольших схем и не масштабируется для крупных сетей. По этой причине, необходимо преобразовывать эту задачу в более простую и менее трудоемкую [12].

Заключение (Conclusions)

Точное прогнозирование солнечной фотоэлектрической мощности необходимое для оптимальной интеграции станций на возобновляемых источниках в существующие энергосистемы в супергридах и для прогноза потребления в микрогридах. В статье представлена методология прогнозирования выработки фотоэлектрических систем на сутки вперед, основанная на алгоритмах машинного обучения. Проведенный анализ построения рабочей модели машинного обучения, продемонстрировал, что для построения оптимальной модели, необходима только история выработки электроэнергии этой станции, сопоставленная с рассчитанными и измеренными данными погоды. Стабильность модели была проверена путем применения метода перекрестной проверки в различных условиях обучения и тестирования. Полученные результаты показали, что модель надежно работает, поскольку среднеквадратическая ошибка самой точной модели находится в районе 600кВт*ч (4 %).

Литература

1. Суржикова О.А. Проблемы и основные направления развития электроснабжения удаленных и малообеспеченных потребителей России // Векторы расчета: экономика и социум. 2012. №3 (4).
2. Сулов К.В. Развитие систем электроснабжения изолированных регионов России с использованием экспортных источников энергии // Вестник ИрГТУ. 2017. №5 (124).
3. International Energy Agency 2022 Renewables 2022 Analysys and Forecasts to 2023//Paris: International Energy Agency
4. Сокольникова Т.В., Сулов К.В., Ломбарди П. Расчет оптимальных параметров накопления для добычи энергии в изолированных энергосистемах с активными пользователями // Вестник ИрГТУ. 2015. №10 (105).
5. Иванов И.Ю., Новокрещенов В.В., Иванова В.Р. Современное состояние проблем функциональности комплексов релейной защиты и автоматики, преступлений в активно-адаптивной сети. Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2022;24(6):102-123.
6. Виноградов А.В., Виноградова А.В., Сейфуллин А.Ю., Букреев А.В., Большев В.Е. Принципы управления конфигурацией электрической сети и задачи по их реализации. Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2021;23(3):34-46.
7. Zatsarinnaya Y., Logacheva A., Gainullin R., et al. Solution for renewable future// E3S Web of Conferences. 2019. Vol. 124, p.04010.
8. Лаврик А.Ю., Жуковский Ю.Л., Лаврик А.Ю., Булдыско А.Д. Особенности выбора оптимального состава ветро-солнечной электростанции с дизельными генераторами. Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2020;22(1):10-17.
9. Ercan I., Ahmet O., Bihter Y., Mustafa K.K., Ahmet D.S. Shortmid-term solar power prediction by using artificial neural networks, Solar Energy. 2012. Vol. 86. № 2. p. 725–733
10. Gigoni L., Betti A., Crisostomi E., et al. Day-ahead hourly forecasting of power generation from photovoltaic plants, IEEE Trans Sustain Energy, vol. 9 (2), pp. 831- 842, 2018.
11. Khan P., Byun Y., Lee S., et al. Machine learning-based approach to predict energy consumption of renewable and nonrenewable power sources, Energies, vol. 13, no. 18, p. 4870, 2020.
12. Khalyasmaa A., Eroshenko S., Tashchilin V., et al. Industry Experience of Developing Day-Ahead Photovoltaic Plant Forecasting System Based on Machine Learning, Remote Sens., vol. 12, p.3420, 2020.
13. Рамазанова Р.И., Исаева О.В. Электроснабжение отдаленных населенных пунктов с помощью ветродизельных установок// Тинчуринские чтения - 2022 "Энергетика и цифровая трансформация": Сборник статей по материалам конференции. В 3-х томах; 27–29 апреля 2022 года., Казань: Казанский государственный энергетический университет, 2022. С. 669-671.
14. Eltamaly A., Ahmed M., Alotaibi M., et al. Performance of Communication Network for Monitoring Utility Scale Photovoltaic Power Plants, Energies, vol. 13, p. 5527, 2020.
15. Воркунов О.В., Ихсанова А.И., Гайнутдинова А.М. Оптимальная ориентация солнечных фотоэлектрических модулей в г. Казани// Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2015. №11-12. С. 26-29.

16. Eroshenko S., Khalyasmaa A., Snegirev D. Machine learning techniques for short-term solar power stations operational mode planning. *E3S Web of Conferences*, vol.51, p.02004, 2018.

17. Эльмохлави А.Э., Очков В.Ф., Казанджан Б.И. Оценка производительности и энергоэффективности интегрированного солнечного комбинированного цикла электростанции. // Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2019. №21(1-2). С.43-54.

Авторы публикации

Зацаринная Юлия Николаевна – канд. техн. наук, доцент кафедры «Электрические станции им. В.К. Шибанова», Казанского государственного энергетического университета E-mail: zac_jul@mail.ru.

Реутин Глеб Владимирович – ассистент кафедры «Электроэнергетические системы и сети», Казанского государственного энергетического университета E-mail: reutingleb@gmail.com.

Курилов Сергей Сергеевич – ассистент кафедры «Электрические станции им. В.К. Шибанова», Казанского государственного энергетического университета E-mail: e-assist@bk.ru.

Исаева Ольга Витальевна – магистрант, Казанского государственного энергетического университета E-mail: isaeva.olga01@mail.ru

Ковалев Георгий Сергеевич – студент, Казанского государственного энергетического университета E-mail: GSKovalev@stud.kpfu.ru

References

1. Surzhikova OA. Problemy i osnovnye napravleniya razvitiya elektrosnabzheniya udalennykh i malonaselennykh potrebitel'ei Rossii. *Bulletin of Siberian Science (Vestnik nauki Sibiri)*.2012; 4(3):103–108.
2. Suslov KV. Razvitie sistem e`lektrosnabzheniya izolirovanny`kh territorij Rossii s ispol`zovaniem vozobnovlyaemy`kh istochnikov e`nergii. *Bulletin of Irkutsk State Technical University (Vestnik Irkutskogo gosudarstvennogo tekhnicheskogo universiteta)*. 2017; 5:131–142.
3. International Energy Agency 2022 Renewables 2022 Analysys and Forecasts to 2023. Paris: International Energy Agency
4. Soko`lnikova TV, Suslov KV, Lombardy P. Opredelenie optimal`ny`kh parametrov nakopitelya dlya integraczii vozobnovlyaemy`kh istochnikov e`nergii v izolirovanny`kh e`nergosistemakh s aktivny`mi potrebitelyami). *Bulletin of Irkutsk State Technical University (Vestnik Irkutskogo gosudarstvennogo tekhnicheskogo universiteta)*. 2017; 10:206–211.
5. Vinogradov AV, Vinogradova AV, Seyfullin AYU, et al. Principles of electrical grid configuration management and tasks of their implementation. *Power engineering: research, equipment, technology*. 2021;23(3):34-46. doi:10.30724/1998-9903-2021-23-3-34-46.
6. Ivanov IYU, Novokreshchenov VV, Ivanova VR. Sovremennoe sostoyanie problem funkcionirovaniya kompleksov relejnoj zashchity i avtomatiki, ispol`zuemyh v aktivnoj adaptivnoj seti. *Energetika: issledovaniya, oborudovanie, tekhnologii*. 2022;24(6):102-123. doi:10.30724/1998-9903-2022-24-6-102-123.
7. Zatsarinnaya Y, Logacheva A, Gainullin R, et al. Solution for renewable future. *E3S Web of Conferences*. 2019;124:04010. doi:10.1051/e3sconf/201912404010.
8. Lavrik AY, Zhukovsky YL, Lavrik AY, Buldysko A.D. Fatures of the optimal composition of a wind-solar power plant with diesel generators. *Power engineering: research, equipment, technology*. 2020;22(1):10-17. doi: 10.30724/1998-9903-2020-22-1-10-17.
9. Ercan I, Ahmet O, Bihter Y, et al. Shortmid-term solar power prediction by using artificial neural networks, *Solar Energy*. 2012;86(2):725–733.
10. Gigoni L, Betti A, Crisostomi E., et al. Day-ahead hourly forecasting of power generation from photovoltaic plants. *IEEE Trans Sustain Energy*. 2018;9(2):831-42. doi: 10.1109/TSTE.2017.2762435.
11. Khan P, Byun Y, Lee S, et al. Machine learning-based approach to predict energy consumption of renewable and nonrenewable power sources. *Energies*. 2020;13(18):4870. doi:

10.3390/en13184870.

12. Khalyasmaa A., Eroshenko S., Tashchilin V., et al. Industry Experience of Developing Day-Ahead Photovoltaic Plant Forecasting System Based on Machine Learning. *Remote Sens.* 2020;12:3420. doi: 10.3390/rs12203420.

13. Ramazanova RI., Isaeva OV., Elektrosnabzhenie ot dalennykh naselennykh punktov s pomoshch'yu vetrodizel'nykh ustanovok. *Tinchurinskie chteniya - 2022 "Energetika i cifrovaya transformatsiya": Sbornik statej po materialam konferencii. In 3 tomah; 27–29 Apr 2022 goda; Kazan': Kazanskij gosudarstvennyj energeticheskij universitet, 2022. pp. 669-671.*

14. Eltamaly A, Ahmed M, Alotaibi M, et al. Performance of Communication Network for Monitoring Utility Scale Photovoltaic Power Plants. *Energies.* 2020;13:5527. doi: 10.3390/en13215527.

15. Vorkunov OV, Ikhsanova AI., Gainutdinova AM. Optimum orientation of solar pv modules in kazan. *Power engineering: research, equipment, technology.* 2015;(11-12):26-29. doi: 10.30724/1998-9903-2015-0-11-12-26-29.

16. Eroshenko S, Khalyasmaa A, Snegirev D. Machine learning techniques for short-term solar power stations operational mode planning. *E3S Web of Conferences.* 2018; 51:02004. doi: 10.1051/e3sconf/20185102004.

17. Lukutin BV, Karrar Hameed K. Optimization of energy balances of a photovoltaic power plant with electrochemical and thermal storage of solar energy. *Power engineering: research, equipment, technology.* 2022;24(2):3-13. doi: 10.30724/1998-9903-2022-24-2-3-13.

Authors of the publication

Yuliya N. Zatsarinnaya – Kazan State Power Engineering University, Kazan, Russia.

Gleb V. Reutin – Kazan State Power Engineering University, Kazan, Russia.

Sergey S. Kurilov – Kazan State Power Engineering University, Kazan, Russia..

Olga V. Isaeva – Kazan State Power Engineering University, Kazan, Russia.

George S. Kovalev – Kazan Federal University, Kazan, Russia.

Шифр научной специальности: 2.4.3. Электроэнергетика.

Получено 28.02.2023 г.

Отредактировано 18.04.2023 г.

Принято 31.05.2023 г.