Обзор методов краткосрочного прогнозирования выработки электроэнергии фотоэлектрическими станциями / Камалова Д.М., Минина Д.К., Леонов Д.Д. и др.// Международный журнал информационных технологий и энергоэффективности. – 2024. – Т. 9 № 7(45) с. 242-249

Международный журнал информационных технологий и энергоэффективности

Сайт журнала:
http://www.openaccessscience.ru/index.php/ijcse/

УДК 621.311.25

ОБЗОР МЕТОДОВ КРАТКОСРОЧНОГО ПРОГНОЗИРОВАНИЯ ВЫРАБОТКИ ЭЛЕКТРОЭНЕРГИИ ФОТОЭЛЕКТРИЧЕСКИМИ СТАНЦИЯМИ

[1]Камалова Д.М., Минина Д.К., Леонов Д.Д., Яропуда Н.А., Беляев С.В.
ФГБОУ ВО "НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ "МЭИ", Москва, Россия (111250, г. Москва, Красноказарменная ул., 14, стр.1) e-mail: [1]onelittlebird@mail.ru

Прогнозирование выработки электроэнергии фотоэлектрическими станциями необходимо для управления энергосистемами, обеспечения надежности энергоснабжения и эффективного использования ресурсов энергетических компаний. Прогнозирование генерации электроэнергии требует учета различных факторов, таких как метеорологические условия и географическое расположение панели. Для решения задач прогнозирования существует множество различных алгоритмов, в данном исследовании произведен их обзор и анализ.

Ключевые слова: Солнечная электростанция, методы краткосрочного прогнозирования, алгоритмы машинного обучения.

REVIEW OF METHODS FOR SHORT-TERM FORECASTING OF PHOTOVOLTAIC POWER GENERATION

[1]Kamalova D.M., Minina D.K., Leonov D.D., Yaropuda N.A., Belyaev S.V.
"NATIONAL RESEARCH UNIVERSITY "MPEI", Moscow, Russia (111250, Moscow, Krasnokazarmennaya st., 14, bld.1) e-mail: [1]onelittlebird@mail.ru

Forecasting the generation of electricity by photovoltaic plants is necessary to manage energy systems, ensure the reliability of energy supply and efficient use of energy companies' resources. Forecasting electricity generation requires taking into account various factors such as meteorological conditions and the geographical location of the panel. There are many different algorithms for solving forecasting problems, and their review and analysis are carried out in this study.

Keywords: Solar power plant, short-term forecasting methods, machine learning algorithms.

Фотоэлектрические батареи — это технология, которая применяется для превращения энергии солнечного света в электрическую энергию. Данная технология становится все более значимой для общества, так как она способствует сокращению зависимости от ископаемых ресурсов и снижению выбросов в атмосферу. Фотоэлектрические батареи, или солнечные панели, используют полупроводниковые материалы, которые преобразуют свет в электричество посредством фотоэлектрического эффекта. При поглощении фотонов поверхностью панели создается разность потенциалов, что приводит к возникновению электрического тока, который может быть использован для питания электрических устройств [1].

Возможность применения солнечных панелей зависит от ряда факторов: интенсивности солнечного излучения, температуры окружающей среды, погоды и географического расположения панели.

Непостоянство возобновляемой генерации создает вызов для современной электроэнергетики. В каждый момент времени в энергосистеме должен соблюдаться баланс генерации и потребления электроэнергии, поэтому подключение солнечных электростанций к электрической сети может приводить к снижению надежности электроснабжения, кроме того, недоотпуск электроэнергии приводит к экономическому ущербу. Таким образом, особую актуальность имеет краткосрочное прогнозирование выработки фотоэлектрическими станциями, как правило, на сутки вперед с почасовой детализацией. Краткосрочные прогнозы необходимы для разработки планов распределения, которые будут использоваться диспетчерскими центрами системного оператора на следующие сутки. Существует также долгосрочное прогнозирование, которое предназначено для оценки технико-экономических показателей солнечных электростанций (СЭС), однако в данной работе эта тема рассматриваться не будет.

В различных странах сетевые компании устанавливают обязательства для солнечных станций относительно прогнозирования их производительности. Например, согласно национальному стандарту Китая GB/T 19964-2012, от СЭС требуется предоставлять прогноз выработки электроэнергии на сутки вперед с 15 минутной детализацией [2]. При этом отказ от прогноза или неточный прогноз (ошибка свыше 10÷15 %) приводят к штрафным санкциям [3]. В России установлены допустимые отклонения фактического производства от почасовых плановых объемов для СЭС в размере 10 % от установленной мощности генерирующего оборудования [4].

Прогнозирование объема электроэнергии, вырабатываемой солнечной электростанцией, по сути является предсказанием количества солнечной радиации, получаемой солнечными панелями. Методы прогнозирования выработки электроэнергии солнечными станциями можно классифицировать следующим образом: физические модели, статистические модели, методы машинного обучения или адаптивные модели и гибридные модели [5]. Гибридные модели комбинируют различные методы для улучшения точности прогнозирования посредством использования преимуществ обеих методологий. Гибридные модели в данной статье рассматриваться не будут. Упомянутые выше методы реализуют два подхода к прогнозированию генерируемой мощности.

Первый подход - физический, он предполагает знание данных о метеорологических условиях, конструкции солнечной станции и характеристиках солнечных батарей. Физический подход может быть применен до ввода в эксплуатацию фотоэлектрической системы, соответственно, методы, основанные на нем, часто применяются для оценки экономической части разрабатываемых проектов СЭС. Методы, основанные на физическом подходе, могут быть более точными и надежными в долгосрочном прогнозировании, но требуют большего количества вычислительных ресурсов и экспертных знаний для разработки и поддержки моделей. Второй подход основан на анализе ретроспективных данных, в частности поиске корреляции между метеорологическими условиями и выходной мощностью СЭС. Данный подход включает использование исторической информации для настройки коэффициентов моделей, которые затем применяются для прогнозирования, поэтому необходимо иметь качественную выборку, снятую в процессе эксплуатации конкретной фотоэлектрической системы. Анализ энергетических данных проводится в три этапа. Сначала производится предварительная обработка входных данных, потом разрабатывается алгоритм

и производится моделирование, а затем оценивается качество работы модели с помощью метрик. Сильно коррелированные входные переменные (например, солнечное излучение сильно коррелирует с выходной мощностью) следует использовать в качестве входных векторов для модели прогнозирования, в то время как слабо коррелированные переменные могут быть отброшены [6]. Затем исторические данные подлежат предварительной обработке, чтобы исключить из выборки аномальные всплески, которые могут существенно исказить прогноз.

Методы, основанные на физическом подходе, используют математические уравнения и физические принципы для моделирования процессов, влияющих на выработку энергии. Эти модели учитывают: интенсивность солнечного излучения, угол падения солнечных лучей, облачность и погодные условия, температуру окружающей среды.

Далее будут подробнее рассмотрены модели, которые основаны на анализе ретроспективных данных, то есть на втором подходе.

Статистические модели основаны на анализе исторических данных и выявлении статистических закономерностей, они используют вероятностные и эмпирические методы для прогнозирования. Данные модели могут использоваться без глубокого понимания физических процессов. Статистические модели наиболее широко применяются для средне- и долгосрочного процессов прогнозирования [7]. Точность предсказания таких моделей зависит от качества и объема данных и может быть снижена при резких изменениях условий, которые не учтены в данных. Ниже приведено основное описание широко применяемых статистических методов.

Метод ARIMA (AutoRegressive Integrated Moving Average) является одним из популярных методов временных рядов, используемых для прогнозирования временных данных, таких как генерация электроэнергии солнечными электростанциями. Модель ARIMA может быть описана как "фильтр", который стремится разделить сигнал и шум, после чего экстраполирует сигнал на будущее для получения прогнозных данных. Уравнение прогнозирования ARIMA представляет собой линейное уравнение, в котором предикторы включают лаги зависимой переменной и/или лаги ошибок прогноза. Это означает, что прогнозируемое значение Y является константой и/или взвешенной суммой одного или нескольких предыдущих значений Y и/или взвешенной суммой одного или нескольких предыдущих значений ошибок [8].

Метод сезонного авторегрессионного интегрированного скользящего среднего (SARIMA) расширяет модель ARIMA, добавляя сезонные компоненты для учета регулярных сезонных вариаций в данных.

Обыкновенные наименьшие квадраты (OLS). Этот метод анализирует систему путем установления линейных отношений между одной или несколькими входными переменными и минимизации суммы квадратов ошибок непрерывной или, по крайней мере, интервальной итоговой переменной (фактические и прогнозируемые значения).

Методы машинного обучения (МО) строят модели на основе больших объемов данных и могут выявлять сложные зависимости в них. Методы машинного обучения, являясь более продвинутыми, обеспечивают более высокую точность прогнозирования, однако, в большинстве случаев, они требуют значительных вычислительных ресурсов. Примеры методов машинного обучения, применяемых для прогнозирования выработки

фотоэлектрических станций: линейная регрессия, метод k-ближайших соседей (k-NN), искусственные нейронные сети (ANN), метод опорных векторов (SVM), случайные леса (RF) и градиентный бустинг (GB) [9]. Рассмотрим подробнее каждый из приведенных методов.

Линейная регрессия - это метод, который используется для анализа отношений между независимыми переменными (факторами) и зависимой переменной (целевой переменной). Таким образом, цель линейной регрессии – нахождение линейной функции, которая наилучшим образом описывает отношение между переменными. При прогнозировании линейная регрессия определяет, как величины входных факторов влияют на выходную мощность станции, но, соответственно, данный метод имеет свои ограничения и может быть неточным, особенно если отношения между переменными нелинейные или если имеется сложная взаимосвязь между факторами.

Метод k-ближайших соседей (k-NN k nearest neighbour) является одним из наиболее простых методов машинного обучения. Алгоритм k-NN измеряет евклидовы расстояния между текущим состоянием и обучающими выборками в пространстве признаков, чтобы выбрать «k» ближайших соседей, которые затем используются для прогнозирования. Детальное описание и применение данного метода для прогнозирования мощности фотоэлектрических станций можно найти в [10].

Искусственные нейронные сети (artificial neural network, ANN) - это алгоритм, вдохновленный биологическими нейронными сетями, который включает нейроны (математические элементы) и веса (связи между этими элементами). ANN обучаются решению конкретных задач (например, прогнозированию) с использованием методов оптимизации на основе градиента, которые настраивают «веса». Метод широко применяется для прогнозирования мощности фотоэлектрических станций [9].

Метод опорных векторов (Support Vector Machine, SVM) используется для задач классификации и регрессии. Основная идея SVM заключается в поиске оптимальной гиперплоскости, которая разделяет данные на две категории. Эта гиперплоскость максимизирует зазор (маржу) между двумя классами, что помогает улучшить общую точность модели и ее способность к обобщению. В работе [10] данный метод представлен и использован для краткосрочного прогнозирования мощности фотоэлектрических станций.

Случайные леса (RF) — это ансамблевый метод обучения, используемый для задач классификации, регрессии и других. Он строит множество деревьев решений, результаты которых затем объединяются для получения финального прогноза или классификации, так как совокупность моделей может компенсировать ошибки отдельных моделей и таким образом предоставить более точные и устойчивые предсказания. Для задач классификации итоговый результат случайного леса определяется большинством голосов деревьев. В задачах регрессии возвращается среднее значение прогнозов всех деревьев. Случайные леса устраняют склонность деревьев решений к переобучению на обучающем наборе. Обычно они показывают лучшие результаты по сравнению с деревьями решений, хотя их точность может быть ниже, чем у деревьев с градиентным усилением. Однако характеристики данных могут повлиять на производительность метода. Исследования [11] показывают высокую эффективность случайных лесов для прогнозирования выработки электроэнергии фотоэлектрическими станциями.

Градиентный бустинг (GB) – это метод машинного обучения, используемый для задач регрессии и классификации, который формирует предсказательную модель в виде ансамбля слабых моделей. Этот метод работает поэтапно, совершенствуя модель и позволяя оптимизировать произвольную дифференцируемую функцию потерь. Градиентный бустинг объединяет слабые модели в одну сильную путем итеративного добавления новой модели, что позволяет улучшить точность предсказаний. Новые слабые модели максимально коррелируют с отрицательным градиентом функции потерь всего ансамбля. Основная идея градиентного бустинга заключается в объединении нескольких слабых предсказательных моделей для создания более мощной. В исследовании [12] метод был представлен и применен для прогнозирования мощности фотоэлектрических батарей.

Согласно сравнению, проведенному в [12], методы машинного обучения опережают статистические методы как по скорости, так и по эффективности в прогнозировании (Таблица 1).

Таблица 1 – Сравнение статистических методов и методов машинного обучения

Метод	Время выполнения, сек.	Среднеквадратическое отклонение (RMSE)
ARIMA	86,613	17,27
SARIMA	159,188	14,43
Линейная регрессия	0,007	10,91
Случайный лес	1,59	10,61
Градиентный бустинг	1,59	10,24

Очевидно, что методы машинного обучения показывают наилучшие результаты при прогнозировании выработки электроэнергии солнечными панелями. Это обусловлено рядом причин:

- возможность использования обширного объема данных для обучения модели: погода, время суток, географическое положение и т.д. Таким образом, прогноз становится более точным.
- большая вариативность алгоритмов, каждый из которых имеет свои преимущества и недостатки. Выбор конкретного алгоритма зависит от характеристик данных и задачи прогнозирования. Таким образом, для каждой задачи прогнозирования можно подобрать наиболее подходящий алгоритм.
- актуализация модели по мере поступления новых данных. При прогнозировании необходимо учитывать изменения в погодных условиях, времени суток и прочих факторах. С помощью МО можно периодически обновлять модель на основе новых данных для получения более точного прогноза.
- автоматизация процесса прогнозирования. Это позволяет сократить временные затраты и повысить точность прогнозирования.

Таким образом, в статье был произведен обзор методов краткосрочного прогнозирования генерации электроэнергии фотоэлектрических станций, и был сделан вывод, что методы машинного обучения наилучшим образом подходят для подобных задач прогнозирования в силу возможности использовать большое количество данных, различные

алгоритмы прогнозирования, возможность обновления модели и автоматизации процесса прогнозирования..

Список литературы

1. Риполь- Сарагоси Т.Л. Кууск А.Б., Возобновляемые и нетрадиционные источники энергии. Учебно-методическое пособие. Ростов н/Д: Рост. гос. ун-т. путей сообщения, 2019. – 122 с.
2. Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de-Pison, F. J., & Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. Solar Energy, 136, 78–111. DOI: 10.1016/J.SOLENER.2016.06.069.
3. Reindl T., Walsh W., Yanqin Z., Bieri M. Energy meteorology for accurate forecasting of PV power output on different time horizons. Energy Procedia, 2017;130:130–138.
4. Постановление Правительства РФ от 27 декабря 2010 г. № 1172 «Об утверждении Правил оптового рынка электрической энергии и мощности и о внесении изменений в некоторые акты Правительства Российской Федерации по вопросам организации функционирования оптового рынка электрической энергии и мощности» (с изменениями и дополнениями) [Электронный ресурс]. – Режим доступа: https://www.consultant.ru/document/cons_doc_LAW_112537/688169748ff81438157cd1f4aa5027d29ff1053d/. – (Дата обращения: 11.05.2024.).
5. Методы краткосрочного прогнозирования выработки электрической энергии солнечными электростанциями и их классификация / Д. А. Тюньков, А. А. Сапилова, А. С. Грицай [и др.] // Электротехнические системы и комплексы. – 2020. – № 3(48). – С. 4-10. – DOI 10.18503/2311-8318-2020-3(48)-4-10. – EDN NBEEZZ.
6. Iheanetu, Kelachukwu. Solar Photovoltaic Power Forecasting: A Review. Sustainability. 14. 17005. 10.3390/su142417005.
7. Кивчун Олег Романович Метод векторного рангового анализа при управлении электропотреблением объектов военной инфраструктуры // Известия ТулГУ. Технические науки. 2018. №11.
8. Pasari S, Shah A, Time Series Auto-Regressive Integrated Moving Average Model for Renewable Energy Forecasting. In: Sangwan K., Herrmann C. (eds) Enhancing Future Skills and Entrepreneurship. Sustainable Production, Life Cycle Engineering and Management: Springer; 2020. p.71–77. DOI: 10.1007/978-3-030- 44248-47.
9. Spyros Theocharides, George Makrides, Andreas Livera, Marios Theristis, Paris Kaimakis, George E. Georghiou, Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing, Applied Energy, 2020; V 268, 115023, DOI: 10.1016/j.apenergy.2020.115023.
10. Fei Wang, Zhao Zhen, Bo Wang, and Zengqiang, Comparative Study on KNN and SVM Based Weather Classification Models for Day Ahead Short Term Solar PV Power Forecasting, applied science, 2018, 8, 28; DOI: 10.3390/app8010028.
11. Huertas Tato, J.; Centeno Brito, M. Using Smart Persistence and Random Forests to Predict Photovoltaic Energy Production. Energies 2019, 12, 100. DOI:10.3390/en12010100.

12. Julian Ascencio-Vasquez, Jakob Bevc, Kristjan Reba, Kristijan Brecl, Marko Jankovec and Marko Topic, Advanced PV Performance Modelling Based on Different Levels of Irradiance Data Accuracy, Energies 2020, 13(9), 2166; DIO, 10.3390/en13092166.

References

1. Ripoll-Saragosi T.L. Kuusk A.B., Renewable and non-traditional energy sources. Educational and methodical manual. Rostov n/A: Rostov State University. ways of communication, 2019. – p.122
2. Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de-Pison, F. J., & Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. Solar Energy, 136, 78–111. DOI: 10.1016/J.SOLENER.2016.06.069.
3. Reindl T., Walsh W., Yanqin Z., Bieri M. Energy meteorology for accurate forecasting of PV power output on different time horizons. Energy Procedia, 2017;130:130–138.
4. Resolution of the Government of the Russian Federation dated December 27, 2010 No. 1172 "On approval of the Rules of the wholesale market of electric energy and capacity and on Amendments to Certain Acts of the Government of the Russian Federation on the organization of the functioning of the wholesale market of electric energy and capacity" (with amendments and additions) [Electronic resource]. – Access mode: https://www.consultant.ru/document/cons_doc_LAW_112537/688169748ff81438157cd1f4aa5027d29ff1053d /. – (Date of application: 05/11/2024.).
5. Methods of short-term forecasting of electric power generation by solar power plants and their classification / D. A. Tyunkov, A. A. Sapilova, A. S. Gritsai [et al.] // Electrotechnical systems and complexes. – 2020. – № 3(48). – Pp. 4-10. – DOI 10.18503/2311-8318-2020-3(48)-4-10. – EDN NBEEZZ.
6. Iheanetu, Kelachukwu. Solar Photovoltaic Power Forecasting: A Review. Sustainability. 14. 17005. 10.3390/su142417005.
7. Kivchun Oleg Romanovich The method of vector rank analysis in the management of power consumption of military infrastructure facilities // Izvestiya TulSU. Technical sciences. 2018. №11.
8. Pasari S, Shah A, Time Series Auto-Regressive Integrated Moving Average Model for Renewable Energy Forecasting. In: Sangwan K., Herrmann C. (eds) Enhancing Future Skills and Entrepreneurship. Sustainable Production, Life Cycle Engineering and Management: Springer; 2020. p.71–77. DOI: 10.1007/978-3-030- 44248-47.
9. Spyros Theocharides, George Makrides, Andreas Livera, Marios Theristis, Paris Kaimakis, George E. Georghiou, Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing, Applied Energy, 2020; V 268, 115023, DOI: 10.1016/j.apenergy.2020.115023.
10. Fei Wang, Zhao Zhen, Bo Wang, and Zengqiang, Comparative Study on KNN and SVM Based Weather Classification Models for Day Ahead Short Term Solar PV Power Forecasting, applied science, 2018, 8, 28; DOI: 10.3390/app8010028.
11. Huertas Tato, J.; Centeno Brito, M. Using Smart Persistence and Random Forests to Predict Photovoltaic Energy Production. Energies 2019, 12, 100. DOI:10.3390/en12010100.

12. Julian Ascencio-Vasquez, Jakob Bevc, Kristjan Reba, Kristijan Brecl, Marko Jankovec and Marko Topic, Advanced PV Performance Modelling Based on Different Levels of Irradiance Data Accuracy, Energies 2020, 13(9), 2166; DIO, 10.3390/en13092166.