

Методика прогнозирования солнечной радиации на основе характерных суток: сравнительный анализ средних и медианных профилей

В.З. Ковалев¹, С.В. Буш¹, О.В. Архипова¹, Е.А. Годовников¹, П.Н. Ремизов²

¹Югорский государственный университет, Ханты-Мансийск

²Городские электрические сети, Ханты-Мансийск

Аннотация: В статье рассматривается методика прогнозирования глобальной горизонтальной радиации на сутки вперёд, основанная на концепции характерных суток – типовых суточных профилей глобальной горизонтальной инсоляции. Метод ориентирован на использование в условиях отсутствия оперативной метеоинформации и предназначен как альтернативный (резервный) способ краткосрочного прогнозирования в автономных энергетических системах. В качестве тестового случая применены данные станции Мухрино (Ханты-Мансийский автономный округ), полученные из сервиса PVGIS на основе реанализа ERA5. Построены средние и медианные характерные сутки для каждого месяца и проведено сравнение точности прогнозов по метрикам RMSE, MAE, MdAE и R^2 . Показано, что медианные профили обеспечивают более устойчивые результаты в условиях повышенной погодной изменчивости. Метод может использоваться для ориентировочного планирования работы фотоэлектрических установок в удалённых и северных регионах при ограниченном доступе к метеоданным.

Ключевые слова: солнечная радиация, глобальная горизонтальная инсоляция, ERA5, статистические методы прогнозирования, прогнозирование в энергетических системах, горизонт прогнозирования, прогнозирование на сутки вперёд, методы построения характерных суток, средние и медианные профили, автономная энергетика, северные города, Крайний Север.

Введение

Предсказание солнечной активности и эффективное управление энергией являются ключевыми элементами устойчивого функционирования солнечной энергетики. Эти процессы требуют точных данных о солнечном излучении, погодных условиях и динамике потребления энергии [1]. Без достоверного прогноза солнечной генерации невозможно обеспечить стабильную работу автономных фотоэлектрических систем, особенно в удалённых и труднодоступных районах, включая регионы Крайнего Севера, где характерны нестабильные погодные условия, ограниченная логистика и отсутствие доступа к централизованным энергосетям.

Современные методы прогнозирования солнечной радиации включают численные атмосферные модели, статистические алгоритмы и алгоритмы машинного обучения [2]. Хотя они обеспечивают высокую точность, их применение требует значительных вычислительных ресурсов, актуальных метеоданных и квалифицированного сопровождения – что затрудняет их использование в условиях ограниченной инфраструктуры.

В ситуациях, когда оперативная метеоинформация недоступна, возникает необходимость в простых и автономных решениях. В данной работе рассматривается воспроизводимый метод краткосрочного прогнозирования на основе характерных суток, который может служить резервным инструментом для получения базовой оценки солнечной радиации в условиях информационной изоляции.

Описание используемых данных

В качестве тестовой площадки была выбрана метеостанция Мухрино, расположенная в центральной части Западной Сибири в 30 км к юго-западу от города Ханты-Мансийска (координаты: 60°53'20" с.ш., 68°42'10" в.д., часовой пояс – UTC+5). Регион характеризуется выраженной сезонной неравномерностью инсоляции, высокой долей облачных дней, значительным сокращением светового дня в зимний период и его увеличением летом, что делает его репрезентативным примером для анализа в условиях северных широт.

Для проведения анализа использовались данные глобальной горизонтальной инсоляции (Global horizontal Irradiance – GHI), полученные с помощью сервиса Photovoltaic Geographical Information System (PVGIS) [3]. Источником данных PVGIS, для исследуемой местности, является климатический реанализ ERA5,

предоставляемый Европейским центром среднесрочных прогнозов погоды (European Centre for Medium-Range Weather Forecasts – ECMWF) [4].

Анализ охватывает полные 2022-2023 календарные года. Исходные данные включают 17 520 почасовых значений GHI, соответствующих двум полным годовым рядам без пропусков. На рис. 1 представлен годовой профиль инсоляции за 2022 год, используемый в качестве базы для формирования типичных суточных профилей. Видна отчётливая сезонная динамика: максимум солнечной радиации наблюдается в летние месяцы, минимум – в зимние, что связано с малым углом падения солнечных лучей и длительными периодами отсутствия солнечного света.




Рис. 1. – Годовой профиль инсоляции за 2022 год

Описание метода

Метод характерных суток представляет собой статистический подход к краткосрочному прогнозированию глобальной горизонтальной радиации, основанный на допущении, что внутрисуточный ход инсоляции в пределах одного календарного месяца подчиняется устойчивым закономерностям. Эти закономерности во многом определяются сезонными изменениями

продолжительности светового дня и углом солнечного возвышения, которые изменяются плавно и предсказуемо и могут считаться практически постоянными в пределах месяца [5]. В то же время облачность отличается высокой изменчивостью. Однако при обобщении данных за месяц становятся заметны характерные сезонные особенности облачного покрова, которые также учитываются в рамках данного подхода. В рамках метода, для каждого месяца рассчитывается типовой суточный профиль инсоляции, представляющий собой 24-часовой временной ряд, агрегированный по всем дням каждого месяца. Всего формируется 12 типовых суточных профилей инсоляции для каждого месяца рассматриваемого года. В данной работе рассматриваются два способа построения таких профилей:

1. Агрегирование усреднением:

$$\overline{I_{ik}} = \frac{1}{n_k} \cdot \sum_{j=1}^{n_k} I_{ijk}, \quad (1)$$

где:

- $\overline{I_{ik}}$ – среднее значение GHI в i -й час месяца k ,
- I_{ijk} – значение GHI в i -й час j -го дня месяца k ,
- n_k – количество дней в месяце k .

Данный метод ранее применялся при оценке солнечного потенциала и моделировании режимов работы автономных фотоэлектрических станций в условиях Крайнего Севера [6].

2. Медианное агрегирование:

$$\widetilde{I_{ik}} = \text{median}(I_{i1k}, I_{i2k} \dots I_{in_kk}), \quad (2)$$

где $\widetilde{I_{ik}}$ – медианное значение GHI в i -й час месяца k .

Медианный метод устойчив к выбросам и аномальным значениям, возникающим, например, при резких изменениях облачности. Это наглядно иллюстрируется на рис. 2, где представлена диаграмма размаха, усредненный и медианный профиль за июль 2022 г.




Рис. 2. – Диаграмма размаха горизонтальной инсоляции с медианным и усредненным профилем (июль 2022 г.)

Построенные усреднённые и медианные профили инсоляции использовались для формирования прогноза глобальной горизонтальной радиации на 2023 год. Прогноз реализовывался по статической схеме: каждому дню соответствующего месяца в 2023 году сопоставлялся один и тот же типичный суточный профиль, полученный по данным за 2022 год.

Такой подход обеспечивает простоту реализации и полную независимость от внешней метеоинформации. При этом предполагается, что характер суточного хода радиации достаточно стабилен в пределах одного месяца при переходе от года к

году, что оправдано в контексте задач ориентировочного прогнозирования для изолированных или автономных энергосистем.

Для оценки точности краткосрочного прогноза солнечной радиации применён стандартный набор метрик регрессионной ошибки: RMSE, MAE, MedAE и R^2 [7, 8]. Каждая из этих метрик характеризует качество прогноза с разных сторон, а вместе они дают всестороннюю оценку. Ниже представлены определения и обоснование выбора каждой метрики.

Среднеквадратичная ошибка (Root mean square error – RMSE):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}, \quad (3)$$

где y_i – истинное значение, $\hat{y}_i$ – предсказанное значение, N – число наблюдений.

Данная метрика особенно чувствительна к крупным ошибкам из-за возведения отклонения в квадрат. Выбор RMSE обусловлен тем, что в задачах прогноза солнечной генерации большие ошибки более критичны. RMSE акцентирует внимание именно на таких случаях, сильно штрафую прогноз за крупные промахи. Кроме того, RMSE широко используется в литературе по прогнозированию, что позволяет сравнивать результаты с другими работами.

Средняя абсолютная ошибка (Mean absolute error – MAE):

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (4)$$

MAE показывает средний модуль отклонения прогноза от фактического значения. Как и RMSE, выражается в тех же единицах, что и сама радиация. В отличие от RMSE, эта метрика линейно зависит от величины ошибки, без квадратичного усиления, поэтому одинаково учитывает, как крупные, так и мелкие

ошибки. Выбор MAE продиктован стремлением охарактеризовать типичную ошибку прогноза, имеющую прямой физический смысл. В контексте солнечной радиации MAE даёт представление о том, насколько, в среднем, прогнозируемая солнечная радиация отличается от фактической в каждый момент времени.

Средняя медианная ошибка (Median absolute error – MdAE):

$$\text{MdAE} = \text{median}(|y_1 - \hat{y}_1|, |y_2 - \hat{y}_2|, \dots, |y_N - \hat{y}_N|). \quad (5)$$

Эта метрика включена ввиду её робастности к выбросам. В то время как RMSE и даже MAE могут существенно увеличиваться из-за нескольких экстремальных ошибок, медианная абсолютная ошибка остаётся относительно невосприимчивой к редким крупным промахам. Для солнечной радиации это особенно важно: отдельные дни с аномальными метеоусловиями могут приводить к огромной ошибке прогноза по сравнению с более типичными днями. MdAE позволяет оценить типичную точность прогноза в большинстве случаев, отфильтровывая влияние таких исключительных ситуаций.

Оценка R^2 (коэффициент детерминации):

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad (6)$$

где $\bar{y}$ – среднее значение истинных значений.

Значение $R^2=1$ соответствует идеальному прогнозу (нулевые ошибки), а $R^2=0$ соответствует случаю, когда модель ничуть не лучше тривиального предсказания на уровне среднего. R^2 может принимать и отрицательные значения, если модель даёт результаты хуже, чем прогноз постоянным средним значением. Выбор коэффициента детерминации верификации обусловлен тем, что он даёт нормированную оценку качества прогноза. В отличие от метрических ошибок,

имеющих размерность, R^2 безразмерен и удобно позволяет сравнить качество моделей в относительном выражении.

Результаты исследования

Сводные значения метрик RMSE, MAE, MdAE и R^2 для прогнозов с использованием средних (ср.) и медианных (мед.) суточных профилей представлены в таблице № 1. Анализ показывает, что медианный профиль обеспечивает более высокую точность в большинстве месяцев года.

Наибольший выигрыш наблюдается в переходные сезоны – весной и осенью, когда погодные условия характеризуются высокой переменчивостью. В мае RMSE снижается с 96,8 до 81,2 Вт/м² (на 16 %), а MAE – с 67,5 до 56,1 Вт/м² (на 17 %). В сентябре медианный профиль также показывает снижение RMSE на 3,5 % и MAE на 3,1 %, а коэффициент детерминации R^2 возрастает с 0,57 до 0,63. Это указывает на устойчивость медианного подхода к выбросам и его способность точнее воспроизводить характерный суточный ход инсоляции.

Зимой, при низких уровнях солнечной радиации и частом наличии нулевых значений, различия между методами минимальны. Например, в январе, феврале и декабре значения RMSE и MAE практически совпадают, а MdAE равен нулю. Летом различия также сглаживаются: в июне медианный профиль даёт небольшое улучшение (R^2 увеличивается с 0,63 до 0,66), а в июле и августе наблюдается незначительное ухудшение RMSE и MAE по сравнению со средним.

В среднем по году медианный профиль демонстрирует улучшение всех трёх абсолютных метрик (RMSE снижается с 56,1 до 55,8 Вт/м², MAE — с 36,3 до 35,6 Вт/м², MdAE — с 17,6 до 16,9 Вт/м²) и повышение R^2 с 0,74 до 0,76. Это делает его предпочтительным для краткосрочного прогнозирования в условиях нестабильной облачности и ограниченной доступности оперативных метеоданных.

Таблица №1

Результаты оценки точности прогнозов GHI на 2023 год

Месяц	RMSE (ср.), Вт/м ²	RMSE (мед.), Вт/м ²	MAE (ср.), Вт/м ²	MAE (мед.), Вт/м ²	MdAE (ср.), Вт/м ²	MdAE (мед.), Вт/м ²	R ² (ср.)	R ² (мед.)
Январь	10,2	10,2	4,8	4,8	0,0	0,0	0,77	0,71
Февраль	22,4	21,6	12,3	11,6	0,0	0,0	0,86	0,85
Март	59,6	63,2	35,9	37,5	5,9	4,6	0,80	0,80
Апрель	59,0	59,0	38,4	37,7	20,8	20,3	0,91	0,92
Май	96,8	81,2	67,5	56,1	46,2	41,4	0,75	0,85
Июнь	104,1	104,6	71,4	70,9	46,5	45,0	0,63	0,66
Июль	100,1	105,7	68,7	72,0	45,6	46,4	0,73	0,73
Август	88,8	94,7	59,0	61,3	33,7	33,8	0,73	0,75
Сентябрь	76,8	74,1	48,0	46,5	12,1	11,6	0,57	0,63
Октябрь	34,8	34,9	19,2	19,2	0,0	0,0	0,67	0,67
Ноябрь	14,3	14,5	7,1	7,1	0,0	0,0	0,69	0,69
Декабрь	6,4	6,2	2,7	2,6	0,0	0,0	0,82	0,81
Среднее значение	56,1	55,8	36,3	35,6	17,6	16,9	0,74	0,76

Выводы

Методика характерных суток представляет собой простое и воспроизводимое решение задачи краткосрочного прогнозирования солнечной радиации. Она не требует внешнего метеоввода, работает исключительно на исторических данных, и может быть реализована даже в условиях ограниченных вычислительных ресурсов.

Проведённый сравнительный анализ показал, что медианные профили обладают большей устойчивостью и обеспечивают более точный прогноз, особенно в сезоны с высокой облачностью. Методика может быть рекомендована для проектирования и эксплуатации автономных солнечных энергетических установок,

особенно в удалённых и северных регионах. Подобные методы могут быть использованы совместно с математическим моделированием фотоэлектрических установок [9], что позволяет оценивать суточные профили выработки энергии на основе характерных суток. Разработанная методика прогнозирования солнечной радиации также может быть интегрирована с алгоритмами МРРТ для повышения эффективности автономных солнечных энергетических систем [10].

Однако у метода есть и недостатки: он не учитывает фактические погодные условия текущего дня, что снижает точность при резких изменениях облачности, и не позволяет предсказывать экстремальные значения инсоляции. Кроме того, типовые профили не отражают внутри-месячную изменчивость и ограничены горизонтом прогноза в одни сутки.

Таким образом, метод характерных суток может рассматриваться как базовая альтернатива более сложным численным или машинным моделям в условиях, где недоступна актуальная метеоинформация или отсутствуют ресурсы для выполнения прогностических расчётов в реальном времени. Наиболее эффективным может быть комбинированный подход, при котором простые методы, такие как описанный, используются как базовый уровень прогноза или резервный сценарий при отказе основной прогностической системы.

Благодарность

Исследование выполнено при финансировании Западно-Сибирского межрегионального научно-образовательного центра мирового уровня, технологический проект "Доступная и чистая энергия для малых поселений Арктики и районов Крайнего Севера".

Литература

1. Чаплыгин И.С. ИИ и солнечная энергетика: перспективы мирового рынка // М.: Издательские решения, 2025. 85 с.
2. Киселева С.В., Лисицкая Н.В., Фрид С.Е. Прогнозирование выработки солнечных станций и фотоэлектрических установок: основные подходы и результативность // Международный научный журнал Альтернативная энергетика и экология. 2020. № 7-18(330-341). С. 24-43. DOI: 10.15518/isjaee.2020.07-18.024-043. EDN NVYXUK.
3. European Commission. Photovoltaic Geographical Information System (PVGIS): Documentation. URL: re.jrc.ec.europa.eu/pvgis/ (дата обращения: 10.04.2025).
4. European Centre for Medium-Range Weather Forecasts. ERA5: data documentation. URL: confluence.ecmwf.int/display/CKB/ERA5:+data+documentation (дата обращения: 10.03.2025).
5. Salazar G., Gueymard Ch., Galdino Ja. B. Solar irradiance time series derived from high-quality measurements, satellite-based models, and reanalyses at a near-equatorial site in Brazil // Renewable and Sustainable Energy Reviews. 2020. Vol. 117. P. 109478. DOI: 10.1016/j.rser.2019.109478. EDN TFSMML.
6. Дмитриенко В.Н., Лукутин Б.В. Методика оценки энергии солнечного излучения для фотоэлектростанции // Известия Томского политехнического университета. Инжиниринг георесурсов. 2017. Т. 328, № 5. С. 49-55. EDN YTANXZ.
7. Auffarth, B. Machine Learning for Time-Series with Python: Forecast, Predict, and Detect Anomalies with State-of-the-Art Machine Learning Methods. Birmingham: Packt Publishing, 2021. 446 p. ISBN 978-1-80181-962-6.

8. Scikit-learn. Machine Learning in Python. URL: scikit-learn.ru/stable/modules/model_evaluation.html#regression-metrics (дата обращения: 13.05.2025).

9. Колосов Р. В., Максимов Ю. М., Титов В. Г. Проектирование малых энергосистем на основе возобновляемых источников энергии // Инженерный вестник Дона. 2014. № 4-1. URL: ivdon.ru/ru/magazine/archive/N4y2014/2713

10. Пученкин А. В., Титов В. Г., Ходыкина И. В. Анализ алгоритмов управления регулятором точки максимальной мощности для солнечных батарей // Инженерный вестник Дона. 2013. № 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2020

References

1. Chaplygin I. S. II i solnechnaya e`nergetika: perspektivy` mirovogo ry`nka [AI and Solar Energy: Global Market Prospects]. M.: Izdatel'skie resheniya, 2025. 85 p.

2. Kiseleva S. V., Lisiczka N. V., Frid S. E. Mezhdunarodny`j nauchny`j zhurnal Al'ternativnaya e`nergetika i e`kologiya. 2020. № 7-18(330-341). pp. 24-43. DOI: 10.15518/isjaee.2020.07-18.024-043. EDN NVYXUK.

3. European Commission. Photovoltaic Geographical Information System (PVGIS): Documentation. URL: re.jrc.ec.europa.eu/pvgis (date assessed: 10.04.2025).

4. European Centre for Medium-Range Weather Forecasts. ERA5: data documentation. URL: confluence.ecmwf.int/display/CKB/ERA5:+data+documentation (date assessed: 10.03.2025).

5. Salazar G., Gueymard Ch., Galdino Ja. B. Renewable and Sustainable Energy Reviews. 2020. Vol. 117. P. 109478. DOI: 10.1016/j.rser.2019.109478. EDN TFSMML.

6. Dmitrienko V. N., Lukutin B. V. Izvestiya Tomskogo politexnicheskogo universiteta. Inzhiniring georesursov. 2017. T. 328, № 5. pp. 49-55. EDN YTANXZ.



7. Auffarth, B. Machine Learning for Time-Series with Python: Forecast, Predict, and Detect Anomalies with State-of-the-Art Machine Learning Methods. Birmingham: Packt Publishing, 2021. 446 p. ISBN 978-1-80181-962-6.

8. Scikit-learn. Machine Learning in Python URL: scikit-learn.ru/stable/modules/model_evaluation.html#regression-metrics (date assessed: 13.05.2025).

9. Kolosov R. V., Maksimov Yu. M., Titov V. G. Inzhenernyj vestnik Dona. 2014. № 4-1. URL: ivdon.ru/ru/magazine/archive/N4y2014/2713

10. Puchenkin A. V., Titov V. G., Xody`kina I. V. Inzhenernyj vestnik Dona. 2013. № 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2020.

Дата поступления: 29.05.2025

Дата публикации: 25.07.2025