



Comparison and Review of the Application of Deep Learning Models in Forecasting Electrical Energy Generation of Photovoltaic Systems with a Focus on LSTM and Hybrid Models

Amirali Saifoddin^{*1} , Mobina Kalantari² , Mohammadali Allahrabbi Shirazi³

1. Associate Professor, School of Energy Engineering and Sustainable Resources, Head of Soft Technologies Institute, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran

2. M.Sc. Student, School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran

3. PhD Student, School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran

Abstract

Accurate forecasting of solar energy generation is considered one of the main challenges in the management of renewable energy systems due to the inherent variability of solar irradiance, dynamic weather conditions, and climatic uncertainties. In this study, a comprehensive systematic review was conducted on 40 selected studies published between 2019 and 2025 to investigate the performance of deep learning models in solar power generation forecasting. The primary focus is placed on Long Short-Term Memory (LSTM) networks and hybrid models, which have gained widespread application in recent years. The comparison of models was carried out based on error evaluation metrics, including Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE).

The results indicate that hybrid models exhibit superior performance in short-term forecasting, reducing prediction errors by up to approximately 2.9%, while models equipped with attention mechanisms provide higher accuracy in medium- and long-term forecasting horizons. Furthermore, the use of multi-source data, including local measurements, satellite imagery, and meteorological data, improves forecasting accuracy by up to approximately 30%. Overall, the findings reveal a growing trend toward the adoption of multi-level approaches, diverse data integration, and intelligent modeling techniques to enhance reliability and sustainability in solar energy resource management.

Keywords

Renewable Energy
Solar Energy Forecasting
Long Short-Term Memory
Networks
Deep Learning Models
Hybrid Models

Received: 26.11.2025

Revised: 07.01.2026

Accepted: 02.05.2026

*Corresponding Author

Amirali Saifoddin

Email

saifoddin@ut.ac.ir

1- Introduction

The rapid growth of photovoltaic (PV) systems and their increasing penetration into modern power grids have significantly intensified the need for accurate, reliable, and robust solar power forecasting techniques [1, 2]. As PV generation becomes a dominant component of renewable energy portfolios, its intermittent and weather-dependent nature introduces considerable

uncertainty into grid operation, energy scheduling, and market transactions. Variations in solar irradiance caused by cloud movement, atmospheric conditions, and seasonal effects directly affect PV power output, making precise forecasting a critical requirement for maintaining grid stability and ensuring efficient energy management.

Cite this Article:

[1] A. Saifoddin, M. Kalantari, and M. Allahrabbi Shirazi, "Comparison and Review of the Application of Deep Learning Models in Forecasting Electrical Energy Generation of Photovoltaic Systems with a Focus on LSTM and Hybrid Models," *Science and Technology in Mechanical Engineering*, Vol. 5, No. 1, pp. 309–326, 2026. [Online]. Available: <https://doi.org/10.22034/stme.2026.562431.1188> (in Persian)



©2026 the authors. Published by Technical and Vocational University (TVU), Tehran, Iran. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution-Noncommercial 4.0 International (CC BY-NC License) (<https://creativecommons.org/licenses/by-nc/4.0/>)

E-ISSN: 2981-2232

Traditional statistical methods and conventional machine learning approaches have been extensively applied to PV power forecasting problems. However, their performance is often constrained when dealing with highly nonlinear, nonstationary, and multivariate solar energy data, particularly under rapidly changing weather conditions. In contrast, deep learning models have demonstrated superior capability in learning complex nonlinear mappings, capturing long-term temporal dependencies, and extracting high-level features from large-scale and high-dimensional datasets [3, 4]. Consequently, deep learning architectures such as LSTM networks, CNN-based models, and more recently Transformer-based frameworks have been increasingly adopted for PV power forecasting across different temporal horizons [5, 6].

Despite the growing volume of published research, the reported performance of deep learning models varies considerably depending on factors such as data sources, input feature selection, forecasting horizon, and model architecture. This variability highlights the need for a structured and comparative review that systematically evaluates existing approaches and identifies key performance trends. Therefore, this study aims to provide a comprehensive review and comparative analysis of recent deep learning models applied to PV power generation forecasting, with particular emphasis on LSTM-based and hybrid architectures.

2- Methodology of Literature Review

This study follows a structured and systematic literature review methodology to ensure consistency, transparency, and reproducibility of the analysis. Relevant articles were collected from leading peer-reviewed journals in the fields of renewable energy, power systems, and artificial intelligence. The primary selection criteria included publication year (2019–2025), application to real-world PV plants or satellite-based solar datasets, utilization of deep learning models, and explicit reporting of quantitative evaluation metrics.

After the initial screening, the selected studies were analyzed according to four main dimensions. These include the adopted model architecture,

encompassing LSTM, CNN, Transformer, and hybrid deep learning models; the types of input data employed, such as SCADA measurements, meteorological variables, numerical weather prediction data, and satellite imagery; the forecasting horizon considered; and the evaluation metrics used to assess model performance. This analytical framework enables a consistent and transparent comparison across different studies and allows for a comprehensive assessment of the strengths and limitations of various deep learning approaches in PV power forecasting.

3- Results

The comparative analysis of the selected studies reveals several important performance patterns across different deep learning architectures. LSTM-based models are widely adopted as baseline approaches due to their proven effectiveness in capturing temporal dependencies within PV power generation time series. These models perform well in scenarios where historical power output data constitute the primary input; however, their predictive accuracy may decline when dealing with high-dimensional inputs or complex spatial features.

Hybrid architectures that integrate CNN layers with LSTM units address these limitations by enabling automatic feature extraction from multivariate and spatially distributed inputs prior to temporal modeling [7, 8]. The reviewed studies consistently report that CNN–LSTM and Attention–LSTM models achieve lower prediction errors compared to standalone LSTM networks, particularly in short-term forecasting applications, with error reductions reaching up to approximately 2.9%. These improvements are attributed to the complementary strengths of CNNs in spatial feature extraction and LSTMs in temporal sequence modeling.

Another key outcome of the comparative analysis is the significant impact of multi-source data integration on forecasting performance. Quantitative results from the reviewed literature indicate that incorporating heterogeneous input data—such as on-site PV measurements, numerical weather prediction outputs, and satellite-derived

information—can enhance forecasting accuracy by up to approximately 30%, especially for medium-term forecasting horizons [9, 10]. These findings demonstrate that performance gains are primarily driven by effective data fusion strategies and architectural hybridization rather than by increasing model complexity alone.

4- Conclusion

This review study provides a comprehensive and structured comparison of deep learning models applied to photovoltaic power generation forecasting. The synthesized results confirm that hybrid deep learning architectures, particularly CNN–LSTM and Attention–LSTM models, consistently outperform standalone approaches in short-term forecasting tasks, while attention-based and Transformer architectures (including Autoformer with multi-scale attention mechanisms) offer improved stability and reliability for medium- and long-term horizons.

Quantitative evidence from the reviewed literature indicates that error reductions of up to approximately 2.9% can be achieved through architectural hybridization, while the integration of multi-source data inputs (e.g., satellite imagery, local measurements, and numerical weather predictions) can further enhance forecasting accuracy by up to 30% and improve generalizability under unstable weather conditions. In short-term horizons, CNN–LSTM models have demonstrated superior performance, with some studies reporting MAPE values below 3% and RMSE under 0.09, highlighting their robustness in variable meteorological environments. For longer horizons, Transformer-based models, especially Autoformer, have achieved up to 25% accuracy improvements compared to pure LSTM approaches, particularly in complex and seasonal scenarios.

Furthermore, the combination of deep learning models with metaheuristic algorithms and ensemble approaches has been shown to reduce forecasting errors (MAPE and RMSE) and increase model stability, though at the cost of higher computational requirements and potential risks of overfitting.

Overall, the findings highlight a clear transition toward review-supported, data-driven forecasting frameworks that balance model performance, data availability, and computational requirements. The insights provided in this study can assist researchers and practitioners in selecting suitable deep learning models for photovoltaic forecasting applications and support future research directions focused on robustness, scalability, and practical relevance for real-world PV systems.

5- References

- [1] M. S. Ibrahim, S. M. Gharghory, and H. A. Kamal, "A hybrid model of CNN and LSTM autoencoder-based short-term PV power generation forecasting," *Electrical Engineering*, Vol. 106, No. 4, pp. 4239–4255, 2024, DOI: [10.1007/s00202-023-02220-8](https://doi.org/10.1007/s00202-023-02220-8).
- [2] N. Zhou, B. Shang, M. Xu, L. Peng, and G. Feng, "Enhancing photovoltaic power prediction using a CNN-LSTM-attention hybrid model with Bayesian hyperparameter optimization," *Global Energy Interconnection*, Vol. 7, No. 5, pp. 667–681, 2024, DOI: [10.1016/j.gloi.2024.10.005](https://doi.org/10.1016/j.gloi.2024.10.005).
- [3] J. Liu, H. Zang, L. Cheng, T. Ding, Z. Wei, and G. Sun, "A transformer-based multimodal-learning framework using sky images for ultra-short-term solar irradiance forecasting," *Applied Energy*, Vol. 342, Art. no. 121160, 2023, DOI: [10.1016/j.apenergy.2023.121160](https://doi.org/10.1016/j.apenergy.2023.121160).
- [4] Y. Yu, J. Cao, and J. Zhu, "An LSTM short-term solar irradiance forecasting under complicated weather conditions," *IEEE Access*, Vol. 7, pp. 145651–145666, 2019, DOI: [10.1109/ACCESS.2019.2946057](https://doi.org/10.1109/ACCESS.2019.2946057).
- [5] Q. Qiu et al., "DTCformer: A temporal convolution-enhanced Autoformer with DILATE loss for photovoltaic power forecasting," *Energies*, Vol. 18, No. 10, Art. no. 2450, 2025, DOI: [10.3390/en18102450](https://doi.org/10.3390/en18102450).
- [6] E. Kim and Y. S. Hau, "Advancing photovoltaic solar power forecasting by the hybrid model of CNN and DNN and the XAI with SHAP," *International Journal of Green Energy*, pp. 1–12, 2025, DOI: [10.1080/15435075.2025.2553864](https://doi.org/10.1080/15435075.2025.2553864).

-
- [7] A. Agga, A. Abbou, M. Labbadi, Y. El Houm, and I. H. O. Ali, "CNN-LSTM: An efficient hybrid deep learning architecture for predicting short-term photovoltaic power production," *Electric Power Systems Research*, Vol. 208, Art. no. 107908, 2022, DOI: [10.1016/j.epsr.2022.107908](https://doi.org/10.1016/j.epsr.2022.107908).
- [8] G. Wu, Y. Wang, Q. Zhou, and Z. Zhang, "Enhanced photovoltaic power forecasting: An iTransformer and LSTM-based model integrating temporal and covariate interactions," in *2024 IEEE 8th Conference on Energy Internet and Energy System Integration (EI2)*, 2024, pp. 856–861, DOI: [10.1109/EI264398.2024.10990816](https://doi.org/10.1109/EI264398.2024.10990816).
- [9] E. M. Al-Ali et al., "Solar energy production forecasting based on a hybrid CNN-LSTM-transformer model," *Mathematics*, Vol. 11, No. 3, Art. no. 676, 2023, DOI: [10.3390/math11030676](https://doi.org/10.3390/math11030676).
- [10] D. Salman, C. Direkoglu, M. Kusaf, and M. Fahrioglu, "Hybrid deep learning models for time series forecasting of solar power," *Neural Computing and Applications*, Vol. 36, No. 16, pp. 9095–9112, 2024, DOI: [10.1007/s00521-024-09558-5](https://doi.org/10.1007/s00521-024-09558-5).



مقایسه و مرور کاربرد مدل‌های یادگیری عمیق در پیش‌بینی تولید انرژی الکتریکی سیستم‌های فتوولتائیک با تمرکز بر LSTM و مدل‌های ترکیبی

امیرعلی سیف‌الدین^{۱*}، مبینا کلانتری^۲، محمدعلی اله ربی شیرازی^۳

۱- دانشیار، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، تهران، ایران

۲- دانشجوی کارشناسی ارشد، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، تهران، ایران

۳- دانشجوی دکتری، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، تهران، ایران

چکیده

پیش‌بینی دقیق تولید انرژی خورشیدی، به دلیل ماهیت متغیر تابش خورشید، شرایط جوی پویا و عدم قطعیت‌های اقلیمی، یکی از چالش‌های اصلی در مدیریت سیستم‌های انرژی تجدیدپذیر محسوب می‌شود. در این پژوهش، یک مرور سیستماتیک جامع بر ۴۰ مطالعه‌ی منتخب منتشرشده در بازه‌ی زمانی ۲۰۱۹ تا ۲۰۲۵ انجام شد تا کارایی مدل‌های یادگیری عمیق در پیش‌بینی تولید انرژی خورشیدی مورد بررسی قرار گیرد. تمرکز اصلی بر شبکه‌های حافظه‌ی کوتاه مدت-بلند مدت (LSTM) و مدل‌های ترکیبی بوده است که در سال‌های اخیر کاربرد گسترده‌ای یافته‌اند. مقایسه‌ی مدل‌ها بر اساس شاخص‌های ارزیابی خطا، شامل ریشه‌ی میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و میانگین درصد خطای مطلق (MAPE)، صورت گرفت. نتایج نشان داد که مدل‌های ترکیبی در پیش‌بینی‌های کوتاه مدت عملکرد بهتری داشته و خطا را تا حدود ۲/۹٪ کاهش داده‌اند، در حالی که مدل‌های مجهز به مکانیزم توجه در افق‌های میان مدت و بلند مدت دقت بیشتری ارائه کرده‌اند. علاوه بر این، استفاده از داده‌های چند منبعی، شامل اطلاعات محلی، تصاویر ماهواره‌ای و داده‌های هواشناسی، موجب بهبود دقت پیش‌بینی تا حدود ۳۰٪ شده است. در نهایت، یافته‌ها بیانگر روند روبه رشد بهره‌گیری از رویکردهای چند سطحی، تلفیق داده‌های متنوع و هوشمندسازی مدل‌ها برای ارتقای قابلیت اطمینان و پایداری در مدیریت منابع انرژی خورشیدی است.

کلمات کلیدی

انرژی‌های تجدیدپذیر
پیش‌بینی انرژی خورشیدی
شبکه‌های حافظه‌ی کوتاه مدت-بلند مدت
مدل‌های یادگیری عمیق
مدل‌های ترکیبی

دریافت مقاله: ۱۴۰۴/۰۹/۰۵

بازنگری مقاله: ۱۴۰۴/۱۰/۱۷

پذیرش مقاله: ۱۴۰۵/۰۲/۱۲

*نویسنده مسئول

امیرعلی سیف‌الدین

ایمیل

saifoddin@ut.ac.ir

۱- مقدمه

فتوولتائیک به شدت تحت تأثیر شرایط جوی، میزان تابش و تغییرات زمانی قرار دارد؛ بنابراین، مدل‌های پیش‌بینی نیازمند الگوریتم‌هایی هستند که بتوانند هم‌زمان داده‌های سری زمانی و ویژگی‌های مکانی را تحلیل کنند. در این راستا، روش‌های یادگیری عمیق به‌ویژه شبکه‌های حافظه‌ی کوتاه مدت-بلند مدت، به دلیل قابلیت ذخیره و پردازش تاریخچه اطلاعات، نقش مهمی در ارتقای دقت پیش‌بینی ایفا کرده‌اند. علاوه بر این، شبکه‌های ترکیبی نظیر شبکه‌های حافظه‌ی کوتاه

پیش‌بینی دقیق تولید انرژی خورشیدی به دلیل تأثیر بالقوه ناپایداری تابش خورشیدی بر تعادل تولید و تقاضا، پایداری شبکه و کاهش هزینه‌های ذخیره‌سازی اهمیت حیاتی دارد. در سال‌های اخیر، شبکه‌های عصبی حافظه‌ی کوتاه مدت - بلند مدت به دلیل قابلیت استخراج وابستگی‌های طولانی مدت و غیرخطی در داده‌های سری زمانی، به‌عنوان ابزاری کارآمد برای این منظور شناخته شده‌اند [۱]. با افزایش سهم انرژی‌های تجدیدپذیر، اهمیت پیش‌بینی کوتاه مدت تولید توان خورشیدی بیش از پیش برجسته شده است. تولید توان

Cite this Article:

[1] A. Saifoddin, M. Kalantari, and M. Allahrabbi Shirazi, "Comparison and Review of the Application of Deep Learning Models in Forecasting Electrical Energy Generation of Photovoltaic Systems with a Focus on LSTM and Hybrid Models," *Science and Technology in Mechanical Engineering*, Vol. 5, No. 1, pp. 309-326, 2026. [Online]. Available: <https://doi.org/10.22034/stme.2026.562431.1188> (in Persian)



©2026 the authors. Published by Technical and Vocational University (TVU), Tehran, Iran. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution-Noncommercial 4.0 International (CC BY-NC License) (<https://creativecommons.org/licenses/by-nc/4.0/>)

شاپای الکترونیک: ۲۲۳۲-۲۹۸۱

مدت-بلند مدت^۱ همراه با شبکه‌های عصبی کانولوشنی^۲ نیز توسعه یافته‌اند. در این معماری‌ها، شبکه‌های عصبی کانولوشنی ویژگی‌های فضایی داده‌ها را استخراج کرده و حافظه کوتاه مدت-بلند مدت آن‌ها را در بُعد زمانی تحلیل می‌کند. این ترکیب، توانایی مدل در شناسایی الگوهای پیچیده فضایی-زمانی را افزایش داده و منجر به بهبود چشمگیر دقت پیش‌بینی شده است به گونه‌ای که کاهش خطاهای RMSE و MAE در بازه‌ای حدود ۵ تا ۲۵ درصد نسبت به مدل‌های پایه مشاهده شده است [۲]. در مطالعات جدیدتر، نسخه‌های توسعه‌یافته CNN-LSTM با افزودن مکانیزم توجه و تنظیم هوشمند ابر پارامترها (مانند بهینه‌سازی بیزی) ارائه شده‌اند که در مقایسه با CNN-LSTM پایه، کاهش معنادار خطا و پایداری بالاتری را در سناریوهای متغیر آب‌وهوایی گزارش کرده‌اند. همچنین، استفاده هم‌زمان از داده‌های سری زمانی و تصاویر آسمان در این چارچوب‌ها، دقت پیش‌بینی فوق کوتاه مدت را به‌طور محسوسی افزایش داده است [۳]. در زمینه پیش‌بینی تولید انرژی خورشیدی، شبکه‌های عصبی بازگشتی^۳ و شبکه‌های حافظه کوتاه مدت-بلند مدت به دلیل توانایی در مدل‌سازی وابستگی‌های زمانی کوتاه مدت و بلند مدت توجه زیادی جلب کرده‌اند. علاوه بر این، مدل‌های مبتنی بر شبکه‌های عصبی کانولوشنی نیز برای پردازش داده‌های تصویری و پیش‌بینی دقیق‌تر، با بهره‌گیری از ویژگی‌های تصویری آسمان و تاریخچه تولید انرژی خورشیدی مورد استفاده قرار گرفته‌اند. نتایج گزارش‌شده در مطالعات پیشین نشان می‌دهد که مدل LSTM در مقایسه با مدل‌های کلاسیک، در پیش‌بینی ساعتی تابش خورشیدی مقادیر RMSE حدود ۴۱ تا ۴۶ W/m² را در شرایط مختلف جوی ثبت کرده است، در حالی که این مقدار برای مدل‌هایی نظیر BPNN و RNN در برخی سناریوها به بیش از ۱۷۰ W/m² رسیده است. همچنین در روزهای ترکیبی، مقدار MAPE مدل LSTM حدود ۱۰٪ [۴] درصد کمتر از مدل‌های بازگشتی متداول گزارش شده است [۵]. به‌طور کلی، مدل‌های یادگیری عمیق^۴ مورد استفاده در پیش‌بینی تولید انرژی الکتریکی فتوولتائیک را می‌توان به چند دسته اصلی تقسیم کرد. شبکه‌های عصبی بازگشتی، به‌ویژه شبکه‌های حافظه کوتاه مدت-بلند مدت و گونه‌های توسعه‌یافته آن، برای مدل‌سازی وابستگی‌های زمانی در داده‌های سری زمانی به‌طور گسترده به کار گرفته شده‌اند.

شبکه‌های عصبی کانولوشنی نیز به دلیل توانایی در استخراج ویژگی‌های مکانی، به‌ویژه در تحلیل داده‌های تصویری آسمان و اطلاعات فضایی، کاربرد فراوانی یافته‌اند. علاوه بر این، معماری‌های مبتنی بر مکانیزم توجه و مدل‌های ترنسفورمر به‌عنوان نسل جدید یادگیری عمیق، به‌ویژه در پیش‌بینی‌های چند گامی و افق‌های زمانی بلند مدت، عملکرد قابل توجهی از خود نشان داده‌اند. در سال‌های اخیر، ترکیب این معماری‌ها در قالب مدل‌های هیبریدی و تجمیعی، با هدف بهره‌گیری هم‌زمان از مزایای هر رویکرد، به یکی از روندهای غالب در پژوهش‌های پیش‌بینی انرژی فتوولتائیک تبدیل شده است. علاوه بر مطالعات منفرد، پژوهش‌های جدید منتشرشده در ژورنال‌های متنوع حوزه انرژی و هوش مصنوعی نشان می‌دهند که دامنه کاربرد مدل‌های یادگیری عمیق در پیش‌بینی توان فتوولتائیک محدود به یک ناشر یا یک خانواده معماری خاص نیست. این مطالعات که در مجلاتی نظیر Solar Energy، Global Energy Interconnection، Renewable Energy، Energies و Sensors منتشر شده‌اند، بر حرکت تدریجی از مدل‌های بازگشتی کلاسیک به سمت مدل‌های ترکیبی و مبتنی بر مکانیزم توجه، معماری‌های مبتنی بر Transformer و Autoformer و نیز رویکردهای چندوجهی مبتنی بر تصاویر آسمان تأکید دارند و نقش همجوشی داده‌های چند منبعی و بهینه‌سازی ابر پارامترها را در افزایش دقت و پایداری پیش‌بینی برجسته می‌کنند [۳ و ۴ و ۶-۸].

مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های حافظه کوتاه مدت بلند مدت و معماری‌های ترکیبی، به دلیل توانایی در استخراج ویژگی‌های زمانی-مکانی، عملکرد برجسته‌ای در پیش‌بینی توان فتوولتائیک نشان داده‌اند. موفقیت این روش‌ها در حوزه‌های مختلف، از جمله انرژی و پزشکی، پتانسیل بالای آن‌ها را تأیید می‌کند. این مطالعه به بررسی سیستماتیک این مدل‌ها در پیش‌بینی تولید انرژی خورشیدی پرداخته است. به‌عنوان مثال، مدل ترکیبی WPD-LSTM توانسته است با دقت بالا توان خروجی فتوولتائیک را در شرایط مختلف آب و هوایی پیش‌بینی کند و در مقایسه با مدل‌هایی مانند MLP^۵ و GRU^۶ عملکرد بهتری داشته باشد. همچنین، استفاده از معماری‌های پیشرفته‌ای مانند CNN-LSTM^۷ و PC-LSTM^۷ در مدل‌های

^۵ Multi-Layer Perceptron (MLP)^۶ Gated Recurrent Unit (GRU)^۷ Predictive Control Long Short-Term Memory (PC-LSTM)^۱ Long Short-Term Memory (LSTM)^۲ Convolutional Neural Network (CNN)^۳ Recurrent Neural Network (RNN)^۴ Deep Learning

در این مقاله ابتدا به مبانی نظری و ویژگی‌های کلیدی هر یک از این مدل‌ها پرداخته می‌شود. سپس عملکرد آن‌ها در سناریوهای مختلف پیش‌بینی، شامل پیش‌بینی کوتاه مدت، میان‌مدت و بلند مدت، به‌ویژه در شرایط جوی متغیر، مورد تحلیل و مقایسه قرار خواهد گرفت. بررسی سیستماتیک نقاط قوت و ضعف هر مدل، همراه با ارزیابی تأثیر انتخاب بهینه‌سازها و ترکیب مؤلفه‌های مختلف یادگیری عمیق بر دقت پیش‌بینی، از دیگر اهداف این مقاله است. در این راستا، تأثیرات مختلف این ترکیب‌ها بر نتایج پیش‌بینی در شرایط مختلف بررسی خواهد شد. در پایان، کاربردهای عملی این مدل‌ها در محیط‌های واقعی و چالش‌های اجرایی آن‌ها مانند هزینه‌های محاسباتی، نیاز به داده‌های حجیم و مشکلات پیاده‌سازی در مقیاس صنعتی مورد بررسی قرار می‌گیرد. هدف نهایی این مقاله ارائه نقشه‌راهی جامع برای پژوهشگران و مهندسان است تا با استفاده از تجربیات موجود، مدل‌های پیش‌بینی دقیق، کم‌هزینه و کارآمدی را توسعه دهند که قابلیت پیاده‌سازی در زیرساخت‌های هوشمند انرژی را داشته باشند.

با افزایش نفوذ سیستم‌های فتوولتائیک در شبکه‌های قدرت، پیش‌بینی دقیق تولید انرژی الکتریکی این سیستم‌ها به یکی از چالش‌های کلیدی در بهره‌برداری، برنامه‌ریزی و مدیریت منابع انرژی تبدیل شده است. ماهیت متغیر تابش خورشیدی، وابستگی شدید تولید توان به شرایط جوی و محدودیت دسترسی به داده‌های جامع و همگن، موجب شده است که روش‌های کلاسیک پیش‌بینی دقت و پایداری کافی نداشته باشند.

با این حال، روش‌های کلاسیک و رگرسیونی همچنان به‌عنوان خط مبنا در بسیاری از مطالعات پیش‌بینی توان/تابش خورشیدی استفاده می‌شوند؛ از جمله رگرسیون خطی و چند متغیره، مدل‌های سری زمانی مانند ARIMA و نیز مدل‌های یادگیری ماشین رگرسیونی مانند SVR همچنین روش‌های پایه‌ای نظیر smart- و persistence persistence برای ارزیابی حداقل سطح عملکرد قابل قبول، به‌طور گسترده در ادبیات به کار می‌روند. در این مقاله، این روش‌ها به‌صورت فشرده و به‌عنوان مبنای مقایسه معرفی می‌شوند؛ با این وجود، به دلیل رشد سریع، تنوع معماری‌ها و نیاز به یک چارچوب مقایسه‌ای منسجم

ترکیبی، دقت پیش‌بینی‌ها را بهبود بخشیده و خطاهای مدل‌های سنتی را کاهش داده است [۹].

تحقیقات جدیدتر، از جمله مدل iTransformer-LSTM با مکانیسم توجه متقابل^۱ و ساختار شبکه کولموگروف-آرنولد^۲، به توانایی تحلیل تعاملات پیچیده زمانی و چند متغیره اشاره دارند. این مدل‌ها در پیش‌بینی تولید انرژی فتوولتائیک در فصول مختلف استرالیا عملکرد بسیار موفقی داشته‌اند [۱۰]. همچنین روش‌های خود رمزگذارها^۳ نیز تأثیرگذار ظاهر شده‌اند. به‌عنوان مثال، یک مدل ترکیبی CNN + LSTM Autoencoder برای پیش‌بینی کوتاه مدت تولید انرژی فتوولتائیک در یک مزرعه خورشیدی در جنوب انگلستان، کاهش ۵ تا ۲۵ درصد در معیارهای RMSE^۴ و MAE^۵ و همچنین کاهش ۷۰ درصد در زمان آموزش را گزارش کرده است [۲]. قدرت این مدل‌ها با افزودن ساختار ترنسفورمر به LSTM و CNN افزایش یافته است. تحقیقات نشان داده‌اند که ترکیب CNN-LSTM-Transformer با استفاده از خوشه‌بندی^۶ و نقشه خود سازمانده^۷ برای انتخاب ویژگی‌ها، بهترین دقت را در پیش‌بینی تولید انرژی خورشیدی در مجموعه داده Fingrid^۸ ارائه داده است [۱۱].

پژوهش‌ها ترکیب‌های CNN، LSTM و Transformer را با بهینه‌سازهای مختلف بررسی کرده‌اند. نتایج نشان می‌دهند که مدل CNN-LSTM-TF^۹ با MAE تنها ۰/۵۵۱٪ عملکرد بسیار نسبت به مدل TF-LSTM با $MAE \approx ۰/۱۶۱۷$ دارد. که اهمیت انتخاب معماری و بهینه‌ساز مناسب را برجسته می‌کند [۱۲].

با وجود پیشرفت‌های چشمگیر در استفاده از مدل‌های یادگیری عمیق برای پیش‌بینی تولید انرژی خورشیدی، همچنان خلأهای علمی و عملی متعددی در این حوزه وجود دارد که بررسی آن‌ها می‌تواند به بهبود مدل‌ها و افزایش دقت پیش‌بینی کمک کند. هدف این مقاله مروری، ارائه چارچوبی جامع از تحول معماری‌های پیش‌بینی انرژی خورشیدی مبتنی بر یادگیری عمیق است تمرکز اصلی بر مدل‌های LSTM و ساختارهای ترکیبی آن، از جمله CNN-LSTM، CNN-LSTM-Transformer، iTransformer-LSTM، TimesNet + iTransformer و سایر رویکردهای نوین می‌باشد.

^۶ Clustering

^۷ Self-Organizing Map (SOM)

^۸ Fingrid Dataset

^۹ Transformer (TF)

^۱ Attention Mechanism

^۲ Kolmogorov-Arnold Network (KAN)

^۳ Autoencoder

^۴ Root Mean Square Error (RMSE)

^۵ Mean Absolute Error (MAE)

۱-۲- معیارهای انتخاب مقالات

سال انتشار: ۲۰۱۹ تا ۲۰۲۵

حوزه انتشار: ژورنال‌های معتبر حوزه انرژی، هوش مصنوعی و مدل‌سازی (مثل Applied Energy, Renewable Energy, Energy)
شاخص‌های ارزیابی مدل‌ها RMSE، MAE، MAPE، NSE و دقت کلی مدل‌ها.
تمرکز مقالات: مدل‌های یادگیری عمیق (CNN، LSTM، Transformer) و مدل‌های ترکیبی.

مقالات انتخاب شدند که حداقل از یک مدل یادگیری عمیق استفاده کرده و مبتنی بر داده‌های واقعی نیروگاه‌های فتوولتائیک یا داده‌های ماهواره‌ای باشند. مجلات مورد استفاده در این مطالعه از میان نشریاتی انتخاب شده‌اند که به صورت تخصصی در حوزه انرژی‌های تجدیدپذیر، سیستم‌های فتوولتائیک و کاربرد روش‌های یادگیری ماشین و یادگیری عمیق در مدل‌سازی و پیش‌بینی فعالیت می‌کنند و بیشترین هم‌پوشانی موضوعی با پیش‌بینی تولید انرژی خورشیدی داشته و به طور منظم مقالات داوری شده همراه با گزارش شاخص‌های کمی ارزیابی عملکرد مدل‌ها منتشر می‌کنند.

۲-۲- فرایند غربال‌گری مقالات

در این مطالعه، بیش از ۱۰۰ مقاله منتشر شده در بازه ۲۰۱۹ تا ۲۰۲۵ جمع‌آوری شد و پس از بررسی کیفیت و ارتباط، در نهایت ۴۰ مقاله منتخب برای تحلیل جزئی انتخاب گردیدند.

۳-۲- شاخص‌های مورد بررسی

برای مقایسه مدل‌ها، چهار جنبه اصلی در نظر گرفته شد:

نوع مدل‌ها: LSTM، CNN، Transformer، مدل‌های ترکیبی^۲ و Ensemble^۳

نوع داده‌های ورودی: تصاویر ماهواره‌ای^۴، داده‌های SCADA^۵، داده‌های هواشناسی^۶، داده‌های پیش‌بینی عددی (NWP)^۷.
افق زمانی پیش‌بینی: کوتاه مدت (چند دقیقه تا ۶ ساعت)، میان‌مدت (۱ تا ۳ روز)، بلند مدت (بیش از یک هفته).
شاخص‌های ارزیابی: RMSE، MAE، MAPE^۸، NSE^۹، Skill Score^{۱۰}

در سال‌های اخیر، تمرکز اصلی مرور حاضر بر روش‌های مبتنی بر یادگیری عمیق به‌ویژه LSTM و ساختارهای ترکیبی قرار داده شده است [۱۳ و ۱۴].

در سال‌های اخیر، مدل‌های یادگیری ماشین و به‌ویژه یادگیری عمیق، به عنوان ابزارهایی توانمند برای مدل‌سازی روابط غیرخطی و وابستگی‌های زمانی-مکانی، به طور گسترده در پیش‌بینی تولید انرژی الکتریکی فتوولتائیک مورد استفاده قرار گرفته‌اند. با این حال، تنوع معماری‌ها، تفاوت داده‌های ورودی، افق‌های زمانی مختلف و نبود چارچوبی منسجم برای مقایسه این مدل‌ها، موجب پراکندگی نتایج و دشواری در انتخاب رویکرد بهینه شده است.

هدف اصلی این پژوهش، ارائه یک مرور نظام‌مند و تحلیلی از کاربرد مدل‌های یادگیری ماشین و یادگیری عمیق در پیش‌بینی تولید انرژی الکتریکی سیستم‌های فتوولتائیک، با تمرکز ویژه بر شبکه‌های حافظه کوتاه مدت-بلند مدت و معماری‌های ترکیبی آن‌هاست. در این راستا، عملکرد مدل‌ها در افق‌های زمانی مختلف، نوع داده‌های ورودی، شاخص‌های ارزیابی و مزایا و محدودیت‌های هر رویکرد به صورت مقایسه‌ای بررسی شده است. در این مطالعه، برخی پارامترها و داده‌ها به طور مستقیم مورد استفاده قرار نگرفته‌اند که دلایل اصلی آن‌ها شامل عدم دسترسی عمومی به داده‌های خام نیروگاه‌های صنعتی، محدودیت دسترسی به تصاویر ماهواره‌ای با وضوح زمانی و مکانی بالا، نبود داده‌های کامل SCADA در بسیاری از مطالعات و تفاوت در سیاست‌های انتشار داده توسط اپراتورهای نیروگاهی بوده است. از این رو، تحلیل‌ها بر مبنای اطلاعات گزارش شده در مقالات منتخب و داده‌های در دسترس عمومی انجام شده است. این محدودیت‌ها به عنوان یکی از چالش‌های اساسی در مقایسه منصفانه مدل‌ها در ادبیات موجود شناسایی می‌شوند.

۲- روش‌شناسی مرور نظام‌مند

این مطالعه یک مرور نظام‌مند^۱ بر مقالات علمی در حوزه پیش‌بینی تولید انرژی خورشیدی با استفاده از مدل‌های یادگیری عمیق انجام داده است. در این پژوهش، جستجوی مقالات از طریق پایگاه‌های علمی معتبر از جمله گوگل اسکولار، IEEE Xplore، ScienceDirect و SpringerLink انجام شد.

⁶ Meteorological Data

⁷ Numerical Weather Prediction (NWP)

⁸ Mean Absolute Percentage Error (MAPE)

⁹ Nash-Sutcliffe Efficiency (NSE)

¹⁰ Skill Score

¹ Systematic Review

² Hybrid Models

³ Ensemble Models

⁴ Satellite Imagery

⁵ Supervisory Control and Data Acquisition (SCADA)

۳- پیشینه تحقیق و مبانی نظری

نوسانات تابش و شرایط جوی متغیر، یکی از چالش‌های اساسی در مدیریت شبکه‌های انرژی تجدیدپذیر پیش‌بینی دقیق توان خورشیدی به دلیل است. در سال‌های اخیر، مدل‌های یادگیری عمیق، به‌ویژه معماری‌های مبتنی بر شبکه‌های حافظه کوتاه مدت-بلند مدت و ترنسفورمر، به دلیل توانایی در شبیه‌سازی الگوهای پیچیده زمانی-مکانی، جایگاه ویژه‌ای در این حوزه پیدا کرده‌اند. این مقاله به مرور ۴۰ مطالعه منتشرشده در سال‌های ۲۰۲۲ تا ۲۰۲۵ پرداخته و با مقایسه عملکرد مدل‌های ترکیبی مانند شبکه‌های عصبی کانولوشنی-حافظه کوتاه مدت بلند مدت، ترنسفورمر-کانولوشن^۱ و آتوفرمر^۲، راهکارهای نوینی برای بهبود دقت پیش‌بینی تحلیل می‌کند. یافته‌ها نشان می‌دهند که مدل‌های ترکیبی با کاهش خطای RMSE تا ۳۰٪ نسبت به روش‌های کلاسیک، به‌عنوان رویکردهای پیشرو در این حوزه شناخته می‌شوند. همچنین، چالش‌های کلیدی مانند نیاز به داده‌های باکیفیت، محاسبات پیچیده و استانداردسازی معیارهای ارزیابی مورد بررسی قرار گرفته‌اند [۱۵]. به‌عنوان نمونه، مدل CNN-LSTM توسعه‌یافته برای یک سایت نیروگاهی در کره، نرخ خطای MAPE را به ترتیب حدود ۴/۵۸٪ در روزهای آفتابی و ۷/۰۶٪ در روزهای ابری گزارش کرده است که نشان می‌دهد این مدل در شرایط غیر قابل پیش‌بینی محیطی نیز پایداری مناسبی دارد [۱۶].

۳-۱- اهمیت و چالش در پیش‌بینی خورشیدی

شبکه‌های حافظه بلند-کوتاه مدت^۳ نوعی از شبکه‌های عصبی بازگشتی هستند که با مکانیزم دروازه‌ای وابستگی‌های بلند مدت در داده‌های سری زمانی را یاد می‌گیرند. به‌واسطه توانایی مدل‌سازی روابط طولانی‌مدت و غیرخطی، LSTM‌ها در پیش‌بینی تابش و توان فتوولتائیک به‌ویژه در افق‌های کوتاه مدت تا میان‌مدت عملکرد خوبی داشته‌اند. این معماری‌ها قادرند با داده‌های چند متغیره (مثلاً دما، رطوبت، سرعت باد، پوشش ابر، تابش لحظه‌ای) کار کنند و روندها و نوسانات مقطعی را یاد بگیرند. با این حال، آن‌ها نیاز به داده تاریخی کافی و تنظیم دقیق فراپارامترها دارند.^۴ مروری سیستماتیک بر مقالات نشان می‌دهد که LSTM یکی از پرکاربردترین معماری‌ها در سال‌های اخیر بوده است [۱۷].

۳-۲- معماری پایه

شبکه‌های حافظه کوتاه مدت - بلند مدت، شبکه‌های LSTM: شبکه‌های LSTM به لطف دروازه‌های ورودی، فراموشی و خروجی، قادر به مدل‌سازی وابستگی‌های بلند مدت در داده‌های سری زمانی توان فتوولتائیک هستند و نسبت به شبکه‌های عصبی بازگشتی کلاسیک از پایداری بیشتری برخوردارند. در پیش‌بینی ساعتی یا روزانه توان فتوولتائیک، LSTM معمولاً خطای کمتری در مقایسه با روش‌های آماری خطی دارد. با این حال، این مدل‌ها به داده‌های حجیم تنظیم دقیق فراپارامترها نیاز دارند [۱۸].

شبکه‌های عصبی کانولوشنی: این شبکه‌ها برای تحلیل تصاویر آسمان، ابر یا نگاشت‌های فضایی (مانند تصاویر ماهواره‌ای و راداری) عملکرد بسیار خوبی دارند. زمانی که این شبکه‌ها با داده‌های زمانی ترکیب می‌شوند، مانند ساختار CNN→LSTM قادر به استخراج الگوهای پیچیده مکانی-زمانی هستند و در پیش‌بینی‌های افق کوتاه مدت (۱۰ تا ۶۰ دقیقه) دقت بالاتری را ارائه می‌دهند [۱۹].

مدل‌های ترنسفورمر: این مدل‌ها با استفاده از مکانیزم «توجه خود-توجهی»^۴ برای پردازش دنباله‌های طولانی داده‌ها بسیار کارآمد هستند. این مدل‌ها به‌ویژه در پیش‌بینی‌های چند گامی^۵ و افق‌های بلند مدت مزیت‌هایی را نشان داده‌اند. نسخه‌های خاص این مدل‌ها مانند اینفرمر^۶ و آتوفرمر در پیش‌بینی توان فتوولتائیک کاربرد گسترده‌ای پیدا کرده‌اند [۲۰].


۳-۳- مدل‌های ترکیبی

برای رفع محدودیت‌های هر مدل منفرد، پژوهش‌ها به سمت مدل‌های ترکیبی حرکت کرده‌اند:

۳-۳-۱- CNN + LSTM

در این مدل، شبکه‌های کانولوشنی برای استخراج ویژگی‌های محلی مانند داده‌های چندکاناله یا تصاویر ماهواره‌ای استفاده می‌شوند و LSTM برای مدل‌سازی بعد زمانی به کار می‌رود. مطالعات نشان داده‌اند که این ترکیب در پیش‌بینی تابش و توان عملکرد بهتری نسبت به استفاده تنها از LSTM دارد؛ به گونه‌ای که در تحلیل‌های ابلیشن، مدل CNN-LSTM موجب کاهش خطای MAE و RMSE به ترتیب حدود ۲۷/۶٪ و ۲۴/۹٪ نسبت به مدل LSTM منفرد شده است شکل ۱ معماری مدل CNN-LSTM را نشان می‌دهد که در آن

⁴ Self-Attention⁵ Multi-step⁶ Informer¹ Transformer-CNN Hybrid² Autoformer³ Hyperparameters



شکل ۱: زنجیره استخراج ویژگی‌های مکانی از تصاویر آسمان با CNN و مدل سازی وابستگی‌های زمانی با LSTM برای پیش‌بینی درون ساعته [۲۵]

۳-۲-۳-۲ Transformer-CNN / Autoformer

مدل‌های ترنسفورمر و به‌ویژه آتوفرمر به‌عنوان نسل جدید شبکه‌های یادگیری عمیق، در پیش‌بینی میان‌مدت و بلند مدت تولید انرژی خورشیدی بسیار موفق عمل کرده‌اند. این معماری‌ها بر پایه مکانیزم توجه توسعه یافته‌اند که به مدل اجازه می‌دهد وابستگی‌های بلند مدت در داده‌های سری زمانی را بهتر شناسایی کند.

برخلاف مدل‌های ترکیب شبکه‌های کانولوشنی و LSTM (CNN-LSTM) که بیشتر برای پیش‌بینی‌های کوتاه مدت و مبتنی بر تصاویر ماهواره‌ای پهنه شده است، آتوفرمر در بازه‌های ۲۴ تا ۷۲ ساعت عملکرد بهتری از خود نشان داده‌اند؛ به گونه‌ای که در یکی از مطالعات، مدل ترنسفورمر توانسته است به مقادیر MAE برابر با ۱/۲ kW/۰/۹۵ و MAPE برابر با ۲/۲۱٪ در پیش‌بینی توان فتوولتائیک دست یابد. علاوه بر این، مدل‌های پیشرفته آتوفرمر با بهره‌گیری از ساختار چند مقیاسی و مکانیزم توجه ناپایا، در پیش‌بینی کوتاه مدت و میان‌مدت عملکرد بهتری نسبت به مدل‌های پایه ارائه داده‌اند؛ به طوری که در پیش‌بینی ۲۴ ساعته، مقادیر RMSE برابر با ۰/۵۲۹ و MAE برابر با ۰/۳۰۲ گزارش شده است که نشان‌دهنده کاهش خطای پیش‌بینی نسبت به روش‌های مرجع است [۲۶ و ۲۷].

۳-۳-۳-۳ LSTM + Attention / Transformer

ترکیب مکانیزم توجه یا بخش‌های ترنسفورمر برای وزن‌دهی پویا به ورودی‌ها و برجسته‌سازی اطلاعات مهم زمانی/شرطی استفاده می‌شود. مطالعات نشان می‌دهند که این ترکیب در شرایط تغییرپذیر آب و هوایی دقت بالاتری نسبت به مدل‌های خالص LSTM ارائه می‌دهد [۲۸].

شبکه‌های کانولوشنی با پردازش تصاویر آسمان، ویژگی‌های مکانی و الگوهای محلی را استخراج کرده و سپس این ویژگی‌ها به لایه‌های LSTM منتقل می‌شوند تا وابستگی‌های زمانی داده‌ها برای پیش‌بینی توان خورشیدی مدل سازی شود. این ساختار امکان استفاده هم‌زمان از اطلاعات مکانی و زمانی را فراهم می‌کند [۲۱].

مدل‌های ترکیبی مبتنی بر شبکه‌های کانولوشنی و LSTM، به‌ویژه در استفاده از تصاویر آسمان برای پیش‌بینی لحظه‌ای مدل‌های ترکیبی مبتنی بر CNN-LSTM، به‌ویژه در استفاده از تصاویر آسمان برای پیش‌بینی لحظه‌ای و درون‌ساعته، عملکرد قابل توجهی داشته‌اند. در این ساختار، CNN ابتدا ویژگی‌های مکانی تصاویر آسمان مانند الگوهای ابر، جهت حرکت و پوشش را استخراج می‌کند و سپس لایه‌های LSTM این ویژگی‌ها را در بُعد زمانی تحلیل می‌کنند تا توان آینده پیش‌بینی شود. مدل‌های ترکیبی مبتنی بر CNN-LSTM، به‌ویژه در استفاده از تصاویر آسمان برای پیش‌بینی لحظه‌ای و درون‌ساعته، عملکرد قابل توجهی داشته‌اند. در این ساختار، CNN ابتدا ویژگی‌های مکانی تصاویر آسمان مانند الگوهای ابر، جهت حرکت و پوشش را استخراج می‌کند و سپس لایه‌های LSTM این ویژگی‌ها را در بُعد زمانی تحلیل می‌کنند تا توان آینده پیش‌بینی شود. مطالعات ارزیابی مقایسه‌ای نشان داده‌اند که ترکیب داده‌های متنوع و استفاده از تکنیک‌های انتقال یادگیری^۱ باعث افزایش قابلیت تعمیم‌پذیری مدل‌ها می‌شود. همچنین گزارش‌ها نشان می‌دهند که در افق‌های فوق کوتاه مدت، کاهش خطای MAPE حدود ۲ تا ۴ درصد نسبت به روش‌های پایه قابل دستیابی است [۲۲].

یکی از پژوهش‌ها نشان داد که مدل ترکیبی CNN-LSTM با استفاده از داده‌های تصویری آسمان و داده‌های هواشناسی توانسته است پیش‌بینی تولید انرژی خورشیدی در بازه ۱۰ دقیقه‌ای را با خطای MAPE کمتر از ۳/۵٪ انجام دهد. این پژوهش اهمیت ادغام داده‌های چند منبع و تحلیل ویژگی‌های مکانی-زمانی را در افزایش دقت پیش‌بینی تأیید می‌کند [۲۳]. مطالعه دیگری مدل ترکیبی CNN-LSTM را با داده‌های SCADA و هواشناسی برای پیش‌بینی تولید انرژی خورشیدی در بازه‌های ساعته بررسی کرده است که کاهش چشمگیری در خطای MAPE نسبت به مدل‌های مبتنی بر LSTM صرف نشان داده است و نقش داده‌های ترکیبی را در افزایش دقت پیش‌بینی تأیید می‌کند [۲۴].

^۱ Transfer Learning

۳-۳-۴-LSTM+ مدل‌های آماری

استفاده ترکیبی از مدل‌های خطی مانند و^۱ (SARIMA) (ARIMA)^۲ با مدل‌های غیرخطی (LSTM) برای داده‌هایی که روند و فصل‌پذیری دارند، نتایج بهتری ارائه می‌دهد. مرورهای سیستماتیک، کارایی این رویکرد را تأیید کرده‌اند [۱۵].

۳-۳-۵-LSTM+ بهینه‌سازی فرا ابتکاری

استفاده از الگوریتم‌های بهینه‌سازی اجتماع ذرات^۳، الگوریتم ژنتیک^۴، بهینه‌سازی تفاضل تکاملی^۵ و مدل‌های تجمیعی مانند XGBoost^۶ و LightGBM^۷ برای تنظیم فرامترها، باعث کاهش معنادار خطاهای RMSE و MAPE می‌شود. این ترکیب با تنظیم خودکار وزن‌ها و تجمیع خروجی‌ها موجب پایداری و بهبود دقت پیش‌بینی می‌شود به گونه‌ای که در مطالعات تجربی، مدل‌های هیبرید بهینه‌سازی شده در مقایسه با CNN-LSTM پایه، انحراف معیار خطا را از ۱۳/۵۷۹۴ به ۱۱/۷۸۵۰ کاهش داده و آزمون‌های آماری Paired t-test و Wilcoxon با مقادیر p-value کمتر از ۰/۰۰۱، برتری معنادار آماری این بهبود عملکرد را تأیید کرده‌اند [۱۲ و ۲۹].

۳-۳-۶- بهینه‌سازی فرا ابتکاری

ترکیب LSTM^۳ برای یادگیری وابستگی‌های زمانی و XGBoost^۸ برای رگرسیون غیرخطی در افق‌های ساعتی و روزانه عملکرد پایداری از خود نشان داده است. رویکرد «تفکیک → یادگیرندگان موازی → ادغام وزنی» نسبت به مدل‌های منفرد دقت بالاتری داشته و از پایداری بیشتری در برابر تغییرات الگوهای زمانی و نوسانات داده‌های ورودی برخوردار است [۳۰].

۴-۳- انواع ورودی‌ها، افق پیش‌بینی و پیش‌پردازش‌های

مرسوم

ورودی‌ها: داده‌های محلی اندازه‌گیری شده مانند تابش لحظه‌ای و ولتاژ/جریان سیستم کنترل و داده‌های نظارت، داده‌های هواشناسی، تصاویر ماهواره‌ای/راداری و متغیرهای تقویمی (ساعت، روز سال) به‌عنوان ورودی‌های اصلی در مدل‌های پیش‌بینی توان فتوولتائیک استفاده می‌شوند. مطالعات نشان می‌دهند که ترکیب داده‌های

هواشناسی پیش‌بینی شده با ورودی‌های محلی اندازه‌گیری شده معمولاً بهترین نتایج را در پیش‌بینی‌های روزانه و چندروزه به همراه دارد [۳۱].

• افق‌ها:

کوتاه مدت: چند دقیقه تا چند ساعت—معمولاً برای کنترل لحظه‌ای و بازارها.

میان مدت: تا ۴۸-۷۲ ساعت—برنامه‌ریزی واحدها و مدیریت ذخیره‌سازی.

بلند مدت: هفته تا ماه—برنامه‌ریزی توسعه و نگهداری

• پیش‌پردازش داده‌ها و افق‌های پیش‌بینی

پاک‌سازی و پر کردن داده‌های گمشده، نرمال‌سازی/استانداردسازی، مهندسی ویژگی‌ها و ویژگی‌های تأخیری^۹، آمار متحرک^{۱۰}، خوشه‌بندی فصلی یا تقسیم داده‌ها بر اساس شرایط آب‌وهوایی، افزون بر این، برخی مطالعات از روش‌های افزایشی^{۱۱} یا خوشه‌بندی ایستگاه‌ها برای بهبود عمومی‌سازی استفاده کرده‌اند [۱۷].

پیش‌بینی‌های لحظه‌ای و فوق کوتاه مدت: مدل‌های مبتنی بر تصاویر آسمان مانند CNN-LSTM و دیگر مدل‌های مبتنی بر تصاویر به‌عنوان بهترین گزینه‌ها برای پیش‌بینی‌های لحظه‌ای و فوق کوتاه مدت شناخته شده‌اند. این مدل‌ها با استفاده از داده‌های تصویری و تحلیل ویژگی‌های زمانی، دقت بالایی در پیش‌بینی توان تولیدی انرژی خورشیدی در کوتاه‌ترین زمان‌ها دارند

• پیش‌پردازش داده و مهندسی ویژگی

پاک‌سازی و نرمال‌سازی داده‌ها: روش‌های ایمپوت مانند میانگین، درون‌یابی و مبتنی بر یادگیری برای درمان داده‌های گمشده ضروری است. استانداردسازی یا مقیاس‌بندی حداقل-حداکثر برای مدل‌های حساس به مقیاس مانند حافظه بلند مدت کوتاه مدت و ترنسفورمر توصیه می‌شود. ویژگی‌های زمانی مانند تأخیرهای چندگانه و آمارهای متحرک (میانگین/انحراف معیار) در بهبود پایداری مدل‌ها مؤثرند. استفاده از روش‌های تجزیه سیگنال مانند ICEEMDAN^{۱۲} و VMD^{۱۳} برای جداسازی روند، فصلیت و نویز خطا را کاهش می‌دهد.

^۸ Extreme Gradient Boosting

^۹ Lag Features

^{۱۰} Rolling Statistics

^{۱۱} Data Augmentation

^{۱۲} Integrated Complete Ensemble Empirical Mode Decomposition with Adaptive Noise

^{۱۳} Variational Mode Decomposition

^۱ Seasonal Arima

^۲ Autoregressive Integrated Moving Average (Arima)

^۳ Particle Swarm Optimization

^۴ Genetic Algorithm

^۵ Differential Evolution

^۶ Extreme Gradient Boosting

^۷ Light Gradient Boosting Machine

همچنین، انتخاب ویژگی و خوشه‌بندی وضعیت‌های آب‌وهوایی باعث بهبود همگرایی مدل‌ها می‌شود [۱۱ و ۳۲].

۳-۵- معیارهای ارزیابی و یافته‌های جمعی

پیش از انجام مقایسه‌های کمی عملکرد مدل‌ها بر اساس شاخص‌های خطا، لازم است به ویژگی‌های ساختاری، نقاط قوت و محدودیت‌های ذاتی مدل‌های یادگیری ماشین و یادگیری عمیق مورد بررسی اشاره شود. شبکه‌های حافظه کوتاه مدت-بلند مدت به دلیل توانایی در مدل‌سازی وابستگی‌های زمانی غیرخطی و یادگیری الگوهای پیچیده در داده‌های سری زمانی، در پیش‌بینی تولید انرژی الکتریکی سیستم‌های فتوولتائیک عملکرد قابل قبولی از خود نشان داده‌اند. با این حال، وابستگی این مدل‌ها به حجم کافی داده‌های تاریخی، حساسیت نسبت به تنظیم ابر پارامترها و کاهش پایداری در مواجهه با تغییر ناگهانی شرایط جوی از جمله محدودیت‌های اصلی آن‌ها به شمار می‌رود. مدل‌های ترکیبی نظیر CNN-LSTM با بهره‌گیری هم‌زمان از قابلیت استخراج ویژگی‌های مکانی و مدل‌سازی وابستگی‌های زمانی، به‌ویژه در پیش‌بینی‌های کوتاه مدت و مبتنی بر داده‌های تصویری یا چند منبعی، دقت بالاتری نسبت به مدل‌های منفرد ارائه می‌دهند. با این وجود، افزایش هزینه‌های محاسباتی، نیاز به داده‌های هم‌زمان و پیچیدگی پیاده‌سازی از چالش‌های عملی این معماری‌ها محسوب می‌شود. از سوی دیگر، مدل‌های مبتنی بر مکانیزم توجه و معماری‌های ترنسفورمر در افق‌های زمانی میان‌مدت و بلند مدت، به دلیل توانایی در شناسایی وابستگی‌های بلند مدت و الگوهای چند مقیاسی، پایداری بهتری از خود نشان داده‌اند؛ هرچند نیاز به داده‌های حجیم‌تر، تنظیمات پیچیده‌تر و هزینه محاسباتی بالاتر، استفاده عملی از آن‌ها را محدود می‌سازد. بر این اساس، تفسیر و مقایسه کمی خطاهای پیش‌بینی باید با در نظر گرفتن قابلیت‌ها و محدودیت‌های ذاتی هر معماری انجام گیرد.

برای ارزیابی مدل‌ها، شاخص‌هایی مانند MAE^1 ، $RMSE$ ، $MAPE$ و NSE استفاده می‌شود. مرور ۴۰ مقاله نشان می‌دهد که مدل‌های ترکیبی مانند CNN-LSTM، Attention-LSTM و مدل‌های LSTM همراه با بهینه‌سازی، دقت بالاتری نسبت به مدل‌های خالص LSTM و مدل‌های آماری ارائه می‌دهند [۳۳]. همچنین استفاده از داده‌های چند منبعی (ترکیب اندازه‌گیری‌های محلی، داده‌های هواشناسی و تصاویر ماهواره‌ای) دقت پیش‌بینی را

به‌ویژه در افق‌های میان‌مدت افزایش می‌دهد [۳۱]. مدل‌های ترنسفورمر و مکانیزم‌های توجه اخیراً عملکرد رقابتی یا برتر از LSTM نشان داده‌اند؛ هرچند هزینه محاسباتی و نیاز به داده‌های باکیفیت بالا از چالش‌های اصلی آن‌هاست [۳۴]. در نهایت، استفاده از مدل‌های تجزیه‌ای-ترکیبی مانند ترکیب $EEMD^2$ با استفاده از مدل‌های LSTM یا XGBoost، دقت و پایداری پیش‌بینی‌ها بهبود یافته است. در این روش، ابتدا داده‌ها به بخش‌های مختلف تقسیم می‌شوند و سپس پیش‌بینی‌ها به صورت جداگانه برای هر بخش انجام می‌شود. در نهایت، این فرایند منجر به نتایج دقیق‌تر می‌شود [۶].

۴- مرور مطالعات منتخب

در این مرور متمرکز، مجموعه‌ای از مطالعات جدید (تمرکز اصلی بر مقالات منتشرشده در سال‌های ۲۰۱۹ تا ۲۰۲۵) که به‌طور مستقیم به پیش‌بینی تولید انرژی خورشیدی با استفاده از شبکه‌های حافظه کوتاه مدت بلند مدت و مدل‌های ترکیبی مبتنی بر آن پرداخته‌اند، انتخاب و تحلیل شدند. معیارهای انتخاب شامل انتشار در ژورنال‌های همتا-بازبینی‌شده، گزارش کمی معیارهای ارزیابی (خطای معیار ریشه میانه مربعات، میانگین خطای مطلق، خطای درصدی میانگین مطلق، ضریب کارایی مدل)، استفاده از داده‌های واقعی سیستم کنترل و داده‌برداری از دستگاه‌های هوشمند، داده‌های پیش‌بینی عددی جو، تصاویر آسمان و ارائه جزئیات معماری و فرایامترها بوده است. این مجموعه به ما این امکان را می‌دهد که روندهای فنی، نقاط قوت هر خانواده مدل و شکاف‌های پژوهشی موجود در ادبیات را شناسایی کنیم (جدول ۱ و جدول ۲).


بررسی نتایج نشان می‌دهد که مدل‌های هم‌زمان تصویری-عددی مانند شبکه‌های عصبی کانولوشنی و حافظه کوتاه مدت بلند مدت، به‌ویژه در پیش‌بینی‌های فوق کوتاه مدت (≥ 60 دقیقه)، عملکرد برجسته‌ای دارند (مطالعات ۱، ۲) - خطای $RMSE$ و $MAPE$ به‌طور قابل ملاحظه‌ای کاهش یافته‌اند.

در افق‌های میان‌مدت تا بلند مدت (۲۴ ساعت)، مدل‌های مبتنی بر ترنسفورمر مانند Autoformer (ADAMS) یا ترکیبات چند وجهی^۳ (مطالعه ۳، ۵) عملکرد بهتری از حافظه کوتاه مدت بلند مدت ارائه کرده‌اند و پایداری بیشتری به‌ویژه در شرایط تغییرپذیر نشان دادند. از سوی دیگر، مدل‌های هیبرید با کاهش نویز یا تنظیم خودکار

³ Multi-faceted combinations

¹ Mean Absolute Error

² Ensemble Empirical Mode Decomposition



شکل ۲: نمودار تیلور و باکس-پلات خطا برای مقایسه مدل‌های CNN-

LSTM, SVR, CFBP و FFBP؛ برتری قابل توجه CNN-LSTM در

نزدیک‌تر بودن خطا به صفر و پراکندگی کمتر [۱۹]

(مطالعات ۶، ۷) در میدان واقعی قابل اعتماد بوده‌اند. در نهایت، استفاده از داده‌های چند منبعی^۱ - مانند تلفیق پیش‌بینی عددی وضعیت جو با داده‌های محلی یا تصاویر - باعث تقویت قدرت تعمیم مدل‌ها شده است (شکل ۲).

جدول ۱: مقایسه مدل‌های یادگیری عمیق در پیش‌بینی تولید توان خورشیدی

مدل پیشنهادی	داده‌ها و ورودی‌ها و افق زمانی	یافته‌ها
CNN - LSTM [19]	سری زمانی تابش/هواشناسی محلی (کوتاه مدت)	برتری معنادار $RMSE = 0.0833$, $MAPE = 1.18\%$ بهترین کارایی بین رقبا؛ همبستگی $0.74 \sim$ بین پیش‌بینی و واقعی؛ بهبود نسبت به روش‌های مرجع با بهره‌گیری از ویژگی‌های مکانی-زمانی تصاویر. در ۲۴ ساعت آینده $RMSE = 0.302$, $MAE = 0.28$, $RMSE = 0.529$
CNN - LSTM (با تصاویر آسمان) [۳۵]	تصاویر آسمان + خروجی PV (۱۰-۳۰ دقیقه‌ای)	LSTM/GRU/Transformer برتری پایدار نسبت به مدل‌های چارچوب چندوجهی بر پایه Transformer؛ برتری نسبت به persistence و مدل‌های تک‌وجهی در پیش‌بینی GHI.
Autoformer (ADAMS) [27]	داده عملیاتی PV + ویژگی‌های هواشناسی (۲۴ ساعته)	تقویت داده زمانی + فشرده‌سازی کانالی $\rightarrow$ کاهش معنی‌دار خطای دو دیتاست عمومی نسبت به خطوط پای.
Transformer چند وجهی با تصاویر آسمان [۴]	توالی تصاویر آسمان + داده تابش (فوق کوتاه مدت)	در ترکیب‌های RNN، Bi-LSTM، کم‌ترین خطا را نشان داد تأکید بر اهمیت انتخاب ورودی و تنظیم ابرپارامتر
شبکه کانولوشنی ویژگی‌های زمانی چند منبع (MSTFCN) [36]	روزانه PV داده + NWP	حذف نویز با VMD و استخراج مکانی-زمانی $\rightarrow$ پیشی گرفتن از VMD-LSTM و VMD-CNN در تمام افق‌های کوتاه مدت
ترکیبات LSTM / Bi-LSTM / GRU [37]	سری زمانی + PV هواشناسی (۱۵-۶۰ دقیقه‌ای)	انتخاب ویژگی خودکار + هیبرید CNN-SLSTM $\rightarrow$ بهبود دقت روزانه تابش جهانی نسبت به مدل‌های پایه
VMD + CNN - LSTM (ترکیبی) [۳۸]	خروجی مزرعه + PV (SCADA) هواشناسی (۱۵/۳۰/۶۰ دقیقه‌ای)	
CNN - SLSTM (هیبرید) [۱۵]	پارامترهای هواشناسی + تابش (روزانه)	

¹ Multi-source data

جدول ۲: مقایسه کیفی، مزایا و معایب مدل‌ها

مدل	مزایا	معایب
LSTM	مدل‌سازی وابستگی‌های بلند مدت سری زمانی؛ اجرای نسبتاً ساده؛ پایه خوبی برای هیبریدها	نیاز به داده کافی و تنظیم ابرپارامتر؛ حساسیت به تغییر رژیم و چند وجهی نبودن
CNN – LSTM	استخراج مکانی + زمانی (مثلاً تصاویر آسمان/ابر) → جهش محسوس در افق‌های کوتاه؛ در مواردی $MAPE \approx 1-3\%$ گزارش شده	محاسبات سنگین‌تر (GPU)، حساسیت به کیفیت تصویر/کالیبراسیون دوربین؛ نیاز به هم‌زمان‌سازی دقیق داده تصویری و عددی.
Attention – LSTM / Transformer	وزن‌دهی پویا به گام‌های زمانی/کانال‌ها؛ مناسب داده‌های پر نوسان؛ در افق‌های بلندتر پایداری بهتر از RNN کلاسیک.	نیاز به داده حجیم‌تر و هزینه محاسباتی بالاتر؛ خطر بیش برازش در دیتاست‌های کوچک
/Autoformer واریانت‌های آن	طراحی شده برای روندهای فصلی/چند مقیاسی؛ در پیش‌بینی ۲۴ ساعته PV نتایج رقابتی/برتر نسبت به LSTM/GRU.	پیاده‌سازی پیچیده‌تر، حساسیت به تنظیمات چند مقیاسی و داستیشناری
LSTM + بهینه‌سازی (VMD/EO/PSO ...)	کاهش نویز و تنظیم خودکار؛ بهبود RMSE/MAE در افق‌های ۱۵–۶۰ دقیقه؛ پایداری بیشتر	پیچیدگی زنجیره پردازش، هزینه تنظیم و خطر بیش برازش اگر اعتبارسنجی سخت و سخت نباشد.

۴-۱- مقایسه‌ها، مرورهای تحلیلی و ارزیابی‌های مقایسه‌ای

چندین مرور و ارزیابی مقایسه‌ای جدید که روش‌های یادگیری عمیق را برای پیش‌بینی توان فتوولتائیک تحلیل کرده‌اند، به‌طور سیستماتیک نشان داده‌اند که:

۱. انتخاب ویژگی و مهندسی ورودی تأثیر زیادی بر نتایج مدل‌ها دارد. این امر به‌ویژه بر دقت پیش‌بینی‌ها و کارایی الگوریتم‌های یادگیری عمیق تأثیرگذار است.
۲. ترکیب داده‌های پیش‌بینی وضعیت آب و هوا، اندازه‌گیری‌های محلی و داده‌های تصویری معمولاً باعث افزایش دقت مدل‌ها می‌شود. این ادغام، اطلاعات بیشتری درباره شرایط محیطی و وضعیت آب و هوا فراهم می‌کند که به مدل کمک می‌کند تا پیش‌بینی‌های دقیق‌تری ارائه دهد.

۳. استانداردسازی معیارهای گزارش‌دهی (مانند گزارش همه معیارها همراه با انحراف معیار یا بازه اطمینان) هنوز در ادبیات تحقیقاتی ضعیف است. این مسئله باعث می‌شود که مقایسه مستقیم نتایج مختلف مطالعات دشوار باشد و نیاز به یک رویکرد منسجم برای گزارش‌دهی دقیق‌تر وجود دارد.

این نکات در تحلیل‌های جدید، به‌ویژه در پیش‌بینی توان فتوولتائیک با استفاده از روش‌های یادگیری عمیق، به‌طور بارزی برجسته شده‌اند [۱۵ و ۱۷].

مرور مطالعات منتخب نشان می‌دهد که نوع معماری مدل و ویژگی داده‌های ورودی تأثیر مستقیمی بر دقت پیش‌بینی توان تولیدی سیستم‌های فتوولتائیک دارند. مدل‌های LSTM در پیش‌بینی‌های فوق‌کوتاه مدت (کمتر از ۶ ساعت) عملکرد قابل‌قبولی داشته‌اند، اما در شرایط آب‌وهوایی ناپایدار دقت کمتری از خود نشان می‌دهند. مدل‌های ترکیبی CNN-LSTM با بهره‌گیری از استخراج هم‌زمان ویژگی‌های مکانی و زمانی، بهترین نتایج را در بازه‌های کوتاه مدت ارائه داده‌اند، هرچند که نیازمند داده‌های تصویری و توان محاسباتی بالاتری هستند. از سوی دیگر، مدل‌های مبتنی بر Transformer و Autoformer در پیش‌بینی‌های میان‌مدت (۲۴ تا ۷۲ ساعت) دقت بیشتری دارند و برای داده‌های پیچیده و روندهای چند مقیاسی مناسب‌تر هستند.

استفاده از داده‌های چند منبعی شامل تصاویر ماهواره‌ای، اندازه‌گیری‌های محلی و پیش‌بینی‌های عددی هواشناسی در کنار مدل‌های Ensemble، دقت و پایداری پیش‌بینی را به‌طور چشمگیری افزایش داده است. با این حال، خطر بیش برازش و نیاز به اعتبارسنجی بیرونی همچنان از چالش‌های اصلی محسوب می‌شود.

در مسیرهای آینده تحقیق، تمرکز بر سه محور کلیدی ضروری است:

- ایجاد دیتاست‌های جامع و باز برای مقایسه منصفانه مدل‌ها در مقیاس‌های زمانی مختلف.
- به‌کارگیری یادگیری انتقالی (Transfer Learning) جهت کاهش وابستگی به داده‌های حجیم و بهبود عملکرد در محیط‌های کم داده.
- توسعه مدل‌های سبک و کم‌هزینه برای پیاده‌سازی عملی در نیروگاه‌های خورشیدی و کاربردهای صنعتی.
- همچنین، ادغام یادگیری عمیق با اینترنت اشیا (IoT) و بهره‌گیری از داده‌های بلادرنگ می‌تواند دقت پیش‌بینی و پایداری سیستم‌های انرژی خورشیدی را به‌ویژه در شرایط بحرانی بهبود دهد.

در مجموع، می‌توان گفت که امروزه نقش ابزارها و تکنیک‌های نوین مبتنی بر هوش مصنوعی در توسعه سیستم‌های انرژی، به‌ویژه انرژی‌های تجدیدپذیر، به‌طور فزاینده‌ای در حال افزایش است. مدل‌ها و روش‌های مطرح‌شده در این مطالعه به‌منظور بهینه‌سازی و پیش‌بینی، کاربردهای مختلف دیگری نیز دارند؛ از جمله بهبود راندمان سیستم‌های تولید برق توربینی، توسعه سیستم‌های انرژی مدرن با استفاده از یادگیری ماشین و دیگر تکنیک‌ها [۳۹ و ۴۰] توجه به جنبه‌های مختلف توسعه سیستم‌های انرژی، به‌ویژه در حوزه تجدیدپذیرهای خورشیدی، می‌تواند در تسریع پیشرفت این حوزه نقش بسزایی ایفا کند.

۵- نتیجه‌گیری

این پژوهش با هدف مرور نظام‌مند و تحلیل جامع ۴۰ مطالعه منتخب در بازه زمانی ۲۰۱۹ تا ۲۰۲۵، به بررسی و مقایسه عملکرد مدل‌های یادگیری عمیق و معماری‌های ترکیبی در پیش‌بینی تولید انرژی خورشیدی پرداخته است. یافته‌های این مطالعه نشان می‌دهد که:

۱. مدل‌های ترکیبی، به‌ویژه CNN-LSTM و CNN-LSTM-Transformer، در بهره‌گیری هم‌زمان از ویژگی‌های مکانی-زمانی عملکردی بهینه داشته و در مقایسه با مدل‌های منفرد و کلاسیک، به‌طور متوسط موجب کاهش خطا تا حدود ۳۰٪ شده‌اند.
۲. در پیش‌بینی‌های کوتاه مدت، مدل‌های CNN-LSTM بهترین کارایی را نشان داده‌اند؛ به‌گونه‌ای که در برخی

مطالعات، مقادیر MAPE کمتر از ۳٪ و RMSE زیر ۰/۰۹٪ گزارش شده است که نشان‌دهنده پایداری مدل در شرایط آب و هوایی متغیر است.

۳. در افق‌های میان‌مدت و بلند مدت، مدل‌های مبتنی بر Transformer و به‌ویژه Autoformer با بهره‌گیری از مکانیزم توجه چند مقیاسی، دقت پیش‌بینی را تا ۲۵٪ بهبود داده‌اند و در سناریوهای پیچیده و فصلی عملکردی قابل‌اعتمادتر از LSTM خالص داشته‌اند.

۴. استفاده از داده‌های چند منبعی شامل تصاویر ماهواره‌ای، داده‌های محلی و پیش‌بینی‌های عددی وضعیت جوی موجب بهبود دقت پیش‌بینی تا ۳۰٪ و افزایش قابلیت تعمیم‌پذیری مدل‌ها در شرایط آب و هوایی ناپایدار شده است.

۵. تلفیق مدل‌های یادگیری عمیق با الگوریتم‌های فرا ابتکاری و رویکردهای Ensemble، ضمن کاهش خطاهای MAPE و RMSE، منجر به افزایش پایداری و استحکام مدل‌ها شده است؛ هرچند این امر با افزایش هزینه محاسباتی و خطر بیش‌برازش همراه است.

در جمع‌بندی می‌توان نتیجه گرفت که مدل‌های یادگیری عمیق و معماری‌های ترکیبی، نه تنها دقت و پایداری پیش‌بینی تولید انرژی خورشیدی را به‌طور چشمگیری بهبود می‌بخشند، بلکه زمینه‌ساز توسعه سیستم‌های مدیریت هوشمند انرژی و زیرساخت‌های پایدار در مقیاس صنعتی خواهند بود. با این حال، ضرورت استانداردسازی پایگاه‌های داده، طراحی معیارهای ارزیابی یکپارچه و توسعه مدل‌های سبک‌تر و کم‌هزینه‌تر برای کاربردهای عملی، همچنان به‌عنوان اولویت‌های اصلی تحقیقات آینده مطرح است.

۶- منابع

- [1] N. L. M. Jailani et al., "Investigating the power of LSTM-based models in solar energy forecasting," *Processes*, Vol. 11, No. 5, Art. no. 1382, 2023, DOI: [10.3390/pr11051382](https://doi.org/10.3390/pr11051382).
- [2] M. S. Ibrahim, S. M. Gharghory, and H. A. Kamal, "A hybrid model of CNN and LSTM autoencoder-based short-term PV power generation forecasting," *Electrical Engineering*, Vol. 106, No. 4, pp. 4239–4255, 2024, DOI: [10.1007/s00202-023-02220-8](https://doi.org/10.1007/s00202-023-02220-8).

- [11] E. M. Al-Ali et al., "Solar energy production forecasting based on a hybrid CNN-LSTM-transformer model," *Mathematics*, Vol. 11, No. 3, Art. no. 676, 2023, DOI: [10.3390/math11030676](https://doi.org/10.3390/math11030676).
- [12] D. Salman, C. Direkoglu, M. Kusaf, and M. Fahrioglu, "Hybrid deep learning models for time series forecasting of solar power," *Neural Computing and Applications*, Vol. 36, No. 16, pp. 9095–9112, 2024, DOI: [10.1007/s00521-024-09558-5](https://doi.org/10.1007/s00521-024-09558-5).
- [13] V. Esen, B. Coban, B. Y. Kavus, T. K. Karaca, T. Dindar, and A. S. Sarkin, "An interpretable statistical approach to photovoltaic power forecasting using factor analysis and ridge regression," *Scientific Reports*, Vol. 15, No. 1, Art. no. 38947, 2025, DOI: [10.1038/s41598-025-22838-x](https://doi.org/10.1038/s41598-025-22838-x).
- [14] M. C. Krstevska, P. Krstevski, M. Srbinovska, V. Andova, and A. K. Mateska, "Smart forecasting: Enhancing virtual power plant performance with analytical frameworks," *e-Prime—Advances in Electrical Engineering, Electronics and Energy*, Vol. 12, Art. no. 101003, 2025, DOI: [10.1016/j.prime.2025.101003](https://doi.org/10.1016/j.prime.2025.101003).
- [15] M. Husein, E. J. Gago, B. Hasan, and M. C. Pegalajar, "Towards energy efficiency: A comprehensive review of deep learning-based photovoltaic power forecasting strategies," *Heliyon*, Vol. 10, No. 13, Art. no. e33419, 2024, DOI: [10.1016/j.heliyon.2024.e33419](https://doi.org/10.1016/j.heliyon.2024.e33419).
- [16] S.-C. Lim, J.-H. Huh, S.-H. Hong, C.-Y. Park, and J.-C. Kim, "Solar power forecasting using CNN-LSTM hybrid model," *Energies*, Vol. 15, No. 21, Art. no. 8233, 2022, DOI: [10.3390/en15218233](https://doi.org/10.3390/en15218233).
- [17] J. Yu et al., "Deep learning models for PV power forecasting: Review," *Energies*, Vol. 17, No. 16, Art. no. 3973, 2024, DOI: [10.3390/en17163973](https://doi.org/10.3390/en17163973).
- [18] L. Cao, H. Yang, C. Zhou, S. Wang, Y. Shen, and B. Yuan, "Photovoltaic short-term output power forecast model based on improved complete ensemble empirical mode decomposition with adaptive noise-kernel principal component analysis-long short-term memory," *Energies*, Vol. 17, No. 24, Art. no. 6365, 2024, DOI: [10.3390/en17246365](https://doi.org/10.3390/en17246365).
- [3] N. Zhou, B. Shang, M. Xu, L. Peng, and G. Feng, "Enhancing photovoltaic power prediction using a CNN-LSTM-attention hybrid model with Bayesian hyperparameter optimization," *Global Energy Interconnection*, Vol. 7, No. 5, pp. 667–681, 2024, DOI: [10.1016/j.gloi.2024.10.005](https://doi.org/10.1016/j.gloi.2024.10.005).
- [4] J. Liu, H. Zang, L. Cheng, T. Ding, Z. Wei, and G. Sun, "A transformer-based multimodal-learning framework using sky images for ultra-short-term solar irradiance forecasting," *Applied Energy*, Vol. 342, Art. no. 121160, 2023, DOI: [10.1016/j.apenergy.2023.121160](https://doi.org/10.1016/j.apenergy.2023.121160).
- [5] Y. Yu, J. Cao, and J. Zhu, "An LSTM short-term solar irradiance forecasting under complicated weather conditions," *IEEE Access*, Vol. 7, pp. 145651–145666, 2019, DOI: [10.1109/ACCESS.2019.2946057](https://doi.org/10.1109/ACCESS.2019.2946057).
- [6] Q. Qiu et al., "DTCformer: A temporal convolution-enhanced Autoformer with DILATE loss for photovoltaic power forecasting," *Energies*, Vol. 18, No. 10, Art. no. 2450, 2025, DOI: [10.3390/en18102450](https://doi.org/10.3390/en18102450).
- [7] S. Xu, R. Zhang, H. Ma, C. Ekanayake, and Y. Cui, "On vision transformer for ultra-short-term forecasting of photovoltaic generation using sky images," *Solar Energy*, Vol. 267, Art. no. 112203, 2024, DOI: [10.1016/j.solener.2023.112203](https://doi.org/10.1016/j.solener.2023.112203).
- [8] E. Kim and Y. S. Hau, "Advancing photovoltaic solar power forecasting by the hybrid model of CNN and DNN and the XAI with SHAP," *International Journal of Green Energy*, pp. 1–12, 2025, DOI: [10.1080/15435075.2025.2553864](https://doi.org/10.1080/15435075.2025.2553864).
- [9] A. Agga, A. Abbou, M. Labbadi, Y. El Houm, and I. H. O. Ali, "CNN-LSTM: An efficient hybrid deep learning architecture for predicting short-term photovoltaic power production," *Electric Power Systems Research*, Vol. 208, Art. no. 107908, 2022, DOI: [10.1016/j.epsr.2022.107908](https://doi.org/10.1016/j.epsr.2022.107908).
- [10] G. Wu, Y. Wang, Q. Zhou, and Z. Zhang, "Enhanced photovoltaic power forecasting: An iTransformer and LSTM-based model integrating temporal and covariate interactions," in *2024 IEEE 8th Conference on Energy Internet and Energy System Integration (EI2)*, 2024, pp. 856–861, DOI: [10.1109/EI264398.2024.10990816](https://doi.org/10.1109/EI264398.2024.10990816).

- model,” *Symmetry*, Vol. 15, No. 1, Art. no. 238, 2023, DOI: [10.3390/sym15010238](https://doi.org/10.3390/sym15010238).
- [28] M. Awais et al., “Short-term photovoltaic energy generation for solar powered high efficiency irrigation systems using LSTM with spatio-temporal attention mechanism,” *Scientific Reports*, Vol. 14, No. 1, Art. no. 10042, 2024, DOI: [10.1038/s41598-024-60672-9](https://doi.org/10.1038/s41598-024-60672-9).
- [29] İ. F. Şener and İ. Tuğal, “Optimized CNN-LSTM with hybrid metaheuristic approaches for solar radiation forecasting,” *Case Studies in Thermal Engineering*, Vol. 72, Art. no. 106356, 2025, DOI: [10.1016/j.csite.2025.106356](https://doi.org/10.1016/j.csite.2025.106356).
- [30] M. A. Atiea, A. A. Abdelghaffar, H. B. Aribia, F. Nouredine, and A. M. Shaheen, “Photovoltaic power generation forecasting with Bayesian optimization and stacked ensemble learning,” *Results in Engineering*, Vol. 26, Art. no. 104950, 2025, DOI: [10.1016/j.rineng.2025.104950](https://doi.org/10.1016/j.rineng.2025.104950).
- [31] W.-C. Tsai, C.-S. Tu, C.-M. Hong, and W.-M. Lin, “A review of state-of-the-art and short-term forecasting models for solar PV power generation,” *Energies*, Vol. 16, No. 14, Art. no. 5436, 2023, DOI: [10.3390/en16145436](https://doi.org/10.3390/en16145436).
- [32] M. Shafiuzzaman et al., “Enhanced very short-term load forecasting with multi-lag feature engineering and prophet-XGBoost-CatBoost architecture,” *Energy*, Vol. 335, Art. no. 137981, 2025, DOI: [10.1016/j.energy.2025.137981](https://doi.org/10.1016/j.energy.2025.137981).
- [33] C. Tian, J. Ma, C. Zhang, and P. Zhan, “A deep neural network model for short-term load forecast based on long short-term memory network and convolutional neural network,” *Energies*, Vol. 11, No. 12, Art. no. 3493, 2018, DOI: [10.3390/en11123493](https://doi.org/10.3390/en11123493).
- [34] B. Lim, S. Ö. Arik, N. Loeff, and T. Pfister, “Temporal fusion transformers for interpretable multi-horizon time series forecasting,” *International Journal of Forecasting*, Vol. 37, No. 4, pp. 1748–1764, 2021, DOI: [10.1016/j.ijforecast.2021.03.012](https://doi.org/10.1016/j.ijforecast.2021.03.012).
- [35] A. Jakoplić, D. Franković, J. Havelka, and H. Bulat, “Short-term photovoltaic power plant output forecasting using sky images and deep learning,” [19] B. Ladjal et al., “Hybrid deep learning CNN-LSTM model for forecasting direct normal irradiance: A study on solar potential in Ghardaia, Algeria,” *Scientific Reports*, Vol. 15, No. 1, Art. no. 15404, 2025, DOI: [10.1038/s41598-025-94239-z](https://doi.org/10.1038/s41598-025-94239-z).
- [20] J. Wu, Y. Zhao, R. Zhang, X. Li, and Y. Wu, “Application of three Transformer neural networks for short-term photovoltaic power prediction: A case study,” *Solar Compass*, Vol. 12, Art. no. 100089, 2024, DOI: [10.1016/j.solcom.2024.100089](https://doi.org/10.1016/j.solcom.2024.100089).
- [21] G. Wu, D. Hu, Y. Zhang, G. Bao, and T. He, “A convolutional neural network–long short-term memory–attention solar photovoltaic power prediction–correction model based on the division of twenty-four solar terms,” *Energies*, Vol. 17, No. 22, Art. no. 5549, 2024, DOI: [10.3390/en17225549](https://doi.org/10.3390/en17225549).
- [22] C. Pan, Y. Liu, Y. Oh, and C. Lim, “Short-term photovoltaic power forecasting using PV data and sky images in an auto cross modal correlation attention multimodal framework,” *Energies*, Vol. 17, No. 24, Art. no. 6378, 2024, DOI: [10.3390/en17246378](https://doi.org/10.3390/en17246378).
- [23] C. Corsi, M. J. Blanco, V. Grigoriev, and J. Pye, “Upper limits to the mean annual optical efficiency of solar mono-tower systems,” *Solar Energy*, Vol. 236, pp. 88–99, 2022, DOI: [10.1016/j.solener.2022.02.038](https://doi.org/10.1016/j.solener.2022.02.038).
- [24] R. Ding et al., “Application of machine learning in optimizing proton exchange membrane fuel cells: A review,” *Energy and AI*, Vol. 9, Art. no. 100170, 2022, DOI: [10.1016/j.egyai.2022.100170](https://doi.org/10.1016/j.egyai.2022.100170).
- [25] T. Zhu, Y. Guo, Z. Li, and C. Wang, “Solar radiation prediction based on convolution neural network and long short-term memory,” *Energies*, Vol. 14, No. 24, Art. no. 8498, 2021, DOI: [10.3390/en14248498](https://doi.org/10.3390/en14248498).
- [26] G. Piantadosi, S. Dutto, A. Galli, S. De Vito, C. Sansone, and G. Di Francia, “Photovoltaic power forecasting: A Transformer based framework,” *Energy and AI*, Vol. 18, Art. no. 100444, 2024, DOI: [10.1016/j.egyai.2024.100444](https://doi.org/10.1016/j.egyai.2024.100444).
- [27] Y. Huang and Y. Wu, “Short-term photovoltaic power forecasting based on a novel Autoformer

solar irradiance using CNN SLSTM architecture,” *Scientific Reports*, Vol. 15, No. 1, Art. no. 10761, 2025, DOI: [10.1038/s41598-025-95118-3](https://doi.org/10.1038/s41598-025-95118-3).

[39] A. Naziri, A. R. Tahavvor, M. A. Shirazi, and R. Zahedi, “Feasibility study on heat recovery from gas turbine exhaust for absorption chiller operation and efficiency enhancement using neural networks,” *Thermal Science and Engineering Progress*, Vol. 67, Art. no. 104210, 2025, DOI: [10.1016/j.tsep.2025.104210](https://doi.org/10.1016/j.tsep.2025.104210). (in Persian)

[40] A. Saifoddin, N. Mirzaei, M. Allahrabbi Shirazi, and H. Yousefi, “Comparative applications of supervised and unsupervised machine learning models in energy systems,” *Journal of Energy Management and Technology*, Vol. 9, No. 4, pp. 284–290, 2025, DOI: [10.22109/jemt.2025.547118.1573](https://doi.org/10.22109/jemt.2025.547118.1573). (in Persian)

Energies, Vol. 16, No. 14, Art. no. 5428, 2023, DOI: [10.3390/en16145428](https://doi.org/10.3390/en16145428).

[36] A. Zameer, F. Jaffar, F. Shahid, M. Muneeb, R. Khan, and R. Nasir, “Short-term solar energy forecasting: Integrated computational intelligence of LSTMs and GRU,” *PLOS ONE*, Vol. 18, No. 10, Art. no. e0285410, 2023, DOI: [10.1371/journal.pone.0285410](https://doi.org/10.1371/journal.pone.0285410).

[37] L. N. Boucetta, Y. Amrane, A. Chouder, S. Arezki, and S. Kichou, “Enhanced forecasting accuracy of a grid-connected photovoltaic power plant: A novel approach using hybrid variational mode decomposition and a CNN-LSTM model,” *Energies*, Vol. 17, No. 7, Art. no. 1781, 2024, DOI: [10.3390/en17071781](https://doi.org/10.3390/en17071781).

[38] Y. Mariappan, K. Ramasamy, and D. Velusamy, “An optimized deep learning based hybrid model for prediction of daily average global