



The University of Tehran Press

Modeling and forecasting of electricity energy consumption using an optimized Stacking ensemble machine learning model based on particle swarm optimization

Amir Bahrami Yajloo¹ | Amir Mohammad Haddadi² | Erfan Abbasian Hamedani³ |
Mohammad Hossein Nozari⁴ | Mohammad Hadi Eslamian⁵ | Kianoosh Choubineh^{6*}

1. PhD Candidate, Department of Energy Conversion, Faculty of 1 M.Sc. Student in Energy Systems Engineering, Department of Energy Engineering and Physics, Amirkabir University of Technology, Tehran, Iran. Email: amirbahramiyajloo@aut.ac.ir

2. Master of Business Administration, Department of Management and Accounting, Allameh Tabataba'i University, Tehran, Iran. Email: mohammad.haddadi@alumni.kntu.ac.ir

3. PhD Candidate, Department of Energy Conversion, Faculty of 1 M.Sc. Student in Energy Systems Engineering, Department of Energy Engineering and Physics, Amirkabir University of Technology, Tehran, Iran. Email: erfan.abbasian@aut.ac.ir

4. PhD in Mechanical Engineering, School of Mechanical Engineering, Shiraz University, Shiraz, Iran. Email: mhnozari@gmail.com

5. PhD Candidate, Department of Energy Conversion, Faculty of 1 M.Sc. Student in Energy Systems Engineering, Department of Energy Engineering and Physics, Amirkabir University of Technology, Tehran, Iran. Email: hadi.eslamian@aut.ac.ir

6. Corresponding Author, Assistant Professor, Department of Renewable Energy Engineering, Faculty of Energy Engineering, Shahid Beheshti University, Tehran, Iran. Email: k_choubineh@sbu.ac.ir

ARTICLE INFO

Article type:
Research Paper

Article History:

Received: 31 January 2026

Revised: 13 March 2026

Accepted: 11 April 2026

Published Online: 22 June 2026

Keywords:

Ensemble model,
Particle swarm optimization,
Machine learning,
Forecasting,
Electricity energy consumption.

ABSTRACT

In this study, a data-driven framework is developed to model and forecast electricity energy consumption (EEC) in countries with diverse economic, social, and climate characteristics. Five input variables including population (POP), gross domestic product (GDP), energy imports (IMP), energy exports (EXP), and annual average air temperature (TEMP) are used to model EEC. Annual data from 1991 to 2020 are employed for training and evaluation. Four machine learning algorithms, namely ANN, Ridge, Stack, and Stack-PSO, are implemented and assessed using MSE, MAE, R2, and MAPE. The results show that while the standalone ANN and Ridge models achieve acceptable accuracy, they exhibit lower stability and weaker generalization compared with ensemble-based approaches. The Stack model, constructed by combining the outputs of ANN and Ridge, yields noticeable improvements across the error metrics. The results demonstrated that the Stack-PSO model consistently outperformed the other models across the majority of cases. The R2 values for this model ranged from 0.974 to 0.997 across the surveyed countries. The lowest MSE was recorded for China at 0.00015, while for Iran, the Stack-PSO model achieved an MSE of 0.00042 and an R2 of 0.996. Furthermore, the lowest MAPE was observed in the United States at 2.5%, underscoring the high precision of the proposed model in minimizing forecasting errors. Subsequently, the superior model was employed to forecast electrical energy consumption up to the 2035 horizon. The findings indicate a generally increasing consumption trend in most countries; however, growth intensity varied significantly, with some cases exhibiting a moderate growth pattern or approaching relative stability.

Cite this article: Bahrami Yajloo, A.; Haddadi, A. M.; Abbasian Hamedani, E.; Nozari, M. H.; Eslamian, M. H. & Choubineh, K. (2026). Modeling and forecasting of electricity energy consumption using an optimized Stacking ensemble machine learning model based on particle swarm optimization. *Journal of Sustainable Energy Systems*, 5 (3), 579-600. DOI: <http://doi.org/10.22059/ses.2026.412276.1222>



© Amir Bahrami Yajloo, Amir Mohammad Haddadi, Erfan Abbasian Hamedani, Mohammad Hossein Nozari, Mohammad Hadi Eslamian, Kianoosh Choubineh

Publisher: University of Tehran Press.

DOI: <http://doi.org/10.22059/ses.2026.412276.1222>

1. Introduction

The rapid growth in electricity energy consumption over the past few decades, driven by economic development, population growth, urban expansion, and structural changes in demand patterns, has become one of the major challenges for energy planning at both national and international levels. Since annual electricity consumption reflects the level of economic and social activity, as well as climatic conditions, in each country, accurate forecasting plays a critical role in macro-level decision-making, power-sector infrastructure development, and long-term energy policy formulation. Given the nonlinear and multidimensional relationships between economic, demographic, commercial, and climatic variables and electricity consumption, data-driven frameworks and machine learning approaches have increasingly been considered effective tools for modeling these complexities.

In this study, with the aim of improving the accuracy of electricity energy consumption (EEC) forecasting in selected countries, an ensemble-based machine learning framework is proposed that examines the simultaneous effects of economic, demographic, commercial, and climatic drivers. The performance of standalone models is compared with that of an optimized stacking model enhanced by particle swarm optimization, and its ability to reduce prediction errors and improve explanatory power is evaluated. Furthermore, using the superior model, electricity energy consumption is projected to 2035 to provide an analytical basis for long-term energy planning and policy-making.

2. Proposed Model

The In this study, an ensemble-based machine learning framework is developed to forecast EEC in selected countries. As illustrated in Fig. 1, the proposed architecture comprises several main stages: data preprocessing, training base learners, meta-model construction, hyperparameter optimization, and final prediction generation. Five input variables-population (POP), gross domestic product (GDP), energy imports (IMP), energy exports (EXP), and annual average temperature (TEMP) are considered as explanatory features, while electricity energy consumption is defined as the target variable. To eliminate scale differences among variables, the data are standardized before model training.

At the first level of the stacking structure, two base models, namely an artificial neural network and ridge regression, are trained independently to capture nonlinear and linear patterns embedded in the data. The outputs of these base learners are then used as inputs to a second-level meta-learner, implemented through a regression model, which combines the predictions in a data-driven manner. To enhance predictive accuracy and minimize forecasting errors, particle swarm optimization is employed to tune the hyperparameters of the base models, with MSE defined as the primary objective function. Furthermore, to project future input variables within the forecasting horizon, a NARX model is used, and the standardized outputs are fed into the trained ensemble model. By integrating heterogeneous learners and metaheuristic optimization, a coherent and robust framework for electricity energy consumption forecasting is established.




Fig. 1. Proposed model framework for electricity energy consumption forecasting.

3. Results

The test-phase performance of the Stack-PSO model is illustrated in Fig. 2. The blue curve depicts the actual EEC, whereas the red curve shows the model forecasts over the test period. As shown, close agreement is observed between the observed and forecasted values across all investigated countries,

indicating that the proposed model has a strong capability to reproduce previously unseen data. The limited deviation between the two curves, particularly for China, Turkey, and Iran, suggests that the underlying growth patterns are captured with high fidelity. Overall, the visual comparison corroborates the quantitative evaluation, demonstrating that the optimized ensemble framework not only improves error-based metrics but also provides coherent and accurate estimates of electricity energy consumption.




Fig. 2. Comparison of Actual and Forecasted Values over the Test Period Using the Stack-PSO Model.

4. Discussion and Conclusion

Overall, the results indicated that although the ANN and Ridge models achieved acceptable performance in many cases and reported R^2 values above 0.95, they showed limitations when confronted with more complex relationships and cross-country heterogeneity. The stack model, by combining the outputs of the base learners, enabled simultaneous reductions in MSE and MAE and improved forecast stability. However, the best performance was achieved with the Stack-PSO model, which integrated a stacking framework with particle swarm optimization for hyperparameter tuning; as a result, the lowest MSE values and R^2 values close to 0.99 were obtained in most cases. These findings suggest that coupling ensemble learning with metaheuristic optimization can extract nonlinear relationships among the influential drivers with higher accuracy while maintaining appropriate sensitivity to the dominant predictors. Overall, the proposed approach provides a flexible framework for forecasting electricity energy consumption and may serve as a supportive tool for long-term planning and policy-making in the power sector.



انتشارات دانشگاه تهران

فصلنامه سیستم‌های انرژی پایدار

سایت نشریه: <https://ses.ut.ac.ir>

شاپا الکترونیکی: ۸۶۹۳-۲۹۸۰

مدل‌سازی و پیش‌بینی مصرف انرژی الکتریکی با استفاده از مدل یادگیری ماشین تجمیعی استکینگ بهینه‌شده مبتنی بر الگوریتم بهینه‌سازی ازدحام ذرات

امیر بهرامی یاجلو^۱ | امیرمحمد حدادی^۲ | عرفان عباسیان همدانی^۳ | محمدحسین نوذری^۴ | محمدهادی اسلامیان^۵ | کیانوش چوبینه^{۶*}

۱. دانشجوی کارشناسی ارشد مهندسی سیستم‌های انرژی، دانشکده مهندسی انرژی و فیزیک، دانشگاه صنعتی امیرکبیر، تهران، ایران. رایانامه: amirbahramiyajloo@aut.ac.ir
۲. کارشناس ارشد مدیریت کسب‌وکار، گروه مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران. رایانامه: mohammad.haddadi@alumni.kntu.ac.ir
۳. دانشجوی کارشناسی ارشد مهندسی سیستم‌های انرژی، دانشکده مهندسی انرژی و فیزیک، دانشگاه صنعتی امیرکبیر، تهران، ایران. رایانامه: erfan.abbasian@aut.ac.ir
۴. دکتری مهندسی مکانیک، دانشکده مهندسی مکانیک، دانشگاه شیراز، شیراز، ایران. رایانامه: mhnozari@gmail.com
۵. دانشجوی کارشناسی ارشد مهندسی سیستم‌های انرژی، دانشکده مهندسی انرژی و فیزیک، دانشگاه صنعتی امیرکبیر، تهران، ایران. رایانامه: hadi.eslamian@aut.ac.ir
۶. نویسنده مسئول، استادیار، گروه انرژی‌های تجدیدپذیر، دانشکده مهندسی انرژی، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: k_choubineh@sbu.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله:
پژوهشی

تاریخ‌های مقاله:

تاریخ دریافت: ۱۴۰۴/۱۱/۱۱

تاریخ بازنگری: ۱۴۰۴/۱۲/۲۳

تاریخ پذیرش: ۱۴۰۵/۰۱/۲۲

تاریخ انتشار: ۱۴۰۵/۰۴/۰۱

کلیدواژه:

مصرف انرژی الکتریکی،
پیش‌بینی،
یادگیری ماشین،
مدل تجمیعی،
بهینه‌سازی ازدحام ذرات.

پیش‌بینی دقیق مصرف انرژی الکتریکی یکی از الزامات اصلی برنامه‌ریزی بلندمدت انرژی و توسعه زیرساخت‌های برق است. با توجه به اثر هم‌زمان عوامل اقتصادی، جمعیتی، تجاری و اقلیمی بر تقاضای برق، در این پژوهش یک چارچوب داده‌محور مبتنی بر مدل یادگیری ماشین تجمیعی استکینگ بهینه‌شده با الگوریتم بهینه‌سازی ازدحام ذرات ارائه شده است. به این منظور، داده‌های سالانه ۱۹۹۱ تا ۲۰۲۰ برای شش کشور ایران، ایالات متحده، چین، آلمان، استرالیا و ترکیه استفاده شد و پنج متغیر جمعیت، تولید ناخالص داخلی، واردات انرژی، صادرات انرژی و میانگین سالانه دمای هوا به عنوان ورودی مدل در نظر گرفته شدند. عملکرد مدل‌های ANN، Stack، Ridge، و Stack-PSO با شاخص‌های MAE، MSE، R² و MAPE ارزیابی شد. نتایج نشان داد مدل Stack-PSO در مجموع و در بیشتر موارد عملکرد برتری نسبت به سایر مدل‌ها داشته است. مقدار R² این مدل در کشورهای مورد بررسی در بازه ۰/۹۷۴ تا ۰/۹۹۷ قرار گرفت. کمترین مقدار MSE مربوط به چین و برابر با ۰/۰۰۰۱۵ بود و در ایران نیز MSE مدل Stack-PSO به ۰/۰۰۰۴۲ و R² به ۰/۹۹۶ رسید. همچنین، کمترین MAPE در ایالات متحده برابر با ۲/۵ درصد به دست آمد که نشان‌دهنده دقت بالای مدل پیشنهادی در کاهش خطای پیش‌بینی است. سپس با استفاده از مدل برتر، مصرف انرژی الکتریکی تا افق ۲۰۳۵ پیش‌بینی شد و نتایج نشان داد روند کلی مصرف در اغلب کشورها افزایشی است، هرچند شدت رشد بین کشورها متفاوت بوده و در برخی موارد الگوی رشد ملایم یا نزدیک به پایداری مشاهده شد.

استناد: بهرامی یاجلو، امیر؛ حدادی، امیرمحمد؛ عباسیان همدانی، عرفان؛ نوذری، محمدحسین؛ اسلامیان، محمدهادی و چوبینه، کیانوش (۱۴۰۵). مدل‌سازی و پیش‌بینی مصرف انرژی الکتریکی با استفاده از مدل یادگیری ماشین تجمیعی استکینگ بهینه‌شده مبتنی بر الگوریتم بهینه‌سازی ازدحام ذرات. فصلنامه سیستم‌های انرژی پایدار، ۵ (۳) ۵۷۹-۶۰۰.

DOI: <http://doi.org/10.22059/ses.2026.412276.1222>

© امیر بهرامی یاجلو، امیرمحمد حدادی، عرفان عباسیان همدانی، محمدحسین نوذری، محمدهادی اسلامیان، کیانوش چوبینه

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <http://doi.org/10.22059/ses.2026.412276.1222>



۱. مقدمه

افزایش مصرف انرژی در دهه های اخیر، در کنار رشد جمعیت، توسعه صنعتی و گسترش شهرنشینی، به یکی از محرک های اصلی فشار بر منابع طبیعی و تشدید پیامدهای محیط زیستی تبدیل شده است [۱ و ۲]. اتکای بخش بزرگی از تأمین انرژی جهان به سوخت های فسیلی، علاوه بر محدودیت پذیری این منابع، با انتشار گازهای گلخانه ای و آلاینده های محلی همراه است و در نتیجه، به پدیده هایی مانند گرمایش جهانی، افت کیفیت هوا و افزایش مخاطرات سلامت عمومی دامن می زند [۳]. از این رو، سیاست گذاری و برنامه ریزی در حوزه انرژی به سمت افزایش بهره وری، کاهش شدت انرژی و گذار تدریجی به منابع کم کربن حرکت کرده است [۴ و ۵]. با این حال، تحقق این اهداف مستلزم شناخت دقیق الگوهای مصرف و توانایی پیش بینی قابل اتکا از تقاضا در مقیاس های مختلف زمانی و مکانی است [۶ و ۷].

در این میان، مصرف انرژی الکتریکی^۱ (EEC) به عنوان یکی از شاخص های کلیدی تقاضا، در مقیاس سالانه بازتابی از سطح فعالیت اقتصادی، میزان برقی سازی، ساختار بخش های مصرف کننده و تغییرات جمعیتی به شمار می رود [۸]. هرچند در افق سالانه نوسانات کوتاه مدت تا حد زیادی هموار می شود، اما EEC همچنان تحت تأثیر محرک های کلان و نسبتاً پایدار نظیر چشم انداز اقتصادی، تغییرات ساختار تقاضا و شرایط اقلیمی مؤثر بر نیاز سرمایه و گرمایش قرار دارد [۹ و ۱۰]. همچنین، شواهد پژوهشی نشان می دهد متغیرهای اجتماعی - اقتصادی مانند جمعیت و شاخص های اقتصادی می توانند نقش معناداری در توضیح تغییرات تقاضای برق داشته باشند و در کنار عوامل اقلیمی، رفتار EEC را شکل دهند [۱۱ و ۱۲]. از این رو، تحلیل و پیش بینی EEC سالانه، علاوه بر روشن سازی مسیرهای رشد تقاضا، می تواند مبنایی برای مقایسه بین کشوری و پشتیبانی از تصمیم سازی کلان در حوزه انرژی و زیرساخت های برق فراهم کند.

روش های کلاسیک پیش بینی بار، از جمله مدل های آماری و سری زمانی مانند خانواده میانگین متحرک خودرگرسیونیکپارچه^۲ (ARIMA)، به دلیل سادگی و تفسیرپذیری، در بسیاری از پژوهش ها و کاربردهای عملی به کار گرفته شده اند؛ با این حال، در ادبیات اخیر بارها گزارش شده است که این دسته از مدل ها در مواجهه با ویژگی های رایج تقاضای برق، مانند غیرخطی بودن، تغییر رژیم های رفتاری، اثر متغیرهای برونزا و پیچیدگی های فصلی، با محدودیت هایی روبه رو می شوند و همین امر انگیزه حرکت به سوی مدل های منعطف تر را تقویت کرده است [۱۳]. در سال های اخیر، پیشرفت های یادگیری ماشین^۳ و به ویژه یادگیری عمیق^۴، از شبکه های عصبی^۵ و روش های مبتنی بر درخت^۶ تا معماری های نوینی مانند ترنسفورمر، افق های تازه ای برای مدل سازی الگوها و روابط پیچیده در داده های مصرف گشوده است [۱۴ و ۱۵]. با این حال، موفقیت این روش ها به کیفیت و کفایت داده وابسته است. در کشورهای در حال توسعه مانند ایران، کمبود داده های منظم و مشکلات داده های ناقص یا کم کیفیت مانع پیش بینی قابل اتکا می شود [۱۶]. در مقابل، در کشورهای توسعه یافته مانند ایالات متحده، زیرساخت های داده و گسترش کنتورهای هوشمند و سامانه های اندازه گیری پیشرفته، دسترسی به داده های دقیق تر را فراهم می کند و قابلیت اتکای تحلیل ها و تصمیم سازی را افزایش می دهد [۱۷].

تارمانینی^۷ و همکاران، در مطالعه ای درباره پیش بینی کوتاه مدت بار با استفاده از داده های واقعی مصرف خانگی، گزارش کرده اند که مدل مبتنی بر شبکه عصبی به MAPE برابر با ۱/۸ درصد دست یافته است، در حالی که مقدار MAPE در ARIMA حدود ۲/۶۱ درصد داشته است. این تفاوت عملکرد می تواند بیانگر محدودیت های ARIMA در مواجهه با الگوهای غیرخطی موجود در داده های تقاضا باشد [۱۸]. در مطالعه ای دیگر، Cruz و همکاران در پیش بینی فصلی پیک تقاضای برق، با به کارگیری مدل SARIMA به همراه یک متغیر برونزا، مقادیر MAPE برابر با ۱/۷۳ درصد و R² برابر با ۰/۹۳۱ را گزارش

1. Electrical Energy Consumption
2. Autoregressive Integrated Moving Average
3. Machine Learning
4. Deep Learning
5. Neural Networks
6. Tree based Methods
7. Tarmanini

کرده‌اند. نتایج پژوهش آنان نشان می‌دهد SARIMA در این مسئله نسبت به Prophet و XGBoost دقت بیشتری داشته است [۱۹]. در مطالعه‌ای دیگر، از شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم‌های PSO و E PSO برای پیش‌بینی بلندمدت مصرف برق در افق ۲۰۲۰ تا ۲۰۵۰ استفاده شده و داده‌های دوره ۱۹۹۰ تا ۲۰۱۹ برای OECD، ایالات متحده، چین، هند و ایران مبنای تحلیل قرار گرفته است. نتایج پژوهش یادشده نشان می‌دهد بهینه‌سازی E PSO نسبت به PSO خطا را کاهش می‌دهد؛ برای مثال در حالت ورودی GDP، POP و EEC، مقدار MAPE در ایالات متحده از ۱/۲۴ به ۱/۰۱ و در ایران از ۲/۱۷ به ۱/۵۳ کاهش یافته است. همچنین نتایج سناریوها نشان می‌دهد با افزایش تدریجی سهم منابع تجدیدپذیر، مقدار مصرف برق در افق بلندمدت نسبت به سناریوی تداوم روند فعلی به طور محسوسی کمتر برآورد می‌شود و هم‌زمان کاهش قابل توجهی در انتشار CO₂ نیز حاصل خواهد شد [۲۰]. در مقاله‌ای دیگر توسط کابلی و همکاران، یک مدل مبتنی بر متغیرهای کلان اقتصادی اجتماعی برای پیش‌بینی مصرف برق ایران ارائه شده و ضرایب آن با الگوریتم ACS^۱ برآورد شده است. با استفاده از داده‌های ۱۹۹۲ تا ۲۰۱۳، نشان داده می‌شود ACS در مقایسه با روش‌هایی مانند GA و PSO برازش بهتری دارد و در مدل لگاریتمی، MAPE در دوره آزمون ۰/۷۴ درصد گزارش شده است. سپس، مصرف برق تا سال ۲۰۳۰ در چند سناریو پیش‌بینی شده و مقدار سال ۲۰۳۰ حدود ۳۱ تا ۳۲ MTOE در مدل لگاریتمی و حدود ۳۳ تا ۳۴ MTOE در مدل نمایی برآورد شده است [۲۱].

با توجه به اینکه عملکرد یک مدل منفرد می‌تواند تحت تأثیر ناهمگنی داده و تغییر الگوهای مصرف ناپایدار شود، در ادبیات یادگیری ماشین از روش‌های تجمیعی برای بهبود تعمیم پذیری و کاهش حساسیت پیش‌بینی به خطاهای مدل‌های منفرد استفاده می‌شود [۲۲ و ۲۳]. از بعد نظری نیز نشان داده شده است که تنوع در یک مجموعه مدل، فقط یک ویژگی جانبی نیست و به صورت مستقیم در تجزیه خطا و موازنه دقت و پایداری نقش دارد. شواهد تجربی نیز نشان می‌دهد روش‌های تجمیعی مانند بگینگ و تقویت و تصادفی‌سازی می‌توانند دقت را نسبت به مدل‌های منفرد در مسائل واقعی افزایش دهند [۲۴ و ۲۵]. در میان روش‌های تجمیعی، استکینگ به عنوان یک چارچوب فرایادگیری مطرح است که در آن یک مدل فراگیر با استفاده از خروجی مدل‌های پایه آموزش می‌بیند تا ترکیب خروجی‌ها را به شکل داده‌محور و متناسب با الگوهای موجود در داده تنظیم کند. در حوزه پیش‌بینی بار، مطالعات جدید گزارش کرده‌اند که استکینگ، به‌ویژه زمانی که یادگیرنده‌های ناهمگون به کار گرفته شوند، می‌تواند نسبت به مدل‌های منفرد و برخی تجمیع‌های ساده، دقت و پایداری بهتری ارائه دهد [۲۶ و ۲۷].

در مطالعه‌ای، Reddy و همکاران یک چارچوب تجمیعی از نوع stacking برای پیش‌بینی کوتاه‌مدت مصرف برق پیشنهاد کرده‌اند که در آن خروجی چند مدل پایه مانند LSTM، Random Forest و شبکه عصبی عمیق در لایه دوم با XGBoost ترکیب می‌شود. ارزیابی روی یک مجموعه داده بزرگ با حدود ۵۰۰ هزار مقدار مصرف و در قالب پیش‌بینی چندگانه ۴ ساعته انجام شده و برای بهبود ایستایی، از differencing مرتبه ۱ نیز استفاده شده است. نتایج پژوهش یادشده نشان می‌دهد مدل تجمیعی مبتنی بر XGBoost عملکرد بهتری نسبت به روش‌های مرجع دارد؛ به طور نمونه RMSE حدود ۴۲۱ و MAE حدود ۳۰۹ گزارش شده، در حالی که ARIMA در تنظیمات مشابه RMSE بسیار بالاتری داشته است [۲۸]. در پژوهشی دیگر، از یک چارچوب تجمیعی مبتنی بر stacking با نام SMLE^۲ برای پیش‌بینی مصرف انرژی استفاده شده است که در آن برون‌داد مدل‌هایی مانند SVR و BPNN در یک لایه ترکیب خطی ادغام می‌شود. ارزیابی بر پایه داده‌های مصرف جهانی نفت در بازه ۱۹۶۵ تا ۲۰۱۶ انجام شده و نتایج بیانگر برتری رویکرد تجمیعی نسبت به مدل‌های منفرد است؛ به گونه‌ای که مقدار MAPE در افق یک گام حدود ۰/۶۱ درصد و میانگین MAPE در پیش‌بینی ۱۰ گام حدود ۰/۷۴ درصد گزارش شده است [۲۹]. همچنین، Pachauri و Mohan از یک مدل تجمیعی stacking برای پیش‌بینی مصرف انرژی ساختمان استفاده کردند که در آن XGB و DT در نقش مدل‌های پایه و RF به عنوان مدل ترکیب‌کننده استفاده می‌شوند و تنظیم ابرپارامترها با Bayesian optimization انجام می‌گیرد. نتایج روی داده مرجع (بار سرمایشی و گرمایشی) نشان می‌دهد مدل به دقت بسیار بالا رسیده

1. Artificial cooperative search
2. Stacking Multi-Learning Ensemble

است؛ به طور نمونه برای بار گرمایشی مقدار RMSE حدود 0.484 و R^2 حدود 0.999 و برای بار سرمایشی مقدار RMSE حدود 0.948 و R^2 حدود 0.990 گزارش شده است. همچنین روی، داده ساعتی سیستم تهویه مطبوع (HVAC) نیز R^2 حدود 0.981 و RMSE حدود 0.181 به دست آمده است [۳۰].

با وجود پیشرفت‌های اخیر در کاربرد روش‌های یادگیری ماشین برای پیش‌بینی مصرف برق، بخش قابل توجهی از مطالعات پیشین بر مدل‌های منفرد، پیش‌بینی کوتاه‌مدت یا بررسی یک کشور خاص تمرکز داشته‌اند. از این‌رو، نیاز به توسعه و ارزیابی چارچوب‌هایی وجود دارد که بتوانند مصرف انرژی الکتریکی را در افق بلندمدت و در مقیاس چندکشوری، با در نظر گرفتن هم‌زمان محرک‌های اقتصادی، جمعیتی، تجاری و اقلیمی، پیش‌بینی کنند. در این راستا، عملکرد مدل‌های منفرد با یک مدل استکینگ بهینه‌شده از طریق الگوریتم بهینه‌سازی ازدحام ذرات مقایسه شده و توانایی آن در کاهش خطا و افزایش قدرت تبیین ارزیابی شده است. همچنین با اتکا به مدل برتر، مسیر آتی مصرف انرژی الکتریکی تا افق 2035 برآورد شده است تا تصویری تحلیلی برای پشتیبانی از برنامه‌ریزی و سیاست‌گذاری بلندمدت در حوزه انرژی فراهم شود.


۲. روش‌شناسی

مفهوم یادگیری تجمیعی استکینگ^۱ نخستین‌بار در سال ۱۹۹۲ معرفی شده و کارایی آن در افزایش دقت و کاهش خطا از طریق ترکیب چند مدل و افزودن یک لایه اتصال گزارش شده است [۳۱]. در این چارچوب، چندین مدل یادگیری ماشین به صورت هم‌زمان با یکدیگر ترکیب می‌شوند و خروجی مدل‌های پایه^۲ توسط یک زیرمدل سطح بالاتر که متا یادگیر^۳ نامیده می‌شود، تجمیع می‌شود؛ به گونه‌ای که هدف اصلی متا یادگیر، ارزیابی عملکرد مدل‌های پایه و تولید خروجی نهایی با بهره‌گیری از بهترین الگوی عملکرد آن‌ها است و در نهایت عملکرد کلی سیستم افزایش می‌یابد [۳۲]. در این مطالعه، مصرف انرژی الکتریکی^۴ شش کشور شامل ایران، ایالات متحده، چین، آلمان، استرالیا و ترکیه تا سال 2035 پیش‌بینی شده است. با توجه به ماهیت چندعاملی مصرف انرژی الکتریکی و وابستگی آن به محرک‌های اقتصادی، تجاری و اقلیمی، استفاده از یک مدل منفرد معمولاً به پوشش ناقص الگوهای موجود در داده‌ها منجر می‌شود؛ از این‌رو، در این پژوهش یک چارچوب استکینگ برای تجمیع قابلیت‌های چند مدل و افزایش پایداری پیش‌بینی در نظر گرفته می‌شود. ساختار کلی مدل پیشنهادی و مسیر جریان داده مطابق شکل ۱ ارائه شده است و اجزای اصلی آن شامل مرحله آماده‌سازی داده، یادگیری مدل‌های پایه، یادگیری متا - مدل، بهینه‌سازی و در نهایت پیش‌بینی خروجی است.

ابتدا داده‌ها وارد سیستم شده و متغیرهای ورودی شامل جمعیت، تولید ناخالص داخلی، صادرات انرژی، واردات انرژی و دمای میانگین به عنوان ویژگی‌ها در نظر گرفته می‌شوند. سپس برای یکنواخت‌سازی مقیاس متغیرها و کاهش اثر اختلاف مقیاس، مرحله استانداردسازی روی داده‌ها اعمال می‌شود. پس از آماده‌سازی داده‌ها، دو مدل شبکه عصبی مصنوعی (ANN) و رگرسیون ریب^۵ به عنوان مدل‌های پایه به کار گرفته می‌شوند و هر یک به طور مستقل بر اساس داده‌های ورودی، خروجی میانی تولید می‌کنند. خروجی‌های حاصل از این دو مدل پایه به لایه متا منتقل می‌شود و در این لایه، رگرسیون خطی^۶ به عنوان متا یادگیر در نظر گرفته می‌شود تا با ترکیب خروجی مدل‌های پایه، پیش‌بینی نهایی مصرف انرژی الکتریکی تولید شود. در ادامه، به منظور بهبود عملکرد و کاهش خطای پیش‌بینی، الگوریتم بهینه‌سازی ازدحام ذرات^۷ برای تنظیم ابرپارامترهای^۸ مدل‌ها اعمال می‌شود؛ به گونه‌ای که پارامترهای بهینه با هدف کمینه‌سازی معیار خطا انتخاب می‌شوند و مدل نهایی به صورت Trained Model حاصل می‌شود. سپس با استفاده از مدل آموزش‌دیده، مرحله پیش‌بینی انجام می‌شود و خروجی نهایی تولید می‌شود.

1. Stacking Ensemble
2. Base Learners
3. Meta-learner
4. EEC
5. Ridge Regression
6. Linear Regression
7. PSO
8. Hyperparameter

همچنین برای تولید مقادیر ورودی در افق آینده، متغیرهای توضیحی با استفاده از مدل خودرگرسیون غیرخطی با ورودی‌های برون‌زا^۱ (NARX) برآورد شده و پس از استانداردسازی، به مدل آموزش‌دیده تزریق می‌شوند تا پیش‌بینی مصرف انرژی الکتریکی برای سال‌های آتی انجام شود. تمامی شبیه‌سازی‌ها در محیط پایتون انجام شده‌اند و در نهایت، نتایج مدل استکینگ با نتایج مدل‌های پایه مقایسه و تحلیل شده‌اند.



شکل ۱. چارچوب مدل پیشنهادی برای پیش‌بینی مصرف انرژی الکتریکی

۱-۲. گردآوری و پردازش داده‌ها

در این مطالعه، پنج پارامتر شامل جمعیت (POP)، تولید ناخالص داخلی (GDP)، واردات انرژی (IMP)، صادرات انرژی (EXP) و میانگین سالانه دمای هوا (TEMP) به عنوان متغیرهای ورودی در نظر گرفته شده‌اند و مصرف انرژی الکتریکی به عنوان خروجی مدل تعریف شده است. مجموعه داده بازه زمانی ۱۹۹۱ تا ۲۰۲۰ را پوشش داده و از آژانس بین‌المللی انرژی (IEA^۲) و بانک جهانی گرفته شده است. متغیرهای جمعیت و تولید ناخالص داخلی به عنوان عوامل مهم اقتصادی و جمعیتی اثرگذار بر تقاضای برق در نظر گرفته شده‌اند، در حالی که واردات و صادرات انرژی، وضعیت دسترسی به انرژی و الگوهای مصرف را بازتاب داده‌اند. همچنین دما از طریق تغییرات نیاز به گرمایش و سرمایش، بر میزان مصرف انرژی اثرگذار بوده است. در مجموع، این متغیرها محرک‌های اصلی اقتصادی، تجاری و اقلیمی مصرف برق را پوشش داده‌اند.

در این بخش پیش از توسعه مدل، تمامی داده‌ها تحت مراحل پیش‌پردازش قرار داده شده‌اند. به منظور کاهش اثر اختلاف مقیاس متغیرها و بهبود عملکرد پیش‌بینی، داده‌های ورودی و خروجی با استفاده از رابطه ۱ به بازه بین ۰ تا ۱ نرمال‌سازی شده‌اند. این فرایند نرمال‌سازی به تسهیل آموزش مدل و افزایش دقت پیش‌بینی کمک کرده است و پس از انجام پیش‌بینی، مقادیر خروجی با استفاده از رابطه ۲ از حالت نرمال خارج شده‌اند^۳ تا امکان مقایسه میان پیش‌بینی‌های مدل و داده‌های واقعی مصرف انرژی الکتریکی فراهم شود [۳۳].

$$X_{normal} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

$$X = X_{normal} (X_{max} - X_{min}) + X_{min} \quad (2)$$

همچنین در این پژوهش، به منظور تولید داده‌های ورودی موردنیاز برای پیش‌بینی سال‌های آینده، از مدل NARX استفاده شد. همان‌طور که در شکل ۲ نشان داده شده است، ابتدا داده‌های تاریخی متغیرهای POP، GDP، IMP، EXP و TEMP به عنوان مبنای یادگیری به مدل داده می‌شود و سپس پیش‌بینی‌ها به صورت حرکت پنجره‌ای تک‌ساله^۴ انجام می‌گیرد؛ به


1. Nonlinear Auto Regressive With Exogenous Inputs

2. International Energy Agency

3. Denormalize

4. Single-year moving approach

این صورت که برای پیش بینی هر سال، مدل با استفاده از اطلاعات سال های گذشته آموزش داده می شود و مقدار سال بعد را تولید می کند، سپس این خروجی تولید شده به عنوان بخشی از داده های گذشته به گام بعدی منتقل می شود تا پیش بینی سال های بعدی نیز به صورت پیاپی تا افق مورد نظر ادامه یابد. به این ترتیب، NARX امکان برآورد سری های آینده متغیرهای ورودی را فراهم می کند تا این مقادیر پیش بینی شده به عنوان ورودی های مدل نهایی پیش بینی مصرف انرژی مورد استفاده قرار گیرند.



شکل ۲. رویکرد متحرک تک ساله برای پیش بینی داده های تاریخی با استفاده از مدل NARX

۲-۲. معیارهای ارزیابی عملکرد مدل

برای ارزیابی عملکرد مدل های توسعه یافته، چند معیار کلیدی شامل ضریب تعیین (R^2)، میانگین مربعات خطا (MSE)، میانگین قدرمطلق خطا (MAE) و میانگین قدرمطلق خطای درصدی (MAPE) به کار گرفته شده اند. این معیارها مطابق روابط ۳ تا ۶ محاسبه می شوند؛ به گونه ای که y مقادیر واقعی، y_p مقادیر پیش بینی شده توسط مدل و $\bar{y}$ میانگین داده ها را نشان می دهد و n نیز تعداد کل مشاهدات است. عملکرد یک مدل زمانی بهتر تلقی می شود که مقادیر MSE و MAE به صفر نزدیک تر باشند و مقدار R^2 به ۱ نزدیک تر باشد. همچنین، کاهش مقدار MAPE بیانگر نزدیک تر بودن پیش بینی های مدل به مقادیر واقعی از منظر خطای درصدی است. به طور کلی، مقادیر کمتر MSE، MAE و MAPE نشان دهنده دقت بالاتر پیش بینی بوده و مقدار بالاتر R^2 بیانگر توضیح سهم بیشتری از واریانس داده ها توسط مدل است [۳۴].

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_p - y)^2 \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |y - y_p|}{n} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_p - y)^2}{\sum_{i=1}^n (y_p - \bar{y})^2} \quad (5)$$

$$MAPE = \frac{\sum_{i=1}^n |y - y_p|}{ny_p} \times 100 \quad (6)$$

۳-۲. مدل های پایه

در مدل یادگیری تجمیعی استکینگ، مدل های پایه به صورت مستقل با تنظیمات اولیه آموزش داده می شوند و خروجی هر یک به عنوان ورودی برای مدل نهایی (متا یادگیر) در نظر گرفته می شود؛ به این ترتیب، با ترکیب خروجی مدل های پایه، دقت پیش بینی کلی بهبود می یابد [۳۲].

۲-۳-۱. رگرسیون ریج

Ridge regression نوعی روش برآورد بایاس دار برای تحلیل داده‌های هم‌خط^۱ است و از نظر ایده پایه شبیه روش کمترین مربعات در رگرسیون خطی است. تفاوت اصلی این است که در Ridge یک جمله‌ی منظم‌سازی L2 به تابع هدف رگرسیون خطی اضافه می‌شود. این کار با قبول کاهش جزئی دقت و از دست دادن بخشی از اطلاعات، باعث می‌شود ضرایب رگرسیون واقع‌بینانه‌تر و پایدارتر شوند و تحمل مدل نسبت به داده‌های بدشرط^۲ نسبت به روش کمترین مربعات بیشتر شود. در این پژوهش، برای هر سال (در مجموع ۲۰ سال، یعنی T=20) تعداد ۵ متغیر مستقل یعنی (n=5) داریم که آن‌ها را با $x_1, \dots, x_5$ نشان می‌دهیم و هدف، تقریب زدن متغیر وابسته y یعنی EEC است؛ بنابراین مدل خطی به صورت رابطه ۷ در نظر گرفته می‌شود [۳۵].

$$\beta_0 + \sum_{i=1}^5 \beta_i x_i \quad (7)$$

در این مطالعه معیار خطا، میانگین مربعات خطا (MSE) در نظر گرفته می‌شود و هدف، کمینه‌سازی آن است که از طریق رابطه ۸ محاسبه می‌شود. در این رابطه مقدار متغیر x_i در سال t با $x_{i,t}$ و EEC همان سال با y_t نمایش داده شده است [۳۵].

$$MSE = \frac{1}{20} \sum_{t=1}^{20} \left(\beta_0 + \sum_{i=1}^5 \beta_i x_{i,t} - y_t \right)^2 \quad (8)$$

عملکرد رگرسیون ریج به تنظیم دقیق پارامتر منظم‌سازی λ (در برخی نرم افزارها پارامتر α) وابسته است؛ به طوری که مقادیر بزرگ‌تر λ با اعمال جریمه‌ی L2 ضرایب را کوچک‌تر می‌کند و واریانس را کاهش اما بایاس را افزایش می‌دهند، در حالی که مقادیر کوچک‌تر λ مدل را به کمترین مربعات معمولی^۳ نزدیک کرده و خطر بیش‌برازش^۴ را بیشتر می‌کند. درنهایت، Ridge regression با افزودن پارامتر تنظیمی λ ، تابع هدف معادله ۹ را کمینه می‌کند [۳۵].

$$MSE + \lambda \sum_{t=1}^{20} \beta_t^2 \quad (9)$$

۲-۳-۲. شبکه عصبی مصنوعی

شبکه عصبی مصنوعی نوعی رویکرد پیشرفته در یادگیری ماشین است که با الهام از سازوکار پردازش اطلاعات در مغز انسان طراحی شده است. این الگوریتم از مجموعه‌ای از نورون‌ها و لایه‌ها تشکیل می‌شود که وظیفه یادگیری و استخراج ویژگی‌های پیچیده از داده‌ها را به عهده دارند. شبکه‌های عصبی به‌ویژه برای مسائل غیرخطی و پیچیده مناسب در نظر گرفته می‌شوند؛ از جمله مدل‌سازی پویایی سیستم‌های غیرخطی و پیش‌بینی در مجموعه‌داده‌های بزرگ و پیچیده [۳۶].


در این پژوهش، معماری پرسپترون چندلایه (MLP) به عنوان یک شبکه پیش‌خور^۵ انتخاب می‌شود که برای داده‌های غیرخطی و پیچیده کاربرد گسترده‌ای دارد و ساختار کلی آن مطابق شکل ۳ ارائه می‌شود. ساختار MLP شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی در نظر گرفته می‌شود. در این مطالعه، با توجه به استفاده از پنج متغیر ورودی شامل POP، GDP، IMP، EXP و TEMP تعداد نورون‌های لایه ورودی برابر با ۵ در نظر گرفته می‌شود. به منظور ارائه یک پیکربندی اولیه و پیش‌فرض، پیش از اجرای مرحله بهینه‌سازی، تعداد نورون‌های لایه پنهان بر اساس یک قاعده تجربی برابر با دو برابر تعداد ورودی‌ها در نظر گرفته می‌شود؛ بنابراین با توجه به پنج ویژگی ورودی، تعداد نورون‌های لایه پنهان برابر با ۱۰ تعیین می‌شود. در ادامه، در مرحله بهینه‌سازی، این مقدار به عنوان یکی از پارامترهای قابل تنظیم توسط بهینه‌ساز در نظر گرفته می‌شود تا ساختار شبکه متناسب با هدف کمینه‌سازی خطا و افزایش دقت پیش‌بینی بهبود یابد. همچنین، لایه خروجی شامل

1. Collinear
2. Ill-conditioned
3. OLS
4. Overfitting
5. Feedforward

یک نورون بوده و مقدار EEC به عنوان خروجی مدل توسط آن تولید می شود. تعداد لایه های پنهان و تعداد نورون های هر لایه به عنوان عوامل مؤثر بر پیچیدگی مدل و تعادل بایاس - واریانس در نظر گرفته می شوند؛ به گونه ای که انتخاب نامناسب آن ها می تواند به بیش برآزش یا کم برآزش بینجامد. در فرایند یادگیری، سیگنال های ورودی در وزن ها ضرب شده و پس از جمع شدن به همراه بایاس، از تابع فعال ساز عبور داده می شوند. در این پژوهش، تابع سیگموئید برای لایه پنهان و تابع خطی برای لایه خروجی در نظر گرفته شده است که به ترتیب به صورت روابط ۱۰ و ۱۱ بیان می شوند. در این روابط پارامتر γ ورودی خالص نورون، $w_{i,j}$ وزن اتصال بین ورودی z و نورون i ، b_i بایاس نورون است [۳۳].

$$f_1 = \frac{1}{1 + e^{-y}} \quad (10)$$

$$f_2 = w_{i,j} \times z + b_i \quad (11)$$



شکل ۳. پیکربندی شبکه عصبی پرسپترون چندلایه مورد استفاده با ۵ نورون در لایه پنهان

۲-۴. الگوریتم بهینه سازی ازدحام ذرات (PSO)

الگوریتم بهینه سازی ازدحام ذرات^۱ (PSO) نوعی روش فراابتکاری مبتنی بر جمعیت است که با الهام از رفتار اجتماعی پرندگان و ماهیان در جست و جوی غذا معرفی شده است. در PSO، مجموعه ای از ذرات در فضای جست و جو حرکت می کنند و هر ذره یک راه حل کاندید برای مسئله بهینه سازی محسوب می شود. در این پژوهش، PSO به منظور تنظیم هایپرپارامترهای مدل های پیش بینی پایه به کار گرفته شده است؛ به گونه ای که هدف، یافتن ترکیب بهینه ای از هایپرپارامترها است که مقدار MSE را روی داده های آزمون کمینه کند. در اینجا فرض می شود که تعداد هایپرپارامترهای قابل تنظیم برابر n باشد. در این صورت، موقعیت هر ذره i در تکرار t یک بردار n -بعدی از هایپرپارامترها را نمایش می دهد که در آن S فضای جست و جوی مجاز (کران های هر هایپرپارامتر) است که از طریق رابطه ۱۲ به دست می آید. همچنین، هر ذره دارای بردار سرعت مطابق رابطه ۱۳ است [۳۷].

$$x_i^t = (x_{i1}^t, x_{i2}^t, x_{i3}^t, \dots, x_{in}^t)^T \in S \quad (12)$$

$$v_i^t = (v_{i1}^t, v_{i2}^t, v_{i3}^t, \dots, v_{in}^t)^T \in R^n \quad (13)$$

برای ارزیابی کیفیت هر موقعیت یا هر ترکیب هایپرپارامتر، ابتدا مدل‌های پایه با همان تنظیمات اجرا می‌شوند و سپس مقدار تابع هدف به صورت MSE طبق رابطه ۱۴ محاسبه می‌شود، به طوری که در آن y مقدار واقعی، y_p مقدار پیش‌بینی شده و n تعداد نمونه‌های مجموعه ارزیابی است [۳۳].

$$f(x_i^t) = MSE = \frac{1}{n} \sum_{p=1}^n (y_p - y)^2 \quad (14)$$

طی تکرارها، هر ذره بهترین موقعیت تجربه‌شده خود را به عنوان بهترین شخصی (P_{best}^t) ذخیره می‌کند و بهترین موقعیت مشاهده‌شده در کل جمعیت به عنوان بهترین سراسری (G_{best}^t) تعیین می‌شود. در هر تکرار، سرعت و موقعیت ذرات با استفاده از روابط استاندارد PSO به‌روزرسانی می‌شوند. رابطه سرعت شامل سه بخش اینرسی، مؤلفه شناختی و مؤلفه اجتماعی است که از رابطه ۱۵ به دست می‌آید. سپس، موقعیت ذره با استفاده از سرعت جدید که از رابطه ۱۶ به دست می‌آید، اصلاح می‌شود.

$$v_i^{t+1} = wv_i^t + c_1r_1(P_{best,i}^t - x_i^t) + c_2r_2(G_{best}^t - x_i^t) \quad (15)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (16)$$

اگر تابع هدف با $f(0)$ نمایش داده شود (در این پژوهش MSE) آن گاه مقادیر بهترین شخصی P_{best} و بهترین سراسری G_{best} مطابق روابط ۱۷ و ۱۸ به‌روزرسانی می‌شوند [۳۸].

$$P_{best,i}^{t+1} = \begin{cases} x_i^{t+1}, & f(x_i^{t+1}) < f(P_{best,i}^{t+1}) \\ P_{best,i}^t, & \text{Otherwise} \end{cases} \quad (17)$$

$$G_{best}^t = \arg \min_i f(P_{best,i}^{t+1}) \quad (18)$$

در مجموع، الگوریتم PSO با جست‌وجوی تکرارشونده در فضای هایپرپارامترها و به‌روزرسانی موقعیت و سرعت ذرات بر اساس بهترین تجربه‌های شخصی و سراسری، ترکیب بهینه‌ای از هایپرپارامترهای مدل‌های پایه را استخراج می‌کند که به کمینه شدن مقدار MSE منجر می‌شود. برای اجرای این فرایند، مقادیر اولیه پارامترهای اصلی الگوریتم طبق جدول ۱ تنظیم شده‌اند.

جدول ۱. پارامترهای به‌کاررفته در الگوریتم PSO

پارامتر	مقدار
اندازه جمعیت	۳۰
حداکثر تعداد تکرار	۵۰
وزن اینرسی (w)	(کاهش خطی) ۰/۹ به ۰/۴
($c1$) ضریب شناختی	۲
($c2$) ضریب اجتماعی	۲
تابع هدف	حداقل‌سازی MSE

۲-۵. متا مدل (مدل ترکیب‌کننده)

در مدل استکینگ پیشنهادی، متامدل وظیفه دارد خروجی مدل‌های پایه را با یکدیگر ترکیب کرده و پیش‌بینی نهایی EEC را تولید کند. در این پژوهش، رگرسیون خطی به عنوان متامدل انتخاب شده است، زیرا با ساختار ساده و تفسیرپذیر خود می‌تواند وزن‌دهی مناسبی به پیش‌بینی‌های مدل‌های پایه انجام دهد و بدون افزایش پیچیدگی، عملکرد کلی سیستم را بهبود دهد. ورودی‌های متامدل، پیش‌بینی‌های تولیدشده توسط مدل‌های پایه هستند؛ یعنی برای هر نمونه، مقدار پیش‌بینی‌شده توسط ANN و مقدار پیش‌بینی‌شده توسط Ridge Regression به صورت دو ویژگی ورودی به رگرسیون خطی داده می‌شود. خروجی متامدل نیز یک مقدار واحد است که همان پیش‌بینی نهایی EEC است. رابطه کلی متامدل را می‌توان به صورت رابطه ۱۹ بیان کرد که در آن y_{Ridge} و y_{ANN} ورودی‌های متامدل (پیش‌بینی مدل‌های پایه)، $y_{Forecast}$ خروجی نهایی و β_0 ، β_1 و β_2 ضرایبی هستند که در فرایند آموزش برای کمینه‌سازی خطی MSE برآورد می‌شوند.

$$y_{Forecast} = \beta_0 + \beta_1 y_{ANN} + \beta_2 y_{Ridge} \quad (۱۹)$$

۳. یافته ها

۳-۱. صحت سنجی مدل

در این مطالعه، هدف اصلی پیش بینی مصرف انرژی الکتریکی در کشورهای مختلف با الگوهای اقتصادی، اجتماعی و اقلیمی متفاوت با استفاده از مدل های مختلف یادگیری ماشین بوده است. مدل های شبکه عصبی مصنوعی، رگرسیون ریب، مدل تجمیعی استکینگ و مدل استکینگ بهینه شده با الگوریتم PSO برای پیش بینی انتخاب شده اند. به منظور ارزیابی و اعتبارسنجی عملکرد مدل های مورد استفاده در این پژوهش، داده ها به دو بخش آموزش و آزمون تقسیم شدند و عملکرد مدل ها بر روی داده های آزمون مورد بررسی قرار گرفت. برای سنجش دقت پیش بینی، از شاخص های آماری متداول شامل MSE، MAE، R² و MAPE استفاده شد. استفاده همزمان از این شاخص ها امکان ارزیابی جامع عملکرد مدل ها از نظر میزان خطا و قدرت تبیین تغییرات داده ها را فراهم می کند. نتایج حاصل از اعتبارسنجی نشان داد مدل پیشنهادی Stack-PSO در مقایسه با مدل های پایه شامل Ridge، ANN و مدل تجمیعی Stack از دقت بالاتری برخوردار است و مقادیر خطای کمتری را در مجموعه داده آزمون ارائه می دهد. همچنین، تطابق مناسب بین مقادیر واقعی و مقادیر پیش بینی شده در دوره آزمون بیانگر توانایی مناسب مدل در تعمیم پذیری و پیش بینی روند مصرف انرژی الکتریکی در کشورهای مورد بررسی است. جدول ۲ نتایج عملکرد مدل های مختلف را برای کشورهای مختلف بر اساس این معیارها نشان می دهد.

جدول ۲. نتایج ارزیابی عملکرد مدل های مورد استفاده بر اساس شاخص های خطا در مرحله آموزش و تست

کشور	MSE	MAE	R ²	MAPE
ANN				
استرالیا	۰/۰۰۰۷۶	۰/۰۲۵۱	۰/۹۸۲	۷٪/۴
ایران	۰/۰۰۰۹۴	۰/۰۲۶۴	۰/۹۸۲	۱۸٪/۴
ایالات متحده	۰/۰۰۱۵۳	۰/۰۳۱۳	۰/۹۵۴	۷٪/۱
چین	۰/۰۰۰۴۴	۰/۰۱۵۴	۰/۹۹۳	۴٪/۵
ترکیه	۰/۰۰۱۰۶	۰/۰۲۷۱	۰/۹۸۱	۱۴٪/۲
آلمان	۰/۰۰۱۸۶	۰/۰۳۶۰	۰/۹۸۶	۱۰٪/۸
Ridge				
استرالیا	۰/۰۰۰۴۶	۰/۰۱۸۰	۰/۹۸۸	۳٪/۴
ایران	۰/۰۰۱۰۰	۰/۰۲۱۶	۰/۹۶۳	۱۷٪/۱
ایالات متحده	۰/۰۰۱۱۰	۰/۰۳۲۸	۰/۹۷۹	۳٪/۶
چین	۰/۰۰۰۴۱	۰/۰۱۶۴	۰/۹۹۲	۹٪/۶
ترکیه	۰/۰۰۰۹۶	۰/۰۱۸۳	۰/۹۸۹	۱۲٪/۴
آلمان	۰/۰۰۱۵۹	۰/۰۴۰۹	۰/۹۷۸	۹٪/۱
Stack				
استرالیا	۰/۰۰۰۷۳	۰/۰۲۳۰	۰/۹۷۶	۹٪/۸
ایران	۰/۰۰۱۶۹	۰/۰۳۶۳	۰/۹۸۶	۱۵٪/۸
ایالات متحده	۰/۰۰۱۳۱	۰/۰۴۸۲	۰/۹۷۵	۴٪/۸
چین	۰/۰۰۰۳۶	۰/۰۱۱۵	۰/۹۹۶	۷٪/۵
ترکیه	۰/۰۰۰۹۳	۰/۰۲۱۶	۰/۹۹۱	۹٪/۸
آلمان	۰/۰۰۰۹۴	۰/۰۲۵۹	۰/۹۸۹	۵٪/۶
Stack-PSO				
استرالیا	۰/۰۰۰۵۱	۰/۰۲۱۷	۰/۹۸۵	۶٪/۷
ایران	۰/۰۰۰۴۲	۰/۰۱۵۸	۰/۹۹۶	۹٪/۷
ایالات متحده	۰/۰۰۰۸۲	۰/۰۲۲۵	۰/۹۸۴	۲٪/۵
چین	۰/۰۰۰۱۵	۰/۰۱۰۹	۰/۹۹۷	۴٪/۳
ترکیه	۰/۰۰۰۸۱	۰/۰۱۶۷	۰/۹۹۲	۷٪/۶
آلمان	۰/۰۰۱۱۲	۰/۰۳۴۳	۰/۹۷۴	۷٪/۳

نتایج نشان داده‌اند مدل ANN در بیشتر کشورهای مورد بررسی، عملکرد قابل قبولی از خود نشان داده است. به طور خاص، برای کشور چین، مقدار MSE مدل ANN برابر با ۰/۰۰۰۴۴ به دست آمده و MAPE آن ۴/۵٪ و R^2 آن برابر با ۰/۹۹۳ برآورد شده است که دقت نسبی خوب این مدل در پیش‌بینی مصرف انرژی الکتریکی در کشورهای با داده‌های مناسب و ساختار مشخص را نشان می‌دهد. با این حال، در کشورهای ایران و ترکیه، نتایج مدل ANN کمتر موفقیت‌آمیز بوده‌اند. در ایران، MSE برای این مدل به ۰/۰۰۰۹۴ رسید و MAPE آن ۱۸/۴٪ بوده که نشان‌دهنده کاهش دقت پیش‌بینی‌ها در مواجهه با داده‌های پیچیده‌تر است. این موضوع به‌وضوح در جدول ۲ قابل مشاهده است. در مقابل، مدل Ridge که به عنوان یک روش رگرسیونی خطی با تنظیمات خاص شناخته می‌شود، در برخی کشورهای مورد بررسی، دقت بهتری از خود نشان داده است. به‌ویژه در کشور استرالیا، MSE این مدل به ۰/۰۰۰۴۶ کاهش یافته که از MSE مدل ANN (۰/۰۰۰۷۶) دقیق‌تر است. همچنین، R^2 مدل Ridge در استرالیا برابر با ۰/۹۸۸ بوده که بیانگر توانایی بالای این مدل در شبیه‌سازی تقاضای برق است. در کشور آلمان نیز، مدل Ridge توانسته MSE را به ۰/۰۰۱۵۹ کاهش دهد که این مقدار بهتر از مدل ANN بوده است.


مدل Stacking که از تجمع خروجی‌های مدل پایه برای پیش‌بینی استفاده می‌کند، عملکرد بهتری نسبت به مدل‌های منفرد از خود نشان داده است. در کشور چین، مدل Stack توانسته است MSE را به ۰/۰۰۰۳۶ کاهش دهد که این مقدار از مدل‌های ANN و Ridge بهتر بوده است. این مدل به طور مؤثری ضعف‌های مدل‌های منفرد را جبران کرده و دقت پیش‌بینی‌ها را در کشورهایی با داده‌های پیچیده بهبود بخشیده است. در کشور آلمان، مدل Stack توانست MSE را به ۰/۰۰۰۹۴ کاهش دهد و MAPE را به ۵/۶٪ برساند که از مدل‌های ANN و Ridge دقیق‌تر بوده است.

مدل Stack-PSO که با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات برای تنظیم هاپیرپارامترهای مدل‌های پایه پرداخته، عملکرد بهتری نسبت به سایر مدل‌ها در تمامی معیارهای ارزیابی نشان داده است. این مدل به‌ویژه در کاهش MSE، MAPE و MAE در کشورهای مختلف موفق عمل کرده است. طبق جدول ۱، مقدار MSE مدل Stack-PSO در کشور چین به ۰/۰۰۰۱۵ کاهش یافته است که این مقدار از مدل‌های ANN با MSE برابر با ۰/۰۰۰۴۴ و Ridge با MSE برابر با ۰/۰۰۰۴۱، به طور قابل توجهی بهتر بوده است. علاوه بر این، در ایران، MSE مدل Stack-PSO به ۰/۰۰۰۴۲ رسید و MAPE آن ۹/۷٪ کاهش یافته که این مقادیر نشان‌دهنده دقت زیاد مدل در پیش‌بینی مصرف انرژی در این کشور بوده است. همچنین نتایج مدل Stack-PSO در کشورهای دیگر مانند آلمان و ترکیه بهبود قابل توجهی نسبت به دیگر مدل‌ها نشان داده است. این مدل توانسته است MSE و MAPE را به طور چشمگیری کاهش دهد. بنابراین، مدل Stack-PSO توانسته است در اکثر کشورهای بررسی شده نتایج بهتری نسبت به مدل‌های ANN و Ridge ارائه دهد. شکل ۴ خروجی مدل Stack-PSO را برای دوره تست (سال‌های ۲۰۱۴ تا ۲۰۲۰) نشان می‌دهد. در این شکل، پیش‌بینی‌های دوره تست مدل Stack-PSO برای کشورهای چین، ایران، آلمان، ترکیه و استرالیا با خط قرمز رنگ مشخص شده است، در حالی که داده‌های واقعی با خط آبی رنگ نمایش داده شده‌اند. همان‌طور که در شکل ۴ مشاهده می‌شود، پیش‌بینی‌های مدل Stack-PSO تطابق بسیار خوبی با داده‌های واقعی دارند و توانسته‌اند خطای پیش‌بینی را به طور قابل توجهی کاهش دهند. این نتایج تأیید می‌کنند که مدل Stack-PSO می‌تواند بهترین عملکرد را در پیش‌بینی مصرف انرژی الکتریکی در کشورهای مختلف با الگوهای اقتصادی، اجتماعی و جغرافیایی متفاوت از خود نشان دهد.


۳-۲. پیش‌بینی

در این بخش، پس از انتخاب مدل Stack-PSO به عنوان مدل برتر بر اساس نتایج مرحله آزمون، از این مدل برای برآورد مسیر آتی مصرف انرژی الکتریکی کشورهای منتخب تا افق ۲۰۳۵ استفاده شده است. از آنجا که مدل در مرحله آزمون دقت مناسبی در برآورد مصرف برق بر مبنای متغیرهای اقتصادی، اجتماعی و اقلیمی نشان داده است، خروجی آن برای پیش‌بینی آینده به عنوان یک سناریوی داده‌محور ارائه می‌شود. در این چارچوب، پیش‌بینی‌ها حاصل تعمیم روابط آموخته‌شده بین متغیرهای ورودی شامل POP، GDP، IMP، EXP و TEMP با متغیر خروجی (EEC) به دوره آتی هستند و الزاماً به معنای ادامه مستقیم الگوی سری زمانی مصرف برق نیستند؛ بلکه تغییرات آینده مصرف، تابعی از مسیرهای فرض شده یا برآورده شده

برای این محرک‌ها در افق پیش‌بینی خواهد بود. با این حال، باید توجه داشت که وقوع شوک‌های برون‌زا مانند تغییرات شدید سیاستی، بحران‌های اقتصادی، رخدادهای ژئوپلیتیکی یا نوسانات غیرمنتظره اقلیمی می‌تواند باعث انحراف مقادیر واقعی از مقادیر پیش‌بینی شده شود. مطابق شکل ۵، مقادیر تاریخی مصرف انرژی الکتریکی با خط آبی و مقادیر پیش‌بینی شده مدل Stack-PSO برای بازه ۲۰۲۱ تا ۲۰۳۵ با خط قرمز خط‌چین نمایش داده شده‌اند. همان‌گونه که در شکل مشاهده می‌شود، مسیرهای پیش‌بینی شده برای اغلب کشورها استمرار رشد مصرف را نشان می‌دهند، با این تفاوت که در برخی کشورها افزایش مصرف ملایم‌تر شده و الگوی نزدیک به پایداری مشاهده می‌شود، در حالی که در برخی دیگر رشد همچنان محسوس باقی مانده است. بنابراین، این شکل علاوه بر نمایش جهت کلی تغییرات، امکان مقایسه تفاوت‌های بین‌کشوری در شدت رشد یا پایداری مصرف انرژی الکتریکی را نیز فراهم می‌کند؛ تفاوتی که می‌تواند ناشی از تفاوت در روند متغیرهای محرک (جمعیتی، اقتصادی، تجاری و اقلیمی) در هر کشور باشد.



شکل ۴. مقایسه مقادیر واقعی و پیش‌بینی شده داده‌های دوره تست با استفاده از مدل Stack-PSO برای کشورهای مورد مطالعه



شکل ۵. روند مصرف انرژی الکتریکی و پیش‌بینی آن تا افق ۲۰۳۵ در کشورهای منتخب با استفاده از مدل Stack-PSO

به منظور تبیین عمیق‌تر نتایج پیش‌بینی و درک سازوکارهای اثرگذار بر مصرف انرژی الکتریکی در هر کشور، تحلیل اهمیت نسبی متغیرهای ورودی مورد توجه قرار گرفت. از آنجا که مدل Stack-PSO روابط غیرخطی بین متغیرهای اقتصادی، تجاری و اقلیمی و مصرف برق را استخراج کرده است، بررسی سهم هر یک از این متغیرها می‌تواند چارچوب تحلیلی مناسبی برای تفسیر رفتار مصرف و مسیرهای آتی آن فراهم سازد. در این راستا، شکل ۶ میزان اهمیت نسبی هر یک از ویژگی‌های ورودی را در کشورهای منتخب نمایش می‌دهد که مبنایی برای تحلیل مقایسه‌ای بین کشوری ارائه می‌کند.

در استرالیا، بیشترین اهمیت مربوط به جمعیت با مقدار $0/64$ و پس از آن، صادرات انرژی با مقدار $0/33$ گزارش شده است، در حالی که تولید ناخالص داخلی و دمای متوسط سهم محدودی دارند و اثر واردات انرژی تقریباً صفر است. این الگو بیان می‌کند که تغییرات EEC در استرالیا عمدتاً با رشد جمعیت و تا حد قابل توجهی با سازوکارهای مرتبط با صادرات انرژی توضیح داده شده است. از این‌رو، انتظار می‌رود در سناریوهایی که رشد جمعیت ادامه یابد و ساختار صادرات انرژی با تغییرات معنادار همراه شود، مسیر مصرف برق نیز متناسب با این دو محرک دچار تغییر شود، در حالی که نقش نوسانات دما یا تغییرات کوتاه‌مدت در واردات انرژی در سطح پایین‌تری قرار می‌گیرد.

در چین، تولید ناخالص داخلی با مقدار $0/52$ مهم‌ترین عامل و پس از آن واردات انرژی با مقدار $0/34$ به عنوان محرک دوم شناسایی شده است و جمعیت تنها $0/13$ اهمیت داشته، در حالی که صادرات انرژی و دمای متوسط اثر ناچیزی نشان داده‌اند. این


ساختار نشان می دهد EEC در چین بیشتر تابع سطح فعالیت اقتصادی و نیازهای تأمین انرژی از مسیر واردات بوده است. بر این اساس، رشد یا کند شدن اقتصاد و همچنین تغییر در الگوی واردات انرژی می تواند مهم ترین اهرم های تغییر مصرف برق در افق آینده تلقی شود. سهم پایین تر جمعیت نیز بیانگر آن است که اثرگذاری جمعیت در چین نسبت به شدت اثر تولید ناخالص داخلی و صادرات انرژی در مرتبه پایین تری قرار می گیرد و مصرف برق بیشتر با محرک های تولیدی و صنعتی تفسیر می شود. در آلمان، صادرات انرژی با مقدار ۰/۴۴ و تولید ناخالص داخلی با مقدار ۰/۳۳ بیشترین نقش را داشته اند و دمای متوسط نیز با مقدار ۰/۱۷ سهم قابل توجهی را نشان می دهد، در حالی که جمعیت تنها ۰/۰۵ و واردات انرژی تقریباً صفر گزارش شده است. این الگو بیانگر آن است که مصرف برق در آلمان علاوه بر پیوند با فعالیت اقتصادی، به شدت با ساختار تجارت انرژی و نیز شرایط اقلیمی حساس است. بنابراین، تغییرات سیاستی یا ساختاری در بخش انرژی و تجارت انرژی، همراه با نوسانات دمایی که بر نیاز سرمایش و گرمایش اثر دارد، می تواند تغییرات قابل ملاحظه تری در EEC ایجاد کند، حتی اگر رشد جمعیت نقش تعیین کننده ای نداشته باشد.

در ایران، جمعیت با مقدار ۰/۸۹ به صورت کاملاً غالب ظاهر شده است، در حالی که سایر متغیرها سهم بسیار کمتری دارند. این نتیجه نشان می دهد تغییرات مصرف برق در ایران عمدتاً توسط فشار تقاضای ناشی از عوامل جمعیتی توضیح داده شده است و سایر محرک ها در مقایسه با جمعیت نقش ثانویه داشته اند. در نتیجه، در سناریوهایی که رشد جمعیت یا تغییرات مرتبط با توزیع جمعیت و الگوی مصرف خانوار ادامه یابد، افزایش مصرف برق محتمل تر خواهد بود. سهم نسبتاً کوچک واردات و صادرات انرژی نیز می تواند نشان دهد متغیرهای تجاری انرژی در این چارچوب، نسبت به عامل جمعیتی اثرگذاری محدودتری داشته اند، و اثر دمای متوسط در داده های موجود به عنوان عامل تعیین کننده ظاهر نشده است.

در ترکیه، واردات انرژی با مقدار ۰/۷۳ مهم ترین عامل معرفی شده و جمعیت با ۰/۱۲ و تولید ناخالص داخلی با ۰/۱۱ در رتبه های بعدی قرار گرفته اند، در حالی که دمای متوسط و صادرات انرژی اهمیت کمی دارند. این الگو نشان می دهد مصرف برق در ترکیه به طور غالب با وابستگی به واردات انرژی و وضعیت دسترسی به منابع انرژی توضیح داده شده است. بنابراین، هرگونه تغییر در روند واردات انرژی، قیمت ها، محدودیت های تأمین، یا سیاست های مرتبط با واردات می تواند بیشترین اثر را بر مسیر EEC داشته باشد. نقش جمعیت و تولید ناخالص داخلی نیز بیانگر آن است که رشد تقاضای داخلی و توسعه اقتصادی در کنار واردات انرژی بر مصرف برق اثرگذار بوده اند، اما وزن اصلی همچنان با واردات انرژی باقی مانده است.

در ایالات متحده آمریکا، تولید ناخالص داخلی با مقدار ۰/۵۹ بیشترین اهمیت را داشته و جمعیت با مقدار ۰/۳۲ در رتبه بعدی قرار گرفته است، در حالی که صادرات، واردات انرژی و دمای متوسط سهم محدودی نشان داده اند. این ساختار نشان می دهد مصرف برق در آمریکا بیش از هر چیز تابع پویایی اقتصاد و سطح فعالیت های تولیدی و خدماتی بوده و عامل جمعیت نیز نقش قابل توجه اما ثانویه داشته است. بنابراین، در افق آینده، تغییرات در رشد اقتصادی و ساختار فعالیت های اقتصادی می تواند مهم ترین تعیین کننده تغییرات EEC تلقی شود، در حالی که متغیرهای تجاری انرژی و دما در چارچوب داده های مورد استفاده نقش تعیین کننده ای نداشته اند.

در مجموع، نتایج نشان می دهد تفاوت در محرک های غالب، دلیل اصلی تفاوت بین کشوری در رفتار مصرف انرژی الکتریکی است. به همین علت، تفسیر و سناریونویسی برای EEC در افق آینده نیز باید کشورمحور و بر اساس متغیرهای اثرگذار هر کشور انجام شود؛ به گونه ای که در ایران محور اصلی جمعیت است، در آمریکا و چین محور اصلی تولید ناخالص داخلی، در ترکیه محور اصلی واردات انرژی و در آلمان ترکیب صادرات انرژی و تولید ناخالص داخلی نقش اصلی را تشکیل می دهد.



شکل ۶. اهمیت نسبی متغیرهای ورودی در تبیین مصرف انرژی الکتریکی در کشورهای منتخب

۴. بحث و نتیجه‌گیری

در این پژوهش، چارچوبی داده‌محور برای پیش‌بینی مصرف انرژی الکتریکی در کشورهای با ساختارهای اقتصادی، اجتماعی و اقلیمی متفاوت ارائه شد که در آن، روابط غیرخطی میان متغیرهای جمعیتی، اقتصادی، تجاری و اقلیمی با استفاده از الگوریتم‌های یادگیری ماشین مدل‌سازی شد. پنج متغیر ورودی شامل POP، GDP، IMP، EXP و TEMP به عنوان محرک‌های اصلی تقاضای برق در نظر گرفته شدند و عملکرد چهار الگوریتم ANN، Ridge، Stack و Stack-PSO در مرحله آموزش و آزمون مورد مقایسه قرار گرفت.

نتایج کمی نشان داد مدل‌های منفرد ANN و Ridge اگرچه در بسیاری از کشورها دقت قابل قبولی ارائه کردند و مقادیر R^2 بالاتر از ۰/۹۵ را ثبت کردند، اما در مواجهه با ساختارهای پیچیده‌تر داده و روابط غیرخطی، محدودیت‌هایی از خود نشان دادند. در برخی موارد، ANN توانست مقادیر MSE نسبتاً پایینی ارائه دهد، اما نوسان عملکرد آن بین کشورها بیشتر مشاهده شد. از سوی دیگر، Ridge به عنوان یک مدل خطی منظم‌شده، در کشورهایی با رفتار ساختاری پایدارتر عملکرد ثابت‌تری داشت، اما در تبیین روابط غیرخطی عمیق‌تر نسبت به مدل‌های ترکیبی محدودتر ظاهر شد. مدل Stack با ترکیب خروجی‌های چند مدل پایه، بهبود محسوسی در شاخص‌های خطا ایجاد کرد و نشان داد تجمع مدل‌ها می‌تواند ضعف‌های الگوریتم‌های منفرد را جبران کند. کاهش هم‌زمان MSE و MAE نسبت به ANN و Ridge بیانگر آن بود که استفاده از رویکرد چندمدلی، قابلیت تعمیم و پایداری پیش‌بینی را افزایش می‌دهد. با این حال، بهترین عملکرد به مدل Stack-PSO اختصاص یافت؛ مدلی که در آن، ساختار استکینگ با بهینه‌سازی هایپر پارامترها از طریق الگوریتم PSO تلفیق شد. این مدل در اکثر موارد کمترین MSE را ثبت کرده و مقادیر R^2 نزدیک به ۰/۹۹ را نشان داده است که بیانگر قدرت تبیین بسیار بالا و کاهش قابل توجه خطای پیش‌بینی است.

از منظر کیفی نیز نتایج نشان داد ترکیب یادگیری جمعی و بهینه‌سازی فراابتکاری، توانسته است روابط پیچیده میان محرک‌های اقتصادی، جمعیتی و اقلیمی با مصرف انرژی الکتریکی را دقیق‌تر استخراج کند. به‌ویژه در کشورهایی که یک متغیر غالب مانند تولید ناخالص داخلی یا جمعیت سهم بالایی در تبیین مصرف داشت، مدل Stack-PSO توانست حساسیت مناسب به این محرک‌ها را حفظ کرده و هم‌زمان اثر متغیرهای مکمل را نیز در ساختار پیش‌بینی لحاظ کند. این ویژگی موجب شد

مسیرهای پیش بینی شده از انسجام ساختاری و سازگاری اقتصادی بیشتری برخوردار باشند. در مجموع، مقایسه الگوریتم ها نشان داد هرچه ساختار مدل از حالت تک مدلی خطی به سمت مدل های تجمیعی و بهینه شده حرکت کرده، دقت پیش بینی به صورت معناداری افزایش یافته است. بنابراین، رویکرد Stack-PSO نه تنها از نظر شاخص های آماری عملکرد برتری ارائه کرده، بلکه از منظر تحلیلی نیز چارچوبی منعطف تر و سازگارتر با واقعیت های اقتصادی و انرژی کشورهای مختلف فراهم آورده است. این یافته ها بیانگر آن است که استفاده از مدل های هیبریدی بهینه شده می تواند ابزاری برای برنامه ریزی بلندمدت انرژی و تصمیم سازی سیاستی در حوزه برق محسوب شود. اما با وجود عملکرد مناسب مدل پیشنهادی، این پژوهش دارای محدودیت هایی است. استفاده از داده های سالانه و تعداد محدود متغیرهای ورودی ممکن است موجب عدم پوشش کامل برخی عوامل تأثیرگذار بر مصرف انرژی شود. همچنین، فرض پایداری روابط طی زمان و استفاده از مدل NARX برای پیش بینی متغیرهای آینده، می تواند عدم قطعیت را در پیش بینی های بلندمدت افزایش دهد. در پژوهش های آینده، استفاده از داده های با تفکیک پذیری بالاتر، افزودن متغیرهای مؤثر بیشتر (مانند قیمت انرژی و سیاست ها)، و به کارگیری روش های تحلیل عدم قطعیت و پیش بینی احتمالاتی پیشنهاد می شود.

منابع

- [1] E. A. Hamedani, P. Khodaparast, E. Hosseini, T. Mahmudy, and A. B. Yajloo, "A mini-review of energy hub: Concept, components, classifications, and applications," *Energy Reports*, vol. 15, p. 108886, 2026, doi: <https://doi.org/10.1016/j.egy.2025.12.023>.
- [2] B. Gajdzik, R. Wolniak, R. Nagaj, B. Żuromskaitė-Nagaj, and W. W. Grebski, "The influence of the global energy crisis on energy efficiency: A comprehensive analysis," *Energies*, vol. 17, no. 4, p. 947, 2024, doi: <https://doi.org/10.3390/en17040947>.
- [3] E. Abbasian Hamedani, A. Bahrami Yajloo, and S. Talebi, "A comprehensive review on carbon capture, transportation, storage, and utilization technologies; part I: Carbon capture technologies," *Advances in Energy Sciences and Technologies*, vol. 1, no. 1, pp. 119–132, 2025, doi: <https://doi.org/10.22060/aest.2025.5755>.
- [4] R. Mokhtari, N. Mirzaei, S. Ebrahimi Zaker, and M. Abdoos, "Multi-Criteria GIS Analysis of Solar Energy Deployment in Alborz Province: A Case Study on 10 MW PV Plant Siting and Environmental Impact," *Journal of sustainable Energy Systems*, vol. 5, no. 1, pp. 107–119, 2026, doi: 10.22059/ses.2025.394064.1138.
- [5] A. B. Yajloo and E. A. Hamedani, "Simulation of a solar-based small-scale green hydrogen production unit in Iran: A techno-economic-feasibility analysis," *Results in Engineering*, p. 106734, 2025, doi: <https://doi.org/10.1016/j.rineng.2025.106734>.
- [6] E. Köse and S. Kutlu Kaynar, "Energy Demand Forecasting and Policy Development in Turkey," *Energies*, vol. 18, no. 13, p. 3301, 2025, doi: <https://doi.org/10.3390/en18133301>.
- [7] A. B. Yajloo, S. Setayeshi, M. Hosseinpour, and M. Fakhroleslam, "Superstructure optimization of sustainable formic acid synthesis from hydrogen and carbon dioxide: a scenario-based approach," *Journal of Cleaner Production*, vol. 555, p. 148048, 2026, doi: <https://doi.org/10.1016/j.jclepro.2026.148048>.
- [8] "IEA (2024), Electricity 2024, IEA, Paris <https://www.iea.org/reports/electricity-2024>, Licence: CC BY 4.0." (accessed).
- [9] "IEA (2025), Electricity Mid-Year Update 2025, IEA, Paris <https://www.iea.org/reports/electricity-mid-year-update-2025>, Licence: CC BY 4.0".
- [10] E. A. Hamedani, A. R. Araghi, A. Hajinezhad, and H. Yousefi, "A Scenario-Based Techno-Economic Optimization Framework for Power-to-X Residential Energy Hubs Across Diverse Climate Conditions," *Energy*, p. 141155, 2026.
- [11] O. Gulaydin and M. Mourshed, "Machine learning for subnational residential electricity demand forecasting to 2050 under shared socioeconomic pathways: Comparing tree-based, neural and kernel methods," *Energy*, p. 138195, 2025, doi: <https://doi.org/10.1016/j.energy.2025.138195>.
- [12] M. M. Alam, S. Aryal, and Q. K. Hassan, "Shifting Electricity Demand Under Temperature Extremes in Bangladesh," *Earth*, vol. 6, no. 4, p. 127, 2025, doi: <https://doi.org/10.3390/earth6040127>.
- [13] M. Hasan *et al.*, "A state-of-the-art comparative review of load forecasting methods: Characteristics, perspectives, and applications," *Energy Conversion and Management: X*, p. 100922, 2025, doi: <https://doi.org/10.1016/j.ecmx.2025.100922>.
- [14] J. W. Chan and C. K. Yeo, "A transformer based approach to electricity load forecasting," *The Electricity Journal*, vol. 37, no. 2, p. 107370, 2024, doi: <https://doi.org/10.1016/j.tej.2024.107370>.
- [15] Y. Eren and İ. Küçükdemir, "A comprehensive review on deep learning approaches for short-term load forecasting," *Renewable and Sustainable Energy Reviews*, vol. 189, p. 114031, 2024, doi: <https://doi.org/10.1016/j.rser.2023.114031>.
- [16] M. Rezaeifard and Y. Noorollahi, "A Forecast on Natural Gas Consumption in Iran until 2042 Utilizing the ARIMA Model," *Journal of sustainable Energy Systems*, vol. 4, no. 2, pp. 197–211, 2025, doi: 10.22059/ses.2025.389042.1116.
- [17] S. Zhou, "The effect of smart meter penetration on dynamic electricity pricing: Evidence from the United States," *The Electricity Journal*, vol. 34, no. 3, p. 106919, 2021, doi: <https://doi.org/10.1016/j.tej.2021.106919>.

- [18] C. Tarmanini, N. Sarma, C. Gezegegn, and O. Ozgonenel, "Short term load forecasting based on ARIMA and ANN approaches," *Energy Reports*, vol. 9, pp. 550–557, 2023, doi: <https://doi.org/10.1016/j.egy.2023.01.060>.
- [19] E. A. M. Cruz, L. A. H. Armenta, and M. Badaoui, "Seasonal Forecasting of Peak Electricity Demand Using Spectral Analysis ", *Results in Engineering*, p. 107338, 2025, doi: <https://doi.org/10.1016/j.rineng.2025.107338>.
- [20] D. Kamani and M. Ardehali, "Long-term forecast of electrical energy consumption with considerations for solar and wind energy sources," *Energy*, vol. 268, p. 1, ۲۰۲۳, ۲۶۶۱۷, doi: <https://doi.org/10.1016/j.energy.2023.126617>.
- [21] S. H. A. Kaboli, J. Selvaraj, and N. Rahim, "Long-term electric energy consumption forecasting via artificial cooperative search algorithm," *Energy*, vol. 115, pp. 857–871, 2016, doi: <https://doi.org/10.1016/j.energy.2016.09.015>.
- [22] D. H. Wolpert, "Stacked generalization," *Neural networks*, vol. 5, no. 2, pp. 241–259, 1992, doi: [https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1).
- [23] I. D. Mienye and Y. Sun, "A survey of ensemble learning: Concepts, algorithms, applications, and prospects," *Ieee Access*, vol. 10, pp. 99129–99149, 2022, doi: 10.1109/ACCESS.2022.3207287.
- [24] D. Wood, T. Mu, A. M. Webb, H. W. Reeve, M. Luján, and G. Brown, "A unified theory of diversity in ensemble learning," *Journal of machine learning research*, vol. 24, no. 359, pp. 1–49, 2023.
- [25] T. G. Dietterich, "An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization," *Machine learning*, vol. 40, no. ۲, pp. 139–157, 2000, doi: <https://doi.org/10.1023/A:1007607513941>.
- [26] J. Shi, C. Li, and X. Yan, "Artificial intelligence for load forecasting: A stacking learning approach based on ensemble diversity regularization," *Energy*, vol. 262, p. 125295, 2023, doi: <https://doi.org/10.1016/j.energy.2022.125295>.
- [27] M. Abbas, Y. Che, and I. U. Khan, "A Novel Stacked Ensemble Framework with the Kolmogorov-Arnold Network for Short-Term Electric Load Forecasting," *Energy*, p. 137216, 2025, doi: <https://doi.org/10.1016/j.energy.2025.137216>.
- [28] S. Reddy, S. Akashdeep, R. Harshvardhan, and S. Kamath, "Stacking Deep learning and Machine learning models for short-term energy consumption forecasting," *Advanced Engineering Informatics*, vol. 52, p. 101542, 2022, doi: <https://doi.org/10.1016/j.aei.2022.101542>.
- [29] M. A. Khairalla, X. Ning, N. T. Al-Jallad, and M. O. El-Faroug, "Short-term forecasting for energy consumption through stacking heterogeneous ensemble learning model," *Energies*, vol. 11, no. 6, p. 1605, 2018, doi: <https://doi.org/10.3390/en11061605>.
- [30] R. Mohan and N. Pachauri, "An ensemble model for the energy consumption prediction of residential buildings," *Energy*, vol. 314, p. 134255, 2025, doi: <https://doi.org/10.1016/j.energy.2024.134255>.
- [31] J. Zupan, "Introduction to artificial neural network (ANN) methods: what they are and how to use them," *Acta Chimica Slovenica*, vol. 41, no. 3, p. 327, 1994.
- [32] A. M. Haddadi and H. Hamidi, "A hybrid model for improving customer lifetime value prediction using stacking ensemble learning algorithm," *Computers in Human Behavior Reports*, vol. 18, p. 100616, 2025, doi: <https://doi.org/10.1016/j.chbr.2025.100616>.
- [33] E. A. Hamedani and S. Talebi, "Modeling and long-term forecasting of CO2 emissions in Asia: An optimized Artificial Neural Network approach with consideration of renewable energy scenarios," *Energy Conversion and Management: X*, vol. 26, p. 101030, 2025, doi: <https://doi.org/10.1016/j.ecmx.2025.101030>.
- [34] A. Bahrami Yajloo, E. Abbasian Hamedani, P. Maleki, and M. Hosseinpour, "Optimization of economic dispatch for distributed generation-based power networks," *Advances in Energy Sciences and Technologies*, vol. 1, no. 3, pp. 266–279, 2025.
- [35] T. Liu, W. Jiao, Z. Huang, J. Yu, X. Zhang, and L. Li, "A short-term load forecasting framework for air conditioning system based on model stacking," *Scientific Reports*, vol. 15, no. 1, p. 36892, 2025, doi: <https://doi.org/10.1038/s41598-025-20929-3>.

- [36] R. K. Paul *et al.*, "Wavelet decomposition and machine learning technique for predicting occurrence of spiders in pigeon pea," *Agronomy*, vol. 12, no. 6, p. 1429, 2022, doi: <https://doi.org/10.3390/agronomy12061429>.
- [37] R. Şener, M. A. Koç, and K. Ermiş, "Hybrid ANFIS-PSO algorithm for estimation of the characteristics of porous vacuum preloaded air bearings and comparison performance of the intelligent algorithm with the ANN," *Engineering Applications of Artificial Intelligence*, vol. 128, p. 107460, 2024, doi: <https://doi.org/10.1016/j.engappai.2023.107460>.
- [38] A. Nouri, A. Lachheb, and L. El Amraoui, "Optimizing efficiency of Vehicle-to-Grid system with intelligent management and ANN-PSO algorithm for battery electric vehicles," *Electric Power Systems Research*, vol. 226, p. 109936, 2024.