

Intelligent Forecasting of Urban Gas Consumption Using LSTM Neural Networks and Weather Variables

Mahdieh Salary,¹ Najme Mansouri,^{2*} Behnam MohammadHasaniZade,³ Seyed Mohammad Mahdi Hosseini⁴

¹Faculty of Mathematics and Computer Science, Martyr Bahonar, Kerman, Iran, mahdiehsalary1378@math.uk.ac.ir

²Faculty of Mathematics and Computer Science, Martyr Bahonar, Kerman, Iran, n.mansouri@uk.ac.ir

³Faculty of Mathematics and Computer Science, Martyr Bahonar, Kerman, Iran, behnam.m.s@math.uk.ac.ir

⁴Faculty of Mathematics and Computer Science, Martyr Bahonar, Kerman, Iran, mhosseini@uk.ac.ir

Keywords:

Time series,
Energy demand,
Artificial neural network,
Long Short Term Memory model,
Sine Cosine Algorithm,
Variable Mode Decomposition.

Original Research Article

Paper History:

Received: 10/04/2025

Revise: 29/04/2025

Accepted: 27/09/2025

Abstract: One of the main challenges in energy resource management is accurately predicting demand to reduce production and storage costs. The time-series behavior of gas demand is highly complex and nonlinear due to the influence of variables such as weather conditions, prices, and population. In this study, a hybrid model based on Long Short-Term Memory (LSTM) neural networks, combined with the Variational Mode Decomposition (VMD) algorithm and the Cosine-Sine Algorithm (SCA), is proposed. The VMD algorithm decomposes time-series data and extracts the main components, while the SCA optimizes the parameters of the LSTM network to improve prediction accuracy. The prediction accuracy of the model is evaluated using metrics such as Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE), and its performance is compared with three benchmark models: the simple LSTM neural network, the Support Vector Regression (SVR) model, and the Autoregressive Integrated Moving Average (ARIMA) model. The results show that the proposed model provides higher accuracy than other models and can be used as an efficient tool for energy resource planning and management.

How to cite this article: Salary, M., Mansouri, N., MohammadHasaniZade, B., Hosseini, M.M., "Intelligent Forecasting of Urban Gas Consumption Using LSTM Neural Networks and Weather Variables", Energy Engineering and Management, Vol. 15, No. 1, PP. 2-19, 2025. <https://doi.org/10.22052/EEM.2025.256659.1111>
© 2023 University of Kashan Press.

This is an open access article under the CC BY license.(<http://creativecommons.org/licenses/by/4.0/>)



Extended Abstract

Introduction

Natural gas, as a clean and efficient energy source, plays a vital role in economic development and energy supply. With the growing demand driven by urbanization and industrial expansion, accurate forecasting of gas consumption is essential for effective resource management and distribution. This

study proposes a hybrid model that integrates a Long Short-Term Memory (LSTM) network, Variable Mode Decomposition (VMD), and the Sine-Cosine Algorithm (SCA) to enhance the accuracy of residential and commercial gas demand predictions. The findings can support optimal decision-making in energy policy and resource allocation.

Materials and methods

This study employs a hybrid forecasting approach that integrates a Long Short-Term Memory (LSTM) network, Variable Mode Decomposition (VMD), and the Sine-Cosine Algorithm (SCA) to enhance the accuracy of gas demand predictions. Additionally, the Monte Carlo method is utilized to estimate forecasting uncertainties and improve the reliability of predictions. The model is trained and validated using gas demand data from Iran and the state of Pennsylvania, incorporating temperature as an auxiliary variable. This inclusion helps capture the seasonal variations in gas consumption, particularly during colder months, thereby improving forecasting precision.

Result

The results of this study demonstrated that the proposed hybrid model, utilizing LSTM, VMD, and SCA algorithms, significantly improved the accuracy of gas demand forecasting, reducing prediction errors by up to 99.99%. The use of the Monte Carlo method also contributed to better estimation of forecasts. Furthermore, incorporating gas demand data with temperature as an auxiliary variable played a crucial role in capturing seasonal consumption fluctuations. This model can effectively optimize energy resource management, enable more precise gas distribution planning, and reduce operational costs, particularly during colder months.

Discussion and Conclusion

This study presents a hybrid model incorporating LSTM, VMD, and SCA for forecasting gas demand, with results showing a significant improvement in prediction accuracy compared to previous methods. The proposed model, using gas demand data along with temperature as an auxiliary variable, effectively captured seasonal consumption fluctuations and enhanced the forecasting precision. Additionally, the application of the Monte Carlo method for estimating forecast uncertainties strengthened the reliability of the model's results. The findings of this study indicate that the proposed model, in addition to significantly reducing prediction errors, can be effective in optimizing energy resource management, particularly during periods of fluctuating demand in colder months. Therefore, this model can serve as a valuable tool for gas suppliers and policymakers to enable more precise planning for energy distribution and consumption, helping to prevent resource wastage. Based on the obtained results, it is suggested that future studies explore the impact of other environmental and economic variables on gas demand to further improve model accuracy. Furthermore, evaluating the model's performance across different scales and geographical regions could help generalize and enhance the applicability of this approach.

پیش‌بینی هوشمند مصرف گاز شهری با بهره‌گیری از شبکه عصبی LSTM و متغیرهای آب‌وهوایی

مهديه سالاری^۱، نجمه منصوری^۲، بهنام محمدحسینی‌زاده^۳، محمدمهدی حسینی^۴

^۱ دانشجوی کارشناسی‌ارشد، گروه ریاضی کاربردی، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر، کرمان، ایران،

mahdiehsalary1378@math.uk.ac.ir

^۲ دانشیار، گروه علوم کامپیوتر، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر، کرمان، ایران، n.mansouri@uk.ac.ir

^۳ دکتری، گروه علوم کامپیوتر، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر، کرمان، ایران، behnam.m.s@math.uk.ac.ir

^۴ استاد، گروه ریاضی کاربردی، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر، کرمان، ایران، mhosseini@uk.ac.ir

واژه‌های کلیدی:

سری زمانی،

تقاضای انرژی،

شبکه عصبی مصنوعی،

مدل حافظه طولانی کوتاه‌مدت،

الگوریتم کسینوس-سینوسی،

الگوریتم تجزیه حالت متغیر.

مقاله علمی پژوهشی

چکیده: یکی از چالش‌های اصلی مدیریت منابع انرژی، پیش‌بینی دقیق تقاضا به‌منظور کاهش هزینه‌های تولید و ذخیره‌سازی است. رفتار سری زمانی تقاضای گاز، به‌دلیل تأثیر متغیرهایی چون شرایط آب‌وهوایی، قیمت و جمعیت، بسیار پیچیده و غیرخطی است. در این پژوهش، یک مدل ترکیبی بر شبکه عصبی حافظه طولانی کوتاه‌مدت همراه با الگوریتم تجزیه حالت متغیر و الگوریتم کسینوس-سینوسی ارائه شده است. الگوریتم تجزیه حالت متغیر به تجزیه داده‌های سری زمانی و استخراج مؤلفه‌های اصلی می‌پردازد و الگوریتم کسینوس-سینوسی، بهینه‌سازی پارامترهای شبکه حافظه طولانی کوتاه‌مدت را برای افزایش دقت پیش‌بینی انجام می‌دهد. همچنین، در این پژوهش، علاوه‌بر ترکیب الگوریتم‌های فراابتکاری، تأثیر متغیرهای آب‌وهوایی در بهبود عملکرد شبکه نیز بررسی شده است. دقت پیش‌بینی مدل با استفاده از معیارهایی مانند ریشه میانگین مربعات خطا، میانگین مطلق خطا و درصد میانگین مطلق خطا در مقایسه با شبکه عصبی حافظه طولانی کوتاه‌مدت ساده، مدل رگرسیون بردار پشتیبان و مدل میانگین متحرک یکپارچه اتورگرسیون ارزیابی شده است. نتایج نشان می‌دهد که مدل پیشنهادی توانسته است دقت بالاتری نسبت به سایر مدل‌ها ارائه دهد و همچنین در برنامه‌ریزی و مدیریت منابع انرژی به‌عنوان ابزاری کارآمد مورد استفاده قرار گیرد.

تاریخ دریافت: ۱۴۰۴/۰۱/۲۱

تاریخ بازنگری: ۱۴۰۴/۰۲/۰۹

تاریخ پذیرش: ۱۴۰۴/۰۷/۰۵

۱. مقدمه

انرژی، به‌ویژه گاز طبیعی، یکی از عوامل کلیدی توسعه اقتصادی و اجتماعی است. این انرژی نقش حیاتی در تأمین نیازهای روزمره، صنعتی و اقتصادی ایفا می‌کند. گاز طبیعی به‌دلیل مزایای زیست‌محیطی مطلوب، کارایی بالا و هزینه کمتر نسبت به دیگر منابع انرژی، به‌عنوان جایگزین پاک و مؤثری برای نفت خام شناخته می‌شود [۱]. با توجه به رشد جمعیت، گسترش شهرنشینی و توسعه صنعتی، تقاضا برای گاز طبیعی به‌طور پیوسته افزایش یافته است. پیش‌بینی دقیق تقاضای گاز برای مدیریت تأمین و توزیع منابع انرژی ضروری است. این پیش‌بینی به‌ویژه در مواجهه با نوسانات فصلی تقاضای گاز، به‌خصوص در فصل‌های سرد، چالش‌های زیادی ایجاد می‌کند که بر تعادل عرضه و تقاضا و سیاست‌گذاری‌های اقتصادی تأثیرگذار است [۲ و ۳]. هدف این پژوهش، ارائه مدلی ترکیبی با بهره‌گیری از شبکه عصبی حافظه طولانی کوتاه‌مدت،^۱ الگوریتم تجزیه حالت متغیر^۲ و الگوریتم کسینوس-سینوسی^۳ برای پیش‌بینی دقیق‌تر تقاضای گاز خانگی و تجاری است.

در سال‌های اخیر، محققان با ارائه مدل‌های مختلف همراه با الگوریتم‌های بهینه‌ساز، تلاش در پیش‌بینی تقاضای انواع انرژی داشته‌اند. در پژوهشی با عنوان «پیش‌بینی انرژی باد چندمرحله‌ای براساس رویکرد ترکیبی حافظه طولانی کوتاه‌مدت و الگوریتم تجزیه حالت متغیر»^۴، رویکرد ترکیبی^۵ شامل ادغام شبکه حافظه طولانی کوتاه‌مدت و الگوریتم تجزیه حالت متغیر ارائه شد [۴]. در پژوهشی دیگر با عنوان «پیش‌بینی سری زمانی مالی با یادگیری عمیق»^۶ یک بررسی نظام‌مند از ادبیات (۲۰۰۵-۲۰۱۹)، شبکه عصبی بازگشتی^۷، شبکه عصبی حافظه طولانی کوتاه‌مدت، شبکه عصبی پیچشی^۸ و سایر روش‌ها بررسی شدند. در این مطالعه، شبکه حافظه طولانی کوتاه‌مدت به‌عنوان یکی از مناسب‌ترین گزینه‌ها برای پیش‌بینی سری‌های زمانی معرفی و پیشنهاد شده است؛ زیرا در مقایسه با سایر مدل‌ها، عملکرد بهتری در شناسایی وابستگی‌های زمانی بلندمدت و الگوهای پیچیده دارد [۵]. همچنین در پژوهشی با عنوان «مدل‌های رگرسیون سیگموئید^۹ و شبکه عصبی مصنوعی^{۱۰} برای پیش‌بینی مصرف روز

آینده گاز طبیعی»، از روش‌های شبکه عصبی مصنوعی و رگرسیون سیگموئید برای پیش‌بینی دقیق مصرف گاز طبیعی استفاده شده است [۲]. پژوهشی دیگر با هدف توسعه روشی برای پیش‌بینی سری‌های زمانی تجزیه و تحلیل گاز محلول^{۱۱}، از مدل میانگین متحرک یکپارچه اتورگرسیون^{۱۲} به‌همراه الگوریتم بهینه‌ساز شکارچیان دریایی دودویی^{۱۳} استفاده شده است. این پژوهش با عنوان «مدل پیش‌بینی سری زمانی مبتنی بر مدل ترکیبی الگوریتم تجزیه حالت متغیر و مدل خودرگرسیون میانگین متحرک و کاربرد آن در تجزیه و تحلیل گازهای محلول» ارائه شد [۶]. در پژوهشی بعدی با عنوان «پیش‌بینی بار کوتاه‌مدت براساس شبکه‌های عصبی عمیق پیچشی و شبکه عصبی حافظه طولانی کوتاه‌مدت»، با بهره‌گیری از این دو نوع شبکه، به پیش‌بینی تولید برق کوتاه‌مدت پرداخته شده است. تمرکز این مطالعه در تأثیر تعداد لایه‌ها بر دقت پیش‌بینی است [۷]. همچنین در پژوهشی با عنوان «پیش‌بینی مصرف انرژی در ساختمان‌های پردیس با استفاده از حافظه کوتاه‌مدت»، با بهره‌گیری از داده‌های آب‌وهوایی عملکرد مدل‌های حافظه طولانی کوتاه‌مدت، رگرسیون بردار پشتیبان^{۱۴} و رگرسیون فرایند گاوسی^{۱۵} برای پیش‌بینی دقیق مصرف انرژی بررسی شده است. نتایج نشان می‌دهد که عواملی مانند دما و میزان بارندگی، تأثیر بسزایی در دقت پیش‌بینی دارند [۸]. در مطالعه‌ای دیگر با عنوان «پیش‌بینی انرژی چندمتغیره از طریق حافظه طولانی کوتاه‌مدت تنظیم‌شده فراابتکاری و شبکه‌های عصبی واحد بازگشتی دروازه‌دار»^{۱۶}، از یک روش نوین هوش مصنوعی برای حل مشکل تأمین انرژی برق که بحرانی روزافزون است، استفاده شده است. این رویکرد شامل یک الگوریتم ترکیبی، شامل الگوریتم جست‌وجوی بهینه‌ساز عقب‌گرد و الگوریتم کسینوس-سینوسی خودتطبیقی^{۱۷} برای تنظیم ابرپارامترهای مدل است [۹]. در پژوهشی با عنوان «پیش‌بینی تقاضای انرژی با استفاده از شبکه عصبی پیچشی و الگوریتم بهینه‌سازی استراتژی جنگ^{۱۸} اصلاح‌شده»، از ترکیب شبکه عصبی پیچشی و الگوریتم بهینه‌ساز برای پیش‌بینی تقاضای انرژی بهره گرفته شده است [۱۰]. در نهایت، در پژوهشی با عنوان «پیش‌بینی بار کوتاه‌مدت مبتنی بر داده با شبکه‌های عصبی عمیق: گشایش بینش‌هایی

10. Artificial neural network
11. Dissolved Gas Analysis (DGA)
12. Autoregressive Integrated Moving Average (ARIMA)
13. Binary Marine Predator Algorithm (BMPA)
14. Support Vector Regression (SVR)
15. Gaussian Process Regression (GPR)
16. Gated Recurrent Unit (GRU)
17. Backtracking Search Optimization-Algorithm-Sine Cosine Algorithm (BSO-SCA)
18. Modified War Strategy Optimization Algorithm

1. Long Short Term Memory (LSTM)
2. Variational Mode Decomposition (VMD)
3. Sine Cosine Algorithm (SCA)
4. Variational Mode Decomposition-Long Short Term Memory (VMD-LSTM)
5. Mixed Method Approach
6. Deep Learning Method (DL)
7. Feed Back Networks
8. Convolution Neural Network (CNN)
9. Sigmoid Regression Model

از جمله قابلیت‌های کلیدی آن‌ها، تعمیم روابط یادگرفته شده از داده‌های آموزشی به داده‌های جدید و نادیده است؛ امری که موجب کاربرد گسترده این شبکه‌ها در تحلیل تقاضا، مدل‌سازی‌های اقتصاد و سایر حوزه‌های علمی شده است. به کارگیری الگوریتم‌های بهینه‌سازی مناسب برای تنظیم پارامترهای شبکه، نقش بسزایی در افزایش دقت و کارایی آن ایفا می‌کند [۱۲ و ۱۳].

۱.۲ شبکه عصبی حافظه طولانی کوتاه مدت

شبکه‌های عصبی حافظه طولانی کوتاه مدت، نوعی از شبکه بازگشتی هستند که توانایی ذخیره‌سازی اطلاعات کوتاه مدت و بلند مدت را دارند. این شبکه‌ها برای حل مسائل پیچیده‌ای مانند تحلیل پیش‌بینی‌کننده و تحلیل سری‌های زمانی مالی کاربرد فراوانی یافته‌اند [۵ و ۱۴]. ساختار شبکه‌های عصبی حافظه طولانی کوتاه مدت شامل سلول‌های حافظه و دروازه‌های ورودی، خروجی و فراموشی است که وظیفه تنظیم جریان اطلاعات را بر عهده دارند. دروازه فراموشی وظیفه حذف اطلاعات غیر ضروری را بر عهده دارد. دروازه ورودی اطلاعات ارزشمند جدید را ذخیره می‌کند، دروازه خروجی تعیین می‌کند که کدام داده به خروجی منتقل شود. تصمیم‌گیری در این فرایند، به حالت‌های پنهان ورودی و خروجی در زمان‌های مختلف h_{t-1} و h_t وابسته است و این وابستگی با معادلات ریاضی، نظیر محاسبه فعال‌سازی دروازه فراموشی کنترل می‌شوند [۱۵ و ۱۶].

$$f_t = \sigma(X_t U_f + h_{t-1} W_f + b_f) \quad (1)$$

خروجی معادله (۱)، مقداری بین ۰ و ۱ دارد؛ عدد ۰ نشان‌دهنده حذف کامل اطلاعات و عدد ۱ معادل حفظ کامل اطلاعات است. در معادله (۱)، U_f و W_f ماتریس‌های وزن دروازه فراموشی، b_f مقدار بایاس و عبارت σ تابع سیگموئید است که به تنظیم جریان اطلاعات کمک می‌کنند. دروازه ورودی (i_t) نیز شامل دو بخش است: لایه سیگموئید، که مشخص می‌کند کدام بخش از اطلاعات ورودی باید ذخیره یا به روزرسانی شود؛ و لایه تانژانت هائپربولیک، که برداری از حالت سلول ($\tilde{C}_t$) را تولید و به حافظه اضافه می‌کند. این فرایند با ترکیب خروجی دو لایه مذکور در معادلات (۲) و (۳)، موجب افزایش ظرفیت شبکه در یادگیری و تنظیم دقیق اطلاعات می‌شود.

$$i_t = \sigma(X_t U_i + h_{t-1} W_i + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(X_t U_c + h_{t-1} W_c + b_c) \quad (3)$$

در معادلات (۲) و (۳)، U_i و W_i به عنوان ماتریس‌های وزن دروازه ورودی i_t عمل می‌کنند و تابع فعال‌ساز قبلی و $\tilde{C}_t$ نشان‌دهنده وضعیت سلول در لحظه فعلی است. تابع فعال‌ساز^۱ به کاررفته در این

برای مدیریت پایدار انرژی، از رویکرد ترکیبی شامل شبکه عصبی حافظه طولانی کوتاه مدت و واحد بازگشتی دروازه دار برای تنظیم پارامترها و پیش‌بینی تقاضای کوتاه مدت بار استفاده شده است [۱۱]. با وجود این پیشرفت‌ها در مدل‌های پیش‌بینی، هنوز در بسیاری از پژوهش‌ها محدودیت‌هایی در پیش‌بینی دقیق تقاضای انرژی، به ویژه مصرف گاز وجود دارد. یکی از چالش‌های عمده در پیش‌بینی تقاضای گاز، پیچیدگی و غیرخطی بودن رفتارهای آن است. مدل‌های پیشین که به طور عمده بر اساس رگرسیون‌های خطی یا شبکه‌های عصبی ساده طراحی شده‌اند، قادر به مدل‌سازی روابط پیچیده و غیرخطی بین عوامل مختلف تأثیرگذار مانند تغییرات دما، زمان، روندهای اقتصادی و رفتار مصرف‌کنندگان نیستند. به طور خاص، استفاده از مدل‌های شبکه عصبی مصنوعی، به رغم موفقیت‌های نسبی، با مشکلاتی همچون محوشدگی گرادیان مواجه است که منجر به کاهش دقت پیش‌بینی می‌شود، به ویژه زمانی که داده‌ها غیرخطی و نوسانی باشند. محوشدگی گرادیان پدیده‌ای است که در آن، هنگام بازگشت گرادیان‌ها به لایه‌های اولیه در شبکه‌های عصبی عمیق، مقادیر آن‌ها به شدت کاهش می‌یابد. این موضوع باعث می‌شود پارامترهای لایه‌های ابتدایی تقریباً بدون تغییر باقی بمانند و در نتیجه مدل نتواند اطلاعات مفید را از داده‌های قبلی یاد بگیرد. در مقابل، انفجار گرادیان منجر به بزرگ شدن بیش از حد گرادیان‌ها و ناپایداری در فرایند آموزش می‌شود. شبکه حافظه طولانی کوتاه مدت قادر است اطلاعات مهم را برای مدت طولانی‌تری حفظ کند و از محوشدگی یا انفجار گرادیان جلوگیری نماید. در این پژوهش از ترکیب شبکه عصبی حافظه طولانی کوتاه مدت، الگوریتم تجزیه حالت متغیر و بهینه‌ساز کسینوس-سینوسی استفاده شده است. این ترکیب به تحلیل داده‌های پیچیده و غیرخطی کمک می‌کند و با بهینه‌سازی پارامترهای مدل، دقت پیش‌بینی را افزایش می‌دهد. داده‌های دمایی و تقاضای گاز از مناطق مختلف، مانند ایالت پنسیلوانیا و شهر سیرجان، به عنوان ورودی مدل استفاده شده‌اند. نتایج نشان می‌دهند که این روش توانسته است روابط پیچیده میان تغییرات دما و تقاضای گاز را شبیه‌سازی کرده و ابزاری مؤثر برای مدیریت انرژی و پیش‌بینی تقاضا مؤثر ارائه دهد.

۲. مروری بر روش‌های مورد استفاده

شبکه‌های عصبی مصنوعی از جمله روش‌های مدرن یادگیری ماشین هستند که با الهام از ساختار عصبی مغز انسان توسعه یافته‌اند. این شبکه‌ها با بهره‌گیری از نورون‌های به هم پیوسته، قادر به شناسایی روابط خطی و غیرخطی میان داده‌های ورودی و خروجی‌ها هستند.

شامل دو مرحله اصلی است که در گام نخست، مسئله بهینه‌سازی برای تعیین تغییرات دامنه و فرکانس تدوین می‌شود و در ادامه، راه‌حل بهینه از طریق تکرارهای محاسباتی به دست می‌آید. برای هر تابع مد $u_k(t)$ ، سیگنال تحلیلی متناظر با استفاده از تبدیل هیلبرت محاسبه و طیف یک‌طرفه آن استخراج می‌شود [۶]:

$$\left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) \quad (۷)$$

برای هر تابع مد $u_k(t)$ طیف فرکانسی آن به باند پایه متناظر با فرکانس مرکزی خود w_k منتقل می‌شود. این انتقال با ضرب سیگنال در تابع نمایی $e^{-jw_k t}$ صورت می‌گیرد، که در آن w_k نشان‌دهنده فرکانس مرکزی مد $u_k(t)$ است. این فرایند به صورت رابطه (۸) بیان می‌شود:

$$\left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-jw_k t} \quad (۸)$$

این تبدیل، طیف سیگنال را به ناحیه فرکانسی پایین‌تری منتقل می‌کند تا امکان فیلترگذاری و تحلیل بهتر هر مد فراهم شود. برای تخمین پهنای باند هر سیگنال مد، از روش هموارسازی گاوسی برای سیگنال آشکارسازی شده استفاده می‌شود. سپس، مسئله تغییرات با در نظر گرفتن قیود لازم حل می‌شود. در روش تجزیه حالت متغیر، وضعیت‌ها و فرکانس‌های مرکزی آن‌ها با استفاده از یک ضرب‌کننده جهت متناوب به‌روز می‌شوند. تابع هدف در این روش به صورت زیر تعریف می‌شود [۶]:

$$\left\{ \begin{array}{l} \min_{\{u_k\}} \left\{ \sum_{k=1}^K \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-jw_k t} \right\} \\ \text{s.t.} \sum_{k=1}^K u_k(t) = f(t) \end{array} \right. \quad (۹)$$

که عبارت $\delta(t)$ تابع دلتای دیراک است. همچنین: $u_k = u_1, u_2, \dots, u_k; w_k = w_1, w_2, \dots, w_k$. هستند. فرایند حل مسئله تغییرات به صورت زیر انجام می‌شود: برای تبدیل مسئله مقید به یک مسئله تغییرات نامقید، از عوامل جریمه درجه دوم α و عملگرهای ضرب لاگرانژ $\lambda(t)$ استفاده می‌شود. در این فرایند، پارامتر α برای تضمین دقت بازسازی سیگنال و $\lambda(t)$ به منظور حفظ قیود مسئله در نظر گرفته می‌شود. عبارت لاگرانژ اصلاح شده به صورت معادله (۱۰) تعریف می‌شود:

$$L(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-jw_k t} \right\|^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \quad (۱۰)$$

مرحله، تابع تانژانت هایپربولیک ($\tanh$) است. همچنین، ماتریس‌های وزن مرتبط به سلول حافظه جدید $\tilde{C}_t$ ، شامل U_c و W_c هستند. مقادیر b_c و b_i به ترتیب به عنوان بایاس دروازه ورودی و بایاس سلول حافظه جدید در نظر گرفته می‌شوند. نماد $\otimes$ نیز به عنوان ضرب عنصری تعریف شده است [۱۵]. با ترکیب دو لایه و اعمال دروازه فراموشی، سلول C_t به‌روزرسانی می‌شود. این به‌روزرسانی شامل حذف بخشی از وضعیت قبلی سلول از طریق ضرب C_{t-1} در خروجی دروازه فراموشی و سپس افزودن مقدار جدید حاصل از $i_t \otimes \tilde{C}_t$ است، مطابق معادله (۴):

$$C_t = f_t \otimes C_{t-1} \otimes i_t \otimes \tilde{C}_t \quad (۴)$$

یکی از بخش‌های کلیدی این الگوریتم، دروازه خروجی است که وظیفه آن، کنترل صدور اطلاعات به عنوان خروجی شبکه در هر گام زمانی است. در ابتدا، مقدار دروازه خروجی با استفاده از تابع سیگموئید (σ) و براساس ورودی فعلی X_t و خروجی قبلی h_{t-1} و بایاس b_o طبق معادله (۵) محاسبه می‌شود. وضعیت سلول فعلی C_t توسط تابع تانژانت هایپربولیک تبدیل شده و با مقدار دروازه خروجی o_t به صورت ضرب عنصری ترکیب می‌شود تا خروجی نهایی h_t به دست آید؛ این فرایند در معادله (۶) نشان داده شده است:

$$o_t = \sigma(X_t U_o + h_{t-1} W_o + b_o) \quad (۵)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (۶)$$

در معادلات (۵) و (۶)، o_t خروجی دروازه خروجی، W_o وزن‌های لایه خروجی، b_o بایاس لایه خروجی، C_t وضعیت سلول در زمان t و X_t ورودی در زمان t هستند [۱۵].

۲.۲. الگوریتم تجزیه حالت متغیر

روش تجزیه حالت متغیر یکی از روش‌های نوین در حوزه تجزیه سیگنال است که نخستین بار در اگومیرتسکی و زوسو در سال ۲۰۱۴ آن را معرفی کردند [۱۷]. این روش با تجزیه داده‌های ورودی به اجزای فرعی، میزان ناپایداری و ویژگی‌های غیرایستا سیگنال‌ها را بهتر نمایان می‌سازد و امکان تحلیل دقیق‌تری را فراهم می‌کند. در آغاز فرایند، سیگنال اصلی به سه بخش عمده شامل سری‌های بلندمدت، سری نویسانی و سری تصادفی تقسیم می‌شود. این تقسیم‌بندی براساس ویژگی‌هایی مانند میزان تقاضا و دما انجام می‌گیرد [۴ و ۱۸]. در این روش، سیگنال پیچیده اولیه به k زیرسیگنال با تغییرات شکل در دامنه و فرکانس تفکیک می‌شود. فرض بر این است که هر زیرسیگنال دارای پهنای باند محدود بوده و فرکانس مرکزی آن با سایر زیرسیگنال‌ها متفاوت است. هدف اصلی الگوریتم، حداقل‌سازی مجموع پهنای باند تخمینی زیرسیگنال‌هاست. تجزیه حالت متغیر

این الگوریتم نوعی روش تجزیه حالت است که برای هر سیگنال، یک مدل پیش‌بینی اختصاصی ایجاد می‌کند و در نهایت با ترکیب این مدل‌ها، خروجی نهایی پیش‌بینی حاصل می‌شود.

۳.۲. الگوریتم کسینوس-سینوسی

الگوریتم کسینوس-سینوسی، یکی از روش‌های بهینه‌سازی فراابتکاری است که از ویژگی‌های تناوبی توابع سینوس و کسینوس برای کاوش در فضای جست‌وجو و یافتن بهینه کلی بهره می‌گیرد. این روش با اجتناب از بهینه‌های محلی و همگرایی به بهینه سراسری، در مسائل پیچیده بهینه‌سازی عملکرد مناسبی دارد [۱۹].

این الگوریتم فرایند بهینه‌سازی را با ایجاد چندین راه‌حل تصادفی آغاز می‌کند و از طریق ارزیابی مکرر با استفاده از یک تابع هدف و مجموعه‌ای از قوانین، عملکرد راه‌حل‌ها را بهبود می‌بخشد. هرچند جست‌وجوی تصادفی این روش تضمینی برای یافتن بهینه در یک اجرا ندارد، افزایش تعداد راه‌حل‌های اولیه و مراحل بهینه‌سازی (تکرارها) می‌تواند احتمال دستیابی به بهینه جهانی را افزایش دهد [۱۹].

مراحل بهینه‌سازی الگوریتم شامل مقداردهی اولیه، به‌روزرسانی موقعیت، ارزیابی و گزینش و توقف براساس یک شرط مشخص است. معادلات به‌روزرسانی موقعیت به‌صورت زیر تعریف می‌شوند:

$$X_i^{t+1} = \begin{cases} X_i^t + r_1 \times \sin(r_2) \times |r_3 P_i^t - X_i^t| & ; r_4 < 0.5 \\ X_i^t + r_1 \times \sin(r_2) \times |r_3 P_i^t - X_i^t| & ; r_4 \geq 0.5 \end{cases} \quad (۱۶)$$

در معادله (۱۶) X_i^t موقعیت راه‌حل فعلی، P_i^t بهترین موقعیت شخصی راه‌حل است. همچنین، r_1 ، r_2 ، r_3 و r_4 مقادیر تصادفی هستند که عدد تصادفی برای انتخاب بین سینوس و کسینوس در نظر گرفته می‌شود. برای حفظ تعادل میان اکتشاف و بهره‌برداری، دامنه r_1 به‌صورت زیر تغییر می‌کند:

$$r_1 = a - t \frac{a}{T} \quad (۱۷)$$

که در آن، t نشان‌دهنده تکرار فعلی، T حداکثر تعداد تکرارها و a یک اسکالر ثابت است. این تنظیم دامنه به الگوریتم کمک می‌کند که ابتدا فضای جست‌وجو را به‌طور گسترده کاوش کرده و در ادامه روی مناطق با پتانسیل بالا تمرکز نماید. الگوریتم کسینوس-سینوسی به‌دلیل سادگی، سرعت بالا و توانایی مناسب در حل مسائل پیچیده بهینه‌سازی، به‌عنوان یک روش کارآمد در میان الگوریتم‌های فراابتکاری شناخته می‌شود [۱۹].

۴.۲. تخمین با روش مونت کارلو

روش مونت کارلو یک روش قدرتمند محاسباتی است که برای تخمین پاسخ مسائل پیچیده، به‌ویژه در حوزه‌های احتمالی و آماری،

روش جهت‌گیری متناوب ضرب‌کننده‌ها برای حل مسئله تغییرات بالا استفاده می‌شود و بهترین راه‌حل عبارت لاگرانژ افزوده‌شده با به‌روزرسانی متناوب w_k^{n+1} و u_k^{n+1} بهینه می‌شود. در میان این‌ها، تبدیل ایزومتريک فوری می‌تواند برای تبدیل u_k^{n+1} به حوزه فرکانسی استفاده شود. پارامتر α وظیفه دارد بازسازی دنباله را در هنگام مواجهه با نویز گاوسی تضمین کند و همچنین $\lambda(t)$ نیز محدودیت‌های شدید (مقید ماندن) را تضمین می‌کند. الگوریتم تجزیه حالت متغیر فرایند تجزیه را به‌صورت زیر انجام می‌دهد [۶]:

$$\hat{u}_k^{n+1} = \underset{\hat{u}_k, u_k \in X}{\operatorname{argmin}} \left\{ \alpha \|jw \cdot [(1 + \operatorname{sgn}(w + w_k)) \cdot \hat{u}_k(w) + w_k]\| + \left\| \hat{f}(w) - \sum_i \hat{u}_i(w) + \left(\frac{\hat{\lambda}(w)}{2} \right) \right\|_2^2 \right\} \quad (۱۱)$$

معادله (۱۱) با استفاده از تبدیل ایزومتريک فوری به حوزه فرکانس منتقل می‌شود. سپس، حل مسئله بهینه‌سازی درجه دوم (به‌روزرسانی $\hat{u}_k^{n+1}$ و w_k) به دست می‌آید:

$$\hat{u}_k^{n+1} = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2} \quad (۱۲)$$

فرکانس مرکزی نیز به همین ترتیب به‌روزرسانی می‌شود تا مقدار آن به‌شکل مناسبی تنظیم شود.

$$w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 dw}{\int_0^\infty |\hat{u}_k(w)|^2 dw} \quad (۱۳)$$

که در آن، $\hat{u}_k^{n+1}$ معادل فیلتر وینر برای مقدار باقی‌مانده فعلی $\hat{f}(w) - \sum \hat{u}_i(w)$ است؛ به این معنا که فیلتر وینر نقش مهمی در کاهش خطا و بهینه‌سازی تخمین مقدار باقی‌مانده ایفا می‌کند. همچنین، w_k^{n+1} مرکز ثقل طیف توان تابع مد فعلی است که نشان‌دهنده توزیع انرژی سیگنال در فرکانس‌های مختلف است. واضح است که در معادلات فوق، n تعداد تکرارها را نمایش می‌دهد. در ادامه، به‌روزرسانی $\hat{\lambda}$ به‌صورت زیر پرداخته می‌شود:

$$\hat{\lambda}^{n+1}(w) = \hat{\lambda}^n(w) + \tau \left(\hat{f}(w) - \sum_{k=1}^K \hat{u}_k^{n+1}(w) \right) \quad (۱۴)$$

که در آن، τ پارامتر به‌روزرسانی است و مقدار اولیه آن صفر در نظر گرفته می‌شود. در مرحله نهایی، اگر شرط زیر برقرار باشد، حلقه تکرار متوقف می‌شود و تبدیل فوری معکوس بر روی $\hat{u}_k^{n+1}$ اعمال می‌شود تا قسمت واقعی آن به‌عنوان خروجی $\hat{u}_k^{n+1}$ به دست می‌آید؛ در غیر این صورت، مقدار $n+1$ جایگزین n شده و مراحل به‌روزرسانی تکرار می‌شود [۶].

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (۱۵)$$

کوتاه‌مدت، برای پیش‌بینی داده‌های سری زمانی بسیار مناسب است. ساختار شبکه شامل لایه‌های ورودی، لایه حافظه طولانی کوتاه‌مدت، لایه‌های کاملاً متصل^۱، دراپ‌اوت^۲ و خروجی است. در ادامه، تنظیمات مربوط به آموزش شبکه عصبی تعیین می‌شود. برای این منظور، از بهینه‌ساز آدام^۳ استفاده شده است که یکی از روش‌های تطبیقی رایج در یادگیری عمیق به شمار می‌رود. این الگوریتم با ترکیب ویژگی‌های بهینه‌سازهای الگوریتم گرادینت تطبیقی^۴ و الگوریتم تکثیر میانگین مربعات ریشه^۵، قادر است نرخ یادگیری^۶ را براساس ویژگی‌های گرادینت‌ها به صورت پویا تنظیم کند؛ از این رو در مدل‌های پیچیده عملکرد مناسبی از خود نشان می‌دهد. نرخ یادگیری اولیه^۷ نقش کلیدی در تعیین سرعت همگرایی مدل دارد و به همین دلیل، به دقت مقداردهی شده است. برای بهبود فرایند آموزش، از یک برنامه زمانی تکه‌ای^۸ برای تنظیم نرخ یادگیری استفاده شده است که در آن، نرخ یادگیری در بازه‌های مشخصی از دوره‌های آموزشی، کاهش می‌یابد. در این پژوهش، نرخ یادگیری پس از هر ۱۲۵ دوره آموزشی کاهش یافته و این کاهش با ضریب مشخصی اعمال می‌شود. تعداد کل دوره‌های آموزشی^۹ نیز مقدار مشخصی در نظر گرفته شده تا شبکه فرصت کافی برای یادگیری الگوهای پیچیده را داشته باشد. برای کنترل پایداری آموزش، آستانه گرادینت^{۱۰} برابر یک تنظیم شده تا از انفجار گرادینت‌ها جلوگیری شود. همچنین، اندازه دسته آموزشی^{۱۱} برابر با یک در نظر گرفته شده تا شبکه بتواند به صورت نمونه‌به‌نمونه آموزش ببیند. این تنظیمات به منظور حفظ سادگی، تمرکز بر سرعت اجرا و جلوگیری از پیچیدگی‌های بصری اتخاذ شده‌اند.

پس از تکمیل آموزش، عملکرد مدل با استفاده از داده‌های آزمون ارزیابی و خروجی پیش‌بینی با مقادیر واقعی مقایسه می‌شود. معیارهای ارزیابی شامل ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا و میانگین درصد خطای مطلق بوده و نتایج نشان می‌دهند که مدل پیشنهادی در مقایسه با مدل‌هایی مانند حافظه طولانی کوتاه‌مدت ساده، رگرسیون بردار پشتیبان و میانگین متحرک یکپارچه اتورگرسیون، دقت بالاتری دارد. همچنین به منظور سنجش دقت و

استفاده می‌شود. مدل‌سازی مونت‌کارلو شامل بخش‌های اصلی مانند تولید اعداد تصادفی، توابع توزیع احتمال، نمونه‌برداری، شبیه‌سازی، ارزیابی خطای سری‌های زمانی و کاهش انحراف معیار است. در این روش، اعداد تصادفی با استفاده از الگوریتم‌های ویژه تولید می‌شوند و سپس از طریق نمونه‌گیری تصادفی، نتایج محاسبه می‌شوند. روش مونت‌کارلو همچنین یکی از شیوه‌های اصلی برای محاسبه توزیع احتمال کارایی پیش‌بینی شده است و این کار از طریق انتقال عدم قطعیت‌های ورودی به خروجی انجام می‌شود. در این فرایند، با تکرار مراحل شبیه‌سازی، که گاهی هزاران بار انجام می‌شود، توزیع احتمالی نتایج نهایی به دست می‌آید. میانگین و انحراف استاندارد این توزیع، تخمین‌های مناسبی از پاسخ مسئله ارائه می‌دهند. از ویژگی‌های برجسته مونت‌کارلو می‌توان به سادگی پیاده‌سازی در مدل‌های شبکه عصبی، انعطاف‌پذیری در مواجهه با مسائل پیچیده و دقت بالای نتایج با افزایش تعداد شبیه‌سازی‌ها اشاره کرد [۲۰ و ۲۱].

۳. سیستم پیشنهادی

در این پژوهش، یک مدل ترکیبی برای پیش‌بینی تقاضای گاز مصرفی خانگی طراحی شده است. این مدل شامل الگوریتم تجزیه حالت متغیر، الگوریتم بهینه‌سازی کسینوس-سینوسی و شبکه عصبی حافظه طولانی کوتاه‌مدت است. هدف از این مدل، بهبود دقت پیش‌بینی تقاضای گاز با استفاده از تجزیه سری زمانی، بهینه‌سازی پارامترهای مدل و بهره‌گیری از قدرت یادگیری عمیق برای درک الگوهای پیچیده مصرف گاز است.

ابتدا داده‌های خام شامل اطلاعات مصرف گاز و متغیرهای هواشناسی همچون دما، از فایل‌های اکسل استخراج شده، به فرمت عددی تبدیل و با استفاده از میانگین و انحراف معیار نرمال‌سازی می‌شوند. سپس داده‌ها به دو بخش آموزش (۸۰٪) و آزمایش (۲۰٪) تقسیم می‌شوند. در این پژوهش، تنها متغیر دما به عنوان ویژگی کمکی استفاده شده است؛ چراکه دما بیشترین تأثیر را بر تقاضای گاز مصرفی دارد، به ویژه در فصول سرد سال که نیاز به گرمایش افزایش می‌یابد. در گام بعدی، الگوریتم تجزیه حالت متغیر بر روی سری زمانی مصرف گاز و داده‌های دمایی اعمال می‌شود تا مؤلفه‌های مختلفی چون روند، نوسان و نویز استخراج شوند. به منظور بهینه‌سازی پارامترهای این الگوریتم و دستیابی به بهترین بازسازی سری زمانی، از الگوریتم بهینه‌سازی کسینوس-سینوسی استفاده شده است. سپس، مؤلفه‌های به دست آمده به همراه داده‌های دمایی، به عنوان ورودی به شبکه عصبی حافظه طولانی کوتاه‌مدت داده می‌شوند. این شبکه به دلیل توانایی‌اش در مدل‌سازی وابستگی‌های زمانی بلندمدت و

1. Fully Connected
2. Dropout
3. Adam Optimization (Adam)
4. Adaptive Gradient Algorithm (AdaGrad)
5. Root Mean Square Propagation (RMSProp)
6. Learning Rate
7. Initial Learning Rate
8. Piecewise
9. Max Epochs
10. Gradient Threshold
11. Mini-Batch Size

۴. داده‌ها و معیارهای ارزیابی

در این تحقیق، داده‌های مربوط به میزان تقاضای انرژی گاز و ویژگی‌های آب‌وهوایی در دو منطقه ایالت پنسیلوانیا و بخش شهری سیرجان بررسی شده‌اند. داده‌های ایالت پنسیلوانیا که از پایگاه داده معتبر Kaggle استخراج شده‌اند، شامل میزان تقاضای گاز و دمای هوا در بازه زمانی ۲۰۱۵ تا ۲۰۱۷ هستند. داده‌های مربوط به سیرجان که از منابع معتبر داخلی تهیه شده‌اند، به صورت ماهانه و برای بازه زمانی ۱۳۹۳ تا ۱۴۰۲ جمع‌آوری شده‌اند.

یک پیش‌بینی، زمانی می‌تواند کارآمد و مفید باشد و به مقاصد زمانی دست یابد که با کمک تخمینی از خطاهای مورد انتظار ارزیابی می‌شود. معیارهای معرفی شده در ادامه برای بررسی و ارزیابی عملکرد مورد استفاده قرار می‌گیرند. در این پژوهش از انواع شاخص‌های ارزیابی چند نمونه زیر انتخاب شده است: در معیارهای ارزیابی زیر، n تعداد کل نمونه‌هاست و همچنین Y_i مقدار واقعی و $\hat{Y}_i$ مقدار پیش‌بینی شده است.

خطای جذر میانگین مربعات^۱: این معیار تفاوت میان مقدار

پیش‌بینی شده توسط مدل یا برآوردگر آماری و مقدار واقعی است. با گرفتن مجذور انحرافات واقعی از تقاضای پیش‌بینی شده در محاسبه میانگین مربعات، وزن بیشتری به خطاهای بزرگ‌تر داده است. فرمول آن به صورت زیر است:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (18)$$

این معیار، معیاری مناسب برای توصیف خطاهای مثبت و منفی است و هیچ‌گاه صفر نخواهد شد و همواره عددی بزرگ‌تر یا مساوی صفر است [۲۲].

میانگین مطلق خطا^۲: برای محاسبه میانگین مطلق خطا از

تفاوت میان مقدار واقعی و مقدار پیش‌بینی شده یک میانگین گرفته می‌شود. هرگاه بخواهیم کیفیت پیش‌بینی‌ها را نسبت به اندازه مطلق و نه اندازه نسبی آن‌ها ارزیابی کنیم، از این معیار خطا استفاده می‌کنیم. فرمول آن به صورت زیر است:


$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (19)$$

میانگین مطلق خطا به عنوان یک معیار پایدار عمل می‌کند که نسبت به خطای میانگین مربعات^۳ حساسیت کمتری نسبت به جهش‌ها دارد [۲۳].

پایداری مدل در مواجهه با داده‌های دارای عدم قطعیت، از شبیه‌سازی مونت کارلو استفاده شده است. در این مرحله، داده‌های مصنوعی با فرض توزیع نرمال پیرامون میانگین و انحراف معیار سری‌های اصلی تولید و پس از اعمال الگوریتم تجزیه حالت متغیر، به مدل آموزش دیده حافظه طولانی کوتاه مدت وارد شده‌اند. نتایج حاصل از این مرحله نشان می‌دهد که مدل در برابر نوسانات تصادفی و داده‌های نادقیق نیز عملکرد قابل قبولی دارد.

شایان ذکر است که اگرچه مدل در داده‌های مورد بررسی عملکرد مطلوبی نشان داده است، داده‌های مربوط به مناطق گرمسیری در این مطالعه لحاظ نشده‌اند. از آنجاکه الگوهای مصرف در مناطق گرمسیر می‌توانند متفاوت باشند، ارزیابی مدل در این شرایط نیازمند مطالعات آتی است. مدل پیشنهادی با ترکیب الگوریتم‌های تجزیه حالت متغیر، کسینوس-سینوسی و حافظه طولانی کوتاه مدت و بهره‌گیری از تنظیمات آموزشی دقیق، به چارچوبی هدفمند برای پیش‌بینی دقیق تقاضای گاز دست یافته است. این چارچوب قابلیت تعمیم‌پذیری، پایداری و دقت بالا را توأمان داراست و می‌تواند به عنوان یک ابزار مفید در مدیریت منابع انرژی مورد استفاده قرار گیرد.

در این پژوهش، یک چارچوب ترکیبی شامل مراحل پیش‌پردازش داده، تجزیه سری‌های زمانی با الگوریتم تجزیه حالت متغیر، بهینه‌سازی پارامترها با الگوریتم کسینوس-سینوسی و آموزش مدل پیش‌بینی با شبکه حافظه طولانی کوتاه مدت طراحی شده است (شکل ۱). شکل (۱) روند کلی اجرای مدل پیشنهادی را نشان می‌دهد.



شکل (۱): طرح‌واره روش پیشنهادی

1. Root Mean Squared Error (RMSE)

2. Mean Absolute Error (MAE)

3. Mean Squared Error (MSE)

جدول (۱): مقایسه جامع خطای پیش‌بینی مدل‌های مختلف در داده‌های روزانه گاز ایالت پنسیلوانیا

MAPE	MAE	RMSE	نوع تابع ارزیابی نوع شبکه عصبی
۰/۱۸۳۵	۰/۰۲۵۷	۰/۰۳۱۳	میانگین خطای پیش‌بینی مدل شبکه عصبی ترکیبی (۱۰ اجرا)
۰/۸۱۶۰	۰/۲۱۴۷	۰/۲۷۰۹	میانگین خطای پیش‌بینی مدل شبکه عصبی ساده (۱۰ اجرا)
۲/۸۷	۰/۰۲۹۱۰۲	۰/۰۳۲۰۱۹	میانگین خطای پیش‌بینی مدل رگرسیون بردار پشتیبان (۱۰ اجرا)
۳/۱۸	۰/۰۳۱۳۶۰	۰/۰۳۴۳۱۰	میانگین خطای پیش‌بینی مدل میانگین متحرک یکپارچه اتورگرسیو (۱۰ اجرا)

جدول (۲): مقایسه خطای عملکرد حداقلی مدل‌ها برای داده‌های روزانه ایالت پنسیلوانیا

MAPE	MAE	RMSE	نوع مدل تابع ارزیابی
۰/۴۷۳۹	۰/۰۲۵۳	۰/۰۳۲۲	شبکه عصبی ترکیبی (خطای بیشینه)
۰/۹۸۱۴	۰/۳۸۰۸	۰/۴۵۰۴	شبکه عصبی ساده (خطای بیشینه)
۲/۸۷	۰/۰۲۹۱۰۳	۰/۰۳۲۰۲۰	مدل رگرسیون بردار پشتیبان (خطای بیشینه)
۳/۱۸	۰/۰۳۱۳۶۰	۰/۰۳۴۳۱۰	مدل میانگین متحرک یکپارچه اتورگرسیو (خطای بیشینه)

در جدول (۱)، مقادیر ارائه‌شده، میانگین چند اجرای مستقل از هر مدل هستند (به‌جز مدل میانگین متحرک یکپارچه اتورگرسیو که فقط یک پیش‌بینی تولید می‌کند). براساس نتایج، مدل ترکیبی در بهترین حالت بیش از ۹۰ درصد بهبود عملکرد داشته است و به‌طور خاص، در میانگین اجراهای مستقل مدل، نسبت به مدل حافظه طولانی کوتاه‌مدت ساده، تا حدود ۷۷ درصد کاهش خطا در برخی شاخص‌ها مشاهده می‌شود که نشان‌دهنده دقت بالای این مدل در پیش‌بینی سری‌های زمانی است. برای نمونه، مدل ترکیبی توانسته است مقدار خطای میانگین درصدی مطلق را نسبت به مدل ساده حدود ۷۷/۵ کاهش دهد، نسبت به مدل رگرسیون بردار پشتیبان حدود ۳۶/۱ و نسبت به مدل میانگین متحرک یکپارچه اتورگرسیو حدود ۴۲/۳ کاهش دهد. در مجموع، نتایج حاصل نشان می‌دهد که مدل ترکیبی نه تنها نسبت به سایر مدل‌های یادگیری ماشین، بلکه حتی در مقایسه با روش‌های کلاسیک آماری نیز عملکردی قابل توجه و حتی بهبودی بیش از ۹۰٪ در بهترین حالت‌ها از خود نشان داده است. این

درصد میانگین مطلق خطا: درصد میانگین مطلق خطا برای

ارزیابی دقت پیش‌بینی در داده‌های سری زمانی متنوع مورد استفاده قرار می‌گیرد. این معیار میانگین درصد تفاوت بین مقادیر پیش‌بینی‌شده و مقادیر واقعی را محاسبه کرده و مقایسه‌های درستی را بدون توجه به تغییرات مقیاس ساده‌سازی می‌کند [۲]:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{Y_i - \hat{Y}_i}{Y_i} \times 100 \quad (20)$$

خطای نسبی: خطای نسبی معیاری است برای اندازه‌گیری

میزان انحراف مقدار پیش‌بینی‌شده از مقدار واقعی، که این انحراف به مقدار واقعی نسبت داده می‌شود. این خطا معمولاً به‌صورت درصد بیان می‌شود و به‌صورت زیر تعریف می‌شود:

$$RE = \frac{|\hat{Y}_i - Y_i|}{|Y_i|} \quad (21)$$

در بسیاری از مسائل، تغییرات نسبی اهمیت بیشتری دارند تا تغییرات مطلق، به‌ویژه زمانی که مقادیر واقعی متفاوت هستند یا مقیاس‌های مختلفی دارند [۲۴].


۵. ارزیابی عملکرد روش پیشنهادی

برای ارزیابی عملکرد روش پیشنهادی، از روش حافظه طولانی کوتاه‌مدت ساده، مدل میانگین متحرک یکپارچه اتورگرسیو و مدل رگرسیون بردار پشتیبان برای مقایسه عملکرد استفاده شده است، تا توانایی مدل در پیش‌بینی تقاضای گاز مورد سنجش قرار گیرد. در این راستا، از معیارهای رایج ارزیابی شامل ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا، میانگین درصد خطای مطلق و خطای نسبی برای تحلیل دقت مدل استفاده شده است. این شاخص‌ها امکان ارزیابی دقیق‌تر میزان انحراف پیش‌بینی‌ها از مقادیر واقعی را فراهم می‌کند و مقایسه کیفی میان روش پیشنهادی و سایر مدل‌های مرجع را امکان‌پذیر می‌سازند. در ادامه، نتایج کمی این ارزیابی‌ها در قالب جدول ارائه می‌شود.

در بخش اول ارزیابی، نتایج حاصل از مدل پیشنهادی با استفاده از داده‌های روزانه مربوط به ایالت پنسیلوانیا ارزیابی شده است. این داده‌ها شامل اطلاعات تقاضای گاز مصرفی و پارامترهای هواشناسی (مانند دما) برای یک دوره زمانی مشخص هستند. ارزیابی عملکرد مدل براساس شاخص‌های مختلف ارزیابی انجام شده است تا دقت پیش‌بینی مدل بررسی شود.

1. Mean Absolute Percentage Error (MAPE)
2. Relative Error

بنابراین، مدل ترکیبی علاوه بر دقت بالا، در برابر نوسانات نیز عملکرد پایدارتری دارد.



شکل (۲): نمودار توزیع خطای جذر میانگین مربعات داده‌های روزانه ایالت پنسیلوانیا

مدل می‌تواند به عنوان گزینه‌ای بهینه برای تحلیل داده‌های زمانی در کاربردهای واقعی مورد استفاده قرار گیرد.


جدول (۲) حداکثر خطاهای ثبت شده برای مدل‌های مختلف را در پیش‌بینی مصرف گاز روزانه نشان می‌دهد. در این مقایسه، مدل شبکه عصبی ترکیبی حتی در بدترین اجرای خود نیز عملکرد بهتری نسبت به سایر مدل‌ها داشته و مقدار خطاهای آن همچنان در سطح قابل قبولی باقی مانده است (مثلاً ریشه میانگین مربعات خطا برابر ۰/۰۳۲۲). در مقابل، مدل شبکه عصبی ساده در بدترین حالت با افزایش قابل توجه خطا مواجه شده و میانگین درصد خطای مطلق آن به حدود ۰/۹۸۱ درصد رسیده است. نکته مهم این است که دو مدل رگرسیون بردار پشتیبان و میانگین متحرک یکپارچه اتورگرسیون در مقایسه با حالت بهترین خود، در بدترین حالت تغییر چندانی نکرده‌اند. برای مثال، ریشه میانگین مربعات خطا مدل رگرسیون بردار پشتیبان تنها از ۰/۰۳۲۰۰۲ به ۰/۰۳۲۰۲۰ افزایش یافته که اختلافی ناچیز و کمتر از ۰/۰۰۰۰۲ است؛ در عین حال به دقت مدل ترکیبی نمی‌رسند.

جدول (۳): میانگین مقادیر پیش‌بینی و خطای نسبی مدل‌ها برای دو روز (داده‌های روزانه ایالت پنسیلوانیا)

نوع مدل	مقدار تقاضای واقعی روز اول = ۷۵۳۹۱	خطای نسبی	مقدار تقاضای واقعی روز دوم = ۷۱۱۳۸	خطای نسبی
میانگین پیش‌بینی شبکه عصبی ترکیبی (۱۰ اجرا)	۷۲۶۲۳/۳۸۳	۰/۰۳۶۷	۷۴۹۷۲/۸۲۰	۰/۰۵۳۹
میانگین پیش‌بینی شبکه عصبی ساده (۱۰ اجرا)	۸۴۷۶۹/۷۷۶۶	۰/۱۲۴۴	۷۲۳۲۴/۸۵۹	۰/۰۱۶۷
میانگین پیش‌بینی مدل رگرسیون بردار پشتیبان (۱۰ اجرا)	۷۲۲۸۰/۵۴	۰/۰۴۱۲	۷۲۲۹۱/۷۷۹	۰/۰۱۶۲
میانگین پیش‌بینی مدل میانگین متحرک یکپارچه اتورگرسیون (۱۰ اجرا)	۷۶۶۶۹	۰/۰۱۶۹	۷۴۴۵۵	۰/۰۴۶۶

است. نتایج نشان می‌دهد که روش ترکیبی خطای کمتری نسبت به روش ساده دارد. میانگین و میانۀ خطای روش ترکیبی کمتر است و نشان‌دهنده دقت بالاتر آن است. همچنین، دامنه تغییرات خطا در روش ترکیبی محدودتر بوده و پایداری بیشتری دارد. در نهایت، روش ترکیبی در تمامی شاخص‌ها عملکرد بهتری نسبت به روش ساده دارد.

در جدول (۳)، مقایسه مقادیر خطای نسبی میانگین داده‌های پیش‌بینی شده در ده اجرای مستقل را در بین مدل‌های حافظه طولانی کوتاه‌مدت ساده، ترکیبی، رگرسیون بردار پشتیبان و مدل میانگین متحرک یکپارچه اتورگرسیون برای تقاضای انرژی گاز نشان داده شده است. مقایسه این مدل‌ها با مقادیر واقعی تقاضای انرژی گاز، نشان‌دهنده عملکرد متفاوت این مدل‌هاست. نتایج نشان می‌دهد که مدل ترکیبی در هر دو روز اول و دوم، بهترین پیش‌بینی را داشته و نسبت به مدل ساده به ترتیب حدود ۹۰٪ و ۶۲٪ کاهش خطا داشته است. همچنین، در مقایسه با مدل



شکل (۳): نمودار توزیع درصد میانگین مطلق خطا داده‌های روزانه ایالت پنسیلوانیا

در شکل‌های (۲) و (۳)، توزیع خطا برای دو روش شبکه عصبی حافظه طولانی کوتاه‌مدت ساده و ترکیبی نشان داده شده

شایان ذکر است که مقادیر ارائه شده در جدول (۳)، میانگین نتایج حاصل از ده اجرای مستقل مدل‌ها هستند و لزوماً بهترین پیش‌بینی ممکن هر مدل محسوب نمی‌شوند. همچنین، مدل میانگین متحرک یکپارچه اتورگرسیو به دلیل ماهیت غیرتصادفی خود، تنها یک پیش‌بینی تولید کرده و میانگین آن برابر با همان مقدار اولیه است. این نتایج نشان می‌دهند که حتی در مقایسه با بهترین حالت‌های سایر مدل‌ها، مدل ترکیبی همچنان دقیق‌ترین خروجی را ارائه داده و از نظر دقت و پایداری برتری محسوسی دارد. برای جلوگیری از ازدیاد حجم جداول در متن اصلی، نتایج بهترین پیش‌بینی مدل‌ها برای داده‌های روزانه ایالت پنسیلوانیا در پیوست الف ارائه شده است. این نتایج بیانگر برتری مدل ترکیبی در تمامی شاخص‌های ارزیابی و دقت بالای آن در پیش‌بینی مقادیر روزانه است.

رگرسیون بردار پشتیبان نیز دقت بالاتری از خود نشان داده است. این برتری در کاهش خطای نسبی بیانگر توانمندی بیشتر مدل ترکیبی در پیش‌بینی تقاضای انرژی گاز است. در مقایسه با مدل رگرسیون بردار پشتیبان، خطای نسبی در روز اول برابر با ۰/۰۴۱۲ و در روز دوم ۰/۰۱۶۲ است، مدل ترکیبی همچنان دقت بالاتری نشان می‌دهد. در مجموع، این نتایج به‌روشنی نشان می‌دهند که مدل ترکیبی با کاهش معنادار خطای نسبی، دقیق‌ترین پیش‌بینی‌ها را برای تقاضای انرژی گاز ارائه داده است. این تحلیل بیانگر توانمندی بیشتر مدل ترکیبی در پیش‌بینی تقاضای انرژی گاز نسبت به مدل‌های دیگر است و نشان می‌دهد که این مدل گزینه‌ای کارآمد برای تحلیل و پیش‌بینی سری‌های زمانی پیچیده مانند تقاضای انرژی است.


جدول (۴): میانگین خطای پیش‌بینی (۱۰ اجرا) مدل‌ها برای دو ماه ابتدایی (داده‌های ماهانه مصرف گاز شهری در سیرجان)

MAPE	MAE	RMSE	تابع ارزیابی شبکه عصبی
۰/۰۴۹۸	۰/۰۲۹۷	۰/۰۳۴۲	میانگین خطای پیش‌بینی‌های شبکه عصبی ترکیبی
۰/۰۹۹۰۳	۰/۰۵۹۶۶	۰/۰۷۴۳۴	میانگین خطای پیش‌بینی‌های شبکه عصبی ساده
۲۱/۲۱	۰/۲۵۶۸۱۳	۰/۳۵۰۲۶۱	میانگین خطای پیش‌بینی‌های مدل رگرسیون بردار پشتیبان
۱۰/۹۶	۰/۱۲	۰/۱۳	میانگین خطای پیش‌بینی‌های مدل میانگین متحرک یکپارچه اتورگرسیو


جدول (۵): مقایسه خطای عملکرد حداقلی مدل‌ها برای داده‌های ماهانه مصرف گاز شهری سیرجان

MAPE	MAE	RMSE	تابع ارزیابی نوع مدل
۱/۳۳۲۲	۰/۰۶۹۳	۰/۰۷۸۴	شبکه عصبی ترکیبی (خطای بیشینه)
۱۶/۰۵۲۹	۰/۰۸۶۹۳	۰/۰۸۷۹۳	شبکه عصبی ساده (خطای بیشینه)
۲۱/۲۱	۰/۲۵۶۸۱	۰/۳۵۰۲۶	مدل رگرسیون بردار پشتیبان (خطای بیشینه)
۱۰/۹۶	۰/۱۲	۰/۱۳	مدل میانگین متحرک یکپارچه اتورگرسیو (خطای بیشینه)

در شکل (۴)، مقایسه‌ای بین عملکرد دو مدل ساده و مدل ترکیبی پیش‌بینی تقاضای انرژی گاز برای دو روز آینده در ایالت پنسیلوانیا ارائه شده است. خطوط مشکی مقادیر واقعی مصرف گاز را نشان می‌دهند. خروجی مدل ساده با خطوط قرمز و خروجی مدل ترکیبی با خطوط آبی نمایش داده شده‌اند. همان‌طور که مشاهده می‌شود، پیش‌بینی مدل ترکیبی تطابق بیشتری با مقادیر واقعی دارد که نشان‌دهنده دقت بالاتر آن نسبت به مدل ساده در پیش‌بینی تقاضای انرژی گاز است.



شکل (۴): نمودار عملکرد شبکه حافظه طولانی کوتاه‌مدت ترکیبی و ساده هنگام پیش‌بینی داده‌های روزانه ایالت پنسیلوانیا



شکل (۶): نمودار توزیع درصد میانگین مطلق خطا داده‌های ماهانه شهر سیرجان


نمودارهای جعبه‌ای تصاویر (۵) و (۶) مقایسه عملکرد دو مدل شبکه عصبی ساده و ترکیبی در پیش‌بینی تقاضای گاز بخش شهری سیرجان نشان می‌دهند که مدل ترکیبی دقت و پایداری بیشتری نسبت به مدل ساده دارد. به‌طور مثال، میانگین خطا جذر میانگین مربعات در مدل ترکیبی ۰/۰۳ و در مدل ساده ۰/۷۴ است. کاهش پراکندگی خطاها و کاهش نقاط پرت در مدل ترکیبی نیز نشان‌دهنده بهبود دقت پیش‌بینی است. این نتایج نشان می‌دهند که استفاده از متغیرهای تأثیرگذار محیطی مانند دما، دقت پیش‌بینی را افزایش می‌دهد.

در جدول (۶)، میانگین خطای نسبی مدل‌ها را در پیش‌بینی مصرف گاز ماهانه نشان می‌دهد که مدل ترکیبی با استفاده از متغیر کمکی دما برای پیش‌بینی مصرف ماه اول، با خطای نسبی ۰/۱۲۲۶ به ترتیب، بهبود ۷۸/۸ درصدی و ۶۹/۳۴ درصدی نسبت به مدل ساده با خطای نسبی ۰/۵۷۸۴ و رگرسیون بردار پشتیبان با خطای نسبی ۰/۳۹۹۸ داشته است. همچنین برای پیش‌بینی مصرف ماه دوم، با خطای نسبی ۰/۰۸۶۰، مدل ترکیبی عملکرد بهتری نشان داده است. این نتایج تأیید می‌کنند که مدل ترکیبی، به‌ویژه با اضافه کردن دما به عنوان متغیر کمکی، پیش‌بینی‌های دقیق‌تری ارائه داده است. شایان ذکر است که مدل میانگین متحرک یکپارچه اتورگرسیون تنها یک پیش‌بینی منفرد ارائه می‌دهد و میانگین خطای آن براساس این پیش‌بینی محاسبه شده است. بنابراین، مقایسه عملکرد مدل میانگین متحرک یکپارچه اتورگرسیون با مدل‌های شبکه عصبی که میانگین چندین اجرای مستقل را گزارش می‌دهند، باید با احتیاط انجام شود. برای جلوگیری از ازدیاد حجم جداول در متن اصلی، نتایج بهترین پیش‌بینی مدل‌ها برای مصرف ماهانه گاز شهری سیرجان در پیوست ب آمده است. بررسی‌ها نشان می‌دهد مدل ترکیبی با اختلاف معنادار نسبت به سایر مدل‌ها، دقیق‌ترین عملکرد را در پیش‌بینی داده‌های ماهانه داشته است.

در بخش دوم، نتایج مدل برای پیش‌بینی تقاضای گاز در شهر سیرجان ارائه شده است. در این بخش، داده‌های مربوط به مصرف گاز خانگی و شرایط آب‌وهوایی سیرجان استفاده شده است. عملکرد مدل با توجه به معیارهای مشابهی که در بخش اول ذکر شد، ارزیابی شده و نتایج به تفکیک در جدول‌های مربوط نشان داده شده است.

در جدول (۴) میانگین نتایج حاصل از ده بار اجرای مستقل مدل‌ها برای پیش‌بینی تقاضای گاز دو ماه نخست بعدی ارائه شده است. این جدول میزان خطای پیش‌بینی تقاضای گاز در شهر سیرجان را که تحت تأثیر تغییرات دمایی قرار دارد، نشان می‌دهد. مدل حافظه طولانی کوتاه‌مدت ترکیبی در هر دو ماه، کمترین مقدار خطای نسبی را در میان سایر روش‌ها داشته است. این نتایج نشان می‌دهد که مدل ترکیبی توانسته است با دقت بیشتری روند تقاضای گاز را پیش‌بینی کند و عملکرد بهتری نسبت به سایر مدل‌ها ارائه دهد.

جدول (۵) عملکرد مدل‌ها را در بدترین حالت پیش‌بینی برای داده‌های ماهانه سیرجان نمایش می‌دهد. نتایج نشان می‌دهد که مدل شبکه عصبی ترکیبی حتی در نامطلوب‌ترین شرایط نیز دقت مناسبی دارد؛ به‌طوری‌که مقدار خطای درصدی آن حدود ۱/۳۳ گزارش شده، درحالی‌که این مقدار برای مدل عصبی ساده به بیش از ۱۶٪ افزایش یافته که نشان‌دهنده نوسان شدید عملکرد آن در اجراهای مختلف است. نکته قابل توجه آن است که مدل‌های کلاسیک مانند رگرسیون بردار پشتیبان و مدل میانگین متحرک یکپارچه، حتی در بهترین اجرای خود نیز نتوانستند به دقت مدل ترکیبی در بدترین حالت نزدیک شوند. برای مثال، خطای درصدی این دو مدل در بدترین اجرا به ترتیب حدود ۲۱٪ و ۱۱٪ بوده است؛ یعنی بیش از ۸ تا ۱۵ برابر بزرگ‌تر از خطای مدل ترکیبی. این مقایسه به‌روشنی برتری مدل پیشنهادی را نشان می‌دهد و تأکید می‌کند که بهره‌گیری از ساختار ترکیبی موجب بهبود چشمگیر در پیش‌بینی مصرف گاز شده است.



شکل (۵): نمودار توزیع خطای جذر میانگین مربعات داده‌های ماهانه شهر سیرجان

جدول (۶): میانگین خطای نسبی پیش‌بینی (۱۰ اجرا) مدل‌ها برای دو ماه نخست (داده‌های ماهانه مصرف گاز شهری در سیرجان)


نوع شبکه عصبی	مقدار تقاضای واقعی ماه اول = ۱۳۷۸۶۶۵۸	خطای نسبی	مقدار تقاضای واقعی ماه دوم = ۸۴۸۲۵۵۲	خطای نسبی
میانگین پیش‌بینی شبکه عصبی ترکیبی	۱۲۰۹۶۹۶۴/۵۵	۰/۱۲۲۶	۹۲۱۱۶۶۱/۴۵	۰/۰۸۶۰
میانگین پیش‌بینی شبکه عصبی ساده	۵۸۱۲۸۰۰	۰/۵۷۸۴	۴۹۰۵۹۰۰	۰/۴۲۱۶
میانگین پیش‌بینی‌های مدل رگرسیون بردار پشتیبان	۸۲۷۵۱۰۳/۰۱	۰/۳۹۹۸	۸۲۷۵۰۹۵/۱۱	۰/۰۲۴۵
میانگین پیش‌بینی مدل میانگین متحرک یکپارچه اتورگرسیو	۱۱۸۴۵۰۰۰	۰/۱۴	۷۸۱۸۱۰۰	۰/۰۴۶۶

جدول (۷): نتایج آزمون تی مقایسه خطای میانگین مربعات مدل‌های مختلف با مدل شبکه عصبی ترکیبی (تقاضای گاز پنسیلوانیا و شهر سیرجان)


مدل	t-statistic	p-value	p < 0.05
مقایسه با شبکه عصبی ساده (پنسیلوانیا)	-۱۰/۰۴	۰/۰۰۰۱	بله
مقایسه با مدل رگرسیون بردار پشتیبان (پنسیلوانیا)	-۳/۸۴	۰/۰۰۱۱	بله
مقایسه با مدل میانگین متحرک یکپارچه اتورگرسیو (پنسیلوانیا)	-۳/۹۲	۰/۰۰۰۹	بله
مقایسه با شبکه عصبی ساده (سیرجان)	-۱۳/۴۰	$۱۰^{-۱۱} \times ۳/۸۸$	بله
مقایسه با مدل رگرسیون بردار پشتیبان (سیرجان)	-۱۶/۰۹	$۱۰^{-۱۲} \times ۱/۶۰$	بله
مقایسه با مدل میانگین متحرک یکپارچه اتورگرسیو (سیرجان)	-۱۲۴/۵۲	$۱۰^{-۳۵} \times ۲/۱۸$	بله

شکل (۷) مقایسه‌ای بین عملکرد دو مدل شبکه عصبی ساده و ترکیبی در پیش‌بینی مصرف ماهانه گاز در بخش شهری شهرستان سیرجان را نشان می‌دهد. در این نمودار، خطوط مشکی نشان‌دهنده مقادیر واقعی مصرف گاز هستند. خروجی مدل ساده با خطوط قرمز و خروجی مدل ترکیبی با خطوط آبی نمایش داده شده‌اند. همان‌طور که دیده می‌شود، روند مدل ساده اختلاف زیادی با داده‌های واقعی دارد، درحالی‌که مدل ترکیبی هماهنگی بیشتری با روند واقعی دارد. این موضوع نشان می‌دهد که مدل ترکیبی دقت بالاتری در پیش‌بینی مصرف گاز داشته و بهتر توانسته رفتار واقعی داده‌ها را مدل‌سازی کند. برای درک بهتر میزان انطباق داده‌های واقعی و خروجی مدل‌ها، بخشی از نمودار در شکل (۸) به صورت بزرگ‌نمایی شده ارائه شده است. این کار امکان مشاهده جزئیات و بررسی دقیق‌تر تفاوت‌ها و شباهت‌های میان داده‌های واقعی و پیش‌بینی مدل ترکیبی و ساده را فراهم می‌کند.

بررسی عملکرد مدل پیشنهادی در دو مجموعه داده متفاوت، یکی روزانه مربوط به ایالت پنسیلوانیا و دیگری ماهانه مربوط به بخش شهری سیرجان، نشان می‌دهد که مدل ترکیبی در هر دو مورد عملکرد مطلوبی داشته است. در هر دو مجموعه داده، خطای نسبی مدل پیشنهادی کمتر از سایر روش‌ها بوده و دقت بالاتری را نشان داده است. این موضوع بیانگر پایداری و تعمیم‌پذیری بالای مدل پیشنهادی در مواجهه با داده‌هایی با ویژگی‌های زمانی، مکانی و مقیاس متفاوت است. همچنین، تفاوت در نوع و مقیاس داده‌ها (روزانه و ماهانه) تأثیر محسوسی بر کارایی مدل نداشته و مدل ترکیبی توانسته است نسبت به نوسانات، نرمال‌سازی و تغییرات ساختاری در داده‌ها واکنش



شکل (۷): نمودار عملکرد شبکه حافظه طولانی کوتاه‌مدت ترکیبی و ساده هنگام پیش‌بینی داده‌های ماهانه سیرجان



شکل (۸): بزرگ‌نمایی بخشی از نمودار شکل (۷) برای مقایسه دقیق‌تر داده‌های واقعی با نتایج شبکه حافظه طولانی کوتاه‌مدت ترکیبی و ساده در پیش‌بینی داده‌های ماهانه سیرجان

آب و هوایی نظیر دما به عنوان متغیر کمکی بهره برد و با بهینه سازی پارامترهای شبکه، دقت پیش بینی را به میزان چشمگیری افزایش داد. علاوه بر این، روش مونت کارلو برای تخمین پیش بینی ها به کار گرفته شد. نتایج حاصل نشان داد که روش ترکیبی پیشنهادی عملکرد بسیار بهتری نسبت به مدل ساده داشته و توانسته است خطای پیش بینی را تا ۹۹/۹۹ درصد در برخی از پیش بینی ها کاهش دهد. کاربرد این مدل در برنامه ریزی و مدیریت منابع انرژی اهمیت زیادی دارد. کاهش قابل توجه خطای پیش بینی ها به شرکت های تأمین کننده گاز کمک می کند تا برنامه ریزی دقیق تری برای توزیع و مصرف بهینه انرژی داشته باشند و از اتلاف منابع جلوگیری کنند. همچنین، نتایج نشان داد که ترکیب اطلاعات تقاضای گاز با داده های محیطی مانند دما، تأثیر بسزایی در افزایش دقت مدل دارد. این یافته ها می توانند در سیاست گذاری های مرتبط با مدیریت مصرف گاز، به ویژه در فصول سرد سال، مورد استفاده قرار گیرند و به بهبود بهره وری و کاهش هزینه های عملیاتی کمک کنند.

۷. مطالعات آتی

با توجه به نتایج امیدوارکننده مدل ترکیبی ارائه شده در این پژوهش، توسعه های آتی می توانند در چندین جهت ادامه یابند. بررسی عملکرد مدل در مناطق جغرافیایی مختلف با ویژگی های آب و هوایی و الگوهای مصرف متفاوت، می تواند به سنجش میزان تعمیم پذیری آن کمک کند. همچنین، گسترش دامنه متغیرهای ورودی، از جمله عوامل اقلیمی مانند رطوبت و سرعت باد یا متغیرهای اقتصادی نظیر قیمت انرژی، می تواند دقت پیش بینی را افزایش دهد. از سوی دیگر، بهره گیری از ساختارهای پیشرفته تر شبکه های عصبی مانند حافظه طولانی کوتاه مدت دوطرفه^۱ و واحد بازگشتی دروازه دار و سایر مدل های پیشرفته در حوزه یادگیری عمیق، می تواند توانایی مدل را در شناسایی الگوهای پیچیده تر بهبود بخشد. ترکیب این شبکه ها با روش های مختلف تجزیه سیگنال و الگوریتم های بهینه سازی نوین نیز می تواند به توسعه مدلی با عملکرد دقیق تر و پایداری بالاتر منجر شود. در نهایت، پیاده سازی یک سامانه نرم افزاری تصمیم یار مبتنی بر مدل پیشنهادی و ارزیابی آن در شرایط واقعی مانند نوسانات شدید یا بحران های انرژی، گامی مهم در راستای کاربرد عملی این پژوهش در مدیریت بهینه منابع انرژی خواهد بود.

مناسبی نشان دهد. نتایج به دست آمده حاکی از آن است که مدل پیشنهادی قابلیت به کارگیری در شرایط واقعی و داده های متنوع را داراست و می تواند عملکردی قابل اطمینان ارائه دهد.

در انتها نیز به منظور بررسی معناداری آماری تفاوت عملکرد مدل ترکیبی با سایر مدل ها، از آزمون آماری t استفاده شده است. این آزمون به ما امکان می دهد مشخص کنیم که آیا تفاوت مشاهده شده میان مقادیر خطای مدل ها ناشی از تصادف است یا از نظر آماری معنادار است؟ در واقع، با استفاده از این آزمون مشخص شد که برتری مدل ترکیبی در هر دو منطقه (پنسیلوانیا و سیرجان) قابل اتکا و مبتنی بر تفاوت واقعی در عملکرد است، نه صرفاً نوسانات تصادفی داده ها.

در جدول (۷)، نتایج آزمون t برای مقایسه خطای میانگین مربعات میان مدل ترکیبی و سایر مدل ها در دو منطقه ایالت پنسیلوانیا و شهر سیرجان ارائه شده است. در هر دو ناحیه، مدل ترکیبی عملکرد به مراتب بهتری از خود نشان داده و تفاوت های مشاهده شده از نظر آماری معنادار بوده اند. باین حال، شدت این تفاوت در شهر سیرجان چشمگیرتر است؛ به طوری که مقادیر آماره در این ناحیه بسیار بزرگ تر و ارزش p حتی کمتر از ۰/۰۰۰۱ گزارش شده اند. این نتایج نشان می دهند که مدل ترکیبی در شرایط داده های متنوع، از جمله نواحی با پراکندگی و نوسان بالا مانند سیرجان، دارای پایداری عملکرد و دقت بالاتری است. نکته قابل توجه این است که هر دو ناحیه از نوع داده های تقاضای گاز هستند که داده های دما به عنوان داده کمکی به آن ها افزوده شده است. با توجه به نتایج، می توان گفت تلفیق اطلاعات دمایی به ویژه در نواحی با رفتار پیچیده تر (مانند سیرجان) موجب بهبود قابل ملاحظه دقت پیش بینی شده است. این موضوع تأکیدی بر اثربخشی ساختار ترکیبی در بهره برداری از ویژگی های چندمنبعی دارد.

۶. نتیجه گیری

در این پژوهش، با استفاده از ترکیب شبکه عصبی حافظه طولانی کوتاه مدت، الگوریتم تجزیه حالت متغیر و الگوریتم بهینه سازی کسینوس-سینوسی، مدل پیش بینی دقیقی برای تخمین تقاضای گاز ارائه شد. داده های مورد بررسی شامل مصرف گاز شهری سیرجان و داده های ایالت پنسیلوانیا بوده است. مدل پیشنهادی از اطلاعات

مراجع

[1] Sabzekar, M., Rezapour, A., Namakin, M., "Preicting CGS Pressure Using Machine Learning Case Study: Birjand", Energy Engineering and Management, Vol. 14, No. 3, PP. 14-27, 2024,

<https://doi.org/10.22052/EEM.2025.255658.1091>
[2] Ravnik, J., Jovanovac, J., Trupej, A., Vistica, N., Hribersek, M., "A sigmoid regression and artificial neural network models for day-ahead natural gas usage

- forecasting", Cleaner and Responsible Consumption, Vol. 3, article 100040, 2021, <https://doi.org/10.1016/j.clrc.2021.100040>
- [3] Wazirali, R., Yaghoubi, E., Shadi, M., Abujazar, S., Ahmad, R., Vakili, A. H., "State-of-the-art review on energy and load forecasting in microgrids using artificial neural networks, machine learning, and deep learning techniques", Electric Power Systems Research, Vol. 225, article 109792, 2023, <https://doi.org/10.1016/j.epsr.2023.109792>
- [4] Han, L., Zhang, R., Wang, X., Bao, A., Jing, H., "Multi-step wind power forecast based on VMD-LSTM", IET Renewable Power Generation, Vol. 13, No. 10, pp. 1690-1700, 2019, <https://doi.org/10.1049/iet-rpg.2018.5781>
- [5] Sezer, O. B., Gudelek, M. U., and Ozbayoglu, A. M., "Financial time series forecasting with deep learning: A systematic literature review: 2005–2019", Applied Soft Computing, Vol. 90, article 106181, 2020, <https://doi.org/10.1016/j.asoc.2020.106181>
- [6] Xing, Z., He, Y., Wang, X., Shao, K., Duan, J., "VMD-IARIMA-Based Time-Series Forecasting Model and its Application in Dissolved Gas Analysis", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 30, No. 2, pp. 802-811, 2022, <https://doi.org/10.1109/TDEI.2022.322822>
- [7] Agga, A., Abbou, A., El Houm, Y., Labbadi, M., "Short-term load forecasting based on CNN and LSTM deep neural networks", IFAC-PapersOnLine, Vol. 55, No. 12, pp. 777-781, 2022, <https://doi.org/10.1016/j.ifacol.2022.07.407>
- [8] Faiq, M., Tan, K. G., Liew, Ch. P., Hossain, F., Tso, Ch. P., Lim, L. L., Wong, A. Y. K., Shah, Z. M., "Prediction of energy consumption in campus buildings using long short-term memory", Alexandria Engineering Journal, Vol. 67, pp. 65-76, 2023, <https://doi.org/10.1016/j.aej.2022.12.015>
- [9] Bacanin, N., Jovanovic, L., Zivkovic, M., Kandasamy, V., Antonijevic, M., Deveci, M., Strumberger, I., "Multivariate energy forecasting via metaheuristic tuned long-short term memory and gated recurrent unit neural networks", Information Sciences, Vol. 642, pp. 119-122, 2023, <https://doi.org/10.1016/j.ins.2023.119122>
- [10] Hu, H., Gong, S., Taheri, B., "Energy demand forecasting using convolutional neural network and modified war strategy optimization algorithm", Heliyon, Vol. 10, no. 6, pp. 2-15, 2024, <https://doi.org/10.1016/j.heliyon.2024.e27353>
- [11] Waheed, W., Xu, Q., "Data-driven short term load forecasting with deep neural networks: Unlocking insights for sustainable energy management", Electric Power Systems Research, Vol. 232, article 1-12, 2024, <https://doi.org/10.1016/j.epsr.2024.110376>
- [12] Bhambu, A., Gao, R., Suganthan, P. N., "Recurrent ensemble random vector functional link neural network for financial time series forecasting", Applied Soft Computing, Vol. 161, article 111759, 2024, <https://doi.org/10.1016/j.asoc.2024.111759>
- [13] Menhaj, M. B., "Fundamentals of Neural Networks and Computational Intelligence", Amirkabir University of Technology (Tehran Polytechnic), Publication Center, 2008, ISBN:9789644630873
- [14] Hochreiter, S., Schmidhuber, J., "Long short-term memory", Neural Comput., Vol. 9, No. 8, pp. 1735-1780, 1997, <https://doi.org/10.1162/neco.1997.9.8.1735>
- [15] Kumar, I., Tripathi, B. K., Singh, A., "Attention-based LSTM network-assisted time series forecasting models for petroleum production", Engineering Applications of Artificial Intelligence, Vol. 123, article 106440, 2023, <https://doi.org/10.1016/j.engappai.2023.106440>
- [16] Ehteram, M., Nia, M. A., Panahi, F., Farrokhi, A., "Read-First LSTM model: A new variant of long short term memory neural network for predicting solar radiation data", Energy Conversion and Management, Vol. 305, article 118267, 2024, <https://doi.org/10.1016/j.enconman.2024.118267>
- [17] Haghighi Naeini, K., Khanjani, M., and Rastgar Sorkheh, M. A., "A Hybrid LSTM-VMD Model for Predicting Stock Prices in the Tehran Stock Exchange", The 1st International Conference on Management Capabilities in Industrial Engineering, Accounting, and Economics, Rah Danesh Higher Education Institute, Babol, Iran, 2023, Exclusive Code: 01211-81035, <https://civilica.com/doc/1690707/>
- [18] K. Dragomiretskiy, Zosso, D., "Variational mode decomposition", IEEE Transactions on Signal Processing, Vol. 62, No. 3, pp. 531-544, 2013, <https://doi.org/10.1109/TSP.2013.2288675>
- [19] Mirjalili, S., "SCA: a sine cosine algorithm for solving optimization problems", Knowledge-based Systems, Vol. 96, pp. 120-133, 2016, <https://doi.org/10.1016/j.knosys.2015.12.022>
- [20] Ghayas, M., "An Introduction to the Monte Carlo Simulation Method", Iran Polymer and Petrochemical Institute, Vol. 4, No. 1, pp. 67-77, 2014, <https://civilica.com/doc/601265>
- [21] Heydari, R., Haj Seyed Javadi, S. M. R., "Application of a Hybrid Data Mining Model (Genetic Algorithm-Wavelet-Monte Carlo Simulation) for Predicting Agricultural Product Prices: A Case Study of Future Saffron Prices in the Agricultural Commodity Exchange", Vol. 30, No. 4, pp. 73-105, 2022, <https://doi.org/10.30490/AEAD.2023.357440.1412>
- [22] Yadav, H., Thakkar, A., "NOA-LSTM: An efficient LSTM cell architecture for time series forecasting", Expert Systems with Applications, Vol. 238, article 1-10, 2024, <https://doi.org/10.1016/j.eswa.2023.122333>
- [23] Mohammadi, M., Jamshidi, S., Rezvanian, A., Gheisari, M., Kumar, A., "Advanced fusion of MTM-LSTM and MLP models for time series forecasting: An application for forecasting the solar radiation", Measurement: Sensors, Vol. 33, pp. 1-11, 2024, <https://doi.org/10.1016/j.measen.2024.101179>
- [24] Chen, K., Guo, S., Lin, Y., Ying, Z., "Least absolute relative error estimation", Journal of the American Statistical Association, Vol. 105, No. 491, pp. 1104-1112, 2010, <https://doi.org/10.1198/jasa.2010.tm09307>

پیوست الف

در این پیوست، نتایج حاصل از اجرای مدل‌های مختلف یادگیری ماشین و شبکه‌های عصبی بر مجموعه داده روزانه مربوط به ایالت پنسیلوانیا ارائه شده است. هدف از این بخش، مقایسه دقیق‌تر عملکرد مدل‌ها از نظر دقت پیش‌بینی و میزان خطا در شرایط واقعی داده‌های روزانه است. جداول ارائه شده شامل مقادیر کمینه خطا برای شاخص‌های مختلف ارزیابی و نیز بهترین مقادیر پیش‌بینی شده به همراه خطای نسبی آن‌هاست. این تحلیل‌ها درک عمیق‌تری از عملکرد مدل پیشنهادی در مقایسه با روش‌های جایگزین فراهم می‌کنند و نقش مهمی در ارزیابی جامع کارایی مدل ترکیبی در شرایط مختلف ایفا می‌نمایند.

جدول (۱) مقادیر خطای بهترین پیش‌بینی را برای ارزیابی عملکرد مدل‌ها با استفاده از چهار شاخص اصلی نشان می‌دهد. مطابق این جدول، مدل حافظه طولانی کوتاه مدت ترکیبی در تمامی شاخص‌ها دارای کمترین مقدار خطا بوده و در مقایسه با سایر مدل‌ها عملکرد برتری از خود نشان داده است. به طور خاص، مقدار خطای میانگین مربعات در این مدل برابر با $10^{-7} * 8376/6$ گزارش شده، درحالی که در مدل حافظه طولانی کوتاه مدت ساده این مقدار برابر با $0/0389$ است. این اختلاف معادل کاهش $99/998$ درصدی در مقدار خطای میانگین مربعات است. همین روند کاهش در سایر شاخص‌ها از جمله مقدار خطای جذر میانگین مربعات، میانگین مطلق خطا و درصد میانگین مطلق خطا نیز مشاهده می‌شود. نتایج جدول نشان می‌دهد که مدل حافظه طولانی کوتاه مدت ترکیبی بهترین پیش‌بینی را در مقایسه با سایر مدل‌ها به دست آورده است. این مدل نسبت به مدل رگرسیون

بردار پشتیبان و مدل میانگین متحرک یکپارچه اتورگرسیون به ترتیب حدود $99/9$ درصد و $99/94$ درصد کاهش خطا داشته است که نشان دهنده دقت و کارایی بالای آن در پیش‌بینی داده‌هاست. در مجموع، این نتایج نشان می‌دهد که مدل حافظه طولانی کوتاه مدت ترکیبی با کاهش چشمگیر و معنادار در تمامی شاخص‌های خطا، دقیق‌ترین و کارآمدترین مدل پیش‌بینی در این پژوهش بوده و گزینه‌ای مناسب برای تحلیل داده‌های پیچیده زمانی به شمار می‌رود.

جدول (۲) مقایسه بهترین پیش‌بینی‌ها با خطای نسبی برای مدل‌های حافظه طولانی کوتاه مدت ساده، ترکیبی، رگرسیون بردار پشتیبان و میانگین متحرک یکپارچه اتورگرسیون نشان می‌دهد. نتایج نشان می‌دهند که مدل ترکیبی در پیش‌بینی تقاضای روز اول و دوم با بهترین پیش‌بینی نسبت به سایر مدل‌ها عمل کرده است. برای مثال، در پیش‌بینی روز اول (با مقدار واقعی 75391)، مدل ترکیبی با خطای نسبی $0/004$ و مدل ساده با خطای نسبی $0/0419$ به پیش‌بینی پرداخته‌اند که نشان دهنده بهبود چشمگیر مدل ترکیبی است. در پیش‌بینی روز دوم (با مقدار واقعی 71138) نیز مدل ترکیبی با خطای نسبی $0/0065$ نسبت به مدل ساده ($0/0173$) و رگرسیون بردار پشتیبان ($0/0162$) عملکرد بهتری از خود نشان داده است. از سوی دیگر، مدل میانگین متحرک یکپارچه اتورگرسیون در هر دو روز پیش‌بینی، با خطای نسبی $0/0169$ در روز اول و $0/0466$ در روز دوم عملکرد ضعیف‌تری نسبت به مدل ترکیبی داشته است. این مقایسه نشان می‌دهد که مدل حافظه طولانی کوتاه مدت ترکیبی در هر حالت برترین دقت را در پیش‌بینی‌های کوتاه مدت تقاضای انرژی گاز ارائه می‌دهد.

جدول (۱): مقایسه خطای بهترین پیش‌بینی شبکه‌ها برای داده‌های روزانه ایالت پنسیلوانیا

تایم ارزیابی شبکه عصبی	MSE	RMSE	MAE	MAPE
خطای بهترین پیش‌بینی شبکه عصبی ترکیبی	$10^{-7} * 8376/6$	$10^{-2} * 2890/8$	$10^{-4} * 6464/6$	$0/0255$
خطای بهترین پیش‌بینی شبکه عصبی ساده	$0/0389$	$0/1972$	$0/1635$	$0/3683$
خطای بهترین پیش‌بینی مدل رگرسیون بردار پشتیبان	$0/01024$	$0/032002$	$0/029089$	$2/87$
خطای بهترین پیش‌بینی مدل میانگین متحرک یکپارچه اتورگرسیون	$0/01176$	$0/034310$	$0/031360$	$3/18$

جدول (۲): مقایسه عملکرد دقیق‌ترین پیش‌بینی مدل‌ها برای داده‌های روزانه ایالت پنسیلوانیا

نوع مدل	مقدار تقاضای واقعی روز اول =	خطای نسبی	مقدار تقاضای واقعی روز دوم =	خطای نسبی
	۷۵۳۹۱		۷۱۱۳۸	
پیش‌بینی برای شبکه عصبی ترکیبی	۷۵۶۹۶/۰۶۴۹	$0/0040$	۷۰۶۷۳/۴۶۱	$0/0065$
پیش‌بینی برای شبکه عصبی ساده	۷۲۲۲۸/۱۸۷۲	$0/0419$	۷۲۳۶۹/۸۵۱۱	$0/0173$
پیش‌بینی مدل رگرسیون بردار پشتیبان	۷۲۲۸۲/۲۴	$0/0412$	۷۲۲۹۲/۰۳	$0/0162$
پیش‌بینی مدل میانگین متحرک یکپارچه اتورگرسیون	۷۶۶۶۹	$0/0169$	۷۴۴۵۵	$0/0466$

پیوست ب:

این پیوست به بررسی عملکرد مدل‌های مختلف در پیش‌بینی تقاضای گاز در مقیاس ماهانه و در سطح بخش شهری سیرجان اختصاص دارد. هدف از این تحلیل، سنجش دقت مدل‌ها در مواجهه با داده‌هایی با مقیاس زمانی متفاوت (ماهانه) و شرایط جغرافیایی متمایز است. جداول ارائه‌شده شامل مقایسه مقادیر کمینه خطا و همچنین ارزیابی دقت پیش‌بینی مدل‌ها در دو بازه زمانی مختلف است. با بررسی این نتایج، میزان تطابق مدل ترکیبی با داده‌های واقعی و توانایی آن در ارائه پیش‌بینی‌های دقیق در سطح کاربردی مشخص می‌شود. این بخش نشان می‌دهد که مدل پیشنهادی تا چه حد در تحلیل داده‌های متفاوت و محیط‌های شهری قابل اتکا و مؤثر عمل کرده است.

جدول (۳) مقایسه بهترین مقدار پیش‌بینی شده توسط مدل‌ها را نمایش می‌دهد. مدل ترکیبی در هر دو روز، کمترین خطای نسبی را

ثبت کرده است، که نشان‌دهنده عملکرد برتر آن نسبت به سایر مدل‌ها است. درمقابل، مدل حافظه طولانی کوتاه‌مدت ساده، رگرسیون بردار پشتیبان و و مدل میانگین متحرک یکپارچه اتورگرسیون در پیش‌بینی هر دو روز خطای بیشتری داشته‌اند. بنابراین، مدل ترکیبی دقیق‌ترین پیش‌بینی را در میان مدل‌های مورد بررسی ارائه کرده است. جدول (۴) مقایسه بهترین نتایج پیش‌بینی هر مدل را ارائه می‌دهد. مدل ترکیبی در هر دو ماه اول و ۰/۰۱۳۳ در ماه دوم. این درحالی است که مدل حافظه طولانی کوتاه‌مدت ساده، مدل رگرسیون بردار پشتیبان و مدل میانگین متحرک یکپارچه اتورگرسیون به‌ترتیب دارای خطای نسبی بیشتری هستند. مدل ترکیبی با دقت بالای خود، پیش‌بینی‌هایی نزدیک‌تر به مقادیر واقعی ارائه کرده و نسبت به سایر مدل‌ها گزینه‌ای مطمئن‌تر برای تحلیل تقاضای گاز شهری بوده است.

جدول (۳): مقایسه خطا بهترین پیش‌بینی شبکه‌ها برای داده‌های ماهانه بخش شهری سیرجان

MAPE	MAE	RMSE	MSE	تابع ارزیابی شبکه عصبی
۰/۳۴۰۷	۰/۰۰۴۴	۰/۰۰۵۵	۳/۰۶۶۲ ^{۱۰}	خطای بهترین پیش‌بینی شبکه عصبی ترکیبی
۰/۳۶۸۳	۰/۳۷۰۱	۰/۴۹۳۷	۰/۲۴۳۷	خطای بهترین پیش‌بینی شبکه عصبی ساده
۲۱/۲۱	۰/۲۵۶۸۱۳	۰/۳۵۰۲۶۱	۰/۱۲۲۶۸۳	خطای بهترین پیش‌بینی مدل رگرسیون بردار پشتیبان
۱۰/۹۶	۰/۱۲	۰/۱۳	۰/۰۲	خطای بهترین پیش‌بینی مدل میانگین متحرک یکپارچه اتورگرسیون

جدول (۴): مقایسه عملکرد بهترین پیش‌بینی مدل‌ها برای داده‌های ماهانه بخش شهری سیرجان

خطای نسبی	مقدار تقاضای واقعی ماه دوم = ۸۴۸۲۵۵۲	خطای نسبی	مقدار تقاضای واقعی ماه اول = ۱۳۷۸۶۶۵۸	نوع مدل
۰/۰۱۳۳	۸۵۹۵۶۱۸	۰/۰۰۷۲	۱۳۶۸۷۸۸۰	پیش‌بینی برای شبکه عصبی ترکیبی
۰/۰۸۵۸	۷۷۵۴۵۴۱/۵	۰/۴۶۴۴	۷۳۸۳۹۲۵	پیش‌بینی برای شبکه عصبی ساده
۰/۰۲۴۵	۸۲۷۵۰۹۶/۰۵	۰/۳۹۹۸	۸۲۷۵۱۰۳/۷۱	پیش‌بینی مدل رگرسیون بردار پشتیبان
۰/۰۸	۷۸۱۸۱۰۰	۰/۱۴	۱۱۸۴۵۰۰۰	پیش‌بینی مدل میانگین متحرک یکپارچه اتورگرسیون