

A net load forecasting framework for power systems with high renewable energy penetration based on deep learning.

Gholamreza Memarzadeh*, Neda Raam

Department of Electrical Engineering, Faculty of Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran. Email: g.memarzadeh@vru.ac.ir

ARTICLE INFO

Article type:
Research Paper

Article History:

Received 18 May 2025

Revised 15 June 2025

Accepted 13 September 2025

Published Online 23 September 2025

Keywords:

Pure Load Forecast,
Input Selection,
CNN Neural Network,
GRU Neural Network,
LSTM Neural Network.

ABSTRACT

The expansion of renewable energy sources in the residential sector, while an important step towards a more sustainable energy landscape, poses unique challenges for power system operators. The intermittent nature of renewable energy generation, primarily from solar and wind, introduces significant variability and uncertainty into the grid. Unlike conventional power plants, which provide steady and controllable output, renewable generation depends heavily on weather conditions, leading to rapid and sometimes unpredictable fluctuations in supply. To mitigate these challenges, system operators must invest in advanced grid management systems, flexible demand-response mechanisms, and large-scale energy storage solutions. Additionally, accurate forecasting of net load—defined as the total electricity demand minus renewable generation—is crucial for maintaining grid stability, optimizing energy dispatch, and reducing reliance on costly balancing reserves. Traditional forecasting methods often struggle to capture the nonlinear and stochastic nature of net load, particularly in systems with high renewable penetration. This paper presents a comprehensive framework for day-ahead net load forecasting, leveraging advanced machine learning techniques to improve prediction accuracy. The proposed VMD-MIIG-CNN-GRU-BiLSTM approach effectively captures both spatial and temporal dependencies in net load data while accounting for external factors such as weather patterns and consumption behavior. Experimental results demonstrate that the proposed model achieves a MAPE of approximately 8%, significantly outperforming conventional forecasting methods. The framework's robustness in handling the inherent complexities of renewable-integrated power systems makes it a valuable tool for grid operators, enabling more efficient resource allocation and enhanced system reliability.

Cite this article: Memarzadeh, G., & Raam, N. (2025). A net load forecasting framework for power systems with high renewable energy penetration based on deep learning. *Energy Systems: Technology and Management*, 1 (1), 1-7. DOI: <http://doi.org/10.48306/estm.2025.232462>



© Graduate University of Advanced Technology.
DOI: <http://doi.org/10.48306/estm.2025.232462>

* Corresponding author.
Email: g.memarzadeh@vru.ac.ir



یک چارچوب پیش‌بینی بار خالص برای سیستم‌های قدرت با نفوذ بالای انرژی تجدیدپذیر مبتنی بر یادگیری عمیق

غلامرضا معمارزاده*، ندا رام

گروه مهندسی برق، دانشکده مهندسی، دانشگاه ولی عصر (عج) رفسنجان، رفسنجان، ایران. رایانامه: g.memarzadeh@vru.ac.ir

چکیده	اطلاعات مقاله
<p>گسترش منابع انرژی تجدیدپذیر در بخش مسکونی، در حالی که گامی مهم به سوی چشم‌انداز انرژی پایدارتر است، چالش‌های منحصر به فردی را برای اپراتورهای سیستم قدرت ایجاد می‌کند. ماهیت متناوب تولید انرژی‌های تجدیدپذیر، عمدتاً خورشیدی و بادی، می‌تواند تغییرپذیری و عدم قطعیت قابل توجهی را به شبکه وارد کند. علاوه بر این، نوسانات سریع در تولید انرژی‌های تجدیدپذیر می‌تواند زیرساخت شبکه را تحت فشار قرار دهد و نیاز به سرمایه‌گذاری در سیستم‌های پیشرفته مدیریت شبکه و راه‌حل‌های ذخیره‌سازی انرژی برای حفظ پایداری و قابلیت اطمینان سیستم را ایجاد کند. این مقاله یک چارچوب برای پیش‌بینی بار خالص ارائه می‌دهد. در آن با استفاده از تکنیک‌های پیش‌بینی پیشرفته بار خالص روز آینده را پیش‌بینی می‌کند. الگوریتم پیشنهادی VMD-MIIG-CNN-GRU-BiLSTM به میانگین خطای مطلق درصد (MAPE) تقریباً 8٪ برای پیش‌بینی بار خالص دست می‌یابد که اثربخشی آن را در نظر گرفتن پیچیدگی‌های ذاتی این متغیرها نشان می‌دهد.</p>	<p>نوع مقاله: پژوهشی</p> <p>تاریخ‌های مقاله: تاریخ دریافت: ۱۴۰۴/۰۲/۲۸ تاریخ بازنگری: ۱۴۰۴/۰۳/۲۵ تاریخ پذیرش: ۱۴۰۴/۰۶/۲۲ تاریخ انتشار: ۱۴۰۴/۰۷/۰۱</p> <p>کلیدواژه: پیش‌بینی بار خالص، انتخاب ورودی، شبکه عصبی CNN، شبکه عصبی GRU، شبکه عصبی LSTM.</p>

استناد: معمارزاده، غلامرضا، و رام، ندا (۱۴۰۴). یک چارچوب پیش‌بینی بار خالص برای سیستم‌های قدرت با نفوذ بالای انرژی

تجدیدپذیر مبتنی بر یادگیری عمیق. سیستم‌های انرژی: فناوری و مدیریت، ۱ (۱) ۷-۱.

DOI: <http://doi.org/10.48306/estm.2025.232462>

© دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته.

DOI: <http://doi.org/10.48306/estm.2025.232462>



* نویسنده مسئول.

رایانامه: g.memarzadeh@vru.ac.ir

۱- مقدمه

منابع انرژی تجدیدپذیر نقش مهمی در تولید برق در کشورهای بی‌شماری در سطح جهان دارند. در نتیجه، سهم انرژی تجدیدپذیر در تقاضای کلی برق قابل توجه است. نگرانی‌های روبه‌رشد در مورد کاهش انتشار کربن و افزایش هزینه‌های سوخت‌های فسیلی مانند گاز طبیعی، نفت و زغال‌سنگ، بر لزوم گزینه‌های تجدیدپذیر تأکید می‌کند. با این حال، ادغام مقدار قابل توجهی از انرژی باد در سیستم‌های برق، چالش‌های عملیاتی قابل توجهی را ایجاد می‌کند. مسئله اصلی تولید انرژی تجدیدپذیر - به‌ویژه باد و خورشیدی - که به منابع انرژی سنتی پردازش نشده است، عدم اطمینان ذاتی آن است.

پیش‌بینی دقیق کوتاه‌مدت بار برق، منابع تجدیدپذیر و قیمت‌ها برای مدیریت مؤثر و بهینه‌سازی منابع انرژی در میکروگریدها بسیار مهم است. باتوجه به ماهیت نامنظم، متناوب و نامشخص این منابع، طراحی و اجرای مدل‌های پیش‌بینی قوی و دقیق ضروری است. روش‌های مختلف پیش‌بینی برای تولید انرژی تجدیدپذیر در سال‌های اخیر پدیدار شده است که به مدل‌های فیزیکی [۳-۱۱] روش‌های آماری [۷-۴]، رویکردهای هوش مصنوعی و مدل‌های ترکیبی طبقه‌بندی شده‌اند.

مدل‌های فیزیکی از داده‌های هواشناسی و جغرافیایی استفاده می‌کنند، و در پیش‌بینی‌های تولید انرژی تجدیدپذیر بلندمدت اما فاقد قابلیت‌های پیش‌بینی کوتاه‌مدت است. در مقابل، مدل‌های آماری ارتباط بین داده‌های ورودی و خروجی را ایجاد می‌کنند، و دقت پیش‌بینی کوتاه‌مدت برای انرژی‌های تجدیدپذیر را در مقایسه با مدل‌های فیزیکی بهبود می‌بخشند. تکنیک‌های هوش مصنوعی، از جمله شبکه‌های عصبی مصنوعی [۱۲-۸]، بردار پشتیبان ماشین [۱۳]، منطق فازی [۱۴] و شبکه‌های عصبی عمیق [۱۷-۱۵]، در قدرت تجدید پذیر کوتاه مدت دقت قابل توجهی را نشان داده‌اند. نکته قابل توجه، مدل‌های ترکیبی با ادغام نقاط قوت روش‌های مختلف، در نتیجه دقت پیش‌بینی برتر برای تولید انرژی تجدید پذیر کوتاه مدت است [۲۰-۱۸].

ماهیت غیرقابل پیش‌بینی و پیچیده تولید انرژی تجدیدپذیر اهمیت پیش‌بینی دقیق برای تولیدکنندگان انرژی را برجسته می‌کند. با استفاده از مدل‌های ترکیبی، بخش انرژی تجدیدپذیر می‌تواند تصمیمات آگاهانه‌ای اتخاذ کند، عملیات را بهینه کند و مقرون‌به‌صرفه بودن را در بازار برق بی‌ثبات بهبود بخشد. با پیشرفت تحقیق و فناوری، مدل‌های ترکیبی پیشرفته برای افزایش دقت و قابلیت اطمینان پیش‌بینی انرژی تجدیدپذیر قرار دارند و از این طریق باعث گسترش پایدار انرژی تجدیدپذیر در چارچوب جهانی انرژی می‌شوند.

به‌عنوان مثال، رامسامی و همکارانش در سال ۲۰۱۵ یک رویکرد ترکیبی را برای پیش‌بینی تولید انرژی سیستم‌های فتوولتائیک ابداع کردند. این مدل‌های ترکیبی بهتر از مدل‌های تک‌مرحله‌ای مربوطه عمل می‌کنند و نشان دادند که رگرسیون گام‌به‌گام مدل هیبریدی

شبکه عصبی عملکرد مناسبی دارد [۲۱]. در تحقیقی دیگر یک روش تجزیه حالت تجربی چندمتغیره به همراه بهینه‌سازی کلونی مورچه‌ها و جنگل تصادفی برای پیش‌بینی تابش ماهانه خورشیدی ارائه شده است [۲۲]. لی و همکاران یک مدل پیش‌بینی چندمرحله‌ای برای تولید برق فتوولتائیک مبتنی بر مدل ترکیبی متشکل از تجزیه حالت تغییر و یک مدل یادگیری شدید عمیق را معرفی کردند. مدل پیشنهادی دارای قابلیت‌های اطلاعاتی خوبی است و در پروژه‌های عملی به‌راحتی قابل استفاده است [۲۳]. چن و همکارانش، یک روش پیش‌بینی بسیار کوتاه‌مدت برای نیروگاه‌های فتوولتائیک با استفاده از یک مختصات طبقه‌بندی تابش ساده به همراه یک مدل LSTM، با استفاده از مجموعه داده‌های تاریخی چندمتغیره کوتاه‌مدت برای افزایش دقت تهیه کردند [۲۴]. لین و همکاران یک مدل ترکیبی برای پیش‌بینی فتوولتائیک ارائه داد که از یک رویکرد تجزیه دو مرحله‌ای، یک شبکه BiLSTM که توانایی مدل در ضبط روابط داده پیچیده و بهبود صحت را تقویت می‌کند [۲۵]. لیمونی و همکاران با ترکیب شبکه‌های LSTM با شبکه‌های TCN یک روش پیش‌بینی دقیق برای تولید برق فتوولتائیک بسیار کوتاه‌مدت ارائه داد. این رویکرد پیش‌بینی یک‌مرحله‌ای و چندمرحله‌ای را تسهیل می‌کند، و به طور مؤثری وابستگی‌های زمانی در داده‌های انرژی خورشیدی را برای بهبود دقت پیش‌بینی ضبط می‌کند [۲۸].

۲- روش پیش‌بینی بار خالص

این بخش روشی را برای پیش‌بینی بار خالص در حالی که تأثیر منابع انرژی تجدیدپذیر را در نظر می‌گیرد، تشریح می‌کند. برای انجام این کار، بار واقعی ریزش‌بکه با کم کردن سهم ترکیبی تولید باد و خورشید تنظیم می‌شود و پارامتر پیش‌بینی هدف: بار خالص به دست می‌آید. نمایش ریاضی این رویکرد در رابطه (۱) نشان داده شده است:

$$\text{Netload} = \text{Load} - (\text{P}_{\text{PV}} - \text{P}_{\text{Wind}}) \quad (1)$$

که در آن پارامترهای P_{PV} ، P_{Wind} و Netload به ترتیب بار الکتریکی، تولید انرژی خورشیدی و بادی و بار خالص پیش‌بینی شده شبکه هستند.

برای مقابله مؤثر با این چالش پیش‌بینی، یک روش ترکیبی پیشنهاد شده است که تجزیه حالت متغیر (VMD) را برای گسسته‌سازی سیگنال، انتخاب ورودی مبتنی بر MI-IG و یک مدل CNN - GRU - BiLSTM برای پیش‌بینی سیگنال باد چند مرحله‌ای پیش‌بینی می‌کند. اصل اساسی این رویکرد، استفاده از مدل ترکیبی به عنوان یک چارچوب رگرسیون است. این تضمین می‌کند که ابعاد ماتریس هدف مستقیماً با افق پیش‌بینی همبستگی دارد. به عنوان مثال، اگر ابعاد ماتریس آموزش 1000×3000 باشد، ابعاد ماتریس هدف متناسب با افق پیش‌بینی مقیاس می‌شود. به طور خاص، اگر افق پیش‌بینی روی ۲۴ تنظیم شود، ماتریس هدف ابعاد 24×3000 را نشان می‌دهد.

و خروجی با (x_i, y) نشان داده می‌شود که بر اساس محاسبه توزیع احتمالی مشترک $P(x, y)$ و توزیع احتمالی مستقل $P(x)$ و $P(y)$ است. فرض کنید که:

$$SC = \{x_1, x_2, x_3, \dots, x_M\} \quad (2)$$

مجموعه‌ای از ورودی‌ها و y خروجی است که بایستی پیش‌بینی شود. مرتبط بودن خروجی y و با هر یک از x_i ها $D(x_i)$ نامیده شده است و به عبارت دیگر بیانگر میزان شباهت یک ورودی با خروجی مسئله است و رابطه آن برابر است با:

$$D(x_i) = I(x_i, y) \quad (3)$$

همچنین $I(x, y)$ مبتنی بر اطلاعات متقابل بین دو متغیر تصادفی x و y از طریق رابطه (4) محاسبه می‌شود:

$$MI(x, y) = \sum_{i=1}^n \sum_{j=1}^m P(x_i, y_j) \log_2 \left(\frac{P(x_i, y_j)}{P(x_i)P(y_j)} \right) \quad (4)$$

که در معادله فوق متغیرهای تصادفی x و y به ترتیب شامل m و n متغیر هستند.

(ب) فیلتر مشابه بودن 1: در بیش‌تر تحقیقات گذشته تمامی اطلاعات مشترک بین دو ورودی برای محاسبه مشابه بودن پیشنهاد شده است. در مراجع مختلف این موضوع مورد بحث قرار گرفته است که زمانی دو ورودی x_i و x_j بسیار شبیه به هم باشند می‌توان یکی از این دو ورودی را انتخاب کرد. به عبارت دیگر دو ورودی انتخاب شده ممکن است شباهت بسیار بالایی به هم داشته باشند در حالی که این دو ممکن است با خروجی پیش‌بینی شباهت کمی داشته باشند. به عبارت دیگر با استفاده از مفهوم مشابه بودن به بررسی میزان شباهت دو ورودی داده پرداخته شده است پس اگر شباهت دو ورودی مشخص از یک مقدار آستانه بیشتر باشد، حذف یکی از این داده‌های ورودی نه تنها خللی در روند شبیه‌سازی ایجاد نمی‌کند بلکه در روند همگرایی الگوریتم تسریع خواهد بخشید. از طرفی اگر مقدار آستانه زیاد تعیین شود داده‌های زیادی جهت انتخاب مشخص نخواهد شد. محاسبه مشابه بودن یا همان $RE(x_i, x_j)$ به شکل زیر ارائه شده است:

$$RE(x_i, x_j) = I(x_i, x_j) \quad (5)$$

که در این معادله x_i و x_j دو ورودی انتخاب شده هستند. یکی دیگر از معیارها برای مفهوم مشابه بودن برای دو ورودی x_i و x_j بر پایه مفهوم سود متقابل 2 است که شرح و بسط آن در روابط زیر آورده شده است:

$$RE(x_i, x_j) = |IG(x_i; x_j; y)| \quad (6)$$

$$IG(x_i; x_j; y) = MI[(x_i, x_j); y] - MI(x_i, y) - MI(x_j, y) \quad (7)$$

الگوریتم بیان شده در این رساله برای پیاده‌سازی انتخاب ورودی بر پایه مفاهیم مشابه بودن و مرتبط بودن به صورت زیر عمل می‌کند:

۱- ابتدا با استفاده از رابطه (۳) به محاسبه مقدار فیلتر مرتبط بودن بین کلیه ورودی‌ها و خروجی پرداخته شده است. ورودی‌هایی که میزان این فاکتور مرتبط بودن بالاتر از حد آستانه مشخصی باشد انتخاب می‌شوند.

۱. تجزیه سیگنال ورودی با استفاده از VMD: در ابتدا، VMD برای تجزیه سیگنال بار خالص اصلی به اجزای تشکیل دهنده آن اعمال می‌شود.

۲. ایجاد ماتریس: ماتریس‌های آموزش و هدف با استفاده از 1000×3000 نمونه آموزشی ایجاد می‌شوند. ماتریس آموزش دارای ابعاد 1000×3000 خواهد بود، در حالی که ماتریس هدف با توجه به افق پیش‌بینی مقیاس بندی می‌شود.

۳. انتخاب ویژگی مبتنی بر MI-IG: تکنیک انتخاب ویژگی MI-IG برای رتبه بندی ورودی‌های بالقوه بر اساس ارزش اطلاعاتی آنها برای پیش‌بینی بار خالص استفاده می‌شود.

۴. کاربرد مدل: متعاقباً، مدل CNN - GRU - BiLSTM تمامی لایه‌های فرعی مشتق شده از مراحل قبل را پیش‌بینی می‌کند.

۵. تجمیع نتایج: در نهایت، نتایج پیش‌بینی بار خالص با تجمیع پیش‌بینی‌ها از همه لایه‌های فرعی تولید می‌شود.

۲-۱- تجزیه سیگنال ورودی با استفاده از VMD

بارهای الکتریکی و منابع انرژی تجدیدپذیر اغلب رفتارهای غیرخطی و دینامیکی از خود نشان می‌دهند که چالش‌های مهمی را برای پیش‌بینی دقیق ایجاد می‌کنند. تجزیه حالت متغیر (VMD) به ویژه در استخراج ویژگی‌های مختلف این سیگنال‌های سری زمانی، از جمله نقاط شکست و ناپیوستگی‌هایی که ممکن است توسط سایر تکنیک‌های تحلیل سیگنال ناپدید گرفته شوند، ماهر است. با تبدیل سیگنال‌ها به حوزه فرکانس، VMD بینش‌های ارزشمندی را در مورد رفتار آنها در مقیاس‌های زمانی مختلف ارائه می‌دهد. به عنوان یک روش پردازش سیگنال که به طور خاص برای سیگنال‌های غیر ثابت طراحی شده است، VMD آنها را به تعداد محدودی از سیگنال‌های فرعی تجزیه می‌کند که هر کدام دارای ویژگی‌های پراکندگی مشخصی هستند. این امر بازسازی دقیق سیگنال اصلی را با حفظ ویژگی‌های اساسی آن تضمین می‌کند.

۲-۲- انتخاب ورودی مبتنی بر اطلاعات متقابل

انتخاب ورودی فرآیندی است که معمولاً در یادگیری ماشینی استفاده می‌شود، که در آن زیرمجموعه‌ای از ویژگی‌های موجود داده‌ها برای استفاده از الگوریتم یادگیری انتخاب می‌شوند. یکی از پیشرفته‌ترین تکنیک‌های انتخاب ورودی روش MI است که بر اساس مفهوم آنتروپی اطلاعات است. در ادامه روش پیشنهادی برای انتخاب بهترین ورودی‌ها شرح داده شده است. در این بخش روش ارائه شده جهت اعمال فیلتر دومرحله‌ای ورودی برای انتخاب بهترین ورودی‌ها بیان شده است.

الف) فیلتر مرتبط بودن: میزان شباهت داده‌های ورودی و خروجی یک عامل مهم برای انتخاب ورودی است. میزان MI بین خروجی و ورودی یک روش کارا جهت محاسبه این شباهت است. MI بین ورودی

شبیه‌سازی روش پیشنهادی از خالص را طی چهار روز در چهار ماه مختلف سال ۲۰۱۸ با استفاده از روش VMD-MIIG-CNN-GRU-BiLSTM، همانطور که در بخش ۲ شرح داده شده است، پیش‌بینی کردیم. این رویکرد پیش‌بینی نوآورانه به طور موثر مدل‌سازی پارامترهای عدم قطعیت سیستم قدرت، با ترکیب عناصر کلیدی مانند بار الکتریکی، تولید برق بادی و تولید برق خورشیدی را بیشتر افزایش می‌دهد.

برای ارزیابی عملکرد این روش‌های پیش‌بینی، ما از چندین معیار دقت استفاده می‌کنیم، به‌ویژه میانگین درصد مطلق خطا (MAPE)، میانگین خطای مطلق (MAE) و ریشه خطای میانگین مربعات (RMSE). فرمول این شاخص‌ها به ترتیب در معادلات (۸)، (۹) و (۱۰) بیان شده است. فرمول این شاخص‌ها به ترتیب در معادلات (۸)، (۹) و (۱۰) بیان شده است. در این معادلات، N تعداد کل ساعت‌ها در هر ماه، S_i^{Real} نشان دهنده مقدار واقعی در زمان i ، و S_i^{For} مقدار پیش‌بینی شده را در همان زمان نشان می‌دهد. با استفاده از این معیارها، می‌توانیم اثربخشی روش‌های پیش‌بینی پیشنهادی را به صورت کمی ارزیابی کنیم. این ارزیابی جامع نه تنها صحت پیش‌بینی‌های ما را تأیید می‌کند، بلکه بر اهمیت ترکیب تکنیک‌های پیش‌بینی قوی در بهینه‌سازی اندازه ذخیره ساز انرژی در ریزشکها تأکید می‌کند.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|S_i^{Real} - S_i^{For}|}{S_i^{Real}} \times 100\% \quad (8)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |S_i^{Real} - S_i^{For}| \quad (9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i^{Real} - S_i^{For})^2} \quad (10)$$

۲- سپس برای هر ورودی انتخاب‌شده در مرحله قبل با استفاده از روابط مطرح‌شده در قسمت فیلتر مشابه بودن میزان این شاخص محاسبه خواهد شد. اگر مقدار این شاخص از حد آستانه مشخصی بیشتر باشد ورودی با میزان کمتر از این شاخص از چرخه انتخاب ورودی خارج می‌شود.

ورودی‌های باقی‌مانده پس از اجرای دو مرحله فوق، جز ورودی‌ها با ویژگی مرتبط با خروجی و غیر زائد هستند. این روش انتخاب ورودی پیشنهادی یک معیار دقیق برای انتخاب ورودی‌های کارآمد است که می‌تواند تأثیر بسزایی در دقت پیش‌بینی داشته باشد.


۲-۳- تخمینگر مبتنی بر روش CNN-GRU-BiLSTM

ادغام شبکه‌های عصبی کانولوشن (CNN) و حافظه کوتاه مدت (LSTM) یک قدرتمند برای مدیریت موثر داده‌های سری زمانی ارائه می‌دهد. لایه‌های CNN در استخراج بینش‌های ارزشمند و یادگیری بازنمایی‌های داخلی از مجموعه داده‌های سری زمانی برتری دارند، در حالی که لایه‌های LSTM در گرفتن وابستگی‌های کوتاه‌مدت و بلندمدت درون داده‌ها مهارت دارند. بر اساس این پایه، مطالعه ما یک رویکرد ترکیبی را معرفی می‌کند که CNN، واحدهای بازگشتی GRU و LSTM (BiLSTM) را برای بهبود پیش‌بینی بار خالص روز آینده ترکیب می‌کند. مؤلفه اولیه مدل پیش‌بینی ترکیبی ما، لایه CNN است که از عملیات پیچیده ریاضی - ریاضی برای استخراج ویژگی‌های حیاتی از متغیرهای ورودی استفاده می‌کند. این مرحله مقدماتی برای شناسایی الگوهای مهم در داده‌ها بسیار مهم است. اجزای بعدی از ویژگی‌های فضایی تولید شده توسط لایه‌های GRU و BiLSTM استفاده می‌کنند، که برای گرفتن وابستگی‌های زمانی و اطلاعات در بازه‌های زمانی مختلف ضروری هستند. لایه GRU، مجهز به مکانیسم‌های دروازه‌ای، به طور موثر داده‌های متوالی را مدل‌سازی می‌کند، در حالی که لایه BiLSTM اطلاعات را به صورت دو طرفه پردازش می‌کند و هم زمینه‌های گذشته و هم آینده را به طور همزمان در نظر می‌گیرد. برای افزایش بیشتر عملکرد مدل، ما از یک لایه توجه چند سر استفاده می‌کنیم. این مکانیزم مدل را قادر می‌سازد تا بر جنبه‌های خاصی از داده‌ها تمرکز کند و مرتبطترین اطلاعات را برای پیش‌بینی نرخ دقیق اولویت‌بندی کند. با ترکیب نقاط قوت این اجزای شبکه عصبی، این رویکرد ترکیبی، پیش‌بینی بار خالص روز آینده را بهینه می‌کند و راه‌حلی قوی برای ثبت الگوهای پیچیده و وابستگی‌های ذاتی داده‌های بار خالص ارائه می‌کند.


۳- شبیه‌سازی و بحث در مورد نتایج

در این مطالعه، ما از داده‌های پایگاه داده اتریشی که سال‌های ۲۰۱۵ تا ۲۰۱۸ را پوشش می‌دهد برای مطالعات استفاده می‌کنیم. برای

اکتبر	جولای	آوریل	ژانویه	شاخص پیش بینی	روش پیش بینی
9/2512	10/8057	8/0368	6/5926	MAPE (%)	VMD-MIIG-CNN-GRU-Bilstm
681/7032	812/5992	647/8234	521/9182	RMSE (MW)	
555/4398	655/0985	516/2172	411/2747	MAE (MW)	



شکل ۲: خطای پیش بینی بار خالص



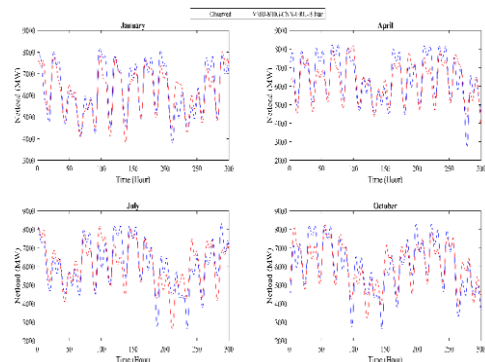
شکل ۳: میانگین مقدار خطای پیش‌بینی برای سال ۲۰۱۸

۴- نتیجه‌گیری

با افزایش روزافزون استفاده از منابع انرژی تجدیدپذیر در بخش مسکونی، اپراتورهای سیستم قدرت ممکن است با هزینه‌های بالاتری ناشی از تغییرپذیری و عدم قطعیت مرتبط با نوسانات کوتاه‌مدت در تولید انرژی‌های تجدیدپذیر مواجه شوند. می‌توان از استراتژی‌های مختلفی برای کاهش این چالش‌ها استفاده کرد. رویکرد ما برای دستیابی به این هدف شامل استفاده از الگوریتم‌های VMD-MIIG-CNN-GRU-BiLSTM برای پیش‌بینی بار خالص روز پیش رو بود. میانگین خطای درصد مطلق (MAPE) برای پیش‌بینی بار خالص و

شکل ۱ نتایج پیش‌بینی بار خالص را برای روزهای خاص در سال ۲۰۱۸ نشان می‌دهد. با توجه به ماهیت فرار و غیرقابل پیش‌بینی تولید برق بادی، مدل پیشنهادی VMD-MIIG-CNN-GRU-BiLSTM دقت بالایی را در پیش‌بینی بار خالص نشان می‌دهد. خطاهای پیش‌بینی در محدوده قابل قبول قرار می‌گیرند. این مدل به طور موثر روندها و نوسانات داده‌های بار خالص در دنیای واقعی را ضبط می‌کند.

برای ارزیابی اثربخشی روش‌های پیش‌بینی پیشنهادی، شکل ۲ مقادیر خطا را برای پیش‌بینی‌های بار خالص نشان می‌دهد. این خطاها با مقایسه مقادیر پیش‌بینی شده با مقادیر واقعی محاسبه شدند. مدل پیشنهادی در به حداقل رساندن خطاها و حفظ سطوح قابل قبول در بیشتر ساعات روز، به طور مداوم مناسب عمل می‌کنند. با ترکیب نقاط قوت اجزای جداگانه، این مدل‌ها یک رویکرد پیش‌بینی قوی، به ویژه برای مدیریت الگوهای پیچیده و پویا مناسب است.



شکل ۱: بار خالص پیش‌بینی شده واقعی برای سال ۲۰۱۸

میانگین خطاهای پیش‌بینی برای بار خالص در سال ۲۰۱۸، همانطور که توسط سه شاخص مشخص شده اندازه‌گیری شده است، در شکل ۳ نشان داده شده است. مدل‌های پیشنهادی به طور موثر عدم قطعیت‌های مرتبط با بار خالص را برطرف می‌کنند و در نتیجه دقت مدل‌سازی ریزشک و برنامه‌ریزی انرژی را افزایش می‌دهند.

- [14] Ahmadi, M., & Khashei, M. (2022). A fuzzy series-parallel preprocessing (FSPP) based hybrid model for wind forecasting. *IET Generation, Transmission & Distribution*, 16(3), 430-452.
<https://doi.org/10.1049/gtd2.12291>.
- [15] Wang, F., Xuan, Z., Zhen, Z., Li, K., Wang, T., & Shi, M. (2020). A day-ahead PV power forecasting method based on LSTM-RNN model and time correlation modification under partial daily pattern prediction framework. *Energy Conversion and Management*, 212, 112766.
<https://doi.org/10.1016/j.enconman.2020.112766>.
- [16] Ahmed, R., Sreeram, V., Togneri, R., Datta, A., & Arif, M. D. (2022). Computationally expedient Photovoltaic power Forecasting: A LSTM ensemble method augmented with adaptive weighting and data segmentation technique. *Energy and Management*, 258, 115563.
<https://doi.org/10.1016/j.enconman.2022.115563>.
- [17] Wang, R., Li, C., Fu, W., & Tang, G. (2019). Deep learning method based on gated recurrent unit and variational mode decomposition for short-term wind power interval prediction. *IEEE transactions on neural networks and learning systems*, 31(10), 3814-3827.
<https://doi.org/10.1109/TNNLS.2019.2946414>.
- [18] Keddouda, A., Ihaddadene, R., Boukhari, A., Atia, A., Arıcı, M., Lebbihiat, N., & Ihaddadene, N. (2023). Solar photovoltaic power prediction using artificial neural network and multiple regression considering ambient and operating conditions. *Energy Conversion and Management*, 288, 117186.
<https://doi.org/10.1016/j.enconman.2023.117186>.
- [19] Mellit, A., Pavan, A. M., & Lughi, V. (2021). Deep learning neural networks for short-term photovoltaic power forecasting. *Renewable Energy*, 172, 276-288.
<https://doi.org/10.1016/j.renene.2021.02.166>.
- [20] Sun, Y., Venugopal, V., & Brandt, A. R. (2019). Short-term solar power forecast with deep learning: Exploring optimal input and output configuration. *Solar Energy*, 188, 730-741.
<https://doi.org/10.1016/j.solener.2019.06.041>.
- [21] Ramsami, P., & Oree, V. (2015). A hybrid method for forecasting the energy output of photovoltaic systems. *Energy Conversion and Management*, 95, 406-413.
<https://doi.org/10.1016/j.enconman.2015.02.052>.
- [22] Prasad, R., Ali, M., Kwan, P., & Khan, H. (2019). Designing a multi-stage multivariate empirical mode decomposition coupled with ant colony optimization and random forest model to forecast monthly solar radiation. *Applied energy*, 236, 778-792.
<https://doi.org/10.1016/j.apenergy.2018.12.034>.
- [23] Li, Q., Zhang, X., Ma, T., Jiao, C., Wang, H., & Hu, W. (2021). A multi-step ahead photovoltaic power prediction model based on similar day, enhanced colliding bodies optimization, variational mode decomposition, and deep extreme learning machine. *Energy*, 224, 120094.
<https://doi.org/10.1016/j.energy.2021.120094>.
- [24] Chen, B., Lin, P., Lai, Y., Cheng, S., Chen, Z., & Wu, L. (2020). Very-short-term power prediction for PV power plants using a simple and effective RCC-LSTM model based on short term multivariate historical datasets. *Electronics*, 9(2), 289.
<https://doi.org/10.3390/electronics9020289>.
- [25] Lin, W., Zhang, B., Li, H., & Lu, R. (2022). Multi-step prediction of photovoltaic power based on two-stage decomposition and BiLSTM. *Neurocomputing*, 504, 56-67.
<https://doi.org/10.1016/j.neucom.2022.06.117>.
- [26] Limouni, T., Yaagoubi, R., Bouziane, K., Guissi, K., & Baali, E. H. (2023). Accurate one step and multistep forecasting of very short-term PV power using LSTM-TCN model. *Renewable Energy*, 2051010-1024.
<https://doi.org/10.1016/j.renene.2023.01.118>.
- قیمت برق به ترتیب تقریباً ۸٪ است. این ارقام نشان‌دهنده نرخ خطای نسبتاً پایین برای پیش‌بینی‌های روز آینده این پارامترها است.
- ## مراجع
- [1] Ogliari, E., Dolara, A., Manzolini, G., & Leva, S. (2017). Physical and hybrid methods comparison for the day ahead PV output power forecast. *Renewable energy*, 113, 11-21.
<https://doi.org/10.1016/j.renene.2017.05.063>.
- [2] De Giorgi, M. G., Ficarella, A., & Tarantino, M. (2011). Error analysis of short term wind power prediction models. *Applied Energy*, 88(4), 1298-1311.
<https://doi.org/10.1016/j.apenergy.2010.10.035>.
- [3] yJung, J., Han, S., & Kim, B. (2019). Digital numerical map-oriented estimation of solar energy potential for site selection of photovoltaic solar panels on national highway slopes. *Applied Energy*, 242, 57-68.
<https://doi.org/10.1016/j.apenergy.2019.03.101>.
- [4] Maatallah, O. A., Achuthan, A., Janoyan, K., & Marzocca, P. (2015). Recursive wind speed forecasting based on Hammerstein Auto-Regressive model. *Applied energy*, 145, 191197.
<http://dx.doi.org/10.1016/j.apenergy.2015.02.032>.
- [5] Gandoman, F. H., Aleem, S. H. A., Omar, N., Ahmadi, A., & Alenezi, F. Q. (2018). Short-term solar power forecasting considering cloud coverage and ambient temperature variation and ambient temperature variation effects. *Renewable Energy*, 123, 793-805.
<https://doi.org/10.1016/j.renene.2018.02.102>.
- [6] Yousuf, M. U., Al-Bahadly, I., & Avci, E. (2022). Statistical wind speed forecasting models for small sample datasets: Problems, Improvements, and prospects. *Energy Conversion and Management*, 261, 115658.
<https://doi.org/10.1016/j.enconman.2022.115658>.
- [7] Besharat, F., Dehghan, A. A., & Faghieh, A. R. (2013). Empirical models for estimating global solar radiation: A review and case study. *Renewable and sustainable energy reviews*, 21, 798-821.
<https://doi.org/10.1016/j.rser.2012.12.043>.
- [8] Wang, J., Du, P., Niu, T., & Yang, W. (2017). A novel hybrid system based on a new proposed algorithm—Multi-Objective Whale Optimization Algorithm for wind speed forecasting. *Applied energy*, 208, 344-360.
<http://dx.doi.org/10.1016/j.apenergy.2017.10.031>.
- [9] Netsanet, S., Zheng, D., Zhang, W., & Teshager, G. (2022). Short-term PV power forecasting using variational mode decomposition integrated with Ant colony optimization and neural network. *Energy Reports*, 8.
<https://doi.org/10.1016/j.egy.2022.01.120>.
- [10] Wang, H., Liu, Y., Zhou, B., Li, C., Cao, G., Voropai, N., & Barakhtenko, E. (2020). Taxonomy research of artificial intelligence for deterministic solar power forecasting. *Energy Conversion and Management*, 214, 112909.
<https://doi.org/10.1016/j.enconman.2020.112909>.
- [11] Yu, Y., Niu, T., Wang, J., & Jiang, H. (2023). Intermittent solar power hybrid forecasting system based on pattern recognition and feature extraction. *Energy Conversion and Management*, 277, 116579.
<https://doi.org/10.1016/j.enconman.2022.116579>.
- [12] Yadav, A. K., & Chandel, S. S. (2014). Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and sustainable energy reviews*, 33, 772-781.
<https://doi.org/10.1016/j.rser.2013.08.055>.
- [13] Santamaria-Bonfil, G., Reyes-Ballesteros, A., & Gershenson, C. J. R. E. (2016). Wind speed forecasting for wind farms: A method based on support vector regression. *Renewable Energy*, 85, 790-809.
<http://dx.doi.org/10.1016/j.renene.2015.07.004>.