

Short-Term Prediction of Wind Speed Using Machine-Learning Algorithms

Hamid Reza Safa^{1,2}, *Masters Student*, Ali Asghar Ghadimi^{1,2}, *Associate Professor*

¹ Department of Electrical Engineering, Faculty of Engineering, Arak University, Arak, Iran

² Research Institute of Renewable Energy, Arak University, Arak, Iran

Abstract:

The demand for electrical energy has sharply increased with the development of industry. However, supplying this demand through fossil fuels leads to problems such as global warming and environmental pollution. Considering the limitations and depletion of fossil fuel resources, finding sustainable alternatives has become essential. Among these alternatives, wind energy stands out as a viable renewable source for electricity generation due to its low cost and lack of pollution. However, to achieve stable power generation from wind farms, accurate information about future wind speed is essential. Predicting wind speed is highly challenging due to its random and intermittent nature. In this paper, a hybrid model combining a Temporal Convolutional Network and Bidirectional Long Short-Term Memory (TCN-BiLSTM) is employed to address this challenge and achieve accurate predictions. First, the hyperparameters of the Variational Mode Decomposition (VMD) algorithm were optimized using the powerful Optuna method. Next, the original wind speed data were normalized to enhance the performance of the hybrid model (TCN-BiLSTM) and then fed into the VMD algorithm to be decomposed into Intrinsic Mode Functions (IMFs). Each IMF is then individually fed into the hybrid model for prediction. Finally, the outputs are denormalized and combined to obtain the final result. Based on the evaluation of the hybrid model using statistical metrics, the results indicate that the proposed model achieves high accuracy. In this evaluation, the coefficient of determination (R^2), mean absolute error (MAE), and root mean square error (RMSE) were found to be 99.1%, 0.36, and 0.48, respectively.

Keywords: Wind speed prediction, Variational mode decomposition, Artificial neural networks

Received: 22 June 2024

Revised: 25 July 2024

Accepted: 10 August 2024

Corresponding Author: Dr. Ali Asghar Ghadimi, a-ghadimi@araku.ac.ir

DOI: <http://dx.doi.org/10.30486/TEEGES.2025.1129333>



فناوری‌های نوین مهندسی برق در سیستم انرژی سبز

پیش بینی کوتاه مدت سرعت باد با استفاده از الگوریتم های یادگیری ماشین

حمیدرضا صفا^۱، دانشجوی کارشناسی ارشد، علی اصغر قدیمی^۲، دانشیار

۱- گروه مهندسی برق، دانشکده مهندسی، دانشگاه اراک، اراک، ایران

۲- پژوهشکده انرژی‌های تجدید پذیر، دانشگاه اراک، اراک، ایران

چکیده: تقاضای انرژی الکتریکی با توسعه صنعت به شدت افزایش یافته است، اما تأمین آن از سوخت‌های فسیلی مشکلاتی مانند گرمایش زمین و آلودگی محیط زیست را به دنبال دارد. با توجه به محدودیت و کاهش منابع فسیلی، یافتن جایگزین‌های پایدار ضروری است. در این میان، انرژی باد به دلیل هزینه کم و عدم تولید آلودگی، به عنوان یک منبع تجدیدپذیر مناسب برای تأمین انرژی الکتریکی مطرح می‌شود. با این حال، برای دستیابی به توان پایدار از نیروگاه‌های بادی، لازم است اطلاعات دقیقی از سرعت باد در آینده در دسترس باشد. پیش‌بینی سرعت باد به دلیل ماهیت تصادفی و متناوب آن بسیار دشوار است، در این مقاله، برای مقابله با این چالش و دستیابی به پیش‌بینی دقیق، از مدل ترکیبی شامل شبکه عصبی کانولوشنال موقتی و بازگشتی دوطرفه (TCN-BiLSTM) استفاده شده است. ابتدا، هاپرپارامترهای الگوریتم تجزیه حالت متغیر، با استفاده از روش قدرتمند Optuna بهینه‌سازی شده‌اند. در مرحله بعد، داده‌های اصلی سرعت باد برای بهبود عملکرد مدل ترکیبی (TCN_BiLSTM) نرمالیزه شده و به الگوریتم تجزیه حالت متغیر داده شده‌اند تا به توابع مد ذاتی (IMF) تجزیه شوند. سپس هر IMF به صورت جداگانه به مدل ترکیبی برای پیش‌بینی داده می‌شود. در آخر در نهایت، خروجی‌ها از حالت نرمال‌سازی خارج و ترکیب شده‌اند تا نتیجه نهایی به دست آید. با توجه به ارزیابی مدل ترکیبی با معیارهای آماری، نتایج نشان می‌دهد که مدل پیشنهادی دقت بالایی دارد. در این ارزیابی، ضریب تعیین برابر با ۹۹.۱٪، میانگین خطای مطلق برابر با ۰.۳۶ و ریشه میانگین مربعات خطا برابر با ۰.۴۸ به دست آمده است.

واژه های کلیدی: پیش‌بینی سرعت باد، تجزیه حالت متغیر، شبکه های عصبی مصنوعی

تاریخ ارسال مقاله: ۱۴۰۳/۰۴/۲

تاریخ بازنگری مقاله: ۱۴۰۳/۰۵/۴

تاریخ پذیرش مقاله: ۱۴۰۳/۰۵/۲۰

نویسنده‌ی مسئول: دکتر علی اصغر قدیمی، a-ghadimi@araku.ac.ir

DOI: <http://dx.doi.org/10.30486/TEEGES.2025.1129333>





۱ - مقدمه

با توجه به رو به اتمام بودن سوخت‌های فسیلی و در مقابل آن تقاضای گسترده جهانی برای انرژی، بهره‌برداری و استفاده از انرژی‌های تجدیدپذیر روز به روز در تامین انرژی با توجه مزایای آنها از جمله هزینه بسیار کم و آلودگی صفر، اهمیت بسیاری پیدا کرده اند، که انرژی باد به عنوان یکی از انرژی‌های تجدید پذیر، جایگزین مناسبی برای مقابله با مشکلات زیست محیطی و تامین انرژی الکتریکی در نظر گرفته می شود [۱، ۲]. با این حال، ماهیت متناوب و تصادفی سرعت باد منجر به مشکلات شدید در تولید انرژی پایدار در نیروگاه بادی و همچنین مدیریت انرژی الکتریکی شده است [۳]. می توان گفت که یکی از کارهای مهم برای غلبه بر این چالش ها، بدست آوردن اطلاعات دقیق از سرعت باد برای آینده است، اما این کار نیاز به یک مدل دقیق برای پیش بینی سرعت باد دارد [۴]. مدل های پیش بینی سرعت باد به طور کلی به چهار دسته تقسیم می شوند، که شامل مدل فیزیکی، مدل آماری، روش های یادگیری ماشین و مدل ترکیبی.

مدل های فیزیکی، قادرند سرعت باد را برای چند روز آینده بر اساس متغیرهای مختلف جوی مانند دما، رطوبت، جهت باد و فشار هوا پیش بینی کنند با این وجود، به دلیل پیچیدگی زیاد داده‌ها و محاسبات، استفاده از این مدل ها محدود شده است [۵]. از جمله این مدل ها می توان به پیش بینی عددی آب و هوا [۶]، رگرسیون فرآیند گاوسی [۷] اشاره کرد.

با توجه به گسترش علم داده، مدل های آماری نیز مورد توجه قرار گرفته اند. از جمله مدل های آماری شامل اتورگرسیون [۸]، میانگین متحرک یکپارچه اتورگرسیون [۹]، زنجیره مارکوف [۱۰] است. به عنوان نمونه، مرجع [۱۱] به بررسی پیش بینی سرعت باد در مناطق کوهستانی با استفاده از مدل بهبود یافته ARIMA می پردازد. و [۱۲] هم برای پیش بینی سرعت باد، از مدل آماری ARMA استفاده می کند. در این روش، سرعت باد به دو مؤلفه جانبی و طولی تقسیم می شود و هر یک از این مؤلفه‌ها با استفاده از یک مدل ARMA مجزا مدل سازی شده است، سپس نتایج این مدل ها ترکیب می شوند تا پیش بینی نهایی سرعت باد به دست آید. این رویکرد به تحلیل دقیق تر و بهبود دقت پیش بینی ها کمک می کند. اما این مدل ها قادر به پیش بینی داده های خطی هستند با این حال، هنگام برخورد با داده های سری زمانی غیرخطی، عملکرد آنها ضعیف است.

در این راستا، مدل های یادگیری ماشین در مقایسه با مدل های آماری قابلیت های پردازش داده های سری زمانی غیرخطی را دارند. از جمله این روش ها می توان به رگرسیون ماشین بردار پشتیبان [۱۳]، مدل های شبکه عصبی مصنوعی [۱۴] اشاره کرد.

که دقت پیش بینی قابل قبولی دارند، اما این نیز ناکافی می باشد. در این راستا برای حل این مشکل مدل های ترکیبی عملکرد خوبی نشان داده اند، که در [۱۵] برای پیش بینی کوتاه مدت سرعت باد از ترکیب چندین پیش بینی کننده پایه با LSTM RNN و یادگیری جمعی متا با شبکه عصبی BP چند ورودی استفاده شده است. این مدل ترکیبی برای بهبود دقت، پایداری و تعمیم پیش بینی های سرعت باد طراحی شده است. همچنین برای بهبود عملکرد بهتر مدل های پیش بینی، روش های پردازش تجزیه داده ها وجود دارد. در این راستا، در [۱۶] برای افزایش دقت پیش بینی سرعت باد از یک مدل ترکیبی (EMD_LSTM) استفاده شده است، به این صورت که ابتدا داده ها توسط روش EMD^۱ برای پردازش بهتر داده ها توسط شبکه عصبی، تجزیه شده اند و سپس برای پیش بینی به شبکه عصبی بازگشتی با حافظه طولانی کوتاه مدت داده شده اند، که این کار باعث عملکرد خوب در پیش بینی شده است. همچنین در مرجع [۱۷] روشی برای پیش بینی کوتاه مدت توان بادی ارائه شده است، که با تجزیه سری زمانی به مؤلفه های فرکانس بالا و پایین توسط EMD، و استفاده از مدل های EncoderForest و TCN، الگوهای پیچیده و روندهای داده را استخراج می کند و با ترکیب این نتایج به کمک شبکه های عصبی، دقت پیش بینی را بهبود می بخشد. روش EMD در مقایسه با تبدیل موجک و فیلتر فوریه دارای مزیت بیشتری است، زیرا نیازی به انتخاب تابع پایه ندارد و فرآیند تجزیه در این روش براساس توزیع نقاط حداکثری و حداقلی سیگنال خود انجام می شود [۱۸].

با وجود عملکرد خوب، روش EMD با مشکل تداخل سیگنال ها مواجه است که به دلیل تداخل و همپوشانی فرکانس ها در سیگنال های متناوب رخ می دهد. این مسئله می تواند باعث کاهش دقت و صحت تجزیه و تحلیل سیگنال ها شود. برای غلبه بر مشکل EMD در مورد تداخل سیگنال ها، الگوریتم EEMD^۲ توسط وو و هوانگ در سال ۲۰۰۹ پیشنهاد شده است، در این روش، نویز اضافی برای رفع مشکل اختلاط مدها اضافه می شود [۱۹، ۲۰]. مرجع [۲۱] یک مدل ترکیبی برای پیش بینی دقیق سرعت باد ارائه می دهد که از EEMD و شبکه های حافظه بلند مدت کوتاه مدت دوطرفه (BiLSTM) استفاده می کند. EEMD داده های سرعت باد را به سیگنال های فرکانس بالا و پایین تجزیه می کند و BiLSTM این زیرسری ها را به طور جداگانه پیش بینی می کند و برای دستیابی به نتایج نهایی ترکیب



می‌شوند. همچنین [۲۲] یک مدل ترکیبی EEMD-ARIMA را برای پیش‌بینی سرعت باد در بازه‌های زمانی بسیار کوتاه معرفی می‌کند. این مدل با تجزیه سری‌های زمانی باد به کمک EEMD و پیش‌بینی مؤلفه‌ها با استفاده از ARIMA، باعث افزایش دقت پیش‌بینی سرعت باد شده است. در روش EEMD، اضافه کردن نویز تصادفی به سیگنال برای حل مشکل تداخل مدها به کار می‌رود. این نویز باعث افزایش خطای بازسازی و کاهش دقت پیش‌بینی شود. اما الگوریتم VMD، روش دیگری برای تجزیه داده‌ها می‌باشد که دارای پایه ریاضی قوی می‌باشد، در [۲۳] پیشنهاد شده است. در این راستا، در [۲۴] ویژگی‌های سرعت باد، از الگوریتم VMD برای تجزیه سرعت باد به بخش‌های غیرخطی، خطی و نویز استفاده می‌شود. بخش غیرخطی با مدل PCA-RBF^۱ و بخش خطی با مدل ARMA پیش‌بینی می‌شود. بخش نویز با توزیع نرمال برازش می‌شود. در نهایت، این سه بخش برای تشکیل مدل VMD-PRBF-ARMA-E بازسازی می‌شوند. با این حال، هرچقدر دقت پیش‌بینی بیشتر باشد، مدیریت انرژی و پایداری توان در نیروگاه‌های بادی بهبود می‌یابد. در این راستا، انتخاب شبکه‌های مناسب در مدل‌های ترکیبی و همچنین روش‌های تجزیه داده از اهمیت زیادی برخوردار است تا پیش‌بینی دقیق‌تری از سرعت باد داشته باشیم. در این مقاله از مدل ترکیبی TCN-BiLSTM استفاده شده است که می‌تواند وابستگی‌های طولانی‌مدت و غیرخطی در داده‌ها را مدل‌سازی کند. در مقایسه با مدل‌های سنتی مانند RBF و ARIMA که معمولاً برای روابط خطی یا غیرخطی ساده‌تر مناسب‌ترند، قابلیت بیشتری در این زمینه دارند. TCN به خوبی ویژگی‌های محلی را استخراج می‌کند، در حالی که BiLSTM اطلاعات گذشته و آینده را به‌طور همزمان پردازش می‌کند. ترکیب این دو مدل برای پیش‌بینی‌های دقیق‌تر در سرعت باد بسیار مؤثر است. همچنین استفاده از الگوریتم VMD نیاز به تنظیم دقیق این الگوریتم دارد که به صورت دستی بسیار زمان‌بر و چالش‌برانگیز است. در این مقاله برای حل این چالش در ابتدا مهم‌ترین هابیر پارامترهای الگوریتم VMD که شامل K و α توسط روش قدرتمند Optuna بهینه‌سازی شده است و در مرحله بعد، داده‌های سرعت باد با استفاده از الگوریتم VMD به توابع مد ذاتی (IMF) تجزیه شده‌اند، که هر کدام از IMFها نمایانگر ویژگی‌های مختلف سیگنال اصلی با فرکانس‌های متفاوت هستند. این IMFها به مدل کمک می‌کنند تا ویژگی‌های مختلف و الگوهای پیچیده را به‌طور جدا تحلیل کند، مدل ترکیبی با تمرکز بر روی هر IMF به‌صورت جداگانه، قادر است به‌طور مؤثرتری نوسانات و الگوهای اصلی را شناسایی کند. لذا هر IMF، به‌صورت جداگانه برای پیش‌بینی به مدل ترکیبی داده شده است. در نهایت، خروجی‌های پیش‌بینی با هم ترکیب شده و نتیجه نهایی با ضریب تعیین برابر با ۹۹.۱٪، میانگین خطای مطلق برابر با ۰.۳۶ و ریشه میانگین مربعات خطا برابر با ۰.۴۸ به‌دست آمده است که نشان‌دهنده دقت بسیار بالای مدل می‌باشد. نوآوری‌های این مقاله به شرح ذیل است:

- ارائه یک مدل ترکیبی TCN_BiLSTM با الگوریتم تجزیه حالت متغیر بهینه شده (Optuna_VMD)

این مقاله به این گونه سازمان‌دهی شده است که در بخش دوم روش پیشنهادی حل مسئله که عملکرد مدل ترکیبی و فرمولاسیون اجزای آن به‌طور کامل تشریح شده است. سپس در بخش سوم نتایج تست و ارزیابی مدل استخراج شده برای سناریوهای مختلف انجام شده است و در بخش چهارم، نتیجه‌گیری این مسئله پژوهشی آورده شده است. در نهایت در بخش پایانی این مقاله یک پیوست، که قسمتی از مقادیر پیش‌بینی شده با مقادیر تست است، در جدول (الف) آورده شده است.

۲- روش پیشنهادی حل مسئله

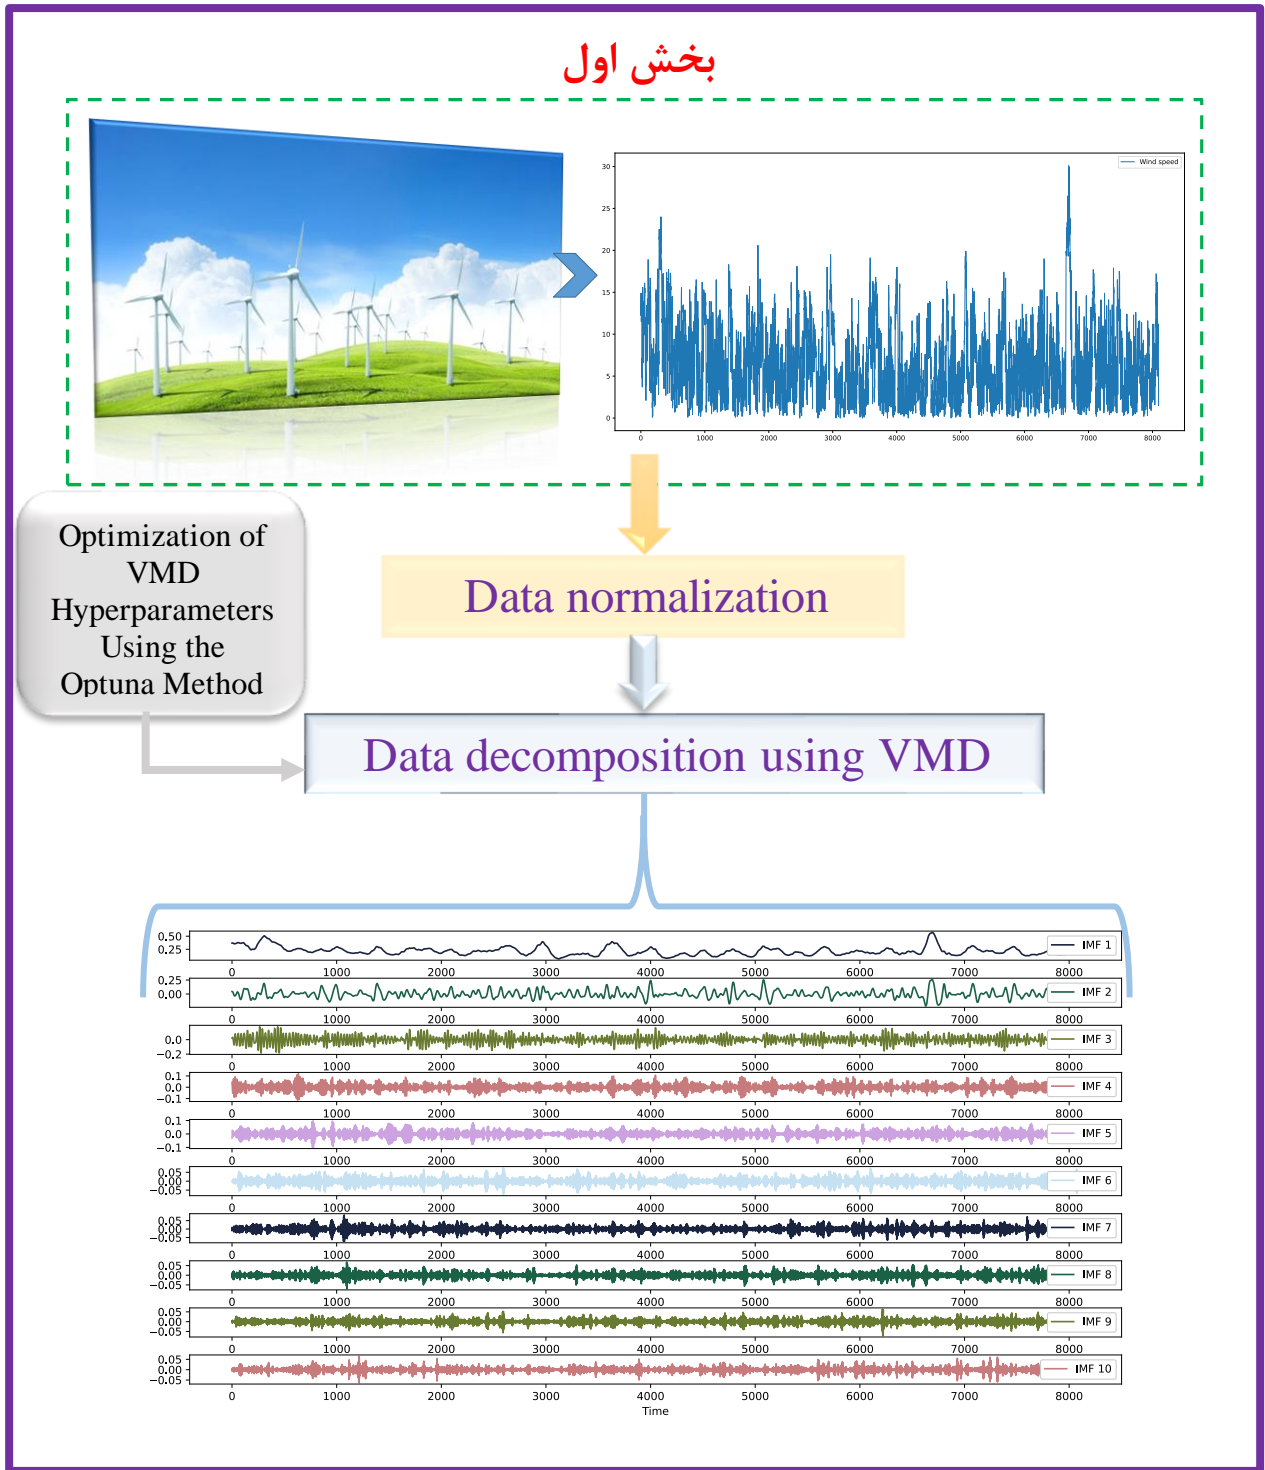
در این قسمت از مقاله، به بررسی اجزای مختلف مدل ترکیبی از نظر فرمولاسیون و عملکرد آن برای پیش‌بینی دقیق سرعت باد در کوتاه مدت برای نیروگاه بادی پرداخته شده است.

۲-۱- مدل پیشنهادی (TCN_BiLSTM)

در بخش اول، با توجه شکل (۱) داده‌های اصلی باد ابتدا نرمالیزه شده و سپس جهت تجزیه به توابع مد ذاتی، به الگوریتم VMD داده می‌شوند و برای افزایش دقت عملکرد این الگوریتم، هابیر پارامترهای این الگوریتم توسط Optuna بهینه شده‌اند. در شکل (۲)، IMFهای تجزیه شده ابتدا به ۸۰ درصد برای آموزش و ۲۰ درصد تست تقسیم شده و بعد IMFهای مربوط به آموزش شبکه، به صورت جداگانه



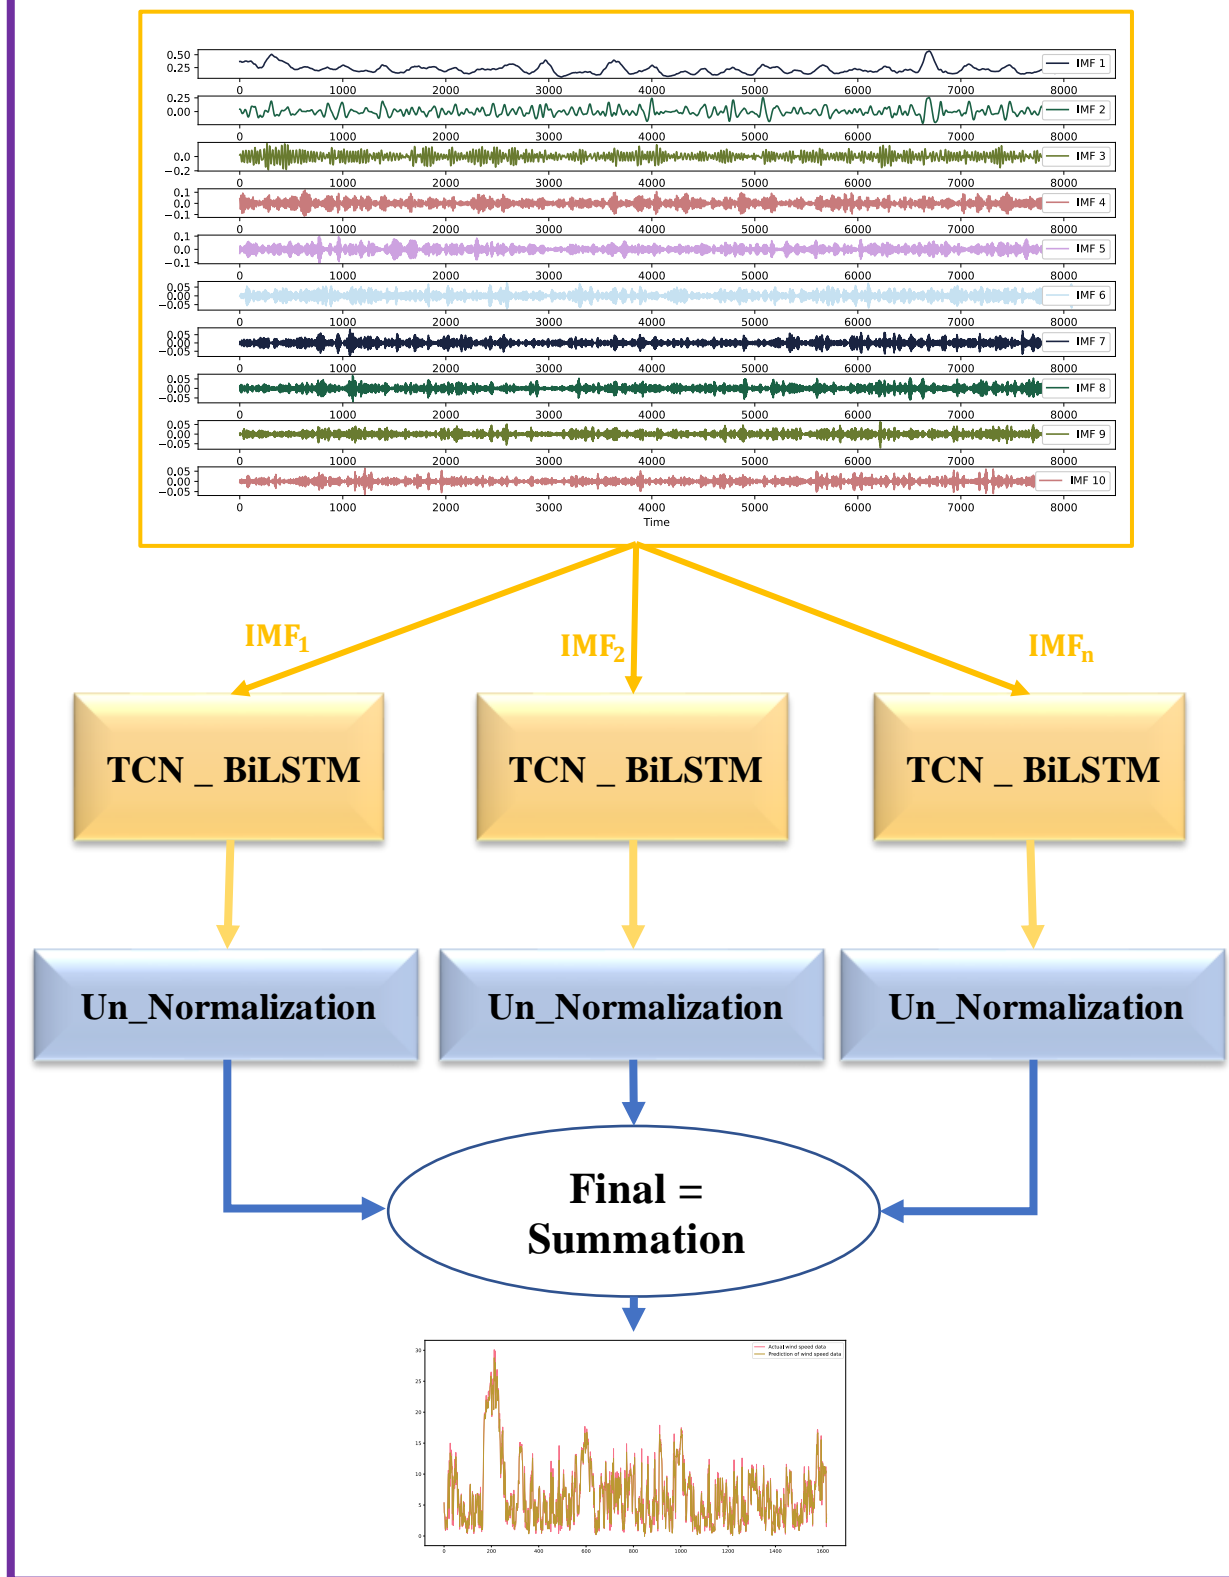
به مدل پیشنهادی برای پیش بینی فرستاده می شوند. عملکرد مدل پیشنهادی به این صورت است که به چند گام زمانی قبلی نگاه می کند تا بتواند مقدار بعدی را پیش بینی کند، در اینجا، مدل از ۳ مقدار قبلی سری زمانی به عنوان ورودی استفاده می کند. (داده های سری زمانی در این مقاله $[x_{t-1}, x_{t-2}, x_{t-3}]$ می باشد و مدل پیشنهادی از این داده ها برای پیش بینی مقدار x_t استفاده می کند) و در آخر داده ها از حالت نرمالیز شده و خروجی ها با هم ترکیب، و خروجی نهایی بدست میاید.



شکل (۱): فلوچارت مدل پیشنهادی



بخش دوم



شکل (۲): فلوچارت مدل پیشنهادی



۲-۲- الگوریتم تجزیه حالت متغیر (VMD)

الگوریتم VMD یک روش قدرتمند و تطبیقی در پردازش سیگنال است که برای تجزیه سیگنالهای پیچیده به اجزای ساده‌تر و معنادارتر استفاده می‌شود. این الگوریتم سیگنال ورودی را به K IMF با پهنای باند محدود تقسیم کرده، که در این مقاله داده‌های سرعت باد را به ده IMF تقسیم کرده است و فرکانس مرکزی هر IMF را استخراج می‌کند، به طوری که مد u_k در اطراف فرکانس مرکزی k نوسان می‌کند. VMD به دلیل توانایی بالا در استخراج ویژگی‌های دقیق از سیگنال‌ها، در زمینه‌های مختلفی مانند پردازش تصویر، استخراج روندها و تحلیل سری‌های زمانی کاربردهای گسترده‌ای دارد. که فرمولاسیون آن به صورت زیر تعریف شده است [۲۴، ۲۵]:

• تعیین هدف و محدودیت‌ها

$$\min_{\{u_k\}\{w_k\}} \left\{ \sum_{k=1}^k \left\| \left(\delta(t) + j \frac{1}{\pi t} \right) * [u_k(t) - e^{jw_k t}] \right\|_2^2 \right\} \quad (1)$$

با محدودیت:

$$f(t) = \sum_{k=1}^k u_k(t) \quad (2)$$

در این معادله u_k ، IMF $_k$ با پهنای باند محدود است، k فرکانس مرکزی مربوطه و سیگنال $f(t)$ ورودی است. برای تبدیل این مسئله به یک مسئله بهینه‌سازی نامحدود، لاگرانژ را با استفاده از ضریب لاگرانژ $\lambda(t)$ و فاکتور جریمه α تعریف می‌شود:

$$L(\{u_k\}, \{w_k\}, \lambda(t)) = \alpha \sum_{k=1}^k \left\| \left(\delta(t) + j \frac{1}{\pi t} \right) * [u_k(t) - e^{jw_k t}] \right\|_2^2 + \left\| f(t) - \sum_{k=1}^k u_k(t) \right\|_2^2 \quad (3)$$

• حل مسئله

برای حل مسئله، از روش ضرب متناوب استفاده می‌شود. این روش شامل به روز رسانی متناوب u_k ، w_k و λ است تا مینیمم تابع لاگرانژ بدست آید. معادلات به روز رسانی به شرح زیر است:

۱. به روز رسانی u_k :

$$u_k^{(n+1)}(t) = \frac{f(t) - \sum_{i \neq k} u_i^{(n)}(t) + \frac{\lambda^n(t)}{2}}{1 + 2\alpha(w_k^n)^2} \quad (4)$$

۲. به روز رسانی w_k :

$$w_k^{(n+1)}(t) = \frac{\int_0^\infty t \cdot |\hat{u}_k^{(n+1)}(t)|^2 dt}{\int_0^\infty |\hat{u}_k^{(n+1)}(t)|^2 dt} \quad (5)$$

۳. به روز رسانی λ :

$$\lambda^{(n+1)}(t) = \lambda^n(t) + \tau \left[f(t) - \sum_{k=1}^k u_k(t) \right] \quad (6)$$

در نهایت، این الگوریتم تا زمانی ادامه می‌یابد که همگرایی مدها و فرکانس‌های مرکزی به دست آید.



۱-۲-۲- روش بهینه سازی Optuna

Optuna یک روش بهینه‌سازی نسل جدید برای تنظیم خودکار ابرپارامترهای الگوریتم‌های یادگیری ماشین است [۲۶]. این روش برای بهینه‌سازی هایپرپارامترهای VMD از الگوریتم Tree-structured Parzen Estimator (TPE) استفاده می‌کند. این الگوریتم با مدل‌سازی توزیع احتمالاتی عملکرد مدل در مقایسه با مقادیر مختلف هایپرپارامترها، به‌طور هوشمندانه بهترین ترکیب‌ها را شناسایی می‌کند. TPE به جای جستجوی تصادفی یا شبکه‌ای، از یک فرآیند بهینه‌سازی توزیع احتمالاتی استفاده می‌کند که به آن امکان می‌دهد سریع‌تر به مقادیر بهینه برسد. در الگوریتم VMD، α ضریب جریمه‌ای است که پهنای باند IMFها را کنترل می‌کند، در حالی که K تعداد IMFها است که سیگنال به آن‌ها تجزیه می‌شود. با توجه به این که این دو پارامتر مستقیماً بر روی تعداد IMFها و پهنای باند آن‌ها تأثیر دارند، اگر K به درستی تنظیم نشود، ممکن است برخی از جزئیات سیگنال از دست برود یا نویز اضافی وارد شود. و همچنین پهنای باند α نیز تعیین می‌کند که هر IMF چقدر دقیق و متمرکز بر فرکانس‌های خاص باشد، لذا اگر α بیش از حد کوچک یا بزرگ باشد، این می‌تواند منجر به ترکیب نامناسب فرکانس‌ها یا تفکیک ضعیف اجزای سیگنال شود، که نهایتاً دقت الگوریتم را کاهش می‌دهد. به همین خاطر مقادیر این دو پارامتر باید درست انتخاب شود. در این راستا فرآیند بهینه‌سازی با استفاده از Optuna، این پارامترها را به‌گونه‌ای تنظیم می‌کند که خطای میانگین مربعات (MSE) بین سیگنال اصلی و نسخه بازسازی‌شده از مدهای تجزیه‌شده به حداقل برسد. Optuna با تست مقادیر مختلف برای α و K، بهترین پارامترها را که کمترین خطای بازسازی را به همراه دارند، شناسایی می‌کند و دقت بیشتری در تجزیه سیگنال فراهم می‌آورد. در این مقاله مقادیر بهینه برای $k=10$ و $\alpha=10.037713770895465$ بدست آمده است.

۳-۲- شبکه TCN

شبکه TCN در این مقاله با ۱۶ فیلتر و هسته به طول ۳ برای استخراج ویژگی‌های زمانی استفاده می‌شود. این شبکه با شناسایی الگوها و وابستگی‌های زمانی موجود در داده‌های ورودی، اطلاعات مهم را برای پردازش و تحلیل در لایه‌های بعدی BiLSTM آماده می‌سازد. این کار به پیش‌بینی دقیق‌تر کمک می‌کند، زیرا TCN به دلیل استفاده از کانولوشن با نرخ افزایشی (dilated convolution) قادر به درک روابط زمانی طولانی‌مدت است. نمونه‌ای از معماری این شبکه در شکل (۳) نمایش داده شده است. ورودی به لایه TCN به صورت $x = [x_1, x_2, \dots, x_T]$ باشد x_i نمایانگر مقدار سری زمانی در زمان i می‌باشد. یک فیلتر کانولوشن یک بعدی با وزن‌های $w = [w_1, w_2, \dots, w_k]$ و بایاس b داریم که با استفاده از آن، خروجی y_t به ازای زمان t محاسبه می‌شود، همچنین برای حفظ اندازه‌ی ورودی و خروجی، از causal padding استفاده می‌شود که مقادیر صفر به ابتدای ورودی اضافه می‌شود تا طول ورودی و خروجی یکسان باقی بماند. فرمولاسیون مدل به صورت زیر تعریف شده است [۲۷، ۱۷]:

$$y_t = \sum_{i=0}^{k-1} w_i \cdot x_{t-d.i} + b \quad (7)$$

K: اندازه‌ی فیلتر کانولوشن (تعداد پارامترهای وزن).

d: ضریب dilation است که باعث می‌شود فیلتر با فاصله‌های مشخصی از داده‌ها عمل کند و وابستگی‌های زمانی بلندمدت‌تر را مدل کند.

$x_{t-d.i}$: این مقدار به این معناست که داده‌ی ورودی با ضریب dilation به عقب منتقل شده است.

b: بایاس لایه کانولوشن است که به خروجی اضافه می‌شود.

پس از اعمال کانولوشن، تابع فعال‌سازی ReLU به خروجی اعمال می‌شود:

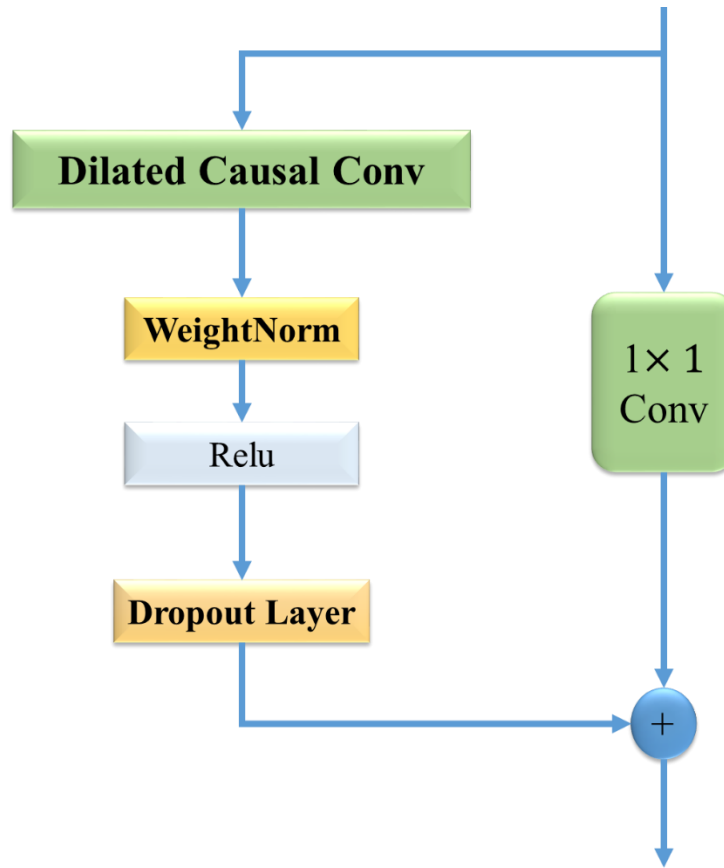
$$y_t^{activated} = Relu(y_t) = \max(0, y_t) \quad (8)$$

خروجی نهایی در زمان t به این صورت محاسبه می‌شود:



$$y_t = Relu\left(\sum_{i=0}^{k-1} w_i \cdot x_{t-d.i} + b\right)$$


(۹)



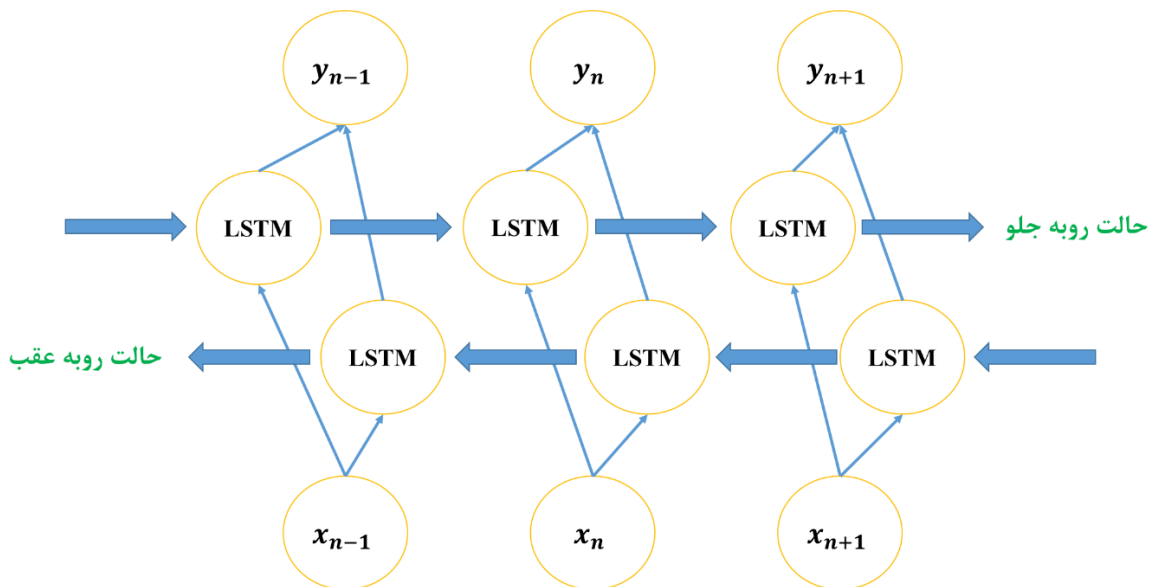
شکل (۳): معماری شبکه TCN

۲-۴- شبکه BiLSTM

لایه های LSTM دارای معماری قدرتمند برای پردازش داده های دنباله ای هستند. این معماری به ویژه برای پیش بینی و تحلیل سری های زمانی طراحی شده است. شبکه LSTM با استفاده از گیت های مختلف، اطلاعات را در طول زمان به خوبی مدیریت می کند و مشکلات وابستگی های طولانی مدت و ناپدید شدن گرادینان ها را که در شبکه های عصبی بازگشتی معمولی وجود دارد، برطرف می سازد [۲۹]. که ساختار LSTM برای درک بهتر در شکل (۴) نمایش داده شده است. در این مقاله، از مدل پیشرفته LSTM به نام LSTM دوطرفه (BiLSTM) استفاده شده است، که در مدل پیشنهادی از دو لایه BiLSTM استفاده شده است، خروجی لایه قبلی (TCN) به اولین لایه BiLSTM با ۶۰ واحد منتقل می شود. در این لایه، با استفاده از توالی برگشتی، تمام وضعیت های زمانی حفظ و به لایه بعدی ارسال می شود. سپس، خروجی اولین لایه BiLSTM از طریق لایه Dropout با نرخ ۰.۲ به ورودی دومین لایه BiLSTM با ۶۰ واحد منتقل می شود. لایه Dropout با غیرفعال کردن تصادفی برخی از نورون ها در طول آموزش، به جلوگیری از برازش بیش از حد کمک می کند. خروجی لایه دوم BiLSTM به لایه Dense منتقل می شود تا پیش بینی نهایی انجام شود. در کل، لایه BiLSTM شامل دو بلوک LSTM است (شکل (۵))، که به صورت موازی داده ها را در دو جهت مخالف پردازش می کنند، یکی از گذشته به آینده و دیگری از آینده به گذشته. خروجی نهایی از ترکیب این دو بلوک به دست می آید. این پردازش دوطرفه به BiLSTM امکان می دهد تا اطلاعات کامل تری از دنباله های زمانی استخراج کند و در نتیجه، به پیش بینی های دقیق تری دست یابد. و فرمولاسیون LSTM دو طرفه به صورت زیر می باشد [۲۱]، [۳۰]:



شکل (۴): معماری شبکه LSTM



شکل (۵): معماری شبکه BiLSTM

- گیت فراموشی در واحد LSTM وظیفه دارد تا مشخص کند کدام اطلاعات از حالت قبلی باید نگه داری و کدام باید حذف شود. این گیت با استفاده از تابع سیگموئید به حالت مخفی قبلی (h_{n-1}) و ورودی فعلی (x_n) نگاه می‌کند، خروجی گیت فراموشی یک بردار است که برای هر عدد در حالت سلول (c_{n-1}) یک مقدار بین ۰ و ۱ تولید می‌کند. این مقدار تعیین می‌کند که هر عدد مربوط به اطلاعات قبلی، که نزدیک به ۰ است باید حذف، و عدد نزدیک به ۱ باید نگه داری شود.

$$f_n = \delta(w_f [h_{n-1}, x_n] + b_f) \quad (10)$$



- گیت ورودی در LSTM مشخص می کند که چه مقدار از اطلاعات جدید باید به وضعیت سلول (c_n) اضافه شود. این گیت با استفاده از تابع سیگموئید i_n مشخص می کند که کدام مقادیر باید از فیلتر عبور کنند، و سپس تابع تانژانت هایپربولیک (\tanh) به این مقادیر بر اساس اهمیت شان وزنی بین -۱ تا ۱ اختصاص می دهد.

$$i_n = \delta(w_i \cdot [h_{n-1}, x_n] + b_i) \quad (11)$$

$$\tilde{c}_n = \tanh(w_c \cdot [h_{n-1}, x_n] + b_c) \quad (12)$$

- در این رابطه، c_{n-1} وضعیت قبلی است که با f_t ضرب نقطه ای شده و به آن مقدار ورودی جدید i_n اضافه می شود تا وضعیت جدید c_n به دست آید:

$$c_n = c_{n-1} f_t + i_n \quad (13)$$

- گیت خروجی با استفاده از ورودی و حافظه بلوک، خروجی نهایی را تعیین می کند. ابتدا تابع سیگموئید مشخص می کند که کدام مقادیر باید از فیلتر عبور کنند. سپس، تابع تانژانت هایپربولیک (\tanh) به این مقادیر وزنی بین -۱ تا ۱ اختصاص می دهد و این مقدار با خروجی تابع سیگموئید ترکیب می شود تا خروجی نهایی گیت مشخص شود.

$$o_n = \delta(w_o [h_{n-1}, x_n] + b_o) \quad (14)$$

$$h_n = o_n \tanh(c_n) \quad (15)$$

۳- نتایج تست و مقایسه

در این بخش به ترتیب به بررسی نرم افزار و سیستم مورد نیاز، اطلاعات داده های سرعت باد، VMD، TCN_BiLSTM پرداخته شده است.

۳-۱- نرم افزار و سیستم مورد نیاز

شبیه سازی ها به کمک نرم افزار پایتون در سیستم که مشخصات آن در جدول (۱) آمده، انجام شده است. نتایج شبیه سازی در ادامه آورده شده و سپس جهت ارزیابی عملکرد مدل پیشنهادی و همچنین مقایسه آن با دیگر مدل ها توسط شاخص های آماری مختلف مورد ارزیابی قرار گرفته است.


جدول (۱): مشخصات سیستمی که شبیه سازی ها با آن انجام شده.

مشخصات	قسمت
P553UJ	مدل سیستم
Intel(R) Core(TM) i5-6198DU CPU@ 2.30GHZ (4CPUS), ~2.4GHZ	پردازنده
819MB RAM	حافظه



۳-۲- اطلاعات داده های سرعت باد

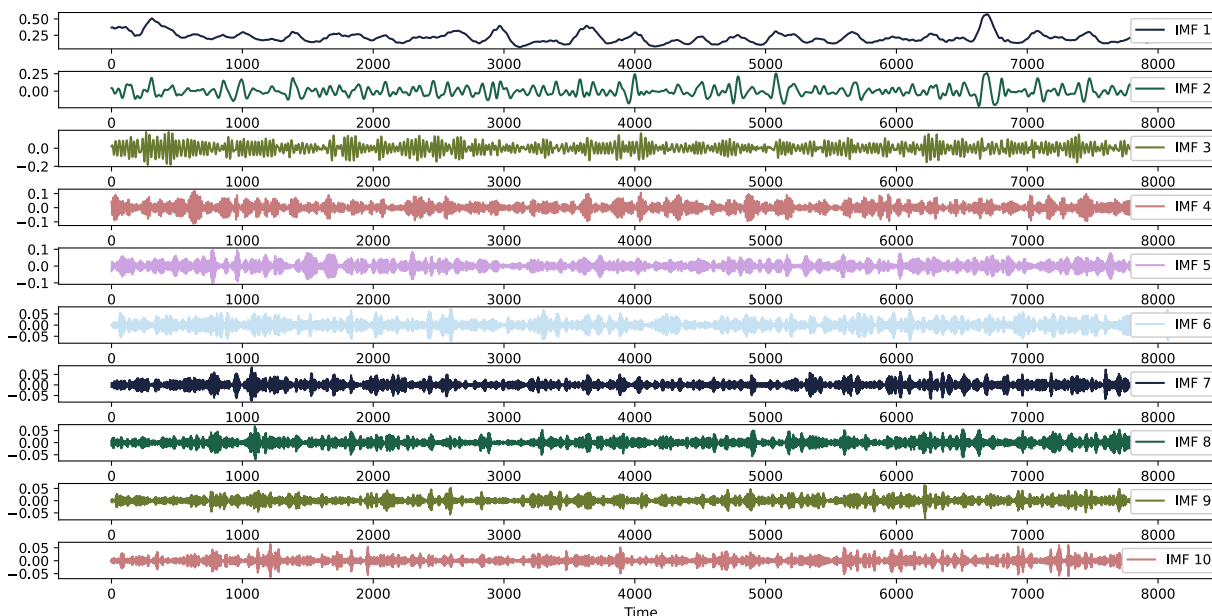
در این پژوهش، با توجه به شکل (۶) که داده های واقعی سرعت باد که با فاصله زمانی ۱ ساعت اندازه گیری شده را نشان می دهد، استفاده شده است.



شکل (۶): داده های سرعت باد با فاصله زمانی یک ساعت.

۳-۳- الگوریتم تجزیه حالت متغیر (VMD)

در این بخش برای افزایش عملکرد مدل پیشنهادی، داده اصلی سرعت باد توسط الگوریتم VMD، به IMF ها تجزیه می شود، که این کار در شکل (۷) نشان داده شده است.




شکل (۷): تجزیه داده های اصلی سرعت باد توسط الگوریتم VMD به IMF ها.



۳-۴- مدل پیشنهادی (TCN_BiLSTM)

ابتدا IMF ها به ۸۰ درصد برای آموزش و ۲۰ درصد برای تست تقسیم می شوند. سپس هر IMF به طور جداگانه به مدل پیشنهادی داده می شود تا پیش بینی انجام شود. در پایان، تمامی خروجی ها با یکدیگر ترکیب می شوند و خروجی نهایی تولید می شود. همانطور که در شکل (۸) نشان داده شده است مدل پیشنهادی دقت بسیار خوبی در پیش بینی داشته است.



شکل (۸): خروجی نهایی پیش بینی داده ها

در این مقاله جهت ارزیابی دقت و عملکرد مدل ترکیبی از مفاهیم آماری شناخته شده ای مانند R^2 ، RMSE، MAE استفاده شده است. این معیارهای ارزیابی ریاضیاتی می توانند به صورت زیر بیان شوند [۱]، [۱۶]:
 R^2 : نشان می دهد که مدل چه مقدار از واریانس در متغیرهای وابسته را توضیح می دهد. هرچه مقدار R^2 به عدد یک نزدیک تر باشد، مدل عملکرد بهتری دارد. در این راستا، مدلی که بالاترین مقدار R^2 را دارد، بهترین عملکرد را خواهد داشت.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (16)$$

y_i : مقدار نام از داده واقعی سرعت باد

\hat{y}_i : مقدار نام از داده پیش بینی شده

RMSE: این معیار میزان خطا یا انحراف مدل از واقعیت را نشان می دهد. RMSE کمتر به معنای دقت مدل بالاتر است. مدل با RMSE کمتر بهترین عملکرد را دارد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (17)$$

MAE: یکی از معیارهای ارزیابی عملکرد مدل های پیش بینی است که میانگین قدر مطلق خطاها را محاسبه می کند. MAE نشان می دهد که پیش بینی های مدل به طور متوسط چقدر از مقادیر واقعی فاصله دارند. هرچه مقدار MAE کمتر باشد، مدل دقیق تر است و پیش بینی های بهتری ارائه می دهد.



$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

در این مقاله، عملکرد مدل های مختلف پیش بینی مورد ارزیابی قرار گرفته است. داده های اصلی سرعت باد که با استفاده از روش Optuna_VMD تجزیه شده بودند، عملکرد مدل پیشنهادی TCN_BiLSTM را به طور قابل توجهی بهبود بخشیدند. همان طور که در جدول ۲ نشان داده شده است، مدل پیشنهادی با توجه به کمترین میزان میانگین خطای مطلق (۰.۳۶) و ریشه میانگین مربعات خطا (۰.۴۸) و بالاترین مقدار ضریب تعیین (۹۹) در پیش بینی بدست آورده است، در مقایسه با سایر مدل ها، بهترین نتایج را داشته است. این مدل به طور قابل ملاحظه ای دقت پیش بینی را نسبت به مدل های SVR، RBF، BiLSTM، Decision Tree Regressor، TCN_LSTM بهبود داده است.

جدول (۲): نتایج حاصل از تست و مقایسه مدل های پیشین و مدل پیشنهادی.

مدل های پیش بینی	R ² %	RMSE	MAE
SVR	۷۳.۵	۲.۶۵	۱.۹۱
RBF	۷۸.۳۵	۲.۳۹	۱.۷۵
Decision Tree Regressor	۶۳.۳	۳.۱۲	۲.۳۴
BiLSTM	۸۰.۷	۲.۲۶	۱.۶۵
TCN_BiLSTM	۸۲.۲	۲.۲۰	۱.۶۱
(Optuna_VMD)_TCN_BiLSTM	۹۹.۱	۰.۴۸	۰.۳۶

۴- نتیجه گیری

پیش بینی سرعت باد به دلیل ماهیت تصادفی و متناوب آن، یکی از چالش های مهم در مدل سازی انرژی بادی است. در این مقاله، یک مدل پیشنهادی TCN_BiLSTM برای پیش بینی دقیق تر سرعت باد ارائه شد. با استفاده از الگوریتم Optuna_VMD، داده های سرعت باد به IMFها تجزیه شدند و هر کدام به صورت جداگانه به مدل داده شدند. نتایج نشان داد که مدل پیشنهادی با دستیابی به کمترین میزان میانگین خطای مطلق (۰.۳۶) و ریشه میانگین مربعات خطا (۰.۴۸) و بالاترین مقدار ضریب تعیین (۹۹.۱)، در مقایسه با مدل های دیگر نظیر SVR، RBF، BiLSTM، Decision Tree Regressor و TCN_LSTM، عملکرد بهتری داشته است. این یافته ها نشان می دهد که مدل TCN_BiLSTM می تواند به طور مؤثری دقت پیش بینی سرعت باد را بهبود بخشد و به عنوان یک ابزار کارآمد برای تخمین میزان تولید توان در نیروگاه بادی و همچنین باعث تصمیم گیری بهتر برنامه ریزان در کنترل توان، برای آینده مورد استفاده قرار گیرد.

پیوست

جدول (الف): مقایسه مقادیر پیش بینی شده سرعت باد با مقادیر واقعی

مقادیر پیش بینی	مقادیر پیش بینی	مقادیر تست	مقادیر پیش بینی	مقادیر تست	مقادیر پیش بینی	مقادیر تست	مقادیر پیش بینی	مقادیر تست	مقادیر پیش بینی
۷.۶	۲.۳۷۹۸۸۲	۲	۲۳.۱۷۱۱۶	۲۲.۹	۱.۲۲۵۶۹	۱.۲	۵.۴۹۸۳۹۸	۵.۴	۷.۶۰۷۲۱۶
۷.۷	۲.۴۷۲۸۸۷	۲	۲۰.۴۹۰۴۹	۲۰.۳	۱.۶۸۶۰۱۷	۱.۲	۳.۹۶۸۳۷۲	۳.۷	۷.۶۷۳۸۴۲
۷.۸	۲.۰۸۳۱۱۲	۱.۶	۱۹.۹۴۶۷۶	۱۹.۳	۱.۶۳۷۷۳۳	۱.۴	۳.۷۵۱۷۱۳	۳.۶	۷.۹۲۹۶۹۸
۸	۲.۳۵۲۷۴۵	۱.۹	۲۴.۰۳۲۲۲	۲۴.۴	۱.۹۷۴۲۰۴	۱.۳	۳.۶۳۷۲۳۲	۳.۳	۸.۱۳۸۹۲۱
۷.۷	۳.۲۶۷۹۸۶	۲.۷	۲۴.۳۲۲۷۴	۲۴.۶	۲.۵۰۶۸۰۱	۲.۶	۲.۶۹۹۹۴۸	۲.۵	۷.۶۲۲۱۹۴
۶.۱	۴.۷۰۸۰۳۱	۴.۷	۲۳.۸۰۹۰۸	۲۳.۴	۱.۹۳۲۹۹۲	۱.۲	۱.۴۶۶۷۲۱	۱.۱	۶.۱۵۸۱۶۹
۴.۹	۵.۴۳۵۷۳۹	۴.۸	۲۳.۳۹۹۰۳	۲۴.۱	۳.۴۳۲۲۶۶	۳.۹	۱.۲۸۶۷۵۷	۰.۹	۴.۸۹۴۱۳۹
۳.۱	۴.۸۲۵۹۴	۴.۹	۲۴.۸۷۲۶۱	۲۵.۴	۲.۵۹۳۲۶۸	۱.۹	۱.۵۰۴۳۶۵	۱.۵	۳.۲۱۳۷۶۶



۳.۱	۲.۶۱۹۰۷۴	۳.۸	۳.۹۸۵۳۹۵	۲۴.۴	۲۳.۹۸۶۷۳	۵	۵.۴۶۴۷۶۸	۱.۳	۱.۵۲۵۷۱۳
۲.۱	۲.۸۷۵۸۴۷	۷.۴	۷.۳۷۷۴۸۴	۲۱.۲	۲۱.۳۹۸۵۲	۴.۸	۵.۲۸۱۵۷۴	۱	۱.۴۷۰۶۱۲
۳	۲.۳۵۸۸۸۶	۸.۲	۷.۹۰۸۱۴۸	۲۰.۶	۲۰.۹۳۵۹۲	۴.۱	۴.۴۱۱۷۲۳	۱.۹	۱.۸۳۹۱۲۶
۱.۹	۲.۷۸۲۱۷۱	۸.۴	۸.۴۷۳۴۷۸	۲۸.۳	۲۷.۰۱۳۷۳	۴.۷	۵.۱۰۸۳۷۶	۲.۷	۲.۶۱۴۲۲۳
۲.۸	۲.۸۵۰۴۷۱	۶.۶	۶.۶۵۵۵۴	۳۰.۱	۲۹.۲۲۱۸۹	۴.۶	۵.۴۱۷۲۹۹	۰.۴	۰.۷۹۱۴۴۹
۱	۲.۰۹۳۴۱۵	۳.۶	۴.۰۵۸۰۷	۲۸.۶	۲۷.۹۶۳۴۶	۶.۴	۶.۹۹۶۷۹	۲.۱	۲.۰۸۹۰۷
۱.۷	۱.۵۸۹۶۹۲	۳.۴	۳.۸۲۱۸۳۲	۲۷.۶	۲۶.۷۷۸۲۶	۹	۹.۲۶۷۸۷۳	۲.۱	۲.۳۵۹۴۲۷
۴	۴.۶۳۰۰۲۳	۳.۳	۳.۷۵۹۶۱۳	۲۵.۷	۲۵.۴۴۱۲	۸.۹	۹.۲۳۲۶۳	۳.۱	۲.۹۱۹۲۹
۶.۵	۶.۲۴۲۵۴۵	۳.۸	۳.۸۹۹۰۲	۲۹.۹	۲۸.۵۰۲۲۲	۸.۴	۸.۷۸۲۶۶۸	۱	۱.۳۹۱۹۸۷
۹.۱	۹.۰۷۵۰۵۹	۱.۱	۱.۸۸۷۱۶۶	۲۲.۸	۲۳.۸۷۱۳	۱۲.۵	۱۱.۸۲۷۱۸	۰.۹	۱.۲۳۷۲۶۳
۱۰.۶	۱۰.۱۴۷۸۲	۳.۸	۳.۶۴۷۱۸۸	۲۲.۵	۲۲.۳۶۷۸۵	۱۳.۳	۱۳.۲۷۷۵۹	۳.۶	۳.۶۵۶۳۴۱
۱۰	۱۰.۲۸۹	۵.۱	۵.۴۲۲۶۲۵	۲۱.۱	۲۱.۱۰۱۲۸	۱۳.۱	۱۳.۲۰۳۰۷	۵.۵	۵.۲۶۸۸۱۴
۱۰.۴	۹.۶۲۰۵۹۶	۷.۲	۷.۱۰۱۸۸۷	۲۳.۱	۲۲.۵۹۶۸۷	۱۵.۱	۱۴.۷۱۲۲۴	۵.۵	۵.۸۵۹۲۱۳
۲.۸	۴.۶۴۲۲۲۲	۶.۵	۶.۵۰۵۹۱۴	۲۴.۲	۲۳.۹۸۱۴۶	۱۳.۶	۱۳.۸۱۲۵۶	۵.۴	۵.۳۷۲۷۵
۱۲.۲	۱۰.۸۳۶۲۶	۶.۷	۶.۶۹۰۹۵۵	۲۴.۹	۲۴.۶۱۵۲۲	۱۴.۱	۱۴.۲۰۲۷۸	۷.۴	۷.۰۱۴۹۰۷
۱۱.۲	۱۲.۰۹۱۶۹	۶.۲	۶.۲۶۴۲۶۶	۲۶.۴	۲۵.۵۲۲۷۳	۱۵.۱	۱۴.۷۷۰۹۶	۵	۵.۲۲۰۰۰۸
۱۲	۱۰.۹۳۳۴۴	۲.۴	۳.۰۱۴۲۱۹	۲۶.۹	۲۶.۲۲۱۳۵	۱۴	۱۳.۹۹۳۸۸	۳.۷	۴.۱۶۱۴۰۹
۸	۹.۳۸۲۶۷۶	۲.۸	۳.۰۰۲۰۷۳	۲۴.۲	۲۴.۴۳۵۱۴	۱۴.۱	۱۳.۹۳۸۳۸	۳.۹	۴.۰۰۷۵۸۸
۱۵	۱۳.۶۴۰۳۷	۰.۴	۰.۹۴۷۸۰۹	۲۳.۳	۲۳.۲۴۵۹۱	۱۴.۱	۱۳.۹۳۴۷۳	۵.۳	۵.۲۹۹۱۳۲
۱۰.۹	۱۱.۴۴۹	۲.۱	۲.۰۵۳۳۴۱	۲۱.۹	۲۲.۴۱۴۶۲	۱۴.۸	۱۴.۷۶۵۸۵	۶.۵	۶.۱۲۸۸۵۸
۱۰.۵	۱۰.۳۳۲۴۴	۲.۳	۲.۳۹۶۹۳۹	۲۳.۶	۲۲.۶۹۴۶۲	۱۴.۶	۱۴.۵۶۰۱۹	۳.۹	۴.۴۲۲۹۹۷
۱۲.۵	۱۲.۶۲۱۲۲	۳.۷	۳.۹۲۹۹۲۱	۲۳.۷	۲۳.۸۳۶۱۹	۱۴.۸	۱۴.۴۲۷۹۴	۳.۲	۳.۴۲۸۱۴۷
۱۳.۹	۱۳.۱۶۹۶۸	۲.۵	۲.۵۸۹۴۴۸	۲۳.۸	۲۳.۴۴۶۲۷	۱۳.۳	۱۲.۶۹۲۶۵	۱.۸	۲.۳۹۴۰۳۵
۱۲.۳	۱۲.۷۱۶۹۷	۱.۵	۱.۸۲۷۳۱۹	۲۲.۵	۲۲.۱۲۱۱۴	۱۲.۳	۱۲.۵۰۱۸۵	۴.۳	۴.۲۲۶۱۸۲
۱۳.۳	۱۲.۲۶۱۹۲	۵.۵	۴.۹۰۵۵۴۲	۱۸.۴	۱۸.۸۲۴۴۴	۱۱.۴	۱۱.۰۶۴۵	۲.۴	۳.۲۳۲۲۸۸
۱۰.۸	۱۱.۷۹۲۷۵	۶.۷	۶.۷۵۶۱۳۴	۱۷.۴	۱۷.۲۴۴۵	۹.۶	۹.۷۵۴۰۵۸	۴.۴	۴.۵۴۹۳۴۳
۱۱.۲	۹.۶۱۴۵۸۱	۶	۵.۷۶۰۰۷۲	۱۸	۱۸.۴۱۳۷۴	۶.۷	۷.۰۷۳۱۰۵	۵.۷	۵.۶۴۹۲۱۸
۱.۸	۳.۹۰۵۰۴۵	۳.۸	۳.۷۹۳۸۳۶	۱۹.۸	۱۹.۳۲۷۹۴	۴.۱	۴.۵۹۵۹۶۸	۴	۴.۰۹۰۰۶
۹.۸	۹.۰۱۵۱۴۲	۵.۴	۵.۵۴۴۴۸۹	۱۶.۴	۱۶.۴۰۷۷	۴.۸	۵.۰۲۶۹۵۹	۲.۱	۲.۴۳۷۵۱۴
۹.۶	۱۰.۰۲۹۹۳	۵.۸	۵.۴۴۴۴۸۵	۱۵.۷	۱۵.۸۳۲۳۴	۳.۸	۴.۵۹۲۰۸۲	۱.۵	۱.۴۴۲۱۱۶
۵.۳	۴.۹۱۲۸۵۵	۴.۶	۴.۹۴۵۶۳۵	۱۳.۴	۱۳.۵۷۶۹۳	۴.۵	۵.۰۱۴۵۹۸	۱.۴	۱.۴۳۰۵۶۲
۱.۷	۲.۹۱۸۶۲۳	۵.۴	۵.۶۲۴۵۷۳	۹.۴	۱۰.۴۹۹۳۵	۶	۶.۲۳۲۶۰۹	۲.۱	۲.۴۱۹۵۷۲
۵.۴	۵.۰۲۰۲۹۸	۶.۸	۶.۸۷۸۹۲۱	۱۰.۴	۱۰.۶۱۷۰۱	۱۱.۲	۱۰.۳۱۴۳۵	۲	۱.۸۷۴۰۱۴
۷.۲	۷.۶۷۸۰۸۷	۶.۵	۶.۶۶۶۷۰۳	۱۰.۸	۱۱.۳۲۳۱	۷.۳	۷.۷۹۹۵۴۸	۱.۸	۲.۶۷۹۰۹۶
۸.۹	۸.۶۴۰۷۳۶	۶.۹	۶.۶۳۹۵۲۷	۱۲.۷	۱۲.۹۶۷۰۵	۶.۵	۶.۳۵۵۰۴۹	۱.۹	۱.۶۷۳۲۲۸
۷.۹	۸.۶۲۲۵۱۹	۵.۶	۶.۱۰۹۹۶۳	۱۴.۹	۱۴.۵۸۰۲۲	۱.۴	۲.۵۰۵۱۲۹	۱.۳	۱.۴۱۹۱۷۳
۱۰.۷	۱۰.۱۷۷۰۲	۵	۴.۳۵۹۸۰۸	۱۱.۶	۱۲.۷۶۰۸۴	۲.۸	۳.۳۳۳۳۶۸	۱.۳	۱.۴۳۰۷۰۹
۷.۷	۸.۸۴۶۶۰۲	۱.۸	۲.۱۳۵۹۹۹	۱۶.۹	۱۶.۲۷۴۷۸	۵.۸	۵.۸۳۰۰۳	۲.۷	۲.۷۸۹۶۸۳
۱۲.۴	۱۱.۲۵۵۵۸	۴.۲	۴.۲۵۹۴۹۶	۱۶.۹	۱۶.۵۴۲۲۲	۴.۳	۴.۷۰۸۴۸۸	۱.۹	۲.۳۲۰۳۰۶
۱۰.۱	۱۱.۱۸۴۵۶	۶.۸	۶.۵۷۹۲۸۲	۱۶.۳	۱۶.۰۰۴۵۴	۱.۴	۲.۲۴۹۷۱۷	۵.۲	۵.۳۸۲۵۰۱
۹.۲	۸.۸۷۵۵۵۵	۱.۳	۱.۸۴۴۹۱۹	۱۷.۶	۱۷.۲۳۵۴۶	۱.۱	۱.۳۵۱۹۱۹	۶.۹	۶.۴۴۷۲۶۲
۱۰.۱	۹.۹۴۳۷۲۲	۱.۳	۱.۷۰۳۵۷۲	۱۳.۳	۱۳.۸۱۸۹۵	۲	۲.۳۰۰۳۶۵	۴.۴	۴.۹۴۶۹۵۷
۱۳.۵	۱۳.۱۲۵۸۶	۴.۵	۴.۴۰۷۲۳۷	۱۲.۸	۱۲.۷۵۹۸۹	۱.۵	۱.۹۹۲۱۹۳	۵.۹	۵.۲۷۵۵۰۶
۸.۳	۹.۷۶۴۷۷۸	۴.۵	۴.۹۰۵۷۲۹	۱۰.۸	۱۱.۱۷۹۸۶	۱.۴	۱.۸۵۹۵۰۶	۰.۷	۲.۰۵۹۳۶۲
۱۱.۵	۱۰.۵۶۹۳۱	۴.۴	۴.۳۹۶۰۱۸	۱۰.۱	۱۰.۱۲۲۳۳	۱.۲	۱.۱۸۵۲۴۱	۱۲.۱	۱۰.۳۱۹۵۷



۹.۹	۱۰۰۷۲۳۵	۴.۸	۵.۱۳۹۴۱۷	۷	۷.۵۳۵۹۱۹	۱	۱.۵۶۷۷۷۲	۴.۲	۵.۴۸۵۹۵
۸.۹	۹.۳۳۳۶۷۶	۷.۹	۷.۰۴۱۶۶۵	۶.۲	۶.۷۹۶۷۱۶	۱.۴	۱.۹۹۵۶۳۳	۵.۱	۵.۰۲۸۶۶۲
۱۰.۳	۱۰.۳۰۶۸۵	۲.۵	۳.۰۰۶۶۶	۱۰.۳	۱۰.۵۳۷۴۹	۴.۵	۴.۳۷۸۱۷۲	۴.۱	۴.۳۸۲۷۵۷
۸.۷	۸.۵۵۷۲۷۹۷	۱.۳	۱.۷۰۱۴۳	۱۱.۹	۱۲.۰۸۳۳۹	۲.۹	۳.۰۱۴۷۰۱	۳.۷	۳.۹۱۶۳۱۲
۳.۵	۴.۷۹۷۵۵۳	۴.۱	۳.۹۴۷۹۵۸	۱۰.۹	۱۰.۹۲۱۲۳	۰.۸	۱.۱۳۸۷۹۹	۳.۹	۴.۱۲۳۷۳۹
۵.۲	۴.۹۵۴۵۸۴	۲.۳	۲.۶۰۲۷۹۷	۱۰.۶	۱۰.۳۴۳۵	۰.۵	۰.۵۰۶۳۹۳	۳.۷	۴.۰۷۵۵
۷	۷.۰۹۰۳۳۷	۰.۷	۱.۰۶۵۲۴۳	۹.۸	۹.۶۷۷۸۹۱	۰.۶	۱.۴۴۹۳۷۷	۶.۱	۶.۲۱۳۹۶
۷.۵	۷.۸۹۱۵۱۳	۴	۴.۰۹۹۰۴۹	۵.۷	۵.۸۳۶۲۶	۰.۹	۱.۱۰۴۸۰۹	۱۰.۹	۹.۵۷۸۳۳۷
۶.۸	۶.۹۳۶۸۰۸	۲.۸	۳.۲۵۷۶۶۱	۲.۷	۳.۵۱۸۶۵۳	۱.۶	۱.۶۰۱۷۷۴	۷	۷.۶۵۲۰۸۴
۵.۸	۵.۴۳۵۵۱۴	۱.۱	۱.۳۰۷۸۳۱	۲.۳	۲.۷۷۴۱۳۹	۲.۴	۲.۴۴۱۰۰۴	۲.۲	۲.۲۳۲۱۷۸
۴.۵	۵.۱۰۱۱۷۴	۱.۳	۲.۰۱۹۰۷۶	۳.۸	۴.۰۱۹۳۳۸	۴.۷	۴.۶۲۹۹۹۷	۲.۶	۳.۴۶۱۸۴۶
۴	۴.۱۳۰۵۴۱	۶	۶.۱۰۵۴۱۱	۴.۴	۴.۴۴۷۵۵۳	۷.۸	۷.۳۲۰۹۶۲	۳.۲	۲.۴۲۲۲۵
۴	۴.۱۰۰۱۶۱	۸.۳	۸.۶۵۳۸۱۴	۲.۸	۳.۴۵۹۵۳۷	۹.۴	۸.۷۰۶۱۰۶	۳.۴	۳.۷۴۷۱۵۴
۱.۱	۱.۸۲۲۱۲۲	۱۰.۶	۱۰.۳۴۸۸۹	۵.۸	۵.۵۱۷۰۱۱	۶	۶.۲۰۰۹۳۲	۲.۹	۳.۱۸۴۴۱
۴.۳	۳.۸۷۲۴۹۸	۱۴.۴	۱۴.۴۴۲۲۸	۱.۹	۲.۴۴۹۹۸	۴.۴	۴.۶۶۴۲۰۱	۲.۷	۲.۷۵۶۲۹۱
۵.۲	۴.۹۶۵۴۶۷	۱۶.۸	۱۶.۶۳۸۳۸	۳.۵	۳.۴۰۵۵۳۸	۹.۹	۹.۰۴۷۹۳۵	۲.۳	۲.۴۸۴۲۶
۳.۲	۳.۶۹۹۷۵۸	۱۸.۵	۱۷.۸۹۲۷	۵.۵	۵.۴۹۷۰۲۵	۷.۸	۸.۱۴۸۹۷۲	۱.۴	۱.۹۱۰۹۳۱
۳.۳	۳.۴۴۲۰۴	۱۹.۷	۱۹.۱۲۲۸۶	۳.۱	۳.۴۵۰۱۱۲	۱۰.۵	۹.۸۲۹۴۵۶	۲.۳	۲.۴۴۸۰۰۷
۵.۸	۵.۵۱۸۹۴۲	۱۹.۹	۱۹.۸۵۶۰۴	۲.۷	۲.۷۰۷۱۱۱	۷.۲	۷.۳۳۳۵۹۶	۳.۳	۲.۸۷۲۰۱۳
۶.۳	۶.۳۲۳۳۹۷	۱۹.۷	۱۸.۹۸۰۰۴	۳.۵	۳.۳۵۵۴۸۵	۹.۱	۹.۱۶۶۵۶۸	۳.۱	۳.۳۲۲۷۲۷
۶.۸	۶.۷۶۳۸۲۴	۱۹.۸	۱۹.۳۰۴۴۸	۳.۳	۳.۷۴۰۶۷۶	۱۱.۷	۱۱.۶۹۵۷۸	۲	۲.۴۶۸۲۳۱
۵.۶	۵.۶۴۵۵۳۹	۱۹.۵	۱۹.۳۵۸۴۴	۴.۱	۴.۰۳۹۹۷۴	۱۳.۳	۱۲.۷۱۸۱۲	۵.۹	۵.۷۳۰۳۳۵
۲.۴	۲.۶۵۴۴	۱۹.۴	۱۹.۱۷۱۰۶	۳.۷	۴.۲۸۲۵۷۹	۱۰.۹	۱۰.۶۴۲۳۹	۳	۳.۹۸۷۹۳۷
۱.۷	۱.۹۹۴۱۸۹	۲۰.۷	۲۰.۰۷۱۱۶	۴.۷	۴.۶۶۵۴۰۹	۵.۸	۶.۰۰۳۹۸۹	۲.۵	۲.۲۵۷۴۷۲
۱.۵	۱.۷۹۹۸۸۲	۲۱.۵	۲۰.۹۷۶۶۵	۴.۲	۴.۹۳۳۳۸۶	۴.۶	۴.۶۵۷۱۷۷	۴.۳	۴.۴۱۱۴۶۵
۳.۴	۳.۶۹۴۰۷۴	۲۲.۷	۲۲.۲۵۳۴۳	۳.۶	۳.۴۳۴۴۲۷	۳.۷	۴.۰۸۴۴۰۳	۳.۵	۳.۷۴۰۶۹۴
۳.۷	۳.۷۹۴۴۴۳	۲۰.۳	۲۰.۳۳۶۹۸	۲.۹	۳.۴۴۴۴۶۸	۳.۴	۳.۸۶۵۰۰۳	۲.۳	۳.۳۶۸۶۵۲
۱.۷	۲.۱۱۴۹۷۴	۲۱.۲	۲۰.۹۱۰۶۹	۴.۳	۴.۰۰۸۳۵۸	۲.۱	۱.۸۵۵۵۲۹	۴.۴	۴.۲۸۷۴۱۹
۳.۶	۴.۰۱۳۳۲۳	۲۱.۵	۲۱.۲۸۵۴	۴.۷	۴.۶۳۶۶۵۸	۵.۲	۴.۹۲۵۵۵۸	۶.۷	۶.۸۶۵۵۰۸
۵.۶	۵.۶۱۶۸۸۹	۲۱.۴	۲۱.۱۳۴۶۴	۶.۹	۶.۵۰۴۵۸۸	۲.۶	۳.۲۷۰۰۷۴	۷.۲	۶.۹۶۳۱۴۲
۴.۸	۴.۹۵۹۵۱۶	۲۱.۴	۲۱.۰۷۳۸۹	۵.۸	۵.۸۵۳۳۵۹	۴.۲	۴.۵۴۶۱۱۹	۹	۸.۰۷۴۵۲۹
۵.۲	۵.۱۷۵۶۵۳	۲۲.۱	۲۱.۷۸۱۱۴	۵.۹	۵.۸۴۳۶۱	۵.۹	۵.۸۱۴۸۱۸	۰.۴	۱.۷۸۳۰۷۸
۵.۴	۵.۲۰۰۷۲۶	۲۲.۱	۲۲.۰۵۷۱۷	۴.۹	۴.۹۱۴۰۲۴	۴.۲	۴.۳۶۱۷۴۳	۲.۶	۳.۶۰۹۲۲۷
۳.۸	۳.۹۲۷۷۳۴	۲۰.۹	۲۱.۰۹۹۳۷	۶.۸	۶.۴۶۹۶۵۵	۴.۱	۳.۸۵۹۴۹۷	۱۴.۶	۱۲.۲۸۰۷
۳.۳	۳.۵۴۸۶۳۱	۲۳.۳	۲۲.۹۱۴۰۳	۴.۲	۴.۷۲۱۹۷۹	۱.۳	۱.۹۸۱۸۳۷	۵.۹	۷.۲۳۴۹۷۴
۲.۴	۲.۲۸۴۹۰۷	۲۳.۱	۲۲.۷۳۶۹۴	۴.۴	۴.۲۰۴۳۷۷	۰.۴	۱.۱۲۷۹۸۵	۶.۴	۶.۱۸۱۸۷۶
۲.۷	۲.۸۲۸۲۱۸	۲۲.۹	۲۲.۴۶۴۵۸	۱.۵	۲.۰۴۶۱۵۸	۲.۲	۲.۲۷۲۵۳۵	۲.۲	۲.۵۸۴۳۰۱
۳.۲	۳.۱۲۸۳۵۲	۲۲.۸	۲۲.۲۸۶۱۹	۲	۲.۱۵۰۵۶۳	۳.۷	۳.۵۳۹۵۵۳	۴.۴	۴.۲۵۲۴۳۱
۱.۴	۱.۹۸۸۸۱۱	۲۳.۵	۲۲.۹۵۷۷۳	۱.۶	۲.۰۷۵۳۵۳	۳	۳.۳۱۸۳۲۳	۰.۹	۲.۰۰۸۰۷۲
۲.۱	۲.۵۵۱۲۸	۲۲.۶	۲۲.۵۱۶۰۷	۳.۵	۳.۴۲۲۰۶۵	۴.۷	۴.۹۲۳۹۰۸	۴.۲	۳.۹۵۵۳۰۱
۱.۲	۱.۷۴۶۵۸۸	۲۳	۲۲.۶۵۱۹۷	۴	۴.۲۱۵۰۴۷	۳.۳	۳.۷۶۳۶۵۸	۶.۸	۶.۵۸۴۵۴۴
۱.۹	۱.۶۰۷۴۴	۲۴.۶	۲۴.۳۶۳۸۵	۴.۴	۴.۴۷۶۲۶۱	۲.۱	۲.۷۵۷۴۵۲	۵.۷	۵.۸۵۰۱۴۱
۲	۲.۲۵۵۰۹۹	۲۴.۷	۲۴.۶۹۸۱۵	۷.۴	۶.۷۸۸۶۶۷	۲.۸	۳.۲۷۴۵۹۹	۵.۲	۵.۰۲۵۶۹۸
۰.۵	۰.۸۱۶۳۸۱	۲۴.۸	۲۴.۸۲۳۵۲	۱.۱	۲.۰۴۲۵۲۲	۴.۱	۳.۸۸۴۰۳۲	۱.۶	۲.۴۴۰۱۵۷
۱.۷	۱.۶۳۳۵۱۷	۲۴.۹	۲۴.۸۷۱۱۵	۱.۴	۱.۷۰۲۰۲۱	۲.۳	۳.۱۳۰۱۷۲	۱.۲	۲.۰۵۲۸۴۶



۲.۹	۲.۸۳۸۱۹۱	۲۶.۲	۲۶.۲۵۲۲۶	۱	۱.۲۶۰۹۶۷	۵.۱	۴.۸۴۹۶۷۸	۳.۲	۱.۹۹۱۰۸۳
۰.۴	۰.۸۶۳۰۶۲	۲۶.۵	۲۵.۸۴۷۸۲	۱	۱.۶۰۲۶۱۳	۵.۷	۵.۹۶۴۴۷۱	۲.۱	۲.۹۵۸۴۱۲

مراجع

- [1] Y. Zhao, L. Ye, Z. Li, X. Song, Y. Lang, and J. Su, "A novel bidirectional mechanism based on time series model for wind power forecasting," *Applied energy*, vol. 177, pp. 793-803, 2016. doi: 10.1016/j.apenergy.2016.03.096
- [2] M. Tavvosi, F. E. Heydarian, M. H. Amirioun, and M. M. Parsa, "A Review on the Technical Challenges of Connecting Wind Energy Conversion Systems to the Grid," 2022. doi: 10.30486/teeges.2022.1965932.1031
- [3] J. Wan, G. Ren, J. Liu, Q. Hu, and D. Yu, "Ultra-short-term wind speed prediction based on multi-scale predictability analysis," *Cluster Computing*, vol. 19, pp. 741-755, 2016. doi: 10.1007/s10586-016-0554-0
- [4] D. Song *et al.*, "New perspectives on maximum wind energy extraction of variable-speed wind turbines using previewed wind speeds," *Energy conversion and management*, vol. 206, p. 112496, 2020. doi: 10.1016/j.enconman.2020.112496
- [5] J. Zhao, Y. Guo, X. Xiao, J. Wang, D. Chi, and Z. Guo, "Multi-step wind speed and power forecasts based on a WRF simulation and an optimized association method," *Applied energy*, vol. 197, pp. 183-202, 2017. doi: 10.1016/j.apenergy.2017.04.017
- [6] H. Verbois, R. Huva, A. Rusydi, and W. Walsh, "Solar irradiance forecasting in the tropics using numerical weather prediction and statistical learning," *Solar Energy*, vol. 162, pp. 265-277, 2018. doi: 10.1016/j.solener.2018.01.007
- [7] V. Hoolohan, A. S. Tomlin, and T. Cockerill, "Improved near surface wind speed predictions using Gaussian process regression combined with numerical weather predictions and observed meteorological data," *Renewable Energy*, vol. 126, pp. 1043-1054, 2018. doi: 10.1016/j.renene.2018.04.019
- [8] M. Gan, H. Peng, X. Peng, X. Chen, and G. Inoussa, "A locally linear RBF network-based state-dependent AR model for nonlinear time series modeling," *Information Sciences*, vol. 180, no. 22, pp. 4370-4383, 2010. doi: 10.1016/j.ins.2010.07.012
- [9] E. Grigonytė and E. Butkevičiūtė, "Short-term wind speed forecasting using ARIMA model," *Energetika*, vol. 62, no. 1-2, 2016. doi: 10.6001/energetika.v62i1-2.3313
- [10] Z. Lu, S. Lu, M. Xu, and B. Cui, "A robust stochastic stability analysis approach for power system considering wind speed prediction error based on Markov model," *Computer Standards & Interfaces*, vol. 75, p. 103503, 2021. doi: 10.1016/j.csi.2020.103503
- [11] Z. Zhou, Y. Dai, J. Xiao, M. Liu, J. Zhang, and M. Zhang, "Research on Short-Time Wind Speed Prediction in Mountainous Areas Based on Improved ARIMA Model," *Sustainability*, vol. 14, no. 22, p. 15301, 2022. doi: 10.3390/su142215301
- [12] E. Erdem and J. Shi, "ARMA based approaches for forecasting the tuple of wind speed and direction," *Applied Energy*, vol. 88, no. 4, pp. 1405-1414, 2011. doi: 10.1016/j.apenergy.2010.10.031
- [13] G. Santamaría-Bonfil, A. Reyes-Ballesteros, and C. Gershenson, "Wind speed forecasting for wind farms: A method based on support vector regression," *Renewable Energy*, vol. 85, pp. 790-809, 2016. doi: 10.1016/j.renene.2015.07.004
- [14] Z. Qu, W. Mao, K. Zhang, W. Zhang, and Z. Li, "Multi-step wind speed forecasting based on a hybrid decomposition technique and an improved back-propagation neural network," *Renewable energy*, vol. 133, pp. 919-929, 2019. doi: 10.1016/j.renene.2018.10.043
- [15] Z. Ma, T. Wu, S. Guo, H. Wang, G. Xu, and S. Aziz, "An integrated prediction model based on meta ensemble learning for short-term wind speed forecasting," *IET Renewable Power Generation*, 2024. doi: 10.1049/rpg2.13016
- [16] Y. Ding, X.-W. Ye, and Y. Guo, "A multistep direct and indirect strategy for predicting wind direction based on the EMD-LSTM model," *Structural Control and Health Monitoring*, vol. 2023, no. 1, p. 4950487, 2023. doi: 10.1155/2023/4950487



- [17] Y. Sun, J. Yang, X. Zhang, K. Hou, J. Hu, and G. Yao, "An Ultra-short-term wind power forecasting model based on EMD-EncoderForest-TCN," *IEEE Access*, 2024. doi: 10.1109/ACCESS.2024.3373798
- [18] D. Niu, Y. Liang, and W.-C. Hong, "Wind speed forecasting based on EMD and GRNN optimized by FOA," *Energies*, vol. 10, no. 12, p. 2001, 2017. doi: 10.3390/en10122001
- [19] D. Zhang, C. Cai, S. Chen, and L. Ling, "An improved genetic algorithm for optimizing ensemble empirical mode decomposition method," *Systems Science & Control Engineering*, vol. 7, no. 2, pp. 53-63, 2019. doi: 10.1080/21642583.2019.1627598
- [20] A. Kang, Q. Tan, X. Yuan, X. Lei, and Y. Yuan, "Short-Term Wind Speed Prediction Using EEMD-LSSVM Model," *Advances in Meteorology*, vol. 2017, no. 1, p. 6856139, 2017. doi: 10.1155/2017/6856139
- [21] K. Jaseena and B. C. Kovoov, "EEMD-based Wind Speed Forecasting system using Bidirectional LSTM networks," in *2021 International Conference on Computer Communication and Informatics (ICCCI)*, 2021, pp. 1-9: IEEE. doi: 10.1109/ICCCI50826.2021.9402648
- [22] K. Gezici, O. M. Katipoğlu, and S. Şengül, "Hybrid machine learning models for groundwater level prediction in a snow-dominated region: An evaluation of EEMD, VMD and EWT decomposition techniques," *Hydrological Processes*, vol. 38, no. 5, p. e15169, 2024. doi: 10.1002/hyp.15169
- [23] A. L. Wood, A. Simon, P. W. Downs, and C. R. Thorne, "Bank-toe processes in incised channels: The role of apparent cohesion in the entrainment of failed bank materials," *Hydrological Processes*, vol. 15, no. 1, pp. 39-61, 2001. doi: 10.1002/hyp.15169
- [24] Y. Zhang, Y. Zhao, C. Kong, and B. Chen, "A new prediction method based on VMD-PRBF-ARMA-E model considering wind speed characteristic," *Energy Conversion and Management*, vol. 203, p. 112254, 2020. doi: 10.1016/j.enconman.2019.112254
- [25] A. A. Abdoos, "A new intelligent method based on combination of VMD and ELM for short term wind power forecasting," *Neurocomputing*, vol. 203, pp. 111-120, 2016. doi: 10.1016/j.neucom.2016.03.054
- [26] M. Hassanali, M. Soltanaghaei, T. Javdani Gandomani, and F. Zamani Boroujeni, "Software development effort estimation using boosting algorithms and automatic tuning of hyperparameters with Optuna," *Journal of Software: Evolution and Process*, p. e2665, 2024. doi: 10.1002/smr.2665
- [27] J. Zhu, L. Su, and Y. Li, "Wind power forecasting based on new hybrid model with TCN residual modification," *Energy and AI*, vol. 10, p. 100199, 2022. doi: 10.1016/j.egyai.2022.100199
- [28] R. Zhu, W. Liao, and Y. Wang, "Short-term prediction for wind power based on temporal convolutional network," *Energy Reports*, vol. 6, pp. 424-429, 2020. doi: 10.1016/j.egy.2020.11.219
- [29] S. Moalem, R. MP Ahari, G. Shahgholian, M. Moazzami, and S. M. Kazemi, "A Hybrid Method for Long-Term Demand Forecasting in the Electrical Energy Supply Chain of Basic Metal Production Industries in the Presence of Incomplete Data," *Technovations of Electrical Engineering in Green Energy System*, vol. 2, no. 1, pp. 117-139, 2023. doi: 10.30486/tee.2023.1974408.1051
- [30] A. Saeed *et al.*, "Hybrid bidirectional LSTM model for short-term wind speed interval prediction," *IEEE Access*, vol. 8, pp. 182283-182294, 2020. doi: 10.1109/ACCESS.2020.3027977

زیر نویس ها

¹ Numerical Weather Prediction (NWP)

² Gaussian Process Regression

³ Autoregressive

⁴ Autoregressive Integrated Moving Average (ARIMA)

⁵ Markov Chain

⁶ Support Vector Regression (SVR)

⁷ Artificial Neural Network (ANN) methods

⁸ Empirical Mode Decomposition

⁹ Ensemble Empirical Mode Decomposition

¹⁰ Principal Component Analysis - Radial Basis Function

