



Technovations of Electrical Engineering in Green Energy System

Research Article

(2024) 3(3):15-26

Short-Term Forecasting of Wind Farm Power Production Using a Modified Artificial Neural Networks Based Algorithm in Python: A Case Study in Manjil

Hamid Jabari¹, *M.Sc Student*, Ardalan Shafiei-Ghazani¹, *Assistant Professor*,
Farkhondeh Jabari², *Assistant Professor*

¹ Faculty of Mechanical Engineering, Sahand University of Technology, Tabriz, Iran

² Power Systems Operation and Planning Research Department, Niroo Research Institute (NRI), Shahrak Ghods, Tehran, Iran

Abstract:

This paper presents a new approach for short-term forecasting of wind farm power generation using artificial neural networks under Python programming language. In this method, weather conditions such as wind speed, wind direction, temperature and air pressure are selected as key features affecting the power production of the wind farm. To achieve a relatively accurate estimate, the root mean squared error of the predicted values is calculated and minimized as the objective function. The speed and accuracy of the proposed algorithm have been evaluated by conducting a case study on a wind farm located in Manjil, Iran. The power production of the wind power plant is predicted for a time horizon of one week and hour by hour using the wind speed, wind direction, temperature and air pressure during 8592 hours (total hours of a year minus hours of a week). The root mean squared error, the highest relative error percentage, the time resolution of the forecasts and the calculation time of the proposed algorithm are compared with other algorithms published in recent years, which shows the effectiveness and high accuracy of the results in a short calculation time. The power production of the wind farm was predicted hour by hour during a week and 168 data points were obtained, the root mean squared error in the optimal scenario is equal to 0.010817. The calculation time of the forecasting algorithm is less than 1 minute, and the maximum relative error in the proposed method is 2.3%, which demonstrates that the uncertainties associated with the power production of the wind farm can be reduced by using this short-term forecasting approach.

Keywords: Wind farm, Short time interval, Artificial neural networks (AANs), Root mean squared error (RMSE).

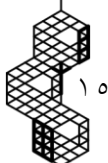
Received: 09 April 2023

Revised: 08 February 2024

Accepted: 26 July 2023

Corresponding Author: Dr. Ardalan Shafiei-Ghazani, shafiei.ardalan@sut.ac.ir

DOI: 10.30486/TEEGES.2024.952164





پیش‌بینی کوتاه‌مدت توان تولیدی مزرعه بادی به کمک الگوریتم بهبودیافته مبتنی بر شبکه‌های عصبی مصنوعی در پایتون: مطالعه موردی در منجیل

حمید جباری^۱، دانشجوی کارشناسی ارشد، اردلان شفیع‌ی غازانی^۱، استادیار، فرخنده جباری^۲، استادیار

۱- دانشکده مهندسی مکانیک، دانشگاه صنعتی سهند، تبریز، ایران

۲- گروه پژوهشی برنامه‌ریزی و بهره‌برداری سیستم‌های قدرت، پژوهشگاه نیرو، تهران، ایران

چکیده: این مقاله یک رویکرد جدید برای پیش‌بینی کوتاه‌مدت توان تولیدی مزارع بادی با استفاده از شبکه‌های عصبی مصنوعی تحت زبان برنامه‌نویسی پایتون ارائه می‌دهد. در این روش شرایط آب و هوایی مانند سرعت باد، جهت باد، دما و فشار هوا به عنوان ویژگی‌های کلیدی تاثیرگذار بر توان تولیدی مزرعه بادی انتخاب می‌شوند. برای دستیابی به یک تخمین نسبتاً دقیق، جذر میانگین مربعات خطای مقادیر پیش‌بینی شده محاسبه و به عنوان تابع هدف کمینه می‌شود. سرعت و دقت الگوریتم پیشنهادی با انجام مطالعه موردی بر روی یک مزرعه بادی واقع در منجیل ارزیابی شده است. توان تولیدی نیروگاه بادی برای افق زمانی یک هفته و به صورت ساعت به ساعت با استفاده از سرعت باد، جهت باد، دما و فشار هوا در طول ۸۵۹۲ ساعت (کل ساعات یک سال - ساعات یک هفته) پیش‌بینی می‌شود. جذر میانگین مربعات خطا، بیشترین درصد خطای نسبی، وضوح زمانی پیش‌بینی‌ها و مدت زمان اجرای محاسبات توسط الگوریتم پیشنهادی با سایر الگوریتم‌های منتشر شده در سالهای اخیر مقایسه می‌شود که نشان‌دهنده اثربخشی و دقت بالای نتایج حاصل در یک زمان محاسباتی کوتاه است. توان تولیدی مزرعه بادی در طول یک هفته به صورت ساعت به ساعت پیش‌بینی شده و ۱۶۸ نقطه داده بدست آمده که جذر میانگین مربعات خطای پیش‌بینی در سناریوی بهینه برابر با ۰/۱۰۸۱۷ است. زمان اجرای محاسبات الگوریتم پیش‌بینی کمتر از ۱ دقیقه بوده و حداکثر خطای نسبی در روش پیشنهادی ۲/۳ درصد است که نشان می‌دهد عدم قطعیت‌های مرتبط با توان تولیدی مزرعه بادی را می‌توان با استفاده از این رویکرد پیش‌بینی کوتاه‌مدت کاهش داد.

واژه‌های کلیدی: مزرعه بادی، بازه زمانی کوتاه‌مدت، شبکه‌های عصبی مصنوعی (AANs)، جذر میانگین مربعات خطا (RMSE)

تاریخ ارسال مقاله: ۱۴۰۲/۱۱/۱۹

تاریخ بازنگری مقاله: ۱۴۰۳/۰۴/۱۳

تاریخ پذیرش مقاله: ۱۴۰۳/۰۵/۰۵

نویسنده‌ی مسئول: دکتر اردلان شفیع‌ی غازانی، shafiei.ardalan@sut.ac.ir

DOI: 10.30486/TEEGES.2024.952164



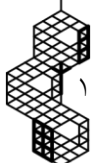
۱- ضرورت انجام پژوهش، مرور منابع و نوآوری مقاله

مدلسازی عدم قطعیت نگرانی اصلی تصمیم‌گیرندگان صنعت برق و انرژی کشور شامل دولت، مهندسان، مدیران و پژوهشگران بوده است. پارامترهای دارای عدم قطعیت در مطالعات سیستم‌های انرژی به دو دسته پارامترهای فنی و اقتصادی طبقه‌بندی می‌شوند [۱]. پارامترهای فنی شامل پارامترهای توپولوژیکی و پارامترهای بهره‌برداری سیستم است. پارامترهای توپولوژیکی مربوط به توپولوژی شبکه شامل خرابی^۱ یا خروج از مدار تجهیزات یا چون خطوط انتقال، ژنراتورها، دستگاه‌های اندازه‌گیری و سایر اجزای سیستم می‌شود. پارامترهای بهره‌برداری نظیر مقادیر تقاضا یا بار و تولید که بر تصمیم‌گیری در حوزه بهره‌برداری سیستم تأثیر گذارند. پارامترهایی نظیر تأمین سوخت، مالیات، هزینه‌های تولید، نرخ بهره و موارد دیگر که بر شاخص‌های اقتصادی سیستم تأثیر گذارند. اقتصاد خرد تصمیمات بخش‌های کوچکتر نظیر تصمیم‌کننده‌ها، مصرف‌کنندگان خانگی یا صنعتی را بررسی می‌کند. در حالیکه اقتصاد کلان به تصمیم‌گیری در حوزه سیستم قدرت و انرژی به هم پیوسته (سراسری) می‌پردازد. به عنوان مثال، نایقینی در تأمین سوخت، هزینه‌های تولید، مالیات‌های کسب‌وکار، تأمین مواد خام مورد نیاز، در اقتصاد خرد تحلیل می‌شود. از سویی دیگر موضوعاتی چون قانون‌گذاری یا مقررات‌زدایی، سیاست‌های زیست‌محیطی، رشد اقتصادی، نرخ بیکاری، تولید ناخالص داخلی (GDP)^۲، و نرخ‌های بهره در اقتصاد کلان مورد بحث قرار می‌گیرد. همه پارامترهای معرفی شده دارای عدم قطعیت بوده و می‌بایست در مطالعات اقتصادی سیستم‌های انرژی به درستی در نظر گرفته شوند.

مطالعات سیستم‌های انرژی شامل محدوده وسیعی از موضوعات در مقیاس زمانی کوتاه‌مدت (تصمیم‌گیری در حوزه بهره‌برداری زمان واقعی یا آنلاین، ساعتی، روزانه و هفتگی) تا بلندمدت (به عنوان مثال برنامه‌ریزی و سیاست‌گذاری) است. زنجیره تصمیم‌گیری در حوزه مطالعات سیستم‌های انرژی با پارامترهای ورودی تغذیه شده و برخی از پارامترهای ورودی نیز دارای عدم قطعیت هستند. در مطالعات فنی و اقتصادی سیستم‌های انرژی پارامترهایی نظیر قیمت برق، میزان بارهای الکتریکی، حرارتی، برودتی و آب شرب، تابش خورشید و سرعت باد معمولاً دارای عدم قطعیت هستند. با توجه به سیاست‌گذاری‌های کلان در زمینه سرمایه‌گذاری و توسعه سهم منابع انرژی تجدیدپذیر در سبد انرژی کشور به منظور تأمین پایدار انرژی مصرفی در بخش‌های مختلف خانگی، صنعتی، تجاری و کشاورزی با کمترین میزان آلاینده‌گی و بیشترین صرفه‌جویی اقتصادی، ضروریست نایقینی تولیدات منابع انرژی تجدیدپذیری چون خورشیدی و بادی مدنظر قرار گیرد. تاکنون مطالعات ارزشمندی در زمینه مدلسازی رفتار منابع انرژی تجدیدپذیر در مطالعات سیستم‌های قدرت و انرژی پیشنهاد شده است که می‌توان به چهار دسته عمده طبقه‌بندی نمود:

- روش‌های احتمالاتی مونت کارلو و تخمین نقطه‌ای
- تئوری تصمیم‌گیری مبتنی بر شکاف اطلاعاتی (IGDT)^۳
- بهینه‌سازی مقاوم
- پیش‌بینی

نخستین روش احتمالاتی توسط Dantzig در سال ۱۹۵۵ ارائه شده و فرض شده بود که پارامترهای ورودی مدل، متغیرهای رندم با توابع چگالی احتمال معین هستند [۲]. در روش احتمالاتی، یک تابع چندمتغیره به صورت $\gamma = f(Z)$ وجود دارد. Z یک بردار به فرم مشخص $Z = [Z_1, Z_2, \dots, Z_m]$ بوده و Z_1 تا Z_m پارامترهای تصادفی با تابع چگالی احتمال (PDF)^۴ معلوم هستند. سعی بر آنست تابع چگالی احتمال γ تعیین گردد. تابع f مدل سیستم را توصیف می‌کند (به عنوان مثال، معادلات پخش بار الکتریکی در شبکه‌های توزیع نیروی برق)، Z یک بردار شامل پارامترهای ورودی دارای عدم قطعیت (به عنوان مثال، توان تولیدی منابع انرژی تجدیدپذیر و بارهای الکتریکی)، و γ متغیر خروجی (به عنوان مثال، کل تلفات توان اکتیو سیستم، هزینه بهره‌برداری کل) است. شبیه‌سازی مونت کارلو و الگوریتم تخمین نقطه‌ای دو روش احتمالاتی متداول برای مدلسازی عدم قطعیت منابع انرژی بادی و خورشیدی هستند [۳، ۴]. در روش MCS، فرض می‌شود که Z_m پارامترهای دارای عدم قطعیت باشند. با استفاده از تابع چگالی احتمال آن، یک نمونه Z_i^e برای هر پارامتر ورودی Z_m تولید می‌شود. مقدار γ^e به عنوان متغیر خروجی با رابطه $\gamma^e = f(Z^e)$ محاسبه می‌شود که در آن $Z^e = [Z_1^e, Z_2^e, \dots, Z_m^e]$ الگوریتم برای تعداد دفعات N_{MC} تکرار می‌شود. در نهایت، خروجی‌ها با استفاده از معیارهای آماری، هیستوگرام‌ها، بازه‌های اطمینان و احتمال قرارگیری متغیرهای نایقین در یک بازه مشخص، تحلیل می‌شوند. روش تخمین نقطه‌ای بر اساس مفهوم گشتاورهای پارامترهای ورودی نایقین عمل می‌کند. در روش 2-PEM دو مقدار مشخص برای هر متغیر دارای عدم قطعیت محاسبه می‌شود. بسته به تقارن یا عدم تقارن تابع چگالی احتمال متغیر دارای عدم قطعیت، این دو نقطه ممکن است به صورت متقارن یا نامتقارن حول میانگین یک متغیر باشند.





لازم به ذکر است که در این روش تعداد نقاط نمونه انتخابی با افزایش تعداد متغیرهای غیرقطعی افزایش می‌یابد. با این وجود تعداد سناریوهای مورد بررسی در روش تخمین نقطه‌ای کمتر از روش مونت کارلو بوده و دقت روش مونت کارلو بیشتر از روش تخمین نقطه‌ای می‌باشد. در مطالعات احتمالاتی سیستم‌های انرژی یافتن تابع توزیع متغیرهای خروجی مطلوبست. بنابراین لازمست داده‌های آماری مربوط به متغیرهای خروجی (به عنوان مثال میانگین^۶ و انحراف معیار^۷) محاسبه گردد [۵،۶]. بر اساس مرجع [۷]، روش تخمین $k \times m + 1$ نقطه‌ای هانگ برای تخمین $k \times m + 1$ نقطه به کار می‌رود. فرض می‌شود که تابع F ربط‌دهنده متغیرهای ورودی (احتمالاتی p و مشخص یا غیراحتمالاتی C) و متغیرهای خروجی باشد. تابع $Z = F(p_1, p_2, \dots, p_m, C)$ بستگی به همه متغیرهای ورودی (m) دارد. در روش تخمین نقطه‌ای هانگ، برای هر متغیر تصادفی p_i تابع F باید $k \times m + 1$ مرتبه محاسبه شود که k تعداد نقاط بوده و $m, l=1, 2, \dots, m$ نقطه مربوط به m متغیر تصادفی بر اساس اطلاعات آماری و تابع چگالی احتمال آن متغیر محاسبه می‌شوند. الگوریتم IGDT و بهینه‌سازی مقاوم برای مدل‌سازی عدم قطعیت‌هایی مناسب هستند که بعلت نبود اطلاعات کافی نمی‌توانند با توابع عضویت فازی و توابع چگالی احتمال توصیف شوند. IGDT برای تصمیم‌گیری مقاوم در برابر عدم قطعیت شدید پارامترهای ورودی به کار می‌رود. مقاومت به صورت برآورده شدن یک قید از پیش تعیین شده تعریف می‌شود. برای درک بهتر موضوع، فرض می‌شود که تابع f مدل سیستم انرژی را توصیف می‌کند (به عنوان مثال هزینه تأمین انرژی از منابع مختلف)، X بردار پارامترهای ورودی نایقین (به عنوان مثال قیمت برق ساعت به ساعت) و Y متغیر خروجی (به عنوان نمونه، قراردادهای تولید برای تأمین‌کنندگان انرژی) است. d به مجموعه متغیرهای تصمیم‌گیری (به عنوان مثال میزان انرژی خریداری شده از منابع انرژی مختلف نظیر واحدهای تولید پراکنده (DG))^۹، بازارهای برق، و قراردادهای دوجانبه^{۱۰} اشاره دارد. مقاوم بودن در IGDT و بهینه‌سازی مقاوم به معنی آنست که هزینه کل یا تابع f در مقایسه با مقدار آستانه l_c همیشه کمتر باشد و بیشترین فاصله پارامتر نایقین از مقدار پیش‌بینی شده خود نیز محاسبه گردد.

نکته قابل توجه آنست که روش‌های مرور شده قابلیت مدل‌سازی توان تولیدی منابع انرژی تجدیدپذیری چون توربین‌های بادی و منابع تولید خورشیدی را در بازه‌های زمانی یک ساعت برای افق زمانی روزانه، هفتگی، ماهانه، و سالانه جهت انجام مطالعات برنامه‌ریزی بلندمدت و بهره‌برداری کوتاه‌مدت دارند. بر اساس تحقیقات صورت گرفته در مراجعی چون [۸]، نوسانات تابش خورشید در بازه‌های زمانی کوتاه‌تر نظیر یک تا چند دقیقه بالاست. به طور مشابه بر اساس آمار گزارش شده در [۹]، تغییرات سرعت باد در بازه‌های کمتر از یک ساعت (به عنوان مثال ۱۰ دقیقه) نیز زیاد بوده و از آنجا که توان تولیدی توربین بادی به سرعت باد بستگی دارد، تغییرات سرعت باد در بازه‌های زمانی کمتر از یک ساعت نیز سبب تغییر شدید توان تولیدی توربین‌های بادی خواهد شد. در برخی موارد نوسانات تابش خورشید و سرعت باد در بازه زمانی کمتر از یک ساعت (یک تا چند دقیقه) نیز چشمگیر بوده و نیازمند مدل‌سازی در مطالعات سیستم‌های انرژی خواهد بود. یکی از روش‌هایی که می‌تواند توان تولیدی منابع DG خورشیدی و بادی را با دقت خوبی محاسبه کند، روش‌های پیش‌بینی به کمک شبکه‌های عصبی است. در [۱۰]، تابش خورشید تحت شرایط مختلف آسمان نظیر آسمان صاف، مه‌آلود، نسبتاً ابری و پوشیده از ابر^{۱۱} پیش‌بینی شده و با مقادیر واقعی اندازه‌گیری شده آن مقایسه شده است. نتایج تحقیقات نشان داد که دقت روش‌های پیش‌بینی در تخمین میزان تابش خورشید بالا بوده و برای تعیین پارامتر نایقین در بازه‌های زمانی بسیار کوتاه‌مدت (یک دقیقه) نیز کاربرد دارد. در [۱۱]، شبکه عصبی مبتنی بر توابع گاوسی برای پیش‌بینی توان یک مزرعه بادی واقع در تایوان در طول یک روز نمونه و به صورت ساعت به ساعت مورد استفاده بوده است. یکی از نقاط ضعف این روش آنست که شرایط آب و هوایی به عنوان داده‌های ورودی در الگوریتم کاربرد نداشته است. در [۱۲]، یک روش ترکیبی مبتنی بر برنامه‌نویسی خطی آمیخته با اعداد صحیح و تجزیه مویک برای تخمین توان تولیدی یک مزرعه بادی در جنوب ایتالیا با استفاده از داده‌های هواشناسی نظیر سرعت باد، دما و رطوبت هوا به کار رفته است. در [۱۳]، الگوریتم شبکه دارای حافظه کوتاه‌مدت و مدل گاوسی برای پیش‌بینی توان تولیدی یک مزرعه بادی دارای ۱۲۳ توربین بادی واقع در شمال چین معرفی شده است. در [۱۴]، فیلتر کالمن برای تخمین توان مزرعه بادی واقع در شرق چین با استفاده از سرعت باد، جهت باد، دما، فشار، رطوبت و توان گزارش شده توسط SCADA به عنوان ابزاری دقیق و کاربردی ارزیابی شده است. در [۱۵] نیز یک روش ترکیبی از بهینه‌سازی ازدحام ذرات و مدل فازی برای پیش‌بینی توان مزرعه بادی واقع در ایتالیای به کمک داده‌های دمای هوا و سرعت باد پیشنهاد شده است.

بر اساس موارد مطرح شده، پیش‌بینی دقیق توان تولیدی مزارع بادی به کمک شبکه‌های عصبی مصنوعی (ANNs)^{۱۲} نیز می‌تواند در برنامه‌ریزی و بهره‌برداری بهینه سیستم‌های قدرت و انرژی موثر باشد و همچنین سبب بهبود پایداری و قابلیت اطمینان سیستم گردد. نوآوری‌های کلیدی مقاله حاضر در مقایسه با تحقیقات انجام شده به شرح ذیل بیان می‌گردد:



- یک الگوریتم پیش‌بینی‌کننده توان تولیدی مزارع بادی به کمک شبکه‌های عصبی مصنوعی و کدنویسی تحت زبان برنامه‌نویسی Python پیشنهاد شده است.
 - در الگوریتم پیشنهادی، سرعت و جهت باد، دما و فشار هوا به عنوان پارامترهای ورودی تاثیرگذار بر توان تولیدی مزرعه بادی در نظر گرفته می‌شوند. جذر میانگین مربعات خطا (RMSE)^{۱۳} به عنوان تابع هدف مسئله بهینه‌سازی کمینه می‌شود.
 - به منظور اثبات سرعت و دقت بالای الگوریتم پیشنهادی در مقایسه با روش‌های موجود، مطالعه موردی بر روی یک مزرعه بادی واقع در منجیل انجام شده و نتایج پیش‌بینی با مقادیر واقعی نیز مقایسه شده است. همچنین تابع هدف، درصد خطای نسبی، وضوح زمانی مقادیر پیش‌بینی شده، زمان اجرای محاسبات توسط الگوریتم پیشنهادی نیز ارائه می‌گردد.
- در بخش دوم، جزئیات بیشتر در مورد الگوریتم پیشنهادی ارائه می‌گردد. بخش سوم به مطالعه موردی بر روی یک مزرعه بادی واقعی و تحلیل نتایج می‌پردازد. در بخش چهارم نیز نتایج کلیدی به دست آمده و مطالعات آینده بیان شده است.

۲- الگوریتم پیشنهادی

بر اساس مرجع [۱۶]، توان تولیدی یک توربین بادی به سرعت باد، توان نامی توربین، سرعت‌های cut-in و cut-out و سرعت نامی بستگی دارد.

$$P_w = \begin{cases} 0 & V_w \leq V_{in} \text{ or } V_w \geq V_{out} \\ P_r \frac{V_w - V_{in}}{V_r - V_{in}} & V_{in} < V_w < V_r \\ P_r & V_r \leq V_w < V_{out} \end{cases} \quad (1)$$

که در رابطه (۱)، داریم:

P_w : توان تولیدی توربین بادی بر حسب کیلووات

P_r : توان نامی توربین بر حسب کیلووات

V_w : سرعت باد بر حسب متر بر ثانیه

V_{in} و V_{out} : سرعت‌های cut-in و cut-out به عنوان حداقل و حداکثر سرعت مجاز برای تولید توان، بر حسب متر بر ثانیه

V_r : سرعت نامی بر حسب متر بر ثانیه

طبق رابطه (۲)، باد نتیجه اختلاف فشار هوا در یک سطح افقی بوده و معمولاً هوا از ناحیه با فشار بالاتر به ناحیه با فشار کمتر جریان می‌یابد. هر چه اختلاف (یا گرادیان) فشار هوا بین دو نقطه بیشتر باشد، سرعت جریان هوا (یا سرعت باد) بیشتر خواهد بود [۱۷].

$$V_w^x = \frac{1}{\rho_a \times f_c} \cdot \frac{\partial P_a}{\partial x}, \quad V_w^y = \frac{1}{\rho_a \times f_c} \cdot \frac{\partial P_a}{\partial y} \quad (2)$$

V_w^x و V_w^y : مولفه‌های افقی و عمودی سرعت باد بر حسب متر بر ثانیه

ρ_a : چگالی هوا بر حسب کیلوگرم بر مترمکعب

$\frac{\partial P_a}{\partial y}$ و $\frac{\partial P_a}{\partial x}$: گرادیان فشار هوا در راستای افقی و عمودی (بین دو نقطه) بر حسب کیلوپاسکال بر کیلومتر

f_c : ضریب Coriolis (برابری با ۱/۴۵۸۴ بر حسب یک بر ثانیه)

با توجه به رابطه (۳)، فشار هوا با تغییر دما متغیر خواهد بود و لازم به ذکر است که پارامتر R برابرست با نسبت ثابت جهانی گازها $(R_u = 8.315 \frac{kJ}{kmol.K})$ به وزن مولکولی هوا (MW_a بر حسب کیلوگرم بر کیلومول) که در رابطه (۴) بیان شده است [۱۸].

$$P = \rho_a RT \quad (3)$$

$$R = \frac{R_u}{MW_a} \quad (4)$$

بر اساس روابط (۲) و (۳)، با تابش غیریکسان نور خورشید به سطح زمین و گرم شدن غیریکنواخت نقاط مختلف، سرعت باد به دمای هوا در دو نقطه نیز بستگی داشته و در نتیجه می‌توان بردار سرعت باد، دما و فشار هوا را به عنوان داده‌های ورودی برای آموزش الگوریتم یادگیری در نظر گرفت.

در این مقاله، جذر میانگین مربعات خطای تخمین به عنوان تابع هدف مسئله بهینه‌سازی در نظر گرفته شده است که از رابطه (۵) محاسبه می‌شود:



$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_w - \hat{P}_w)^2} \quad (5)$$

P_w و \hat{P}_w به ترتیب به مقادیر واقعی و تخمینی توان تولیدی مزرعه بادی در بازه زمانی i ام اشاره دارد. فلوچارت الگوریتم پیشنهادی در شکل (۱) نشان داده شده است. در الگوریتم پیشنهادی، داده‌های ورودی به شبکه عصبی بر مبنای رابطه (۶) نرمالیزه می‌شوند:

$$x_i^{norm} = \frac{x_i - x_i^{min}}{x_i^{max} - x_i^{min}} \quad (6)$$

x_i^{norm} : مقدار نرمالیزه داده ورودی مربوط به بازه زمانی i ام

x_i : داده ورودی مربوط به بازه زمانی i ام

x_i^{max} و x_i^{min} : مقادیر مینیمم و ماکزیمم داده ورودی مربوط به بازه زمانی i ام



شکل (۱): فلوچارت الگوریتم پیش‌بینی توان تولیدی مزرعه بادی



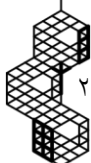
همانطور که در شکل (۱) مشاهده می‌شود، سرعت و جهت باد و همچنین دما و فشار هوا به عنوان داده‌های ورودی در نظر گرفته شده و با استفاده از رابطه (۶) نرمالیزه می‌شوند. نرمالیزه کردن داده‌ها برای تبدیل مقادیر داده‌های ورودی به یک مقیاس مشترک و افزایش انسجام انواع ورودی استفاده می‌شود. در این مقاله، از بسته ابزاری Python Keras برای شبکه عصبی مصنوعی استفاده شده است. داده‌های ورودی برای ۳۶۵ روز سال در نظر گرفته شده است. همچنین برای هر روز ۲۴ نقطه داده که هرکدام مربوط به شرایط آب و هوایی در یک بازه زمانی یک ساعته هستند، استفاده شده است. داده‌های ورودی مربوط به ۳۵۸ روز (۸۵۹۲ نقطه داده) به عنوان مجموعه داده آموزشی انتخاب می‌شود. از این رو، ۱۶۸ نقطه داده مربوط به ۷ روز به عنوان مجموعه داده تست انتخاب می‌شود. توان تولیدی مزرعه بادی مربوط به داده‌های تست پیش‌بینی می‌شود و سپس به منظور به حداقل رساندن RMSE با مقادیر واقعی مقایسه می‌شود.

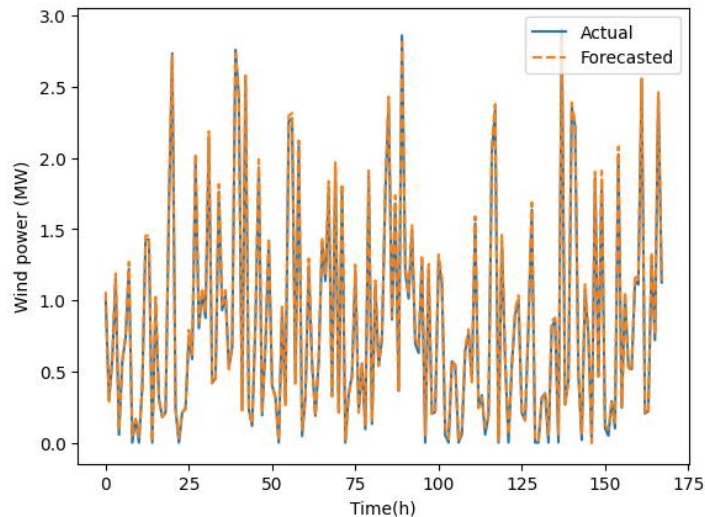
در این مقاله از Relu به عنوان یک تابع تکه‌ای خطی در شبکه عصبی مصنوعی استفاده شده است. مقدار Batch یکی دیگر از پارامترهای ANN است که تعداد نمونه‌های آموزشی مورد استفاده در هر تکرار را مشخص می‌کند. یک لایه حذف^{۱۴} به طور تصادفی مجموعه‌ای از نوروں‌ها را نادیده می‌گیرد تا از برازش بیش از حد^{۱۵} ANN جلوگیری کند. در حالی که، یک لایه متراکم^{۱۶} به طور کامل در یک ANN متصل است. در این مقاله، بهینه‌ساز «Adam» برای به حداقل رساندن RMSE انتخاب شده است. جزئیات بیشتر روش بهینه‌سازی «Adam» را می‌توان در [۱۹] یافت.

در روش پیش‌بینی مبتنی بر شبکه‌های عصبی مصنوعی، ابتدا داده‌های ورودی فراخوانی می‌شوند. در مسئله پیش‌بینی توان تولیدی مزرعه بادی، داده‌های هواشناسی (دما و فشار هوا) و سرعت و جهت باد به عنوان اطلاعات ورودی به الگوریتم معرفی می‌شوند. سپس طبق رابطه (۶) و بر اساس مینیمم و ماکزیمم مقدار هر پارامتر ورودی، می‌توان داده‌های ورودی را نرمالیزه کرد و درصدی از آنها را به عنوان داده‌های آموزش انتخاب نمود. باقیمانده داده‌ها به عنوان داده‌های تست به الگوریتم معرفی شده و معیار ارزیابی دقت پیش‌بینی‌ها قرار می‌گیرند. در گام بعدی، مشخصات شبکه عصبی مصنوعی تعیین می‌شود که شامل نوع تابع فعال‌ساز، تابع بهینه‌ساز، نرخ یادگیری شبکه عصبی، سایز هر دسته یا سایز Batch، سایز Epoch، تراکم و حذف‌شوندگی نوروں‌های عصبی در لایه‌های پنهان شبکه می‌باشد. بسته به تعداد Epochها الگوریتم بر اساس داده‌های آموزش و تست مقدار توان تولیدی مزرعه بادی را تخمین زده و جذر میانگین مربعات خطای پیش‌بینی‌ها محاسبه می‌گردد و کمترین آن به عنوان بهترین جواب گزارش خواهد شد.

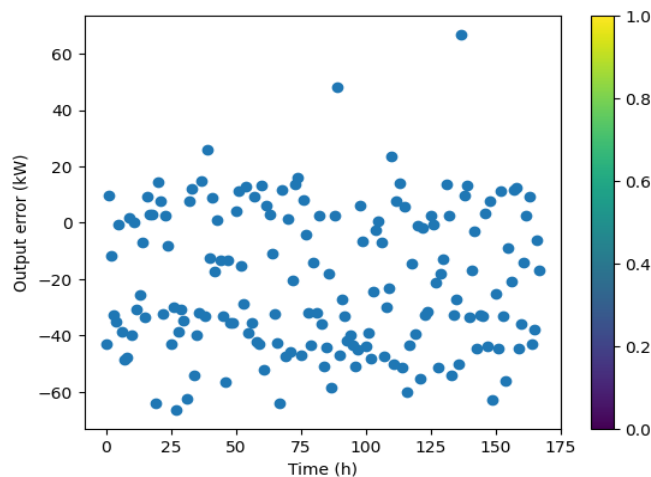
۳- مطالعه موردی و تحلیل نتایج

برای ارزیابی دقت و سرعت الگوریتم پیشنهادی در پیش‌بینی توان تولیدی مزرعه بادی، یک مطالعه موردی بر روی مزرعه بادی واقع در منجیل انجام شده است. داده‌های دما و فشار هوا و همچنین سرعت و جهت باد در [۲۰] گزارش شده است. همانطور که در بخش دوم ذکر شد، داده‌های ورودی الگوریتم پیش‌بینی پیشنهادی شامل دما و فشار هوا و سرعت و جهت باد در طول ۳۵۸ روز سال است که در [۲۱] گزارش شده است. علاوه بر این، داده‌های آموزش شامل داده‌های گزارش شده برای ۳۵۸ روز (۸۵۹۲ بازه زمانی با مدت زمان ۱ ساعت) است. از این رو، ۱۶۸ داده به عنوان داده‌های تست استفاده می‌شود. الگوریتم پیش‌بینی پیشنهادی که در شکل (۱) نشان داده شده است، برای پیش‌بینی توان تولیدی مزرعه بادی در یک هفته اجرا می‌شود. به عبارت دیگر، ۱۶۸ نقطه داده تست که مربوط به ۷ روز است، برای مقایسه مقادیر پیش‌بینی شده با نمونه‌های مشاهده شده یا واقعی استفاده می‌شود. شکل (۲) مقادیر واقعی و پیش‌بینی شده توان تولیدی مزرعه بادی را در طول یک هفته نشان می‌دهد. لازم به ذکر است که هر نقطه داده مربوط به بازه زمانی ۱ ساعت بوده که به کمک الگوریتم پیشنهادی پیش‌بینی شده است. خطای پیش‌بینی استراتژی پیشنهادی در شکل (۳) نشان داده شده است.





شکل (۲): مقادیر واقعی و پیش‌بینی شده توان تولیدی مزرعه بادی در طول یک هفته



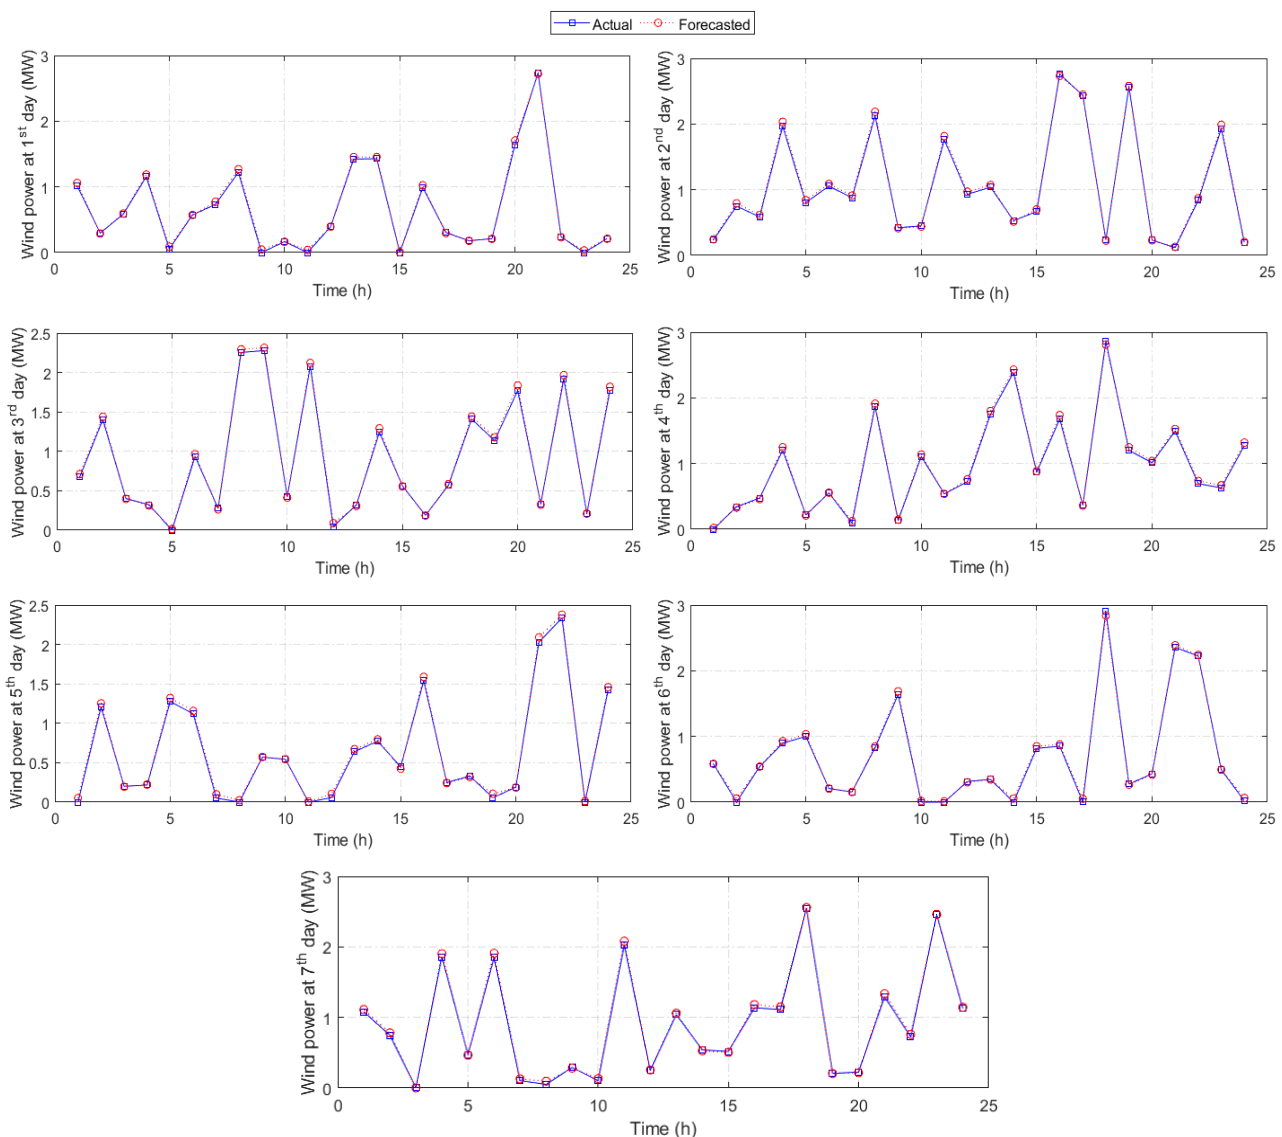
شکل (۳): خطای پیش‌بینی الگوریتم پیشنهادی

شکل‌های (۲) و (۳) دقت روش پیشنهادی را در پیش‌بینی توان تولیدی مزرعه بادی نشان می‌دهد. جذر میانگین مربعات خطای پیش‌بینی نقاط بدست آمده برابر با 0.10817 است. علاوه بر این، زمان محاسبه مسئله بهینه‌سازی در یک لپ‌تاپ Lenovo با CPU 2.10 گیگاهرتز، ۴ گیگابایت RAM، کمتر از ۱ دقیقه است. شکل (۳) ثابت می‌کند که حداکثر خطای پیش‌بینی برابر با ۶۶.۹ وات است که به ساعت ۱۳۸ ام یا نقطه داده ۱۳۸ ام (ساعت ۱۸ از روز ششم) اشاره دارد. بنابراین مقادیر واقعی و پیش‌بینی شده توان مزرعه بادی در این بازه زمانی به ترتیب برابر با ۲۰۶۴ و ۲۰۸۳۹۵ مگاوات بوده است. از این رو، حداکثر درصد خطای روش پیش‌بینی پیشنهادی ۲.۳ درصد است. این بدان معنی است که عدم قطعیت‌های مرتبط با توان تولیدی مزرعه بادی را می‌توان با استفاده از این رویکرد پیش‌بینی کوتاه‌مدت کاهش داد. لازم به ذکر است که پارامترهای شبکه عصبی مصنوعی بر دقت نمونه‌های پیش‌بینی شده به طور قابل توجهی تأثیر می‌گذارد. در این مقاله، از یک الگوریتم پیش‌بینی مبتنی بر شبکه عصبی مصنوعی برای پیش‌بینی توان تولیدی مزرعه بادی استفاده شده است. با توجه به نوسانات سرعت و جهت باد، دما و فشار هوا در روزها و ساعات مختلف، خروجی مزرعه بادی باید در بازه‌های زمانی کوتاه‌مدت ساعت به ساعت پیش‌بینی شود. علاوه بر این، برای ارزیابی دقت الگوریتم پیشنهادی و آشکارسازی اثربخشی عملکرد آن، مقادیر واقعی توان تولید شده توسط مزرعه بادی با مقادیر پیش‌بینی شده مقایسه می‌شوند. همانطور که نتایج عددی شکل‌های (۲) و (۳) نشان می‌دهد، مقدار پیش‌بینی شده توان مزرعه بادی بسیار شبیه به مقادیر واقعی بوده است. علاوه بر این، حداکثر مقدار خطای نسبی پیش‌بینی برابر با ۲.۳ درصد است که دقت بالای روش ارائه شده را ثابت می‌کند.

به منظور اثبات دقت الگوریتم پیشنهادی، مقادیر پیش‌بینی شده مربوط به توان تولیدی مزرعه بادی در هر روز به صورت ساعت به ساعت با مقادیر واقعی آن مقایسه شده است (شکل ۴). لازم به ذکر است که بیشترین میزان اختلاف مقادیر پیش‌بینی شده با نمونه‌های واقعی برای روزهای هفته در جدول (۱) گزارش شده است. بنابراین بیشترین درصد خطای نسبی پیش‌بینی مربوط به ۶۶.۹ وات اختلاف بین مقادیر واقعی و خروجی الگوریتم پیشنهادی بوده که ۲.۳ درصد به دست آمده است.

جدول (۱): خطای نسبی مقادیر پیش‌بینی شده و واقعی توان مزرعه بادی

روز	اول	دوم	سوم	چهارم	پنجم	ششم	هفتم
ماکزیمم خطا (وات)	۶۴.۰۷	۶۶.۴۵	۶۴.۰۶	۵۸.۶۴	۶۰.۰۳	۶۶.۹	۶۳.۰۴



شکل (۴): مقایسه مقادیر پیش‌بینی شده توان تولیدی مزرعه بادی با مقادیر واقعی به صورت ساعت به ساعت در طول روز

در جدول (۲)، ورودی‌ها، خروجی‌ها، رزولوشن زمانی پیش‌بینی‌ها، دوره مطالعه الگوریتم پیشنهادی با سایر روش‌های موجود مقایسه شده است. ملاحظه می‌شود که تاکنون روش‌های مختلفی برای پیش‌بینی کوتاه‌مدت توان تولیدی توربین‌های بادی پیشنهاد شده است. تقریباً در تمام روش‌ها، سرعت و جهت باد و همچنین دما و فشار هوا به عنوان ورودی‌های تأثیرگذار بر توان تولیدی مزرعه بادی به الگوریتم پیشنهادی داده شده است. همچنین مقادیر واقعی توان تولیدی توربین‌های بادی معیار ارزیابی خطای مقادیر پیش‌بینی شده انتخاب





شده است. با این وجود مزیت الگوریتم پیشنهادی به روش‌های موجود در زمان اجرای کمتر از یک دقیقه و دقت بالای مقادیر تخمینی در مقایسه با مقادیر واقعی است.

جدول (۲): مقایسه قابلیت الگوریتم پیشنهادی با روش‌های موجود

مرجع	الگوریتم	ورودی‌ها	خروجی‌ها	رزولوشن زمانی پیش‌بینی‌ها	دوره مطالعه
[۱۱]	Radial Basis Function Neural Network (RBFNN) Double Gaussian function (DGF)	داده‌های مربوط به توان یک مزرعه بادی در تایوان	توان توربین بادی	۱ ساعت	۲۴ ساعت
[۱۲]	Mixed linear programming Wavelet decomposition	سرعت باد، دما و رطوبت هوا	توان تولیدی یک مزرعه بادی در جنوب ایتالیا	۱ ساعت	۱۲ ماه
[۱۳]	Short-term memory network (LSTM) algorithm Gaussian mixture model (GMM)	سرعت باد	توان تولیدی یک مزرعه بادی دارای ۱۲۳ توربین بادی واقع در شمال چین	۱ ثانیه	۲۰۰ ثانیه
[۱۴]	Kalman Filter	سرعت باد، جهت باد، دما، فشار، رطوبت و توان گزارش شده توسط SCADA	یک مزرعه بادی در شرق چین	۶ ساعت	۱۲ ماه
[۱۵]	روش ترکیبی بهینه‌سازی ازدحام ذرات و فازی	سرعت باد و دما	یک مزرعه بادی در اتیوپی	۱ ساعت	۱۲ ماه
الگوریتم پیشنهادی	مبتنی بر شبکه عصبی مصنوعی	دمای و فشار هوا سرعت و جهت باد	توان تولیدی مزرعه بادی واقع در منجیل	۱ ساعت	یک هفته

۴- نتیجه‌گیری

در این مقاله، یک الگوریتم بهبودیافته مبتنی بر شبکه عصبی مصنوعی برای پیش‌بینی توان تولیدی مزرعه بادی با استفاده از کدنویسی تحت زبان برنامه‌نویسی Python ارائه و ارزیابی شد. سرعت باد، جهت باد، دما و فشار هوا در طول ۳۶۵ روز سال به عنوان داده‌های ورودی شبکه عصبی مصنوعی استفاده می‌شود. علاوه بر این، داده‌های سری زمانی شامل ۳۵۸ روز یا ۸۵۹۲ نقطه داده است که برای آموزش شبکه عصبی مصنوعی استفاده می‌شود. آخرین ۱۶۸ نمونه داده مربوط به هفته آخر بوده که برای تست الگوریتم پیشنهادی و برآورد خطای پیش‌بینی استفاده شده است. مشخص شد که مدل پیشنهادی در پیش‌بینی توان تولیدی مزرعه بادی در فواصل زمانی یک ساعته سریع و دقیق است. توان تولیدی مزرعه بادی در طول یک هفته به صورت ساعت به ساعت پیش‌بینی شده و ۱۶۸ نقطه داده بدست آمده که جذر میانگین مربعات خطای پیش‌بینی در سناریوی بهینه برابر با ۰/۰۱۰۸۱۷ است. زمان اجرای محاسبات الگوریتم پیش‌بینی کمتر از ۱ دقیقه بوده و حداکثر خطای نسبی در روش پیشنهادی ۲/۳ درصد است که نشان می‌دهد عدم قطعیت‌های مرتبط با توان تولیدی مزرعه بادی را می‌توان با استفاده از این رویکرد پیش‌بینی کوتاه‌مدت کاهش داد. به عنوان رویکرد آینده، عملکرد آن در بازه‌های زمانی کوتاه‌تر (۵ دقیقه‌ای) بررسی می‌شود. علاوه بر این، قابلیت و اثربخشی مدل پیشنهادی باید بر روی یک مزرعه خورشیدی مجهز به پنل‌های فتوولتیک با تغییرات شدید تابش خورشید تحت شرایط مختلف آسمان (ابری، نیمه‌ابری و صاف) در دوره‌های زمانی بسیار کوتاه‌مدت مانند ۱ دقیقه ارزیابی شود. همچنین ترکیبی از روش پیش‌بینی و بهینه‌سازی مقاوم به منظور کاهش تاثیر ناپیوستگی تولیدات منابع انرژی بادی و خورشیدی در یک ریزشبه بررسی خواهد شد. پیش‌بینی میزان مصرف برق، حرارت و برودت در یک ریزشبه مبتنی بر منابع انرژی بادی و خورشیدی نیز می‌تواند توسط الگوریتم شبکه عصبی مصنوعی انجام شود و سپس میزان تولیدات توان، حرارت و سرمایش سیستم‌های مولد بر اساس دیماند ریزشبه تعیین گردد. قیمت برق نیز در بازارهای برق به عنوان پارامتر دارای عدم قطعیت مطرح است که می‌تواند با استفاده از الگوریتم‌های ترکیبی مبتنی بر شبکه‌های عصبی مصنوعی و مدل‌های ریسک‌پذیر یا ریسک‌گریز نظیر IGDT و بهینه‌سازی مقاوم در محیط بازارهای برق پیش‌بینی و تحلیل شود.



- [1] A. Soroudi and T. Amraee, "Decision making under uncertainty in energy systems: State of the art," *Renewable and Sustainable Energy Reviews*, vol. 28, pp. 376-384, 2013, doi: 10.1016/j.rser.2013.08.039.
- [2] G. B. Dantzig, "Linear programming under uncertainty," *Management Science*, vol. 50, no. 12, supplement, pp. 1764-1769, 2004.
- [3] H. Khorsand and A. R. Seifi, "Probabilistic energy flow for multi-carrier energy systems," *Renewable and Sustainable Energy Reviews*, vol. 94, pp. 989-997, 2018, doi: 10.1016/j.rser.2018.07.008.
- [4] V. Singh, T. Moger, and D. Jena, "Uncertainty handling techniques in power systems: A critical review," *Electric Power Systems Research*, vol. 203, p. 107633, 2022, doi: 10.1016/j.epsr.2021.107633.
- [5] M. Ghahramani, M. Nazari-Heris, K. Zare, and B. Mohammadi-Ivatloo, "A two-point estimate approach for energy management of multi-carrier energy systems incorporating demand response programs," *Energy*, vol. 249, p. 123671, 2022, doi: 10.1016/j.energy.2022.123671.
- [6] M. Aien, M. G. Khajeh, M. Rashidinejad, and M. Fotuhi-Firuzabad, "Probabilistic power flow of correlated hybrid wind-photovoltaic power systems," *IET Renewable Power Generation*, vol. 8, no. 6, pp. 649-658, 2014, doi: 10.1049/iet-rpg.2013.0120.
- [7] S. A. Alavi, A. Ahmadian, and M. Aliakbar-Golkar, "Optimal probabilistic energy management in a typical micro-grid based on robust optimization and point estimate method," *Energy Conversion and Management*, vol. 95, pp. 314-325, 2015, doi: 10.1016/j.enconman.2015.02.042.
- [8] M. Järvelä, K. Lappalainen, and S. Valkealahti, "Characteristics of the cloud enhancement phenomenon and PV power plants," *Solar Energy*, vol. 196, pp. 137-145, 2020, doi: 10.1016/j.solener.2019.11.090.
- [9] Z. H. Hulio, W. Jiang, and S. Rehman, "Techno-Economic assessment of wind power potential of Hawke's Bay using Weibull parameter: A review," *Energy Strategy Reviews*, vol. 26, p. 100375, 2019, doi: 10.1016/j.esr.2019.100375.
- [10] S. Park, Y. Kim, N. J. Ferrier, S. M. Collis, R. Sankaran, and P. H. Beckman, "Prediction of solar irradiance and photovoltaic solar energy product based on cloud coverage estimation using machine learning methods," *Atmosphere*, vol. 12, no. 3, p. 395, 2021, doi: 10.3390/atmos12030395.
- [11] Y.-Y. Hong and C. L. P. P. Rioflorida, "A hybrid deep learning-based neural network for 24-h ahead wind power forecasting," *Applied Energy*, vol. 250, pp. 530-539, 2019, doi: 10.1016/j.apenergy.2019.05.044.
- [12] M. G. De Giorgi, A. Ficarella, and M. Tarantino, "Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods," *Energy*, vol. 36, no. 7, pp. 3968-3978, 2011, doi: 10.1016/j.energy.2011.05.006.
- [13] J. Zhang, J. Yan, D. Infield, Y. Liu, and F.-s. Lien, "Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and Gaussian mixture model," *Applied Energy*, vol. 241, pp. 229-244, 2019, doi: 10.1016/j.apenergy.2019.03.044.
- [14] P. Zhao, J. Wang, J. Xia, Y. Dai, Y. Sheng, and J. Yue, "Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China," *Renewable Energy*, vol. 43, pp. 234-241, 2012, doi: 10.1016/j.renene.2011.11.051.
- [15] D. M. Teferra, L. M. Ngoo, and G. N. Nyakoe, "Fuzzy-based prediction of solar PV and wind power generation for microgrid modeling using particle swarm optimization," *Heliyon*, vol. 9, no. 1, 2023, doi: 10.1016/j.heliyon.2023.e12802.
- [16] F. Jabari, H. Seyedi, S. Najafi Ravadanegh, and B. Mohammadi-Ivatloo, "Multi-objective optimal preventive islanding based on stochastic backward elimination strategy considering uncertainties of loads and wind farms," *International Transactions on Electrical Energy Systems*, vol. 27, no. 12, p. e2451, 2017, doi: <https://doi.org/10.1002/etep.2451>.
- [17] [https://geo.libretexts.org/Bookshelves/Meteorology_and_Climate_Science/Practical_Meteorology_\(Stull\)/10%3A_Atmospheric_Forces_and_Winds/10.04%3A_Section_5](https://geo.libretexts.org/Bookshelves/Meteorology_and_Climate_Science/Practical_Meteorology_(Stull)/10%3A_Atmospheric_Forces_and_Winds/10.04%3A_Section_5)
- [18] R. Turns Stephen, "An introduction to combustion," ed: McGraw-hill, 2000.
- [19] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.





- [20] <https://www.irimo.ir>
[21] S. J. Ghousechi, S. Manjili, A. Mardani, and M. K. Saraji, "An extended new approach for forecasting short-term wind power using modified fuzzy wavelet neural network: A case study in wind power plant," Energy, vol. 223, p. 120052, 2021, doi: 10.1016/j.energy.2021.120052.

زیر نویس‌ها

-
- ¹ Failure
² Aggregators
³ Gross Domestic Product (GDP)
⁴ Information Gap Decision Theory (IGDT)
⁵ Probability Density Function (PDF)
⁶ Expected value
⁷ Standard Deviation (STD)
⁸ Deterministic
⁹ Distributed Generation (DG)
¹⁰ Bilateral contracts
¹¹ Overcast
¹² Artificial Neural Networks (ANNs)
¹³ Root Mean Squared Error (RMSE)
¹⁴ Dropout layer
¹⁵ Overfitting
¹⁶ Dense layer

