

Introducing a Hybrid Meta-Heuristic Algorithm for Short-Term wind Speed Forecasting**Houman Gadari¹, PhD student, Hamidreza Akbari¹, Associate Professor, Somayeh Mousavi², Associate Professor, Zohreh Beheshtipour¹, Assistant Professor**¹ Department of Electrical Engineering, Yazd Branch, Islamic Azad University, Yazd, Iran

h.gadari@iauyazd.ac.ir

ha.akbari@iau.ac.ir

Zo.beheshtipour@iau.ac.ir

² Department of Industrial Engineering, Meybod University- Meybod -Iran

mousavi@meybod.ac.ir

Abstract:

Among renewable energies, the short-term forecast of wind energy helps significantly in determining the size of wind energy resources. Short-term forecast of wind speed can lead to more accurate planning of power systems. There are different approaches in determining the uncertainty of wind turbines, which are being optimized for more accuracy every day. In this study, the training of the group method of data modeling is done using the artificial jellyfish search optimization algorithm. This combined model does not have the complexity of similar methods, and in reaching the optimal answer, it converges earlier than other short-term prediction models and reaches the desired answer in less time. To evaluate the accuracy of the proposed method, the real data of Kerman city have been used to predict the short-term wind speed of this region. The results of this prediction have been compared with support vector machine and long short-term memory neural network. In the evaluation of the proposed model, the average percentage of absolute error has a value of 7.5807, which shows a better performance than the similar models evaluated. The mentioned error based on the average value of absolute error percentage has been reduced by 4.2904 compared to the optimal support vector machine model and 5.6193 compared to the optimal a Long short-term memory model respectively. Also, the evaluation of the model includes the criteria of the rating coefficient and the standard of the mean square error.

Keywords: Short-term forecasting of wind speed – GMDH method – JSO algorithm.**Received:** 28 May 2024**Revised:** 13 September 2024**Accepted:** 20 October 2024**Online Publication:** 22 December 2025**Corresponding Author:** Dr. Hamidreza Akbari

ارائه یک الگوریتم فراابتکاری ترکیبی به منظور پیش بینی کوتاه مدت سرعت باد

هومن گداری^۱، دانشجوی دکتری، حمیدرضا اکبری^۱، دانشیار، سمیه السادات موسوی^۲، دانشیار،
زهره بهشتی پور^۱، استادیار

۱- گروه مهندسی برق- واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران

h.gadari@iauyazd.ac.ir

ha.akbari@iau.ac.ir

Zo.beheshtipour@iau.ac.ir

۲- گروه مهندسی صنایع- دانشگاه میبد، میبد، ایران

mousavi@meybod.ac.ir

چکیده: تخمین نزدیک به واقعیت منابع انرژی تجدیدپذیر که دارای عدم قطعیت هستند امری دشوار و پیچیده است. در برنامه ریزی بهینه سیستم قدرت نیازمند روشی هستیم که خطای تخمینی داده‌ها را به حداقل برساند. در این میان پیش‌بینی کوتاه مدت سرعت باد می‌تواند منجر به برنامه ریزی دقیق‌تر سیستم قدرت بخصوص ریزشکه‌ها شود. رویکردهای متفاوتی در تعیین عدم قطعیت توان بادی وجود دارد که در جهت دقت بیشتر هر روزه درحال بهینه شدن هستند. در این مقاله آموزش روش گروهی مدل سازی داده‌ها با استفاده از الگوریتم بهینه ساز جستجوی عروس دریایی مصنوعی انجام می‌شود. این مدل ترکیبی، پیچیدگی روش‌های مشابه را ندارد و در رسیدن به پاسخ بهینه نسبت به دیگر مدل‌های پیش‌بینی کوتاه مدت زودتر همگرا شده و در زمان کمتری به پاسخ مطلوب می‌رسد. برای ارزیابی دقت مدل پیشنهادی، از داده‌های واقعی شهرستان کرمان برای پیش بینی کوتاه مدت سرعت باد این منطقه استفاده شده است. نتایج این پیش بینی با روش‌های مشابه GMDH-PSO، ماشین بردار پشتیبان و شبکه عصبی حافظه‌ی کوتاه مدت طولانی مقایسه گردیده است. در ارزیابی مدل پیشنهادی معیار میانگین درصد خطای مطلق بمقدار ۷,۵۸۰۷ را دارد که نسبت به مدل‌های مشابه مورد ارزیابی عملکرد بهتری را نشان می‌دهد. همچنین مدل پژوهش مقادیر ۰,۹۹۲۳ و ۰,۳۸۹۱ برای معیارهای ضریب تعیین امتیاز و مجذور میانگین مربعات خطا کسب کرده است.

کلمات کلیدی: روش گروهی مدل‌سازی داده‌ها، الگوریتم بهینه ساز جستجوی عروس دریایی مصنوعی، پیش بینی کوتاه مدت سرعت باد.

تاریخ ارسال مقاله: ۱۴۰۳/۳/۸

تاریخ بازنگری مقاله: ۱۴۰۳/۶/۲۳

تاریخ پذیرش مقاله: ۱۴۰۳/۷/۲۹

تاریخ انتشار: ۱۴۰۴/۱۰/۱

نام نویسنده‌ی مسئول: دکتر حمیدرضا اکبری

نشانی نویسنده‌ی مسئول: یزد- دانشگاه آزاد اسلامی واحد یزد- گروه مهندسی برق

۱- مقدمه

منابع تجدیدپذیر در شبکه قدرت، بخصوص ریز شبکه‌ها نقشی اساسی ایفا می‌کنند و نفوذ آنها در شبکه هر روز بیشتر و بیشتر می‌شود. در حال حاضر تمرکز زیادی در بخش تولید و استفاده از انرژی‌های پاک از سیاست‌های مهم بخش انرژی بشمار می‌رود. مدیریت انرژی و توسعه شبکه نیاز به برنامه‌ریزی‌های کوتاه مدت و بلند مدت دارد. این برنامه‌ریزی بدون پیش بینی تولید امکان پذیر نیست. برخلاف منابع انرژی فسیلی، نیروی باد و تابش خورشید به شدت تحت تأثیر شرایط جوی قرار دارند و پارامترهای توان خروجی ناشی از آنها تصادفی هستند [۱]. با توجه به تصادفی بودن این منابع، چالش‌های مهمی در زمینه امنیت شبکه برق ایجاد می‌شود [۲]. بنابراین پیش بینی دقیق توان بادی و توان خورشیدی و کمی سازی عدم قطعیت آنها یک بخش حیاتی در چندین فرآیند تصمیم گیری سیستم قدرت از جمله بحث اقتصادی و ذخیره سازی توان است [۳]. در مرجع [۴] پژوهشگر با ایده‌ای جدید به پیش‌بینی سرعت باد پرداخته است. آنها براساس خطاهای رخ داده به پیش‌بینی مقادیر آینده پرداخته است، به این صورت که خطای پیش‌بینی برای هر حالت وزنی داده می‌شود و الگوریتم بهینه‌سازی ازدحام ذرات برای جستجوی وزن بهینه خطاهای پیش‌بینی اعمال می‌شود. این مدل نیازمند این هست که مجموعه دیتای خطا در دسترس باشد. مرجع [۵] دید عمیقی رو از پیش‌بینی توان بادی با استفاده از شبکه‌های عصبی را ارائه می‌دهد. در این پژوهش با استفاده از مدل شبکه عصبی مکرر^۱ (RNN) مدلی را ارائه کرده است که با شاخص آماری میانگین خطای مطلق^۲ (MAE) آن را ارزیابی کرده است. این مدل در بحث آموزش شبکه عصبی نیاز به توسعه دارد. الگوریتم‌ها و روش‌های پیش‌بینی تک ابزار هر کدام ایراداتی دارند که می‌توان تا اندازه‌ای با ترکیب آنها با یکدیگر معایب را برطرف کرد که نتیجه بهتری در بحث پیش‌بینی حاصل شود.

لذا در روند بهینه‌سازی مدل‌ها به سمت ترکیب شبکه‌ها با الگوریتم‌های بهینه‌سازی حرکت کرده است. در مرجع [۶] برای رسیدن به پیش بینی دقیق‌تر همراه با زمان‌های محاسباتی کوتاه‌تر، آموزش شبکه عصبی رگرسیون عمومی^۳ (GRNN) را با استفاده از الگوریتم بهینه‌سازی گرگ خاکستری^۴ (GWO) انجام شده است. از معایب الگوریتم گرگ خاکستری می‌توان به دقت حل کم، توانایی جستجوی محلی بد و سرعت همگرایی کند اشاره کرد. در مرجع [۷] پژوهشگران نسخه جهش یافته دینامیکی الگوریتم بهینه‌سازی گرگ خاکستری را برای حل مسئله دو مزرعه بادی پیشنهاد داده‌اند. در این پژوهش برای مدل سازی توان مزرعه بادی از تابع توزیع احتمال ویبول استفاده شده است. در مرجع [۸] پژوهشگر با استفاده از تلفیق شبکه‌های عصبی مصنوعی با الگوریتم‌های وال و مورچگان تخمین دقیقی از نرخ نفوذ در یک فرایند حفاری داشته است و داده‌های خروجی را با شبکه عصبی مصنوعی ساده مقایسه کرده است. مدل پیشنهادی برای سه بخش آموزش، آزمایش و اعتبار سنجی عملکرد را نسبتاً خوبی را نشان داده است. در مرجع [۹] با استفاده از روش گروهی مدل سازی داده‌ها^۵ (GMDH) برای پیش بینی بارندگی اقلیم پارا در کشور تونس استفاده می‌شود. نتایج به‌دست آمده از مدل GMDH با مدل طراحی شده با شبکه عصبی مصنوعی چندلایه معمولی مقایسه شده است که نشان از برتری مدل گروهی مدل‌سازی داده‌ها نسبت به مدل ذکر شده است.

در مرجع [۱۰] نقش عدم قطعیت منابع بادی در بازار برق مطرح شده است و جهت پیش‌بینی سرعت باد از روش GMDH استفاده شده است و عملکرد آن با روش شبکه‌های عصبی مصنوعی مقایسه شده است. در هر دو مرجع ذکر شده، مقایسه قابل قبولی را ارائه نشده است و نیاز بود که GMDH با روش‌های برجسته‌تری مقایسه شود. با توجه به نیاز روش گروهی مدل سازی داده‌ها به آموزش صحیح، با الگوریتم‌های بهینه‌سازی ترکیب شد. در مرجع [۱۱] پیش بینی سرعت باد براساس یک مدل ترکیبی شبکه‌های عصبی انجام گرفته است. در این مدل شبکه عصبی با روش تجزیه حالت متغیر^۶ (VMD) و سیستم اختلال لورنز ترکیب شده است. در این روش VMD برای پردازش داده‌ها برای به دست آوردن چندین تابع حالت ذاتی^۷ (IMF) استفاده می‌شود سپس مدل شبکه عصبی براساس IMF های ایجاد می‌شود. پس از آن، با توجه به غیرخطی بودن سرعت باد، اغتشاش لورنز برای تعیین مدل نهایی اضافه می‌شود. مشکل این روش با توجه به اغتشاش لورنز در این است که به شرایط اولیه بسیار حساس است. در مرجع [۱۲] از GMDH برای پیش بینی سرعت باد استفاده شده است و از توابع موجک (Wavelet) برای غربالگری داده‌های ورودی به شبکه استفاده کرده است و در این مقاله پژوهشگران به بحث آموزش شبکه GMDH نپرداخته‌اند. در کنار مدل‌هایی براساس روش گروهی مدل‌سازی داده‌های دیگر هم در مبحث پیش‌بینی معرفی شدند. روش‌های ماشین بردار پشتیبان^۸ (SVM)، شبکه‌ی عصبی^۹ (LSTM) و شبکه عصبی بازگشتی^{۱۰} (RNN) به طور گسترده در مقالات متعدد در

زمینه پیش بینی و تخمین به کار گرفته می‌شوند و معیار ارزیابی مناسبی برای مقایسه با متدهای معرفی شده دیگر هستند. هر یک از روشهای ذکر شده معایبی دارند که با الگوریتم‌های بهینه سازی تا اندازه ای قابل جبران است. در مرجع [۱۳] بیان شده است که یک مدل بهبود یافته از شبکه عصبی بازگشتی را جهت پیش بینی کوتاه مدت و میان مدت توان بادی ارائه داده است که می‌تواند تاثیر داده‌های غیرعادی ناگهانی را بر نتایج پیش‌بینی سرعت باد کاهش دهد این مدل با الگوریتم تجزیه حالت متغیر بهینه شده است. در نتیجه دقت پیش‌بینی آنی نیروی باد را بهبود می‌یابد و بهبودی ۸۵ درصدی را نسبت مدل کلاسیک RNN در بر داشته است. در مرجع [۱۴] پیش بینی کوتاه مدت سرعت باد بر اساس شبکه عصبی LSTM بهینه‌سازی شده توسط الگوریتم آتش بازی^{۱۱} (FWA) انجام شده است. در این پژوهش تمرکز بر تغییر و وابستگی ناگهانی در زمان واقعی داده‌های سرعت باد قرار داده شده است. در این مدل بهینه‌سازی هاپیرپارامترها به گونه‌ای انجام می‌شود که مدل می‌تواند پارامترها را به صورت تطبیقی تنظیم کند. در مرجع [۱۵] پژوهشگران بر اساس داده‌های پیشین شامل سرعت باد و دما، مدل پیش بینی ARMA و مدل پیش بینی SVM توان بادی را ارائه داده‌اند و در مدل SVM از الگوریتم PSO برای بهینه‌سازی پارامترهای آن استفاده شده است. در این راستا PSO برای تعیین وزن های بهینه استفاده شده است. در مرجع [۱۶] با استفاده از شبکه عصبی بازگشتی و شبکه عصبی LSTM پیش بینی سرعت باد انجام داده است و LSTM برای آموزش شبکه عصبی بازگشتی بکار گرفته شده است. روش ذکر شده جهت پیش بین توان بادی منطقه هالفاکس کاناد در دو فصل بهار و تابستان بررسی شده است.

روشهای مبتنی بر یادگیری ماشین نیز نقش موثری در بحث پیش بینی دارند. پژوهشگران برزیلی در مرجع [۱۷] به پیش‌بینی سرعت باد با استفاده از الگوریتم‌های یادگیری ماشین پرداخته‌اند و نتایج را بایکدیگر مقایسه کرده‌اند. در این مطالعه، شبکه عصبی پیشخور چند لایه^{۱۲} (MLFFNN)، رگرسیون برداری پشتیبان^{۱۳} (SVR)، سیستم استنتاج فازی^{۱۴} (FIS)، سیستم استنتاج عصبی فازی تطبیقی^{۱۵} (ANFIS)، روش گروهی پردازش داده‌ها از نوع شبکه عصبی، ANFIS بهینه شده با الگوریتم بهینه سازی ازدحام ذرات (ANFIS-PSO) و ANFIS بهینه شده با الگوریتم ژنتیک (ANFIS-GA) برای پیش‌بینی سرعت باد بکار گرفته شده‌اند. براساس نتایج این تحقیق مدل GMDH برای تمام بازه‌های زمانی می‌تواند با موفقیت داده‌های سرعت باد سری زمانی را با دقت بالا پیش‌بینی کند. همچنین ترکیب مدل‌های ANFIS با الگوریتم های PSO و GA می‌تواند دقت پیش‌بینی مدل ANFIS را برای تمام بازه‌های زمانی افزایش داده است. مدل‌های ماشین بردار مبتنی بر کمینه کردن ساختاری ریسک هستند و مشکل آنها زمان بالا در حل مسائل برنامه‌ریزی درجه دوم است و ازطرفی دیگر ضروری است پارامترهای مدل رگرسیون بردار پشتیبان به صورت مناسب انتخاب شوند.

در مرجع [۱۸] پژوهشگران بیان می‌کنند که با توجه به نوسانات سرعت باد نمی‌تواند به طور مؤثر مورد بهره برداری قرار گیرد و نیاز به یک تخمین دقیق از توان بادی می‌باشد. در این پژوهش پیش بینی کوتاه مدت سرعت باد را با استفاده از الگوریتم ترکیبی Jaya-SVM انجام شده است. داده‌های ورودی با استفاده از الگوریتم بهینه‌سازی انتخاب می‌شوند و مدل بر روی ناحیه‌ای از چین مورد ارزیابی قرار گرفته است. از دیدگاه طبقه بندی افق زمانی پیش‌بینی، پیش‌بینی بار به سه دسته پیش‌بینی بار بلند مدت، میان مدت و کوتاه مدت تقسیم می‌شود. پیش‌بینی بار میان مدت و بلندمدت عمدتاً برای برنامه‌ریزی نیروگاه و برنامه‌ریزی مخازن استفاده می‌شود [۱۹]. در مرجع [۲۰] پیش‌بینی کوتاه مدت تابش خورشیدی و سرعت باد جهت تعیین میزان عدم قطعیت منابع تجدیدپذیر یک ریزشبه را در ایتالیا با استفاده از مدلی جدید ارائه داده است. این مدل از چند بخش تبدیل موجک، انتخاب ویژگی ترکیبی، روش گروهی شبکه عصبی مدیریت داده‌ها، و الگوریتم بهینه‌سازی مگس میوه چندهدفه^{۱۶} (HMFOA) تشکیل شده است و این روش عملکرد قابل قبولی را ارائه داده است. در مبحث پیش‌بینی بلند مدت هم روش‌های یادگیری عمیق نقش نقش برجسته‌ای دارند. اما در الگوریتم بهینه‌سازی مگس میوه در مرحله روزرسانی موقعیت مکانی از رندوم استفاده می‌کند که همین مقدار تصادفی باعث می‌شود که در بعضی شرایط جستجوی کورکورانه داشته باشد. مرجع [۲۱] پیش‌بینی توان تولیدی توربین‌های بادی یک مزرعه بادی در کشور سوئد را انجام داده است. مدل پیش بینی این پژوهش GMDH است که شبکه عصبی براساس روش فازی و الگوریتم بهینه‌سازی گرگ خاکستری بهینه شده است. در این ترکیب وزن قواعد فازی با استفاده از الگوریتم گرگ خاکستری بهینه گشته است. این مدل با برداشت داده‌ها ده دقیقه‌ای روزانه یکساله پیش‌بینی کوتاه مدت را انجام می‌دهد. مشکل این مدل در این است که هم زمان زیادی برای پردازش نیاز دارد و هم به داده‌های ورودی زیادی برای پیش‌بینی نیاز

دارد. همانطور که بررسی کارهای پیشین نشان می‌دهد توسعه روش‌های پیش‌بینی به سمت مدل‌هایی می‌رود که با داده قابل قبول، دقت بیشتر یا خطای کمتر را کسب کنند. لذا هدف اصلی از این مطالعه، ارائه روشی ترکیبی جهت پیش‌بینی براساس روش گروهی مدل‌سازی داده‌ها همراه با بهینه‌سازی وزن نرونها توسط الگوریتم بهینه ساز جستجوی عروس دریایی مصنوعی است. الگوریتم GMDH با قابلیت انعطاف قابل توجه و توانایی تبیین روابط غیرخطی و پیچیده سرعت باد، کارایی قابل توجهی نسبت به مدل‌های مطالعه شده دارد اما برای جلوگیری از واگرایی الگوریتم GMDH نیاز به آموزش صحیح شبکه است. الگوریتم بهینه سازی عروس دریایی مصنوعی علاوه بر سادگی با داشتن استراتژیهای جهش در رسیدن به پاسخ بهینه نسبت به دیگر الگوریتم‌های بهینه‌سازی زودتر همگرا شده و در زمان کمتری به پاسخ مطلوب می‌رسد. لذا در این راستا روش پیش‌بینی GMDH-JSO به عنوان یک تکنیک هوشمند ترکیبی کارآمد در جهت پیش‌بینی کوتاه مدت سرعت باد پیشنهاد شده است که برای پیش بینی میزان سرعت باد در منطقه شهرستان کرمان مورد استفاده قرار گرفته است. سنجش یافته‌های این مطالعه، با نتایج برآمده از ابزارهای پیش‌بینی مشابه در جهت نشان دادن دقت مدل پیشنهادی براساس معیارهای ارزیابی از اهداف این تحقیق است.

۲- الگوریتم بهینه ساز جستجوی عروس دریایی مصنوعی

الگوریتم بهینه‌ساز پیشنهادی جستجوی عروس دریایی^{۱۷} (JSO) یک الگوریتم فرا ابتکاری الهام گرفته از طبیعت است و بر اساس رفتار عروس دریایی در یافتن غذا در اقیانوس ایجاد شده است. الگوریتم بهینه‌سازی پیشنهادی مبتنی بر سه قانون است: الف) عروس دریایی یا جریان اقیانوس را دنبال می‌کند و یا در داخل دسته حرکت می‌کند و یک "مکانیسم کنترل زمان" بر جابجایی بین این دو نوع حرکت حاکم است.

ب) عروس دریایی در جستجوی غذا در اقیانوس حرکت می‌کند. آنها بیشتر جذب مکان‌هایی می‌شوند که در آن مقدار غذای در دسترس بیشتر است.

ج) مقدار غذای یافت شده بر اساس مکان و عملکرد هدف مربوطه آن تعیین می‌شود [۲۲].

۲-۱- جریان اقیانوس

در این الگوریتم جریان اقیانوس که حاوی مقادیر زیادی مواد مغذی است عروس دریایی را جذب می‌کند. جهت جریان اقیانوس جریان $(\overrightarrow{OCD})$ با میانگین گیری تمام بردارها از هر عروس دریایی در اقیانوس به عروس دریایی که در حال حاضر در بهترین مکان هست با استفاده از رابطه زیر تعیین می‌شود

$$\overrightarrow{OCD} = X^* - \gamma * rand(0,1) * \mu \quad (۱)$$

در این رابطه X^* آن عروس دریایی هست که بهترین موقعیت را در ازدحام دارد، μ محل متوسط همه عروس‌های دریایی می‌باشد. همچنین در معادله $\gamma(۲,۱)$ ضریب توزیع هست که مقداری بزرگتر از صفر دارد و براساس طول جریان اقیانوس $(\overrightarrow{OCD})$ است و بر اساس نتایج تحلیل حساسیت در آزمایش‌های عددی مقدار ۳ برای آن تعیین می‌شود [۲۳]. بر این اساس موقعیت هر عروس دریایی با رابطه زیر بدست می‌آید:

$$X_i(t+1) = X_i(t) - rand(0,1) * (X^* - \gamma * rand(0,1) * \mu) \quad (۲)$$

۲-۲- ازدحام عروس دریایی

دو نوع حرکت در دسته (ازدحام) برای عروس‌های دریایی در نظر گرفته شده است، در ابتدا حرکات غیرفعال یا نوع A و سپس حرکت فعال یا نوع B را دارند. حرکت نوع A در واقع، حرکت عروس دریایی در اطراف مکان‌های خود عروس دریایی و مکان‌های بروز شده متناظر با هر عروس دریایی است که با رابطه زیر بدست می‌آید:

$$X_i(t+1) = X_i(t) - \omega * rand(0,1) * (H_b - D_b) \quad (۳)$$

در معادله (۳) H_b بیان کننده حد بالا و D_b بیان کننده حد پایین فضاهاى جستجو هستند. همچنین در این رابطه ω ضریب حرکت است که مقداری بزرگتر از صفر دارد و وابسته میزان طول حرکت در مکان‌های اطراف عروس دریایی می‌باشد. بر اساس نتایج تحلیل حساسیت در آزمایشات عددی مقدار آن ۰٫۱ به دست آمده است.

برای بیان شبیه‌سازی حرکت نوع B، یک چتر دریایی را با اندیس (j) در نظر می‌گیریم که برای تعیین جهت حرکت علاوه بر حرکت تصادفی، یک بردار از عروس دریایی مورد نظر دیگر که با اندیس (i) مشخص است، استفاده می‌شود. زمانی که مقدار غذا در محل عروس دریایی انتخاب شده (j) بیشتر از مقدار غذایی است که در مکان چتر دریایی (i)، i به سمت j حرکت می‌کند. اگر مقدار غذای موجود برای چتر دریایی انتخابی (j) کمتر از (i) باشد عروس دریایی (i) در جهت بهتر شدن از آن دور می‌شود. در روابط زیر معادله (۶) جهت حرکت و معادله (۷) مکان به روز شده یک عروس دریایی را شبیه‌سازی می‌کند. این حرکت به عنوان یک بهره برداری موثر از فضای جستجوی محلی در نظر گرفته می‌شود.

$$\overline{Track} = X_i(t+1) - X_i \quad (4)$$

$$\overline{Track} = rand(0,1) * \overline{Side} \quad (5)$$

$$\overline{Side} = \begin{cases} X_j(t) - X_i(t) & \text{if } f(X_i) \geq f(X_j) \\ X_i(t) - X_j(t) & \text{if } f(X_i) < f(X_j) \end{cases} \quad (6)$$

در رابطه (۶) f تابع هدف مکان X است که به این ترتیب می‌توان رابطه زیر را نوشت:

$$X_i(t+1) = X_i + \overline{Track} \quad (7)$$

برای تعیین نوع حرکت در طول زمان از مکانیزم کنترل زمان استفاده می‌شود. این مکانیزم نه تنها حرکت نوع A و نوع B را در یک ازدحام کنترل می‌کند بلکه حرکات عروس دریایی به سمت جریان اقیانوسی را نیز کنترل می‌کند [۲۳].

۳-۲- مکانیزم کنترل زمان

مکانیزم کنترل زمانی برای تنظیم حرکت عروس دریایی در دنبال کردن جریان اقیانوس و یا حرکت در داخل ازدحام عروس‌های دریایی ایجاد شده است. مکانیزم کنترل زمان شامل یک تابع کنترل زمان $M(t)$ و یک مقدار ثابت M_0 است. تابع کنترل زمان یک مقدار تصادفی است که در طول زمان از ۰ تا ۱ در نوسان است. معادله (۹) تابع کنترل زمان را فرموله می‌کند. زمانی که ارزش تابع کنترل زمان بیشتر از مقدار ثابت M_0 است عروس دریایی جریان اقیانوس را دنبال می‌کند و زمانی که مقدار آن کمتر از مقدار ثابت M_0 باشد، در داخل ازدحام حرکت می‌کنند. مقدار M_0 روی ۰٫۵ تنظیم شده است که میانگین صفر و یک است.

$$M(t) = \left| \left(1 - \frac{t}{Max_{iter}} \right) * (2 * rand(0,1) - 1) \right| \quad (8)$$

۳-۲- شرایط مرزی

با توجه به گستردگی اقیانوسها و کروی بودن زمین، برای حرکت یک عروس دریایی کرانی را مشخص می‌کنیم که معادله (۹) آن را بیان می‌کند.

$$\begin{cases} X'_{i,d} = (X_{i,d} - H_{b,d}) + D_b(d) & \text{if } X_{i,d} > H_{b,d} \\ X'_{i,d} = (X_{i,d} - H_{b,d}) + H_b(d) & \text{if } X_{i,d} < D_{b,d} \end{cases} \quad (9)$$

در این معادله $X_{i,d}$ موقعیت عروس دریایی i ام در بعد d ام است و $X'_{i,d}$ موقعیت بروز شده پس از بررسی محدودیت‌های مرزی است. $H_{b,d}$ و $D_{b,d}$ به ترتیب کران بالا و پایین بعد d ام در فضاهاى جستجو هستند [۲۴].


۳- روش گروهی مدل سازی داده ها (GMDH)

شبکه عصبی نوع GMDH شبکه‌ای است که خود را سازمان دهی می‌کند و یک سویه است و مدل یک سیستم غیر خطی پیچیده را با یک شبکه عصبی چند لایه‌ای ارائه می‌دهد که این شبکه از چندین لایه و هر لایه از چندین نورون تشکیل یافته است.

مبنای ریاضی الگوریتم GMDH براساس تجزیه سری توابع ولتر^{۱۸} به چند جمله ای های دو متغیره درجه دوم مطابق با معادله زیر پایه ریزی شده است:

$$Z = a_0 + \sum_{i=1}^M a_i x_i + \sum_{i=1}^M \sum_{j=1}^M a_{ij} x_i x_j + \sum_{i=1}^M \sum_{j=1}^M \sum_{k=1}^M a_{ijk} x_i x_j x_k + \dots \quad (10)$$

بردار وزن ها $A(a_1, a_2, \dots, a_m)$ در این رابطه m متغیر ورودی $X = (x_1, x_2, \dots, x_m)$ را به یک متغیر خروجی Z مرتبط می کند که نمای این اتصال در شکل (۱) نمایش داده شده است:



شکل (۱): ساختار شبکه GMDH

Figure (1): GMDH network structure

الگوریتم GMDH که توسط ایواخنکو ارائه شد یک مدل خود تنظیم کننده می سازد که امکان پیش بینی و تشخیص را دارد و همانطور که بیان شد، مبنای الگوریتم عبارت است از فرایندی که منجر به یک چند جمله ای مرتبه بالاتر (۹) است [۲۵]. در واقع هدف این الگوریتم بدست آوردن ضرایب مجهول a_i است. برای محاسبه مقدار خروجی Z برای هر بردار ورودی بر اساس رابطه (۱۰)، میانگین مربعات خطا (معادله ۱۱) باید به حداقل برسد:

$$error = \sum_{i=1}^n (\hat{z}_i - z_i)^2 \quad (11)$$

بنابراین برای یافتن حداقل مقدار خطا از مشتق جزئی معادله (۱۱) استفاده می شود. با جایگزینی معادله (۱۰) به این مشتق جزئی، یک معادله ماتریسی $(Q_{a=Z})$ به دست می آید که ماتریس Q مطابق رابطه (۱۲) است:

$$Q = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}x_{Mq} & x_{Mp}^2 & x_{Mq}^2 \end{bmatrix} \quad (12)$$

در ماتریس فوق m مشاهدات در مجموعه آموزشی است. فرآیند حداقل مربعات از تحلیل رگرسیون چندگانه یک جواب معادله نرمال به شرح معادله (۱۳) ایجاد می کند:

$$a = (Q^T Q)^{-1} Q^T Z \quad (13)$$

که به این ترتیب بردار بهترین ضرایب معادله درجه دوم را محاسبه می شود. در این پژوهش با استفاده از الگوریتم ترکیبی GMDH-JSO این ضرایب مجهول به صورت بهینه تعیین می شوند.

۴- مدل پیش بینی ترکیبی پیشنهادی GMDH-JSO

بهینه‌سازی بر اساس روش‌های شبکه‌های عصبی هر روز در حال گسترش و بهبود است. از آنجا که الگوریتم *GMDH* دارای رویکرد خود سازمان دهی است و ساختار آن در ابتدا نامشخص است، بنابراین الگوریتم‌های جستجو می‌توانند برای آموزش و بهینه‌سازی وزن‌ها در ساختار هر نورون در شبکه *GMDH* مورد استفاده قرار بگیرد. در مرجع [۲۶] مدل‌های هوشمند ترکیبی جدید برای پیش‌بینی سیل ارائه شده است و بهینه‌سازی مدل‌های *GMDH* و *SVR* با الگوریتم ژنتیک و جستجوی هارمونی مورد بررسی قرار گرفته است. مسئله طراحی شبکه عصبی *GMDH* به جهت جلوگیری از رشد واگرایی شبکه است و از سوی دیگر مسائل غیرخطی پیش‌بینی نیاز به مدل کارآمدتر و دقیق‌تری هستند. الگوریتم *JSO* و روش پیش‌بینی *GMDH* که دو روش شناخته شده هستند، در این پژوهش الگوریتم ترکیبی *GMDH-JSO* را ایجاد می‌کنند. روش ترکیبی در این تحقیق، از الگوریتم بهینه‌سازی جستجوی عروس دریایی جهت بهبود ضرایب جملات چند جمله‌ای در *GMDH* استفاده شده است. ابتدا با اعمال الگوریتم *GMDH* ضرایب رگرسیون بدست می‌آیند. این ضرایب را به عنوان مقدار اولیه الگوریتم *JSO* قرار می‌گیرند. به عبارت دیگر *GMDH-JSO* به سادگی یک فرآیند *GMDH* است که در آن داده مجموعه‌ای از گره‌ها برای انتقال به لایه بعدی توسط *JSO* تعیین می‌شود. در واقع هدف مدل *JSO*، تعیین وزن‌های بهینه مطلوب در زمان کوتاه برای دستیابی به ساختار مطلوب *GMDH* با حداقل خطا است. بنابراین الگوریتم *GMDH-JSO* شامل مراحل زیر است:

۱- داده‌ها به دو دسته داده‌های آموزشی و آزمایشی تقسیم شده و مقادیر اولیه ضرایب چند جمله‌ای در *GMDH* درج شد. اما قبل از جداسازی، نرمال‌سازی را به صورت زیر انجام می‌دهیم:

$$X = \frac{x_i}{\max x_i} \quad (14)$$

براساس رابطه (۱۴) برای نرمال‌سازی داده‌ها، مقدار هر ورودی بر بیشترین مقدار آن تقسیم می‌شود [۲۷].

۲- مدل *GMDH* در سطح آموزشی اجرا می‌شود.

۳- الگوریتم‌های *JSO* برای تنظیم پارامترهای *GMDH* بکار گرفته می‌شود.

۴- مقادیر اولیه ضرایب چند جمله‌ای جمعیت اولیه الگوریتم‌ها در نظر گرفته می‌شود. این پژوهش همانطور که بیان شد از چند جمله‌ای درجه دوم شبکه *GMDH* استفاده شده است که به صورت زیر نوشته می‌شود:

$$\hat{z} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (15)$$

در روش *GMDH* ضرایب وزنی معادله (۱۵) با استفاده از تکنیک‌های رگرسیون محاسبه می‌شوند. به طوری که تفاوت بین خروجی واقعی، z و یک خروجی محاسبه شده برای هر جفت w ، به عنوان متغیرهای ورودی، به حداقل برسد. در این راستا a بردار ضرایب مجهول چند جمله‌ای درجه دوم در به شکل زیر نمایش می‌دهیم:

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\} \quad (16)$$

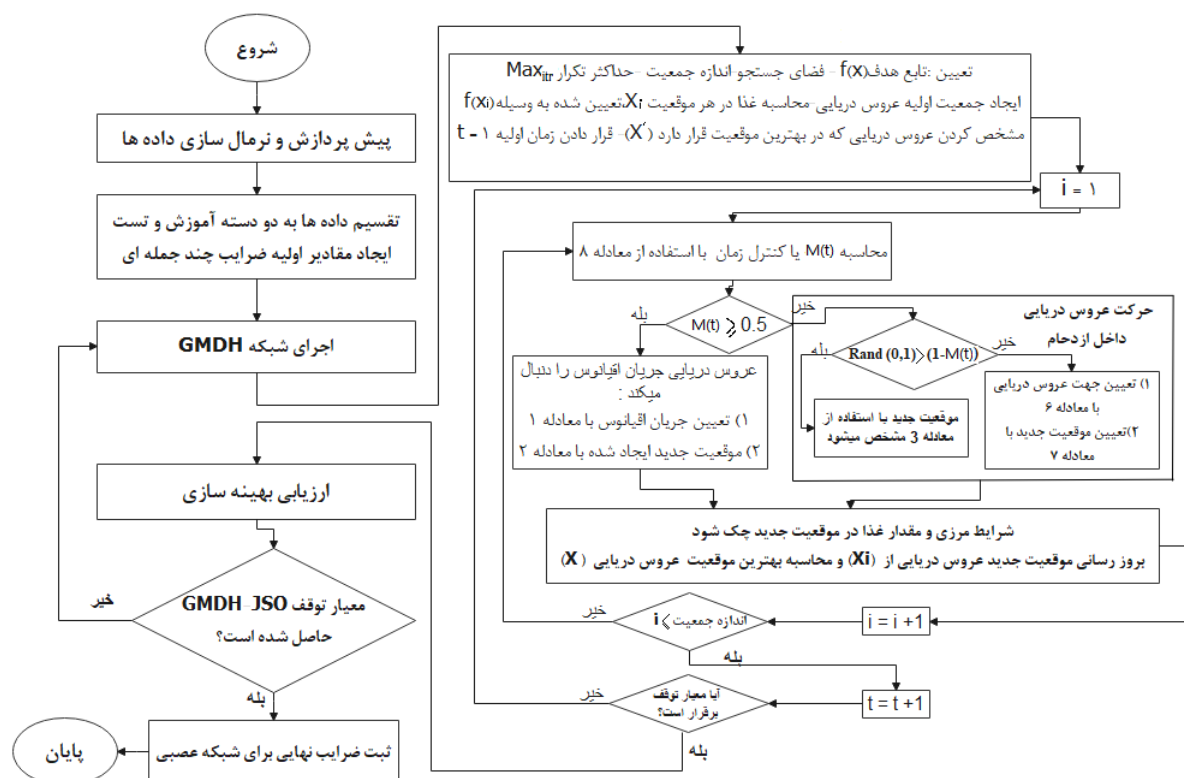
الگوریتم *JSO* برای طراحی مدل بهینه شبکه عصبی براساس تعیین بهینه ضرایب مجهول بردار رابطه (۱۶) استفاده شده است. تعداد معینی از تکرار بدون مشاهده بهبودی خاص در نتیجه، شرط توقف الگوریتم *JSO* است.

۵- در صورت تحقق شرط توقف (معادله ۱۷)، مدل در سطح تست اجرا می‌شود. در غیر این صورت، مجدداً وارد الگوریتم *JSO* برای تنظیم پارامترهای *GMDH* استفاده می‌شود.

$$\text{error} = \sum_{i=1}^n (\hat{y}_i - y_i)^2 \rightarrow \min \quad (17)$$

۶- مجدداً مدل *GMDH* اجرا می‌شود. تابع هدف (معادله ۱۷) برای ارزیابی عملکرد مدل *GMDH-JSO* بررسی می‌شود. مقادیر ضرایب به روز می‌شوند.

برای درک بهتر عملکرد روش *GMDH-JSO*، فلوچارت زیر ارائه شده است:



شکل (۲): فلوچارت روش ترکیبی GMDH-JSO

Figure (2): Flowchart of the combined GMDH-JSO method

۵- داده های ایستگاه مورد مطالعه

اطلاعات مورد استفاده در این تحقیق شامل داده های هواشناسی روزانه (حداقل دما، حداکثر دما، میانگین دما، رطوبت نسبی، سرعت باد) ثبت شده در ایستگاه هواشناسی کرمان طی سال ۱۴۰۰ است. مشخصات جغرافیایی و اقلیمی ایستگاه هواشناسی کرمان در جدول (۱) آورده شده است.

Table (1): Geographical characteristics of the studied station

جدول (۱): مشخصات جغرافیایی ایستگاه مورد مطالعه

نام ایستگاه	طول جغرافیایی (درجه شرقی)	عرض جغرافیایی (درجه شمالی)	ارتفاع از سطح دریا (متر)	اقلیم منطقه (یونسکو)
کرمان	۳۰°۱۵'	۵۶°۵۸'	۱۷۵۳/۸	خشک گرم

با توجه به طبقه بندی یونسکو، اقلیم ایستگاه در مرجع [۲۸] خشک و گرم در نظر گرفته شده است. انتخاب این طبقه بندی اقلیمی به دلیل کاربردی تر بودن آن در علوم کشاورزی (زیرا علاوه بر منعکس کردن رژیم های حرارتی و رطوبتی، توازن آبی را در ایستگاه مورد نظر است) صورت گرفت. پارامترهای برداشت شده جهت ورود به مدل پیش بینی شامل دمای حداقل، دمای حداکثر، میانگین رطوبت نسبی و سرعت باد است. دو پارامتر آخر به صورت میانگین در نظر گرفته شده اند. جدول شماره (۲) پارامترهای ذکر شده را در بازه آموزش نشان می دهد.


Table (2): Statistical characteristics of meteorological data of the studied station

جدول (۲): مشخصات آماری اطلاعات هواشناسی ایستگاه مورد مطالعه

پارامتر	نماد	کمینه	بیشینه	میانگین
دمای حداقل (درجه سانتی گراد)	T_{min}	-۱۶/۲	۲۶,۶	۷/۴
دمای حداکثر (درجه سانتی گراد)	T_{max}	-۴	۴۲	۲۵,۵
میانگین رطوبت نسبی (درصد)	R_H	۸/۹	۹۸,۴	۳۲/۱
سرعت باد (متر بر ثانیه)	W	۸	۱۳/۵	۱۰/۷۵

۶- پیش بینی کوتاه مدت سرعت باد با استفاده از الگوریتم GMDH-JSO


در این پژوهش به مدل سازی و پیش بینی سری زمانی سرعت باد به عنوان متغیر خروجی، پرداخته خواهد شد. برای انجام مراحل آموزش و اعتبارسنجی مدل، داده ها به دو قسمت تقسیم می شوند. سری داده های ثبت شده سال ۱۴۰۰ که برابر ۱۴۶۰ داده ورودی است و ۷۵ درصد این داده ها برای آموزش و ۲۵ درصد در مرحله اعتبار سنجی مورد استفاده قرار می گیرد. برای درک بهتر ورودی ها و خروجی مدل، بلوک دیاگرام پروسه در شکل (۳) ارائه شده است.



شکل (۳): بلوک دیاگرام ساده مدل بر مبنای ورودی ها و خروجی

Figure (3): Simple block diagram of the model based on inputs and outputs

در شکل (۴) پیش بینی روز ۱۵ آبان سال ۱۴۰۰ را با الگوریتم GMDH-JSO نمایش داده شده است. روش پیشنهادی با دقت قابل قبولی مقادیر واقعی سرعت باد را تخمین زده است. همانطور که در شکل (۵) مشخص است شبکه آموزش دیده علی رغم اندکی خطا مقادیر واقعی را دنبال کرده است. معیار ضریب تعیین امتیاز^{۱۸} (R^2) در مرحله آزمون مقدار ۰/۹۹۱۲ را داراست. معیار مجذور میانگین مربعات خطا^{۱۹} (RMSE) در مرحله آزمون ۰/۳۸۹۱ است. معیار میانگین درصد خطای مطلق^{۲۰} (MAPE) نیز ۸/۰۱۹۶ است.



شکل (۴): پیش بینی ۲۴ ساعت سرعت باد براساس روش GMDH-JSO

Figure (4): 24-hour wind speed forecast based on the GMDH-JSO method

شبکه GMDH-JSO طراحی شد و آموزش آن براساس بهترین انتخاب و حداقل خطا در داده‌های آزمون انجام گردید. در مدل پیشنهادی معیار همگرایی و توقف الگوریتم JSO تکرار می‌باشد. در این مدل حداکثر تکرار ۳۰۰ است و معیار توقف بهبود نیافتن بعد از ۵۰ تکرار در نظر گرفته شده است. پارامترهای الگوریتم بهینه ساز جستجوی عروس دریایی مصنوعی در جدول (۳) آمده است.

Table (3): JSO algorithm parameters

جدول (۳): پارامترهای الگوریتم JSO

۵۰۰	تعداد جمعیت
۳	ضریب توزیع β
۰٫۵	پارامتر معیار کنترل زمان Co
۳۰۰	ماکزیمم تعداد تکرارها

۷- معیارهای ارزیابی روش GMDH-JSO

به منظور ارزیابی قدرت پیش‌بینی تکنیک‌های مختلف در پژوهش‌های گوناگون از معیارهای مختلفی استفاده می‌شود. با وجود این، سه شاخص آماری ضریب تعیین امتیاز (R^2)، میانگین درصد قدرمطلق خطا (MAPE) و معیار مجذور میانگین مربعات خطا (RMSE) در مبحث خطاهای پیش‌بینی از پرکاربردترین معیارها محسوب می‌شوند [۲۸].

$$R^2 = 1 - \frac{\sum_{i=1}^N (x_i - \hat{z}_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (19)$$

$$MAPE = \frac{\sum_{i=1}^N \left| \frac{x_i - \hat{z}_i}{x_i} \right|}{N} * 100\% \quad (20)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - z_i)^2}{N}} \quad (21)$$


در معادلات بالا X_i و Z_i به ترتیب بیانگر مقادیر واقعی و پیش‌بینی شده سرعت باد هستند و N بیانگر تعداد ساعات در افق پیش‌بینی است که در این مطالعه برابر ۲۴ ساعت در نظر گرفته شده است. جدول (۴) معیارهای ارزیابی شبکه GMDH-JSO برای داده‌های آموزش و آزمون را نمایش می‌دهد. معیار ضریب تعیین امتیاز R^2 هرچه بیشتر باشد نشان دهنده میزان تطابق خروجی مدل با هدف است و اگر یک باشد، معرف این هست که خروجی سیستم با هدف برابر می‌باشد. این ضریب در مرحله آزمون مقدار ۰/۹۹۲۳ را داراست که معرف کارایی شبکه است. هر چقدر معیار RMSE کمتر باشد عملکرد شبکه در پیش‌بینی بهتر است همچنین مقدار آن در مرحله آزمون ۰/۳۵۱۱ است. معیار MAPE نیز به همین شکل است. لذا ارزیابی‌های آماری ثابت می‌کنند که نتایج مدل پیشنهادی دقت بسیار بالایی دارند به طوری که حدود قابل توجهی تغییرات مقادیر متغیر پاسخ توسط مدل بهینه شده می‌تواند تعیین گردد.

Table (4): Results of implementing the GMDH-JSO network in the training and testing phase

جدول (۴): نتایج اجرای شبکه GMDH-JSO در مرحله آموزش و آزمون

داده ها	شاخص های ارزیابی	GMDH-JSO
آموزش	R^2	۰/۹۹۱۲
	MAPE (%)	۸/۱۹۶
	RMSE	۰/۳۸۹۱
آزمون	R^2	۰/۹۹۲۳
	MAPE (%)	۷/۵۸۰۷
	RMSE	۰/۳۵۱۱

نتیجه تجزیه و تحلیل پراکندگی داده‌ها یا در شکل (۵) [انرمالیزه شده] ارائه شده است. در این شکل‌ها ارتباط بین مقادیر واقعی سرعت باد با مقادیر برآورد شده توسط شبکه GMDH-JSO نشان داده شده است. در این شکل داده‌های آموزش و آزمون نشان داده شده است. همانگونه که دیده می‌شود، نزدیک بودن شیب خط به عدد یک و کم بودن مقدار عرض از مبدا، بیان‌کننده کارایی خوب شبکه طراحی شده در تخمین سرعت باد است.



شکل (۵): ارتباط بین مقادير واقعی سرعت باد با مقادير برآورد شده توسط شبکه GMDH-JSO (داده های نرمالیزه شده)

Figure (5): Relationship between actual wind speed values and values estimated by the GMDH-JSO network (normalized data)


در ارزیابی دقیقتر، مدل ارائه شده با الگوریتم‌ها و روش‌های ترکیبی مشابه مقایسه گردیده است. همانطور که در جدول (۵) نمایش داده شده الگوریتم GMDH-JSO در معیارهای ذکر شده برتری نسبی به روش‌های ذکر شده در جدول دارد. مدل پیشنهادی پروژه با اختلاف قابل توجه از دید معیارهای ارزیابی نسبت به مدل GMDH قرار دارد. در معیار میانگین درصد قدرمطلق خطا مدل GMDH-PSO نسبت به بهینه‌سازی انجام شده با الگوریتم JSO مقدار ۰/۲۹ درصد خطا دارد که طراحی یک شبکه GMDH به صورت بهینه یا به عبارت دیگر تعیین وزن‌های شبکه با استفاده از الگوریتم بهینه‌سازی مناسب مانند JSO می‌تواند سهم بسزایی در مسائل تخمین و پیش‌بینی با دقت بالا را داشته باشد. جدول (۵) نشان می‌دهد که مدل پیشنهادی برای معیارهای $RMSE$, $MAPE$, R^2 به ترتیب مقادیر ۰/۹۹۲۳، ۷/۵۸۰۷ و ۰/۳۵۱۱ کسب کرده است و می‌تواند به عنوان ابزاری کارآمد در مسائل برنامه‌ریزی مورد استفاده قرار گیرد.

Table (5): Comparison of evaluation criteria for the GMDH-JSO method with similar methods

جدول (۵): مقایسه معیارهای ارزیابی برای روش GMDH-JSO با روش‌های مشابه

معیار روش	R ²	MAPE (%)	RMSE
GMDH-JSO	۰/۹۹۲۳	۷/۵۸۰۷	۰/۳۵۱۱
GMDH-PSO [30]	۰/۹۸۳۲	۷/۸۶۹۳	۰/۵۷۹۸
LWGMDH ²¹ [31]	۰/۹۷۹۳	۸/۲۳۱۱	۰/۶۱۲۱
GMDH	۰/۹۷۸۹	۹/۵۴۳۶	۰/۷۳۸۸
LSTM [29]	۰/۶۸۴۷	۱۹/۱۷۹	۰/۸۳۹۹
OVMD-LSTM [29]	۰/۸۸۰۵	۱۳/۲۰۰	۰/۵۱۷۰
Jaya-SVM [18]	۰/۹۰۵۲	۱۱/۸۷۱۱	۰/۸۰۳۲

شکل (۶) معیار دیگری از پیش بینی مقادیر حقیقی مدل GMDH-JSO نسبت به مدل‌های ترکیبی عصبی LSTM را نشان می‌دهد که لازم است موتور عملکرد آنها بررسی شود. شبکه‌ی LSTM ساز و کارهایی داخلی به اسم گیت (Gate) دارد. این گیت‌ها جریان اطلاعات را کنترل می‌کنند و مشخص می‌کنند چه داده‌هایی در توالی مهم هستند و باید هم‌چنان حفظ شوند و چه داده‌هایی باید حذف شوند. شبکه‌های LSTM پارامترهای زیادی دارند، بنابراین هزینه محاسبات دارد. در مقایسه دیگر، روش ماشین بردار پشتیبان در حقیقت یک الگوریتم یادگیری ماشین با ناظر است که نمونه‌ی داده‌هایی را به صورت نقاطی در فضا نشان داده شده است، با استفاده از یک خط یا هایپرپلین از هم جدا می‌کند. این جداسازی به گونه‌ای است که نقاط داده‌ای که در یک طرف خط هستند مشابه هم و در یک گروه قرار می‌گیرند. نمونه داده‌های جدید هم بعد از اضافه شدن به همان فضا در یکی از دسته‌های موجود قرار خواهند گرفت. ساختن یک هایپرپلین برای نقاط داده‌ی تفکیک‌پذیر خطی کار آسانی است، اما وقتی داده‌ها غیرخطی تفکیک‌پذیر باشند، کار بسیار چالش برانگیز خواهد بود. از طرفی دیگر کرنل‌ها در SVM به ما اجازه می‌دهند تا داده‌هایی که به صورت خطی جداسازی‌پذیر نیستند را به فضای ویژگی بالاتری انتقال دهیم که در آن جداسازی ممکن است. انتخاب نوع کرنل اهمیت دارد. اگر کرنل انتخابی با ماهیت داده‌ها همخوانی نداشته باشد، مدل نهایی نمی‌تواند الگوهای پیچیده را یاد بگیرد و این موضوع می‌تواند به کاهش دقت پیش‌بینی‌ها منجر شود. اما الگوریتم GMDH-JSO این پیچیدگی‌ها را ندارد و یک روش خودسامان ده هست که بر روی مدل‌های پیچیده بخصوص در مبحث پیش‌بینی، براساس تکامل عملکردشان بر روی یک مجموعه شکل می‌گیرد. از طرف دیگر الگوریتم JSO که برای آموزش شبکه بکار گرفته شده است که علیرغم ساختار ساده، توانایی جستجوی ویژه‌ای دارد و این براساس استراتژی‌های جهشی هست که برای آن تعریف شده است.



شکل (۶): مقایسه مدل GMDH-JSO در پیش بینی سرعت باد با مدل‌های پیش بینی مطرح شده در سالهای اخیر

Figure (6): Comparison of the GMDH-JSO model in wind speed forecasting with forecasting models proposed in recent years.

لازم به ذکر است که زمان میانگین برای آموزش روش پیشنهادی حدود ۱/۲ دقیقه است. مشخصات سخت‌افزاری رایانه بکارگرفته شده در این تحقیق، پروسسور Intel Cor i5 همراه با CPU 2.30 GHz و RAM 4GB است.

۷- نتیجه گیری

در این تحقیق، به منظور بهبود عملکرد پیش‌بینی کوتاه مدت سرعت باد، روش گروهی مدل سازی داده‌ها با الگوریتم بهینه ساز جستجوی عروس دریایی آموزش داده شده است. در این راستا الگوریتم JSO به شکل مطلوبی ضرایب وزنی شبکه GMDH را مشخص می‌کند. جهت بررسی عملکرد الگوریتم GMDH-JSO، پیش‌بینی کوتاه مدت سرعت باد شهر کرمان انجام گرفته است. از نتایج ذکر شده مشخص است که دقت پیش‌بینی و تخمین مدل ارائه شده قابل قبول و رقابت با الگوریتم مشابه است. مدل پژوهش در مقایسه با مدل کلاسیک GMADH در معیار میانگین درصد قدرمطلق خطا کاهش خطایی ۲ درصدی را دارا هست در مدل ترکیبی مشابه GMDH-PSO هم بهینه سازی قابل توجه است. همچنین مدل ارائه شده مقدار ۷/۵۸۰۷ را در معیار میانگین درصد قدرمطلق خطا کسب کرده است که کمترین مقدار در مقایسه با شبکه عصبی LSTM بهینه شده با الگوریتم تجزیه مودال متغیر و روش Jaya-SVM است. با توجه به اینکه تخمین صحیح عدم قطعیت‌ها در برنامه‌ریزی سیستم‌های مختلف ضروری است، می‌توان گفت این مدل قادر به توضیح عدم قطعیت‌ها به نحو کارآمد است و برای برنامه‌ریزی دقیق‌تر سیستم قدرت و استفاده حداکثری از ظرفیت انرژی باد کارایی لازم را دارد. همچنین نتایج حاصل از معیارهای ارزیابی دیگر شامل ضریب تعیین امتیاز و معیار مجذور میانگین مربعات خطا تاییدی بر دقت روش GMDH-JSO است.

References

مراجع

- [1] L. Hirth, "The market value of variable renewables: The effect of solar wind power variability on their relative price", Energy Econ, vol. 38, pp. 218-236, July. 2013 (doi.org/10.1016/j.eneco.2013.02.004)
- [2] F. Bouffard, FD. Galiana, "Stochastic security for operations Planning with Significant Wind Power Generation", IEEE Trans Power Syst, vol. 23, pp. 306 – 316, May. 2008 (doi: 10.1109/TPWRS.2008.919318)

- [3] Y. Zhang, N. Gatsis, GB. Giannakis, "Robust energy management for microgrids with high-penetration renewables", IEEE Trans Sust Energy, vol. 4, pp. 944-953, Oct. 2013 (doi:10.1109/TSTE.2013.22551135)
- [4] G. Tang, Y. Wu, C. Li, P. Wong, Z. Xiao, X. An, "A Novel wind speed interval prediction based on error prediction method", IEEE Transactions on Industrial Informatics, Vol. 16, pp. 6806 – 6815, Nov. 2020 (doi: 10.1109/TII.2020.2973413)
- [5] B. Huang, Y. Liang, X. Qiu, "Wind power forecasting using attention-based recurrent neural networks: A comparative Study", IEEE Access, Vol 9, pp. 40432 – 40444, March. 2021, (doi: 10.1109/ACCESS.2021.3065502)
- [6] C. Tu, W. Tsai, C Hong ,W Lin, "Short-Term solar power forecasting via general regression neural network with grey wolf optimization", Energies, vol. 15, pp. 6624, Sep 2022 (doi.org/10.3390/en15186624)
- [7] M. Afrozeh, H. Abdolmohamadi, M. Nazari, "Apply a mutation in gray wolf optimization algorithm to Solve the Economic-Environmental Dispatch Problem of Integrated Power Plants Including Thermal and wind ", Journal of Intelligent Procedures in Electrical Technology, Vol. 14, pp. 59-76, Winter. 2022
- [8] E. Brenjkar, " Evaluation of the performance of artificial neural networks integrated with whale optimization and ant colony optimization algorithms in estimating the drilling rate of penetration and compare with simple neural networks and mathematical conventional models", Modeling in Engineering, Vol. 19, pp. 115-135, summer. 2021
- [9] E. Alves, M. Lopes, F. Sales, A. Balieiro, "A GMDH Approach for Forecast Monthly Rainfall in Southeast of Para", IEEE Latin America Transactions, Vol. 21, Pp. 707–714, June. 2023 (doi: 10.1109/TLA.2023.10172135)
- [10] B. Badyalina, AF. Azimi, "Data-driven models for wind speed forecasting in malacca state", Matematika MJIM, vol 38, Num. 2, pp. 125–139, Aug. 2022 (<https://matematika.utm.my/index.php/matematika/article/view/1404>)
- [11] Y. Zhang, Y. Zhao, S. Gao, "A novel hybrid model for wind speed prediction based on VMD and neural network considering atmospheric uncertainties", IEEE Access, Vol. 7, pp. 60322 - 60332, May. 2019 (doi: 10.1109/ACCESS.2019.2915582)
- [12] S. Makhloufi, G. Gopalakrishna Pillai, "Wind speed and wind power forecasting using wavelet denoising-GMDH neural network", 2017 5th International Conference on Electrical Engineering - Boumerdes (ICEE-B), (doi: 10.1109/ICEE-B.2017.8192155)
- [13] Chongqing Shi1, Xiaoli Zhang, "Recurrent neural network wind power prediction based on variational modal decomposition improvement", AIP Advances 13, Issue 2, Feb. 2023 (doi.org/10.1063/5.0135711)
- [14] Bilin Shao , Dan Song , Genqing Bian , Yu Zhao, " Wind speed forecast based on the LSTM neural network optimized by the firework algorithm", Hindawi Advances in Materials Science and Engineering, Vol. 2021, Article. ID 4874757 (doi.org/10.1155/2021/4874757)
- [15] Y. wang, D. wang, Y. tang, "Clustered hybrid wind power prediction model based on ARMA, PSO-SVM, and clustering methods", IEEE access, Vol. 8, Jan. 2020 (doi: 10.1109/ACCESS.2020.2968390)
- [16] M. elsaraiti, A. Merabet, " Application of Long-Short-Term-Memory recurrent neural networks to forecast wind speed", Appl. Sci, Oct. 2021 (<https://doi.org/10.3390/app11052387>)
- [17] A. Khosravi, L. Machado, R.O. Nunes, "Time-series prediction of wind speed using machine learning algorithms: A case study Osorio wind farm, Brazil", Applied Energy, vol. 224, pp. 550-566, , Aug. 2018 (doi.org/10.1016/j.apenergy.2018.05.043)
- [18] M. Liua, Z. Caoc, J. Zhanga, L. Wanga, C. Huang, X. Luoa, " Short-term wind speed forecasting based on the Jaya-SVM model", Electrical Power and Energy systems (Elsevier), Volume 121, Feb 2020, doi.org/10.1016/j.ijepes.2020.106056
- [19] L. Jinghua, L. Yongsheng , Y. Shuhui, "Mid-long term load forecasting model based on support vector machine optimized by improved sparrow search algorithm", Energy Reports, vol. 8, pp. 491–497, Aug 2022 (doi.org/10.1016/j.egyr.2022.02.188)
- [20] A. Heydari, D. Astiaso Garcia, F. Keynia, F. Bisegna, L. De Santoli, "A novel composite neural network based method for wind and solar power forecasting in microgrids", Applied Energy, vol. 251, issue 113353, Oct. 2019 (doi.org/10.1016/j.apenergy.2019.113353)
- [21] A. Heydari , M. Majidi Nezhad, M. Neshat, D. Astiaso Garcia, F. Keynia, L. Santoli, L. Bertling Tjernberg, "A combined fuzzy GMDH neural network and grey wolf optimization application for wind

- turbine power production forecasting considering SCADA data,” *energies*,14, pp. 3459, June 2021 (doi.org/10.3390/en14123459)
- [22] M.FARHAT,S.KAMEL,A.M.ATALLAH1,B. KHAN. "Optimal power flow solution Based on Jellyfish Search Optimization Considering Uncertainty of Renewable Energy Sources". *IEEE Access*,Volume: 9,July 2021,pp 100911 – 100933,DOI: 10.1109/ACCESS.2021.3097006
- [23] J.Sheng Chou, D.Nhat Truong. "A novel metaheuristic optimizer inspired by behavior of jellyfish in ocean". *Applied Mathematics and Computation* , Vol. 389, pp. 125535, Jan. 2021 (doi.org/10.1016/j.amc.2020.125535)
- [24] A. Alam Preeti Verma, M. Tariq , A. Sarwar , B.Alamri, N. Zahra,S. Urooj. "Jellyfish search optimization algorithm for MPP tracking of PV system”. *MDPI sustainability*, Vol. 13, pp. 11736, 2021(doi.org/10.3390/su132111736)
- [25] A.G. Ivakhnenko, "Polynomial theory of complex systems", *IEEE Transactions on systems*, vol, SMC-1, pp. 364–378, 1971 (doi: 10.1109/TSMC.1971.4308320)
- [26] E. Dodangeh,M. Panahi,S. Lee,D. Tien Bui, “Novel hybrid intelligence models for flood-susceptibility prediction: Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search“, *Journal of Hydrology*, Vol 590, pp. 125423, Nov. 2020 (doi.org/10.1016/j.jhydrol.2020.125423)
- [27] YU.P Zaychenko,I.O. Zayets, “The fuzzy group method of data handling and its application to the problems of the macroeconomic indexes forecasting” ,*Systems Analysis Modelling Simulation*,vol 43,Oct 2010,Issue 10,pp. 1321-1329,doi.org/10.1080/02329290290023349.
- [28] A. Sabziparvar,M. Bayat, "Evaluation of accuracy of artificial neural network and neural-fuzzy methods in simulating total solar radiation", *Iranian Journal of Physics Research*, vol. 10, Vol. 4, winter. 2019
- [29] LIJUAN ZHU AND WEI HU, “Short term wind speed prediction based on VMD and DBN combined model optimized by improved sparrow intelligent algorithm”, *IEEE Access*, Vol. 10, pp. 92259 – 92272, Aug 2022, (doi: 10.1109/ACCESS.2022.3202970)
- [30] V. Vahidinasab, H. Sohrabi Vafa, ”Wind power forecasting by a new hybrid forecast engine composed of GA/EP SO-Based mutual information and group method of data handling (GMDH)”, *Scientific Journal of Computational Intelligence in Electrical Engineering*, Vol. 9, Pages 1-14, Sep. 2018 (doi: 10.22108/isee.2018.89972.0)
- [31] E. Elattar, I. Taha, ”Improved short term wind power prediction using a combined locally weighted GMDH and KPCA”, *International Journal of Scientific & Engineering Research*, Vol 4, pp1216, Aug. 2013

زیر نویس ها:

1. Recurrent neural network
2. Mean Absolute Error
3. General regression neural network
4. Grey wolf optimization
5. Group Method of Data Handling
6. Variational mode decomposition
7. Intrinsic mode functions
8. Support vector machine
9. Long short-term memory
10. Recurrent Neural Network
11. the firework algorithm
12. Multilayer feed-forward neural network
13. Support vector regression
14. Fuzzy inference system
15. Adaptive neuro-fuzzy inference system
16. Modified fruit fly optimization algorithm
17. jellyfish search optimizer
18. Coefficient of Determination
19. Root Mean Squared Error
20. Mean Absolute Percentage Error
21. Locally Weighted