



Golestan University



Journal of the Climate Change Research

Scientific Journal of Golestan University
Vol. 6, No. 24, Winter 2026



Evaluating the performance of metaheuristic algorithms for optimizing input data to model dust storms (A case study of Sistan and Baluchestan province)

Ramtin Tavoosi Rad¹ , Sadaf Piri² , Mohammad Ansari ghoghghar^{3*} , Hossein Azarnivand⁴

¹ Master Candidate, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran, Email: ramtintavosirad@ut.ac.ir

² Ph.D. candidate, Department of Reclamation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran Email: Sadaf.piri@ut.ac.ir

³ Assistant Professor, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran, Email: ansari.ghoghghar@ut.ac.ir

⁴ Professor, Department of Reclamation of Arid & Mountain regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran, Email: hazar@ut.ac.ir

Article Info

Article type:

Research Full Paper

Article history:

Received: 2025-10-10

Accepted: 2025-11-08

Keywords:

120-day winds

Water Cycle Algorithm

Invasive Weed

Optimization

FCMR-MA hybrid model

ABSTRACT

Dust storms are among the most severe climatic hazards affecting arid and semi-arid regions, particularly southeastern Iran. The Sistan and Baluchestan Province is especially vulnerable due to its proximity to desert areas, persistent drought conditions, reduced vegetation cover, and the influence of the seasonal 120-day winds. Given the complex and uncertain nature of dust storm prediction—especially in regions with limited or low-quality meteorological data—this study investigates the role of metaheuristic algorithms in improving predictive accuracy through input optimization. The main objective is to evaluate the performance of two metaheuristic algorithms, Invasive Weed Optimization (IWO) and Water Cycle Algorithm (WCA), for optimizing input variables in the hybrid Fuzzy Clustering Model Regression–Moving Average (FCMR–MA) model. The hybrid model was employed to predict the seasonal frequency of dust storm days (FDSD) across five synoptic stations in Sistan and Baluchestan over a 40-year period (1980–2020). Four predictive scenarios were examined. The baseline FCMR–MA model using only dust storm data; the same model incorporating drought indices (SPI and SPEI); and the optimized FCMR–MA models enhanced with WCA and IWO algorithms. Multiple forecasting horizons (one- to four-season lags) were applied to assess model sensitivity to past dust storm events. Model performance was evaluated using four statistical indicators: Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Nash–Sutcliffe Efficiency (NS), and the Correlation Coefficient (R). Results indicate that both metaheuristic algorithms substantially enhance the predictive accuracy of the FCMR–MA model, with the IWO algorithm consistently achieving the best performance across all stations and evaluation metrics—particularly in Zabol and Zahedan, which exhibit higher FDSD frequencies. These findings highlight the potential of metaheuristic optimization for improving dust storm forecasting in data-scarce arid environments.

Cite this article: Tavoosi Rad, R., Piri, S., Ansari ghoghghar, M., Azarnivand, H. (2025). Evaluating the performance of metaheuristic algorithms for optimizing input data to model dust storms (A case study of Sistan and Baluchestan province). *Journal of the Climate Change research*, 6 (24), 73-88.



©The author(s)

Publisher: Golestan University

DOI: [10.30488/ccr.2025.552548.1307](https://doi.org/10.30488/ccr.2025.552548.1307)



ارزیابی عملکرد الگوریتم‌های فرا ابتکاری در بهینه‌سازی داده‌های ورودی به منظور مدل‌سازی طوفان‌های گرد و غبار (مطالعه موردی: استان سیستان و بلوچستان)

رامتین طاوسی‌راد^۱، صدف پیری^۲، محمد انصاری قوجقار^{۳*}، حسین آذرنیوند^۴

^۱ دانشجوی کارشناسی ارشد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران،

رایانامه: ramtintavosirad@ut.ac.ir

^۲ دانشجوی دکتری، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران، رایانامه: Sadaf.piri@ut.ac.ir

^۳ استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران، رایانامه: ansari.ghojghar@ut.ac.ir

^۴ استاد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران، رایانامه: hazar@ut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله کامل علمی تاریخ دریافت: ۱۴۰۴/۷/۱۹ تاریخ پذیرش: ۱۴۰۴/۸/۱۸ واژه‌های کلیدی: طوفان‌های ۱۲۰ روزه الگوریتم چرخه آب الگوریتم علف‌های هرز مدل هیبریدی FCMR-MA	طوفان‌های گرد و غبار به‌عنوان یکی از مهم‌ترین مخاطرات اقلیمی در مناطق خشک و نیمه‌خشک ایران به‌ویژه استان سیستان و بلوچستان، پیامدهای گسترده‌ای در ابعاد اجتماعی، اقتصادی و زیست‌محیطی ایجاد می‌کنند. یکی از چالش‌های اصلی در مدل‌سازی و پیش‌بینی این پدیده، عدم قطعیت در داده‌های ورودی و محدودیت ایستگاه‌های سینوپتیکی است. این پژوهش با هدف بهبود عملکرد مدل‌های پیش‌بینی، به ارزیابی نقش الگوریتم‌های فراابتکاری در بهینه‌سازی داده‌های ورودی پرداخته است. در این راستا، یک مدل هیبریدی مبتنی بر رگرسیون فازی خوشه‌بندی‌شده و میانگین متحرک FCMR-MA توسعه داده شد و برای بهینه‌سازی داده‌های ورودی، دو الگوریتم فراابتکاری چرخه آب و بهینه‌سازی علف‌های هرز مهاجم به‌کار گرفته شدند. یکی از عوامل کلیدی در تشدید و تداوم این پدیده، وقوع خشکسالی‌های متوالی و کاهش رطوبت خاک است که بستر تولید و انتقال گردوغبار را تقویت می‌کند. به‌منظور تحلیل پیوند بین شرایط خشکسالی و وقوع طوفان‌های گردوغبار، شاخص‌های خشکسالی SPI و SPEI نیز به‌عنوان متغیرهای اقلیمی در ساختار مدل لحاظ شدند. داده‌های مورد استفاده شامل فراوانی روزهای همراه با طوفان گردوغبار در پنج ایستگاه سینوپتیکی استان سیستان و بلوچستان طی دوره ۴۰ ساله بود. عملکرد مدل‌ها با استفاده از چهار معیار ارزیابی R، RMSE، MAE، NS سنجیده شد. یافته‌ها نشان داد که به‌کارگیری الگوریتم‌های فراابتکاری موجب بهبود معنادار در دقت مدل نسبت به حالت بدون بهینه‌سازی شد. در این میان، الگوریتم علف‌های هرز مهاجم با دستیابی به بالاترین ضریب همبستگی ($R=0.94$) و کم‌ترین میزان خطا، عملکرد برتری نسبت به الگوریتم چرخه آب و مدل پایه ارائه کرد. به‌طور کلی، نتایج این مطالعه بیانگر اهمیت استفاده از الگوریتم‌های فراابتکاری در بهینه‌سازی داده‌های ورودی برای ارتقاء دقت مدل‌های پیش‌بینی طوفان‌های گردوغبار در مناطق خشک و نیمه‌خشک است.

استناد: طاوسی‌راد، رامتین؛ پیری، صدف؛ انصاری قوجقار، محمد؛ آذرنیوند، حسین (۱۴۰۴). ارزیابی عملکرد الگوریتم‌های فرا ابتکاری در بهینه‌سازی داده‌های ورودی به منظور مدل‌سازی طوفان‌های گرد و غبار (مطالعه موردی: استان سیستان و بلوچستان). نشریه پژوهش‌های تغییرات آب و هوایی، ۶ (۲۴)، ۷۳-۸۸.



مقدمه

یکی از چالش‌های اساسی که امروزه مناطق گرم و خشک با آن مواجه هستند، پدیده گرد و غبار است (Dargahian & Ashrafi, 2021). این پدیده حدی اقلیمی در مناطق دارای اقلیم گرم و خشک، بارش کم، خشکسالی، خاک حساس به فرسایش، فقر پوشش گیاهی و در معرض وزش بادهای شدید، دیده می‌شود (Goudiolin, 2018). بر اساس توافق سازمان جهانی هواشناسی^۱، اگر در ایستگاه‌های اندازه‌گیری، سرعت باد از ۱۵ متر بر ثانیه بیشتر و دید افقی به کمتر از یک کیلومتر برسد، طوفان گرد و غبار گزارش می‌شود (Mehrabi et al, 2015). نواحی جنوبی ایران از جنوب شرق تا جنوب غرب ایران، به دلیل نزدیکی با مناطق کویری کشورهای همسایه، همواره در معرض طوفان‌های گرد و غبار و اثرات تخریبی آن قرار دارند (Javadnia & Zahedi, 2022). نتایج ارزیابی اقتصادی اثرات گرد و غبار بر سیستم نشان می‌دهد که طوفان‌های گرد و غبار، خسارات زیادی در ابعاد اقتصادی، اجتماعی و زیست محیطی به ساکنین استان سیستان و بلوچستان وارد می‌کند و از مهم‌ترین معضلات منطقه به‌شمار می‌رود (Janbozorgi et al, 2021). برای مثال ذرات گرد و غبار با کاهش دامنه دید رانندگان، باعث وقوع خسارات زیادی به شهروندان می‌شود (Alshammari et al, 2022). همچنین گرد و غبار، تأثیرات مخرب بسیاری بر روی ترکیبات شیمیایی اتمسفر، تشکیلات خاک و تابش ورودی نور خورشید دارد. این تأثیرگذاری به دلیل کاهش کیفیت هوا، سلامت ساکنین حاضر در این مناطق را به خطر می‌اندازد (Mesbahzadeh et al, 2018). بررسی‌ها نشان می‌دهد یکی از مهم‌ترین عوامل اقلیمی مهم بر افزایش طوفان‌های گرد و غبار، پدیده خشکسالی است که این امر بررسی شاخص‌های خشکسالی نظیر SPI^۲ و SPEI^۳ را برای مطالعه گرد و غبار ضروری می‌کند. در استان سیستان و بلوچستان، مدیریت یک‌جانبه آب

درسرخه‌های حوزه آبخیزهامون و احداث سد ها و بندهای انحرافی در ورودی رودخانه‌های منشاء گرفته از کشور افغانستان، دلایل اصلی تشدید طوفان‌های گرد و غبار در این استان گزارش شده‌اند (Shoaei et al, 2020).

مدل‌های گردوغبار که به توصیف، انتشار، انتقال و رسوب غبار می‌پردازند، ابزارهای مهمی به منظور درک چرخه گرد و غبار هستند. مدل‌های جهانی و منطقه‌ای یا مدل‌های هواشناسی گردوغبار، بازخوردهای پیچیده ذرات معلق در هوا را تحلیل کرده و طوفان‌های گردوغبار را پیش‌بینی می‌کنند. عدم قطعیت در داده‌های ورودی و تفاوت‌های بین مدل‌ها، سبب پراکندگی نتایج پیش‌بینی‌ها می‌شود (Tang et al, 2023). پژوهش‌های بسیاری در رابطه با مدل‌سازی و پیش‌بینی طوفان‌های گرد و غبار با استفاده از الگوریتم‌های هوش مصنوعی در سال‌های اخیر صورت گرفته است. در پژوهش‌های ابتدایی، سبحانی و همکاران (2020) به مقایسه مدل‌های ANFIS^۴ و RBF^۵ در پیش‌بینی فراوانی روزهای وقوع طوفان‌های گرد و غبار پرداختند که مدل RBF با ثبت دقت ۹۵/۱ درصد در زمان و فراوانی، پیش‌بینی‌های بهتری را به ثبت رساند. همچنین رحمتی و همکاران (۲۰۲۰) با هیبرید کردن الگوریتم‌های ANFIS و DE به نتایج درخشانی در زمینه پیش‌بینی صحیح و بهینه پدیده گرد و غبار دست پیدا کردند. دهشیری و فیروزآبادی (۲۰۲۳) یک چارچوب چند هدفه مدل شیمی WRF-Chem^۶ به‌منظور تعیین گزینه‌های بهینه مدل‌سازی و پیش‌بینی تحقیقات آب و هوایی ارائه کردند که نتایج این تحقیق نشان از دقت بالای مدل پیشنهادی در پیش‌بینی گرد و غبار داشت اما انتخاب نامناسب ورودی‌های شیمیایی و فیزیکی باعث نقض عملکرد مدل شیمی پیشنهادی می‌شد. غلامی و محمدی‌فر (۲۰۲۲) به منظور طبقه‌بندی حساسیت منابع گرد و غبار در خاورمیانه، دو مدل هیبریدی

4. Adaptive Neuro-Fuzzy Inference System
5. Radial Basis Function
6. Weather Research and Forecasting - Chemistry

1. World Meteorological Organization
2. Standardized Precipitation Index
3. Standardized Precipitation Evapotranspiration Index

یادگیری عمیق ^۱GRU و ^۲DLDL-RF را ارائه کردند. نتایج این تحقیق نشان داد که مدل هیبریدی DLDL-RF دقت بیش‌تری را به منظور پیش‌بینی گرد و غبار و عوامل دخیل در وقوع این پدیده حدی به ثبت رساند. انصاری قوجقار و پورمحمد (۲۰۲۴) با ارائه مدل هیبریدی سه‌گانه GRNN- SVM- LSTM و مقایسه دقت پیش‌بینی آن با فرامدل‌های انفرادی SVM و GRNN^۳، عملکرد بسیار بهتری را در زمینه پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار (FDSD) ثبت کردند. پیاده‌سازی این مدل هیبریدی سه‌گانه با چالش‌هایی از قبیل کمبود داده، تغییرات اقلیمی و بهینه‌سازی داده‌ها مواجه بود.

الگوریتم‌های فراابتکاری^۴، الگوریتم‌های بهینه‌سازی هستند که برای حل مسائل پیچیده‌ای به کار می‌روند که با روش‌های استاندارد قابل حل نیستند. این الگوریتم‌ها از فرآیندهای طبیعی مانند ژنتیک، رفتار گروهي و تکامل الهام گرفته‌اند و برای کاوش در یک فضای جستجوی گسترده به منظور شناسایی بهینه سراسری یک مسئله، استفاده می‌شوند (Almufti et al, 2023). مطالعه‌ای توسط انصاری قوجقار و همکاران (۲۰۲۰) با استفاده از الگوریتم‌های بهینه‌سازی فراابتکاری مانند الگوریتم ژنتیک (GA)^۵ و الگوریتم ازدحام ذرات (PSO)^۶ در ترکیب با مدل ANFIS برای پیش‌بینی فراوانی روزهای طوفان گرد و غبار در استان خوزستان انجام شد. نتایج آن‌ها نشان داد که ترکیب مدل‌های هوش مصنوعی با الگوریتم‌های بهینه‌سازی می‌تواند دقت پیش‌بینی را بهبود بخشد. همچنین رحمتی و همکاران (۲۰۲۰)، یک روش جدید مبتنی بر الگوریتم‌های یادگیری ماشین ترکیبی برای شناسایی مناطق منبع گرد و غبار توسعه دادند. هر مدل ترکیبی که به عنوان یک سیستم هوشمند طراحی شده است، شامل یک سیستم استنتاج عصبی- فازی تطبیقی

(ANFIS) است که با ترکیبی از الگوریتم‌های بهینه‌سازی فراابتکاری ادغام شده است: الگوریتم خفاش (BA)^۷، الگوریتم فرهنگی (CA)^۸ و الگوریتم تکامل تفاضلی (DE)^۹. نتایج نشان داد که مدل ترکیبی ANFIS-DE می‌تواند به عنوان یک روش امیدوارکننده و مقرون‌به‌صرفه برای شناسایی کارآمد مناطق منبع گرد و غبار مورد استفاده قرار گیرد. رضوی و همکاران (۲۰۲۳) در پژوهشی نشان دادند که مدل‌های یادگیری ماشین گروهی که توسط الگوریتم‌های تکاملی تقویت شده‌اند مانند جنگل تصادفی با تکامل تفاضلی، دقت بالایی در نقشه‌برداری استعداد گرد و غبار نشان می‌دهند. نتایج پژوهش ما و همکاران (۲۰۲۲) نشان داد که الگوریتم چرخه آب برای بهینه‌سازی پارامتری در زمینه‌های مهندسی موفق عمل کردند. همچنین ابراهیم و همکاران (۲۰۲۲) با ترکیب الگوریتم علف‌های هرز و با مدل‌های یادگیری ماشین به جهت بهینه‌سازی داده‌های ورودی، موفق به تشخیص سریع و دقیق‌تر متورها شدند. در مناطقی که داده‌های آماری کمی وجود دارد و یا داده‌های موجود دقیق نیست، بکارگیری الگوریتم‌های فراابتکاری به‌منظور بهینه‌سازی داده‌های ورودی و رفع مشکل کمبود داده برای افزایش دقت و عملکرد مدل و پیش‌بینی‌ها امری ضروری است. با وجود مطالعات بسیاری که بر روی مدل‌سازی گرد و غبار با رویکردهای فیزیکی، ریاضی و هوش مصنوعی صورت گرفته است اما بررسی نقش الگوریتم‌های فراابتکاری در بهینه‌سازی داده‌های ورودی و بهبود عملکرد مدل‌های هوش مصنوعی بسیار کمرنگ است و اشاره‌ای به تاثیر این الگوریتم‌ها به‌ویژه در مناطقی که با کمبود داده و داده‌های دقیق نظیر استان سیستان و بلوچستان مواجه است، صورت نگرفته است.

این پژوهش با هدف برجسته کردن نقش الگوریتم‌های فراابتکاری در مدل‌سازی طوفان‌های گرد و غبار و مقایسه عملکرد مدل‌سازی‌ها با بهره‌گیری از

7. Convolutional Neural Network-Gated Recurrent Unit

8. Dense Layer Deep Learning-Random Forest

1. Support Vector Machine

2. Metaheuristic Algorithms

3. Genetic Algorithms

4. Particle Swarm Optimization

5. Bat Algorithm

6. Cultural Algorithms

7. Differential Evolution


مواد و روش‌ها

منطقه مورد مطالعه: داده‌های مورد استفاده شامل فراوانی روزهای همراه با طوفان گردوغبار (FDSD) در پنج ایستگاه سینوپتیکی استان سیستان و بلوچستان طی بازه زمانی ۴۰ ساله بود. برای تحلیل نقش خشکسالی و حافظه زمانی سامانه از شاخص‌های SPI و SPEI استفاده شد و حساسیت و کارایی مدل با معیارهای ارزیابی (R, RMSE, MAE, NS) سنجیده شد.

الگوریتم‌های فرا ابتکاری (IWO) و (WCA) به منظور بهینه‌سازی داده‌های ورودی صورت گرفته است. این مدل ضمن ادغام قابلیت‌های تحلیل فازی و میانگین متحرک، با بهینه‌سازی ورودی‌های کلیدی از طریق الگوریتم‌های فرا ابتکاری، گامی در جهت کاهش عدم قطعیت مدل‌ها و بهبود کارایی در مناطقی که کمبود داده دقیق مانند استان سیستان و بلوچستان وجود دارد برمی‌دارد.

جدول ۱: فراوانی روزهای همراه با طوفان‌های گردوغبار استان سیستان و بلوچستان (۱۹۸۰-۲۰۲۰)

ایستگاه	عرض جغرافیایی (درجه)	طول جغرافیایی (درجه)	ارتفاع از سطح دریا (متر)	میانگین فصلی FDSD (روز)	FDSD (روز)
سراوان	۲۷/۲۰	۶۲/۲۰	۱۱۹۵	۱/۰۶	۱۰۶
خاش	۲۸/۱۳	۶۱/۱۲	۱۳۹۴	۱/۸۰	۱۸۰
ایران‌شهر	۲۷/۱۲	۶۰/۴۲	۵۹۱	۲/۱۱	۲۱۱
زاهدان	۲۹/۲۸	۶۰/۵۳	۱۳۷۰	۳/۱۴	۳۱۴
زابل	۳۱/۲۰	۶۱/۲۹	۴۸۹	۷/۱۱	۷۱۱



شکل ۱. معرفی منطقه و پهنه‌بندی شاخص FDSD در ایستگاه‌های مورد مطالعه

شد. بخش فازی بر پایه الگوریتم خوشه‌بندی فازی-c-means بنا شده و تابع هدف آن به صورت رابطه ۱ نوشته می‌شود: (Ravanbakhsh, 2022):

$$Jq(\mu, V, X) = \sum_{i=1}^c \sum_{j=1}^n (\mu_{i,j})^q D_{i,j}^2 \quad (1)$$

که در آن n و j تعداد داده‌ها، c تعداد خوشه‌ها، μ ماتریس عضویت فازی، V بردار مرکز خوشه‌ها، q عدد

مدل هیبریدی FCMR-MA به منظور پیش‌بینی شاخص FDSD: برای مدل‌سازی رابطه بین ورودی‌های اقلیمی و فراوانی روزهای گردوغبار از یک مدل ترکیبی مبتنی بر رگرسیون خوشه‌بندی‌شده فازی (FCMR) و میانگین متحرک (MA)^۲ استفاده

1. Fuzzy C-Means Regression
2. Moving Average

حقیقی مثبت و $D_{i,j}^2$ فاصله بین داده i و مرکز خوشه j می‌باشد (Bezdek, 1984).

بخش میانگین متحرک برای گرفتن اثر نوسانات تصادفی و تکانه‌های کوتاه‌مدت به کار رفت (Zeng, 2024). در مدل میانگین متحرک Y_t به خطاهای تصادفی که در پی نویزهای سفید رخ میدهند بستگی دارد که در رابطه ۲ نشان داده شده است:

$$Y_t = f(\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \varepsilon_{t-3} \dots \varepsilon_{t-1}) \quad (2)$$

یک نمایش رایج از یک مدل میانگین متحرک که در آن Y_t به q از بستگی دارد مقادیر گذشته آن مدل $MA(q)$ نامیده می‌شود و در رابطه ۳ نشان داده شده است:

(۳)

$Y_t = \beta_0 + \varepsilon_t + \phi \varepsilon_{t-1} + \phi \varepsilon_{t-2} + \phi \varepsilon_{t-3} + \dots + \phi^q \varepsilon_{t-q}$
عبارات خطا ε_t به عنوان فرآیندهای نویز سفید^۱ با میانگین صفر و واریانس σ^2 در نظر گرفته می‌شوند (Ivanovski, 2018).

الگوریتم‌های بهینه‌سازی WCA و IWO

الگوریتم بهینه‌سازی چرخه آب (WCA): الگوریتمی مبتنی بر شبیه‌سازی چرخه هیدرولوژیک است که از جریان آب الهام گرفته شده و برای کاوش فضای جستجو و جلوگیری از همگرایی زودرس طراحی شده است (Hanafi, 2021) و (Ghosh, 2020). در ساختار پیاده‌سازی این پژوهش، جمعیت اولیه به صورت روابط ۴ و ۵ محاسبه میگردد:

$$N_{sr} = \text{Number of rivers} + 1 (\text{Sea}) \quad (4)$$

$$N_{\text{Streams}} = N_{\text{pop}} + N_{sr} \quad (5)$$

که در آن N_{pop} تعداد جمعیت نخستین قطرات باران، Sea به عنوان بهترین پاسخ، N_{sr} تعدادی از بهترین پاسخ‌ها و N_{Streams} به عنوان بقیه قطرات آب ممکن است به بهترین پاسخ در صورت لزوم اضافه شوند (Kardan, 2024).

الگوریتم بهینه‌سازی علف‌های هرز (IWO): بر اساس مدل رشد و تکثیر بذر گیاهان عمل می‌کند و مکانیزم آن موجب جستجوی مؤثر محلی و سراسری در فضای پارامتری می‌شود (Ranjbar, 2017).

فرمول تعیین تعداد بذر تولیدی توسط هر عضو به صورت رابطه ۶ به کار گرفته شد: (Kakkar, 2021):

$$Seed_n = \frac{f - f_{min}}{f_{max} - f_{min}} (S_{max} - S_{min}) \quad (6)$$

$Seed_n$ تعداد بذرهای تولید شده، f تابع هدف در تکرار فعلی، f_{min} کم‌ترین مقدار هدف در تکرار فعلی، f_{max} بیش‌ترین مقدار هدف در تکرار فعلی، S_{min} حداقل مقدار تولید دانه ممکن و S_{max} حداکثر مقدار تولید دانه ممکن است.

SPI: شاخص بُنیادی بارندگی است که نوسانات بارش را در بازه‌های زمانی ۱-۴۸ ماهه منعکس می‌کند (Saravi et al., 2017). محاسبه SPI مطابق رابطه ۷ و طبقه‌بندی شدت آن در جدول ۲ ارائه شده است:

$$SPI = \frac{X_{ik} - \bar{X}_l}{\delta i} \quad (7)$$

که SPI شاخص بارش استاندارد، δi انحراف معیار داده‌های i ایستگاه، X_{ik} مقادیر بارندگی برای تعداد ایستگاه‌های بارندگی i و تعداد مشاهدات (k) و $\bar{X}_l$ متوسط بارندگی ایستگاه‌های سینوپتیک را نشان می‌دهد.

SPEI: SPEI با در نظر گرفتن تراز آبی بارش منهای اثرات دمایی و تبخیر-تعرق بالقوه را پوشش می‌دهد و برای سناریوهای متاثر از تغییر اقلیم مناسب‌تر است (Javadian et al., 2019). با در نظر گرفتن تبخیر و تعرق پتانسیل PET، تفاوت بین بارندگی P و تبخیر و تعرق پتانسیل برای ماه i به صورت رابطه ۸ محاسبه میگردد:

$$D_i = P_i - PET_i \quad (8)$$

مقادیر D در مقیاس‌های زمانی مختلف از رابطه ۹ محاسبه می‌شود:

$$D_n^k = \sum_{n=0}^{K-1} P_{n-1} - PET_{n-i} \quad (9)$$

که k ماه‌ها مقیاس زمانی مورد نظر و n ماه مورد نظر در محاسبه می‌باشد.

در جدول ۳، طبقه‌بندی SPEI در وضعیت‌های

مختلف نشان داده شده است.

جدول ۲: کلاس‌بندی خشکسالی بر اساس شاخص بارش استاندارد شده (مک کی و همکاران، ۱۹۹۳)

وضعیت	SPI
ترسالی خیلی شدید	بیشتر از ۲
ترسالی شدید	۱/۵ تا ۲
ترسالی متوسط	۱ تا ۱/۵
ترسالی ملایم	۰ تا ۱
خشکسالی ملایم	۰ تا -۱
خشکسالی متوسط	-۱/۵ تا -۱
خشکسالی شدید	-۲ تا -۱/۵
خشکسالی خیلی شدید	کمتر از -۲

جدول ۳: طبقه بندی SPEI

وضعیت	SPEI
ترسالی خیلی شدید	بیشتر از ۲
ترسالی شدید	۱/۹۹ تا ۱/۵
ترسالی ملایم	۱ تا ۱/۴۹
نرمال	۰/۹۹ تا -۰/۹۹
خشکسالی ملایم	-۱ تا -۱/۴۹
خشکسالی شدید	-۱/۵ تا -۱/۹۹
خشکسالی خیلی شدید	کمتر از -۲

حالت‌ها و مدل‌های پیش‌بینی: برای بررسی تأثیر

حافظه زمانی و به‌کارگیری شاخص‌ها چهار حالت مدل‌سازی تعریف شد (تا چهار گام تأخیر فصلی):

حالت ۱ FCMR-MA: با ورودی تنها از FDS_D مدل با یک گام تأخیر.

حالت ۲ FCMR-MA: با FDS_D گذشته و شاخص‌های خشکسالی (SPEI, SPI) در بازه‌های ۳، ۶، ۹ و ۱۲ ماه.

حالت ۳ FCMR-MA: با بهینه‌سازی ورودی‌ها بوسیله WCA.

حالت ۴ FCMR-MA: با بهینه‌سازی ورودی‌ها بوسیله IWO.

نمایش عمومی روابط در حالت‌های با تأخیر به‌صورت مدل‌های ۱ تا ۷ است:

مدل ۱

$$FDS_{D(t+1)} = f(FDS_{D(t)})$$

مدل ۲

$$FDS_{D(t+1)} = f(FDS_{D(t)}, FDS_{D(t-1)})$$

مدل ۳

$$FDS_{D(t+1)} = f(FDS_{D(t)}, FDS_{D(t-1)}, FDS_{D(t-2)})$$

مدل ۴

$$\begin{aligned} \llbracket FDS_{D(t+1)} \rrbracket = f(\llbracket FDS_{D(t)} \rrbracket, \llbracket FDS_{D(t-1)} \rrbracket, \llbracket FDS_{D(t-2)} \rrbracket, \\ \llbracket FDS_{D(t-3)} \rrbracket, \llbracket FDS_{D(t-4)} \rrbracket, \llbracket FDS_{D(t-5)} \rrbracket, \llbracket FDS_{D(t-6)} \rrbracket, \llbracket FDS_{D(t-7)} \rrbracket, \\ \llbracket FDS_{D(t-8)} \rrbracket, \llbracket FDS_{D(t-9)} \rrbracket, \llbracket FDS_{D(t-10)} \rrbracket, \llbracket FDS_{D(t-11)} \rrbracket, \llbracket FDS_{D(t-12)} \rrbracket) \end{aligned}$$

مدل توسعه‌یافته با شاخص‌های خشکسالی

مدل ۵

$$\begin{aligned} \llbracket FDS_{D(t+1)} \rrbracket = f(\llbracket FDS_{D(t)} \rrbracket, \llbracket FDS_{D(t-1)} \rrbracket, \llbracket FDS_{D(t-2)} \rrbracket, \llbracket FDS_{D(t-3)} \rrbracket, \\ \llbracket FDS_{D(t-4)} \rrbracket, \llbracket FDS_{D(t-5)} \rrbracket, \llbracket FDS_{D(t-6)} \rrbracket, \llbracket FDS_{D(t-7)} \rrbracket, \llbracket FDS_{D(t-8)} \rrbracket, \\ \llbracket FDS_{D(t-9)} \rrbracket, \llbracket FDS_{D(t-10)} \rrbracket, \llbracket FDS_{D(t-11)} \rrbracket, \llbracket FDS_{D(t-12)} \rrbracket, \llbracket SPI(t) \rrbracket, \\ \llbracket SPEI(t) \rrbracket, \llbracket SPI(t-1) \rrbracket, \llbracket SPEI(t-1) \rrbracket, \llbracket SPI(t-2) \rrbracket, \llbracket SPEI(t-2) \rrbracket, \llbracket SPI(t-3) \rrbracket, \\ \llbracket SPEI(t-3) \rrbracket, \llbracket SPI(t-4) \rrbracket, \llbracket SPEI(t-4) \rrbracket, \llbracket SPI(t-5) \rrbracket, \llbracket SPEI(t-5) \rrbracket, \llbracket SPI(t-6) \rrbracket, \\ \llbracket SPEI(t-6) \rrbracket, \llbracket SPI(t-7) \rrbracket, \llbracket SPEI(t-7) \rrbracket, \llbracket SPI(t-8) \rrbracket, \llbracket SPEI(t-8) \rrbracket, \llbracket SPI(t-9) \rrbracket, \\ \llbracket SPEI(t-9) \rrbracket, \llbracket SPI(t-10) \rrbracket, \llbracket SPEI(t-10) \rrbracket, \llbracket SPI(t-11) \rrbracket, \llbracket SPEI(t-11) \rrbracket, \llbracket SPI(t-12) \rrbracket, \\ \llbracket SPEI(t-12) \rrbracket) \end{aligned}$$

که در آن m نشان‌دهنده بازه‌های ۳، ۶، ۹ و ۱۲ ماهه است.

مدل‌های پایه بر اساس تأخیر

مدل بهینه‌سازی شده با الگوریتم‌های چرخه آب و علف‌های هرز

مدل ۶

$$FDSD_{(t+1)} = f_{IWO} (FDSD_{(t)} \dots FDSD_{(t-k)})$$

مدل ۷

$$FDSD_{(t+1)} = f_{WCA} (FDSD_{(t)} \dots FDSD_{(t-k)})$$

در روابط فوق k بیانگر تعداد گام‌های تأخیر زمانی در داده‌های شاخص $FDSD$ است.

معیارهای ارزیابی: برای سنجش کارایی مدل‌ها، از چهار معیار ارزیابی یعنی ضریب همبستگی (R)، جذرمیانگین مربعات خطا ($RMSE$)، میانگین قدرمطلق خطا (MAE) و نش ساتکلیف (NS) استفاده شد. این معیارها به صورت روابط ۱۰ تا ۱۳ تعریف می‌شوند:

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}} \quad -1 \leq R < 1 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad 0 \leq RMSE < \infty \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^N |x_i - y_i| \quad 0 \leq MAE < \infty \quad (12)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad -\infty < NS \leq 1 \quad (13)$$

در روابط ۱۰ تا ۱۳، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام‌های زمانی i ام، N تعداد گام‌های زمانی، و $\bar{x}$ و $\bar{y}$ به ترتیب میانگین مقادیر مشاهداتی و محاسباتی است (Zhou et al., 2007). نمودار جریانی پژوهش حاضر در شکل ۲ نمایش داده شده است.



شکل ۲- مراحل توسعه و ارزیابی مدل هیبریدی FCMR-MA در پیش‌بینی طوفان‌های گردوغبار

نتایج و بحث

تحلیل آماری داده‌های ۲۵ ساله نشان داد که پراکنش مکانی طوفان‌های گردوغبار در استان سیستان و بلوچستان به شدت ناهمگن است. ایستگاه زابل با بیشترین تعداد روزهای طوفانی، به عنوان کانون اصلی رخداد شناخته شد. این نتیجه بی‌ارتباط با موقعیت جغرافیایی خاص زابل نیست؛ جایی که در معرض بادهای ۱۲۰ روزه قرار دارد و همچنین در مجاورت منابع بیابانی افغانستان واقع شده است. به علاوه، خشکیدگی دریاچه هامون و تغییر کاربری اراضی کشاورزی در این منطقه، کانون‌های جدیدی از گردوغبار ایجاد کرده‌اند که وقوع طوفان‌ها را تشدید کرده است. در مقابل، ایستگاه سراوان که در جنوب شرقی استان قرار دارد و تا حدودی تحت تأثیر پوشش گیاهی و شرایط کوهستانی است، کمترین میزان طوفان را ثبت کرده است. این اختلاف بار دیگر تأکید می‌کند که عوامل محلی نظیر توپوگرافی و پوشش زمین و عوامل فرامرزی مانند خشکسالی و کمبود حق‌آبه در بالادست، هر دو در شدت پدیده نقش تعیین‌کننده دارند. این یافته مشابه پژوهش شعاعی و همکاران (۲۰۲۰) است که نقش عوامل محلی و فرامرزی را در رخداد طوفان‌های سیستان بررسی کرده بودند. مقایسه چهار حالت زمانی نشان داد که مدل با چهار گام تأخیر بالاترین دقت را دارد. در واقع، استفاده از اطلاعات چهار فصل گذشته باعث شد ضریب همبستگی مدل به بیش از ۰/۹۶ برسد. این امر نشان می‌دهد که گردوغبار نه تنها یک پدیده لحظه‌ای، بلکه بازتابی از شرایط اقلیمی و کاربری زمین در گذشته است. برای نمونه، رسوبات ریزدانه‌ای که در اثر یک طوفان روی زمین ته‌نشین می‌شوند، در طوفان‌های بعدی دوباره به هوا برمی‌خیزند و چرخه‌ای تکرارشونده ایجاد می‌کنند. این نتیجه با یافته‌های انصاری قوجقار و پورمحمد (۲۰۲۴) هم‌راستا است که تأکید کردند مدل‌های دارای حافظه بلندمدت قادرند روندهای اقلیمی را بهتر بازنمایی کنند. بنابراین می‌توان نتیجه گرفت که مدل‌های کوتاه‌مدت، گرچه در پیش‌بینی

مقادیر آنی موفق‌اند، اما برای پیش‌بینی فصلی و سالانه نیازمند داده‌های بلندمدت هستند.

جداول ۴ تا ۷ نشان می‌دهد که مدل پایه-FCMR-MA بدون بهینه‌سازی، دقت قابل قبولی در پیش‌بینی شاخص روزهای همراه با گردوغبار داشته است اما همچنان خطاهای نسبی بالایی در برخی ایستگاه‌ها مشاهده می‌شود. افزودن تمام شاخص‌های خشکسالی SPI و SPEI به مدل، بهبود چشمگیری در همبستگی و کاهش خطا ایجاد نکرده و در مقیاس‌های زمانی موجب افت نتایج شده است. این موضوع بیانگر آن است که اگرچه خشکسالی یکی از عوامل مهم بروز گردوغبار است اما ورود مستقیم شاخص‌های اقلیمی به مدل لزوماً باعث بهبود معنادار عملکرد پیش‌بینی نمی‌شود. بهینه‌سازی داده‌های ورودی با الگوریتم‌های فراابتکاری موجب کاهش چشمگیر خطاهای مدل شد. در بین الگوریتم‌ها، IWO بهترین عملکرد را داشت و توانست در ایستگاه زابل مقدار NS را نزدیک به ۰/۹۶ ثبت کند. این در حالی است که الگوریتم WCA نیز عملکرد مناسبی داشت اما همبستگی آن در برخی ایستگاه‌ها اندکی کمتر بود. علت این تفاوت را می‌توان در ماهیت جستجوی الگوریتم‌ها دانست. IWO به دلیل داشتن مکانیسم رقابتی و تکثیر تدریجی، توانایی بیشتری در پرهیز از گیر افتادن در نقاط بهینه محلی دارد، در حالی که WCA در برخی مواقع دچار همگرایی زودرس می‌شود. این یافته مشابه مطالعه الموفتی و همکاران (۲۰۲۳) است که نشان دادند IWO در مسائل غیرخطی پیچیده دقت بالاتری دارد. این نتایج همچنین نشان داد که استفاده از شاخص‌های خشکسالی به منظور پیش‌بینی شاخص FDSD، باعث کاهش محسوس دقت پیش‌بینی‌ها و همچنین افزایش چشمگیر خطاها می‌شود. جداول ۴ تا ۷ که معیارهای R، RMSE، MAE و NS را برای حالت‌های مختلف ارائه می‌دهند، به وضوح نشان می‌دهند که با افزایش گام تأخیر و استفاده از الگوریتم IWO، دقت مدل به طور پیوسته افزایش یافته است. برای مثال، در ایستگاه زابل ضریب همبستگی از ۰/۸ در حالت پایه به بیش از ۰/۹۴ در حالت بهینه‌شده با

IWO ارتقاء یافته است. چنین بهبودی در مقیاس مدل‌سازی اقلیمی بسیار معنادار است. در ایستگاه سراوان نیز هرچند مقدار شاخص‌ها پایین‌تر است اما بهینه‌سازی داده‌ها همچنان منجر به کاهش خطای RMSE از حدود ۰/۳۶۹ به ۰/۲۹۳ شده است. این امر نشان می‌دهد که حتی در شرایط داده‌های محدود، الگوریتم‌های فراابتکاری توانایی بهبود نتایج را دارند، هرچند کیفیت داده‌های اولیه همچنان عامل اصلی باقی می‌ماند.

جدول ۴: معیارهای ارزیابی محاسبه شده مدل FCMR-MA برای پیش‌بینی شاخص FDS

ایستگاه	مدل بهینه	داده‌های آزمایشی				داده‌های آموزشی			
		NS	MAE	RMSE	R	NS	MAE	RMSE	R
زابل	۴	۰/۸۰۳	۰/۳۵۴	۰/۳۳۱	۰/۸۵۹	۰/۸۴۷	۰/۳۱۸	۰/۳۰۵	۰/۸۸۲
	۳	۰/۸۰۱	۰/۳۵۵	۰/۳۲۹	۰/۸۵۸	۰/۸۴۸	۰/۳۱۷	۰/۳۰۴	۰/۸۸۱
	۲	۰/۷۹۹	۰/۳۵۷	۰/۳۲۸	۰/۸۵۶	۰/۸۴۶	۰/۳۱۵	۰/۳۰۳	۰/۸۷۸
	۱	۰/۷۹۸	۰/۳۵۹	۰/۳۲۷	۰/۸۵۴	۰/۸۴۳	۰/۳۱۳	۰/۳۰۲	۰/۸۷۵
زاهدان	۴	۰/۷۹۹	۰/۳۵۹	۰/۳۲۹	۰/۸۵۸	۰/۸۴۷	۰/۳۱۶	۰/۳۰۴	۰/۸۸۱
	۳	۰/۷۹۸	۰/۳۶۱	۰/۳۲۵	۰/۸۵۶	۰/۸۴۵	۰/۳۱۴	۰/۳۰۲	۰/۸۷۹
	۲	۰/۷۹۷	۰/۳۶۳	۰/۳۳۳	۰/۸۵۵	۰/۸۴۴	۰/۳۱۲	۰/۳۰۱	۰/۸۷۶
	۱	۰/۷۹۶	۰/۳۶۴	۰/۳۲۱	۰/۸۵۳	۰/۸۴۲	۰/۳۱۱	۰/۲۹۹	۰/۸۷۴
خاش	۴	۰/۷۹۸	۰/۳۶۱	۰/۳۲۸	۰/۸۵۶	۰/۸۶۴	۰/۳۱۴	۰/۳۰۳	۰/۸۷۹
	۳	۰/۷۹۷	۰/۳۶۲	۰/۳۲۶	۰/۸۵۴	۰/۸۴۳	۰/۳۱۳	۰/۲۹۸	۰/۸۷۷
	۲	۰/۷۹۵	۰/۳۶۵	۰/۳۲۵	۰/۸۵۱	۰/۸۴۱	۰/۳۱۱	۰/۲۹۶	۰/۸۷۵
	۱	۰/۷۹۴	۰/۳۶۷	۰/۳۲۴	۰/۸۴۸	۰/۸۳۹	۰/۳۱۰	۰/۲۹۵	۰/۸۷۳
ایرانشهر	۴	۰/۷۹۶	۰/۳۶۲	۰/۳۲۵	۰/۸۵۴	۰/۸۴۵	۰/۳۱۳	۰/۳۰۲	۰/۸۷۷
	۳	۰/۷۹۵	۰/۳۶۳	۰/۳۲۱	۰/۸۵۱	۰/۸۴۴	۰/۳۰۹	۰/۲۹۶	۰/۸۷۵
	۲	۰/۷۹۳	۰/۳۶۶	۰/۳۱۹	۰/۸۴۹	۰/۸۳۹	۰/۳۰۹	۰/۲۹۵	۰/۸۷۴
	۱	۰/۷۹۱	۰/۳۶۸	۰/۳۱۷	۰/۸۴۶	۰/۸۳۷	۰/۳۰۸	۰/۲۹۴	۰/۸۷۱
سراوان	۴	۰/۷۹۴	۰/۳۶۴	۰/۳۲۴	۰/۸۵۲	۰/۸۴۳	۰/۳۱۱	۰/۳۰۱	۰/۸۷۶
	۳	۰/۷۹۳	۰/۳۶۵	۰/۳۲۳	۰/۸۴۵	۰/۸۴۲	۰/۳۰۷	۰/۲۹۳	۰/۸۷۴
	۲	۰/۷۹۲	۰/۳۶۷	۰/۳۲۲	۰/۸۴۳	۰/۸۳۸	۰/۳۰۶	۰/۲۹۱	۰/۸۷۳
	۱	۰/۷۸۹	۰/۳۶۹	۰/۳۱۸	۰/۸۴۱	۰/۸۳۶	۰/۳۰۵	۰/۲۸۹	۰/۸۶۹

جدول ۵: معیارهای ارزیابی محاسبه شده شاخص‌های خشکسالی SPI و SPEI همراه مدل FCMR-MA برای پیش‌بینی شاخص FDS

ایستگاه	مدل بهینه	داده‌های آزمایشی				داده‌های آموزشی			
		NS	MAE	RMSE	R	NS	MAE	RMSE	R
زابل	۴	۰/۶۵۳	۰/۴۷۵	۰/۳۷۱	۰/۷۲۱	۰/۶۸۷	۰/۴۵۶	۰/۳۵۵	۰/۷۸۹
	۳	۰/۶۵۱	۰/۴۷۶	۰/۳۷۲	۰/۷۱۹	۰/۶۸۶	۰/۴۵۷	۰/۳۵۷	۰/۷۸۷
	۲	۰/۶۴۸	۰/۴۷۷	۰/۳۷۳	۰/۷۱۶	۰/۶۸۵	۰/۴۵۹	۰/۳۵۸	۰/۷۸۶
	۱	۰/۶۴۶	۰/۴۷۹	۰/۳۷۳	۰/۷۱۵	۰/۶۸۴	۰/۴۶۲	۰/۳۶۱	۰/۷۸۴
زاهدان	۴	۰/۶۵۱	۰/۴۷۷	۰/۳۷۲	۰/۷۱۸	۰/۶۸۵	۰/۴۶۱	۰/۳۵۶	۰/۷۸۶
	۳	۰/۶۴۹	۰/۴۷۹	۰/۳۷۵	۰/۷۱۷	۰/۶۸۳	۰/۴۶۳	۰/۳۵۹	۰/۷۸۳
	۲	۰/۶۴۷	۰/۴۸۱	۰/۳۷۶	۰/۷۱۶	۰/۶۸۱	۰/۴۶۵	۰/۳۶۲	۰/۷۸۱
	۱	۰/۶۴۳	۰/۴۸۳	۰/۳۷۶	۰/۷۱۳	۰/۶۷۹	۰/۴۶۸	۰/۳۶۳	۰/۷۷۹
خاش	۴	۰/۶۴۶	۰/۴۷۹	۰/۳۷۳	۰/۷۱۶	۰/۶۸۲	۰/۴۶۴	۰/۳۵۸	۰/۷۸۴

۰/۷۸۱	۰/۳۶۱	۰/۴۶۶	۰/۶۸۱	۰/۷۱۴	۰/۳۷۷	۰/۴۸۱	۰/۶۴۵	۳	ایران شهر
۰/۷۷۹	۰/۳۶۴	۰/۴۶۶	۰/۶۷۹	۰/۷۱۲	۰/۳۷۹	۰/۴۸۴	۰/۶۴۲	۲	
۰/۷۷۸	۰/۳۶۶	۰/۴۶۷	۰/۶۷۷	۰/۷۱۱	۰/۳۸۱	۰/۴۸۵	۰/۶۳۹	۱	
۰/۷۸۲	۰/۳۶۲	۰/۴۶۶	۰/۶۷۹	۰/۷۱۴	۰/۳۷۴	۰/۴۸۲	۰/۶۴۴	۴	
۰/۷۷۸	۰/۳۶۳	۰/۴۶۸	۰/۶۷۷	۰/۷۱۱	۰/۳۷۸	۰/۴۸۳	۰/۶۴۳	۳	
۰/۷۷۵	۰/۳۶۵	۰/۴۶۹	۰/۶۷۵	۰/۷۰۹	۰/۳۸۲	۰/۴۸۵	۰/۶۴۳	۲	
۰/۷۷۳	۰/۳۶۷	۰/۴۷۱	۰/۶۷۴	۰/۷۰۷	۰/۳۸۳	۰/۴۸۷	۰/۶۴۱	۱	سراوان
۰/۷۸۱	۰/۳۶۴	۰/۴۶۸	۰/۶۷۷	۰/۷۱۲	۰/۳۷۵	۰/۴۸۴	۰/۶۴۲	۴	
۰/۷۷۶	۰/۳۶۸	۰/۴۷۱	۰/۶۷۵	۰/۷۰۸	۰/۳۷۹	۰/۴۸۶	۰/۶۴۱	۳	
۰/۷۷۴	۰/۳۶۹	۰/۴۷۳	۰/۶۷۳	۰/۷۰۶	۰/۳۸۳	۰/۴۸۸	۰/۶۳۹	۲	
۰/۷۷۱	۰/۳۷۱	۰/۴۷۵	۰/۶۷۱	۰/۷۰۵	۰/۳۸۴	۰/۴۸۹	۰/۶۳۷	۱	

جدول ۶: معیارهای ارزیابی محاسبه شده مدل FCMR-MA و الگوریتم فرا ابتکاری WCO

ایستگاه	مدل بهینه	داده‌های آزمایشی				داده‌های آموزشی			
		NS	MAE	RMSE	R	NS	MAE	RMSE	R
زابل	۴	۰/۹۵۴	۰/۲۰۳	۰/۲۵۵	۰/۹۴۱	۰/۹۳۵	۰/۲۳۳	۰/۲۸۱	۰/۹۲۱
	۳	۰/۹۵۳	۰/۲۰۴	۰/۲۵۶	۰/۹۳۹	۰/۹۳۴	۰/۲۳۴	۰/۲۸۲	۰/۹۱۹
	۲	۰/۹۵۲	۰/۲۰۵	۰/۲۵۹	۰/۹۳۷	۰/۹۳۳	۰/۲۳۵	۰/۲۸۳	۰/۹۱۸
	۱	۰/۹۵۲	۰/۲۰۶	۰/۲۶۱	۰/۹۳۶	۰/۹۳۱	۰/۲۳۷	۰/۲۸۴	۰/۹۱۷
زاهدان	۴	۰/۹۵۳	۰/۲۰۴	۰/۲۵۶	۰/۹۳۸	۰/۹۳۴	۰/۲۳۴	۰/۲۸۲	۰/۹۲۰
	۳	۰/۹۵۱	۰/۲۰۷	۰/۲۵۷	۰/۹۳۶	۰/۹۳۳	۰/۲۳۶	۰/۲۸۴	۰/۹۱۷
	۲	۰/۹۴۹	۰/۲۰۸	۰/۲۶۱	۰/۹۳۴	۰/۹۳۲	۰/۲۳۸	۰/۲۸۵	۰/۹۱۶
	۱	۰/۹۴۸	۰/۲۱۱	۰/۲۶۳	۰/۹۳۳	۰/۹۳۲	۰/۲۳۹	۰/۲۸۶	۰/۹۱۵
خاش	۴	۰/۹۵۲	۰/۲۰۵	۰/۲۵۸	۰/۹۳۶	۰/۹۳۳	۰/۲۳۵	۰/۲۸۳	۰/۹۱۹
	۳	۰/۹۵۰	۰/۲۰۸	۰/۲۵۹	۰/۹۳۵	۰/۹۳۱	۰/۲۳۷	۰/۲۸۵	۰/۹۱۵
	۲	۰/۹۴۸	۰/۲۰۹	۰/۲۶۲	۰/۹۳۳	۰/۹۲۹	۰/۲۳۹	۰/۲۸۷	۰/۹۱۴
	۱	۰/۹۴۷	۰/۲۱۲	۰/۲۶۵	۰/۹۳۱	۰/۹۲۷	۰/۲۴۱	۰/۲۸۹	۰/۹۱۳
ایران شهر	۴	۰/۹۵۱	۰/۲۰۶	۰/۲۵۹	۰/۹۳۵	۰/۹۳۲	۰/۲۳۶	۰/۲۸۴	۰/۹۱۸
	۳	۰/۹۴۹	۰/۲۰۹	۰/۲۶۱	۰/۹۳۴	۰/۹۲۹	۰/۲۳۸	۰/۲۸۶	۰/۹۱۳
	۲	۰/۹۴۷	۰/۲۱۳	۰/۲۶۳	۰/۹۳۲	۰/۹۲۸	۰/۲۴۲	۰/۲۸۹	۰/۹۱۲
	۱	۰/۹۴۶	۰/۲۱۵	۰/۲۶۶	۰/۹۲۹	۰/۹۲۶	۰/۲۴۴	۰/۲۹۱	۰/۹۱۱
سراوان	۴	۰/۹۴۹	۰/۲۰۷	۰/۲۶۱	۰/۹۳۳	۰/۹۳۱	۰/۲۳۷	۰/۲۸۵	۰/۹۱۷
	۳	۰/۹۴۸	۰/۲۱۱	۰/۲۶۲	۰/۹۳۲	۰/۹۲۶	۰/۲۳۹	۰/۲۸۶	۰/۹۱۲
	۲	۰/۹۴۵	۰/۲۱۴	۰/۲۶۴	۰/۹۳۱	۰/۹۲۵	۰/۲۴۳	۰/۲۹۱	۰/۹۱۱
	۱	۰/۹۴۳	۰/۲۱۸	۰/۲۶۷	۰/۹۲۸	۰/۹۲۳	۰/۲۴۵	۰/۲۹۳	۰/۹۰۹

جدول ۷: معیارهای ارزیابی محاسبه شده مدل FCMR-MA و الگوریتم فراابتکاری IWO


ایستگاه	مدل بهینه	داده‌های آزمایشی				داده‌های آموزشی			
		NS	MAE	RMSE	R	NS	MAE	RMSE	R
زابل	۴	۰/۹۴۸	۰/۱۸۴	۰/۱۳۵	۰/۹۵۸	۰/۹۷۳	۰/۱۴۳	۰/۱۰۳	۰/۹۸۷
	۳	۰/۹۴۷	۰/۱۸۵	۰/۱۳۶	۰/۹۵۷	۰/۹۷۲	۰/۱۴۴	۰/۱۰۵	۰/۹۸۶
	۲	۰/۹۴۶	۰/۱۸۷	۰/۱۳۷	۰/۹۵۵	۰/۹۶۹	۰/۱۴۶	۰/۱۰۷	۰/۹۸۶
	۱	۰/۹۴۴	۰/۱۸۸	۰/۱۳۹	۰/۹۵۴	۰/۹۶۸	۰/۱۴۸	۰/۱۰۸	۰/۹۸۵
زاهدان	۴	۰/۹۴۷	۰/۱۸۵	۰/۱۳۶	۰/۹۵۷	۰/۹۷۲	۰/۱۴۵	۰/۱۰۴	۰/۹۸۵
	۳	۰/۹۴۶	۰/۱۸۶	۰/۱۳۸	۰/۹۵۶	۰/۹۷۱	۰/۱۴۷	۰/۱۰۶	۰/۹۸۴
	۲	۰/۹۴۵	۰/۱۸۸	۰/۱۴۱	۰/۹۵۵	۰/۹۶۷	۰/۱۴۹	۰/۱۰۸	۰/۹۸۳
	۱	۰/۹۴۳	۰/۱۸۹	۰/۱۴۲	۰/۹۵۳	۰/۹۶۵	۰/۱۵۱	۰/۱۰۹	۰/۹۸۲
خاش	۴	۰/۹۴۵	۰/۱۸۶	۰/۱۳۷	۰/۹۵۵	۰/۹۷۱	۰/۱۴۶	۰/۱۰۵	۰/۹۸۴
	۳	۰/۹۴۴	۰/۱۸۷	۰/۱۳۹	۰/۹۵۳	۰/۹۶۹	۰/۱۴۸	۰/۱۰۷	۰/۹۸۲
	۲	۰/۹۴۲	۰/۱۹۱	۰/۱۴۳	۰/۹۴۹	۰/۹۶۶	۰/۱۵۲	۰/۱۱۱	۰/۹۸۱
	۱	۰/۹۴۱	۰/۱۹۳	۰/۱۴۴	۰/۹۴۷	۰/۹۶۴	۰/۱۵۴	۰/۱۱۴	۰/۹۷۹
ایران‌شهر	۴	۰/۹۴۴	۰/۱۸۸	۰/۱۳۹	۰/۹۵۴	۰/۹۷۰	۰/۱۴۷	۰/۱۰۷	۰/۹۸۳
	۳	۰/۹۴۳	۰/۱۹۲	۰/۱۴۱	۰/۹۵۲	۰/۹۶۸	۰/۱۴۹	۰/۱۰۹	۰/۹۸۱
	۲	۰/۹۴۰	۰/۱۹۴	۰/۱۴۴	۰/۹۴۸	۰/۹۶۵	۰/۱۵۳	۰/۱۱۳	۰/۹۷۷
	۱	۰/۹۳۹	۰/۱۹۶	۰/۱۴۶	۰/۹۴۶	۰/۹۶۳	۰/۱۵۶	۰/۱۱۵	۰/۹۷۶
سراوان	۴	۰/۹۱۷	۰/۲۸۵	۰/۲۳۷	۰/۹۵۲	۰/۹۶۹	۰/۱۴۹	۰/۱۰۹	۰/۹۸۱
	۳	۰/۹۱۲	۰/۲۸۶	۰/۲۳۹	۰/۹۵۱	۰/۹۶۶	۰/۱۵۱	۰/۱۱۴	۰/۹۷۹
	۲	۰/۹۱۱	۰/۲۹۱	۰/۲۴۳	۰/۹۴۶	۰/۹۶۴	۰/۱۵۴	۰/۱۱۷	۰/۹۷۵
	۱	۰/۹۰۹	۰/۲۹۳	۰/۲۴۵	۰/۹۴۴	۰/۹۶۲	۰/۱۵۷	۰/۱۲۱	۰/۹۷۳

شکل‌های پراکندگی (۲) نشان می‌دهند که نقاط مربوط به مدل IWO تراکم بیشتری در نزدیکی خط همبستگی دارند. این امر به‌ویژه در ایستگاه‌های زابل و زاهدان مشهود است. در مقابل، WCA در برخی ایستگاه‌ها پراکندگی بیشتری داشت که به معنای دقت پایین‌تر مدل در این حالت است. این موضوع اهمیت انتخاب الگوریتم بهینه‌سازی مناسب برای داده‌های اقلیمی را نشان می‌دهد. شکل‌های سری زمانی نیز بیانگر انطباق بالای داده‌های پیش‌بینی‌شده و مشاهده‌ای بودند. به‌ویژه الگوریتم IWO توانست قله‌های شدید را با دقت بالاتری بازسازی کند. این ویژگی از نظر کاربردی اهمیت زیادی دارد زیرا برای سامانه‌های هشدار سریع، شناسایی درست پیک‌ها به‌مراتب مهم‌تر از میانگین کلی است. در واقع قله‌های شدید هستند که بیشترین خسارات اقتصادی و اجتماعی را به منطقه وارد می‌کنند. مقایسه نتایج این

پژوهش با مطالعات پیشین نیز نشان می‌دهد که یافته‌ها در راستای ادبیات روز قرار دارد. برای نمونه، رحمتی و همکاران (۲۰۲۰) نشان دادند که ترکیب ANFIS با الگوریتم تکامل تفاضلی موجب کاهش قابل توجه خطا در پیش‌بینی گردوغبار می‌شود. همچنین غلامی و محمدی‌فر (۲۰۲۰) با بهره‌گیری از مدل‌های هیبریدی یادگیری عمیق، توانستند حساسیت منابع گردوغبار در خاورمیانه را با دقت بالاتری طبقه‌بندی کنند. نتایج این پژوهش که برتری IWO نسبت به WCA در شبیه‌سازی رخداد‌های حدی و بازسازی پیک‌های گردوغبار را نشان می‌دهد، با یافته‌های مشابه در مقالات بین‌المللی درباره برتری این الگوریتم در مسائل غیرخطی همخوانی دارد. این مقایسه نشان می‌دهد که نوآوری اصلی پژوهش حاضر، تمرکز بر بهینه‌سازی ورودی‌ها در شرایط اقلیمی خاص سیستان و بلوچستان است؛ منطقه‌ای که همواره با کمبود

استفاده از داده‌های ماهواره‌ای پرتفیک‌تر، سناریوهای تغییر اقلیم و اعتبارسنجی زمانی چندگانه می‌تواند در تحقیقات آتی موجب افزایش اعتمادپذیری مدل‌ها شود. به‌طور کلی نتایج این پژوهش نشان می‌دهد که بهینه‌سازی ورودی‌ها با الگوریتم‌های فراابتکاری، نه تنها موجب ارتقاء دقت مدل‌های پیش‌بینی گردوغبار می‌شود، بلکه ابزاری ارزشمند برای مدیریت ریسک، کاهش آسیب‌پذیری زیرساخت‌های حیاتی و طراحی سیاست‌های سازگار با تغییر اقلیم به شمار می‌آید.

داده‌های معتبر و ناپایداری اقلیمی مواجهه بوده است. این امر ثابت می‌کند که بهره‌گیری از الگوریتم‌های فراابتکاری در مناطقی که ایستگاه‌های کمی وجود دارد و داده‌های اندک و نامعتبر وجود دارد، به افزایش دقت مدل‌سازی‌ها کمک محسوسی می‌کند. با وجود این دستاوردها، باید به محدودیت‌های این تحقیق نیز توجه داشت. کیفیت داده‌های مشاهداتی، محدودیت در طول دوره آماری و فقدان اطلاعات دقیق کاربری اراضی می‌تواند بر نتایج تأثیرگذار باشد. بنابراین،



شکل ۳- نتایج مقادیر پیش‌بینی شده شاخص FDSD در ایستگاه‌های مورد مطالعه

نتیجه‌گیری

نتایج این پژوهش نشان داد که به‌کارگیری الگوریتم‌های فراابتکاری در فرآیند بهینه‌سازی ورودی‌ها می‌تواند به شکل معناداری دقت مدل‌های پیش‌بینی طوفان‌های گرد و غبار را ارتقاء دهد. مقایسه الگوریتم‌های مورد استفاده نشان دادند که هر دو رویکرد توانایی کاهش خطا و افزایش کارایی مدل هیبریدی FCMR-MA را دارند اما الگوریتم علف‌های هرز مهاجم در دستیابی به همگرایی سریع‌تر و پایداری بیشتر، عملکرد بهتری از خود نشان داد. یافته‌های این تحقیق با برخی مطالعات پیشین همسو است اما تفاوت اصلی آن در تمرکز بر نقش الگوریتم‌های فراابتکاری در شرایط اقلیمی خاص استان سیستان و بلوچستان و در بستر کمبود داده‌های معتبر اقلیمی است. این موضوع، نوآوری اصلی پژوهش حاضر را تشکیل می‌دهد؛ چراکه تاکنون کمتر به مسئله بهینه‌سازی ورودی‌ها در مدل‌سازی گرد و غبار توجه شده بود. با این وجود، محدودیت‌هایی همچون دسترسی محدود به داده‌های بلندمدت و فقدان اطلاعات دقیق کاربری اراضی می‌تواند بر نتایج اثرگذار باشد. از منظر مدیریتی و سیاستی، بهبود پیش‌بینی طوفان‌های گردوغبار می‌تواند نقش تعیین‌کننده‌ای در مدیریت بحران، برنامه‌ریزی شهری، سلامت عمومی و حفاظت از زیرساخت‌های حیاتی داشته باشد. به‌عنوان نمونه، پیش‌بینی دقیق‌تر شدت و زمان وقوع طوفان‌ها، امکان صدور هشدارهای زودهنگام را فراهم می‌کند و می‌تواند به کاهش خسارات اقتصادی و اجتماعی منجر شود. همچنین نتایج این پژوهش می‌تواند به‌عنوان مبنایی برای سیاست‌گذاری در زمینه مدیریت منابع آب، مقابله با تغییر کاربری اراضی و کاهش آسیب‌پذیری مناطق پرخطر مورد استفاده قرار گیرد. بنابراین، پیشنهاد می‌شود در پژوهش‌های آینده با

استفاده از داده‌های ماهواره‌ای پرتفیک‌تر، سناریوهای تغییر اقلیم و الگوریتم‌های ترکیبی جدید مانند رویکردهای تکاملی-یادگیری عمیق، کارایی مدل‌ها بیش از پیش ارزیابی شود و امکان کاربرد عملی مدل‌ها در سطح سیاست‌گذاری و مدیریت منطقه‌ای فراهم شود. نتایج پژوهش حاضر نشان داد که به‌کارگیری رویکردهای فراابتکاری در بهینه‌سازی داده‌های ورودی، می‌تواند به‌عنوان راهکاری مؤثر در ارتقاء دقت مدل‌های پیش‌بینی پدیده‌های اقلیمی پیچیده مانند طوفان‌های گردوغبار مورد استفاده قرار گیرد. در شرایط اقلیمی خشک و نیمه‌خشک ایران که محدودیت داده‌های اقلیمی، ایستگاه‌های کافی و نوسانات شدید محیطی چالش‌های اصلی مدل‌سازی به‌شمار می‌آیند، استفاده از الگوریتم‌هایی مانند IWO و WCA می‌تواند به ایجاد چارچوبی کارآمد برای تصمیم‌سازی‌های مبتنی بر داده کمک کند. استمرار پژوهش در زمینه‌ی ترکیب الگوریتم‌های فراابتکاری با مدل‌های یادگیری عمیق، تحلیل سناریوهای تغییر اقلیم و به‌کارگیری داده‌های سنجش‌ازدور، مسیر آینده‌ی توسعه مدل‌های پیش‌بینی دقیق‌تر و کاربردی‌تر در مدیریت پدیده‌های گردوغبار را هموار خواهد کرد. بررسی کارایی مدل هیبریدی-FCMR MA بهینه‌شده با الگوریتم‌های فراابتکاری در مناطق دیگر ایران (مانند خوزستان یا کرمان) می‌تواند به تعمیم‌پذیری نتایج و اعتبار مدل در شرایط اقلیمی مختلف کمک کند. به‌طور کلی، این پژوهش نشان داد که استفاده از الگوریتم‌های فراابتکاری نه‌تنها به بهبود عملکرد مدل‌های پیش‌بینی گرد و غبار منجر می‌شود بلکه می‌تواند به‌عنوان ابزاری کارآمد برای پشتیبانی از مدیریت بحران‌های زیست‌محیطی و کاهش آسیب‌پذیری جوامع محلی نیز مورد توجه قرار گیرد.

منابع

۱. انصاری قوجغار، م. و پورمحمد، پ. (۲۰۲۴). مدل‌سازی طوفان گرد و غبار با استفاده از مدل ترکیبی سه‌گانه-GRNN SVM-LSTM (مطالعه موردی: استان سیستان و بلوچستان). مجله آب و خاک ایران، ISSN: 2423-7833
<https://doi.org/10.22059/ijswr.2025.385882.669844>

۲. جان‌بزرگی، م.، زهتابیان، غ.، خسروی، ح.، و حنیفه‌پور، م. (۱۳۹۰). بررسی چالش‌های گرد و غبار و راهکارهای مقابله با آن در منطقه سیستان. *مجله دانشجویی زیست سپهر*، ۱۴(۱)، ۳۷-۴۵.
۳. درگاهیان، ف. و اشرفی، س. (۱۳۹۰). بررسی پتانسیل شدت طوفان‌های گرد و غبار با استفاده از مقایسه داده‌های دید افقی و شاخص DSI در استان یزد. *مجله پژوهش‌های اقلیم‌شناسی*، ۱۳(۵۲)، ۱۸۳-۱۹۲.
۴. رنجبر، ا.، حکیم‌پور، ف. و طلعت‌اهری، س. (۱۳۹۶). ارزیابی و مقایسه الگوریتم‌های بهینه‌سازی فرا ابتکاری در مکان‌یابی تسهیلات مطالعه موردی: بانک‌ها. *فصلنامه علمی-پژوهشی داده‌های جغرافیایی*، ۲۶(۱۰۱).
۵. روانبخش، ا.، مومنی، م. و رباطی، ا. (۲۰۲۴). پیش‌بینی نرخ شکست لوله در شبکه‌های توزیع آب با استفاده از روش‌های RCNN-SVR و FCMR. *مجله مهندسی منابع آب*، ۱۶(۵۹)، ۲۴-۱۱. DOI: 10.30495/wej.2021.27427.2301
۶. سبحانی، ب.، صفریان زنگیر، و. و فیض‌الله‌زاده، س. (۲۰۲۰). مدل‌سازی و پیش‌بینی گرد و غبار در غرب ایران. *تحقیقات جغرافیای فیزیکی*، ۵۲(۱)، ۳۵-۱۷. DOI: 10.22059/JPHGR.2020.284389.1007408
۷. سلیمانی‌ساردو، ف.، مصباح‌زاده، ت.، سلاجقه، ا.، زهتابیان، غ.، رنجبر، ا.، ماگیلیتا، م. و کرمی، س. (۲۰۲۱). شناسایی چشمه‌های گرد و غبار با استفاده از مدل WRF-Chem و طرحواره‌های فرسایش بادی GOCART و AFWA. *مجله علوم محیطی*، ۱۹(۲)، ۹۱-۱۱۰. DOI: 10.52547/ENVS.33897
۸. شعاعی، ز.، کریمی، س. و آذرین، ع.ر. (۱۳۹۹). بررسی روند تغییرات وقوع طوفان‌های گرد و غبار در ایران (۲۰۰۹-۲۰۲۰). *چهارمین همایش ملی حفاظت خاک و آبخیزداری با محوریت گرد و غبار*.
۹. کاردان، ن. و حبیبی، ت. (۲۰۲۴). مقایسه عملکرد الگوریتم‌های تکاملی WCA و IWO در بهینه‌سازی چندهدفه سرریزهای کنگره‌ای دوزنقه‌ای. *مجله آبیاری و زهکشی ایران*، ۱۸(۱)، ۱۱۵-۱۳۰.
10. Alshammari, RK., Alrwais, O., & Aksoy, M. (2022). Machine learning Applications to dust storms: A Meta-Analysis. *Taiwan Association for Aerosol Research*, ISSN:2071-1409. <https://doi.org/10.4209/aaqr.220183>.
11. Almofti, S., Shaban, A., Ali, R., & Foente, J. (2023). Overview of Metaheuristic Algorithms. *Polaris Global Journal Of Scholarly Research and Trends*, 2(2), 10-32. <https://doi.org/10.58429/pgjsrt.v2n2a144>
12. Bezdek, J.C., Ehrlich, R. and Full, W. (1984) FCM: The Fuzzy C-Means Clustering Algorithm. *Comput. Geosci.* 10, 191-203. [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7)
13. Dehshiri, S., & Firouzabadi, B. (2023). A multi-objective framework to select numerical options in air quality prediction models: A case study on dust storm modeling. *Science Total Environment*. doi: 10.1016/j.scitotenv.2022.160681
14. Ghosh, P., Sadhu, P., Basak, P., & Sanal, A. (2020). *Ain Shams Engineering Journal*, 11, 1139-1147. <https://doi.org/10.1016/j.asej.2020.01.017>
15. Gholami, H., & Mohammadifar, A. (2022). Novel deep learning hybrid models (CNN-GRU and DLDL-RF) for the susceptibility classification of dust sources in the Middle East: a global source. *Scientific Reports*, 11;12(1), 19342. doi: 10.1038/s41598-022-24036-5
16. Guidolin. (2018). Autoregressive Moving Average (ARMA) Models and their Practical Applications. University lecture.
17. Hanafi, M., Bahreininejad, A., & Uddin, N. (2021). Optimization of shell and tube heat exchanger using the water cycle algorithm. *IOP Conference: Materials Science and Engineering*. doi:10.1088/1757-899X/1173/1/012005
18. Hui, Tang et al. (2023). Modelling the 2021 East Asia super dust storm using FLEXPART and FLEXDUST and its comparison with reanalyses and observations. *Frontiers in Environmental Science*. DOI 10.3389/fenvs.2022.1013875
19. Ibrahim, A., Anayi, F., Packianather, M., & Alomari, O. A. (2022). New Hybrid Invasive Weed Optimization and Machine Learning Approach for Fault Detection. *Energies*, 15(4), 1488. <https://doi.org/10.3390/en15041488>
20. Ivanovski, Z., & Milenovski, A. (2018). Time Series Forecasting Using a Moving Average Model for Extrapolation of Number of Tourist. *UTMS Journal of Economics* 9 (2), 121-132. <https://hdl.handle.net/10419/281836>

21. Javadnia, E., & Zahedi, N. (2022). Investigation Impact of Massive Dust Storm on Aerosol Optical, Physical, Radiative Properties over Southwest Iran. *Earth Observation and Geomatics Engineering*, 6(1), 135-149. DOI: 10.22059/EOGE.2022.347630.1123
22. Javadian, M. Behrangi, A. & Sorooshian, A. (2019). Impact of drought on dust storms: Case study over southeast Iran. *Environmental Research Letters*, 14(12), 29-40. DOI: 10.1088/1748-9326/ab574e
23. Kakkar, S., Maity, T., Ahuja, R., Walde, P., Saket, R.K., Khan, B., & Padmanaban, S. (2021). Design and Control of Grid-Connected PWM Rectifiers by Optimizing Fractional Order PI Controller Using Water Cycle Algorithm. *IEEE POWER & ENERGY SOCIETY SECTION*, 9, 125941-125954. DOI:10.1109/ACCESS.2021.3110431
24. Ma, C., Gao, Z., Yang, J., Cheng, L., & Zhao, T. (2022). Calibration of Adjustment Coefficient of the Viscous Boundary in Particle Discrete Element Method Based on Water Cycle Algorithm. *Water*, 14(3), 439. <https://doi.org/10.3390/w14030439>
25. McKee, T.B., N.J. Doesken and J. Kleist. (1993). The relationship of drought frequency and duration to time scale. In: *Proceedings of the Eighth Conference on Applied Climatology*, Anaheim, California, Boston, American Meteorological Society, 179-184.
26. Mehrabi, Sh., Soltani, S., & Jafari, R. (2015). Analyzing the relationship between duststorms occurrence and climatic parameters (case study: Khuzestan province). *Journal of Agricultural Sciences and Technologies and Natural Resources, Water and Soil Sciences*, 19(71). DOI:10.18869/acadpub.jstnar.19.71.69
27. Mobarhan, E., & Khaleghi, A. (2024). Analyzing the Trend of Changes in the Dust Storm Index (DSI) and Its Relationship with the Meteorological Drought in the Arid Climate (Case Study: Semnan Province). *Environmental Sciences*, 22(2), 289-304. DOI: 10.48308/envs.2024.1369
28. Motlagh, F., Bardsiri, V., & Bardsiri, A. (2023). Human-Whale cooperation optimization (HWO) algorithm: A metaheuristic algorithm for solve optimization problems. *Int. J. Nonlinear Anal. Appl*, 14(1), 2279-2300. <http://dx.doi.org/10.22075/ijnaa.2022.27197.3529>
29. Omid Rahmati, M. Panahi, Seid Saeid Ghiasi, R. Deo et al. Hybridized neural fuzzy ensembles for dust source modeling and prediction. (2020). *Atmospheric Environment*. DOI:10.1016/j.atmosenv.2020.117320
30. Rahmati, O et al. (2020). Hybridized neural fuzzy ensembles for dust source modeling and prediction. *Atmospheric Environment*, 224(1), <https://doi.org/10.1016/j.atmosenv.2020.117320>
31. Razavi-Termeh, S., Sadeghi-Niaraki, A., Naqvi, R.A. & Choi, Soo Mi. (2023). Dust detection and susceptibility mapping by aiding satellite imagery time series and integration of ensemble machine learning with evolutionary algorithms. *Environmental Pollution*, 15:335:122241. doi: 10.1016/j.envpol.2023.122241.
32. Salehpour Jama, A., Karimpour Reihanb, M., Mohseni Saravi, M., Bazrafshand, J. & Khalighi Sigaroudi, SH. (2017). Investigation of climate change effect on drought characteristics in the future period using the HadCM3 model (Case study: Khoy station, northwest of Iran). *Desert Journal*, 22(1), 43-50. DOI: 10.22059/JDESERT.2017.62294
33. Zeng, W. (2024). Application of AR, MA, and ARMA Models in Financial Time Series Analysis. *ICFTBA Workshop*. DOI: 10.54254/2754-1169/141/2024.GA18862