

Assessment of Hybrid Jenkins-Catalyst SARIMA-ACOR and SARIMA-PSO Models for Dust Storm modeling (Case Study: Khuzestan Province)

Mohammad Ansari Ghojghar^{1*}  | Sosan Salajegheh² | Paria Pourmohammad¹

1. Department of Reclamation of Arid and Mountainous Regions, Faculty of Natural Resources, University of Tehran, Karaj, Iran
2. Faculty of Environment, University of Tehran, Tehran, Iran
E-mail: ansari.ghojghar@ut.ac.ir

Article Info

Article type:
Research Article

Article history:
Received: 31 Oct. 2024
Revised: 30 Nov. 2024
Accepted: 08 Dec. 2024
Published online: 04 Jan. 2025

Keywords:
*Horizontal visibility,
Forecasting,
Catalyst,
Seasonal Combination,
Box-Jenkins.*

Abstract

This study aims to model dust storms in Khuzestan province using hybrid Jenkins-Catalyst SARIMA-ACOR and SARIMA-PSO models. For this purpose, hourly dust data and codes from the World Meteorological Organization (WMO) were used from seven synoptic stations across Khuzestan over a 40-year period. To enhance accuracy and minimize potential errors, this research employs the integration of optimization algorithms, namely Ant Colony Optimization (ACOR) and Particle Swarm Optimization (PSO), with the Box-Jenkins SARIMA model. The optimization algorithms are used for model training, parameter selection, pattern recognition, clustering, reinforcement learning, image processing, intelligent system design, and optimizing generative models. To determine the best-fitting model, the goodness-of-fit criteria, including R, RMSE, MAE, and NS, were applied. The results indicate that the hybrid SARIMA-ACOR model outperforms both the SARIMA-PSO hybrid model and the standalone SARIMA model. Among the seasonal combinations tested, combinations one and two demonstrated the highest performance and accuracy. The SARIMA-ACOR hybrid model showed superior performance in predicting the FDSI index, with Root Mean Square Error (RMSE = 0.219–0.198), Correlation Coefficient (R = 0.891–0.859), Mean Absolute Error (MAE = 0.142–0.123), and Nash-Sutcliffe Efficiency (NS = 0.881–0.862) compared to the other models.

Cite this article: Ansari Ghojghar, M., Salajegheh, S., Pourmohammad, P. (2025). Assessment of Hybrid Jenkins-Catalyst SARIMA-ACOR and SARIMA-PSO Models for Dust Storm modeling (Case Study: Khuzestan Province). *Journal of Range & Watershed Management*, 77 (4), 525-542. DOI: <http://doi.org/10.22059/jrwm.2025.386249.1791>



© The Author(s).

Publisher: University of Tehran Press

بررسی مدل‌های هیبریدی جنکینز - کاتالیزور SARIMA- ACOR و SARIMA- PSO به منظور مدل‌سازی طوفان‌های گرد و غبار (مطالعه موردی: استان خوزستان)

محمد انصاری قوجقار^{۱*} | سوسن سلاجقه^۲ | پریا پورمحمد^۱

۱. گروه احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

رایانامه: ansari.ghojghar@ut.ac.ir

۲. دانشکده محیط زیست، دانشگاه تهران، تهران، ایران

چکیده

اطلاعات مقاله

این مطالعه با هدف مدل‌سازی طوفان‌های گرد و غبار با استفاده از مدل‌های هیبریدی جنکینز - کاتالیزور SARIMA- ACOR و SARIMA- PSO در استان خوزستان انجام شده است. بدین منظور از داده‌های ساعتی گرد و غبار و کدهای سازمان جهانی هواشناسی در هفت ایستگاه سینوپتیک استان خوزستان در طول دوره آماری ۴۰ ساله استفاده شده است. به منظور ارزیابی دقیق‌تر و کاهش خطاهای ممکن، در این پژوهش از ترکیب کاتالیزور (الگوریتم‌های بهینه‌سازی) کلونی مورچگان (ACOR) و ازدحام ذرات (PSO) با مدل باکس - جنکینز SARIMA استفاده شده است. در واقع از کاتالیزورها به منظور آموزش مدل‌ها، انتخاب بهترین مقادیر برای پارامترها، تشخیص الگو و خوشه‌بندی، یادگیری تقویتی، پردازش تصویر، طراحی سیستم‌های هوشمند و بهینه‌سازی مدل‌های مولد استفاده می‌شود. به منظور انتخاب و تعیین بهترین مدل، معیارهای نیکویی برازش شامل R ، $RMSE$ ، MAE و NS مورد استفاده قرار گرفته‌اند. نتایج پژوهش حاکی از عملکرد بهتر مدل هیبریدی جنکینز - کاتالیزور SARIMA- ACOR با اختلاف، نسبت به مدل هیبریدی SARIMA- PSO و همچنین مدل انفرادی SARIMA بود. در این بین نیز، ترکیب‌های فصلی یک و دو بیشترین عملکرد و دقت را نسبت به سایر ترکیب‌های فصلی داشتند. مدل بهتر مدل هیبریدی جنکینز - کاتالیزور SARIMA- ACOR با بار ریشه میانگین مربعات خطا ($RMSE = 0/219 - 0/198$)، ضریب همبستگی ($R = 0/891 - 0/859$)، میانگین قدرمطلق خطا ($MAE = 0/142 - 0/123$) و ضریب نش - ساتکلیف ($NS = 0/881 - 0/862$) بهترین عملکرد را نسبت به سایر مدل‌های استفاده‌شده برای پیش‌بینی شاخص FDSD نمایش داده است.

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۸/۱۰

تاریخ بازنگری: ۱۴۰۳/۰۹/۱۰

تاریخ پذیرش: ۱۴۰۳/۰۹/۱۸

تاریخ انتشار: ۱۴۰۳/۱۰/۱۵

کلیدواژه‌ها:

دید افقی،

پیش‌بینی،

کاتالیزور،

ترکیب فصلی،

باکس - جنکینز.

استناد: انصاری قوجقار؛ محمد، سلاجقه؛ سوسن، پورمحمد؛ پریا (۱۴۰۳). بررسی مدل‌های هیبریدی جنکینز - کاتالیزور SARIMA- ACOR و SARIMA- PSO به منظور مدل‌سازی طوفان‌های گرد و غبار (مطالعه موردی: استان خوزستان). نشریه مرتع و آبخیزداری، ۷۷(۴)، ۵۴۲-۵۲۵.

DOI: <http://doi.org/10.22059/jrwm.2025.386249.1791>



© نویسندگان.

ناشر: انتشارات دانشگاه تهران.

۱. مقدمه

گرد و غبار را می‌توان مواد جامد بسیار ریزی که در اثر باد و طوفان در هوا معلق هستند، تعریف کرد. این مواد، پس از طی مسافت‌های طولانی، با کاهش یافتن سرعت باد، براساس وزن مخصوص خود به تدریج رسوب می‌کنند. از نظر دانه‌بندی، گرد و غبار یا ریزگرد از ذرات بسیار ریز سیلت، رس و کمی شن ریز تشکیل شده است. ذرات تشکیل دهنده طوفان‌های گرد و غبار هم از نظر معدنی و هم از نظر شیمیایی با توجه به منطقه منبع و انرژی باد متفاوت می‌باشند. انرژی ضریب انتقال نشان داده شده توسط باد، اندازه و وزن ذرات منتقل شده از منطقه منبع به منطقه رسوب را تعیین می‌کند (Awadh, 2023). طوفان‌های گرد و غبار یک پدیده رایج در مناطق خشک و نیمه خشک جهان است. فرسایش در مناطق بیابانی، کشاورزی، شهری و روستایی به گرد و غبار معدنی جو کمک می‌کند (Guevara- Macias et al., 2023). این طوفان‌ها و فراوانی وقوع آن‌ها ارتباط نزدیکی با شرایط اقلیمی منطقه مورد مطالعه (به‌عنوان مثال: بارندگی، دما و ...)، ویژگی‌های سطح زمین مثل توپوگرافی، رطوبت سطح، وضعیت پوشش گیاهی، ویژگی‌های خاک مانند باخت، ساختمان، تراکم و همچنین کاربری اراضی دارد (Sun et al., 2004; Sobhani et al., 2020). یکی دیگر از عوامل موثر بر بروز طوفان‌های گرد و غبار، سرعت وزش باد در منطقه است. مکانیسم شکل‌گیری طوفان‌های گرد و غبار به سه مرحله اساسی جدا شدن ذرات خاک^۱، انتقال ذرات^۲ و رسوب‌گذاری^۳ تقسیم می‌شوند. هنگام رسیدن سرعت وزش باد به سرعت آستانه فرسایش بادی (که خود تابعی از وضعیت و ویژگی‌های موجود در سطح زمین است)، ذرات طی سه فرآیند جهش، تعلیق و خزش امکان انتقال به مسافت‌های دورتر را پیدا می‌کنند (Gillette, 1981; Li et al., 2002). ذرات گرد و غبار تاثیر مستقیمی بر سلامت انسان و اکوسیستم، شرایط جوی و تولیدات کشاورزی دارد (Hahnenberger et al., 2014). همچنین طوفان‌های شن و گرد و غبار باعث آسیب به زیرساخت‌ها، جامعه انسانی و محیط زیست می‌شود. به‌طور مثال، روزهای همراه با طوفان‌های گرد و غبار شدید، سبب ایجاد شرایط بحرانی در سراسر عراق شده است. در سال‌های اخیر، افزایش مداوم تعداد رخداد طوفان‌هایی که عراق را در نوردیده است توجه همگان را به‌خود جلب کرده است. در آوریل ۲۰۲۲، یک طوفان تنها ۵۰۰۰ نفر مصدوم برجای گذاشت و حداقل یک نفر جان خود را از دست داد (Middleton et al., 2021; Shuker et al., 2022). با توجه به قرارگیری ایران در کمربند بیابانی دنیا و منطقه خشک و نیمه‌خشک و همچنین مجاورت با منابع اصلی گرد و غبار مانند بیابان‌های عراق، عربستان و سوریه، پدیده گرد و غبار یکی از مخاطراتی است که سالانه خسارت‌های زیادی در منطقه جنوب و جنوب غرب کشور ایجاد می‌کند (انصاری قوجقار و همکاران، ۱۳۹۹). روش‌های مورد استفاده برای کنترل فرسایش بادی به نوع اکوسیستم و کاربری زمین بستگی دارد (Abbassi et al., 2024). علاوه بر اثرات محلی، طوفان‌های گرد و غبار از طریق انتقال ذرات به مقیاس‌های منطقه‌ای و جهانی، چرخه‌های محیط‌زیستی و اقلیمی را تحت تاثیر قرار می‌دهند. علاوه بر این، ذرات گرد و غبار با تغییر تعادل تابشی زمین و جو، نقش مهمی در پدیده‌هایی مانند گرمایش جهانی و تغییرات اقلیمی ایفا می‌کنند. به‌طور خاص، آئروسول‌های غبار درشت و فوق درشت یک اثر تابشی مثبت (گرم شدن) در بالای جو ایجاد می‌کنند و می‌توانند دما و مشخصات بخار آب را تغییر دهند و بر توزیع ابرها و بارش تأثیر بگذارند (Adebiyi et al., 2023). بیش از ۶۵ درصد از طوفان‌های گرد و غبار در ایران منشأ خارجی دارند و بادهای غربی و جنوب غربی این ذرات را به استان‌های غرب و جنوبی کشور به‌ویژه خوزستان حمل می‌کنند. علاوه بر این، عوامل داخلی همچون خشک‌شدن تالاب‌های هورالعظیم و گاوخونی، کاهش دبی رودخانه‌ها و مدیریت نامناسب منابع آبی به شدت گرفتن این بحران‌ها در سال‌های اخیر کمک کرده‌اند.

افزایش قابل توجهی در انتشار سالانه گرد و غبار جهانی به دلیل ترکیبی از تغییرات کاربری زمین و آب و هوا در طول قرن گذشته وجود داشته است. افزایش میانگین دمای هوا در عراق به میزان ۲ درجه به مدت شصت سال، به افزایش تعداد طوفان‌های گرد و غبار از ۷۵ به ۲۰۰ برابر در سال انجامیده است (Awadh, 2023). تعدادی از گرد و غبارها طبیعت نائوسکوپی دارند که به دلیل فعالیت‌های انسانی

¹ Detachment

² Transport

³ Deposition

(معدن کاوی، انفجار، غبار زغال سنگ، گرد و غبار سیلیس کریستالی و غیره)، یا رویدادهای طبیعی (آتشفشان، گرد و غبار طبیعی، سوزاندن جنگل‌ها، و اسپری دریا) به جو اضافه می‌شوند. این اندازه‌های کوچک باعث بیماری‌های ریوی می‌شود که ممکن است به دلیل تجمع آلاینده‌های گرد و غبار قابل استنشاق (۱۰۰ میکرون) در ریه‌ها، منجر به مرگ شود (Guo et al., 2011). پیامدهای گرد و غبار در ایران بسیار گسترده است. افزایش میزان بیماری‌های ریوی، تعطیلی مکرر فعالیت‌های روزانه (UNEP, 2016)، کاهش بهره‌وری اقتصادی و تخریب محیط‌زیست از جمله مشکلاتی هستند که جوامع محلی و دولت با آن‌ها مواجه‌اند. در استان خوزستان، شدت این بحران به‌ویژه در سال‌های اخیر به دلیل خشکسالی‌های مداوم و کاهش چشمگیر دبی رودخانه‌ها به اوج خود رسیده است. پیش‌بینی طوفان‌های گرد و غبار یکی از ابزارها و روش‌های کلیدی برای مدیریت بحران‌های ناشی از این پدیده‌ها است. مدل‌سازی دقیق این طوفان‌ها به مدیران و سیاست‌گذاران این امکان را می‌دهد تا پیش از وقوع بحران، اقداماتی مانند انتشار هشدارهای به‌موقع، تخصیص منابع و اقدامات کاهش اثرات را انجام دهند. با توجه به پیچیدگی و عدم قطعیت‌های موجود در رخداد طوفان‌های گرد و غبار، استفاده از روش‌های مدل‌سازی ضروری است (کارگر و همکاران، ۱۳۹۵). استفاده از مدل‌های سری‌زمانی به‌منظور پیش‌بینی در علوم هیدرولوژی، اقلیم و هواشناسی کاربردهای متعددی دارد (Aghelpour et al., 2021). مدل‌های سری‌زمانی به دو گروه مدل‌های غیرخطی و مدل‌های خطی تقسیم‌بندی می‌شوند. مدل‌های غیرخطی برای سری‌های زمانی با رفتار غیرخطی استفاده می‌شود. از جمله این مدل‌ها می‌توان به مدل‌های شبکه عصبی و یادگیری عمیق برای سری‌های زمانی پیچیده نام برد. مدل‌های خطی شامل مدل‌هایی است که رابطه میان مقادیر متوالی سری‌زمانی را خطی فرض می‌کنند. مدل‌های باکس-جنکینز (مدل‌های جعبه سیاه) زیرمجموعه‌ای از آن‌ها هستند. مدل‌های AR^۱، MA^۲، ARMA^۳، ARIMA^۴ و SARIMA^۵ از جمله مدل‌های باکس-جنکینز هستند. مدل‌های باکس-جنکینز در تحلیل سری‌های زمانی خطی متمرکز بوده و بر داده‌های ایستا اعمال می‌شوند. این مدل‌ها پایه و اساس تحلیل سری‌های زمانی کلاسیک را تشکیل داده و معمولاً در مسائل اقتصادی، اقلیمی و پیش‌بینی‌های کوتاه‌مدت به کار می‌روند (Box et al., 2015). آرامی و همکاران (۱۴۰۳) به بررسی الگوی زمانی-مکانی خطر و ریسک طوفان گرد و غبار در استان خوزستان پرداختند. یافته‌های آنان نشان داد که ۷۸ درصد روزهای طوفان گرد و غبار منشا فرامحلی و ۲۲ درصد منشا محلی دارند. بیش از ۸۸ درصد استان خوزستان در طبقه‌های ریسک زیاد و خیلی زیاد قرار دارد که یکی از دلایل آن به جمعیت بیش‌تر آن مربوط می‌شود. سبحانی و صفریان زنگیر (۲۰۱۹) پدیده گرد و غبار در جنوب غربی ایران را با استفاده از مدل شبکه عصبی هیبرید-داده‌های پانلی و سیستم استنتاج فازی مبتنی بر شبکه تطبیقی (ANFIS) پیش‌بینی کردند. نتایج نشان داد که قابلیت اطمینان مدل شبکه عصبی هیبرید-داده‌های پانلی بالاتر از ANFIS است. بر اساس مدل‌های SAW و TOPSIS، بالاترین احتمال وقوع پدیده گرد و غبار در ایستگاه آبادان با ۹۹ درصد و ایستگاه اسلام‌آباد با ۹۷ درصد طی ۲۳ سال آینده پیش‌بینی شد. برای کاهش خسارات ناشی از پدیده گرد و غبار در منطقه مورد مطالعه، علاوه بر اقدامات داخلی مانند همکاری بین‌سازمانی، توافقات بین‌المللی با کشورهای همسایه ضروری است. افخمی و همکاران (۲۰۱۵) امکان پیش‌بینی سرعت باد را با استفاده از مدل‌های موجک ANN و موجک ANFIS-مورد بررسی قرار دادند (مطالعه موردی: ایستگاه سینوپتیک یزد). بر اساس نتایج، مدل موجک ANFIS-عملکرد بهتری در مقایسه با مدل موجک ANN-داشت. در مطالعه‌ای دیگر، طهرودی و همکاران (۲۰۱۳) مدل‌های ARIMA و PARMA را در مدل‌سازی و پیش‌بینی حداکثر سرعت باد مورد ارزیابی قرار دادند (مطالعه موردی: ایستگاه سینوپتیک بندرعباس). بر اساس نتایج، مدل PARMA به دلیل همبستگی بیشتر بین داده‌های واقعی و تعدیل‌شده عملکرد بهتری داشت و از این رو

^۱ خود رگرسیون

^۲ میانگین متحرک

^۳ خود رگرسیون میانگین متحرک

^۴ خود رگرسیون یکپارچه میانگین متحرک

^۵ خود رگرسیون یکپارچه میانگین متحرک فصلی

برای پیش‌بینی و تولید حداکثر سرعت باد در منطقه تا سال ۲۰۲۶ استفاده شد. با توجه به اثرات زیان‌بار طوفان‌های گرد و غبار، یکی از رویکردهای اساسی برای مقابله با این بحران‌ها، مدل‌سازی و پیش‌بینی دقیق این پدیده‌ها است. پیش‌بینی طوفان‌های گرد و غبار با استفاده از مدل‌های دقیق، امکان ارائه هشدارهای به‌موقع، مدیریت بهینه منابع و برنامه‌ریزی مناسب برای کاهش اثرات منفی آن‌ها را فراهم می‌کند. روش‌های مختلفی برای مدل‌سازی این پدیده‌ها توسعه یافته‌اند که شامل مدل‌های فیزیکی، عددی، و آماری می‌شوند. مدل‌های فیزیکی به شبیه‌سازی فرآیندهای پیچیده جوی و دینامیک ذرات معلق می‌پردازند، اما به دلیل پیچیدگی بالا و نیاز به داده‌های گسترده، اجرای آن‌ها در مقیاس محلی چالش‌برانگیز است. در مقابل، مدل‌های آماری و سری‌های زمانی نظیر SARIMA به دلیل ساختار ساده‌تر و نیاز به داده‌های تاریخی محدودتر، به‌طور گسترده‌ای برای پیش‌بینی طوفان‌های گرد و غبار استفاده می‌شوند. لذا در پژوهش حاضر از مدل‌های هیبریدی SARIMA- ACOR و SARIMA- PSO به منظور پیش‌بینی طوفان‌های گرد و غبار استفاده شده است.

۲. مواد و روش‌ها

۲-۱. منطقه مورد مطالعه

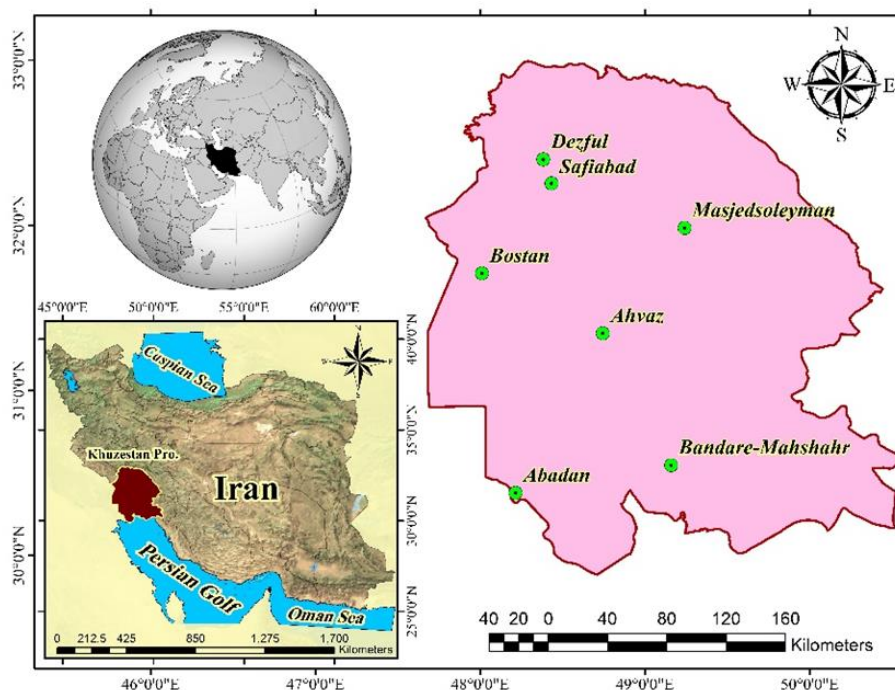
در پژوهش حاضر به بررسی ترکیب الگوریتم‌های بهینه‌سازی ACOR و PSO با مدل SARIMA به منظور پیش‌بینی فصلی فراوانی روزهای همراه با طوفان‌های گرد و غبار در هفت ایستگاه هواشناسی استان خوزستان (دزفول، صفی‌آباد، مسجد سلیمان، بستان، اهواز، بندر ماهشهر و آبادان) با طول دوره آماری ۴۰ سال (۱۹۸۰-۲۰۱۹) پرداخته شده است (شکل ۱). بدین ترتیب از داده‌های ساعتی قدرت دید افقی و ۱۱ کد مرتبط با گرد و غبار (جدول ۱) سازمان جهانی هواشناسی در هشت سینوپ در مقیاس فصلی به‌منظور پیش‌بینی گرد و غبار استفاده شده است. براساس تعریف سازمان جهانی هواشناسی، روز همراه با طوفان گرد و غبار روزی است که در گزارش‌های دیده‌بانی سه‌ساعته، حداقل یکی از کدهای مرتبط با پدیده گرد و غبار که در جدول ۱ نمایش داده شده است، در بخش هوای حاضر گزارش شده باشد. علاوه بر این، داده‌های قدرت دید افقی گزارش‌شده برای کدهای متناظر، باید در کم‌تر از ۱۰۰۰ متر ثبت شده باشند. در جدول ۲ تقسیم‌بندی گرد و غبار براساس قابلیت مشاهده و شدت آن نشان داده شده است.

جدول ۱. کدهای سازمان جهانی هواشناسی مربوط به پدیده گرد و غبار (Socha et al., 2008)

کد	توضیحات
۰۶	رخداد طوفان گرد و خاک گسترده در خارج از ایستگاه هواشناسی
۰۷	خاک یا شن برخاسته از زمین در محدوده ایستگاه هواشناسی
۰۸	مشاهده گردباد در محدوده ایستگاه هواشناسی یا خارج از آن طی ساعت‌های دیدبانی یا ساعت گذشته
۰۹	طوفان شن یا خاک در زمان دیدبانی در خارج از ایستگاه یا طی ساعت گذشته در محدوده ایستگاه هواشناسی
۳۰	طوفان خفیف یا متوسط شن یا خاک با روند کاهشی طی ساعت گذشته- با سرعت باد ۱۵ متر بر ثانیه یا بیش‌تر- کاهش میدان دید به کم‌تر از ۱۰۰۰ ولی بیش‌تر از ۲۰۰ متر
۳۱	طوفان خفیف یا متوسط شن یا خاک بدون تغییر شدت طی ساعت گذشته- با سرعت باد ۱۵ متر بر ثانیه یا بیش‌تر- کاهش میدان دید به کم‌تر از ۱۰۰۰ ولی بیش‌تر از ۲۰۰ متر
۳۲	طوفان خفیف یا متوسط شن یا خاک با افزایش شدت طی ساعت گذشته- با سرعت باد ۱۵ متر بر ثانیه یا بیش‌تر- کاهش میدان دید به کم‌تر از ۱۰۰۰ ولی بیش‌تر از ۲۰۰ متر
۳۳	طوفان شدید شن یا خاک همراه با روند کاهشی طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیش‌تر- کاهش دید کم‌تر از ۲۰۰ متر
۳۴	طوفان شدید شن یا خاک همراه بدون تغییر شدت طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیش‌تر- کاهش دید کم‌تر از ۲۰۰ متر
۳۵	طوفان شدید شن یا خاک همراه با افزایش شدت طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیش‌تر- کاهش دید کم‌تر از ۲۰۰ متر
۹۸	رعد و برق- بدون بارش- همراه با طوفان شن یا خاک

جدول ۲. تقسیم‌بندی گرد و غبار بر اساس قابلیت مشاهده و شدت آن (شاهسونی و همکاران، ۱۳۸۹)

توضیحات	شعاع دید افقی	
شدیدترین نوع از وقوع گرد و غبار است که کاملاً هوا را آلوده می‌کند و اگر بسیار شدید باشند، شعاع دید افقی حدوداً به صفر می‌رسد.	کمتر از ۱۰۰۰ متر	طوفان گرد و غبار
گرد و غبار با شدتی متوسط روی می‌دهد- ارتفاع بادهای حامل گرد و غبار و شن زیاد است	۱۰۰۰ تا ۱۰۰۰۰ متر	گرد و غبار وزشی
کمترین شدت وقوع را دارد	کمتر از ۱۰۰۰۰ متر	گرد و غبار معلق



شکل ۱. موقعیت جغرافیایی منطقه مورد مطالعه و ایستگاه‌های مورد بررسی

۲-۲. الگوریتم‌های بهینه‌سازی^۱

این الگوریتم‌ها در هوش مصنوعی نقش کاتالیزور را دارند چون عملکرد مدل‌ها و سیستم‌های هوش مصنوعی را بهینه‌سازی می‌کنند و آن‌ها را به سمت دستیابی به بهترین نتیجه‌های ممکن هدایت می‌کنند. از کاتالیزورها به منظور آموزش مدل‌ها، انتخاب بهترین مقادیر برای پارامترها، تشخیص الگو و خوشه‌بندی، یادگیری تقویتی، پردازش تصویر، طراحی سیستم‌های هوشمند و بهینه‌سازی مدل‌های مولد استفاده می‌شود. انواع الگوریتم‌های بهینه‌سازی را می‌توان به الگوریتم‌های عددی^۲ (روش گرادیان کاهشی^۳ و الگوریتم نیوتون^۴) (زینلی و همکاران، ۱۳۹۶)، الگوریتم‌های تصادفی^۵ (گرادیان کاهشی تصادفی و الگوریتم Simulated Annealing) (هادی غاصری و همکاران، ۱۳۹۸)، الگوریتم‌های مبتنی بر هوش جمعی^۶ (الگوریتم بهینه‌سازی کلونی مورچگان، الگوریتم ازدحام ذرات و الگوریتم زنبورها^۷)، الگوریتم‌های

¹ Optimization algorithms

² Deterministic Optimization

³ Gradient Descent

⁴ Newton's Method

⁵ Stochastic Optimization

⁶ Swarm Intelligence

⁷ Bee Algorithm

تکاملی^۱ (الگوریتم ژنتیک^۲ و الگوریتم تفاضلی تکاملی^۳) و الگوریتم‌های ترکیبی تقسیم‌بندی کرد (گلستان و همکاران، ۱۳۹۲).

۲-۳. الگوریتم کلونی مورچگان (ACO)^۴

الگوریتم مورچگان روشی قدرتمند به منظور حل مسائل بهینه‌سازی ترکیبیاتی^۵ می‌باشد. الگوریتم‌های مشتق‌شده از کلونی مورچگان، زیرمجموعه‌ای از روش‌های هوش ازدحامی است. این گروه از روش‌ها به مطالعه الگوریتم‌های الهام گرفته شده از رفتارهای ازدحامی^۶ می‌پردازند. الگوریتم‌های هوش ازدحامی از مجموعه‌ای از موجودیت‌های تکی و فردی ایجاد شده‌اند که با استفاده از خودسازماندهی^۷، با یکدیگر همکاری و تعامل می‌کنند (گلستان و همکاران، ۱۳۹۲). وجود خودسازماندهی به معنای عدم وجود سیستم کنترل مرکزی به منظور کنترل و ایجاد هماهنگی بین اجزای یک سیستم هوش ازدحامی است. براساس نتایج حاصل از آزمایش‌های صورت گرفته بر رفتار مورچگان، محققان دریافتند که مورچه‌ها از رفتار بهینه ازدحامی مبتنی بر بازخورد مثبت به منظور یافتن کوتاه‌ترین مسیر از کلونی به منابع غذایی استفاده می‌کنند. به چنین رفتاری، خودکاتالیز یا اتوکاتالیز می‌گویند (Dorigo et al., 2004).

۲-۳-۱. الگوریتم بهینه‌سازی کلونی مورچگان پیوسته ACOR^۸

این الگوریتم یکی از روش‌های بهینه‌سازی مبتنی بر هوش ازدحامی است که برای مسائل با فضای پیوسته طراحی شده است. این الگوریتم در واقع نسخه‌ای توسعه‌یافته از الگوریتم کلونی مورچگان است که به جای مسائل گسسته، برای مسائل پیوسته استفاده می‌شود (زینلی و همکاران، ۱۳۹۶). در این الگوریتم، مورچه‌ها (نمایندگان حل مسئله) به جای جستجوی مسیرهای گسسته، در فضایی پیوسته حرکت می‌کنند. از مزایای این الگوریتم می‌توان به انعطاف‌پذیری بالا، استفاده از حافظه و پایداری در همگرایی (تنظیم مناسب پارامترها به منظور تسریع همگرایی به سمت جواب بهینه) اشاره کرد. در لیست حافظه^۹، لیستی از راه‌حل‌های ممکن در فضای جستجو ذخیره و نگهداری می‌شوند که در طول زمان بروزرسانی می‌شوند. راه‌حل‌های بهتر احتمال بیش‌تری برای انتخاب دارند. تابع احتمال^{۱۰} راه‌حل‌های مناسب را به منظور انتخاب با کیفیت راه‌حل‌ها از لیست حافظه برمی‌گزیند. از تابع توزیع گاوسی (توزیع نرمال) برای تولید نقاط جدید در فضای جستجو استفاده می‌شود (Socha and Dorigo et al., 2008). پس از ذخیره راه‌حل‌های تولیدشده در لیست حافظه، ضعیف‌ترین راه‌حل‌ها به منظور حفظ کیفیت حافظه حذف می‌شوند (Karahan et al., 2012). در مرحله آخر نیز، از پارامترهایی مانند عرض توزیع گاوسی برای جلوگیری از گرفتار شدن در بهینه‌سازهای محلی و به منظور کنترل همگرایی استفاده می‌شود.

۲-۴. الگوریتم بهینه‌سازی ازدحام ذرات (PSO)^{۱۱}

در سال ۱۹۹۵، ابرهارت و کندی الگوریتم PSO را به عنوان روشی غیرقطعی برای بهینه‌سازی توابع معرفی کردند. این الگوریتم با الهام از رفتار جمعی پرندگان در جستجوی غذا طراحی شده است (شفیعی نژاد و همکاران، ۱۴۰۲). در این مدل، گروهی از پرندگان به صورت تصادفی در فضایی به دنبال غذا می‌گردند، درحالی‌که تنها یک منبع غذا وجود دارد و هیچ‌یک از پرندگان از محل دقیق آن آگاه نیستند.

¹ Evolutionary Algorithms

² Genetic Algorithm

³ Differential Evolution

⁴ Ant Colony Optimization

⁵ Combinatorial Optimization Problems

⁶ Swarm Behaviors

⁷ Self-Organizing

⁸ Ant Colony Optimization for Continuous Domains

⁹ Archive List

¹⁰ Gaussian Probability

¹¹ Particle Swarm Optimization

یک استراتژی کارآمد در این شرایط می‌تواند دنبال کردن پرنده‌ای باشد که فاصله‌ی کمتری با غذا دارد. این ایده، اساس الگوریتم PSO است (Gorissen et al., 2015). در این الگوریتم، هر راه‌حل که ذره نامیده می‌شود، توسط یک تابع شایستگی ارزیابی می‌شود. هرچه یک ذره به هدف (که در این مدل نماد غذا است) نزدیک‌تر باشد، شایستگی بیشتری خواهد داشت. علاوه‌براین، هر ذره دارای سرعتی است که جهت و میزان حرکت آن را مشخص می‌کند. ذرات با استفاده از اطلاعات خود و پیروی از ذراتی که عملکرد بهتری دارند، موقعیت و سرعتشان را به‌روزرسانی کرده و به جست‌وجوی خود در فضای مسئله ادامه می‌دهند (شفیعی نژاد و همکاران، ۱۴۰۲؛ Zhu et al., 2014).

۲-۵. مدل سری زمانی فصلی خطی (SARIMA)

مدل یکپارچه میانگین متحرک خودبازگشتی فصلی، به دلیل توانایی در تحلیل داده‌های سری زمانی فصلی، برای پیش‌بینی پدیده‌هایی که الگوهای دوره‌ای دارند بسیار مناسب است. برای اولین بار برای سری‌های زمانی فصلی به کار برده شد (Box et al., 1994). به عبارت دیگر، سری زمانی که در فاصله‌های زمانی معینی دارای رفتار تناوبی S باشد، دارای تناوب فصلی است و برای مدل‌سازی آن از مدل سری زمانی فصلی خطی استفاده می‌شود. باین‌حال، این مدل‌ها در تعیین پارامترهای بهینه خود با محدودیت‌هایی روبه‌رو هستند. به‌منظور رفع این محدودیت‌ها، الگوریتم‌های هوشمند نظیر ACOR (بهینه‌سازی کلونی مورچگان پیوسته) و PSO (بهینه‌سازی ازدحام ذرات) می‌توانند به‌عنوان ابزارهایی برای جست‌جوی بهینه پارامترهای مدل SARIMA مورد استفاده قرار گیرند. مدل SARIMA یا مدل یکپارچه میانگین متحرک خودبازگشتی فصلی^۱، یکی از مدل‌های پیشرفته در تحلیل سری‌های زمانی است که برای پیش‌بینی داده‌های دوره‌ای و فصلی استفاده می‌شود. این مدل، نسخه‌ای توسعه‌یافته از مدل ARIMA است که علاوه بر ویژگی‌های استاندارد ARIMA، قابلیت تحلیل الگوهای فصلی را نیز داراست (جهانبخش اصل و همکاران، ۱۴۰۰). مدل SARIMA با استفاده از ترکیب چهار بخش اصلی طراحی می‌شود. بخش اول بخش خودبازگشتی یا انتقال به عقب (AR) است که شامل ارتباط بین مقادیر گذشته سری زمانی و مقدار فعلی است. این بخش الگوهای خطی بین داده‌های قبلی و فعلی را مدل‌سازی می‌کند. میانگین متحرک (MA) (بخش دوم)، بر اساس خطاهای پیش‌بینی گذشته و نحوه تأثیر آن‌ها بر مقدار فعلی سری زمانی عمل می‌کند. در بخش یکپارچه‌سازی (I)، از تفاضل‌گیری به‌منظور تبدیل سری زمانی ناپایدار به سری پایدار استفاده می‌شود. این بخش تعداد دفعات تفاضل‌گیری لازم برای دستیابی به پایداری سری را مشخص می‌کند. و در بخش آخر نیز، برای مدل‌سازی الگوهای دوره‌ای که در سری زمانی با فواصل زمانی مشخص (مانند ماهانه یا سالانه) تکرار می‌شوند، از الگوهای فصلی (S) استفاده می‌شود. مدل SARIMA با شش پارامتر اصلی شامل (p, d, q) برای جزء غیر فصلی و (P, D, Q, m) برای جزء فصلی به کار برده می‌شود (انصاری قوجقار و همکاران، ۱۴۰۱). شکل کلی این مدل براساس رابطه ۱ است:

$$\varphi_P(B)\theta_Q(B^S)\nabla^d\nabla_S^D Z_t = \theta_Q(B^S)\varphi_P(B)a_t \quad (\text{رابطه ۱})$$

در رابطه ۱، $\varphi_P(B^S)$ و $\theta_Q(B^S)$ به ترتیب چندجمله‌ای برحسب B^S و از درجه P و Q می‌باشند. همچنین $\varphi_P(B)$ و $\theta_Q(B)$ نیز به ترتیب چندجمله‌ای از مرتبه p و q هستند. p مرتبه خودهمبسته غیرفصلی، q مرتبه میانگین متحرک غیرفصلی، d تعداد تفاضل‌گیری غیرفصلی، P مرتبه خودهمبسته غیرفصلی، Q مرتبه میانگین متحرک غیرفصلی، D تعداد تفاضل‌گیری غیرفصلی و S طول فصل است (احمدپور و همکاران، ۱۳۹۹).

۲-۶. مدل هیبریدی دوگانه SARIMA- ACOR

ترکیب الگوریتم بهینه‌سازی ACOR (Ant Colony Optimization for Continuous Domains) با مدل پیش‌بینی SARIMA

¹ Seasonal Autoregressive Integrated Moving Average

(Seasonal Autoregressive Integrated Moving Average) رویکردی نوآورانه برای بهبود تحلیل سری‌های زمانی است که از قابلیت‌های هر دو تکنیک بهره می‌برد. مدل SARIMA که به طور گسترده برای پیش‌بینی سری‌های زمانی فصلی و غیرایستا استفاده می‌شود، بر پایه چهار مجموعه پارامتر اصلی $p, d, q, P, D, Q, sp, d, q, P, D, Q, sp, d, q, P, D, Q, s$ عمل می‌کند که شامل مؤلفه‌های خودرگرسیون، تفاضل‌گیری، میانگین متحرک، و اجزای فصلی است (جهانبخش اصل و همکاران، ۱۴۰۰). تعیین این پارامترها معمولاً به روش‌های آزمون و خطا یا الگوریتم‌های جستجوی جامع صورت می‌گیرد که به دلیل فضای وسیع پارامترها و طبیعت غیرخطی مدل، منجر به افزایش هزینه محاسباتی و کاهش کارایی می‌شود. در این راستا، استفاده از ACOR به عنوان یک الگوریتم بهینه‌سازی که برای مسائل با متغیرهای پیوسته طراحی شده، امکان کاوش بهینه در فضای پارامترهای SARIMA را فراهم می‌کند. این الگوریتم با استفاده از ساختار کلونی مورچه‌ها و اعمال توزیع احتمال گوسی بر روی راه‌حل‌های بالقوه، پارامترهایی را جستجو می‌کند (Socha and Dorigo et al., 2008) که خطای پیش‌بینی مدل را به حداقل می‌رسانند. در این ترکیب، ابتدا الگوریتم ACOR یک جمعیت اولیه از ترکیبات پارامترهای SARIMA را به صورت تصادفی تولید می‌کند و سپس، هر ترکیب با استفاده از داده‌های آموزشی مدل‌سازی می‌شود. عملکرد هر ترکیب بر اساس تابع هدف که معمولاً خطای پیش‌بینی است، ارزیابی می‌گردد. الگوریتم با استفاده از حافظه پویا و توزیع گوسی (Socha and Dorigo et al., 2008)، وزن‌دهی مناسبی به راه‌حل‌های برتر انجام می‌دهد و توزیع احتمال خود را به گونه‌ای به‌روزرسانی می‌کند که در تکرارهای بعدی، مورچه‌ها به سمت نواحی با پاسخ‌های بهینه‌تر هدایت شوند. این رویکرد اجازه می‌دهد که جستجوی همزمان در مقیاس محلی و جهانی انجام شود؛ به طوری که از یک سو، مورچه‌ها به بهترین نقاط موجود نزدیک می‌شوند و از سوی دیگر، امکان کشف نقاط جدید در فضای پارامترها وجود دارد. به‌روزرسانی تکراری حافظه و توزیع احتمال موجب می‌شود که فرآیند بهینه‌سازی با کمترین احتمال گیر افتادن در نقاط بهینه محلی (Local Optima) به سمت یافتن بهینه جهانی هدایت شود. مزیت اصلی این ترکیب در کاهش زمان محاسباتی و افزایش دقت پیش‌بینی مدل SARIMA نهفته است. الگوریتم ACOR قادر است پیچیدگی و تعاملات میان پارامترهای متعدد SARIMA را به صورت کارآمد مدیریت کرده و ترکیباتی را پیدا کند که دستیابی به آنها از طریق روش‌های کلاسیک دشوار است. این رویکرد علاوه بر کاهش وابستگی به فرآیندهای آزمون و خطای انسانی، امکان استفاده از SARIMA را در حوزه‌هایی با داده‌های پیچیده و غیرایستا بهینه‌تر می‌کند. کاربردهای این ترکیب در زمینه‌هایی مانند پیش‌بینی تقاضای انرژی، مدل‌سازی بازارهای مالی، و تحلیل داده‌های فصلی محیطی نشان داده که این روش در مقایسه با رویکردهای سنتی نه تنها دقت بالاتری دارد، بلکه در مواجهه با چالش‌های سری‌های زمانی واقعی، کارایی قابل توجهی ارائه می‌دهد.

۲-۶-۱. مراحل ترکیب مدل هیبریدی جنکینز- کاتالیزور

در نخستین مرحله، تابع هدف تعریف می‌شود. هدف اصلی به حداقل رساندن خطای پیش‌بینی مدل SARIMA است. در این مرحله از معیارهای نکویی برازش شامل جذر میانگین مربعات و میانگین خطای مطلق براساس روابط ۲ و ۳ استفاده می‌شود.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad \text{رابطه ۲}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad \text{رابطه ۳}$$

تابع هدف برای الگوریتم ACOR به صورت رابطه‌های ۴ و ۵ قابل محاسبه است:

$$MAE = \text{Fitness}(X) \quad \text{رابطه ۴}$$

$$RMSE = \text{Fitness}(X) \quad \text{رابطه ۵}$$

در آن، X معادل $[p, d, q, P, D, Q, s]$ ، بردار پارامترهای مدل SARIMA است که توسط الگوریتم ACOR بهینه‌سازی می‌شود. در مرحله دوم، انتخاب پارامترها و راه‌حل‌ها با استفاده از توزیع احتمال گوسی حول بهترین راه‌حل انجام می‌شود. راه‌حل‌های جدید براساس ترکیب نتایج فعلی و بهترین راه‌حل‌ها بروزرسانی می‌شوند. پس از محاسبه تابع هدف برای تمامی راه‌حل‌ها، راه‌حل‌های برتر برای هدایت فرآیند جستجو در تکرارهای بعدی انتخاب می‌شوند. در نهایت نیز، مدل‌سازی SARIMA انجام می‌شود. پیش‌بینی مدل با استفاده از داده‌های آموزشی ضرایب را تخمین می‌زند و پیش‌بینی سری زمانی صورت می‌گیرد.

۲-۷. مدل هیبریدی SARIMA- PSO

ترکیب مدل SARIMA با کاتالیزور بهینه‌سازی ازدحام ذرات، روشی کارآمد به‌نظر بهبود پیش‌بینی سری‌های زمانی است. تمرکز این روش بر بهینه‌سازی خودکار پارامترهای مدل و کاهش خطا است. الگوریتم PSO با استفاده از مکان و سرعت ذرات در فضای پارامترها و بروزرسانی مداوم آن‌ها براساس بهترین پاسخ محلی و جهانی، این فرآیند را تسهیل می‌کند. مزیت اصلی ترکیب SARIMA و PSO در کاهش پیچیدگی جستجوی پارامترها و افزایش دقت پیش‌بینی نهفته است. PSO با استفاده از مکانیزم‌های به‌روزرسانی گروهی و جستجوی جهانی، خطر گیر افتادن در بهینه‌های محلی را کاهش می‌دهد و سرعت همگرایی را افزایش می‌دهد. به دلیل تعامل مداوم میان ذرات، الگوریتم قادر است بهترین نواحی در فضای جستجو را شناسایی کند و با تنظیم دقیق پارامترهای مدل SARIMA، تابع هدف را به‌صورت مؤثری کمینه کند. این ترکیب در کاربردهای مختلف، از جمله پیش‌بینی تقاضای انرژی، تحلیل بازارهای مالی، و مدل‌سازی داده‌های فصلی، نتایج دقیقی ارائه داده و عملکرد بهتری نسبت به روش‌های سنتی بهینه‌سازی نشان داده است. علاوه بر این، استفاده از PSO، فرآیند تنظیم پارامترهای SARIMA را خودکار می‌کند و نیاز به مداخله انسانی را کاهش می‌دهد که این موضوع موجب می‌شود ترکیب پیشنهادی در شرایط داده‌های پیچیده و غیرایستا، قابل اطمینان‌تر و کارآمدتر باشد.

۲-۸. مدل‌های پیش‌بینی

به‌منظور پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار در هفت ایستگاه سینوپتیک استان خوزستان، از مدل سری‌زمانی باکس-جنکینز و ترکیب آن با الگوریتم‌های فراکوشی بهینه‌سازی ACOR و PSO استفاده شده است. پس از آن براساس معیارهای نیکویی برازش، بهترین مدل انتخاب شده است. در این‌جا، از تعداد فصل‌های گذشته به‌منظور پیش‌بینی فصول آتی استفاده شده است. تعداد فصول گذشته برای پیش‌بینی فصل‌های آینده، از یک تا چهار فصل قبل از FDSO می‌باشد (انصاری قوجقار و همکاران، ۱۳۹۹).

۲-۹. آماده‌سازی داده‌ها

در این مرحله، پس از کنترل کیفیت آمار ایستگاه‌های موجود و رفع نقص‌های آماری، بررسی همگنی داده‌ها با استفاده از آزمون Run Test مورد بررسی قرار گرفت. سپس بخشی از متغیرها و یا همه آن‌ها به عنوان ورودی مدل SARIMA انتخاب شدند. در روش فوق، ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد آن‌ها برای آزمون مورد استفاده قرار گرفتند. از روش صحت‌سنجی متقاطع به‌منظور عدم رخداد بیش‌برازش استفاده شد. در این روش، در هر مرتبه اجرای مدل، بخشی از داده‌های آموزشی به‌عنوان داده‌های صحت‌سنجی برای مدل، کنار گذاشته می‌شوند و داده‌های باقی‌مانده، برای آموزش مدل کنار گذاشته می‌شوند. این فرآیند تا زمانی ادامه پیدا می‌کند تا همه داده‌های آموزشی، مورد صحت‌سنجی قرار بگیرند (انصاری قوجقار و همکاران، ۱۳۹۹).

۲-۱۰. معیارهای انتخاب مدل مناسب

در پژوهش حاضر، به منظور بررسی کارایی مدل‌ها، از ضریب همبستگی^۱ (R)، ریشه میانگین مربعات خطا^۲ (RMSE)، میانگین قدر مطلق خطا^۳ (MAE) و ضریب نش- ساتکلیف^۴ (NS) همان‌طور که در رابطه‌های ۶ تا ۹ نمایش داده شده است، استفاده شده است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad (\text{رابطه ۶})$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (\text{رابطه ۷})$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad (\text{رابطه ۸})$$

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (\text{رابطه ۹})$$

در این روابط، O_i مقادیر مشاهده شده در زمان i ، f_i مقادیر پیش‌بینی شده در زمان i ، \bar{O} میانگین مقادیر مشاهده شده و \bar{f} میانگین مقادیر پیش‌بینی شده، n تعداد داده‌ها می‌باشد.

۳. نتایج و بحث

در پژوهش حاضر، هفت ایستگاه سینوپتیک استان خوزستان (دزفول، صفی‌آباد، مسجد سلیمان، بستان، اهواز، بندر ماهشهر و آبادان) به منظور پیش‌بینی فراوانی شاخص FDSD مورد بررسی قرار گرفته است. پس از بررسی داده‌های ایستگاه‌های منتخب در دوره زمانی ۴۰ ساله (۱۹۸۰-۲۰۱۹)، تعداد روزهای همراه با طوفان گرد و غبار با استفاده از کدهای سازمان هواشناسی و داده‌های دید افقی محاسبه شد. از نتایج حاصل از محاسبه معیارهای ارزیابی R ، $RMSE$ ، NS و MAE جهت انتخاب مدل مناسب استفاده و در جدول‌های ۳ تا ۵ نمایش داده شده است. ارزیابی و اجرای مدل انفرادی با کس- جنکینز SARIMA، جهت پیش‌بینی شاخص FDSD، با استفاده از زبان برنامه‌نویسی R صورت گرفته است و نتایج آماری داده‌های ورودی به مدل در جدول ۳ نمایش داده شده است. با توجه به کاهش معیار خطای $RMSE$ پس از بکارگیری شاخص FDSD از چهار فصل به دو فصل قبل در تمامی ایستگاه‌ها، می‌توان بیان کرد که به‌طور کلی ترکیب‌های فصلی یک و دو، نتایج بهتری را نسبت به سایر فصول نشان داده‌اند. به‌عنوان مثال در ایستگاه آبادان، با بیش‌ترین تعداد شاخص FDSD، معیارهای خطای MAE و $RMSE$ از ۰/۲۷۳ و ۰/۳۴۳ روز در ترکیب چهارم، به ۰/۲۷۱ و ۰/۳۴۲ روز کاهش یافته است. این روند برای تمامی ایستگاه‌های مورد بررسی در نتیجه مدل‌سازی طوفان‌های گرد و غبار با مدل SARIMA تکرار شده است. در جدول ۴، نتایج حاصل از ترکیب مدل SARIMA با الگوریتم بهینه‌سازی مبتنی بر هوش ازدحامی، جهت پیش‌بینی شاخص FDSD نمایش داده شده است. در این مدل نیز مانند مدل SARIMA، مقادیر خطای گزارش شده پس از در نظر گرفتن تعداد فصول بیش‌تر، در هر هفت ایستگاه، افزایش می‌یابد. به‌عنوان مثال مقدار $RMSE$ با بکارگیری شاخص FDSD از چهار فصل به دو فصل قبل در تمامی ایستگاه‌های مورد نظر طبق جدول زیر، از مقادیر ۰/۳۱۹، ۰/۳۲۴، ۰/۳۲۷، ۰/۳۳۲، ۰/۳۳۶، ۰/۳۴۱ و ۰/۳۴۴ به ۰/۳۱۸، ۰/۳۲۱، ۰/۳۲۵، ۰/۳۲۸، ۰/۳۳۳، ۰/۳۳۷ و ۰/۳۴۲ کاهش یافته است. روند مشابهی در نتیجه مدل‌سازی طوفان‌های گرد و غبار پس از ترکیب مدل انفرادی SARIMA با

¹ Correlation

² Root Mean Square Error

³ Mean Absolute Error

⁴ Nash- Sutcliffe

کاتالیزور کلونی مورچگان پیوسته در جدول ۵ قابل مشاهده است. همان طور که از مقایسه ترکیبات فصلی هر ایستگاه مشخص است، مقدار ضریب همبستگی پس از افزایش تعداد فصل‌های گذشته کاهش و شاخص RMSE افزایش می‌یابد. مقدار شاخص RMSE در تمام ترکیبات فصلی در هر هفت ایستگاه مورد بررسی در نتیجه ترکیب مدل باکس-جنکینز با الگوریتم بهینه سازی ACOR، کاهش یافته است. به عنوان مثال مقدار این شاخص در ترکیب‌های فصلی یک و دو در ایستگاه‌های آبادان و اهواز در نتیجه مدل‌سازی با مدل هیبریدی فوق، به ترتیب از ۰/۳۴۱ و ۰/۳۴۲ روز به ۰/۱۹۸ و ۰/۱۹۹ روز کاهش یافته است. با توجه به موارد بیان شده می‌توان نتیجه گرفت که افزایش پیچیدگی در مدل‌سازی و استفاده از داده‌های فصل‌های دورتر، بهبود نتایج پیش‌بینی شاخص FDS در ایستگاه‌های مورد مطالعه را به همراه نخواهد داشت.

جدول ۳. نتایج آماری داده‌های ورودی به مدل SARIMA به منظور پیش‌بینی FDS

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
آبادان	۱	۰/۷۲۱	۰/۲۵۲	۰/۳۱۲	۰/۶۹۹	۰/۷۰۱	۰/۲۷۱	۰/۳۴۱	۰/۶۹۳
	۲	۰/۷۲۱	۰/۲۵۲	۰/۳۱۴	۰/۶۹۸	۰/۷۰۱	۰/۲۷۱	۰/۳۴۲	۰/۶۹۲
	۳	۰/۷۲۱	۰/۲۵۳	۰/۳۱۴	۰/۶۹۷	۰/۶۹۸	۰/۲۷۲	۰/۳۴۳	۰/۶۹۱
	۴	۰/۷۲۰	۰/۲۵۴	۰/۳۱۵	۰/۶۹۷	۰/۶۹۷	۰/۲۷۳	۰/۳۴۳	۰/۶۹۰
اهواز	۱	۰/۷۱۹	۰/۲۵۵	۰/۳۱۵	۰/۶۹۶	۰/۶۹۷	۰/۲۷۴	۰/۳۴۴	۰/۶۸۹
	۲	۰/۷۱۸	۰/۲۵۶	۰/۳۱۷	۰/۶۹۶	۰/۶۹۷	۰/۲۷۵	۰/۳۴۵	۰/۶۸۸
	۳	۰/۷۱۷	۰/۲۵۷	۰/۳۱۷	۰/۶۹۵	۰/۶۹۶	۰/۲۷۶	۰/۳۴۶	۰/۶۸۶
	۴	۰/۷۱۶	۰/۲۵۸	۰/۳۱۸	۰/۶۹۵	۰/۶۹۵	۰/۲۷۷	۰/۳۴۷	۰/۶۸۵
بستان	۱	۰/۷۱۵	۰/۲۵۸	۰/۳۱۹	۰/۶۹۴	۰/۶۹۵	۰/۲۷۸	۰/۳۴۸	۰/۶۸۵
	۲	۰/۷۱۴	۰/۲۵۹	۰/۳۲۱	۰/۶۹۳	۰/۶۹۴	۰/۲۷۹	۰/۳۴۹	۰/۶۸۴
	۳	۰/۷۱۳	۰/۲۶۱	۰/۳۲۲	۰/۶۹۲	۰/۶۹۳	۰/۲۸۰	۰/۳۵۱	۰/۶۸۳
	۴	۰/۷۱۲	۰/۲۶۱	۰/۳۲۳	۰/۶۹۱	۰/۶۹۲	۰/۲۸۱	۰/۳۵۲	۰/۶۸۲
مسجد سلیمان	۱	۰/۷۱۲	۰/۲۶۲	۰/۳۲۴	۰/۶۹۱	۰/۶۹۱	۰/۲۸۲	۰/۳۵۳	۰/۶۸۱
	۲	۰/۷۱۲	۰/۲۶۳	۰/۳۲۵	۰/۶۹۰	۰/۶۸۸	۰/۲۸۳	۰/۳۵۴	۰/۶۸۱
	۳	۰/۷۱۱	۰/۲۶۴	۰/۳۲۶	۰/۶۹۰	۰/۶۸۸	۰/۲۸۴	۰/۳۵۴	۰/۶۷۹
	۴	۰/۷۱۰	۰/۲۶۵	۰/۳۲۷	۰/۶۸۶	۰/۶۸۵	۰/۲۸۵	۰/۳۵۵	۰/۶۷۸
بندر ماهشهر	۱	۰/۷۰۹	۰/۲۶۶	۰/۳۲۷	۰/۶۸۶	۰/۶۸۴	۰/۲۸۶	۰/۳۵۶	۰/۶۷۷
	۲	۰/۷۰۸	۰/۲۶۷	۰/۳۲۸	۰/۶۸۵	۰/۶۸۳	۰/۲۸۶	۰/۳۵۷	۰/۶۷۶
	۳	۰/۷۰۸	۰/۲۶۸	۰/۳۲۹	۰/۶۸۴	۰/۶۸۲	۰/۲۸۷	۰/۳۵۸	۰/۶۷۵
	۴	۰/۷۰۶	۰/۲۶۹	۰/۳۳۱	۰/۶۸۳	۰/۶۸۱	۰/۲۸۸	۰/۳۵۹	۰/۶۷۴
صفی‌آباد	۱	۰/۷۰۵	۰/۲۷۱	۰/۳۳۲	۰/۶۸۳	۰/۶۷۹	۰/۲۸۹	۰/۳۶۱	۰/۶۷۳
	۲	۰/۷۰۴	۰/۲۷۲	۰/۳۳۳	۰/۶۸۲	۰/۶۷۷	۰/۲۹۱	۰/۳۶۲	۰/۶۷۲
	۳	۰/۷۰۳	۰/۲۷۳	۰/۳۳۴	۰/۶۸۱	۰/۶۷۸	۰/۲۹۱	۰/۳۶۳	۰/۶۷۱
	۴	۰/۷۰۲	۰/۲۷۴	۰/۳۳۵	۰/۶۷۹	۰/۶۷۷	۰/۲۹۲	۰/۳۶۴	۰/۶۷۱
دزفول	۱	۰/۷۰۱	۰/۲۷۵	۰/۳۳۶	۰/۶۷۸	۰/۶۷۵	۰/۲۹۲	۰/۳۶۵	۰/۶۶۹
	۲	۰/۷۰۱	۰/۲۷۶	۰/۳۳۷	۰/۶۷۷	۰/۶۷۵	۰/۲۹۳	۰/۳۶۶	۰/۶۶۲
	۳	۰/۷۰۱	۰/۲۷۷	۰/۳۳۸	۰/۶۷۶	۰/۶۷۵	۰/۲۹۴	۰/۳۶۷	۰/۶۶۱
	۴	۰/۶۹۹	۰/۲۷۸	۰/۳۳۹	۰/۶۷۵	۰/۶۷۵	۰/۲۹۵	۰/۳۶۸	۰/۶۵۹

جدول ۴- نتایج آماری داده‌های ورودی به مدل SARIMA- PSO به منظور پیش‌بینی FDS

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
آبادان	۱	۰/۷۳۱	۰/۳۰۲	۰/۲۲۱	۰/۷۴۲	۰/۲۲۱	۰/۳۰۲	۰/۷۳۱	۰/۷۱۷
	۲	۰/۷۳۱	۰/۳۰۳	۰/۲۲۱	۰/۷۴۱	۰/۲۲۱	۰/۳۰۳	۰/۷۳۱	۰/۷۱۶
	۳	۰/۷۳۰	۰/۳۰۳	۰/۲۲۲	۰/۷۴۱	۰/۲۲۲	۰/۳۰۳	۰/۷۳۰	۰/۷۱۶
	۴	۰/۷۲۹	۰/۳۰۴	۰/۲۲۳	۰/۷۴۱	۰/۲۲۳	۰/۳۰۴	۰/۷۲۹	۰/۷۱۵
اهواز	۱	۰/۷۲۸	۰/۳۰۵	۰/۲۲۸	۰/۷۴۰	۰/۲۲۸	۰/۳۰۵	۰/۷۲۸	۰/۷۱۴
	۲	۰/۷۲۷	۰/۳۰۶	۰/۲۲۸	۰/۷۳۹	۰/۲۲۸	۰/۳۰۶	۰/۷۲۷	۰/۷۱۳
	۳	۰/۷۲۶	۰/۳۰۷	۰/۲۲۹	۰/۷۳۹	۰/۲۲۹	۰/۳۰۷	۰/۷۲۶	۰/۷۱۳
	۴	۰/۷۲۵	۰/۳۰۸	۰/۲۳۱	۰/۷۳۸	۰/۲۳۱	۰/۳۰۸	۰/۷۲۵	۰/۷۱۳
بستان	۱	۰/۷۲۴	۰/۳۰۹	۰/۲۳۲	۰/۷۳۷	۰/۲۳۲	۰/۳۰۹	۰/۷۲۴	۰/۷۱۲
	۲	۰/۷۲۳	۰/۳۱۱	۰/۲۳۳	۰/۷۳۶	۰/۲۳۳	۰/۳۱۱	۰/۷۲۳	۰/۷۱۲
	۳	۰/۷۲۱	۰/۳۱۲	۰/۲۳۴	۰/۷۳۵	۰/۲۳۴	۰/۳۱۲	۰/۷۲۱	۰/۷۱۱
	۴	۰/۷۲۱	۰/۳۱۳	۰/۲۳۵	۰/۷۳۴	۰/۲۳۵	۰/۳۱۳	۰/۷۲۱	۰/۷۱۰
مسجد سلیمان	۱	۰/۷۲۱	۰/۳۱۴	۰/۲۳۶	۰/۷۳۳	۰/۲۳۶	۰/۳۱۴	۰/۷۲۱	۰/۷۰۹
	۲	۰/۷۱۹	۰/۳۱۴	۰/۲۳۷	۰/۷۳۲	۰/۲۳۷	۰/۳۱۴	۰/۷۱۹	۰/۷۰۹
	۳	۰/۷۱۸	۰/۳۱۵	۰/۲۳۷	۰/۷۳۲	۰/۲۳۷	۰/۳۱۵	۰/۷۱۸	۰/۷۰۹
	۴	۰/۷۱۷	۰/۳۱۶	۰/۲۳۸	۰/۷۳۱	۰/۲۳۸	۰/۳۱۶	۰/۷۱۷	۰/۷۰۸
بندر ماهشهر	۱	۰/۷۱۶	۰/۳۱۷	۰/۲۳۹	۰/۷۳۱	۰/۲۳۹	۰/۳۱۷	۰/۷۱۶	۰/۷۰۸
	۲	۰/۷۱۵	۰/۳۱۸	۰/۲۴۱	۰/۷۳۱	۰/۲۴۱	۰/۳۱۸	۰/۷۱۵	۰/۷۰۶
	۳	۰/۷۱۴	۰/۳۱۹	۰/۲۴۲	۰/۷۳۰	۰/۲۴۲	۰/۳۱۹	۰/۷۱۴	۰/۷۰۶
	۴	۰/۷۱۳	۰/۳۲۱	۰/۲۴۲	۰/۷۲۹	۰/۲۴۲	۰/۳۲۱	۰/۷۱۳	۰/۷۰۵
صفی‌آباد	۱	۰/۷۱۲	۰/۳۲۲	۰/۲۴۳	۰/۷۲۹	۰/۲۴۳	۰/۳۲۲	۰/۷۱۲	۰/۷۰۴
	۲	۰/۷۱۱	۰/۳۲۳	۰/۲۴۴	۰/۷۲۸	۰/۲۴۴	۰/۳۲۳	۰/۷۱۱	۰/۷۰۴
	۳	۰/۷۰۹	۰/۳۲۴	۰/۲۴۵	۰/۷۲۷	۰/۲۴۵	۰/۳۲۴	۰/۷۰۹	۰/۷۰۳
	۴	۰/۷۰۸	۰/۳۲۵	۰/۲۴۶	۰/۷۲۷	۰/۲۴۶	۰/۳۲۵	۰/۷۰۸	۰/۷۰۲
دزفول	۱	۰/۷۰۶	۰/۳۲۶	۰/۲۴۶	۰/۷۲۶	۰/۲۴۶	۰/۳۲۶	۰/۷۰۶	۰/۷۰۲
	۲	۰/۷۰۶	۰/۳۲۷	۰/۲۴۷	۰/۷۲۵	۰/۲۴۷	۰/۳۲۷	۰/۷۰۶	۰/۷۰۱
	۳	۰/۷۰۵	۰/۳۲۷	۰/۲۴۷	۰/۷۲۴	۰/۲۴۷	۰/۳۲۷	۰/۷۰۵	۰/۷۰۱
	۴	۰/۷۰۴	۰/۳۲۸	۰/۲۴۸	۰/۷۲۳	۰/۲۴۸	۰/۳۲۸	۰/۷۰۴	۰/۶۹۹

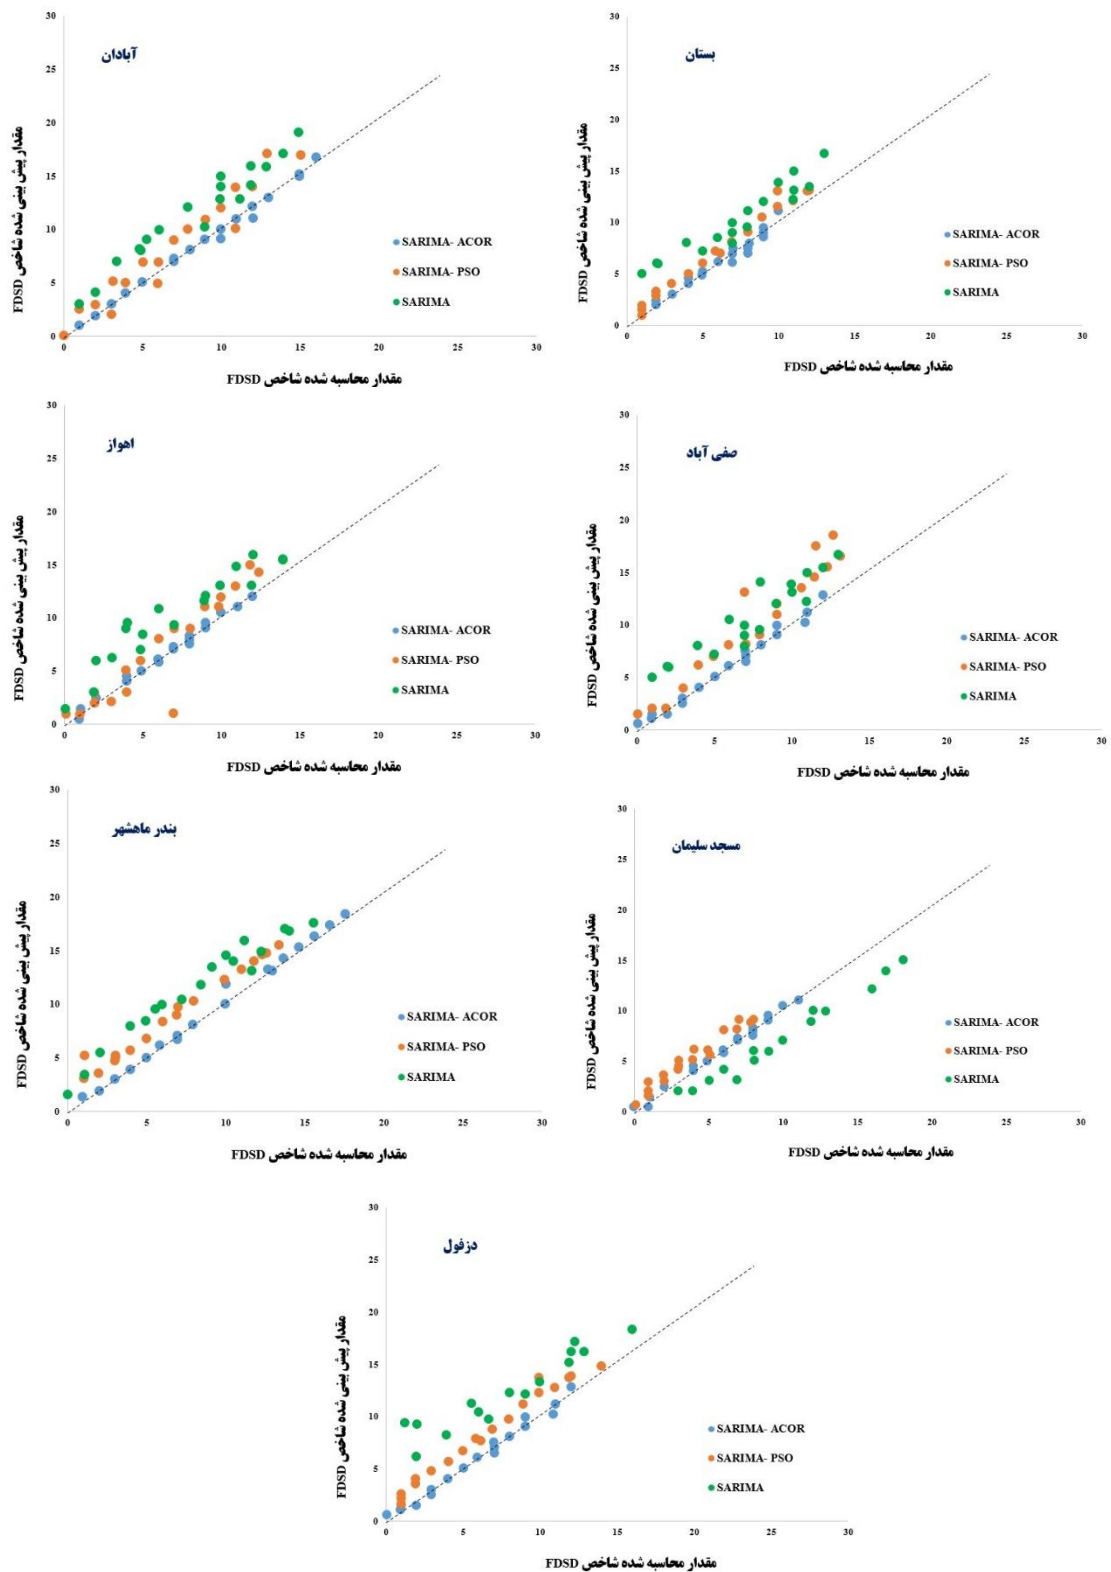
با مقایسه به نتایج مدل‌سازی در جداول ۳ تا ۵ می‌توان بیان کرد که دقت و بازدهی پیش‌بینی طوفان‌های گرد و غبار در نتیجه مدل‌سازی با مدل هیبریدی SARIMA- ACOR، به صورت چشم‌گیری در مقایسه با مدل هیبریدی SARIMA- PSO و مدل انفرادی SARIMA، افزایش یافته است. لذا مدل هیبریدی دوگانه SARIMA- ACOR به عنوان مدل برگزیده جهت پیش‌بینی شاخص FDS در استان خوزستان انتخاب شده است و پس از آن، مدل تلفیقی دوگانه SARIMA- PSO در رتبه دوم قرار گرفته است و مدل انفرادی SARIMA با اختلاف جزئی نسبت به آن، در رتبه سوم قرار دارد (شکل ۲). تفاوت نتایج ناشی از ترکیب مدل SARIMA با کاتالیزورهای کلونی مورچکان پیوسته و الگوریتم ازدحام ذرات را می‌توان در ذات مدل و وجود تفاوت‌های کلیدی در نحوه عملکرد کاتالیزورهای به کاررفته، جستجو کرد. PSO که بر اساس به‌روزرسانی موقعیت و سرعت ذرات عمل می‌کند، بیشتر برای مسائل پیوسته طراحی شده

است و در مواجهه با فضای جستجوی گسسته، ممکن است دقت و کارایی کمتری را به نمایش بگذارند. نتایج این قسمت با نتایج پورغلام آمیجی و همکاران (۱۳۹۸)، گودی (۲۰۰۶) و سبحانی و همکاران (۱۳۹۴) مطابقت دارد.

جدول ۵- نتایج آماری داده‌های ورودی به مدل SARIMA- ACOR به منظور پیش‌بینی FSD

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
آبادان	۱	۰/۹۰۲	۰/۱۷۵	۰/۱۰۲	۰/۹۰۹	۰/۸۸۱	۰/۱۹۸	۰/۱۲۳	۰/۸۹۱
	۲	۰/۹۰۲	۰/۱۷۶	۰/۱۰۲	۰/۹۰۸	۰/۸۸۰	۰/۱۹۹	۰/۱۲۴	۰/۸۹۱
	۳	۰/۹۰۱	۰/۱۷۷	۰/۱۰۲	۰/۹۰۷	۰/۸۸۰	۰/۱۹۹	۰/۱۲۴	۰/۸۹۰
	۴	۰/۹۰۱	۰/۱۷۸	۰/۱۰۳	۰/۹۰۶	۰/۸۷۹	۰/۲۰۱	۰/۱۲۵	۰/۸۸۹
اهواز	۱	۰/۹۰۱	۰/۱۷۸	۰/۱۰۴	۰/۹۰۶	۰/۸۷۸	۰/۲۰۱	۰/۱۲۶	۰/۸۸۸
	۲	۰/۹۰۱	۰/۱۷۹	۰/۱۰۵	۰/۹۰۵	۰/۸۷۸	۰/۲۰۲	۰/۱۲۷	۰/۸۷۶
	۳	۰/۹۰۱	۰/۱۷۹	۰/۱۰۶	۰/۹۰۵	۰/۸۷۶	۰/۲۰۳	۰/۱۲۷	۰/۸۷۶
	۴	۰/۸۹۹	۰/۱۸۱	۰/۱۰۷	۰/۹۰۵	۰/۸۷۶	۰/۲۰۴	۰/۱۲۸	۰/۸۷۵
بستان	۱	۰/۸۹۹	۰/۱۸۱	۰/۱۰۷	۰/۹۰۴	۰/۸۷۵	۰/۲۰۵	۰/۱۲۸	۰/۸۷۴
	۲	۰/۸۹۸	۰/۱۸۲	۰/۱۰۷	۰/۹۰۳	۰/۸۷۴	۰/۲۰۵	۰/۱۲۹	۰/۸۷۲
	۳	۰/۸۹۷	۰/۱۸۳	۰/۱۰۸	۰/۹۰۳	۰/۸۷۳	۰/۲۰۶	۰/۱۲۹	۰/۸۷۲
	۴	۰/۸۹۷	۰/۱۸۴	۰/۱۰۹	۰/۹۰۲	۰/۸۷۳	۰/۲۰۶	۰/۱۳۰	۰/۸۷۲
مسجد سلیمان	۱	۰/۸۹۶	۰/۱۸۵	۰/۱۰۹	۰/۹۰۲	۰/۸۷۲	۰/۲۰۷	۰/۱۳۰	۰/۸۷۱
	۲	۰/۸۹۵	۰/۱۸۵	۰/۱۱۱	۰/۹۰۱	۰/۸۷۲	۰/۲۰۸	۰/۱۳۱	۰/۸۷۰
	۳	۰/۸۹۵	۰/۱۸۵	۰/۱۱۲	۰/۹۰۱	۰/۸۷۱	۰/۲۰۸	۰/۱۳۲	۰/۸۶۹
	۴	۰/۸۹۵	۰/۱۸۶	۰/۱۱۳	۰/۸۹۹	۰/۸۷۰	۰/۲۰۹	۰/۱۳۳	۰/۸۶۸
بندر ماهشهر	۱	۰/۸۹۴	۰/۱۸۷	۰/۱۱۴	۰/۸۹۹	۰/۸۷۰	۰/۲۱۰	۰/۱۳۴	۰/۸۶۷
	۲	۰/۸۹۳	۰/۱۸۷	۰/۱۱۵	۰/۸۹۸	۰/۸۶۹	۰/۲۱۱	۰/۱۳۵	۰/۸۶۷
	۳	۰/۸۹۳	۰/۱۸۷	۰/۱۱۶	۰/۸۹۷	۰/۸۶۹	۰/۲۱۲	۰/۱۳۶	۰/۸۶۶
	۴	۰/۸۹۲	۰/۱۸۸	۰/۱۱۷	۰/۸۹۷	۰/۸۶۸	۰/۲۱۳	۰/۱۳۶	۰/۸۶۵
صفی‌آباد	۱	۰/۸۹۲	۰/۱۸۹	۰/۱۱۷	۰/۸۹۶	۰/۸۶۸	۰/۲۱۴	۰/۱۳۶	۰/۸۶۵
	۲	۰/۸۹۱	۰/۱۸۹	۰/۱۱۷	۰/۸۹۵	۰/۸۶۷	۰/۲۱۵	۰/۱۳۷	۰/۸۶۴
	۳	۰/۸۹۰	۰/۱۸۹	۰/۱۱۸	۰/۸۹۴	۰/۸۶۷	۰/۲۱۶	۰/۱۳۷	۰/۸۶۳
	۴	۰/۸۸۹	۰/۱۹۱	۰/۱۱۹	۰/۸۹۳	۰/۸۶۶	۰/۲۱۷	۰/۱۳۸	۰/۸۶۲
دزفول	۱	۰/۸۸۷	۰/۱۹۲	۰/۱۱۹	۰/۸۹۳	۰/۸۶۵	۰/۲۱۸	۰/۱۳۹	۰/۸۶۱
	۲	۰/۸۸۷	۰/۱۹۳	۰/۱۲۱	۰/۸۹۲	۰/۸۶۴	۰/۲۱۸	۰/۱۴۱	۰/۸۶۱
	۳	۰/۸۸۶	۰/۱۹۴	۰/۱۲۲	۰/۸۹۱	۰/۸۶۳	۰/۲۱۸	۰/۱۴۲	۰/۸۶۱
	۴	۰/۸۸۵	۰/۱۹۵	۰/۱۲۳	۰/۸۹۱	۰/۸۶۲	۰/۲۱۹	۰/۱۴۲	۰/۸۵۹

استفاده از کاتالیزور در مدل‌سازی، علی‌رغم بهبود دقت و کیفیت پیش‌بینی‌ها، معمولاً منجر به افزایش قابل توجه در زمان محاسبات، هزینه‌های اجرایی و پیچیدگی ساختار مدل می‌شود. این مسئله ناشی از ویژگی‌های ذاتی الگوریتم‌های کاتالیزوری و فرآیندهای پیچیده بهینه‌سازی است. کاتالیزورها، برای دستیابی به مقادیر بهینه پارامترها، نیازمند کاوش گسترده و ارزیابی مکرر تابع هدف در فضای جستجوی چندبعدی هستند. در مدل‌هایی نظیر SARIMA، که شامل تعداد زیادی از پارامترهای وابسته و اثرگذار است، این فرآیند مستلزم اجرای مکرر مدل برای هر ترکیب پارامتری است، که به‌طور طبیعی زمان محاسبات را به‌صورت نمایی افزایش می‌دهد.



شکل ۲. مقادیر محاسبه شده و پیش‌بینی شده شاخص FDS برای داده‌های تست هفت ایستگاه استان خوزستان

علاوه بر افزایش زمان، استفاده از کاتالیزور مستلزم بهره‌گیری از منابع محاسباتی پیشرفته نظیر پردازنده‌های گرافیکی (GPU) یا زیرساخت‌های پردازش ابری است. این امر نه تنها هزینه‌های مربوط به سخت‌افزار را افزایش می‌دهد، بلکه به دلیل مصرف انرژی بالا در محاسبات سنگین، هزینه‌های اجرایی کلی پروژه را نیز به طور چشمگیری بالا می‌برد. الگوریتم‌هایی نظیر ACOR یا PSO، که بر پایه تعاملات پیچیده و پردازش‌های تکرارشونده عمل می‌کنند، به سخت‌افزارهای پیشرفته برای کاهش زمان محاسبات و افزایش کارایی نیاز دارند. این الزامات فنی منجر به افزایش هزینه‌های مستقیم و غیرمستقیم مدل‌سازی می‌شود. نتایج این بخش با مطالعات گودرز و همکاران (۱۳۹۶) و Panicker و همکاران (۲۰۲۴) مطابقت دارد. علاوه بر این، استفاده از کاتالیزور نیازمند حضور متخصصانی با دانش عمیق در زمینه‌های ریاضیات پیشرفته، بهینه‌سازی و تحلیل داده است. طراحی، پیاده‌سازی، و تنظیم دقیق این الگوریتم‌ها، نیازمند نیروی انسانی با مهارت‌های تخصصی و تجربه کافی است، که هزینه‌های نیروی انسانی پروژه را افزایش می‌دهد. همچنین، ممکن است تیم‌های اجرایی نیازمند آموزش‌های اضافی برای استفاده از چنین ابزارهای پیشرفته‌ای باشند، که این امر زمان‌بری و هزینه‌زایی بیشتری را به دنبال خواهد داشت. به طور کلی، استفاده از کاتالیزور در مدل‌سازی با افزایش قابل توجه در زمان اجرا، هزینه‌های عملیاتی و پیچیدگی فنی همراه است. در نتیجه، انتخاب این ابزارها باید با توجه به منابع موجود، محدودیت‌های پروژه و اهداف مدنظر انجام شود، به گونه‌ای که بتوان تعادلی مناسب میان کیفیت پیش‌بینی‌ها و بهره‌وری کلی فرآیند مدل‌سازی برقرار کرد. لذا در شرایطی که تفاوت جزئی در نتایج و عملکرد مدل‌های SARIMA و SARIMA- PSO وجود دارد، و اختلاف این دو مدل در سطح اطمینان ۹۵ و ۹۹ درصد پس از اعتبار سنجی مدل معنادار نبوده است، استفاده از مدل انفرادی SARIMA به دلیل بهره‌وری اقتصادی بالاتر، کاهش در هزینه و پیچیدگی مدل‌سازی و صرف زمان کمتر، انتخابی منطقی‌تر به نظر می‌رسد. این امر به‌ویژه در پروژه‌هایی که محدودیت زمانی و مالی دارند یا نیازمند تکرارپذیری و مقیاس‌پذیری هستند، اهمیت بیشتری پیدا می‌کند. نتایج این بخش با مطالعات پورغلام آمیچی و همکاران (۱۴۰۰) و انصاری قوجقار و همکاران (۱۴۰۱) مطابقت دارد. در شکل ۲، مقادیر محاسبه‌شده و پیش‌بینی شده شاخص FDSO برای داده‌های تست هفت ایستگاه مدنظر، نمایش داده شده است. در واقع این شکل، افزایش عملکرد و کارایی روش‌های مذکور را به‌منظور پیش‌بینی FDSO را به خوبی نمایش می‌دهد. ارتباط میان مقادیر محاسبه‌شده و پیش‌بینی شده در هر هفت ایستگاه، خطی با شیب ۴۵ درجه می‌باشد. از میان مدل‌های بررسی شده، مدل انفرادی SARIMA دارای بیش‌ترین پراکندگی و مدل هیبریدی سه‌گانه SARIMA- ACOR کم‌ترین پراکندگی و لذا بیش‌ترین دقت را دارد.

۴. نتیجه‌گیری

طوفان‌های گرد و غبار از جمله مهم‌ترین چالش‌های زیست‌محیطی و اقلیمی در مناطق خشک و نیمه‌خشک جهان، به‌ویژه استان خوزستان، محسوب می‌شوند. این پدیده اثرات گسترده‌ای بر سلامت انسان، کیفیت زندگی، کشاورزی، زیرساخت‌ها و تعادل اکوسیستم‌های طبیعی دارد. عوامل متعددی در بروز و تشدید این طوفان‌ها نقش دارند که می‌توان آن‌ها را به دو دسته طبیعی و انسانی تقسیم کرد. عوامل طبیعی شامل کاهش بارندگی، خشکسالی‌های طولانی‌مدت، تخریب پوشش گیاهی و وزش بادهای شدید می‌شوند، در حالی که عوامل انسانی نظیر بهره‌برداری ناپایدار از منابع آب، کاهش جریان رودخانه‌ها و خشک‌شدن تالاب‌ها نقش قابل توجهی در افزایش فرکانس و شدت این پدیده دارند. موقعیت جغرافیایی استان خوزستان و مجاورت آن با کانون‌های خارجی گرد و غبار در کشورهای همسایه مانند عراق و سوریه نیز به این معضل دامن زده است. در این مطالعه، به منظور مدل‌سازی دقیق‌تر و مؤثرتر طوفان‌های گرد و غبار در استان خوزستان، از مدل‌های هیبریدی SARIMA-ACOR و SARIMA-PSO استفاده شده است. نتایج حاصل از بررسی معیارهای ارزیابی و نیکویی برازش در دو مرحله آموزش و تست داده‌ها، نشان می‌دهد که مدل هیبریدی SARIMA-ACOR به‌طور قابل توجهی عملکرد بهتری نسبت به سایر مدل‌های مورد بررسی داشته است. این مدل با ترکیب الگوریتم کلونی مورچگان (ACOR) و قابلیت‌های مدل SARIMA، موفق به کاهش خطای پیش‌بینی شده و الگوهای زمانی و فصلی را با دقت بیشتری شناسایی کرده است. الگوریتم ACOR به دلیل قدرت بالای خود در جستجوی

بهینه و همگرایی سریع، به‌عنوان یکی از اجزای کلیدی در بهبود عملکرد مدل شناخته شده است. ترکیب الگوریتم‌های هوشمند بهینه‌سازی مانند ACOR با مدل‌های انفرادی سری زمانی نظیر SARIMA، به‌عنوان رویکردی نوین در پیش‌بینی پدیده‌های پیچیده محیطی، نتایج چشمگیری ارائه داده است. این مدل هیبریدی نه تنها دقت پیش‌بینی را افزایش داده، بلکه امکان تحلیل‌های دقیق‌تر و گسترده‌تری از پویایی طوفان‌های گرد و غبار را فراهم کرده است. دستاوردهای این پژوهش نه تنها درک علمی از طوفان‌های گرد و غبار را ارتقا می‌بخشد، بلکه به‌عنوان ابزاری کاربردی برای سیاست‌گذاران و مدیران بحران در کاهش اثرات مخرب این پدیده و طراحی برنامه‌های منطقه‌ای مؤثر قابل استفاده است. این نتایج همچنین نشان‌دهنده ارزش روش‌های ترکیبی و پیشرفته در حل مسائل پیچیده اقلیمی و محیط‌زیستی هستند.

References

- Abbasi, H., Jalili, A., Kosroshahi, M., Fayaz, M., Khaksarian, F., Kenshlo, H., ... & Opp, C. (2024). Land management to control sand and dust storm sources—case study: The dust hotspot of south-eastern Ahvaz, Iran. In *E3S Web of Conferences* (Vol. 575, p. 07003). EDP Sciences.
- Adebiyi, A., Kok, J. F., Murray, B. J., Ryder, C. L., Stuu, J. B. W., Kahn, R. A., ... & Meng, J. (2023). *A review of coarse mineral dust in the Earth system, Aeolian Res.*, 60, 100849.
- Aghelpour, P., Singh, V. P., & Varshavian, V. (2021). Time series prediction of seasonal precipitation in Iran, using data-driven models: a comparison under different climatic conditions. *Arabian Journal of Geosciences*, 14, 1-14. (In Persian)
- Ahmadpour, A., Mirhashemi, & Panahi. (2021). Evaluation of neural network algorithms, time series models, and the SARIMA-SETAR hybrid model in monthly wind speed prediction. *Arid Biome*, 10(2), 131-146. (In Persian)
- Ansari Ghojghar, M. A., Pourgholam-Amiji, M., Bazrafshan, J., Araghinejad, S., Liaghat, A., & Hosseini-Moghari, S. M. (2021). Performance Evaluation of Genetic Algorithm and GA-SA Hybrid Method in Forecasting Dust Storms (Case Study: Khuzestan Province). *Soil and Water Research*, 51(10), 2623-2639. (In Persian)
- Ansari Ghojghar, M., Araqi Nejad, Sh., Bazrafshan, J., Zahraei, B., & Parsi, E. (2021). Assessing the efficiency of the GRU-LSTM hybrid model in predicting dust storms (Case study: Khuzestan province). (In Persian)
- Ansari Ghojghar, M., Bazrafshan, J., & Araghinejad, S. (2022). Evaluating the Efficiency of Hybrid Metamodels of Machine Learning and Box Jenkins in Order to Model Dust Storms (Case Study: Khuzestan Province). *Iranian Journal of Soil and Water Research*, 53(8), 1695-1714. (In Persian)
- Ansari Ghojghar, M., Pourgholam-Amiji, M., Araghinejad, S., Zahraie, B., Razavi, S., & Salajegheh, A. (2021). Evaluation of the Combination of ANFIS Model with Metaheuristic Optimization Algorithms in Predicting Dust Storms of Khuzestan Province. *Journal of Range and Watershed Management*, 73(4), 691-708. (In Persian)
- Ansari Ghojghar, M., Pourgholam-Amiji, M., Bazrafshan, J., Liaghat, A., & Araghinejad, S. (2020). Performance Comparison of statistical, fuzzy and perceptron neural network models in forecasting dust storms in critical regions in Iran. *Iranian Journal of Soil and Water Research*, 51(8), 2051-2063. (In Persian)
- Araghinejad, S., Ansari Ghojghar, M., PourGholam Amigi, M., Liaghat, A., & Bazrafshan, J. (2022). The effect of climate fluctuation on frequency of dust storms in Iran. *Desert Ecosystem Engineering*, 7(21), 13-32. (In Persian)
- Arami, S. H., Karimi Sangchini, E., Alimahmoodi Sarab, S., Dinarvand, M. and Yasrebi, B. (2024). Mapping spatial and temporal pattern of risk and hazard of dust storms in Khuzestan province. *Journal of Arid Biome*, 14(1), 61-78.
- Awadh, S. M. (2023). Impact of North African sand and dust storms on the Middle East using Iraq as an example: Causes, sources, and mitigation. *Atmosphere*, 14(1), 180.
- Bahrami, H.-A., Jalali, J., & Darvishi Balourani, B. (2014). Spatiotemporal modeling of dust storm occurrences in Khuzestan province. *Iranian Journal of Remote Sensing and GIS*, 5(2). (In Persian)
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- de Jesús Guevara-Macías, M., Pineda-Martínez, L. F., & Carbajal, N. (2023). A descriptive study of dust storms and air quality in a semi-arid region of Mexico. *Air Quality, Atmosphere & Health*, 16(8), 1645-1660.
- Dorigo, M. (2007). Ant colony optimization. *Scholarpedia*, 2(3), 1461.

- Fallah Ghalehri, F., & Sarvestan, S. (2020). Analysis and forecasting of dust phenomena in Khuzestan province using Box-Jenkins time series models. *Watershed Engineering and Management Journal*, 12(3), 608–620. (In Persian)
- Gillette, D. A. (1981). Production of dust that may be carried great distances.
- Golestan, A., & Molai-Zahedi, Z. (2013). A review of swarm intelligence-based optimization algorithms. *Conference on Computer*. (In Persian)
- Gorissen, B. L., Yankıođlu, İ., & Den Hertog, D. (2015). A practical guide to robust optimization. *Omega*, 53, 124-137.
- Goudie, A. S., & Middleton, N. J. (2006). Desert dust in the global system. Springer Science & Business Media.
- Guo, Y. T., Zhang, J., Wang, S. G., She, F., & Li, X. (2011). Long-term characterization of major water-soluble inorganic ions in PM 10 in coastal site on the Japan Sea. *Journal of atmospheric chemistry*, 68, 299-316.
- Hahnenberger, M., & Nicoll, K. (2014). Geomorphic and land cover identification of dust sources in the eastern Great Basin of Utah, USA. *Geomorphology*, 204, 657-672.
- Helmi Mahtab, M., Bakhtiari Bahram, B., & Qadri Kourosh, K. (2020). Modeling and predicting meteorological drought using the SARIMA time series model in various climatic regions of Iran. (in persian)
- Jahanbakhsh-Asl, M., Khorshidoost, M., Abbasi-Qasrekik, & Abbasi-Qasrekik. (2024). Comparative application of time series models in predicting precipitation in West Azerbaijan province. *Applied Research in Geographical Sciences*, 24(75), 98–115. (In Persian)
- Karahan, H., Gurarlan, G., & Geem, Z. W. (2013). Parameter estimation of the nonlinear Muskingum flood-routing model using a hybrid harmony search algorithm. *Journal of Hydrologic Engineering*, 18(3), 352-360.
- Kargar, E., Badaq Jamali, J., Ranjbar Sa'adat Abadi, A., Moeinoddini, M., & Gashtasb, H. (2016). Simulation and numerical analysis of severe dust storms in eastern Iran. *Spatial Analysis of Environmental Hazards*, 3(4), 101–119. (In Persian)
- Li, A., & Draine, B. T. (2002). Infrared Emission from Interstellar Dust. III. The Small Magellanic Cloud. *The Astrophysical Journal*, 576(2), 762.
- Middleton, N., Kashani, S. S., Attarchi, S., Rahnama, M., & Mosalman, S. T. (2021). Synoptic causes and socio-economic consequences of a severe dust storm in the Middle East. *Atmosphere*, 12(11), 1435.
- Nasari, S. H., & Chitgar, S. (2020). A new method for solving multi-objective stochastic optimization models with chance constraints. *Operational Research and Its Applications (Applied Mathematics)*, 17(3), 63–79. (In Persian)
- Nickling, W. G., & Gillies, J. A. (1989). Emission of fine-grained particulates from desert soils. In *Paleoclimatology and Paleometeorology: modern and past patterns of global atmospheric transport* (pp. 133-165). Dordrecht: Springer Netherlands.
- Panicker, N. K. K., & Valarmathi, J. (2024). Time series prediction of aerosol optical depth across the northern Indian region: integrating PSO-optimized SARIMA-SVR based on MODIS data. *Acta Geophysica*, 1-30.
- Pourgholam Amiji, A., Ansari Qojaqar, M., Bazrafshan, J., Liaqaat, A., & Araqi Nejad, Sh. (2020). Comparing the performance of SARIMA and Holt-Winters time series models with artificial intelligence methods in forecasting dust storms (Case study: Sistan and Baluchestan province). *Journal of Natural Geography Research*, 52(4), 567–587. (In Persian)
- Shafieejad, I., Dehkordi, M. R. B., & Amin, M. (2024). A review of the application of optimization algorithms nature inspired in the design of flight paths. *Technology in Aerospace Engineering*, 8(3), 75-99. (In Persian)
- Shuker, Z. (2022). Dust Storms and Climate Change: A Crisis for the Iraqi Economy, and the Need for Multilateral Solutions. *The Institute of Regional and International Studies: Islamabad, Iraq*.
- Sobhani, B., Safarian Zengir, V., & Faizollahzadeh, S. (2020). Modeling and prediction of dust in western Iran. *Physical Geography Research Quarterly*, 52(1), 17-35. (In Persian)
- Socha, K., & Dorigo, M. (2008). Ant colony optimization for continuous domains. *European journal of operational research*, 185(3), 1155-1173.
- Sun, Y., Zhuang, G., Yuan, H., Zhang, X., & Guo, J. (2004). Characteristics and sources of 2002 super dust storm in Beijing. *Chinese Science Bulletin*, 49, 698-705.
- UNEP, W. (2021). UNCCD (2016) Global assessment of sand and dust storms. *United Nations Environment Programme, Nairobi*.
- Zeynali, M. J., & Bilandi, M. P. (2018). Estimation of optimal parameters of the nonlinear Muskingum routing model using the continuous ant colony algorithm. *Iranian Journal of Irrigation and Drainage Engineering*, 8(3), 94–106. (in persian)
- Zhu, W., & Duan, H. (2014). Chaotic predator–prey biogeography-based optimization approach for UCAV path planning. *Aerospace science and technology*, 32(1), 153-161.