

## Development of a nonparametric K-Nearest neighbors model enhanced by the PSO metaheuristic catalyst for dust storm modeling in Western Iran

Mohammad Ansari Ghojghar <sup>1\*</sup>, Haniyeh Mohammadi <sup>2</sup>

1. Department of reclamation of arid and mountainous regions Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

2. Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

\* Corresponding author: [ansari.ghojghar@ut.ac.ir](mailto:ansari.ghojghar@ut.ac.ir)

(Received: 03 May 2025

Revised: 06 Jun 2025

Accepted: 15 July 2025)

### Extended Abstract

**Introduction:** Dust storms are among the most significant climatic hazards in the arid and semi-arid regions of Iran, accompanied by consequences such as reduced visibility, severe air pollution, threats to public health, decreased agricultural productivity, and damage to urban and rural infrastructure. In recent years, particularly in the western regions of the country, an increasing trend has been observed in the intensity, frequency, and spatial extent of this phenomenon. This alarming trend results from a combination of natural factors, such as recurring droughts, declining soil moisture, and strong winds, as well as human-induced drivers, including unbalanced land use changes, excessive exploitation of water resources, and unsustainable land management practices. Given the widespread impacts of this phenomenon on the environment and the livelihoods of local populations, accurately predicting the number of dusty days within specific time periods is of great importance as a critical tool for damage mitigation and informed operational and managerial decision-making. Achieving this goal requires the use of advanced data-driven methods and artificial intelligence algorithms that can be effective in identifying complex, nonlinear, and non-deterministic patterns.

**Materials and methods:** In this study, a nonparametric predictive model based on the K-Nearest Neighbors (KNN) algorithm was developed. The Particle Swarm Optimization (PSO) metaheuristic algorithm was employed as a catalyst to optimize the model structure and enhance its prediction accuracy. The input data included the Frequency of Dust Storm Days (FDSD) index from 26 synoptic stations located in 11 provinces across western Iran, covering the long-term period from 1981 to 2020. To construct the predictive model, lagged values of the FDSD index over the four previous time steps were used as input variables to accurately capture the temporal patterns of this phenomenon. Initially, the base KNN model was implemented by adjusting the k parameter. Subsequently, the PSO algorithm was applied to optimize key model parameters, including the number of influential neighbors and the weighting of input variables. The models' performance was evaluated using four statistical indicators: the correlation coefficient (r), root mean square error (RMSE), mean absolute error (MAE), and Nash–Sutcliffe efficiency (NS) coefficient, to assess the model's accuracy and stability in predicting the FDSD index.

**Results and Discussion:** The results show that the KNN-PSO model outperformed the standalone KNN model. The application of the PSO algorithm allowed for automatic and optimal determination of key KNN parameters, such as the optimal number of neighbors (k) and weighting of input variables. For instance, at Abadan station, the correlation coefficient (R) of the KNN-PSO model increased to 0.997, while the RMSE decreased to 0.113. In contrast, the KNN model values were 0.654 and 0.437, respectively, indicating a significant improvement in prediction accuracy using the hybrid model. Comparison between observed and predicted values confirmed the improved model performance with an increased frequency of dust storm days. Among the stations studied, Abadan, which recorded the highest FDSD values, showed the highest agreement between the observed and predicted data. Overall, high-dust stations, such as Abadan, Ahvaz, Masjed Soleyman, Bostan, Sarpol-e Zahab, and Bandar Mahshahr, exhibited strong correlations between actual and predicted values. In scatter plots, these predictions closely followed the 1:1 line ( $f(x) = x$ ), indicating the high efficiency of the KNN-PSO model. Furthermore, results revealed that using lagged FDSD indices from previous seasons did not enhance model performance, and simpler models utilizing only one-step lag yielded more accurate predictions.

**Conclusions:** Overall, the results demonstrate that the hybrid KNN-PSO model can significantly enhance the accuracy of predicting the frequency of dust storm days, particularly at stations with high occurrence rates, such as Abadan. By leveraging the capability of the PSO algorithm to automatically and optimally determine the sensitive parameters of the KNN model, this approach improves predictive performance compared to the base model. The findings indicate that integrating metaheuristic optimization algorithms such as PSO with simple data-driven models such as KNN not only increases prediction accuracy and efficiency in climatically challenging regions but also enhances the stability and generalizability under varying climatic and spatial conditions. Therefore, the use of such hybrid approaches can be considered an effective strategy for improved monitoring and management of climate-related hazards, including dust storms, in arid and semiarid regions.

**Keywords:** Metaheuristic Algorithm, Particle Swarm Optimization, Dust Storm, Hybrid Models, Artificial Intelligence.

Citation: Ansari Ghojghar, M., & Mohammadi, H. (2026). Development of a nonparametric K-Nearest neighbors model enhanced by the PSO metaheuristic catalyst for dust storm modeling in Western Iran. *Integrated Watershed Management*, 6(1), 85-106. doi= 10.22034/iwm.2025.2059627.1226

### Copyrights:

Copyright for this article is retained by the author(s), with publication rights granted to Integrated Watershed Management. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>).



## توسعه مدل ناپارامتریک K نزدیکترین همسایه با کاتالیزور فراابتکاری PSO به منظور مدل

### سازی طوفان‌های گرد و غباری در غرب ایران

محمد انصاری قوجقار<sup>۱\*</sup>، هانیه محمدی<sup>۲</sup>

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

۲. گروه مهندسی آبیاری و آبادانی، دانشکده کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

\*نویسنده مسئول: [ansari.ghojghar@ut.ac.ir](mailto:ansari.ghojghar@ut.ac.ir)

تاریخ پذیرش: ۱۴۰۴/۰۴/۲۴

تاریخ بازنگری: ۱۴۰۴/۰۳/۲۱

تاریخ دریافت: ۱۴۰۴/۰۲/۱۳

#### چکیده مبسوط

**مقدمه:** طوفان‌های گرد و غبار از مهم‌ترین مخاطرات اقلیمی در مناطق خشک و نیمه‌خشک ایران به شمار می‌آیند و با پیامدهایی نظیر کاهش دید افقی، آلودگی شدید هوا، تهدید سلامت عمومی، کاهش بازدهی محصولات کشاورزی و آسیب به زیرساخت‌های شهری و روستایی همراه هستند. در سال‌های اخیر، به‌ویژه در مناطق غربی کشور، روند افزایشی در شدت، بسامد و گستره مکانی این پدیده مشاهده شده است. این روند نگران‌کننده عمدتاً تحت تأثیر مجموعه‌ای از عوامل طبیعی نظیر خشکسالی‌های مکرر، افت رطوبت خاک و وزش بادهای شدید، در کنار عوامل انسانی همچون تغییرات نامتوازن کاربری اراضی، بهره‌برداری بی‌رویه از منابع آب و مدیریت ناپایدار سرزمین شکل گرفته است. نظر به تبعات گسترده این پدیده بر محیط‌زیست و زندگی ساکنان آن مناطق، پیش‌بینی دقیق پیش‌بینی دقیق تعداد روزهای گرد و غباری در بازه‌های زمانی مشخص، به عنوان ابزاری کلیدی در کاهش خسارات و تصمیم‌گیری‌های مدیریتی و عملیاتی اهمیت فراوان دارد. دستیابی به این هدف مستلزم بهره‌گیری از روش‌های نوین داده‌محور و الگوریتم‌های هوش مصنوعی است که می‌توانند در شناسایی الگوهای پیچیده، غیرخطی و غیرقطعی مؤثر واقع شوند.

**مواد و روش‌ها:** در این پژوهش، یک مدل ناپارامتریک پیش‌بینی بر پایه الگوریتم K نزدیک‌ترین همسایه (KNN) توسعه داده شد که با بهره‌گیری از الگوریتم فراابتکاری ازدحام ذرات (PSO) به‌عنوان کاتالیزور، ساختار مدل بهینه‌سازی و دقت پیش‌بینی آن ارتقاء یافت. داده‌های مورد استفاده شامل شاخص فراوانی روزهای همراه با طوفان گرد و غبار (FSDS) از ۲۶ ایستگاه سینوپتیک واقع در ۱۱ استان در نیمه‌غربی کشور، طی یک دوره بلندمدت ۴۰ ساله (۱۹۸۱ تا ۲۰۲۰) بود. برای ساخت مدل پیش‌بینی، از مقادیر تأخیری شاخص FSDS در قالب چهار گام زمانی گذشته به‌عنوان ورودی استفاده شد تا الگوی تغییرات زمانی این پدیده به‌درستی شناسایی شود. در مرحله نخست، مدل پایه KNN با تنظیم پارامتر k اجرا شد و سپس الگوریتم PSO برای بهینه‌سازی پارامترهای کلیدی مدل، از جمله تعداد همسایگان مؤثر و وزن دهی به متغیرهای ورودی، به کار گرفته شد. ارزیابی عملکرد مدل‌ها با استفاده از چهار معیار آماری شامل ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و ضریب کارایی نش-سانتکلیف (Nash-Sutcliffe Efficiency - NS) صورت گرفت تا میزان دقت و پایداری مدل در پیش‌بینی شاخص FSDS سنجیده شود.

**نتایج و بحث:** نتایج نشان داد که مدل KNN-PSO عملکرد بهتری نسبت به مدل انفرادی KNN دارد. استفاده از الگوریتم PSO موجب شد تا پارامترهای حساس مدل KNN از جمله تعداد همسایگان (k) و وزن‌دهی به متغیرهای ورودی به‌صورت خودکار و بهینه تعیین شود. به‌طوری‌که در ایستگاه آبادان، ضریب همبستگی (r) مدل KNN-PSO به ۰/۹۹۷ افزایش و ضریب RMSE به ۰/۱۱۳ کاهش یافت، در حالی که این مقادیر در مدل KNN به ترتیب ۰/۶۵۴ و ۰/۴۳۷ بودند که نشان‌دهنده بهبود چشمگیر دقت پیش‌بینی با استفاده از فرامدل ترکیبی است. مقایسه مقادیر مشاهداتی و پیش‌بینی‌شده، بهبود عملکرد مدل‌ها را با افزایش فراوانی روزهای گرد و غباری تأیید می‌کند. در این میان، ایستگاه آبادان که بالاترین مقدار شاخص FSDS را در میان ایستگاه‌های مطالعه‌شده دارد، بیشترین انطباق بین مقادیر مشاهداتی و پیش‌بینی‌شده را نشان داد. به‌طور کلی، ایستگاه‌های پرگرد و غبار مانند آبادان، اهواز، مسجدسلیمان، بستان، سرپل‌ذهاب و بندرماهشهر، همبستگی بالایی بین مقادیر واقعی و پیش‌بینی‌شده داشتند؛ به‌گونه‌ای که در نمودارهای پراکندگی، به خط نیمساز ربع اول  $f(x)=x$  بسیار نزدیک بودند و نشان‌دهنده کارایی بالای مدل KNN-PSO می‌باشند. همچنین نتایج نشان داد که به‌کارگیری شاخص‌های تأخیری از فصول گذشته موجب بهبود عملکرد مدل نشد و مدل‌های ساده‌تری که تنها از یک گام تأخیر استفاده کردند، دقت بالاتری را ارائه دادند.

**نتیجه‌گیری:** به‌طور کلی، نتایج نشان داد که مدل ترکیبی KNN-PSO قادر است دقت پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار را به‌ویژه در ایستگاه‌هایی با فراوانی بالا نظیر آبادان، به‌طور معنی‌داری افزایش دهد. این مدل با استفاده از قابلیت الگوریتم PSO در تعیین خودکار و بهینه پارامترهای حساس مدل KNN، توانست عملکرد پیش‌بینی را نسبت به مدل پایه بهبود دهد. یافته‌ها نشان می‌دهند که تلفیق الگوریتم‌های بهینه‌سازی فراکوشی مانند PSO با مدل‌های داده‌محور ساده نظیر KNN نه تنها موجب افزایش دقت و کارایی پیش‌بینی در مناطق پرچالش اقلیمی می‌شود، بلکه می‌تواند پایداری و تعمیم‌پذیری این مدل‌ها را در شرایط متغیر اقلیمی و مکانی نیز ارتقاء دهد؛ بنابراین، استفاده از چنین رویکردهای ترکیبی می‌تواند به‌عنوان راهکاری مؤثر برای پیش و مدیریت بهتر مخاطرات اقلیمی از جمله طوفان‌های گرد و غبار در مناطق خشک و نیمه‌خشک مورد توجه قرار گیرد.

**واژه‌های کلیدی:** الگوریتم فراکوشی، بهینه‌سازی ازدحام ذرات، طوفان گرد و غبار، مدل‌های ترکیبی، هوش مصنوعی.

**استناد:** انصاری قوجقار، م؛ و محمدی، ه (۱۴۰۵). توسعه مدل ناپارامتریک K نزدیک‌ترین همسایه با کاتالیزور فراابتکاری PSO به منظور مدل‌سازی طوفان‌های گرد و غباری در غرب ایران. مدیریت جامع حوزه‌های آبخیز. ۱۰۶-۸۵.

#### حق چاپ:



حق چاپ برای نویسنده (گان) این مقاله محفوظ است. بر اساس قوانین انتشارات با دسترسی آزاد، تمام مطالعات چاپ شده در این نشریه به‌صورت آزاد در وبسایت نشریه برای عموم بدون پرداخت هزینه قابل دسترس است.

## مقدمه

گرد و غبار جوی یکی از پدیده‌های رایج اقلیمی در مناطق خشک و نیمه‌خشک جهان است که می‌تواند تأثیرات گسترده‌ای بر محیط‌زیست، سلامت انسان و سامانه‌های اقتصادی داشته باشد. ذرات گرد و غبار عمدتاً توسط فرسایش بادی در مناطق خشک و نیمه‌خشک در سراسر جهان تولید می‌شوند. برآورد می‌شود که انتشار گرد و غبار جهانی حدود ۳۰۰۰ میلیون تن در سال است که مقدار قابل توجهی از این گرد و غبار منتشر شده در اقیانوس‌ها رسوب می‌کند. با این حال، چنین برآوردهایی در مطالعات مختلف از ۱۰۰ تا ۱۰۰۰۰ میلیون تن متغیر است (Shao, 2008). بزرگترین منابع انتشار گرد و غبار معدنی در جهان در صحرای بزرگ آفریقا، خاورمیانه و مناطق بیابانی مرکزی تا شرق آسیا قرار دارند (Xiong et al., 2020). برآورد می‌شود که نرخ سالانه انتشار گرد و غبار در این مناطق، که به آن کمربند گرد و غبار نیز گفته می‌شود، به ۱۳۰۰-۱۰۰۰ میلیون تن برسد که بیش از سه چهارم از انتشار گرد و غبار جهانی را به خود اختصاص دهد (Ginoux et al., 2012). با توجه به مناطق وسیع خشک، خاورمیانه به‌طور مکرر شاهد وقوع طوفان‌های گرد و غبار است. بر اساس گزارش سال ۲۰۲۲ سازمان جهانی هواشناسی، چهار کانون اصلی در این منطقه که بیشترین فراوانی طوفان‌های گرد و غبار را تجربه می‌کنند، شامل: (۱) شمال سودان و جنوب مصر، (۲) شبه‌جزیره عربستان (به‌ویژه عربستان سعودی)، (۳) بین‌النهرین (عراق و شرق سوریه) و (۴) منطقه فلات ایران تا شمال پاکستان و افغانستان است (WMO, 2022). کشورهای سودان، عربستان سعودی، عراق، ایران، افغانستان و پاکستان درون این مناطق قرار دارند و به‌طور منظم طوفان‌های گرد و غبار را تجربه می‌کنند. با این حال، توزیع زمانی و مکانی این حوادث در مناطق مختلف یکسان نیست (Rezazadeh et al., 2013). پنج

منطقه در ایران وجود دارد (دشت خوزستان در جنوب غربی ایران، دشت ساحلی خلیج فارس، قسمت غربی ایران، منطقه طبس در قسمت مرکزی شرقی ایران و منطقه سیستان در جنوب شرقی ایران) که طوفان‌های گرد و غبار در آن‌ها به‌طور مکرر اتفاق می‌افتد (Alizadeh-Choobari et al., 2016). با این وجود، به‌طور کلی پذیرفته شده است که مقدار قابل توجهی از ذرات گرد و غبار در ایران از منابع فرامرزی، به‌ویژه همسایگان غربی مانند عراق و سوریه منتشر می‌شود (Shahsavani et al., 2012; Ashrafi et al., 2014). طوفان‌های گرد و غبار زمانی رخ می‌دهند که سرعت باد در مناطق خشک و بیابانی (بین ۶/۵ تا ۷ متر بر ثانیه) از آستانه فرسایش عبور کند، که موجب افزایش تعداد ذرات خاک معلق در هوا می‌شود (Namdari et al., 2021). بر اساس تعریف سازمان جهانی هواشناسی<sup>۱</sup>، طوفان‌های گرد و غبار ناشی از آشفته‌گی‌های جوی هستند که باعث ورود حجم بالایی از گرد و غبار به جو شده که در نتیجه آن دید افقی به کمتر از ۱۰۰۰ متر کاهش می‌یابد (Goudie & Middleton, 2006). از طرف دیگر طوفان‌های گرد و غبار پدیده‌های جوی فاجعه‌باری هستند که به شدت بر اقتصاد، محیط‌زیست، سلامت (بیماری‌های تنفسی حاد) و محصولات کشاورزی تأثیر می‌گذارند (Rashki et al., 2021). افزایش وقوع این پدیده در مناطق مختلف جهان از جمله ایران، توجه جامعه علمی را به خود جلب کرده و منجر به اجرای پروژه‌های پژوهشی متعدد در این زمینه شده است. به عنوان مثال، Razavi-Termeh و همکاران (۲۰۲۴) در مطالعه‌ای برای شناسایی وقوع گرد و غبار و تهیه نقشه حساسیت به گرد و غبار<sup>۲</sup> (DSM) در استان بوشهر، از تصاویر MODIS و مدل TabNet استفاده شد. این مدل با

اثربخشی مدل ترکیبی در مدیریت نایستایی و پیچیدگی داده‌های AOD تأکید دارد (Panicker & Valarmathi, 2025).

روش‌های سنتی پیش‌بینی فراوانی طوفان‌های گرد و غبار عمدتاً بر مشاهده و تحلیل آماری داده‌های هواشناسی گذشته و حال برای شناسایی الگوها و روندها تمرکز داشته‌اند (Albugami et al., 2019; Dar et al., 2022) و همچنین از مدل‌های عددی اقلیمی برای شبیه‌سازی شرایط جوی بهره گرفته‌اند (Akhlaq et al., 2012). با این حال، عوامل پیچیده و پویایی مانند منابع گرد و غبار، پوشش گیاهی و تغییرات کاربری اراضی، نیاز به رویکردی جامع‌تر از روش‌های سنتی دارند (Middleton & Goudie, 2001). پیشرفت‌های اخیر در پیش‌بینی طوفان‌های گرد و غبار استفاده از روش‌های یادگیری ماشین را دربرگرفته‌اند (Alshammari et al., 2022). در همین راستا، بهره‌گیری از مدل‌های هوش مصنوعی، به‌ویژه الگوریتم‌های یادگیری ماشین و فراگیری عمیق، به عنوان ابزارهایی قدرتمند در تحلیل داده‌های پیچیده و غیرخطی، در سال‌های اخیر توجه بسیاری از پژوهشگران حوزه گرد و غبار را به خود جلب کرده است. این مدل‌ها با توانایی بالا در شناسایی الگوها و روابط پنهان میان متغیرهای متعدد محیطی، امکان پیش‌بینی دقیق‌تر وقوع و شدت طوفان‌های گرد و غبار را فراهم می‌سازند (Alshammari et al., 2024).

به عنوان مثال، در یکی از مطالعات انجام‌شده در مناطق خشک ایران، نه مدل مختلف یادگیری ماشین از جمله SVM، KNN، RF و XGBoost برای پیش‌بینی شاخص طوفان گرد و غبار<sup>۱۱</sup> (DSI) در دوره ۲۰۰۰ تا ۲۰۱۸ به‌کار گرفته شد و نتایج نشان داد که روش

کمک سه الگوریتم بهینه‌سازی مبتنی بر ازدحام ذرات<sup>۱</sup> (PSO)، بهینه‌سازی گرگ خاکستری<sup>۲</sup> (GWO) و جستجوی بازی‌های گرسنگی<sup>۳</sup> (HGS) بهبود یافت. نتایج نشان داد که مدل TabNet-HGS با مقادیر AUC برابر ۰/۹۹۴ و R<sup>2</sup> برابر ۰/۹۴۷، بالاترین دقت را در پیش‌بینی حساسیت به گرد و غبار دارد. این تحقیق نشان داد که ادغام الگوریتم‌های بهینه‌سازی با مدل TabNet دقت مدل‌سازی حساسیت به گرد و غبار را به‌طور چشمگیری افزایش می‌دهد (Razavi-Termeh et al., 2024). همچنین در مطالعه‌ای دیگر که توسط Ansari Ghojghar و همکاران (۲۰۲۰) صورت گرفت، عملکرد دو مدل ترکیبی W-SVM<sup>۴</sup> و AF-SVM<sup>۵</sup> با مدل SVM در پیش‌بینی شاخص فراوانی روزهای همراه با گرد و غبار<sup>۶</sup> (FSD) با استفاده از داده‌های ۴۰ ساله پنج ایستگاه سینوپتیک استان سیستان و بلوچستان مقایسه شد. نتایج این تحقیق نشان داد مدل ترکیبی موجک-ماشین بردار پشتیبان (W-SVM) با مقادیر بالای ضریب تبیین (تا ۰/۹۸۴) و ضریب نش ساتکلیف (تا ۰/۹۶۵) نسبت به سایر مدل‌ها دقت بهتری در پیش‌بینی این شاخص دارد. در تحقیق دیگری، مدلی ترکیبی به نام PSOSARIMA-PSOSVR برای پیش‌بینی عمق نوری آئروسول<sup>۷</sup> (AOD) ارائه شده است که با تلفیق قابلیت‌های مدل خطی SARIMA<sup>۸</sup> و مدل غیرخطی SVR<sup>۹</sup> و بهینه‌سازی پارامترها با الگوریتم ازدحام ذرات (PSO)، توانسته است دقت پیش‌بینی را به‌طور چشمگیری افزایش دهد. این مدل با داده‌های ماهواره‌ای MODIS در شمال هند (۲۰۱۹-۲۰۰۱) آزمایش شد و نسبت به مدل‌های منفرد SARIMA، SVR<sup>۱۰</sup> و LSTM<sup>۱۱</sup> عملکرد بهتری نشان داد و بر

7- Aerosol Optical Depth

8- Seasonal Autoregressive Integrated Moving Average

9- Support Vector Regression

10- Long Short-Term Memory

11- Dust Storm Index

1- Particle Swarm Optimization

2- Grey Wolf Optimizer

3- Hunger Games Search

4- Support Vector Machine-Wavelet

5- Support Vector Machine-artificial plants algorithm

6- Frequency of Dust Storm Days

این تحقیق با هدف توسعه رویکردهای مدرن پیش‌بینی شاخص FDSM، بر مبنای به‌کارگیری دو مدل یادگیری ماشین، شامل KNN و نسخه بهبود یافته‌ی آن با بهینه‌سازی ازدحام ذرات (KNN-PSO)، انجام شده است. به این منظور، داده‌های ۲۶ ایستگاه سینوپتیک در غرب و جنوب‌غرب ایران، واقع در ۱۱ استان، طی دوره بلندمدت ۴۰ ساله (۱۹۸۱ تا ۲۰۲۰) مورد استفاده قرار گرفت. شکل (۱) موقعیت جغرافیایی ایستگاه‌های سینوپتیک مورد مطالعه در نیمه‌غربی کشور را نشان می‌دهد. اطلاعات به‌کار رفته شامل داده‌های ساعتی دید افقی و کدهای طبقه‌بندی شده طبق استانداردهای سازمان جهانی هواشناسی (WMO) است. در این داده‌ها، مشاهدات وضعیت جوی هر سه ساعت یک‌بار (روزانه هشت بار) ثبت شده و پدیده‌های آب‌وهوایی در قالب ۱۰۰ کد مختلف (از ۰ تا ۹۹) گزارش شده‌اند که از این میان، ۱۱ کد مختص پدیده‌های مرتبط با گرد و غبار است (O'Loingsigh *et al.*, 2014). بر اساس دستورالعمل‌های سازمان جهانی هواشناسی، اگر در دست‌کم یکی از گزارش‌های سه‌ساعته یک روز، یکی از کدهای مربوط به گرد و غبار (کدهای ۰۶، ۰۷، ۰۸، ۰۹، ۳۰ تا ۳۵ و ۹۸) ثبت شده باشد و همزمان دید افقی کمتر از ۱۰۰۰ متر گزارش شود، آن روز به‌عنوان «روز گرد و غباری» شناخته می‌شود (Mohammadi, 2015). با توجه به اینکه داده‌های اولیه شامل کلیه پدیده‌های هم‌دید بود، در گام نخست، کدهای مربوط به گرد و غبار استخراج و جداسازی شد (Goudie & Middleton, 2006).

### الگوریتم K نزدیک‌ترین همسایگی

الگوریتم KNN برای پیش‌بینی به‌شناسایی الگوهای مشابه در داده‌های تاریخی متکی است و برای عملکرد مناسب نیاز به داده‌های کافی و بلندمدت دارد. این مدل تنها قادر به درون‌یابی بین مقادیر مشاهده‌شده گذشته

میانگین‌گیری از مدل‌ها دقت بالاتری نسبت به مدل‌های منفرد دارد. همچنین، فاکتورهایی مانند سرعت باد و شاخص پوشش گیاهی به‌عنوان عوامل مؤثر بر وقوع گرد و غبار شناسایی شدند (Ebrahimi-Khusfi *et al.*, 2021). با این حال، استفاده از الگوریتم K نزدیک‌ترین همسایگی<sup>۱</sup> (KNN)، به‌ویژه در ترکیب با الگوریتم‌های بهینه‌سازی مانند PSO برای بهبود عملکرد در پیش‌بینی FDSM، تاکنون به‌ندرت و به‌صورت محدود مورد بررسی قرار گرفته است. برخی تحقیقات مشابه در حوزه‌های دیگر نشان داده‌اند که بهینه‌سازی پارامترهای KNN با PSO می‌تواند دقت مدل را به شکل قابل‌توجهی افزایش دهد (Bui *et al.*, 2020; Kadry & Ismael, 2019). با توجه به افزایش فراوانی و شدت طوفان‌های گرد و غبار در سال‌های اخیر و تأثیرات گسترده آن بر سلامت عمومی، کشاورزی و زیرساخت‌ها، ضرورت توسعه مدل‌های دقیق و قابل‌اعتماد برای پیش‌بینی این پدیده بیش از پیش احساس می‌شود. در این میان، بررسی‌ها نشان می‌دهد که در محدوده جنوب غرب ایران، روندی افزایشی در تعداد روزهای گرد و غباری و شدت آن‌ها طی دو دهه اخیر مشاهده شده است که زنگ خطری جدی برای ساکنان و منابع طبیعی این منطقه محسوب می‌شود. هدف این پژوهش، ارائه یک مدل داده‌محور دقیق و کارآمد برای پیش‌بینی وقوع طوفان‌های گرد و غبار است که بر پایه الگوریتم KNN بنا شده و با استفاده از الگوریتم PSO به‌صورت خودکار تنظیم و بهینه‌سازی می‌شود. این رویکرد، با انتخاب بهینه پارامترها و متغیرهای مؤثر، تلاش دارد دقت پیش‌بینی را افزایش داده و زمینه‌ساز تصمیم‌گیری‌های مؤثرتر در مدیریت مخاطرات اقلیمی و زیست‌محیطی باشد.

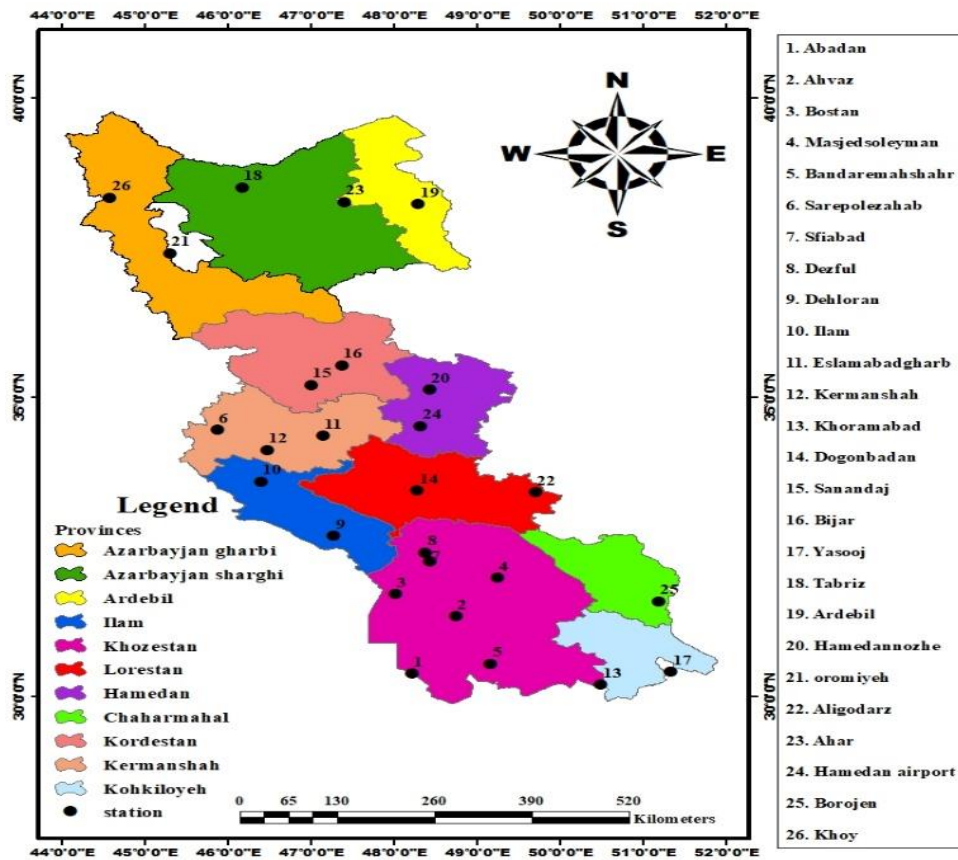
### مواد و روش‌ها

#### منطقه مورد مطالعه و منابع داده‌ای

1- K-Nearest Neighbors

ممکن است باعث بروز خطاهای قابل توجه شود (KarAmooz & Araghi-Nejad, 2015).

است و نمی تواند مقادیری خارج از بازه تاریخی (برون یابی) تولید کند. از این رو، استفاده از آن با داده های کوتاه مدت یا برای پیش بینی مقادیر غیرحدی



شکل ۱- ایستگاه های مورد مطالعه در پژوهش حاضر

Figure 1- The stations studied in the present research

استفاده از روش KNN به صورت زیر است (KarAmooz & Araghi-Nejad, 2015):

۱- ماتریس بردار سطری  $m$  ستونه مقادیر متغیرهای پیش بینی کننده  $X_j$  در زمان  $t$  به صورت رابطه (۱) قابل تعریف است:

$$Pr_{jt} = (X_{jt}) \quad j = 1 \dots m \quad (1)$$

ماتریس  $m$  ستونه و  $n$  سطری از مقادیر متغیرهای پیش بینی کننده  $X_j$  در سری زمانی تاریخی به صورت رابطه (۲) است:

$$Pr_{j,(t-i)} = (X_{j,(t-i)}) \quad j = 1 \dots m, i = 1 \dots n \quad (2)$$

در الگوریتم KNN، توزیع مقادیر پیش بینی شده با استفاده از تابع کرنل به صورت ناپارامتری برآورد می شود. این مدل با مشاهده متغیرهای مستقل فعلی، به دنبال الگوهای مشابه در داده های تاریخی می گردد و رویدادهای گذشته در این الگوها را به عنوان حالت های محتمل برای شرایط فعلی در نظر می گیرد. احتمال وقوع هر رویداد بر اساس میزان شباهت بین شرایط فعلی و داده های تاریخی تعیین می شود. دو عامل مهم در به کارگیری روش KNN، تعداد همسایه ها ( $k$ ) و وزن پیش بینی کننده ها ( $W_j$ ) هستند. براساس توضیحات ارائه شده، الگوریتم انجام پیش بینی با

می‌شود که تکرار این مراحل تا کسب پاسخ مطلوب ادامه خواهد یافت (Shi, 2001).

### الگوریتم ترکیبی KNN-PSO

الگوریتم بهینه‌سازی ازدحام ذرات، روشی نوین و سریع برای کاهش ابعاد داده‌ها از طریق تبدیل ماتریس اولیه به ماتریسی با ابعاد کمتر است (Shafiee & Nakhaei, 2018). هدف این مقاله بررسی امکان استفاده از PSO و وزن‌دهی به همسایه‌های الگوریتم KNN، هم‌زمان با کاهش خطای داده‌های اولیه و خطای دسته‌بندی KNN می‌باشد. الگوریتم PSO با بهره‌گیری از چندین نقطه جستجو و به‌کارگیری مفاهیم Pbest و Gbest، قابلیت جستجوی سراسری در مسائل پیوسته و گسسته را دارد، هرچند در جستجوی محلی ممکن است به بهینه محلی محدود شود. در این پژوهش، با ترکیب PSO و KNN الگوریتم جدیدی با عنوان PSO-WeightedKNN ارائه شده است. در این روش، ابتدا ابعاد داده کاهش یافته، سپس با استفاده از PSO به داده‌ها وزن‌دهی می‌شود تا فاصله بین داده ورودی و همسایه‌ها بهینه شده و خطای دسته‌بندی کاهش یابد. تابع هدف PSO بر اساس دقت الگوریتم KNN تعریف شده است. همانطور که در شکل (۲) آمده، تابع شایستگی برای الگوریتم PSO با استفاده از کارایی الگوریتم KNN تعریف می‌شود. بدین صورت که در ابتدا وزن‌های تصادفی به ذره‌ها یا همان همسایه‌ها داده می‌شود و سپس این وزن‌های تصادفی بر روی  $k$  همسایه داده تست، اعمال شده و عمل دسته‌بندی بر روی داده موردنظر انجام می‌گیرد. میزان خطای دسته‌بندی به عنوان  $fitness$  روی الگوریتم PSO از قبیل مکان ذره و سرعت ذره و همچنین Gbest و Pbest به روزرسانی می‌شوند و این روند تا یافتن، بهترین وزن برای همسایه‌ها که منجر به کمینه شدن میزان خطا و بیشینه شدن دقت دسته‌بندی است، ادامه می‌یابد

با استفاده از تابع فاصله‌سنجی  $Dist$ ، فواصل بین بردار  $Pr_{j,t}$  با سطرهای ماتریس  $Pr_{j,(t-i)}$  به‌صورت رابطه (۳) استخراج می‌گردد.

$$Dist(t-i) = f(W_j, X_{j,(t-i)}, X_{jt}) \quad (3)$$

که در این رابطه اندیس  $j$  نشان‌دهنده متغیرهای پیش‌بینی‌کننده و اندیس  $i$  بیان‌کننده گام زمانی در سری تاریخی است. مقادیر  $W_j$ ، وزن‌هایی است که برای پیش‌بینی‌کننده‌ها در نظر گرفته می‌شود.

۲- از یک تابع کرنل گسسته برای وزن‌دهی به همسایه‌ها استفاده می‌شود. Yakowitz (۱۹۸۵)، تابع کرنل طبق رابطه (۴) را پیشنهاد داده است:

$$K(Dist(t-i)) = \frac{1/Dist(t-1)}{\sum_{i=1}^k 1/Dist(t-i)} \quad (4)$$

در این روش، نزدیک‌ترین همسایه‌ها بر اساس وزن، از ۱ تا  $K$  رتبه‌بندی می‌شوند؛ به‌گونه‌ای که همسایه با وزن بیشتر، رتبه پایین‌تری دارد. در صورت برابر بودن وزن، همسایه‌ای که فاصله زمانی کمتری با زمان پیش‌بینی دارد، رتبه بهتری می‌گیرد. یکی از چالش‌های این روش، تعیین تعداد بهینه همسایه‌ها برای پیش‌بینی دقیق‌تر است. در نهایت مقدار پیش‌بینی از رابطه (۵) محاسبه می‌شود.

$$D(t) = \sum_{i=1}^K k(Dist(t-i)) \times D(t-i) \quad (5)$$

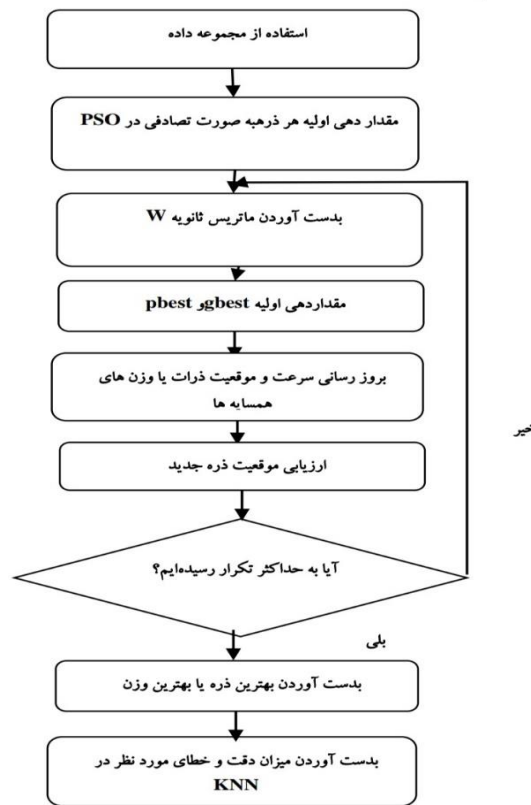
که در این رابطه  $D(t-i)$ ، مقدار متغیر وابسته در زمان  $t-i$  و  $D(t)$  مقدار متغیر وابسته در زمان  $t$  است.

### الگوریتم ازدحام ذرات

الگوریتم بهینه‌سازی ازدحام ذرات (PSO) یکی از روش‌های بهینه‌سازی تکاملی الهام گرفته از طبیعت می‌باشد. چارچوب این الگوریتم که تعدادی ذره را شامل می‌شود که در فضای جستجوی تابع هدف مسئله باید کمینه شوند. مقدار تابع هدف توسط هر ذره در موقعیت فعلی خود محاسبه می‌شود، سپس بهترین موقعیت قبلی و اطلاعات یک یا چند عدد از بهترین ذرات با استفاده از ترکیب اطلاعاتی که در اختیار قرار گرفته، مشخص شده و در نهایت جهتی برای حرکت انتخاب می‌شود. هر ذره جهتی را برای حرکت اتخاذ می‌کند و بعد از حرکت، یک مرحله از الگوریتم تمام

سایز ماتریس ثانویه را هم داراست و بدین ترتیب می-توان تصمیمی در این باره اتخاذ نمود که بهترین ماتریس ثانویه در نظر گرفته شود. در شکل (۲) مراحل اجرای الگوریتم پیشنهادی آمده است.

(Chen *et al.*, 2015). تعداد تکرار، تعداد ذرات و نیز تعداد همسایه ها در این الگوریتم قابل تغییر می باشد و به همین دلیل می توان بهترین مقدار مناسب برای هر پارامتر را کشف نمود، همچنین الگوریتم قابلیت تغییر



شکل ۲- مراحل انجام تکنیک PSO-WeightedKNN

Figure 2- The steps for implementing the PSO-WeightedKNN technique

جهت شبیه سازی و پیش بینی شاخص FDS، دو فرامدل مختلف شامل KNN و مدل ترکیبی KNN- PSO مورد ارزیابی قرار گرفتند. برای این منظور، از داده های دید افقی و کدهای گزارش های هواشناسی با تأخیر زمانی سه ساعته طی یک دوره ۴۰ ساله استفاده شد. پس از استخراج شاخص FDS، ۷۰ درصد داده ها برای مرحله آموزش و ۳۰ درصد آن برای آزمون مدل ها به کار گرفته شد. در این فرآیند، با بهره گیری از شاخص های نیکویی برازش، بهترین عملکرد مدل ها در هر مرحله پیش بینی انتخاب شد. برای پیش بینی مقادیر فصل آتی، از اطلاعات یک تا چهار فصل گذشته شاخص FDS استفاده گردید. در

در الگوریتم پایه PSO، جمعیت اولیه ذرات به صورت تصادفی و یک بعدی تولید می شود؛ در الگوریتم پیشنهادی نیز همین روند رعایت شده، با این تفاوت که مقدار k (تعداد همسایه ها) به عنوان ستون آخر به هر ذره اضافه شده است. این ذرات در واقع وزن های الگوریتم KNN وزن دار را تشکیل می دهند. از ابتدا می توان ماتریس وزن ها (W) را تولید و برای دسته بندی آماده کرد. سپس الگوریتم با استفاده از این وزن ها و تعداد متغیر همسایه ها، فرآیند دسته بندی را تکرار می کند.

مدل های پیش بینی

طوری که به ترتیب از سه و چهار فصل پیشین برای پیش‌بینی مقادیر آینده استفاده شد. روابط (۶) تا (۹)، نحوه ساخت این مدل‌های پیش‌بینی را تشریح می‌کنند. همچنین، در شکل (۳) چگونگی انتخاب تعداد فصل‌های گذشته برای پیش‌بینی فصل آینده نمایش داده شده است.


مدل اول، پیش‌بینی بر اساس مقدار شاخص در یک فصل گذشته انجام شد؛ بدین صورت که مقدار FDS<sub>D</sub> در فصل t برای پیش‌بینی مقدار فصل t+1 به کار رفت. در مدل دوم، داده‌های مربوط به دو فصل گذشته به عنوان ورودی پیش‌بینی فصل آینده لحاظ شدند. همین روند برای مدل‌های سوم و چهارم نیز ادامه یافت، به

$$FDS_{D(t+1)} = f(FDS_{D(t)}) \quad \text{مدل ۱} \quad (۶)$$

$$FDS_{D(t+1)} = f(FDS_{D(t)}, FDS_{D(t-1)}) \quad \text{مدل ۲} \quad (۷)$$

$$FDS_{D(t+1)} = f(FDS_{D(t)}, FDS_{D(t-1)}, FDS_{D(t-2)}) \quad \text{مدل ۳} \quad (۸)$$

$$FDS_{D(t+1)} = f(FDS_{D(t)}, FDS_{D(t-1)}, FDS_{D(t-2)}, FDS_{D(t-3)}) \quad \text{مدل ۴} \quad (۹)$$



شکل ۳- چارچوب‌های به کار گرفته شده برای پیش‌بینی شاخص FDS  
Figure 3- The frameworks used for predicting the FDS index

### معیارهای ارزیابی

برای ارزیابی مدل‌ها و مقایسه نتایج روش‌های مختلف، از چهار معیار ارزیابی یعنی ضریب همبستگی<sup>۱</sup> (r)، جذر میانگین مربعات خطا<sup>۲</sup> (RMSE)، میانگین قدرمطلق خطا<sup>۳</sup> (MAE) و نش-ساتکلیف<sup>۴</sup> (NS) استفاده شد. این معیارها به صورت روابط (۱۰) تا (۱۳) تعریف می‌شوند:

$$r = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (۱۰)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad (۱۱)$$

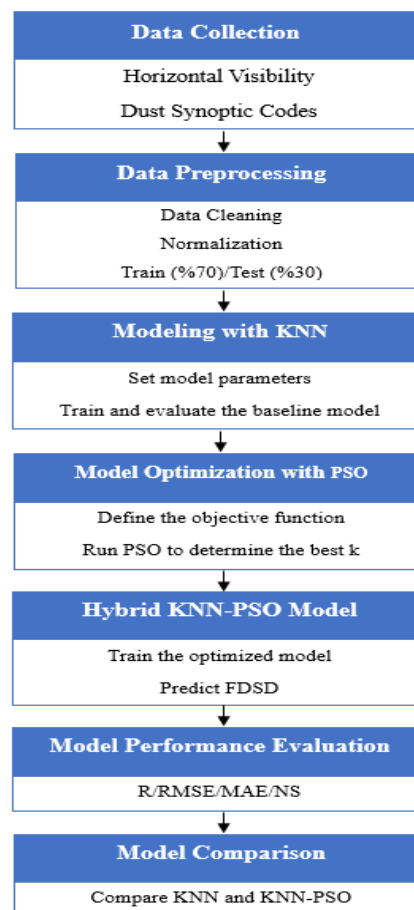
$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad (۱۲)$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۱۳)$$

در این روابط،  $O_i$  مقادیر مشاهده شده در گام زمانی  $i$ ام،  $f_i$  مقادیر پیش‌بینی شده در گام زمانی  $i$ ام،  $\bar{O}$  میانگین

شده با کاهش فراوانی روزهای همراه با طوفان گرد و غبار رابطه مستقیمی دارد. بدین معنی که با کاهش فراوانی روزهای همراه با طوفان‌های گرد و غبار، مقادیر معیارهای ارزیابی مورد استفاده نیز تقلیل می‌یابند. به نحوی که ضریب همبستگی برای داده‌های آزمایشی در فرامدل‌های KNN و KNN-PSO به ترتیب از مقادیر ۰/۶۴۵ و ۰/۹۹۷ به ۰/۶۱۱ و ۰/۹۷۷ کاهش یافته است. همچنین ضریب RMSE به ترتیب از ایستگاه آبادان تا خوی برای فرامدل‌های ذکر شده از مقدار ۰/۴۳۷ و ۰/۱۱۳ به ۰/۴۷۶ و ۰/۱۳۳ و ضریب MAE نیز به ترتیب از مقدار ۰/۳۰۴ و ۰/۰۴۴ به ۰/۳۴۳ و ۰/۰۷۱ افزایش یافته است که نشان‌دهنده ضعیف شدن عملکرد فرامدل‌های هوش مصنوعی با کاهش فراوانی طوفان‌های گرد و غبار در ایستگاه‌های مورد بررسی می‌باشد. با بررسی مقادیر معیارهای ارزیابی مدل‌های KNN و KNN-PSO در ۲۶ ایستگاه سینوپتیک مورد مطالعه، مشاهده شد که استفاده از روش ترکیبی KNN-PSO در مقایسه با مدل انفرادی عملکرد بهتری در پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار داشته است که نشان‌دهنده توانمندی بالای مدل‌های ترکیبی در بهبود دقت پیش‌بینی این پدیده اقلیمی می‌باشد. به طوری که مقادیر معیارهای ارزیابی  $r$ ، RMSE، MAE و NS در ایستگاه آبادان که فراوانی روزهای همراه با طوفان‌های گرد و غبار را در مقایسه با ایستگاه‌های دیگر دارد به ترتیب ۰/۹۹۷، ۰/۱۱۳، ۰/۰۴۴ و ۰/۹۸۱ و در ایستگاه خوی که ضعیف‌ترین ایستگاه از لحاظ فراوانی طوفان‌های گرد و غبار در مقایسه با ایستگاه‌های دیگر است به ترتیب ۰/۹۷۷، ۰/۱۳۳، ۰/۰۷۱ و ۰/۹۶۳ می‌باشند. اما در مدل انفرادی KNN مقادیر معیارهای ارزیابی  $r$ ، RMSE، MAE و NS در ایستگاه آبادان ۰/۶۵۴، ۰/۴۶۷، ۰/۳۴۳ و ۰/۶۸۳ و در ایستگاه خوی نیز به ترتیب ۰/۶۱۱، ۰/۴۷۶، ۰/۳۴۳ و ۰/۶۶۱ می‌باشند. با مقایسه نتایج معیارهای ارزیابی حاصل از دو مدل KNN و KNN-PSO مشخص شد که ادغام الگوریتم PSO با مدل KNN به بهبود قابل توجه دقت

مقادیر مشاهده‌شده،  $\bar{f}$  میانگین مقادیر پیش‌بینی‌شده و  $n$  تعداد داده‌ها است. هر مدلی که دارای  $r$  و NS بیشتر و RMSE و MAE کمتر باشد از مطلوبیت بیشتری برخوردار است. شکل (۴) فلوچارت انجام مراحل تحقیق را نمایش می‌دهد.



شکل ۴- فلوچارت مراحل انجام پژوهش

Figure 4- Flowchart of the research process

## نتایج و بحث

### مدل‌سازی با فرامدل‌های یادگیری ماشین

جدول‌های ۱ و ۲ نتایج حاصل از مدل‌سازی شاخص فراوانی روزهای همراه با طوفان گرد و غبار با بهره‌گیری از فرامدل‌های هوش مصنوعی KNN و KNN-PSO را ارائه می‌کنند. با توجه به اینکه در این جداول ترتیب ایستگاه‌ها از آبادان تا خوی به صورت نزولی بوده، می‌توان دریافت که کاهش عملکرد روش پیش‌بینی ذکر

یافته است که به نظر می‌رسد با توجه به شرایط آب و هوایی در منطقه مورد مطالعه، تأثیر شاخص FDSO فصل‌های قبل به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار در فصل آینده، آنچنان قابل قبول نیست که دلیل آن را می‌توان عدم تأثیر ذرات به جامانده از طوفان‌های قبلی و فصل‌های گذشته بر شکل‌گیری طوفان‌های گرد و غبار فصل آینده جستجو کرد. در نهایت با توجه به نتایج ذکر شده و با مقایسه معیارهای ارزیابی در دو روش پیش‌بینی طوفان‌های گرد و غبار می‌توان استنباط کرد که استفاده از فرامدل ترکیبی پیشنهادی KNN-PSO توانسته است با بهینه‌سازی وزن همسایه‌ها در مدل KNN، موجب کاهش خطا و افزایش دقت پیش‌بینی در شرایط پیچیده‌تر اقلیمی شود. این موضوع بیانگر آن است که بهره‌گیری از الگوریتم‌های بهینه‌سازی فراکوشی در کنار مدل‌های پایه، می‌تواند پایداری و قدرت تعمیم مدل‌های پیش‌بینی را در مناطق حساس اقلیمی، به‌ویژه مناطق متأثر از طوفان‌های گرد و غبار، به‌طور معنی‌داری ارتقاء دهد که این موضوع با مطالعات Razavi-Termeh و همکاران (۲۰۲۴) و Panicker و Valarmathi (۲۰۲۵) مطابقت دارد. فرامدل ترکیبی پیشنهادی دارای قدرت پیش‌بینی بیشتری می‌باشد که می‌تواند جهت مدل‌سازی طوفان‌های گرد و غبار در سایر مناطق غرب کشور نیز مورد استفاده قرار گیرد.

و کارایی پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار منجر شده است. این بهبود عملکرد به ویژه در ایستگاه‌هایی که فراوانی روزهای گرد و غباری بالاتری داشته‌اند، نظیر ایستگاه آبادان، محسوس‌تر بوده است. در جدول‌های ۱ و ۲، مدل‌های بهینه در پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار به ترتیب از ۱ تا ۴ شماره‌گذاری شده است. در نتیجه می‌توان استنباط کرد که انتخاب مدل ساده‌تر به‌عنوان مدل بهینه پیش‌بینی‌کننده در تمامی ایستگاه‌های مورد مطالعه نتیجه بهتری را از خود نشان می‌دهد. به‌نحوی که برای پیش‌بینی فراوانی روزهای همراه با طوفان‌های گرد و غبار در همه ایستگاه‌های مورد بررسی مدل شماره ۱ (با یک گام تأخیر) نتیجه بهتری را ارائه می‌دهد. این امر نشان می‌دهد که در ساختار فرامدل‌های هوش مصنوعی در منطقه غرب و جنوب‌غربی کشور، استفاده از سوابق فراوانی روزهای همراه با طوفان گرد و غبار در فصل‌های قبل، موجب بهبودی چشمگیری در نتایج پیش‌بینی نمی‌شود. به‌طوری که در دوره آزمایش، با اعمال شاخص FDSO از چهار به یک فصل قبل، مقدار RMSE در فرامدل KNN-PSO در ایستگاه آبادان از ۰/۱۱۹ روز به ۰/۱۱۳ روز و در ایستگاه خوی از ۰/۱۴۶ روز به ۰/۱۳۳ روز کاهش یافت. در مقابل، در مدل پایه KNN، مقدار RMSE در ایستگاه آبادان از ۰/۴۴۱ روز به ۰/۴۳۷ و در ایستگاه خوی از ۰/۴۷۳ روز به ۰/۴۷۲ روز کاهش

جدول ۱- خروجی‌های مدل KNN و عوامل بهینه جهت پیش‌بینی شاخص FDSO

Table 1- The outputs of the KNN model and the optimal factors for predicting the FDSO index

داده‌های آموزشی				داده‌های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	r	NS	MAE	RMSE	r		
0.754	0.273	0.421	0.711	0.683	0.304	0.437	0.654	1	آبادان
0.753	0.274	0.422	0.709	0.682	0.305	0.438	0.653		
0.753	0.275	0.423	0.709	0.681	0.307	0.439	0.651		
0.751	0.275	0.425	0.706	0.679	0.309	0.441	0.649		
0.753	0.274	0.423	0.708	0.682	0.306	0.438	0.652	2	اهواز
0.752	0.275	0.424	0.707	0.681	0.308	0.439	0.652		
0.751	0.276	0.425	0.706	0.679	0.309	0.441	0.651		
0.749	0.277	0.426	0.705	0.676	0.311	0.443	0.647		
0.751	0.275	0.425	0.707	0.681	0.308	0.439	0.651	1	بستان
0.749	0.276	0.426	0.706	0.679	0.311	0.441	0.649		

داده های آموزشی				داده های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	r	NS	MAE	RMSE	r		
0.748	0.277	0.427	0.704	0.677	0.313	0.442	0.646	3	مسجد سلیمان
0.746	0.278	0.428	0.703	0.675	0.314	0.444	0.644	4	
0.749	0.276	0.426	0.705	0.679	0.309	0.441	0.651	1	
0.746	0.277	0.427	0.704	0.677	0.312	0.442	0.648	2	
0.745	0.278	0.428	0.702	0.676	0.315	0.443	0.644	3	بندر ماهشهر
0.744	0.279	0.429	0.702	0.674	0.316	0.445	0.643	4	
0.748	0.277	0.428	0.704	0.677	0.311	0.442	0.649	1	
0.746	0.278	0.429	0.703	0.675	0.313	0.443	0.647	2	
0.744	0.279	0.431	0.701	0.674	0.317	0.444	0.645	3	سرپل ذهاب
0.743	0.281	0.432	0.701	0.673	0.319	0.446	0.643	4	
0.747	0.279	0.431	0.702	0.675	0.313	0.443	0.647	1	
0.745	0.279	0.432	0.701	0.674	0.315	0.444	0.645	2	
0.743	0.281	0.433	0.701	0.673	0.318	0.445	0.643	3	صفی آباد
0.741	0.283	0.434	0.699	0.672	0.321	0.447	0.641	4	
0.746	0.281	0.432	0.698	0.674	0.314	0.444	0.645	1	
0.744	0.282	0.433	0.697	0.673	0.316	0.445	0.643	2	
0.741	0.282	0.435	0.697	0.672	0.319	0.446	0.641	3	دزفول
0.739	0.283	0.436	0.695	0.671	0.322	0.448	0.639	4	
0.745	0.282	0.433	0.696	0.673	0.315	0.445	0.643	1	
0.743	0.283	0.434	0.695	0.671	0.317	0.446	0.642	2	
0.741	0.284	0.436	0.695	0.669	0.321	0.448	0.638	3	دهلران
0.737	0.285	0.437	0.693	0.668	0.323	0.449	0.637	4	
0.744	0.283	0.435	0.694	0.671	0.316	0.446	0.642	1	
0.742	0.284	0.436	0.693	0.669	0.318	0.447	0.641	2	
0.739	0.285	0.438	0.691	0.667	0.322	0.449	0.639	3	ایلام
0.735	0.286	0.439	0.691	0.665	0.324	0.451	0.635	4	
0.734	0.284	0.436	0.693	0.669	0.317	0.447	0.641	1	
0.741	0.285	0.437	0.692	0.668	0.319	0.448	0.637	2	
0.738	0.287	0.439	0.689	0.665	0.313	0.451	0.634	3	کرمانشاه
0.734	0.288	0.441	0.688	0.664	0.325	0.452	0.632	4	
0.642	0.285	0.437	0.691	0.667	0.319	0.488	0.639	1	
0.739	0.286	0.438	0.688	0.666	0.321	0.449	0.636	2	
0.736	0.288	0.441	0.687	0.665	0.324	0.452	0.633	3	اسلام آباد غرب
0.733	0.289	0.442	0.686	0.664	0.327	0.453	0.631	4	
0.741	0.286	0.438	0.689	0.666	0.321	0.449	0.638	1	
0.738	0.287	0.439	0.686	0.655	0.322	0.451	0.635	2	
0.735	0.289	0.443	0.685	0.663	0.325	0.453	0.632	3	دوگنبدان
0.732	0.291	0.444	0.684	0.661	0.328	0.454	0.629	4	
0.739	0.288	0.439	0.688	0.665	0.322	0.451	0.635	1	
0.737	0.289	0.441	0.685	0.663	0.324	0.452	0.633	2	
0.735	0.292	0.444	0.683	0.661	0.327	0.454	0.631	3	خرم آباد
0.731	0.293	0.445	0.682	0.659	0.329	0.455	0.628	4	
0.738	0.289	0.441	0.686	0.663	0.324	0.452	0.634	1	
0.736	0.291	0.442	0.684	0.662	0.325	0.453	0.632	2	
0.733	0.293	0.445	0.682	0.659	0.328	0.455	0.629	3	سنندج
0.729	0.294	0.446	0.681	0.658	0.331	0.457	0.625	4	
0.737	0.291	0.442	0.685	0.661	0.325	0.453	0.633	1	
0.735	0.292	0.443	0.683	0.659	0.327	0.454	0.631	2	
0.732	0.294	0.446	0.681	0.657	0.329	0.456	0.627	3	بیجار
0.728	0.295	0.447	0.679	0.656	0.332	0.458	0.623	4	
0.736	0.293	0.443	0.684	0.658	0.327	0.454	0.631	1	
0.734	0.294	0.444	0.682	0.656	0.328	0.455	0.629	2	
0.731	0.295	0.447	0.678	0.654	0.331	0.457	0.625	3	یاسوج
0.726	0.296	0.448	0.677	0.653	0.333	0.459	0.621	4	
0.735	0.294	0.444	0.683	0.656	0.328	0.456	0.639	1	
0.733	0.295	0.445	0.681	0.655	0.329	0.457	0.627	2	
0.729	0.296	0.448	0.677	0.653	0.332	0.458	0.624	3	تبریز
0.725	0.297	0.449	0.676	0.651	0.334	0.461	0.619	4	
0.734	0.295	0.445	0.682	0.654	0.331	0.457	0.627	1	
0.733	0.296	0.447	0.679	0.653	0.332	0.458	0.625	2	
0.728	0.297	0.449	0.676	0.651	0.334	0.459	0.623	3	

داده‌های آموزشی				داده‌های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	r	NS	MAE	RMSE	r		
0.725	0.298	0.451	0.674	0.648	0.335	0.462	0.621	4	اردبیل
0.734	0.296	0.446	0.681	0.669	0.332	0.458	0.625	1	
0.741	0.297	0.448	0.678	0.665	0.333	0.459	0.623	2	
0.738	0.298	0.451	0.675	0.664	0.335	0.461	0.621	3	
0.734	0.299	0.453	0.673	0.663	0.336	0.463	0.619	4	
0.741	0.297	0.447	0.679	0.667	0.334	0.459	0.623	1	همدان نوزه
0.739	0.298	0.449	0.677	0.663	0.335	0.461	0.622	2	
0.736	0.299	0.452	0.674	0.662	0.337	0.462	0.621	3	
0.733	0.301	0.454	0.672	0.661	0.339	0.464	0.618	4	
0.739	0.299	0.448	0.677	0.665	0.336	0.461	0.621	1	ارومیه
0.738	0.301	0.451	0.676	0.661	0.337	0.462	0.619	2	
0.735	0.302	0.453	0.673	0.661	0.339	0.463	0.617	3	
0.732	0.303	0.454	0.672	0.659	0.341	0.464	0.614	4	
0.738	0.301	0.449	0.675	0.667	0.338	0.463	0.619	1	الیگودرز
0.736	0.302	0.452	0.675	0.661	0.341	0.464	0.617	2	
0.734	0.304	0.454	0.672	0.659	0.342	0.465	0.615	3	
0.731	0.305	0.455	0.671	0.657	0.343	0.476	0.613	4	
0.736	0.302	0.451	0.673	0.663	0.339	0.464	0.617	1	اهر
0.735	0.303	0.452	0.672	0.660	0.342	0.466	0.615	2	
0.732	0.305	0.455	0.669	0.656	0.344	0.467	0.612	3	
0.729	0.306	0.456	0.668	0.655	0.345	0.469	0.611	4	
0.735	0.304	0.452	0.671	0.661	0.341	0.465	0.615	1	همدان هواپیمایی
0.734	0.305	0.453	0.669	0.659	0.343	0.467	0.613	2	
0.732	0.306	0.456	0.668	0.655	0.345	0.468	0.611	3	
0.728	0.307	0.457	0.666	0.653	0.347	0.471	0.609	4	
0.734	0.306	0.453	0.668	0.661	0.342	0.466	0.613	1	بروجن
0.733	0.307	0.454	0.667	0.658	0.344	0.469	0.612	2	
0.731	0.308	0.457	0.666	0.653	0.346	0.471	0.608	3	
0.727	0.309	0.459	0.665	0.652	0.348	0.472	0.607	4	
0.733	0.307	0.455	0.667	0.661	0.343	0.472	0.611	1	خوی
0.732	0.308	0.456	0.665	0.657	0.345	0.471	0.609	2	
0.729	0.309	0.458	0.664	0.657	0.347	0.472	0.605	3	
0.725	0.311	0.461	0.663	0.651	0.349	0.473	0.603	4	

جدول ۲- خروجی‌های فرامدل ترکیبی KNN-PSO و عوامل بهینه جهت پیش‌بینی شاخص FDSI

Table 2- The outputs of the KNN-PSO hybrid model and the optimal factors for predicting the FDSI index

داده‌های آموزشی				داده‌های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	r	NS	MAE	RMSE	r		
0.983	0.043	0.112	0.998	0.981	0.044	0.113	0.997	1	آبادان
0.981	0.045	0.115	0.997	0.980	0.047	0.117	0.995	2	
0.980	0.049	0.116	0.995	0.978	0.051	0.118	0.994	3	
0.980	0.051	0.118	0.994	0.976	0.052	0.119	0.993	4	
0.982	0.045	0.112	0.997	0.981	0.045	0.113	0.996	1	اهواز
0.981	0.046	0.116	0.997	0.980	0.048	0.119	0.994	2	
0.980	0.049	0.117	0.994	0.976	0.051	0.119	0.993	3	
0.979	0.052	0.119	0.993	0.975	0.052	0.120	0.992	4	
0.982	0.046	0.112	0.997	0.980	0.046	0.113	0.997	1	بستان
0.981	0.048	0.117	0.997	0.980	0.048	0.118	0.994	2	
0.979	0.050	0.118	0.993	0.975	0.052	0.120	0.993	3	
0.978	0.053	0.121	0.991	0.974	0.053	0.121	0.990	4	
0.981	0.047	0.113	0.996	0.980	0.047	0.114	0.996	1	مسجد سلیمان
0.981	0.049	0.118	0.995	0.980	0.049	0.118	0.993	2	
0.979	0.051	0.119	0.993	0.975	0.052	0.120	0.993	3	
0.977	0.053	0.122	0.991	0.973	0.054	0.123	0.990	4	
0.981	0.047	0.113	0.995	0.980	0.047	0.114	0.995	1	

داده های آموزشی				داده های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	r	NS	MAE	RMSE	r		
0.980	0.049	0.119	0.995	0.979	0.050	0.119	0.993	2	بندر ماهشهر
0.979	0.052	0.120	0.992	0.975	0.052	0.121	0.992	3	
0.976	0.054	0.123	0.991	0.972	0.055	0.124	0.990	4	
0.981	0.048	0.114	0.995	0.980	0.048	0.115	0.995	1	سرپل ذهاب
0.980	0.049	0.120	0.994	0.979	0.051	0.120	0.992	2	
0.978	0.053	0.121	0.991	0.974	0.053	0.121	0.991	3	
0.975	0.054	0.124	0.991	0.971	0.055	0.124	0.990	4	
0.980	0.048	0.114	0.994	0.979	0.048	0.115	0.994	1	صفی آباد
0.979	0.050	0.121	0.994	0.978	0.052	0.121	0.992	2	
0.977	0.054	0.122	0.990	0.974	0.054	0.122	0.990	3	
0.974	0.055	0.125	0.989	0.971	0.056	0.125	0.989	4	
0.979	0.049	0.115	0.994	0.978	0.050	0.116	0.994	1	دزفول
0.978	0.051	0.122	0.993	0.976	0.053	0.123	0.992	2	
0.977	0.055	0.123	0.989	0.973	0.056	0.124	0.989	3	
0.973	0.056	0.126	0.988	0.970	0.057	0.127	0.988	4	
0.978	0.051	0.115	0.993	0.977	0.052	0.117	0.992	1	دهلران
0.976	0.052	0.123	0.992	0.975	0.053	0.124	0.991	2	
0.976	0.056	0.124	0.989	0.973	0.057	0.125	0.988	3	
0.972	0.057	0.128	0.986	0.970	0.058	0.129	0.985	4	
0.978	0.052	0.116	0.992	0.977	0.053	0.117	0.991	1	ایلام
0.976	0.053	0.124	0.992	0.975	0.054	0.125	0.990	2	
0.975	0.057	0.125	0.988	0.972	0.058	0.126	0.987	3	
0.971	0.058	0.129	0.985	0.970	0.059	0.130	0.984	4	
0.977	0.053	0.117	0.991	0.976	0.054	0.118	0.990	1	کرمانشاه
0.976	0.054	0.125	0.991	0.975	0.055	0.126	0.989	2	
0.974	0.058	0.126	0.987	0.972	0.059	0.127	0.986	3	
0.970	0.059	0.129	0.984	0.969	0.061	0.131	0.983	4	
0.976	0.054	0.118	0.990	0.975	0.055	0.119	0.989	1	اسلام آباد غرب
0.976	0.055	0.126	0.990	0.975	0.056	0.127	0.989	2	
0.974	0.059	0.127	0.986	0.971	0.060	0.128	0.985	3	
0.969	0.060	0.131	0.984	0.968	0.062	0.132	0.982	4	
0.975	0.055	0.119	0.989	0.974	0.056	0.121	0.988	1	دوگنبدان
0.975	0.056	0.127	0.989	0.974	0.057	0.128	0.988	2	
0.973	0.061	0.129	0.985	0.971	0.062	0.129	0.984	3	
0.968	0.062	0.132	0.983	0.967	0.063	0.133	0.981	4	
0.975	0.056	0.121	0.989	0.973	0.057	0.122	0.987	1	خرم آباد
0.974	0.057	0.128	0.989	0.973	0.058	0.129	0.987	2	
0.972	0.062	0.131	0.983	0.960	0.063	0.132	0.982	3	
0.967	0.063	0.133	0.982	0.966	0.064	0.135	0.980	4	
0.974	0.057	0.122	0.988	0.972	0.058	0.123	0.987	1	سنندج
0.973	0.059	0.129	0.987	0.972	0.060	0.131	0.986	2	
0.971	0.063	0.132	0.981	0.969	0.064	0.133	0.980	3	
0.965	0.064	0.134	0.980	0.964	0.065	0.136	0.979	4	
0.973	0.058	0.123	0.987	0.971	0.059	0.124	0.986	1	بیجار
0.973	0.060	0.131	0.986	0.972	0.061	0.132	0.985	2	
0.970	0.064	0.133	0.980	0.968	0.065	0.134	0.979	3	
0.964	0.065	0.135	0.979	0.963	0.066	0.137	0.978	4	
0.972	0.059	0.124	0.986	0.970	0.060	0.125	0.985	1	یاسوج
0.972	0.061	0.132	0.984	0.970	0.062	0.133	0.983	2	
0.969	0.065	0.135	0.978	0.967	0.066	0.136	0.977	3	
0.962	0.066	0.136	0.978	0.961	0.067	0.137	0.976	4	
0.971	0.061	0.125	0.985	0.969	0.062	0.126	0.984	1	تبریز
0.970	0.062	0.133	0.983	0.969	0.063	0.134	0.982	2	
0.968	0.066	0.136	0.975	0.965	0.067	0.137	0.974	3	
0.961	0.067	0.137	0.975	0.960	0.068	0.138	0.974	4	
0.970	0.062	0.126	0.984	0.968	0.063	0.127	0.983	1	اردبیل
0.969	0.063	0.134	0.982	0.967	0.064	0.135	0.981	2	
0.967	0.067	0.137	0.974	0.964	0.068	0.138	0.973	3	
0.959	0.068	0.138	0.973	0.958	0.069	0.139	0.972	4	
0.969	0.063	0.126	0.983	0.967	0.064	0.128	0.982	1	همدان نوزه
0.968	0.063	0.135	0.981	0.966	0.064	0.136	0.980	2	

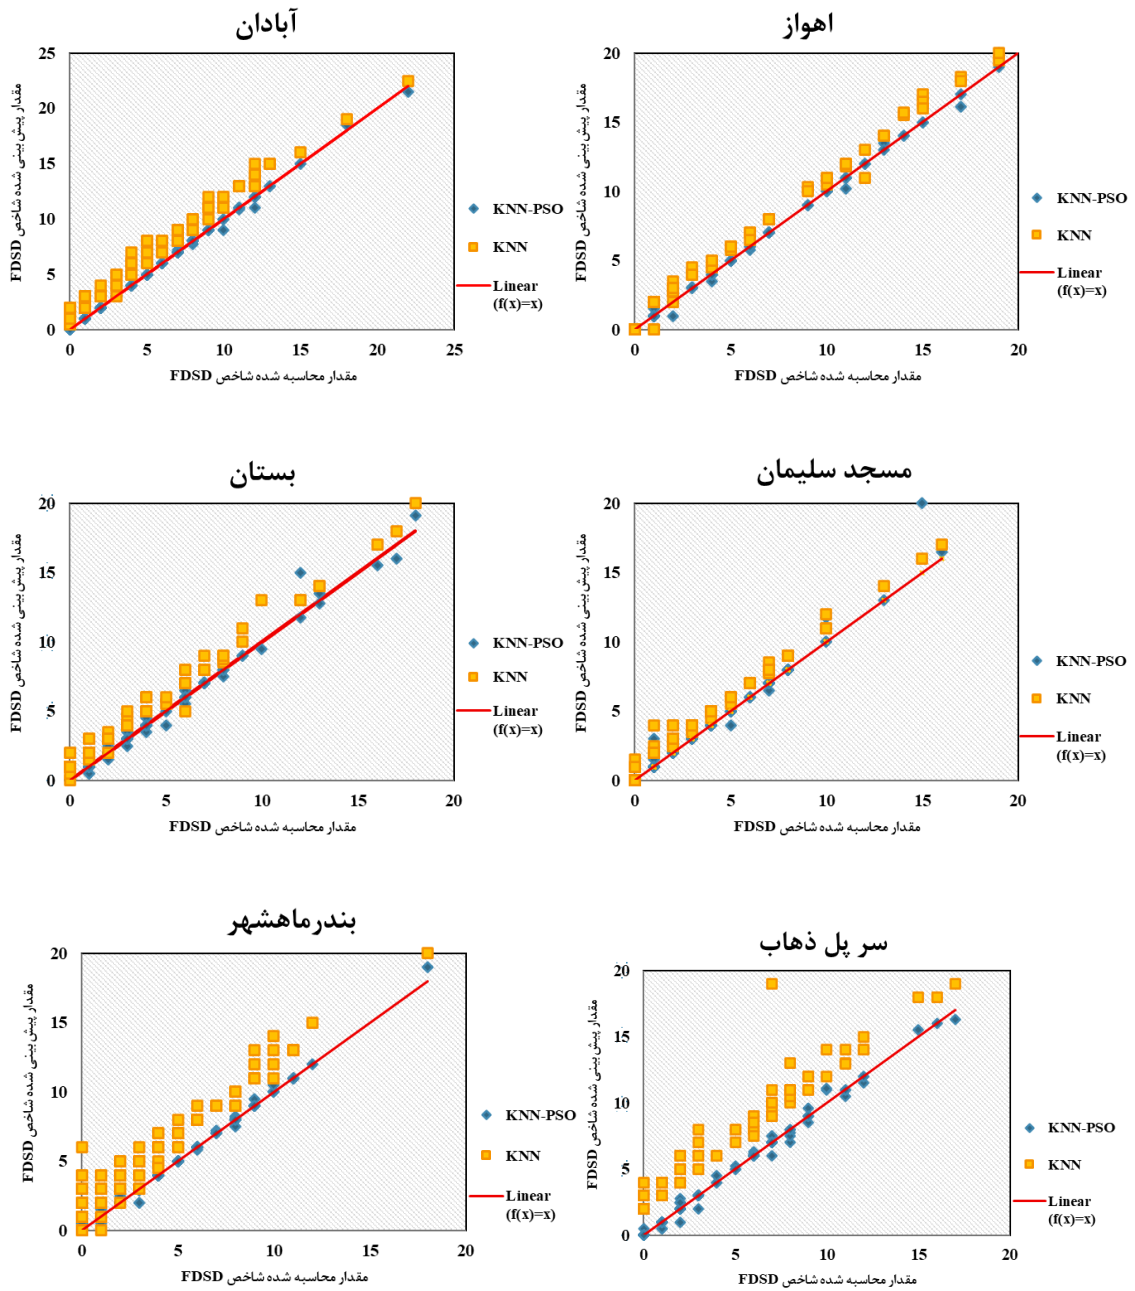
داده‌های آموزشی				داده‌های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	r	NS	MAE	RMSE	r		
0.965	0.068	0.137	0.973	0.964	0.069	0.139	0.972	3	ارومیه
0.958	0.069	0.139	0.972	0.957	0.071	0.140	0.971	4	
0.968	0.064	0.127	0.982	0.966	0.065	0.129	0.981	1	
0.966	0.065	0.136	0.981	0.965	0.066	0.137	0.980	2	
0.964	0.069	0.138	0.972	0.963	0.071	0.141	0.971	3	الیگودرز
0.957	0.071	0.140	0.971	0.955	0.072	0.142	0.970	4	
0.967	0.065	0.128	0.981	0.965	0.066	0.130	0.980	1	
0.965	0.066	0.136	0.980	0.964	0.067	0.138	0.979	2	
0.963	0.071	0.139	0.971	0.962	0.072	0.142	0.970	3	اهر
0.956	0.072	0.141	0.970	0.954	0.073	0.143	0.969	4	
0.967	0.066	0.129	0.980	0.964	0.067	0.131	0.979	1	
0.964	0.067	0.137	0.979	0.963	0.068	0.138	0.978	2	
0.962	0.072	0.141	0.970	0.960	0.073	0.143	0.970	3	همدان هواپیمایی
0.955	0.073	0.142	0.969	0.954	0.074	0.143	0.968	4	
0.966	0.067	0.130	0.979	0.964	0.068	0.131	0.978	1	
0.963	0.068	0.138	0.978	0.962	0.069	0.139	0.975	2	
0.961	0.073	0.141	0.969	0.960	0.074	0.143	0.965	3	بروجن
0.954	0.074	0.143	0.968	0.952	0.076	0.144	0.964	4	
0.966	0.068	0.131	0.979	0.964	0.069	0.132	0.977	1	
0.963	0.069	0.139	0.978	0.961	0.071	0.141	0.975	2	
0.960	0.074	0.142	0.967	0.959	0.075	0.143	0.965	3	خوی
0.953	0.075	0.144	0.967	0.951	0.077	0.145	0.963	4	
0.965	0.069	0.132	0.978	0.963	0.071	0.133	0.977	1	
0.962	0.071	0.141	0.976	0.960	0.072	0.142	0.974	2	
0.959	0.075	0.143	0.965	0.958	0.076	0.144	0.964	3	
0.951	0.076	0.145	0.965	0.950	0.078	0.146	0.962	4	

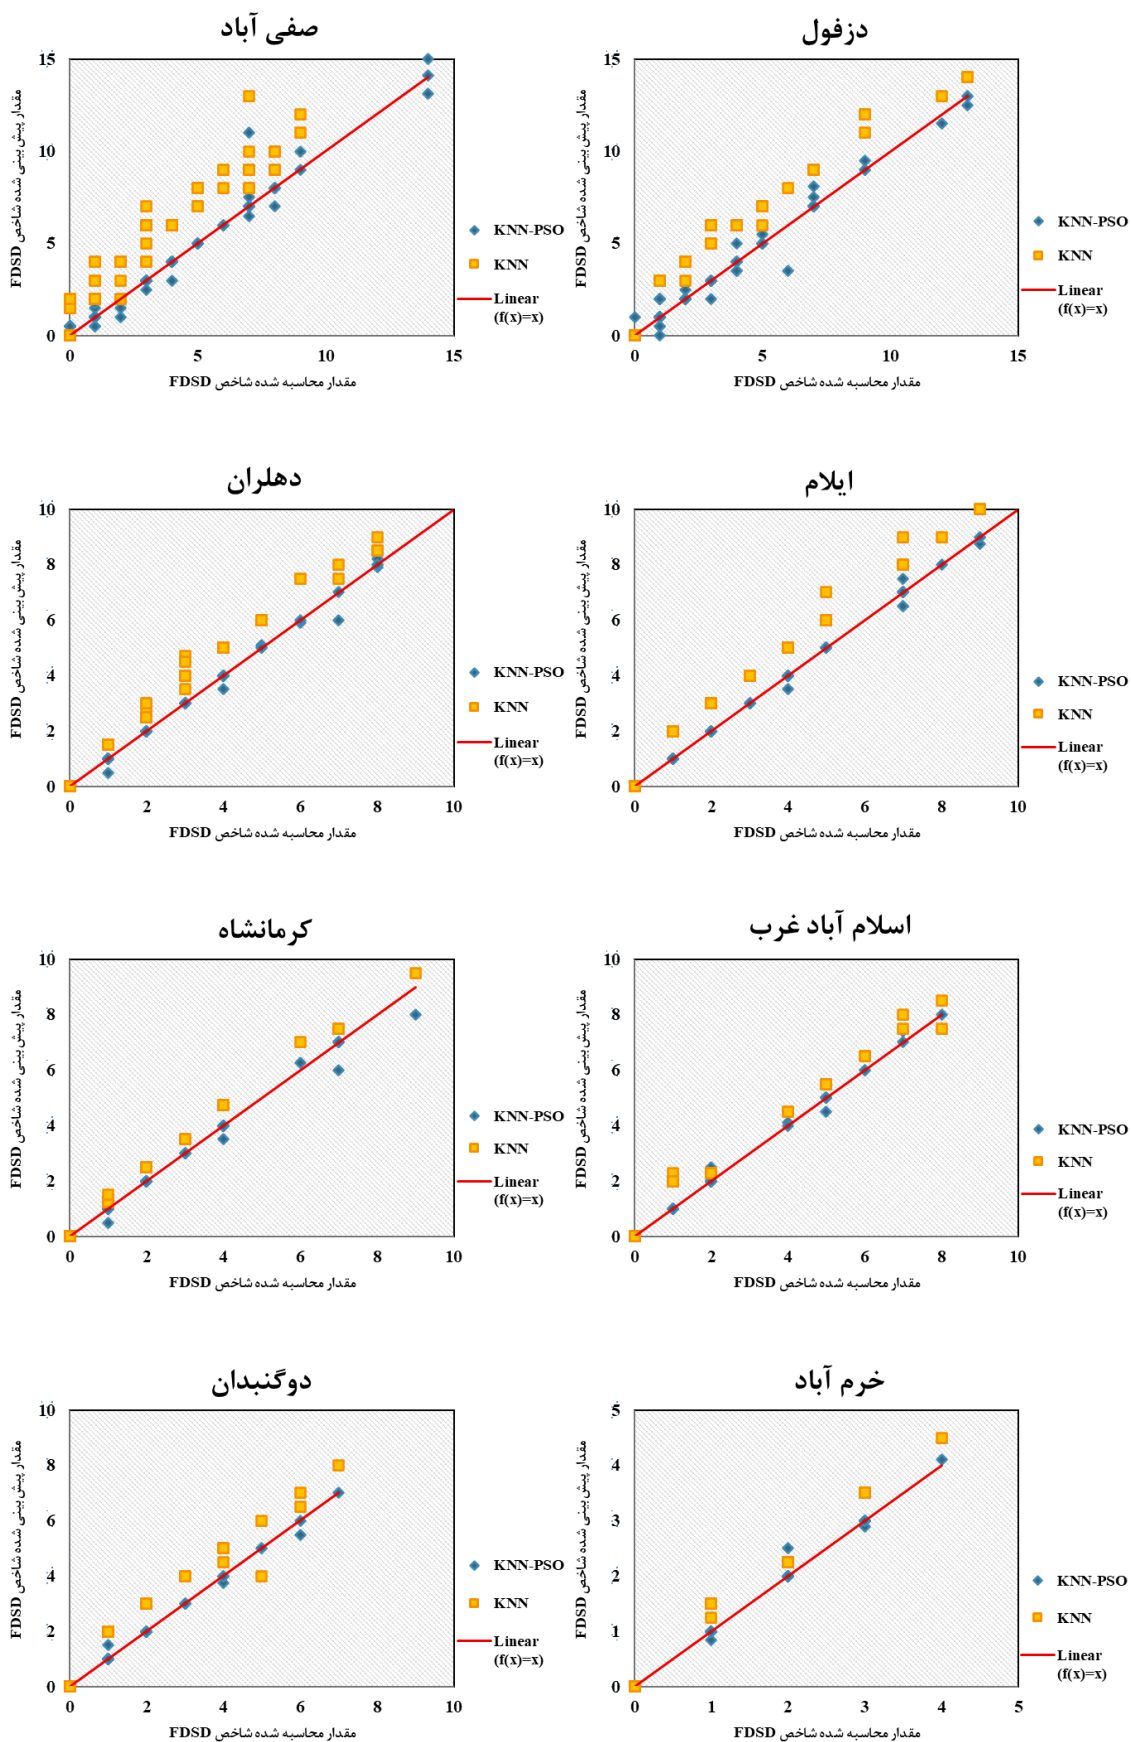
### مقایسه عملکرد فرامدل‌های یادگیری ماشین

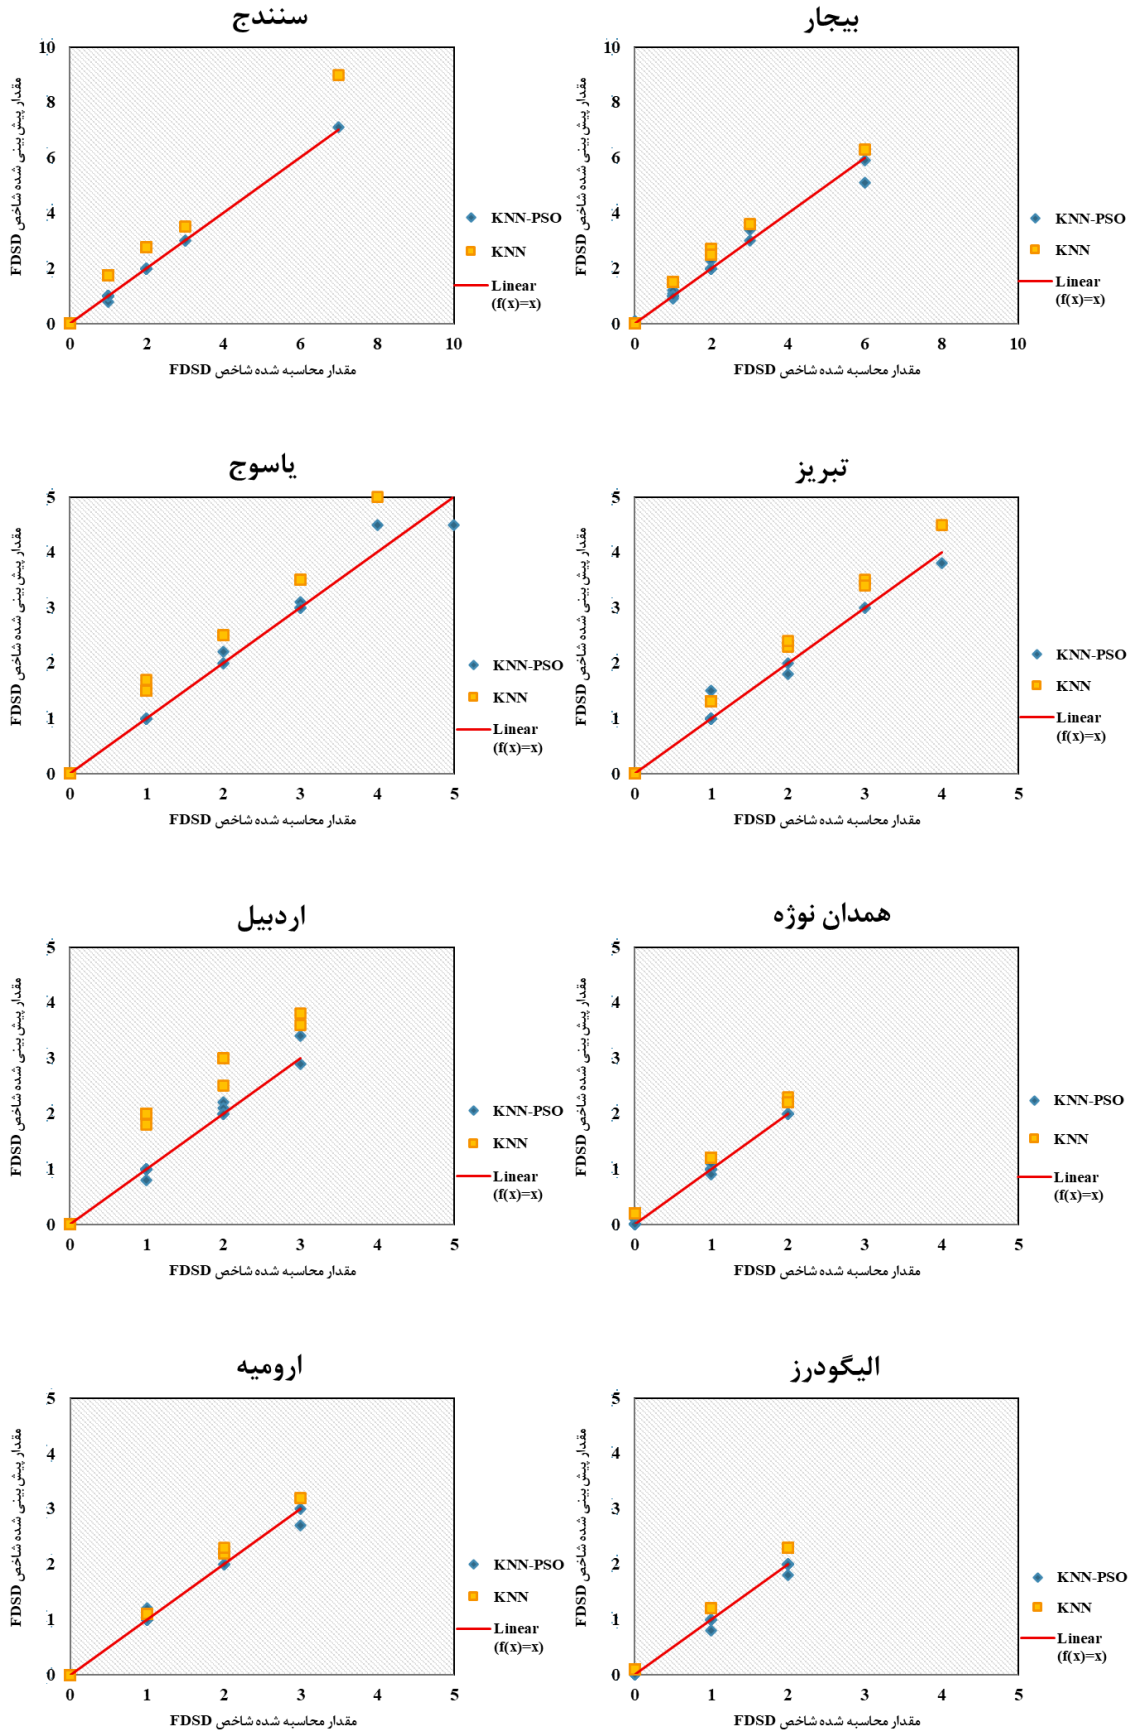
شکل (۵) مقادیر مشاهداتی و پیش‌بینی شده شاخص FDSO را برای داده‌های آزمایش نشان می‌دهد. تمامی شکل‌ها بهبود عملکرد روش‌های مورد استفاده با افزایش فراوانی روزهای همراه با طوفان‌های گرد و غبار را به خوبی بیان می‌کنند؛ به طوری که ایستگاه آبادان به عنوان فراوان‌ترین ایستگاه موجود در منطقه مورد مطالعه، بهترین مطابقت را بین مقادیر مشاهداتی و پیش‌بینی شده شاخص FDSO دارا می‌باشد. همانطور که در شکل مشخص است، ارتباط بین مقادیر مشاهداتی و پیش‌بینی شده در ایستگاه‌های آبادان، اهواز، مسجد سلیمان، بستان، سرپل ذهاب و بندرماهشهر، با شیب تقریباً ۴۵ درجه می‌باشد و فرامدل ترکیبی KNN-PSO بیشترین مطابقت را با نیمساز ربع اول ( $f(x)=x$ ) به خود اختصاص داده است


که این ویژگی می‌تواند تأکیدی بر راندمان بالا و کارایی مؤثر فرامدل ترکیبی KNN-PSO در مقایسه با مدل KNN به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار در نیمه‌غربی کشور باشد. در شکل (۵) به خوبی ملاحظه می‌شود که با کاهش فراوانی روزهای همراه با طوفان‌های گرد و غبار میزان مطابقت مدل‌های به‌کار برده شده کاهش می‌یابد (با پیشروی از ایستگاه آبادان به سمت ایستگاه خوی). همچنین این شکل‌ها نیز بیانگر برتری فرامدل ترکیبی KNN-PSO در پیش‌بینی مقادیر FDSO می‌باشند که با وجود فراوانی کم شاخص FDSO در برخی از ایستگاه‌های منطقه مورد مطالعه (بروجن و خوی) باز هم با نیمساز ربع اول مطابقت بیشتری دارد و کمترین پراکندگی را داراست. شایان ذکر است که به‌منظور مقایسه‌ی دقیق‌تر و ارزیابی میزان انطباق مقادیر

مشاهداتی و پیش بینی شده، در تمامی شکل ها خط تابع  $f(x)=x$  نیز ترسیم شده است.









شکل ۵- مقایسه مقادیر مشاهداتی و پیش‌بینی شده شاخص FDSI در ایستگاه‌های نیمه غربی کشور

Figure 5- Comparison of observed and predicted FDSI index values at stations in the western half of the Iran

در این مطالعه با بهره‌گیری از فرامدل‌های یادگیری ماشین KNN و KNN-PSO به مدل‌سازی شاخص فراوانی روزهای همراه با طوفان‌های گرد و غبار در ۲۶ ایستگاه سینوپتیک واقع در ۱۱ استان در نیمه‌غربی کشور با جمعیت آماری بلندمدت ۴۰ ساله (۱۹۸۱-۲۰۲۰) پرداخته شد. نتایج حاصل نشان داد که عملکرد این مدل‌ها رابطه مستقیمی با میزان فراوانی روزهای گرد و غباری در ایستگاه‌ها دارد، به طوری که در ایستگاه‌هایی با فراوانی بالاتر، دقت پیش‌بینی به‌طور محسوسی بیشتر بوده است.

مدل ترکیبی KNN-PSO در مقایسه با مدل انفرادی KNN توانست با بهینه‌سازی وزن همسایه‌ها، معیارهای ارزیابی را بهبود بخشد و دقت پیش‌بینی را افزایش دهد. بررسی‌ها نشان داد که مدل پایه KNN در اکثر

## نتیجه‌گیری کلی

در نیمه غربی ایران، به‌ویژه در مناطقی مانند استان خوزستان، طوفان‌های گرد و غبار به‌طور مکرر رخ می‌دهند. این پدیده‌ها عمدتاً به دلیل ترکیبی از عواملی چون شرایط اقلیمی خشک و نیمه‌خشک، نبود پوشش گیاهی مناسب، فعالیت‌های انسانی نظیر کشاورزی و دامداری و همچنین وقوع پدیده‌های طبیعی مانند خشکسالی‌های طولانی‌مدت و تغییرات اقلیمی رخ می‌دهند. گرد و غبارها می‌توانند آثار منفی بسیاری بر سلامت انسان‌ها، کشاورزی، محیط‌زیست و فعالیت‌های اقتصادی داشته باشند. در این راستا، مدل‌سازی دقیق و پیش‌بینی زمان و شدت این طوفان‌ها اهمیت زیادی پیدا می‌کند تا بتوان تدابیر پیشگیرانه و مقابله‌ای مناسبی اتخاذ کرد.

به گونه ای که حتی در ایستگاه هایی با فراوانی کمتر، این مدل بیشترین تطابق با نیمساز ربع اول را داشت و کمترین پراکندگی را نشان داد.

در مجموع، یافته های این پژوهش بیانگر آن است که ترکیب الگوریتم های بهینه سازی فراکوشی نظیر PSO با مدل های پایه مانند KNN می تواند قدرت تعمیم و پایداری مدل های پیش بینی اقلیمی را در شرایط پیچیده و متغیر به طور معنی داری ارتقاء دهد؛ بنابراین، مدل ترکیبی پیشنهادی KNN-PSO به عنوان ابزاری کارآمد برای پیش بینی فراوانی طوفان های گرد و غبار در سایر مناطق مستعد کشور نیز قابل پیشنهاد می باشد. همچنین با توجه به افزایش فراوانی این پدیده در سال های اخیر، استفاده از مدل های ترکیبی و بهینه سازی شده همچون KNN-PSO می تواند به طور چشمگیری در کاهش اثرات منفی آن ها بر محیط زیست و سلامت عمومی مؤثر باشد. در راستای ارتقاء دقت پیش بینی ها، پیشنهاد می شود که به کارگیری داده های فضایی و ماهواره ای، ادغام مدل های پیش بینی جوی و استفاده از رویکردهای نوین مانند مدل های عمیق تر، در دستور کار قرار گیرد. همچنین، با توجه به اهمیت پیش بینی دقیق در مقیاس های زمانی کوتاه مدت، به ویژه در مواقع بحرانی، توجه به توسعه مدل هایی برای پیش بینی های آنی می تواند به تصمیم گیری های سریع تر و کارآمدتر کمک کند.

## References

- Akhlaq, M., Sheltami, T. R., & Mouftah, H. T. (2012). A review of techniques and technologies for sand and dust storm detection. *Reviews in Environmental Science and Bio/Technology*, 11, 305-322. <https://doi.org/10.1007/s11157-012-9282-y>
- Albugami, S., Palmer, S., Cinnamon, J., & Meersmans, J. (2019). Spatial and temporal variations in the incidence of dust storms in Saudi Arabia revealed from in situ observations. *Geosciences*, 9(4), 162. <https://doi.org/10.3390/geosciences9040162>

ایستگاه ها عملکرد نسبتاً ضعیف تری دارد؛ به طوری که مقدار RMSE آن در ایستگاه های مورد مطالعه در بازه ای بین ۰/۴۳۷ تا ۰/۴۷۶ روز متغیر بوده و مقدار ضریب همبستگی نیز در محدوده ۰/۶۱ تا ۰/۶۵۴ قرار داشت. با توجه به این مقادیر، می توان نتیجه گرفت که مدل KNN به تنهایی از دقت قابل قبولی برای پیش بینی شاخص FDSO برخوردار نیست و دارای محدودیت هایی در تخمین دقیق مقدار این شاخص است.

در مقابل، مدل ترکیبی KNN-PSO توانست به طور متوسط حدود ۴۵ درصد دقت بیشتری نسبت به مدل KNN به دست آورد. این بهبود دقت در کمترین حالت حدود ۳۷ درصد و در بهترین حالت نزدیک به ۴۸ درصد گزارش شد. همچنین، ضرایب  $r$  و NS مدل ترکیبی در اکثر ایستگاه ها در حدود ۰/۹۰ برآورد شده است که نشان دهنده ارتقای چشمگیر در عملکرد مدل و توانایی بالای الگوریتم PSO در بهینه سازی ساختار مدل پایه KNN است.

علاوه بر این، نتایج نشان داد که استفاده از شاخص های تأخیری فصول گذشته تأثیر قابل ملاحظه ای در بهبود پیش بینی نداشته و مدل های ساده تر با استفاده از تنها یک گام تأخیر، عملکرد بهتری نسبت به مدل های پیچیده تر ارائه داده اند. تحلیل شکل های مربوط به تطابق مقادیر مشاهداتی و پیش بینی شده نیز برتری مدل ترکیبی KNN-PSO را به خوبی تأیید می کند.

- Alizadeh-Choobari, O., Ghafarian, P., & Owlad, E. (2016). Temporal variations in the frequency and concentration of dust events over Iran based on surface observations. *International Journal of Climatology*, 36(4). <https://doi.org/10.1002/joc.4479>
- Alshammari, R. K., Alrwais, O., & Aksoy, M. S. (2022). Machine learning applications to dust storms: a meta-analysis. *Aerosol and Air Quality Research*, 22(12), 220183. <https://doi.org/10.4209/aaqr.220183>
- Alshammari, R. K., Alrwais, O., & Aksoy, M. S. (2024). Machine learning forecast of dust storm frequency in Saudi Arabia using

- multiple features. *Atmosphere*, 15(5), 520. <https://doi.org/10.3390/atmos15050520>
- Ansari Ghojghar, M., Bazrafshan, J., Araghinejad, S., Parsi, E. & Soltani, S. (2020). Evaluation of the performance of the support-wavelet vector machine hybrid model in predicting dust storms (Case study: Sistan and Baluchestan province), *Environmental Management Hazards*, 7(4), 331-351. <https://doi.org/10.22059/jhsci.2021.314582.614> (In Persian)
- Ashrafi, K., Shafiepour-Motlagh, M., Ashrafi, K., Shafiepour-Motlagh, M., Aslemand, A., & Ghader, S. (2014). Dust storm simulation over Iran using HYSPLIT, *Journal of environmental health science and engineering*, 12, 1-9. <https://doi.org/10.1186/2052-336X-12-9>
- Bui, X. N., Jaroonpattanapong, P., Nguyen, H., Tran, Q. H., & Long, N. Q. (2019). A novel hybrid model for predicting blast-induced ground vibration based on k-nearest neighbors and particle swarm optimization, *Scientific reports*, 9(1), 13971. <https://doi.org/10.1038/s41598-019-50262-5>
- Chen, M., Guo, J., Wang, C., & Wu, F. (2015). PSO-based adaptively normalized weighted kNN classifier. *Journal of Computational Information Systems*, 11, 1407-1415. <https://doi.org/10.12733/jcis13449>
- Dar, M. A., Ahmed, R., Latif, M., & Azam, M. (2022). Climatology of dust storm frequency and its association with temperature and precipitation patterns over Pakistan, *Natural Hazards*, 110(1), 655-677. <https://doi.org/10.1007/s11069-021-04962-9>
- Ebrahimi-Khusfi, Z., Taghizadeh-Mehrjardi, R., & Mirakbari, M. (2021). Evaluation of machine learning models for predicting the temporal variations of dust storm index in arid regions of Iran. *Atmospheric Pollution Research*, 12(1), 134-147. <https://doi.org/10.1016/j.apr.2020.08.029>
- Ginoux, P., Prospero, J. M., Gill, T. E., Hsu, N. C., & Zhao, M. (2012). Global-scale attribution of anthropogenic and natural dust sources and their emission rates based on MODIS Deep Blue aerosol products. *Reviews of Geophysics*, 50(3). <https://doi.org/10.1029/2012RG000388>
- Goudie, A. S., & Middleton, N.J. (2006). Desert dust in the global system. Springer Science & Business Media. <https://doi.org/10.1007/3-540-32355-4>
- KarAmooz, M., & Araghi-Nejad, Sh. (2015). *Advanced Hydrology* (Vol. 1). Amirkabir University of Technology Press. (In Persian)
- Kadry, R., & Ismael, O. (2020). A new hybrid KNN classification approach based on particle swarm optimization. *International Journal of Advanced Computer Science and Applications*, 11(11). <http://doi.org/10.14569/IJACSA.2020.0111137>
- Middleton, N. J., & Goudie, A. S. (2001). Saharan dust: sources and trajectories. *Transactions of the Institute of British Geographers*, 26(2), 165-181. <https://doi.org/10.1111/1475-5661.00013>
- Mohammadi, G. H. (2015). Analysis of Atmospheric Mechanisms in Dust Transport from Western Iran (*Doctoral dissertation, University of Tabriz*, 142 pages). (In Persian)
- Namdari, M., Lee, C. S., & Haghghat, F. (2021). Active ozone removal technologies for a safe indoor environment: A comprehensive review. *Building and Environment*, 187, 107370. <https://doi.org/10.1016/j.buildenv.2020.107370>
- O'Loingsigh, T., McTainsh, G. H., Tews, E. K., Strong, C. L., Leys, J. F., Shinkfield, P., & Tapper, N. J. (2014). The Dust Storm Index (DSI): a method for monitoring broadscale wind erosion using meteorological records. *Aeolian Research*, 12, 29-40. <https://doi.org/10.1016/j.aeolia.2013.10.004>
- Panicker, N. K. K., & Valarmathi, J. (2025). Time series prediction of aerosol optical depth across the northern Indian region: integrating PSO-optimized SARIMA-SVR based on MODIS data. *Acta Geophysica*, 73(2), 2097-2126. <https://doi.org/10.1007/s11600-024-01472-7>
- Rashki, A., Middleton, N. J., & Goudie, A. S. (2021). Dust storms in Iran—Distribution, causes, frequencies and impacts. *Aeolian Research*, 48, 100655. <https://doi.org/10.1016/j.aeolia.2020.100655>
- Razavi-Termeh, S. V., Sadeghi-Niaraki, A., Sorooshian, A., Abuhmed, T., & Choi, S. M.

- (2024). Spatial mapping of land susceptibility to dust emissions using optimization of attentive Interpretable Tabular Learning (TabNet) model. *Journal of Environmental Management*, 358, 120682.  
<https://doi.org/10.1016/j.jenvman.2024.120682>
- Rezazadeh, M., Irannejad, P., & Shao, Y. J. A. R. (2013). Climatology of the Middle East dust events. *Aeolian Research*, 10, 103-109.  
<https://doi.org/10.1016/j.aeolia.2013.04.001>
- Shafiee, Sh., & Nakhaei, N. (2018). A technique aimed at improving the speed and accuracy of the KNN classification algorithm. *Nokhbehan of Science and Engineering*, 3(5), 134-142.  
<https://sid.ir/paper/519997/fa> (In Persian)
- Shahsavani, A., Naddafi, K., Haghhighifard, N. J., Mesdaghinia, A., Yunesian, M., Nabizadeh, R., Arahami, M., Sowlat, M. H., Yarahmadi, M., Saki, H., Alimohamadi, M., Nazmara, S., Motevalian, S. A & Goudarzi, G. (2012). The evaluation of PM10, PM2. 5, and PM1 concentrations during the Middle Eastern Dust (MED) events in Ahvaz, Iran, from april through september 2010. *Journal of arid environments*, 77, 72-83.  
<https://doi.org/10.1016/j.jaridenv.2011.09.007>  
[Get rights and content](#)
- Shao, Y. (2008). *Physics and modelling of wind erosion*. Atmospheric and Oceanographic Sciences Library, 37. Springer, Dordrecht.  
[https://doi.org/10.1007/978-1-4020-8895-7\\_9](https://doi.org/10.1007/978-1-4020-8895-7_9)
- Shi, Y. (2001). Particle swarm optimization: developments, applications and resources. In Proceedings of the 2001 congress on evolutionary computation (IEEE Cat. No. 01TH8546), 1, 81-86.  
<https://doi.org/10.1109/CEC.2001.934374>
- Xiong, J., Zhao, T., Bai, Y., Liu, Y., Han, Y., & Guo, C. (2020). Climate characteristics of dust aerosol and its transport in major global dust source regions. *Journal of Atmospheric and Solar-Terrestrial Physics*, 209, 105415.  
<https://doi.org/10.1016/j.jastp.2020.105415>
- Yakowitz, S. J. (1985). Nonparametric density estimation, prediction, and regression for Markov sequences. *Journal of the American Statistical Association*, 80(389), 215-221.  
<https://doi.org/10.1080/01621459.1985.10477164>