The prediction of dust storm events using the integrated triple model GRNN-AF-ARMA and the Ensemble Kalman filter approach (Case Study: Khuzestan Province)

Mohammad Ansari ghojghar [*] |**Ramtin Tavoosi Rad**[2]
Corresponding Author, Assistant Professor, Department of Reclamation of Arid and Mountainous regions .Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran
Master Candidate, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

Research Full Paper
Article History (Received: 2026/04/21 Accepted: 2026/07/11)

Extended abstract

1- Introduction
Dust storms are considered one of the most important extreme climate phenomena in arid and semi-arid regions with widespread consequences for health, the environment and natural resource management. Despite extensive research efforts, accurately predicting dust storm occurrence and intensity remains a significant scientific challenge because of the nonlinear, multiscale, and highly dynamic interactions among atmospheric, land surface, and climatic factors. Accurate understanding of the temporal and spatial variations of destructive climatic phenomena is a fundamental step toward integrated management of these hazards. In recent years, the use of dual hybrid models for simulating dust storms has attracted significant attention. The use of GRNN, due to its high ability to learn complex and nonlinear relationships between variables and identify hidden patterns in data, helps this model act as a strong core for combination with other methods such as AF and ARMA to increase the prediction accuracy of the FDSD index. In this research, the application and performance evaluation of the triple hybrid GRNN-AF-ARMA metamodel has been addressed in a more comprehensive manner and with a new approach.

2- Methodology
This study models the frequency index of dust storm days in Khuzestan province over a 50-year period (1971–2020). The performance of the triple hybrid model GRNN–AF–ARMA in predicting this index was compared with single models GRNN and ARMA, as well as dual hybrid models GRNN–AF, ARMA–AF, and GRNN–ARMA. The dust storm intensity index, representing the severity and frequency of dust events, was selected as the target variable, and Khouzestan Province was chosen as the case study area due to its high exposure to dust storm activity and its climatic vulnerability. To investigate the influence of temporal input structure on model performance, four distinct temporal configurations were designed, ranging from short-term to long-term forecasting horizons. These configurations included time lags from one season up to one year, enabling a comprehensive analysis of how prediction horizon affects model accuracy. After appropriate pre-processing data were divided into training (80%) and testing (20%) sets, and the models' performance was evaluated using the statistical metrics NS, RMSE, MAE and correlation coefficient (R).

3- Results
The results demonstrated the superior performance of the triple hybrid model. Subsequently, to enhance prediction accuracy and stability, the Ensemble Kalman Filter (EnKF) was employed to correct and optimize the outputs of the hybrid model. The findings indicated that integrating this filter with the triple hybrid model significantly improved the correlation coefficient and the Nash–Sutcliffe efficiency. Therefore, the proposed model exhibits high capability in predicting the temporal and spatial patterns of dust storms in Khuzestan province. The use of the cumulative Kalman filter has optimized the model state and improved the accuracy of the forecasts. In addition to improving the accuracy of the FDSD index forecast, the use of the cumulative Kalman filter has increased the stability of the model in the face of nonlinear and noisy climate data. This feature is of particular importance because climate data, especially indicators related to dust storms, due to their complex nature and inherent fluctuations, require methods that can prevent unexpected fluctuations and ensure the stability of the forecasts. In practical terms, the high prediction accuracy of this index can play a significant role in management planning and environmental policy-making, especially in areas facing

[*] **Corresponding Author: ansari.ghojghar@ut.ac.ir**

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

dust crises due to climate change. The results of this research can help develop more effective strategies to control and reduce the negative consequences of these phenomena. Also, combining traditional statistical models such as ARMA with generalized neural networks (GRNN) and evolutionary algorithms such as AF, especially in combination with adaptive filters such as EnKF, showed that the advantages of both linear and nonlinear methods can be used simultaneously.

4- Discussion and Conclusions

The findings of this study emphasize that the use of the Encumbrance Kalman Filter (EnKF) plays an important role in improving the stability and forecast accuracy of hybrid models and can be used as an advanced solution in modeling complex climate phenomena, such as dust storms. Furthermore, the results show that simpler models with shallower temporal inputs can perform better than more complex models in some situations, which highlights the importance of choosing the right model for the climate conditions and available data. Also, results of this research could be used in other articles which had done in same study areas as this research such as western province of Iran. The outcomes of this research can serve as an effective tool for management planning and the implementation of preventive measures to mitigate damages caused by dust storms.

Keywords: Artificial Neural Network, Box-Jenkins Method, FDSD Index, Artificial Plants Algorithm, Modeling.

Cite this article: Ansari ghojghar, M., & Tavoosi Rad, R. (2026). The prediction of dust storm events using the integrated triple model GRNN-AF-ARMA and the Ensemble Kalman filter approach (Case Study: Khuzestan Province). *Journal of Environmental Erosion Research. 2026; 16 (2) :154-178*. http//doi.org/10.61882/jeer.16.2.8

© The Author(s).
DOI: http//doi.org/10.61882/jeer.16.2.8
Published by Hormozgan University Press.
URL: http://magazine.hormozgan.ac.ir

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

بررسی پیش‌بینی طوفان‌های گرد و غبار با استفاده از مدل تلفیقی سه‌گانه GRNN-AF-ARMA و راهکار فیلتر کالمن تجمعی (مطالعه موردی: استان خوزستان)

محمد انصاری قوجقار*: *نویسنده مسئول، استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران.*

رامتین طاوسی راد: *دانش‌آموخته کارشناسی ارشد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران.*

نوع مقاله: پژوهشی

تاریخچهٔ مقاله (تاریخ دریافت: ۱۴۰۵/۰۲/۰۱ تاریخ پذیرش: ۱۴۰۵/۰۴/۲۰)

DOI: http//doi.org/10.61882/jeer.16.2.8

چکیده

شناخت دقیق تغییرات زمانی و مکانی پدیده‌های اقلیمی مخرب، گامی اساسی در مدیریت یکپارچه این مخاطرات است. در سال‌های اخیر، استفاده از فرامدل‌های هیبریدی دوگانه به‌منظور شبیه سازی طوفان‌های گرد و غبار و مقابله با این پدیده و کاهش اثرات مخرب آن بر محیط زیست و سلامت انسان‌ها، مورد توجه گسترده‌ای قرار گرفته است. در این پژوهش، مدل‌سازی شاخص فراوانی روزهای همراه با طوفان گرد و غبار در استان خوزستان طی دوره آماری ۵۰ ساله (۱۹۷۱ تا ۲۰۲۰) انجام شد. عملکرد فرامدل هیبریدی سه‌گانه GRNN–AF–ARMA در پیش‌بینی این شاخص با مدل‌های منفرد GRNN و ARMA و همچنین فرامدل‌های دوگانه GRNN–AF، ARMA–AF و GRNN–ARMA مقایسه گردید که نتایج بیان‌گر برتری قابل توجه فرامدل هیبریدی سه‌گانه بود. در مرحله بعد، به‌منظور افزایش دقت و پایداری پیش‌بینی‌ها، فیلتر کالمن تجمعی جهت تصحیح و بهینه‌سازی خروجی مدل هیبریدی مذکور به‌کار گرفته شد. نتایج نشان داد که ادغام این فیلتر با فرامدل سه‌گانه، موجب افزایش چشمگیر ضریب همبستگی و ضریب نش ساتکلیف شده است. به طوری که مقادیر بیشتر از ۰/۹۶۴ برای ضریب نش ساتکلیف و مقادیر بیشتر از ۰/۹۵۳ برای ضریب همبستگی به ثبت رسید. این افزایش دقت در پیش‌بینی دقیق‌تر این پدیده حدی اقلیمی و تلاش برای کاهش اثرات مخرب آن، تاثیر به‌سزایی دارد. بنابراین، مدل پیشنهادی توانمندی بالایی در پیش‌بینی الگوهای زمانی و مکانی طوفان‌های گرد و غبار در استان خوزستان دارد. از نتایج پژوهش حاضر میتوان بر سایر مناطق مشابه درگیر با پدیده گرد و غبار مانند استان‌های غربی کشور ایران بهره برد. یافته‌های این مطالعه تأکید می‌کند که بهره‌گیری از فیلتر کالمن تجمعی(EnKF) در بهبود پایداری و دقت پیش‌بینی مدل‌های هیبریدی، نقش مهمی ایفاء می‌کند. یافته‌های این پژوهش می‌تواند به‌عنوان ابزاری کارآمد در برنامه‌ریزی مدیریتی و اتخاذ تدابیر پیشگیرانه به‌منظور کاهش خسارات ناشی از طوفان‌های گرد و غبار مورد استفاده قرار گیرد.

کلیدواژه‌ها: شبکه عصبی مصنوعی، باکس جنکینز، شاخص فراوانی روزهای همراه با طوفان گرد و غبار FDSD، الگوریتم گیاهان مصنوعی،مدل‌سازی.

* نویسندهٔ مسئول: ansari.ghojghar@ut.ac.ir

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]
[DOI: 10.61882/jeer.16.2.8]

۱ـ مقدمه

طوفان‌های گرد و غبار پدیده‌های طبیعی جوی هستند که غالباً در مناطق خشک رخ داده و باعث کاهش کیفیت هوا و دید می‌شوند (Nazari et al., 2016). این طوفان‌ها چالش‌هایی ایجاد می‌کنند که مانع دستیابی به اهداف توسعه پایدار تعریف شده در دستور کار ۲۰۳۰ سازمان ملل می‌شوند. از میان ۱۷ هدف، سلامت و رفاه، آب پاک و بهداشت، انرژی پاک و مقرون‌به‌صرفه، صنعت، نوآوری و زیرساخت، شهرها و جوامع پایدار، جلوگیری از تغییرات اقلیمی و حفاظت از زندگی روی زمین، به صورت مستقیم یا غیرمستقیم تحت تأثیر طوفان‌های گرد و غبار قرار می‌گیرند. پیش‌بینی دقیق منابع گرد و غبار حتی با وجود مدل‌های پیشرفته جوی، شناسایی منابع و پیش‌بینی حرکت گرد و غبار در جو کار آسانی نیست و همچنان یک چالش است. دلیل اصلی این مشکل، درک محدود از توزیع منابع گرد و غبار و رفتار آن‌ها در واکنش به تغییرات محیطی است (Feuerstein & Schepanski, 2018). جهت شناسایی منابع گرد و غبار، روش‌های مختلفی مانند سنجش از دور، تحلیل دید افقی، بررسی کانی‌شناسی گرد و غبار و تحلیل مسیر حرکت ذرات مورد استفاده قرار می‌گیرد (Baddock et al., 2014). اما این روش‌ها محدودیت‌هایی دارند و شناسایی منابع گرد و غبار در مناطق وسیع مانند بیابان‌ها همچنان دشوار است (Schepanski et al., 2013).

در سال‌های اخیر، به منظور غلبه بر محدودیت‌های روش‌های سنتی، پژوهشگران از رویکردهای نوین مدل‌سازی آماری و هوش مصنوعی برای بهبود دقت پیش‌بینی طوفان‌های گرد و غبار استفاده کرده‌اند که در ادامه به برخی از مطالعات شاخص در این زمینه اشاره می‌شود. Alshammari و همکاران (۲۰۲۴) با به‌کارگیری مدل‌های LSTM و TCN به پیش‌بینی فراوانی طوفان‌های گرد و غبار در شهرهای ریاض، جده و دمام پرداختند و نشان دادند که این مدل‌ها به‌دلیل توانایی درک روابط زمانی پیچیده، دقت بالاتری نسبت به روش‌های کلاسیک دارند. نتایج آن‌ها حاکی از کاهش خطای پیش‌بینی و افزایش ضریب تعیین (R^2) در مناطق مورد مطالعه بود. این پژوهش نقش کلیدی شبکه‌های عصبی عمیق در پیش‌بینی دقیق‌تر طوفان‌های گرد و غبار را برجسته می‌کند. یک مطالعه جدید با استفاده از مدل‌های هیبریدی CNN-LSTM و ConvLSTM به پیش‌بینی مسیر طوفان‌های گرد و غبار تا ۲۴ ساعت آینده پرداخت که با به‌کارگیری داده‌های متئورولوژیکی و ویژگی‌های انتخاب شده توسط روش جنگل تصادفی، دقت پیش‌بینی را افزایش داد. نتایج نشان داد مدل CNN-LSTM با لحاظ کردن اطلاعات زمینه‌ای عملکرد بهتری نسبت به ConvLSTM دارد. این پژوهش بر اهمیت استفاده از داده‌های چندبُعدی و یادگیری عمیق در بهبود پیش‌بینی طوفان‌های گرد و غبار تأکید دارد (Yarmohamadi et al., 2025).

Ansari ghojghar و همکاران (۲۰۲۰) به مقایسه کارایی شبکه‌های عصبی آماری، فازی و پرسپترونی در پیش‌بینی طوفان‌های گرد و غبار در نواحی بحرانی کشور پرداختند. یافته‌های آنان نشان‌دهنده عملکرد بالای مدل ANFIS و پس از آن GRNN به‌منظور پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار (FDSD) در زابل، آبادان، اهواز، زاهدان، بستان و مسجدسلیمان بود Pang و همکاران (۲۰۲۴) در مطالعه خود با ترکیب فیلتر کالمن تجمعی (EnKF) و مکانیزم جابجایی زمانی معتبر (VTS)، مدل VTS-EnKF را به منظور بهبود خطاهای موقعیتی و شدت گرد و غبار توسعه دادند. نتایج مطالعه آن‌ها نشان داد که این روش نسبت به فیلتر کالمن تجمعی معمولی، دقت پیش‌بینی و تحلیل طوفان‌های گرد و غبار را به طور قابل توجهی افزایش می‌دهد. Rahmati و همکاران (۲۰۲۰) نیز به بررسی طوفان‌های

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

گرد و غبار با استفاده از ترکیب سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) با ترکیبی از الگوریتم‌های بهینه سازی فراکاو شی شامل الگوریتم خفاش (BA)، الگوریتم فرهنگی (CA) و تکاملی تفا ضلی (DE) پرداخته‌اند. نتایج مطالعه آن‌ها نشان داد که مدل ترکیبی ANFIS-DE رو شی نویدبخش و مقرون‌به‌صرفه برای شناسایی کارآمد مناطق منبع گرد و غبار می‌باشد.

از بررسی مطالعات مختلف در این زمینه میتوان دریافت که به‌منظور مدل‌سازی دقیق متغیرهای اقلیمی، به‌خصوص شاخص FDSD، روش‌ها و راهکارهای کمی توسعه یافته و به‌ویژه مدل‌های هیبریدی چندگانه محدود هستند و راه‌حل‌های موجود نیز از دقت کافی و بالایی جهت پیش‌بینی این شاخص برخوردار نیستند. این امر موجب کاهش دقت مدل‌های مورد استفاده شده. در نتیجه سامانه‌های پیش‌بینی و پایش طوفان‌های گردوغبار تضعیف شده و توانایی متخ صصین در پیش‌بینی این پدیده کاهش میابد. لذا در این پژوهش، برای رفع محدودیت‌های روش‌های ا ستفاده شده قبلی، به ارائه یک فرامدل هیبریدی سه‌گانه شامل شبکه عصبی تعمیم‌یافته (GRNN)، الگوریتم گیاهان مصنوعی (AF) و مدل خودرگرسیونی م یانگین متحرک (ARMA) به‌عنوان رویکردی نوین و ترکیبی از یادگیری غیرخطی، الگوریتم‌های فراکاوشی و مدل‌های سری زمانی ارائه شده است. همچنین، به‌کارگیری راهکار فیلتر کالمن تجمعی (EnKF) دقت پیش‌بینی و تحلیل طوفان‌های گرد و غبار را به طور قابل توجهی افزایش می‌دهد.

استفاده از GRNN به دلیل توانایی بالا در یادگیری روابط پیچیده و غیرخطی میان متغیرها و شناسایی الگوهای پنهان در داده‌ها، کمک می‌کند تا این مدل، به عنوان هسته‌ای قوی برای ترکیب با روش‌های دیگر مانند AF و ARMA عمل کند تا دقت پیش‌بینی شاخصFDSD افزایش یابد. مدل ARMA به دلیل قابلیت مدل‌سازی ساختارهای زمانی و پیش‌بینی روندهای خطی سری‌های داده‌ای، می‌تواند رفتار دینامیکی شاخص FDSD را به خوبی ثبت کرده و در ترکیب با GRNN وAF، جنبه‌های خطی و غیرخطی داده‌ها را به صورت همزمان در نظر گرفته و دقت پیش‌بینی را بهبود بخشد. بدین ترتیب، مطالعه حاضر می‌تواند به‌منظور ارائه یک الگوی نوین و دقیق‌تر جهت پیش‌بینی طوفان‌های گرد و غبار باشد. در حالی که پژوهش‌های پیشین غالباً به بررسی مدل‌های انفرادی یا مدل‌های تلفیقی حداکثر دوگانه پرداخته‌اند، در این پژوهش به کاربرد و ارزیابی عملکرد فرامدل هیبریدی سه‌گانه GRNN-AF-ARMA به‌صورت جامع‌تر و با رویکردی نوین پرداخته شده ا ست. علاوه بر این، نتایج تحقیقات Kazemzadeh Varzaneh و همکاران (۲۰۲۴) به ارتقاء عملکرد مدل رگر سیونی با بهره‌گیری از EnKF ا شاره دارد که انگیزه‌ای قوی برای برر سی تأثیر ا ستفاده از راهکار فیلتر کالمن تجمعی را در این مطالعه فراهم کرده است تا علاوه بر افزایش دقت، قابلیت تعمیم‌پذیری مدل نیز ارتقاء یابد.

پژوهش حا ضر با هدف افزایش توانایی مدل سازی طوفانهای گرد و غبار و تلاش برای کاهش اثرات مخرب این پدیده حدی اقلیمی بر محیطزیست و سلامت موجودات زنده، چارچوبی نوین با استفاده از الگوریتم‌های هوش مصنوعی پیشرفته ارائه داده تا فقدان پژوهش‌های پیشین در زمینه مدلسازی کمی این پدیده با مدل‌های هیبریدی چندگانه پرشده و اساس خوبی برای پژوهش‌های آتی و استفاده در سامانه‌های پایش و پیش‌بینی طوفان‌های گردوغبار قرار گیرد.

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

۲ـ منطقهٔ مورد مطالعه

در پژوهش حاضر به بررسی فرامدل هیبریدی سه‌گانه GRNN-AF-ARMA و مقایسه آن با مدل‌های انفرادی GRNN، ARMA و مدل‌های هیبریدی دوگانه GRNN-AF، ARMA-AF، GRNN-ARMو همچنین بررسی راهکار فیلتر کالمن تجمعی به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان‌های گرد و غبار در ایستگاه‌های دزفول، صفی‌آباد، مسجد سلیمان، بستان، اهواز، بندر ماهشهر و آبادان در استان خوزستان، با طول دوره آماری ۵۰ سال (۲۰۱۹-۱۹۷۱) پرداخته شده است (شکل ۱). بدین منظور، ۸۰٪ داده‌های موجود برای آموزش مدل و ۲۰٪ داده‌ها به منظور آزمون مدل‌های مورد پژوهش به‌کار گرفته شدند.



شکل ۱: منطقه مورد مطالعه و ایستگاه‌های منطقه

۳ـ مواد و روش

۳-۱- پدیده گرد و غبار

پدیده‌های بصری آب و هوا طبق دستورالعمل سازمان جهانی هواشناسی در ۱۰۰ کد از ۰۰ تا ۹۹ تعریف شده‌اند. از مجموع این ۱۰۰ کد، به‌طور کلی ۱۱ کد، طبق جدول ۱، برای ثبت و گزارش پدیده گرد و غبار در ایستگاه‌های مختلف هواشناسی استفاده می شود (O'Loingsigh et al., 2014). بنابر تعریف سازمان جهانی هواشناسی، روز همراه با طوفان‌های گرد و غبار روزی است که در آن، حداقل در یکی از هشت سینوپ، یکی از کدهای مرتبط با گرد و غبار (۰۶، ۰۷، ۰۸، ۰۹، ۳۰، ۳۱، ۳۲، ۳۳، ۳۴، ۳۵ و ۹۸) در بخش گزارش هوای حاضر اعلام شده باشد. مشروط بر این‌که، داده‌های قدرت دید افقی متناظر با کد اعلام‌شده، در کم‌تر از ۱۰۰۰ متر ثبت شده باشد (Goudie & Middleton, 2006; Mohammadi, 2015). بدین‌ترتیب، در این مطالعه، از مؤلفه دید افقی کم‌تر از ۱۰۰۰ متر به‌منظور تشخیص طوفان‌های گرد و غبار، برای همه کدها استفاده شده‌است.

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

جدول۱. کدهای سازمان جهانی هواشناسی مرتبط با فرسایش بادی و پدیده های گرد و غبار (O'Loingsigh et al., 2014).

کد	توضیحات
۰۶	رخداد طوفان گرد و خاک گسترده در خارج از ایستگاه هواشناسی
۰۷	خاک یا شن برخواسته 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 متو سط شن یا خاک بدون تغییر شدت طی ساعت گذ شته- 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 (هبوب)

۳-۲- الگوریتم گیاهان مصنوعی (AF)

الگوریتم گیاهان مصنوعی از چهار بخش اصلی تشکیل شده است: گیاه اصلی، گیاه فرزند، محل استقرار گیاه و فاصله پراکنش. محل استقرار گیاه بیان‌گر موقعیت مکانی آن در محیط است و فاصله پراکنش نشان‌دهنده فاصله‌ای است که دانه‌ها از گیاه اصلی جابه‌جا می‌شوند. در این الگوریتم، سه رفتار اصلی براساس روابط زیر مدل‌سازی می‌شود (Dehghani et al., 2020):

۱) رفتار تکامل: رفتار تکاملی به احتمال انطباق و سازگاری گیاه با تغییرات محیطی اشاره دارد (Wiegand & Sarma, 2004). گیاه اصلی دانه‌های خود را در محیطی دایره‌وار پراکنده می‌کند، به طوری که شعاع این دایره برابر با میزان فاصله پراکنش آن است (رابطه ۱). مقدار این فاصله از ترکیب داده‌های مربوط به فاصله پراکنش گیاه والد و گیاه جد محاسبه می‌شود (Dehghani et al., 2020).

$$d_j = d_{1j} \times rand(0,1) \times c_1 + d_{2j} \times rand(0,1) \times c_2 \quad \text{(رابطه ۱)}$$

در رابطه بالا، d_{1j} معادل فاصله پخش گیاه جد (مادربزرگ)، d_{2j} فاصله پخش گیاه والد (مادر) و c_1 و c_2 ضریب‌های یادگیری می‌باشند. همچنین $rand(0,1)$ معادل عددی است که در بازه ذکر شده، توزیعی ثابت و یکنواخت دارد.

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

۲) رفتار پخش: در گام نخست، الگوریتم فلور مصنوعی به‌صورت تصادفی فلور اولیه را ایجاد می‌کند. این فلور شامل N گیاه اصلی است که هر کدام از آن‌ها در موقعیت خاصی در فضای j بعدی قرار دارند. موقعیت هر گیاه اصلی $P_{i,j}$ با استفاده از یک ماتریس توصیف می‌شود که در آن j تعداد گیاهان موجود در فلور و i ابعاد فضای تعریف‌شده برای موقعیت گیاهان را نشان می‌دهد که در این رابطه، d مقدار حداکثر در منطقه و $P_{i,j}$ موقعیت گیاه اصلی است (رابطه ۲).

$$P_{i,j} = rand\ (0,1) \times d \times 2 - d \quad \text{(رابطه ۲)}$$

۳) رفتار انتخاب: رفتار انتخابی به بقاء یا انقراض گیاه بر اثر عوامل محیطی می‌پردازد (Dehghani Griffin et al., 2004 et al., 2020;). در این بخش، احتمال بقاء به‌عنوان معیاری برای ارزیابی زنده بودن یا نبودن گیاهان فرزند، به‌صورت رابطه ۳ مورد استفاده قرار می‌گیرد:

$$P = \left|\sqrt{\frac{F(\acute{P}_{i,j\times m})}{F_{max}}}\right| \times Q_x^{(i\times m-1)} \quad \text{(رابطه ۳)}$$

که در آن، Q_X معادل احتمال انتخاب شده که عددی بین صفر و یک است، می‌باشد. F_{max} بیش‌ترین شایستگی (برازندگی) در فلور نسل موردبررسی و $F(\acute{P}_{i,j\times m})$ برازندگی جواب j ام را نشان می‌دهد.

۳-۳- شبکه عصبی رگرسیون تعمیم‌یافته (GRNN)

GRNN برای اولین بار در سال ۱۹۹۱ توسط Specht تحت عنوان ابزاری با توانایی تخمین و محاسبه توابع دلخواه مدنظر مبتنی بر استفاده از داده‌های گذشته، مطرح شد (Specht, 1991) که یک نوع خاص از شبکه‌های تابع شعاعی است که از اصول تئوری رگرسیون هسته‌ای برای حل مسائل تقریب خطی یا غیرخطی به‌صورت رابطه زیر استفاده می‌کند. این شبکه خروجی‌ای را محاسبه می‌کند که کمترین مقدار خطای میانگین مربعات[1] (MSE) را به دنبال دارد (رابطه ۴).

$$E(Y|X) = \frac{\int_{+\infty}^{-\infty} y f_{x,y}(X,y)dy}{f_x(X)} \quad \text{(رابطه ۴)}$$

در رابطه فوق، Y معادل مقدار پیش‌بینی شده توسط شبکه می‌باشد. X بردار مشاهده‌های سری‌زمانی، $E(Y|X)$ مقدار خروجی Y که بستگی به بردار مشاهده‌های X دارد و $f(Y|X)$ تابع چگالی احتمالی X و Y است. شبکه GRNN شامل چهار لایه است: لایه ورودی، لایه مخفی، لایه جمع‌بندی و لایه خروجی. اطلاعات ورودی به طور مستقیم به لایه مخفی منتقل می‌شود، بدون اینکه از لایه ورودی عبور کرده و وزن‌دهی شود (Boye et al., 2024). اگر تابع گاوس چند متغیره، تابع هسته در رگرسیون‌گیری باشد با استفاده از رابطه ۵ داریم:

$$a_i = exp(-\frac{\|x-x_i\|^2}{2\sigma^2}) \qquad i = 1,2,3,\dots,N \quad \text{(رابطه ۵)}$$

[1] Mean Squared Error

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

در رابطه بالا، a_i خروجی به ازای بردار x، x_i مرکز نورون و σ پارامتر هموارکننده (پارامتر تعیین‌کننده شکل تابع‌های هسته در لایه دوم) می‌باشند. خروجی شبکه عصبی رگرسیون عمومی (لایه چهارم)، معادل میانگین وزن‌دار مشاهده‌های Y_i پیرامون بردار ورودی است (رابطه۶) که به شکل زیر محاسبه شده و قابل نمایش است:

$$y = \frac{\sum_{i=1}^{N} y_i \ exp(-\frac{\|x-x_i\|}{2\sigma^2})}{\sum_{j=1}^{N} exp(-\frac{\|x-x_j\|}{2\sigma^2})}$$ (رابطه ۶)

برخلاف روش‌های آموزشی تکراری مانند الگوریتم پس‌انتشار، GRNN نیازی به فرآیند آموزش تکراری ندارد و محاسبات در آن به صورت مستقیم و به‌صورت پیشرو انجام می‌شود.

۳-۴- مدل خودهمبسته میانگین متحرک (ARMA)

این مدل یک مدل خطی برای سری‌های زمانی ایستا می‌باشد که توسط باکس و جنکینز مطرح شده و توسعه یافته‌اند. در مدل ARMA، پیش‌بینی‌ها براساس مشاهدات گذشته و خطاهای پیش‌بینی‌های گذشته انجام می‌شود. ARMA (P, Q) به‌صورت رابطه ۷ نمایش داده می‌شود:

$$\emptyset(B)X_t = \theta(B)Z_t$$ (رابطه ۷)

در رابطه بالا، B عملگر برگشت به عقب است که به‌صورت زیر محاسبه می‌شود:

$$B^j X_t = X_{t-j}; B^j \qquad Z_t = Z_{t-j}$$ (رابطه ۸)

اگر $\theta(Z) = 1$ باشد، آن‌گاه سری‌زمانی X_t یادشده را فرآیند خودرگرسیون مرتبه p یا AR(p) می‌نامند. در صورتی که $\emptyset(Z) = 1$ باشد، سری‌زمانی فوق فرآیند میانگین متحرک مرتبه q یا به عبارتی MA(q) می‌باشد (Hoseinali Zadeh & Safabakhsh, 2008). این مدل تنها در صورت ایستایی سری‌زمانی، دارای کارایی لازم برای مدل‌سازی می‌باشد.

۳-۵- الگوریتم فیلتر کالمن تجمعی (EnKF)

فیلتر کالمن تجمعی یک الگوریتم فیلترینگ غیرخطی است که روش‌های مونت‌کارلو را با فیلتر کالمن ترکیب می‌کند. این فیلتر با استفاده از روش‌های تصادفی، مجموعه‌ای از پارامترها و متغیرهای حالت را تولید می‌کند تا وضعیت مدل را پیش‌بینی کند. این روش شامل دو بخش اصلی است: پیش‌بینی و به‌روزرسانی هم‌گرایی. در مرحله پیش‌بینی، هر عضو تجمعی براساس دینامیک مدل رو به جلو انتگرال‌گیری می‌شود تا حالت سیستم را برای حالت بعدی پیش‌بینی کند (معادله ۹) (Pang et al., 2024). فرآیند کلیدی فیلتر کالمن تجمعی، ایجاد معادله انتقال حالت (معادله پیش‌بینی) و معادله مشاهده برای سیستم مدل‌شده است. معادله عمومی انتقال حالت به‌صورت زیر تعریف می‌شود:

$$x_{i+1} = f(x_i, \theta) + \varepsilon_i, \varepsilon_i \sim N(0, Q_i)$$ (رابطه ۹)

در این رابطه، x_{i+1} نشان‌دهنده متغیرهای حالت، f مدل هیدرولوژیکی و θ پارامترهای مدل می‌باشند. ε_i خطای مدل است که از توزیع نرمال تبعیت می‌کند.

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

معیارهای ارزیابی مدل مناسب--۳

در پژوهش حاضر، به‌منظور ارزیابی دقت و کارایی مدل‌ها، از ضریب همبستگی[1] (R)، ریشه میانگین مربعات خطا[2] (RMSE)، میانگین قدر مطلق خطا[3] (MAE) و ضریب نش- ساتکلیف[4] (NS) براساس روابط ۱۰ تا ۱۳، استفاده شده است. بهترین مقدار برای این چهار نمایه، به ترتیب، یک، صفر، صفر و یک است. فلوچارت پژوهش حاضر در شکل ۳ نشان داده شده است.

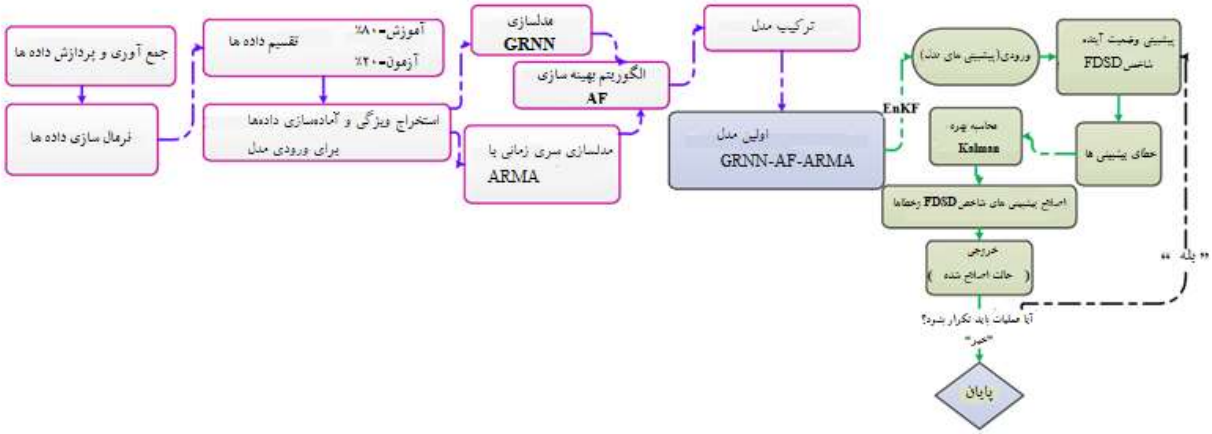
$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(O_i - f_i)^2} \quad \text{(رابطه ۱۰)}$$

$$NS = 1 - \frac{\sum_{i=1}^{n}(O_i - f_i)^2}{\sum_{i=1}^{n}(O_i - \bar{O})^2} \quad \text{(رابطه ۱۱)}$$

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

$$R = \frac{\frac{1}{n}\sum_{i=1}^{n}(O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n}\sum_{i=1}^{n}(O_i - \bar{O})^2}\sqrt{\frac{1}{n}\sum_{i=1}^{n}(f_i - \bar{f})^2}} \quad \text{(رابطه ۱۳)}$$

در رابطه‌های بالا، O_i مقادیر مشاهده‌شده در زمان i، f_i مقادیر پیش‌بینی شده در زمان i، $\bar{f}$ میانگین مقادیر پیش‌بینی شده، $\bar{O}$ میانگین مقادیر مشاهده‌شده و n تعداد داده‌ها می‌باشد. بر این اساس، مدلی که $RMSE$ و MAE کم‌تری و همچنین R و NS بیش‌تر و نزدیک به واحد داشته باشد، کارایی و مطلوبیت بیش‌تری دارد.



شکل ۳: فلوچارت مراحل پیشبینی شاخص FDSD با چارچوب هیبریدی EnKF(GRNN-AF-ARMA)

۴-یافته‌ها

۴-۱- نتایج مدل‌سازی با مدل GRNN

نتایج مرتبط با مدل‌سازی شاخص FDSD در هفت ایستگاه استان خوزستان در بازه زمانی ۵۰ ساله (۲۰۲۰- ۱۹۷۱) در جدول زیر نمایش داده شده است. با توجه به نتایج حاصل از تحلیل و بررسی معیارهای نیکوئی برازش در ایستگاه‌های موردبررسی، ترکیب فصلی شماره یک، به عنوان کارآمدترین ترکیب ورودی برای مدل GRNN شناسایی شد. همان‌طور که در جدول زیر نیز مشخص است، تمامی ایستگاه‌ها به‌ویژه بستان، مسجد سلیمان و دزفول، در ترکیب‌های فصلی یک و دو عملکرد بالایی داشتند. بررسی نتایج نشان می‌دهد که استفاده از داده‌های فصلی قدیمی‌تر (مانند ترکیبات فصلی سه

[1] Correlation Coefficient
[2] Root Mean Square Error
[3] Mean Absolute Error
[4] Nash-Sutcliffe

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]
[DOI: 10.61882/jeer.16.2.8]

و چهار فصل قبل) بهبود معناداری در دقت مدل ایجاد نکرده است و حتی در برخی موارد منجر به افت جزئی دقت شده است. این موضوع حاکی از آن است که تأثیرات زمانی شاخص FDSD عمدتاً به فصل‌های اخیر محدود می‌شود و تأخیرهای زمانی طولانی‌تر نقش کمرنگ‌تری در پیش‌بینی این شاخص دارند. همچنین با توجه به نتایج به‌دست‌آمده از مدل GRNN، مشاهده می‌شود که ایستگاه‌هایی با فراوانی بالای طوفان‌های گرد و غبار (مانند آبادان و اهواز) عملکرد بهتری از نظر معیارهای آماری داشته‌اند. در مقابل، در ایستگاه‌هایی با فراوانی پایین‌تر (مانند صفی‌آباد و دزفول) دقت مدل کاهش یافته است. به عنوان مثال، ضریب NS در ایستگاه آبادان ۰/۸۱۲ بوده که در ایستگاه دزفول به ۰/۷۹۳ کاهش یافته است. از سوی دیگر، نتایج آزمون بر روی مجموعه داده آزمایش نشان می‌دهد که مدل GRNN توانسته است به‌خوبی تعمیم‌پذیری خود را حفظ کند و تفاوت مقادیر NS و R بین مجموعه داده آموزش و آزمایش کمتر از ۲ درصد بوده است، که نشان‌دهنده جلوگیری از بروز بیش‌برازش[1] در فرایند آموزش مدل است.

جدول ۲- نتایج آماری داده‌های ورودی مدل GRNN به‌منظور پیش‌بینی شاخص FDSD

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
آبادان	۱	۰/۸۲۷	۰/۴۱۷	۰/۳۶۹	۰/۷۹۷	۰/۸۱۲	۰/۴۴۱	۰/۳۸۷	**۰/۷۸۲**
	۲	۰/۸۲۷	۰/۴۱۸	۰/۳۶۹	۰/۸۰۱	۰/۸۱۲	۰/۴۴۲	۰/۳۸۸	**۰/۷۸۲**
	۳	۰/۸۲۶	۰/۴۲۳	۰/۳۷۱	۰/۷۹۷	۰/۸۱۱	۰/۴۴۳	۰/۳۸۸	**۰/۷۸۱**
	۴	۰/۸۲۶	۰/۴۱۹	۰/۳۷۱	۰/۷۹۶	۰/۸۱۱	۰/۴۴۳	۰/۳۸۹	**۰/۷۷۶**
اهواز	۱	۰/۸۲۵	۰/۴۲۰	۰/۳۷۲	۰/۷۹۶	۰/۸۱۱	۰/۴۴۴	۰/۳۸۹	**۰/۷۷۹**
	۲	۰/۸۲۵	۰/۴۲۴	۰/۳۷۳	۰/۷۹۵	۰/۸۰۹	۰/۴۴۵	۰/۳۹۱	**۰/۷۷۹**
	۳	۰/۸۲۴	۰/۴۲۵	۰/۳۷۴	۰/۷۹۵	۰/۸۰۹	۰/۴۴۶	۰/۳۹۱	**۰/۷۷۸**
	۴	۰/۸۲۳	۰/۴۲۶	۰/۳۷۵	۰/۷۹۴	۰/۸۰۹	۰/۴۴۷	۰/۳۹۰	**۰/۷۷۶**
بستان	۱	۰/۸۲۳	۰/۴۲۷	۰/۳۷۶	۰/۷۹۳	۰/۸۰۸	۰/۴۴۸	۰/۳۹۰	**۰/۷۷۵**
	۲	۰/۸۲۱	۰/۴۲۸	۰/۳۷۶	۰/۷۹۲	۰/۸۰۷	۰/۴۴۸	۰/۳۹۲	**۰/۷۷۵**
	۳	۰/۸۲۱	۰/۴۲۹	۰/۳۷۷	۰/۷۹۲	۰/۸۰۶	۰/۴۴۸	۰/۳۹۳	**۰/۷۷۵**
	۴	۰/۸۱۹	۰/۴۳۱	۰/۳۷۸	۰/۷۹۱	۰/۸۰۵	۰/۴۴۹	۰/۳۹۳	**۰/۷۷۴**
مسجدسلیمان	۱	۰/۸۱۹	۰/۴۳۲	۰/۳۷۸	۰/۷۹۱	۰/۸۰۴	۰/۴۵۱	۰/۳۹۴	**۰/۷۷۳**
	۲	۰/۸۱۸	۰/۴۳۳	۰/۳۷۹	۰/۷۸۹	۰/۸۰۳	۰/۴۵۱	۰/۳۹۵	**۰/۷۷۲**
	۳	۰/۸۱۸	۰/۴۳۴	۰/۳۸۱	۰/۷۸۹	۰/۸۰۲	۰/۴۵۲	۰/۳۹۶	**۰/۷۷۲**
	۴	۰/۸۱۷	۰/۴۳۵	۰/۳۸۱	۰/۷۹۱	۰/۸۰۱	۰/۴۵۳	۰/۳۹۷	**۰/۷۷۱**
بندرماهشهر	۱	۰/۸۱۷	۰/۴۳۶	۰/۳۸۲	۰/۷۹۳	۰/۸۰۱	۰/۴۵۴	۰/۳۹۸	**۰/۷۶۹**
	۲	۰/۸۱۶	۰/۴۳۷	۰/۳۸۳	۰/۷۸۷	۰/۸۰۱	۰/۴۵۵	۰/۳۹۹	**۰/۷۶۹**
	۳	۰/۸۱۵	۰/۴۳۷	۰/۳۸۴	۰/۷۸۶	۰/۷۹۹	۰/۴۵۶	۰/۴۰۱	**۰/۷۶۸**
	۴	۰/۸۱۵	۰/۴۳۸	۰/۳۸۵	۰/۷۸۶	۰/۷۹۸	۰/۴۵۷	۰/۴۰۱	**۰/۷۶۷**
صفی‌آباد	۱	۰/۸۱۵	۰/۴۳۹	۰/۳۸۶	۰/۷۸۵	۰/۷۹۷	۰/۴۵۷	۰/۴۰۰	**۰/۷۶۹**

[1] Overfitting

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

	۲	۰/۸۱۴	۰/۴۴۰	۰/۳۸۶	۰/۷۸۴	۰/۷۹۶	۰/۴۵۸	۰/۴۰۲	**۰/۷۶۸**
	۳	۰/۸۱۳	۰/۴۴۱	۰/۳۸۸	۰/۷۸۱	۰/۷۹۵	۰/۴۵۹	۰/۴۰۳	**۰/۷۶۵**
	۴	۰/۸۱۳	۰/۴۴۲	۰/۳۸۷	۰/۷۸۲	۰/۷۹۴	۰/۴۵۹	۰/۴۰۴	**۰/۷۶۵**
دزفول	۱	۰/۸۱۲	۰/۴۴۳	۰/۳۸۷	۰/۷۸۲	۰/۷۹۳	۰/۴۶۱	۰/۴۰۴	**۰/۷۶۴**
	۲	۰/۸۱۲	۰/۴۴۴	۰/۳۸۹	۰/۷۸۳	۰/۷۹۲	۰/۴۶۱	۰/۴۰۴	**۰/۷۵۹**
	۳	۰/۸۱۱	۰/۴۴۴	۰/۳۹۱	۰/۷۸۰	۰/۷۹۲	۰/۴۶۲	۰/۴۰۵	**۰/۷۶۳**
	۴	۰/۸۱۱	۰/۴۴۵	۰/۳۹۰	۰/۷۶۹	۰/۷۹۱	۰/۴۶۴	۰/۴۰۶	**۰/۷۶۱**

۴-۲- نتایج مدل‌سازی با مدل ARMA

جدول شماره ۳، نتایج مدل‌سازی شاخص FDSD با مدل خودهمبسته میانگین متحرک را نمایش می‌دهد. مدل‌سازی و پیش‌بینی طوفان‌های گرد و غبار با این روش نیز، با استفاده از ترکیب‌های یک و دو، کاهش خطا و افزایش عملکرد را به نسبت سایر ترکیبات بررسی شده نشان می‌دهد. در این بین نیز، ترکیب شماره یک در تمامی ایستگاه‌ها، با کم‌ترین میزان RMSE، به‌عنوان ترکیب منتخب شناسایی شده است. به‌عنوان مثال، مقدار RMSE در ایستگاه بستان از ۰/۴۳۵ روز درنتیجه پیش‌بینی گرد و غبار فصول آتی با استفاده از ۴ فصل قبل، به ۰/۴۳۲ روز درنتیجه اعمال یک فصل پیشین، کاهش یافته است. علاوه بر این، نتایج مدل ARMA نشان می‌دهد که دقت پیش‌بینی این مدل در ایستگاه‌هایی با فراوانی بالاتر روزهای گرد و غبار، نظیر آبادان و اهواز، بیشتر بوده است. به‌طوری‌که در این ایستگاه‌ها مقادیر ضریب R به میزان قابل‌توجهی بالاتر از ایستگاه‌هایی با فراوانی کمتر نظیر صفی‌آباد و دزفول ثبت شده است. به‌عنوان نمونه، مقدار R در داده‌های آزمایش از ۰/۸۰۳ در ایستگاه آبادان به ۰/۷۸۹ در ایستگاه دزفول کاهش یافته است که نشان‌دهنده افت ۱/۷۴ درصدی دقت مدل در ارتباط‌دهی داده‌های پیش‌بینی شده با مقادیر واقعی می‌باشد. این روند بیان‌گر آن است که هرچه فراوانی روزهای گردوغبار در داده‌های آموزشی بیشتر باشد، مدل ARMA قادر خواهد بود با دقت بالاتری الگوهای زمانی وقوع این پدیده را شناسایی کند.

جدول ۳- نتایج آماری داده‌های ورودی مدل ARMA به‌منظور پیش‌بینی شاخص FDSD

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
آبادان	۱	۰/۸۵۳	۰/۴۰۷	۰/۳۳۲	۰/۸۲۳	۰/۸۳۱	۰/۴۲۹	۰/۳۵۴	**۰/۸۰۳**
	۲	۰/۸۵۲	۰/۴۰۷	۰/۳۳۱	۰/۸۲۳	۰/۸۳۱	۰/۴۲۹	۰/۳۵۴	**۰/۸۰۳**
	۳	۰/۸۵۱	۰/۴۰۷	۰/۳۳	۰/۸۲۴	۰/۸۳۰	۰/۴۲۹	۰/۳۵۵	**۰/۸۰۳**
	۴	۰/۸۵۱	۰/۴۰۸	۰/۳۳۴	۰/۸۲۳	۰/۸۳۰	۰/۴۲۸	۰/۳۵۶	**۰/۸۰۲**
اهواز	۱	۰/۸۵۰	۰/۴۰۹	۰/۳۳۴	۰/۸۲۲	۰/۸۲۹	۰/۴۳۱	۰/۳۵۷	**۰/۸۰۱**
	۲	۰/۸۵۲	۰/۴۱۱	۰/۳۳۴	۰/۸۲۱	۰//۸۲۸	۰/۴۳۰	۰/۳۵۸	**۰/۸۰۱**
	۳	۰/۸۵۲	۰/۴۱۲	۰/۳۳۵	۰/۸۲۱	۰/۸۲۸	۰/۴۳۰	۰/۳۵۹	**۰/۸۰۰**
	۴	۰/۸۵۱	۰/۴۱۳	۰/۳۳۶	۰/۸۲۱	۰/۸۲۷	۰/۴۳۲	۰/۳۶۱	**۰/۸۰۱**
بستان	۱	۰/۸۴۹	۰/۴۱۳	۰/۳۳۷	۰/۸۱۹	۰/۸۲۷	۰/۴۳۲	۰/۳۶۲	**۰/۸۰۱**
	۲	۰/۸۴۹	۰/۴۱۴	۰/۳۳۸	۰/۸۲۰	۰/۸۲۶	۰/۴۳۳	۰/۳۶۳	**۰/۸۰۰**
	۳	۰/۸۴۸	۰/۴۱۵	۰/۳۳۹	۰/۸۲۰	۰/۸۲۵	۰/۴۳۴	۰/۳۶۴	**۰/۷۹۹**
	۴	۰/۸۴۷	۰/۴۱۶	۰/۳۴۱	۰/۸۱۹	۰/۸۲۵	۰/۴۳۵	۰/۳۶۵	**۰/۷۹۸**

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]
[DOI: 10.61882/jeer.16.2.8]

مسجدسلیمان	۱	۰/۸۴۷	۰/۴۱۷	۰/۳۴۲	۰/۸۱۸	۰/۸۲۵	۰/۴۳۶	۰/۳۶۶	۰/۷۹۷
	۲	۰/۸۴۶	۰/۴۱۸	۰/۳۴۳	۰/۸۱۷	۰/۸۲۴	۰/۴۳۷	۰/۳۶۷	۰/۷۹۶
	۳	۰/۸۴۶	۰/۴۱۹	۰/۳۴۴	۰/۸۱۶	۰/۸۲۳	۰/۴۳۸	۰/۳۶۸	۰/۷۹۵
	۴	۰/۸۴۵	۰/۴۲۰	۰/۳۴۵	۰/۸۱۶	۰/۸۲۲	۰/۴۳۸	۰/۳۶۹	۰/۷۹۵
بندرماهشهر	۱	۰/۸۴۴	۰/۴۲۱	۰/۳۴۶	۰/۸۱۶	۰/۸۲۱	۰/۴۳۹	۰/۳۷۱	۰/۷۹۴
	۲	۰/۸۴۳	۰/۴۲۲	۰/۳۴۷	۰/۸۱۵	۰/۸۲۱	۰/۴۴۰	۰/۳۷۲	۰/۷۹۴
	۳	۰/۸۴۲	۰/۴۲۳	۰/۳۴۷	۰/۸۱۴	۰/۸۲۱	۰/۴۴۱	۰/۳۷۳	۰/۷۹۴
	۴	۰/۸۴۲	۰/۴۲۴	۰/۳۴۸	۰/۸۱۳	۰/۸۲۱	۰/۴۴۲	۰/۳۷۴	۰/۷۹۳
صفی‌آباد	۱	۰/۸۴۱	۰/۴۲۵	۰/۳۴۹	۰/۸۱۳	۰/۸۱۹	۰/۴۴۳	۰/۳۷۵	۰/۷۹۲
	۲	۰/۸۴۱	۰/۴۲۶	۰/۳۴۹	۰/۸۱۳	۰/۸۱۹	۰/۴۴۴	۰/۳۷۶	۰/۷۹۱
	۳	۰/۸۳۹	۰/۴۲۷	۰/۳۵۱	۰/۸۱۲	۰/۸۱۸	۰/۴۴۴	۰/۳۷۷	۰/۷۹۱
	۴	۰/۸۳۹	۰/۴۲۸	۰/۳۵۱	۰/۸۱۱	۰/۸۱۷	۰/۴۴۵	۰/۳۷۸	۰/۷۹۰
دزفول	۱	۰/۸۳۸	۰/۴۲۸	۰/۳۵۲	۰/۸۱۱	۰/۸۱۶	۰/۴۴۶	۰/۳۷۹	۰/۷۸۹
	۲	۰/۸۳۷	۰/۴۲۹	۰/۳۵۳	۰/۸۱۰	۰/۸۱۵	۰/۴۴۷	۰/۳۷۹	۰/۷۸۸
	۳	۰/۸۳۶	۰/۴۳۱	۰/۳۵۴	۰/۸۰۹	۰/۸۱۴	۰/۴۴۸	۰/۳۷۸	۰/۷۸۷
	۴	۰/۸۳۵	۰/۴۳۰	۰/۳۵۵	۰/۸۰۸	۰/۸۱۳	۰/۴۴۹	۰/۳۷۷	۰/۷۸۶

۴-۳- نتایج مدل‌سازی با مدل GRNN-AF

نتایج مدل‌سازی با مدل GRNN-AF در جدول ۴ نشان می‌دهد که افزودن کاتالیزور گیاهان مصنوعی (AF) به مدل GRNN نه تنها باعث بهبود نتایج پیش‌بینی شاخص FDSD نشده، بلکه در اغلب موارد منجر به افزایش میزان خطا و کاهش دقت مدل شده است. این کاهش عملکرد به‌ویژه در ایستگاه‌هایی با فراوانی کمتر روزهای گرد و غبار، نظیر دزفول و صفی‌آباد، مشهودتر است؛ به‌گونه‌ای که در ایستگاه دزفول، مقدار RMSE داده‌های آزمایش از ۰/۴۶۱ روز در مدل GRNN به ۰/۵۰۴ روز در مدل GRNN-AF افزایش یافته است. بررسی تغییرات آماری نشان می‌دهد که افزودن متغیرهای مصنوعی (AF) موجب افزایش نویز و کاهش توان مدل در شناسایی الگوهای اصلی داده‌های واقعی شده است . به عبارت دیگر، ساختار ساده و غیرپارامتریک GRNN در مواجهه با داده‌های تقویت‌شده مصنوعی، به دلیل عدم تطابق ویژگی‌های افزوده‌شده با رفتار طبیعی سری‌های زمانی، دچار اختلال عملکرد شده است. این امر به‌ویژه در ایستگاه‌های با الگوهای زمانی پیچیده‌تر و پراکندگی کمتر (نظیر صفی‌آباد و مسجدسلیمان) منجر به افت دقت مدل شده است. بنابراین، می‌توان نتیجه گرفت که مدل GRNN به‌تنهایی عملکرد قابل قبولی در پیش‌بینی شاخص FDSD داشته و افزودن کاتالیزور مصنوعی AF نه تنها موجب بهبود مدل نشده، بلکه با افزایش خطاها، موجب کاهش کیفیت پیش‌بینی نیز شده است.

جدول ۴- نتایج آماری داده‌های ورودی مدل GRNN-AF به‌منظور پیش‌بینی شاخص FDSD

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
آبادان	۱	۰/۸۱۱	۰/۴۵۷	۰/۳۹۱	۰/۷۳۸	۰/۷۸۹	۰/۴۸۶	۰/۴۰۳	۰/۷۱۷
	۲	۰/۸۰۹	۰/۴۵۷	۰/۳۹۱	۰/۷۳۸	۰/۷۸۸	۰/۴۸۷	۰/۴۰۴	۰/۷۱۷

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]
[DOI: 10.61882/jeer.16.2.8]

	۳	۰/۸۰۹	۰/۴۵۶	۰/۳۹۲	۰/۷۳۷	۰/۷۸۸	۰/۴۸۸	۰/۴۰۴	**۰/۷۱۸**
	۴	۰/۸۱۱	۰/۴۵۸	۰/۳۹۲	۰/۷۳۷	۰/۷۸۷	۰/۴۸۸	۰/۴۰۳	**۰/۷۱۹**
	۱	۰/۸۱۰	۰/۴۵۸	۰/۳۹۳	۰/۷۳۶	۰/۷۸۶	۰/۴۸۹	۰/۴۰۳	**۰/۷۲۱**
	۲	۰/۸۱۰	۰/۴۵۹	۰/۳۹۴	۰/۷۳۶	۰/۷۸۶	۰/۴۸۹	۰/۴۰۳	**۰/۷۱۶**
اهواز	۳	۰/۸۱۰	۰/۴۵۹	۰/۳۹۵	۰/۷۳۵	۰/۷۸۶	۰/۴۹۱	۰/۴۰۵	**۰/۷۱۵**
	۴	۰/۸۰۹	۰/۴۶۱	۰/۳۹۶	۰/۷۳۴	۰/۷۸۵	۰/۴۸۷	۰/۴۰۶	**۰/۷۱۷**
	۱	۰/۸۰۸	۰/۴۶۲	۰/۳۹۷	۰/۷۳۳	۰/۷۸۴	۰/۴۹۲	۰/۴۰۷	**۰/۷۱۵**
	۲	۰/۸۰۷	۰/۴۶۱	۰/۳۹۸	۰/۷۳۲	۰/۷۸۳	۰/۴۹۲	۰/۴۰۸	**۰/۷۱۵**
بستان	۳	۰/۸۰۷	۰/۴۶۳	۰/۳۹۹	۰/۷۳۱	۰/۷۸۳	۰/۴۹۳	۰/۴۰۸	**۰/۷۱۴**
	۴	۰/۸۰۷	۰/۴۶۳	۰/۳۹۹	۰/۷۳۱	۰/۷۸۳	۰/۴۹۴	۰/۴۰۹	**۰/۷۱۳**
	۱	۰/۸۰۶	۰/۴۶۴	۰/۴۰۱	۰/۷۲۹	۰/۷۸۲	۰/۴۹۵	۰/۴۰۹	**۰/۷۱۲**
	۲	۰/۸۰۵	۰/۴۶۵	۰/۴۰۱	۰/۷۲۹	۰/۷۸۲	۰/۴۹۶	۰/۴۱۱	**۰/۷۱۲**
مسجدسلیمان	۳	۰/۸۰۴	۰/۴۶۶	۰/۴۰۲	۰/۷۲۸	۰/۷۸۱	۰/۴۹۷	۰/۴۱۲	**۰/۷۱۲**
	۴	۰/۸۰۵	۰/۴۶۷	۰/۴۰۳	۰/۷۲۷	۰/۷۸۰	۰/۴۹۸	۰/۴۱۳	**۰/۷۱۱**
	۱	۰/۸۰۳	۰/۴۶۷	۰/۴۰۴	۰/۷۲۶	۰/۷۸۰	۰/۴۹۸	۰/۴۱۴	**۰/۷۱۰**
	۲	۰/۸۰۲	۰/۴۶۸	۰/۴۰۵	۰/۷۲۶	۰/۷۷۹	۰/۴۹۹	۰/۴۱۴	**۰/۷۱۰**
بندرماهشهر	۳	۰/۸۰۲	۰/۴۶۹	۰/۴۰۶	۰/۷۲۵	۰/۷۷۸	۰/۵۰۱	۰/۴۱۵	**۰/۷۱۰**
	۴	۰/۸۰۱	۰/۴۷۱	۰/۴۰۷	۰/۷۲۴	۰/۷۷۸	۰/۵۰۱	۰/۴۱۶	**۰/۷۰۹**
	۱	۰/۸۰۳	۰/۴۷۲	۰/۴۰۸	۰/۷۲۳	۰/۷۷۶	۰/۵۰۰	۰/۴۱۷	**۰/۷۰۸**
	۲	۰/۸۰۳	۰/۴۷۳	۰/۴۰۹	۰/۷۲۲	۰/۷۷۵	۰/۵۰۲	۰/۴۱۸	**۰/۷۰۸**
صفی‌آباد	۳	۰/۸۰۱	۰/۴۷۴	۰/۴۰۹	۰/۷۲۱	۰/۷۷۴	۰/۵۰۲	۰/۴۱۸	**۰/۷۰۷**
	۴	۰/۸۰۱	۰/۴۷۵	۰/۴۱۰	۰/۷۲۱	۰/۷۷۳	۰/۵۰۳	۰/۴۱۹	**۰/۷۰۶**
	۱	۰/۸۰۰	۰/۴۷۶	۰/۴۱۱	۰/۷۱۹	۰/۷۷۲	۰/۵۰۴	۰/۴۱۹	**۰/۷۰۶**
	۲	۰/۷۹۹	۰/۴۷۷	۰/۴۱۲	۰/۷۱۹	۰/۷۷۱	۰/۵۰۵	۰/۴۲۱	**۰/۷۰۵**
دزفول	۳	۰/۷۹۶	۰/۴۷۸	۰/۴۱۳	**۰/۷۱۸**	۰/۷۷۰	۰/۵۰۶	۰/۴۲۲	**۰/۷۰۴**
	۴	۰/۷۹۷	۰/۴۷۹	۰/۴۱۴	**۰/۷۱۷**	۰/۷۶۹	۰/۵۰۷	۰/۴۲۳	**۰/۷۰۳**

۴-۵- نتایج مدل‌سازی با مدل ARMA-AF

نتایج مدل‌سازی با مدل ARMA-AF (جدول ۵) بیان‌گر آن است که افزودن الگوریتم گیاهان مصنوعی (AF) به مدل ARMA موجب بهبود پایداری و کاهش نوسانات خطای پیش‌بینی در ایستگاه‌های مختلف گردیده است. برخلاف مدل GRNN-AFکه با کاهش دقت مواجه شد، ترکیب ARMA با AF توانسته است بیشترین تطابق با رفتار داده‌های واقعی را در ترکیب‌های منتخب (به‌ویژه ترکیب شماره یک) حفظ نماید. تحلیل داده‌های جدول ۵ نشان می‌دهد که الگوریتم AFبا تنظیم بهینه ضرایب مدل ARMA، توانسته است عملکرد مدل را در مواجهه با الگوهای پیچیده زمانی نظیر طوفان‌های گردوغبار خوزستان بهبود دهد. به‌طور خاص، در ایستگاه‌هایی مانند آبادان و اهواز که رفتار داده‌ها دارای چرخه‌های قوی‌تر و ساختارهای سری زمانی باثبات‌تری هستند، افزودن الگوریتم AF منجر به کاهش میانگین خطای مدل و ارتقاء شاخص‌هایNS و R شده است. برای مثال، در ایستگاه آبادان مقدار RMSE در داده‌های آزمایش به ۰/۴۰۱ روز کاهش

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]
[DOI: 10.61882/jeer.16.2.8]

یافته است که نسبت به مدل ARMA ساده، نشان‌دهنده بهبود قابل‌توجهی در دقت پیش‌بینی است. همچنین در ایستگاه دزفول که به دلیل تعداد کمتر روزهای همراه با طوفان گردوغبار رفتار داده‌ها نوسانات بیشتری دارد، مقدار RMSE از ۰/۴۴۶ روز به ۰/۴۲۲ روز کاهش یافته است. این روند کاهشی در مقادیر خطا حاکی از افزایش انعطاف‌پذیری مدل تلفیقی ARMA-AF در مواجهه با رفتارهای غیرخطی و نوسانات ناگهانی داده‌هاست، به‌طوری که الگوریتم AF توانسته است تا حدودی نواقص ذاتی مدل ARMA در تطبیق با داده‌های پیچیده را جبران کند.

جدول ۵- نتایج آماری داده‌های ورودی مدل ARMA-AF به‌منظور پیش‌بینی شاخص FDSD

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
آبادان	۱	۰/۸۷۱	۰/۳۹۳	۰/۳۰۸	۰/۸۳۷	۰/۸۴۶	۰/۴۰۱	۰/۳۲۳	**۰/۸۲۳**
	۲	۰/۸۷۱	۰/۳۹۴	۰/۳۰۸	۰/۸۳۶	۰/۸۴۶	۰/۴۰۱	۰/۳۲۴	**۰/۸۲۴**
	۳	۰/۸۷۰	۰/۳۹۴	۰/۳۰۹	۰/۸۳۶	۰/۸۴۵	۰/۴۰۱	۰/۳۲۵	**۰/۸۲۰**
	۴	۰/۸۶۹	۰/۳۹۴	۰/۳۱۰	۰/۸۳۵	۰/۸۴۵	۰/۴۰۲	۰/۳۲۵	**۰/۸۲۰**
اهواز	۱	۰/۸۶۹	۰/۳۹۵	۰/۳۱۰	۰/۸۳۴	۰/۸۴۵	۰/۴۰۲	۰/۳۲۶	**۰/۸۲۰**
	۲	۰/۸۶۹	۰/۳۹۵	۰/۳۱۱	۰/۸۳۳	۰/۸۴۴	۰/۴۰۶	۰/۳۲۷	**۰/۸۲۱**
	۳	۰/۸۶۸	۰/۳۹۵	۰/۳۱۲	۰/۸۳۲	۰/۸۴۳	۰/۴۰۴	۰/۳۲۷	**۰/۸۲۱**
	۴	۰/۸۶۸	۰/۳۹۷	۰/۳۱۳	**۰/۸۳۱**	۰/۸۴۲	۰/۴۰۵	۰/۳۲۸	**۰/۸۱۹**
بستان	۱	۰/۸۶۷	۰/۳۹۶	۰/۳۱۴	۰/۸۳۰	**۰/۸۴۱**	۰/۴۰۶	۰/۳۲۹	**۰/۸۱۹**
	۲	۰/۸۶۷	۰/۳۹۶	۰/۳۱۵	**۰/۸۲۹**	**۰/۸۴۱**	۰/۴۰۷	۰/۳۳۰	**۰/۸۱۹**
	۳	۰/۸۶۵	۰/۳۹۸	۰/۳۱۶	**۰/۸۲۸**	۰/۸۴۰	۰/۴۰۷	۰/۳۳۱	**۰/۸۱۸**
	۴	۰/۸۶۴	۰/۳۹۸	۰/۳۱۷	**۰/۸۲۷**	۰/۸۳۹	۰/۴۰۸	۰/۳۳۲	**۰/۸۱۸**
مسجدسلیمان	۱	۰/۸۶۶	۰/۳۹۸	۰/۳۱۸	**۰/۸۲۶**	۰/۸۳۸	۰/۴۱۱	۰/۳۳۲	**۰/۸۱۷**
	۲	۰/۸۶۵	۰/۴۰۱	۰/۳۱۹	**۰/۸۲۵**	**۰/۸۳۷**	۰/۴۱۲	۰/۳۳۳	**۰/۸۱۷**
	۳	۰/۸۶۵	۰/۴۰۲	۰/۳۲۱	**۰/۸۲۴**	۰/۸۳۶	۰/۴۰۹	۰/۳۳۴	**۰/۸۱۶**
	۴	۰/۸۶۴	۰/۴۰۳	۰/۳۲۱	**۰/۸۲۴**	۰/۸۳۵	۰/۴۱۳	۰/۳۳۵	**۰/۸۱۶**
بندرماهشهر	۱	۰/۸۶۳	۰/۴۰۴	۰/۳۲۰	**۰/۸۲۴**	۰/۸۳۵	۰/۴۱۴	۰/۳۳۶	**۰/۸۱۵**
	۲	۰/۸۶۲	۰/۴۰۵	۰/۳۲۰	**۰/۸۲۳**	۰/۸۳۴	۰/۴۱۵	۰/۳۳۶	**۰/۸۱۴**
	۳	۰/۸۶۲	۰/۴۰۵	۰/۳۲۰	**۰/۸۲۱**	۰/۸۳۳	۰/۴۱۶	۰/۳۳۶	**۰/۸۱۳**
	۴	۰/۸۶۱	۰/۴۰۶	۰/۳۲۲	**۰/۸۲۱**	۰/۸۳۲	**۰/۴۱۷**	۰/۳۳۷	**۰/۸۱۲**
صفی‌آباد	۱	۰/۸۶۱	۰/۴۰۷	۰/۳۲۳	**۰/۸۲۱**	**۰/۸۳۱**	۰/۴۱۸	۰/۳۳۸	**۰/۸۱۲**
	۲	۰/۸۶۰	۰/۴۰۷	۰/۳۲۴	**۰/۸۲۰**	۰/۸۳۰	۰/۴۱۹	۰/۳۳۹	**۰/۸۱۱**
	۳	۰/۸۵۹	۰/۴۰۸	۰/۳۲۵	**۰/۸۲۰**	۰/۸۳۰	۰/۴۱۹	۰/۳۴۰	**۰/۸۱۰**
	۴	۰/۸۵۸	۰/۴۰۹	۰/۳۲۶	**۰/۸۱۹**	۰/۸۲۹	۰/۴۲۱	۰/۳۴۰	**۰/۸۱۰**
دزفول	۱	۰/۸۵۷	۰/۴۰۹	۰/۳۲۷	**۰/۸۱۹**	۰/۸۲۹	۰/۴۲۲	۰/۳۴۱	**۰/۸۰۹**
	۲	۰/۸۵۶	۰/۴۰۶	۰/۳۲۸	**۰/۸۱۸**	**۰/۸۲۸**	۰/۴۲۳	۰/۳۴۲	**۰/۸۰۹**
	۳	۰/۸۵۶	۰/۴۱۱	۰/۳۲۹	**۰/۸۱۷**	۰/۸۲۹	۰/۴۲۴	۰/۳۴۳	**۰/۸۰۹**
	۴	۰/۸۵۵	۰/۴۱۲	۰/۳۳۱	۰/۸۱۷	۰/۸۲۷	۰/۴۲۵	۰/۳۴۴	**۰/۸۰۸**

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

۴- نتایج مدل‌سازی با فرامدل هیبریدی GRNN-ARMA

بر اساس جدول ۶، نتایج حاصل از به‌کارگیری فرامدل هیبریدی GRNN-ARMA نشان می‌دهد که تلفیق این دو مدل، برخلاف انتظار، منجر به کاهش دقت پیش‌بینی شاخص FDSD و افزایش خطاها نسبت به مدل‌های پایه (نظیر ARMA-AF) شده است. شاخص‌های NS و R در تمامی ایستگاه‌ها کاهش یافته و مقادیر RMSE و MAE افزایش نشان می‌دهد که این امر بیانگر ضعف مدل هیبریدی در مواجهه با رفتار غیرخطی و نوسانات شدید داده‌های مربوط به طوفان‌های گردوغبار خوزستان است. در تمامی ایستگاه‌ها، ترکیب فصلی شماره ۱ نسبت به سایر ترکیب‌ها عملکرد بهتری داشته است، با این حال، دقت آن در مقایسه با مدل‌های ARMA و ARMA-AF همچنان پایین‌تر باقی مانده است. در ایستگاه‌هایی با ساختار زمانی منظم‌تر نظیر آبادان و اهواز، افت دقت کمتر بوده، اما در ایستگاه‌های پرنوسان مانند دزفول، کاهش دقت و افزایش خطاها محسوس‌تر است. به عنوان مثال، در ایستگاه دزفول، مقدار RMSE در داده‌های آزمایش برای ترکیب شماره ۱ به ۰/۵۱۶ روز رسیده که نسبت به مدل ARMA (۰/۴۲۲ روز) و ARMA-AF (۰/۴۰۱ روز) افزایش قابل‌توجهی دارد. این نتایج نشان می‌دهد که اگرچه GRNN در مدل‌سازی روابط غیرخطی توانمند است، اما ترکیب آن با ARMA به دلیل تضاد در روش‌های پردازش و نبود همخوانی معماری، نتوانسته است دقت مدل را بهبود بخشد. بنابراین طراحی فرامدل‌های هیبریدی باید با توجه به ماهیت داده‌ها و سازگاری درونی مدل‌ها انجام گیرد و صرفاً تلفیق مدل‌های پیشرفته به تنهایی تضمین‌کننده بهبود عملکرد نخواهد بود.

جدول ۶- نتایج آماری داده‌های ورودی مدل GRNN-ARMA به‌منظور پیش‌بینی شاخص FDSD

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
آبادان	۱	۰/۷۵۸	۰/۴۷۶	۰/۴۱۴	۰/۷۱۴	۰/۷۳۱	۰/۴۹۷	۰/۴۲۳	**۰/۷۰۱**
	۲	۰/۷۵۷	۰/۴۷۷	۰/۴۱۴	۰/۷۱۴	۰/۷۳۱	۰/۴۹۷	۰/۴۲۴	**۰/۷۰۱**
	۳	۰/۷۵۷	۰/۴۷۷	۰/۴۱۵	۰/۷۱۳	۰/۷۲۹	۰/۴۹۸	۰/۴۲۵	**۰/۷۰۰**
	۴	۰/۷۵۶	۰/۴۷۵	۰/۴۱۶	۰/۷۱۳	۰/۷۲۹	۰/۴۹۷	۰/۴۲۶	**۰/۷۰۰**
اهواز	۱	۰/۷۵۵	۰/۴۷۸	۰/۴۱۷	۰/۷۱۲	۰/۷۲۸	۰/۴۹۹	۰/۴۲۷	**۰/۶۹۹**
	۲	۰/۷۵۵	۰/۴۷۸	۰/۴۱۸	۰/۷۱۲	۰/۷۲۷	۰/۵۰۱	۰/۴۲۸	**۰/۶۹۸**
	۳	۰/۷۵۵	۰/۴۷۹	۰/۴۱۸	۰/۷۱۱	۰/۷۲۷	۰/۵۰۲	۰/۴۲۸	**۰/۶۹۷**
	۴	۰/۷۵۴	۰/۴۸۱	۰/۴۱۷	۰/۷۱۰	۰/۷۲۶	۰/۵۰۲	۰/۴۲۹	**۰/۶۹۷**
بستان	۱	۰/۷۵۷	۰/۴۸۱	۰/۴۱۸	۰/۷۱۱	۰/۷۲۵	۰/۵۰۳	۰/۴۳۱	**۰/۶۹۷**
	۲	۰/۷۵۳	۰/۴۸۳	۰/۴۱۸	۰/۷۰۹	۰/۷۲۴	۰/۵۰۴	۰/۴۳۲	**۰/۶۹۷**
	۳	۰/۷۵۲	۰/۴۸۴	۰/۴۱۹	۰/۷۰۸	۰/۷۲۳	۰/۵۰۵	۰/۴۳۳	**۰/۶۹۶**
	۴	۰/۷۵۲	۰/۴۸۵	۰/۴۱۹	۰/۷۰۸	۰/۷۲۱	۰/۵۰۶	۰/۴۳۴	**۰/۶۹۵**
مسجدسلیمان	۱	۰/۷۵۱	۰/۴۸۶	۰/۴۲۱	۰/۷۰۷	۰/۷۲۱	۰/۵۰۷	۰/۴۳۵	**۰/۶۹۴**
	۲	۰/۷۵۰	۰/۴۸۷	۰/۴۲۱	۰/۷۰۶	۰/۷۲۱	۰/۵۰۷	۰/۴۳۶	**۰/۶۹۴**
	۳	۰/۷۵۳	۰/۴۸۷	۰/۴۲۲	۰/۷۰۵	۰/۷۱۹	۰/۵۰۸	۰/۴۳۶	**۰/۶۹۳**
	۴	۰/۷۴۹	۰/۴۸۸	۰/۴۲۳	۰/۷۰۴	۰/۷۱۹	۰/۵۰۸	۰/۴۳۷	**۰/۶۹۳**
بندرماهشهر	۱	۰/۷۴۸	۰/۴۸۹	۰/۴۲۴	۰/۷۰۳	۰/۷۲۰	۰/۵۰۹	۰/۴۳۸	**۰/۶۹۲**
	۲	۰/۷۴۷	۰/۴۸۹	۰/۴۲۵	۰/۷۰۳	۰/۷۱۸	۰/۵۰۹	۰/۴۳۹	**۰/۶۹۱**

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

صفی‌آباد	۳	۰/۷۵۱	۰/۴۹۱	۰/۴۲۶	۰/۷۰۲	۰/۷۱۸	۰/۵۱۱	۰/۴۴۱	۰/۶۹۱
	۴	۰/۷۴۶	۰/۴۹۱	۰/۴۲۷	۰/۷۰۲	۰/۷۱۷	۰/۵۱۲	۰/۴۴۲	۰/۶۹۰
	۱	۰/۷۴۶	۰/۴۹۲	۰/۴۲۸	۰/۷۰۲	۰/۷۱۶	۰/۵۱۳	۰/۴۴۳	۰/۶۸۹
	۲	۰/۷۴۵	۰/۴۹۳	۰/۴۲۸	۰/۷۰۴	۰/۷۱۵	۰/۵۱۴	۰/۴۴۴	۰/۶۸۹
	۳	۰/۷۴۶	۰/۴۹۴	۰/۴۲۸	۰/۷۰۴	۰/۷۱۴	۰/۵۱۵	۰/۴۴۵	۰/۶۸۸
	۴	۰/۷۵۱	۰/۴۹۴	۰/۴۲۹	۰/۷۰۱	۰/۷۱۳	۰/۵۱۶	۰/۴۴۶	۰/۶۸۷
دزفول	۱	۰/۷۴۵	۰/۴۹۵	۰/۴۳۱	۰/۷۰۳	۰/۷۱۳	۰/۵۱۶	۰/۴۴۷	۰/۶۸۷
	۲	۰/۷۴۴	۰/۴۹۶	۰/۴۳۲	۰/۷۰۰	۰/۷۱۲	۰/۵۱۴	۰/۴۴۸	۰/۶۸۶
	۳	۰/۷۴۳	۰/۴۹۷	۰/۴۳۳	۰/۷۰۱	۰/۷۱۲	۰/۵۱۷	۰/۴۴۹	۰/۶۸۵
	۴	۰/۷۴۲	۰/۴۹۷	۰/۴۳۴	۰/۷۰۰	۰/۷۱۱	۰/۵۱۵	۰/۴۵۱	۰/۶۸۴

۴-۷- نتایج مدل‌سازی با فرامدل هیبریدی GRNN-AF-ARMA

بر اساس نتایج جدول ۷، ترکیب سه‌گانه مدل شبکه عصبی رگرسیون تعمیم‌یافته (GRNN)، مدل خودهمبسته میانگین متحرک (ARMA) و الگوریتم بهینه‌سازی AF، نسبت به مدل‌های انفرادی و هیبریدی دوتایی پیشین (نظیر GRNN-AF، ARMA-AF و GRNN-ARMA)، دقت پیش‌بینی شاخص FDSD را به‌طور معناداری افزایش داده و خطاهای نسبی را کاهش داده است. در این بین، ترکیب فصلی شماره ۱ بهترین عملکرد را در کلیه ایستگاه‌ها نشان داده است؛ به‌طوری که استفاده از یک فصل قبل به عنوان ورودی مدل، نسبت به ترکیبات دیگر، نتایج دقیق‌تری ارائه کرده است. در ایستگاه‌هایی مانند آبادان و اهواز که سری زمانی رفتار منظم‌تری دارد، دقت مدل بالاتر و خطاها کمتر بوده است. در مقابل، ایستگاه‌هایی نظیر صفی آباد و دزفول با نوسانات شدیدتر، هرچند دقت کاهش یافته اما همچنان مدل سه‌گانه عملکرد بهتری نسبت به مدل‌های قبلی داشته است. به عنوان نمونه، در ایستگاه دزفول و برای ترکیب شماره ۱، مقدار RMSE در داده‌های آزمایش ۰/۴۰۴ روز و شاخص NS نیز ۰/۸۵۱ روز به دست آمده که نسبت به مدل‌های قبلی بهبود محسوسی را نشان می‌دهد. این نتایج بیانگر آن است که ترکیب همزمان مدل‌های خطی و غیرخطی به همراه بهینه‌سازی پارامترها، موجب سازگاری بهتر مدل با ماهیت پیچیده و نوسانی داده‌های طوفان گرد و غبار استان خوزستان شده و فرامدل GRNN-AF-ARMA را به دقیق‌ترین مدل تا این مرحله تبدیل کرده است.

جدول ۷- نتایج آماری داده‌های ورودی مدل GRNN-AF-ARMA به‌منظور پیش‌بینی شاخص FDSD

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
آبادان	۱	۰/۸۸۱	۰/۳۵۴	۰/۲۹۱	۰/۸۸۱	۰/۸۶۹	۰/۳۸۶	۰/۳۰۳	۰/۸۶۱
	۲	۰/۸۸۲	۰/۳۵۴	۰/۲۹۱	۰/۸۸۲	۰/۸۶۹	۰/۳۸۶	۰/۳۰۴	۰/۸۶۱
	۳	۰/۸۸۱	۰/۳۵۵	۰/۲۹۲	۰/۸۸۱	۰/۸۷۱	۰/۳۸۷	۰/۳۰۴	۰/۸۶۰
	۴	۰/۸۸۰	۰/۳۵۶	۰/۲۹۳	۰/۸۸۰	۰/۸۷۱	۰/۳۸۸	۰/۳۰۵	۰/۸۵۹
اهواز	۱	۰/۸۸۰	۰/۳۵۷	۰/۲۹۴	۰/۸۷۹	۰/۸۷۰	۰/۳۸۹	۰/۳۰۶	۰/۸۵۸
	۲	۰/۸۷۹	۰/۳۵۸	۰/۲۹۵	۰/۸۷۸	۰/۸۶۸	۰/۳۹۱	۰/۳۰۶	۰/۸۵۸

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]
[DOI: 10.61882/jeer.16.2.8]

	۳	۰/۸۷۹	۰/۳۵۹	۰/۲۹۳	۰/۸۷۷	۰/۸۶۷	۰/۳۹۰	۰/۳۰۷	۰/۸۵۷
	۴	۰/۸۷۸	۰/۳۶۰	۰/۲۹۴	۰/۸۷۶	۰/۸۶۵	۰/۳۹۰	۰/۳۰۸	۰/۸۵۷
	۱	۰/۸۷۸	۰/۳۶۱	۰/۲۹۴	۰/۸۷۵	۰/۸۶۵	۰/۳۹۰	۰/۳۰۹	۰/۸۵۶
	۲	۰/۸۷۶	۰/۳۶۲	۰/۲۹۵	۰/۸۷۴	۰/۸۶۴	۰/۳۹۲	۰/۳۱۱	۰/۸۵۵
بستان	۳	۰/۸۷۵	۰/۳۶۳	۰/۲۹۶	۰/۸۷۳	۰/۸۶۳	۰/۳۹۳	۰/۳۰۹	۰/۸۵۴
	۴	۰/۸۷۴	۰/۳۶۴	۰/۲۹۶	۰/۸۷۲	۰/۸۶۲	۰/۳۹۴	۰/۳۰۹	۰/۸۵۳
	۱	۰/۸۷۳	۰/۳۶۵	۰/۲۹۷	۰/۸۷۲	۰/۸۶۱	۰/۳۹۴	۰/۳۱۰	۰/۸۵۳
	۲	۰/۸۷۲	۰/۳۶۵	۰/۲۹۷	۰/۸۷۱	۰/۸۶۱	۰/۳۹۲	۰/۳۱۲	۰/۸۵۲
مسجدسلیمان	۳	۰/۸۷۱	۰/۳۶۶	۰/۲۹۸	۰/۸۷۰	۰/۸۶۰	۰/۳۹۵	۰/۳۱۲	۰/۸۵۱
	۴	۰/۸۷۰	۰/۳۶۷	۰/۲۹۸	۰/۸۷۰	۰/۸۵۹	۰/۳۹۴	۰/۳۱۲	۰/۸۵۰
	۱	۰/۸۷۰	۰/۳۶۸	۰/۲۹۹	۰/۸۶۹	۰/۸۵۸	۰/۳۹۶	۰/۳۱۳	۰/۸۴۹
	۲	۰/۸۶۹	۰/۳۶۹	۰/۲۹۸	۰/۸۶۸	۰/۸۵۷	۰/۳۹۷	۰/۳۱۴	۰/۸۴۸
بندرماهشهر	۳	۰/۸۶۹	۰/۳۶۹	۰/۲۹۸	۰/۸۶۷	۰/۸۵۶	۰/۳۹۷	۰/۳۱۵	۰/۸۴۸
	۴	۰/۸۶۸	۰/۳۷۱	۰/۳۰۱	۰/۸۶۷	۰/۸۵۶	۰/۳۹۸	۰/۳۱۶	۰/۸۴۷
	۱	۰/۸۶۸	۰/۳۷۰	۰/۳۰۲	۰/۸۶۷	۰/۸۵۵	۰/۳۹۹	۰/۳۱۷	۰/۸۴۶
	۲	۰/۸۶۸	۰/۳۷۰	۰/۳۰۳	۰/۸۶۷	۰/۸۵۴	۰/۴۰۱	۰/۳۱۸	۰/۸۴۶
صفی‌آباد	۳	۰/۸۶۷	۰/۳۷۲	۰/۳۰۴	۰/۸۶۵	۰/۸۵۳	۰/۴۰۲	۰/۳۱۹	۰/۸۴۷
	۴	۰/۸۵۷	۰/۳۷۲	۰/۳۰۵	۰/۸۶۴	۰/۸۵۲	۰/۴۰۳	۰/۳۲۱	۰/۸۴۷
	۱	۰/۸۶۶	۰/۳۷۳	۰/۳۰۶	۰/۸۶۳	۰/۸۵۱	۰/۴۰۴	۰/۳۲۲	۰/۸۴۶
	۲	۰/۸۶۹	۰/۳۷۴	۰/۳۰۷	۰/۸۶۲	۰/۸۵۱	۰/۴۰۵	۰/۳۲۳	۰/۸۴۶
دزفول	۳	۰/۸۶۵	۰/۳۷۵	۰/۳۰۸	۰/۸۶۱	۰/۸۵۱	۰/۴۰۶	۰/۳۲۴	۰/۸۴۵
	۴	۰/۸۶۴	۰/۳۷۶	۰/۳۰۹	۰/۸۶۱	۰/۸۵۱	۰/۴۰۷	۰/۳۲۵	۰/۸۴۴

۴-۸- نتایج تدقیق فرامدل هیبریدی GRNN-AF-ARMA با بکارگیری فیلتر کالمن تجمعی

نتایج به‌دست‌آمده از جدول ۸ نشان‌دهنده بهبود چشمگیر دقت پیش‌بینی شاخص FDSD پس از ادغام فیلتر کالمن تجمعی با فرامدل هیبریدی سه‌گانه GRNN-AF-ARMA است. به‌وضوح مشاهده می‌شود که استفاده از فیلتر کالمن در این ساختار ترکیبی، موجب کاهش محسوس مقادیر خطاهای RMSE و MAE و همچنین افزایش شاخص‌های نیکویی برازش نظیرNS و R در هر دو مجموعه داده آموزش و آزمایش شده است. این بهبود در تمامی ایستگاه‌ها به چشم می‌خورد و نشان از توانمندی بالای این رویکرد در سازگاری با تغییرات غیرخطی و نویزهای موجود در داده‌ها دارد. در ایستگاه‌هایی مانند آبادان و اهواز که سری‌های زمانی رفتار منظم‌تر و پایدارتری دارند، این بهبود بسیار چشمگیر بوده و مقادیر NS در مجموعه داده آزمایش به بالاتر از ۰/۹۷ رسیده است که حاکی از تقریب بسیار نزدیک پیش‌بینی‌ها به مقادیر واقعی است. در ایستگاه‌های با نوسانات شدیدتر نیز، اگرچه مقادیر NS و R کمی کاهش می‌یابند، اما همچنان نسبت به مدل‌های پیشین بدون استفاده از فیلتر کالمن، دقت و قابلیت اطمینان پیش‌بینی‌ها به‌صورت معناداری افزایش یافته است.

از منظر علمی، فیلتر کالمن تجمعی به عنوان یک الگوریتم بهینه‌سازی و تصحیح‌گر به‌روزرسانی مکرر بر مبنای داده‌های جدید، موجب کاهش انحرافات پیش‌بینی‌ها و بهبود پیوسته مدل شده است. این امر در فرامدل ترکیبی GRNN-AF-ARMA، که خود متشکل از شبکه عصبی رگرسیون تعمیم‌یافته، الگوریتم بهینه‌سازی AF و مدل سری زمانی ARMA

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

است، کارایی مدل را در مواجهه با پویایی‌های پیچیده و تغییرات ناگهانی اقلیمی افزایش می‌دهد. فلوچارت مراحل مدل‌سازی فرامدل هیبریدی $GRNN\text{-}AF\text{-}ARMA)_{EnKF}$ در شکل ۳ نمایش داده شده است که به‌صورت گام‌به‌گام فرآیند تلفیق مدل‌های پایه و فیلتر کالمن تجمعی را برای دستیابی به دقت پیش‌بینی بهینه، ترسیم می‌کند. بنابراین، می‌توان نتیجه گرفت که ترکیب مدل‌های هیبریدی سه‌گانه با فیلتر کالمن تجمعی، رویکردی بسیار مناسب و اثربخش برای پیش‌بینی دقیق‌تر شاخص فراوانی روزهای همراه با طوفان گرد و غبار (FDSD) در استان خوزستان است که قابلیت تعمیم به سایر مناطق با شرایط مشابه مانند استان‌های غربی کشور ایران نظیر استان ایلام که طوفان‌های گردوغبار منشاء خارجی دارند را نیز داراست.

جدول ۸- نتایج آماری داده‌های ورودی مدل هیبریدی EnKF(GRNN-AF-ARMA) به‌منظور پیش‌بینی شاخص FDSD

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
آبادان	۱	۰/۹۹۸	۰/۱۹۴	۰/۱۶۲	۰/۹۹۱	۰/۹۸۴	۰/۲۲۱	۰/۱۷۹	**۰/۹۷۳**
	۲	۰/۹۹۷	۰/۱۹۵	۰/۱۶۳	۰/۹۹۱	۰/۹۸۳	۰/۲۲۳	۰/۱۸۱	**۰/۹۷۱**
	۳	۰/۹۹۷	۰/۱۹۵	۰/۱۶۴	۰/۹۹۲	۰/۹۸۳	۰/۲۲۲	۰/۱۸۲	**۰/۹۷۱**
	۴	۰/۹۹۷	۰/۱۹۶	۰/۱۶۵	۰/۹۹۱	۰/۹۸۲	۰/۲۲۱	۰/۱۸۲	**۰/۹۷۰**
اهواز	۱	۰/۹۹۶	۰/۱۹۷	۰/۱۶۶	۰/۹۸۹	۰/۹۸۲	۰/۲۲۰	۰/۱۸۳	**۰/۹۶۹**
	۲	۰/۹۹۵	۰/۱۹۸	۰/۱۶۷	۰/۹۸۷	۰/۹۸۱	۰/۲۱۹	۰/۱۸۴	**۰/۹۶۸**
	۳	۰/۹۹۶	۰/۱۹۹	۰/۱۶۸	۰/۹۸۷	۰/۹۸۱	۰/۲۱۹	۰/۱۸۵	**۰/۹۶۷**
	۴	۰/۹۹۶	۰/۲۰۱	۰/۱۶۹	۰/۹۸۶	۰/۹۸۱	۰/۲۲۰	۰/۱۸۶	**۰/۹۶۶**
بستان	۱	۰/۹۹۵	۰/۲۰۲	۰/۱۶۹	۰/۹۸۵	۰/۹۷۹	۰/۲۲۰	۰/۱۸۶	**۰/۹۶۵**
	۲	۰/۹۹۴	۰/۲۰۳	۰/۱۶۹	۰/۹۸۴	۰/۹۷۹	۰/۲۱۹	۰/۱۸۵	**۰/۹۶۴**
	۳	۰/۹۹۴	۰/۲۰۳	۰/۱۶۷	۰/۹۸۳	۰/۹۷۸	۰/۲۱۸	۰/۱۸۵	**۰/۹۶۳**
	۴	۰/۹۹۳	۰/۲۰۳	۰/۱۶۷	۰/۹۸۲	۰/۹۷۷	۰/۲۱۸	۰/۱۸۶	**۰/۹۶۲**
مسجدسلیمان	۱	۰/۹۹۲	۰/۲۰۴	۰/۱۶۹	۰/۹۸۲	۰/۹۷۶	۰/۲۱۷	۰/۱۸۶	**۰/۹۶۱**
	۲	۰/۹۹۱	۰/۲۰۵	۰/۱۷۱	۰/۹۸۱	۰/۹۷۵	۰/۲۱۷	۰/۱۸۷	**۰/۹۶۱**
	۳	۰/۹۹۱	۰/۲۰۶	۰/۱۷۲	۰/۹۸۱	۰/۹۷۴	۰/۲۱۶	۰/۱۸۷	**۰/۹۶۱**
	۴	۰/۹۸۹	۰/۲۰۷	۰/۱۷۳	۰/۹۸۰	۰/۹۷۳	۰/۲۱۵	۰/۱۸۸	**۰/۹۵۹**
بندرماهشهر	۱	۰/۹۸۹	۰/۲۰۸	۰/۱۷۴	۰/۹۷۹	۰/۹۷۳	۰/۲۱۴	۰/۱۸۹	**۰/۹۶۰**
	۲	۰/۹۸۸	۰/۲۰۸	۰/۱۷۵	۰/۹۷۹	۰/۹۷۲	۰/۲۱۳	۰/۱۸۹	**۰/۹۶۰**
	۳	۰/۹۸۷	۰/۲۰۹	۰/۱۷۶	۰/۹۷۸	۰/۹۷۲	۰/۲۱۲	۰/۱۹۱	**۰/۹۵۸**
	۴	۰/۹۸۶	۰/۲۱۰	۰/۱۷۶	۰/۹۷۸	۰/۹۷۱	۰/۲۱۲	۰/۱۹۲	**۰/۹۵۹**
صفی‌آباد	۱	۰/۹۸۶	۰/۲۰۸	۰/۱۷۶	۰/۹۷۷	۰/۹۷۱	۰/۲۱۱	۰/۱۹۳	**۰/۹۵۸**
	۲	۰/۹۸۵	۰/۲۰۸	۰/۱۷۷	۰/۹۷۶	۰/۹۶۹	۰/۲۱۱	۰/۱۹۴	**۰/۹۵۷**
	۳	۰/۹۸۵	۰/۲۰۸	۰/۱۷۸	۰/۹۷۵	۰/۹۷۰	۰/۲۱۰	۰/۱۹۵	**۰/۹۵۷**
	۴	۰/۹۸۴	۰/۲۰۹	۰/۱۷۹	۰/۹۷۴	۰/۹۶۸	۰/۲۱۰	۰/۱۹۶	**۰/۹۵۶**
دزفول	۱	۰/۹۸۳	۰/۲۰۹	۰/۱۸۰	۰/۹۷۳	۰/۹۶۸	۰/۲۰۹	۰/۱۹۷	**۰/۹۵۵**
	۲	۰/۹۸۲	۰/۲۰۷	۰/۱۸۱	۰/۹۷۳	۰/۹۶۶	۰/۲۰۹	۰/۱۹۷	**۰/۹۵۴**

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

۳	۰/۹۸۲	۰/۲۰۶	۰/۱۸۲	۰/۹۷۲	۰/۹۶۵	۰/۲۰۸	۰/۱۹۷	**۰/۹۵۳**
۴	۰/۹۸۱	۰/۲۰۹	۰/۱۸۳	۰/۹۷۲	۰/۹۶۴	۰/۲۰۷	۰/۱۹۷	**۰/۹۵۲**

۵- بحث

در این پژوهش، از معیارهای نیکوئی برازش R، RMSE، NS و MAE به‌منظور بررسی عملکرد مدل‌های انفرادی و فرامدل‌های هیبریدی تشریح‌شده در بخش‌های قبلی، جهت پیش‌بینی شاخص FDSD در استان خوزستان طی بازه زمانی ۵۰ ساله (۲۰۲۰-۱۹۷۱) استفاده شده است. علاوه بر این، از فیلتر کالمن تجمعی (EnKF) به‌منظور بهبود و تدقیق خروجی‌های مدل منتخب از میان ۶ مدل بررسی‌شده برای پیش‌بینی شاخص مذکور در فصل‌های آتی بهره گرفته شد.

نتایج پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار، نشان‌دهنده عملکرد برتر و پایداری بالای فرامدل هیبریدی سه‌گانه EnKF(GRNN–AF–ARMA) در هفت ایستگاه بررسی‌شده در استان خوزستان بود. به‌عنوان مثال، پس از اعمال فیلتر EnKF بر مدل هیبریدی سه‌گانه GRNN-AF-ARMA، مقادیر R، RMSE، NS و MAE در ایستگاه مسجدسلیمان به ترتیب از ۰/۸۵۳، ۰/۳۹۴، ۰/۸۶۱ و ۰/۳۱۰ روز به ۰/۹۶۱، ۰/۲۱۷، ۰/۹۷۶ و ۰/۱۸۶ تغییر یافته است که بیانگر کاهش چشمگیر خطا و افزایش همبستگی پیش‌بینی‌ها با مقادیر واقعی است. بنابراین می‌توان نتیجه گرفت که استفاده از فیلتر کالمن تجمعی موجب بهینه‌سازی حالت مدل و ارتقاء دقت پیش‌بینی‌ها شده است. علاوه بر بهبود دقت پیش‌بینی شاخص FDSD، استفاده از فیلتر کالمن تجمعی موجب افزایش پایداری مدل در مواجهه با داده‌های اقلیمی غیرخطی و نویزی شده است. این ویژگی اهمیت ویژه‌ای دارد زیرا داده‌های اقلیمی، به‌ویژه شاخص‌های مرتبط با طوفان‌های گرد و غبار، به دلیل ماهیت پیچیده و نوسانات ذاتی، نیازمند روش‌هایی هستند که بتوانند از نوسانات غیرمنتظره جلوگیری و پایداری پیش‌بینی‌ها را تضمین کنند. از نظر کاربردی، دقت بالای پیش‌بینی این شاخص می‌تواند در برنامه‌ریزی‌های مدیریتی و سیاست‌گذاری‌های زیست‌محیطی نقش بسزایی ایفاء کند، به‌ویژه در مناطقی که به دلیل تغییرات اقلیمی با بحران‌های گرد و غبار مواجه‌اند. نتایج این پژوهش می‌تواند به توسعه استراتژی‌های مؤثرتر در کنترل و کاهش پیامدهای منفی این پدیده‌ها کمک کند. همچنین، ترکیب مدل‌های آماری سنتی مانند ARMA با شبکه‌های عصبی تعمیم‌یافته (GRNN) و الگوریتم‌های تکاملی مانند AF، به‌خصوص در همراهی با فیلترهای تطبیقی مانند EnKF، نشان داد که می‌توان از مزایای هر دو روش خطی و غیرخطی به‌طور همزمان بهره برد. این رویکرد هیبریدی، نه تنها باعث افزایش دقت پیش‌بینی شده بلکه قابلیت تعمیم‌پذیری مدل را در شرایط مختلف اقلیمی ارتقاء می‌دهد، که این امر مزیت چشم‌گیری نسبت به استفاده از مدل‌های منفرد یا غیرتطبیقی فراهم می‌آورد.

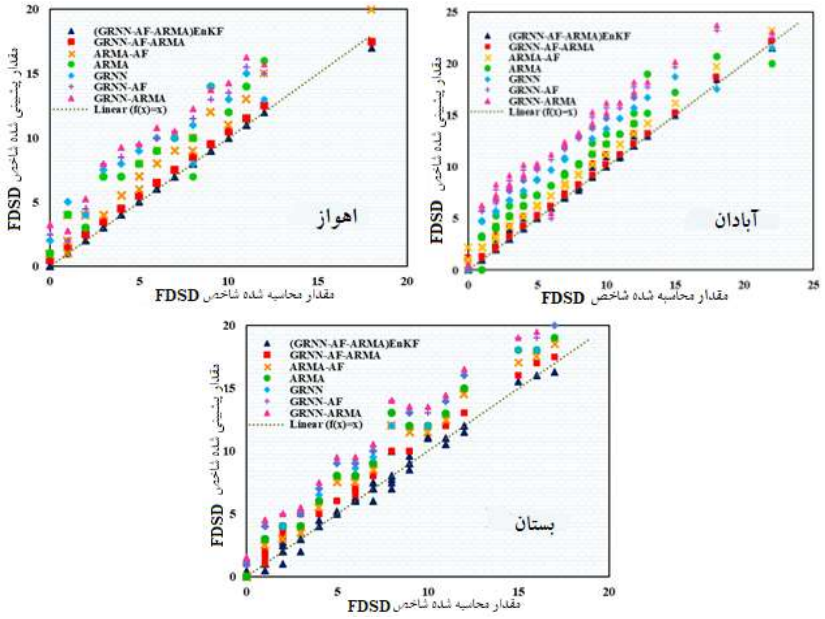
بنابراین، نتایج این مطالعه با پژوهش‌های Pang و همکاران (۲۰۲۴) و Kazemzadeh Varzaneh و همکاران (۲۰۲۴) همخوانی دارد که نشان می‌دهد استفاده از فیلتر کالمن تجمعی باعث بهبود دقت پیش‌بینی و بهینه‌سازی حالت مدل شده است. این مطالعات نقش مؤثر EnKF را در تصحیح شرایط اولیه و افزایش عملکرد مدل‌های پیش‌بینی گرد و غبار تأیید کرده‌اند. رتبه‌های دوم تا ششم در این پژوهش به‌ترتیب به فرامدل هیبریدی سه‌گانه (GRNN-AF-ARMA)، مدل‌های

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

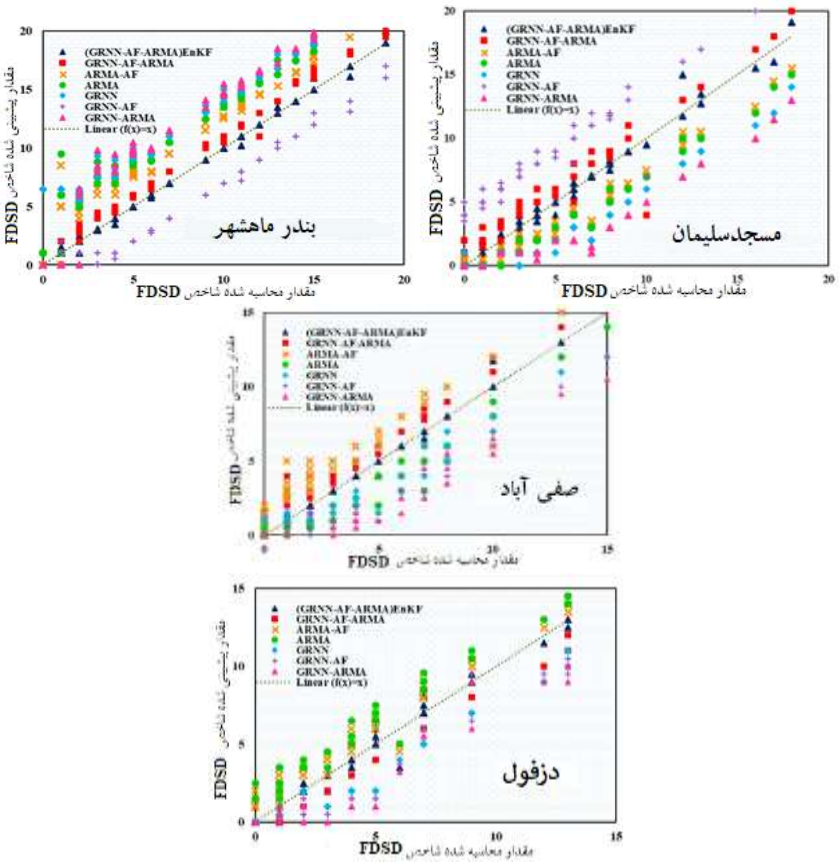
ARMA-AF، ARMA، GRNN، GRNN-AF اختصاص یافت و پایین‌ترین دقت نیز مربوط به مدل هیبریدی GRNN-ARMA بود.

به‌طور کلی، مدل‌های کلاسیک باکس-جنکینز (ARMA) و مدل هیبریدی ARMA-AF عملکرد بهتری نسبت به مدل شبکه عصبی GRNN و ترکیب GRNN-AF داشته‌اند. با این حال، تلفیق مدل‌های باکس-جنکینز با شبکه عصبی در این پژوهش (GRNN-ARMA) کم‌ترین دقت و ضریب همبستگی و بیش‌ترین خطای نسبی را داشته است که نشان می‌دهد ترکیب دو مدل به‌تنهایی تضمین‌کننده بهبود عملکرد نیست و ماهیت و سازگاری الگوریتم‌ها نقش تعیین‌کننده دارد. مقایسه با مطالعات پیشین نشان داد که نتایج این پژوهش با یافته‌های Ansari Ghojghar و همکاران (۲۰۲۰) و Qing-Dao-Er-Ji Ren و همکاران (۲۰۲۲) مطابقت دارد؛ این پژوهش‌ها نیز بر اهمیت استفاده از مدل‌های بهینه‌سازی‌شده و ترکیبی در بهبود پیش‌بینی رخدادهای گرد و غبار تأکید داشته‌اند. با این حال، برخلاف نتایج مطالعه Liu و همکاران (۲۰۲۵) که ترکیب دو مدل هوش مصنوعی را عامل افزایش دقت معرفی کرده بود، در پژوهش حاضر این امر تنها در صورتی محقق شد که از فیلترهای تطبیقی مانند EnKF برای تصحیح خطا و افزایش پایداری پیش‌بینی‌ها استفاده شده باشد. همچنین، مقایسه میانگین مقادیر مشاهده‌شده و پیش‌بینی‌شده شاخص فراوانی روزهای همراه با طوفان گرد و غبار با استفاده از آزمون t نشان داد که تفاوت معناداری بین میانگین‌های سری‌های زمانی مشاهداتی و پیش‌بینی‌شده وجود ندارد (جدول ۹)، که این موضوع بیانگر اعتبار و معناداری کلیه مدل‌های بررسی‌شده است.



[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]



شکل۴: مقایسه مقادیر مشاهده شده و پیشبینی شده شاخص FDSD با استفاده از مدل‌های GRNN, ARMA, GRNN-AF, ARMA-AF, GRNN-ARMA و مدل ترکیبی ۳گانه GRNN-AF-ARMA

جدول۹: آزمون مقایسه میانگین سری‌های زمانی FDSD مشاهده‌شده و پیش‌بینی‌شده

ایستگاه	مشاهده شده	Mean							t-statistic						
		(G-AF-A) EnKF	G-AF-A	A-AF	ARMA	GRNN	G-AF	G-A	(G-AF-A) EnKF	G-AF-A	A-AF	ARMA	GRNN	G-AF	G-A
آبادان	923/0	۰/۹۱۳	۰/۹۰۱	۰/۸۸۳	۰/۸۸۱	۰/۸۷۹	۰/۸۷۳	۰/۸۷۲	۲/۳۳۳	۲/۳۲۱	۲/۲۲٤	۲/۲۲۱	۲/۱۵٦	۲/۰۹۹	۱/۹۲۳
اهواز	۰/۹۱۳	۰/۹۰۱	۰/۸۹۸	۰/۸۸۱	۰/۸۷۹	۰/۸۷۷	۰/۸۷۲	۰/۸۷۱	۲/۳۳۱	۲/۲۲۸	۲/۲۱۸	۲/۱۹٤	۲/۱۳۲	۲/۰۷۸	۱/۹۱٤
بوستان	۰/۹۰۷	۰/۸۹۹	۰/۸۹۱	۰/۸۷۹	۰/۸۷٦	۰/۸۷٤	۰/۸۷۱	۰/۸٦۸	۲/۲۲۸	۲/۲۲۱	۲/۲۱٤	۲/۱۹۱	۲/۱۲۷	۲/۰۷۱	۱/۹۰۳
مسجد سلیمان	۰/۹۰۲	۰/۸۹۲	۰/۸۸۸	۰/۸۷۵	۰/۸۷۳	۰/۸۷۱	۰/۸۷۰	۰/۸٦۷	۲/۲۲۱	۲/۲۱۹	۲/۲۰٦	۲/۱۸٤	۲/۱۱۷	۲/۰۰۱	۱/۸۵٦
اهواز	۰/۸۹۷	۰/۸۸۱	۰/۸۸۰	۰/۸۷۳	۰/۸۷۲	۰/۸٦۹	۰/۸٦۸	۰/۸٦۳	۲/۲۱۹	۲/۲۱٤	۲/۲۰٤	۲/۱۸۳	۲/۱۰٦	۱/۹۹۸	۱/۸۳۲
صفی آباد	۰/۸۸۵	۰/۸۷۷	۰/۸۷۳	۰/۸۷۱	۰/۸٦۸	۰/۸٦۵	۰/۸٦۳	۰/۸٦۱	۲/۲۰۳	۲/۲۰۲	۲/۲۰۰	۲/۱٤۱	۲/۱۰۲	۱/۹۹٦	۱/۷۰٦
دزفول	۰/۸۸۴	۰/۸۷۱	۰/۸٦۹	۰/۸٦۸	۰/۸٦٤	۰/۸٦۲	۰/۸٦۱	۰/۸۵۹	۲/۲۰۱	۲/۲۰۰	۲/۱۹۱	۲/۱۳۵	۲/۰۵۹	۱/۹۷۳	۱/٦۹٦

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]
[DOI: 10.61882/jeer.16.2.8]

۵- نتیجه‌گیری

در پژوهش حاضر، نتایج حاصل از مقایسه مدل هیبریدی سه‌گانه (GRNN-AF-ARMA) با مدل‌های انفرادی GRNN و ARMA و همچنین فرامدل‌های هیبریدی GRNN-AF، ARMA-AF و GRNN-ARMA با توجه به نتایج حاصل از تحلیل شاخص‌های ارزیابی R، RMSE، NS و MAE نشان داد که فرامدل هیبریدی GRNN-AF-ARMA به‌عنوان مدل منتخب در میان سایر مدل‌های مورد بررسی، به‌منظور پیش‌بینی طوفان‌های گرد و غبار در استان خوزستان انتخاب شد. جهت بهبود عملکرد و افزایش دقت مدل‌سازی، از راهکار فیلتر کالمن تجمعی که از جمله روش‌های داده‌گواری است، استفاده شد. این فیلتر، با بروزرسانی داده‌های حاصل از فرامدل یادشده، عملکرد آن را در هر گام زمانی بهبود داده است. بدین ترتیب فرامدل هیبریدی $_{EnKF}$(GRNN-AF-ARMA) بهترین عملکرد را به نسبت سایر مدل‌های ذکرشده به‌منظور مدل‌سازی طوفان‌های گرد و غبار در استان خوزستان نمایش داده است. ایستگاه آبادان با بیش‌ترین میانگین روزهای همراه با طوفان گرد و غبار در مقیاس فصلی، بیش‌ترین دقت را در پیش‌بینی شاخص مذکور نمایش داده‌است. بدین ترتیب درمی‌یابیم که دقت مدل‌سازی نهایی طوفان‌های گرد و غبار، با کمیت داده‌های ورودی به‌منظور پیش‌بینی پدیده مذکور، رابطه مستقیمی دارد. تمامی مدل‌های بررسی‌شده در مطالعه حاضر، بالاترین عملکرد خود را در ترکیب‌های یک و دو ارائه دادند. لذا می‌توان نتیجه گرفت که استفاده از مدل‌های ساده، که از یک یا دو فصل گذشته جهت پیش‌بینی فصل‌های آینده استفاده می‌کنند، در پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار در استان خوزستان، نسبت به مدل‌های پیچیده، با افزایش غنای مدل‌سازی، عملکرد بهتری را به‌نمایش می‌گذارد. با توجه به موارد ذکر شده و ماهیت غیرخطی و پیچیده طوفان‌های گرد و غبار و همچنین خسارات اجتماعی، اقتصادی، زیرساختی، مشکلات سلامتی و ... ناشی از این مخاطره، اتخاذ رویکردهای جامع جهت کاهش خسارات مذکور، امری ضروری است. یکی از راهکارهای مؤثر در این زمینه، اجرای طرح‌های مدیریت یکپارچه منابع آب به‌منظور بهره‌برداری پایدار و بهینه از منابع آبی، به‌ویژه در مناطق خشک و نیمه‌خشک، می‌باشد. این امر نه‌تنها به حفظ و تقویت منابع آب زیرزمینی کمک می‌کند، بلکه موجب کاهش فرسایش خاک و تثبیت آن در برابر وزش بادهای شدید می‌شود. با عنایت به مشکلات تنفسی، پوستی و ... ناشی از این طوفان‌ها در مناطق بحرانی و مستعد فرسایش بادی، کاشت گیاهان مقاوم با اقلیم منطقه به‌منظور کاهش سرعت باد و جلوگیری از پراکندگی ذرات گرد و غبار، می‌تواند به‌عنوان یک راهکار زیست‌محیطی مؤثر برای کاهش اثرات منفی طوفان‌های گرد و غبار مطرح شود. همچنین، یافته‌های این مطالعه تأکید می‌کند که بهره‌گیری از فیلتر کالمن تجمعی(EnKF) در بهبود پایداری و دقت پیش‌بینی مدل‌های هیبریدی، نقش مهمی ایفاء می‌کند و می‌تواند به‌عنوان راهکاری پیشرفته در مدل‌سازی پدیده‌های اقلیمی پیچیده، مانند طوفان‌های گرد و غبار، مورد استفاده قرار گیرد. علاوه بر این، نتایج نشان می‌دهد که مدل‌های ساده‌تر با ورودی‌های کم‌عمق‌تر زمانی در برخی شرایط می‌توانند عملکرد بهتری نسبت به مدل‌های پیچیده‌تر داشته باشند، که این موضوع اهمیت انتخاب مدل مناسب را برای شرایط اقلیمی و داده‌های موجود برجسته می‌سازد. پیشنهاد می‌گردد در پژوهش‌های آتی، ترکیب مدل هیبریدی سه‌گانه همراه با فیلتر کالمن تجمعی پیشنهادی با مدل‌های یادگیری عمیق و ترکیب آن‌ها مقایسه شده تا دقت مطالعاتی بالایی به‌منظور پیش‌بینی طوفان‌های گردوغبار و بهبود سامانه‌های پایش و پیش‌بینی این پدیده مخرب به ثبت رسد.

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

منابع:

1. 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.
2. Ansari ghojghar, M., Pourgholam-Amiji, M., Bazrafshan, J., Liaghat, A. & Araghinejad, S. (2020a). 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. doi: 10.22059/ijswr.2020.302529.668607 (In Persian)
3. Ansari Ghojghar, M., Bazrafshan, J., Araghinejad, S., Parsi, E. & Soltani, S. (2020b). 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. doi: 10.22059/jhsci.2021.314582.614 (In Persian)
4. Baddock, M. C., Strong, C. L., Leys, J. F., Heidenreich, S. K., Tews, E. K., & McTainsh, G. H. (2014). A visibility and total suspended dust relationship. Atmospheric Environment, *89*, 329–336.
5. Boye, C. B., Boye, P., & Ziggah, Y. Y. (2024). Comparative study of suspended sediment load prediction models based on artificial intelligence methods. In Artificial Intelligence and Applications (Vol. 2, No. 2, pp. 155–168).
6. Dehghani, R., Torabi poudeh, H., Younesi, H. & SHahinejad, B. (2020). Aplication of the Hybrid Model of Support Vector Machine-Algorithm Artificial Flora in Estimating the Daily Flow of Rivers (Case study: Dez basin). Iran-Water Resources Research, *16*(2), 132-149. (In Persian)
7. Feuerstein, S., & Schepanski, K. (2018). Identification of dust sources in a Saharan dust hot-spot and their implementation in a dust-emission model. *Remote Sensing*, *11*(1), 4.
8. Goudie, A. S., & Middleton, N. J. (2006). Desert dust in the global system. Springer Science & Business Media.
9. Griffin, D. W., & Kellogg, C. A. (2004). Dust storms and their impact on ocean and human health: Dust in Earth's atmosphere. *EcoHealth*, *1*(3), 284–295.
10. Hoseinali Zadeh, S., & Safabakhsh, R. (2008). Financial time series forecasting using ARMA-GARCH-GRNN model. Annual National Conference of the Iranian Computer Society. SID. https://sid.ir/paper/811150/fa (In Persian)
11. Kazemzadeh Varzaneh, A., Fazeli, M. & Montaseri, H. (2024). Estimation Missing Stream Flow Data of Hydrometric Gauge Using Support Vector Regression and Ensemble Kalman Filter (EnKF) Technique (Case Study: Upstream Zayandehrud Basin). *Iran-Water Resources Research*, 20(1), 181-196. doi: 10.22034/iwrr.2024.382843.2735 (In Persian)
12. Liu, S., Liu, K., Wang, Z., Liu, Y., Bai, B., & Zhao, R. (2025). Investigation of a transformer-based hybrid artificial neural networks for climate data prediction and analysis. Frontiers in Environmental Science, 12, 1464241.
13. Mohammadi, G. H. (2015). Analysis of atmospheric mechanisms in dust transport over west of Iran (Doctoral dissertation, Ph. D, Tabriz University, p. 142, In Persian).
14. Nazari, S., Kermani, M., Fazlzadeh, M., Matboo, S. A., & Yari, A. R. (2016). The origins and sources of dust particles, their effects on environment and health, and control strategies: A review. Journal of Air Pollution and Health, *1*(2), 137–152.
15. 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.

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]

16. Pang, M., Jin, J., Segers, A., Jiang, H., Han, W., Buyantogtokh, B., ... & Liao, H. (2024). Valid time shifting ensemble Kalman filter (VTS-EnKF) for dust storm forecasting. Geoscientific Model Development, *17*(22), 8223–8242.
17. Qing-Dao-Er-Ji Ren, N., & Li, W. Z. (2022). Research on Sand-Dust Storm Forecasting Based on Deep Neural Network with Stacking Ensemble Learning. IEEE Access, 10, 111855-111863.
18. Rahmati, O., Panahi, M., Ghiasi, S. S., Deo, R. C., Tiefenbacher, J. P., Pradhan, B., ... & Bui, D. T. (2020). Hybridized neural fuzzy ensembles for dust source modeling and prediction. Atmospheric Environment, 224, 117320.
19. Schepanski, K., Flamant, C., Chaboureau, J. P., Kocha, C., Banks, J. R., Brindley, H. E., ... & Tulet, P. (2013). Characterization of dust emission from alluvial sources using aircraft observations and high-resolution modeling. Journal of Geophysical Research: Atmospheres, *118*(13), 7237–7259.
20. Specht, D. F. (1991). A general regression neural network. IEEE Transactions on Neural Networks, *2*(6), 568–576.
21. Wiegand RP, & Sarma, J. (2004). Spatial Embedding and loss of gradient in cooperative coevolutionary algorithms. In Proceedings of the International Conference on Parallel Problem Solving from Nature, Berlin Germany. 43, 912–921.
22. Yarmohamadi, M., Alesheikh, A. A., & Sharif, M. (2025). Using Hybrid Deep Learning Models to Predict Dust Storm Pathways with Enhanced Accuracy. Climate, 13(1), 16.
23. Zeinali, B. (2016). Investigation of frequency changes trend of days with dust storms in western half of Iran. Journal of Natural Environmental Hazards, *5*(7), 87–100.

[Downloaded from magazine.hormozgan.ac.ir on 2026-11-20]

[DOI: 10.61882/jeer.16.2.8]