

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 Rad² 

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 FDSI 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 Khuzestan 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 FDSI 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

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 ghoghghar, 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>

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

تاریخ پذیرش: ۱۴۰۵/۰۴/۲۰

تاریخچه مقاله (تاریخ دریافت: ۱۴۰۵/۰۲/۰۱)

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 شبیه‌سازی 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 ARMA-AF، GRNN-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 ساتکیف شده است. به طوری که مقادیر بیشتر از ۰/۹۶۴ برای ضریب نش ساتکیف 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.

۱- مقدمه

طوفان های گرد و غبار پدیده های طبیعی جوی هستند که غالباً در مناطق خشک رخ داده و باعث کاهش کیفیت هوا و دید می شوند (Nazari et al., 2016). این طوفان ها چالش هایی ایجاد می کنند که مانع دستیابی به اهداف توسعه پایدار تعریف شده در دستور کار ۲۰۳۰ سازمان ملل می شوند. از میان ۱۷ هدف، سلامت و رفاه، آب پاک و بهداشت، انرژی پاک و مقرون به صرفه، 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 طوفان های گرد و غبار قرار می گیرند. پیش بینی دقیق منابع گرد و غبار حتی با وجود مدل های پیشرفته جوی، شناسایی منابع و پیش بینی 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، روش های مختلفی مانند سنجش از دور، تحلیل دید افقی، بررسی کانی شناسی گرد و غبار و تحلیل مسیر حرکت ذرات مورد استفاده قرار می گیرد (Baddock et al., 2014). اما این روش ها محدودیت هایی دارند و شناسایی منابع گرد و غبار در مناطق وسیع مانند بیابان ها همچنان دشوار است (Schepanski et al., 2013).

در سال های اخیر، به منظور غلبه بر محدودیت های روش های سنتی، پژوهشگران از رویکردهای نوین مدل سازی آماری و هوش مصنوعی برای بهبود دقت پیش بینی طوفان های گرد و غبار استفاده کرده اند که در ادامه به برخی از مطالعات شاخص در این زمینه اشاره می شود. Alshammari و همکاران (۲۰۲۴) با به کارگیری مدل های LSTM و TCN به پیش بینی فراوانی طوفان های گرد و غبار در شهرهای ریاض، جدّه و دمام پرداختند و نشان دادند که این مدل ها به دلیل توانایی درک روابط زمانی پیچیده، دقت بالاتری نسبت به روش های کلاسیک دارند. نتایج آنها حاکی از کاهش خطای پیش بینی و افزایش ضریب تعیین (R^2) در مناطق مورد مطالعه بود. این پژوهش نقش کلیدی شبکه های عصبی عمیق در پیش بینی دقیق تر طوفان های گرد و غبار را برجسته می کند. یک مطالعه جدید با استفاده از مدل های هیبریدی CNN-LSTM و ConvLSTM به پیش بینی مسیر طوفان های گرد و غبار تا ۲۴ ساعت آینده پرداخت که با به کارگیری داده های متئورولوژیکی و ویژگی های انتخاب شده توسط روش جنگل تصادفی، دقت پیش بینی را افزایش داد. نتایج نشان داد مدل CNN-LSTM با لحاظ کردن اطلاعات زمینه ای عملکرد بهتری نسبت به ConvLSTM دارد. این پژوهش بر اهمیت استفاده از داده های چندبعدی و یادگیری عمیق در بهبود پیش بینی طوفان های گرد و غبار تأکید دارد (Yarmohamadi et al., 2025).

Ansari ghoghbar و همکاران (۲۰۲۰) به مقایسه کارایی شبکه های عصبی آماری، فازی و پرسپترونی در پیش بینی طوفان های گرد و غبار در نواحی بحرانی کشور پرداختند. یافته های آنان نشان دهنده عملکرد بالای مدل ANFIS و پس از آن GRNN به منظور پیش بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار (FDSD) در زابل، آبادان، اهواز، زاهدان، بستان و مسجد سلیمان 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 پیش بینی و تحلیل طوفان های گرد و غبار را به طور قابل توجهی افزایش می دهد. Rahmati و همکاران (۲۰۲۰) نیز به بررسی طوفان های

گرد و غبار با استفاده از ترکیب سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) با ترکیبی از الگوریتم های بهینه سازی فراکاوشی شامل الگوریتم خفاش (BA)، الگوریتم فرهنگی (CA) و تکاملی تفاضلی (DE) پرداخته اند. نتایج مطالعه آنها نشان داد که مدل ترکیبی ANFIS-DE روشی نویدبخش و مقرون به صرفه برای شناسایی کارآمد مناطق منبع گرد و غبار می باشد.

از بررسی مطالعات مختلف در این زمینه میتوان دریافت که به منظور مدل سازی دقیق متغیرهای اقلیمی، به خصوص شاخص FDSD، روش ها و راهکارهای کمی توسعه یافته و به ویژه مدل های هیبریدی چندگانه محدود هستند و راه حل های موجود نیز از دقت کافی و بالایی جهت پیش بینی این شاخص برخوردار نیستند. این امر موجب کاهش دقت مدل های مورد استفاده شده. در نتیجه سامانه های پیش بینی و پایش طوفان های گردوغبار تضعیف شده و توانایی متخصصین در پیش بینی این پدیده کاهش میابد. لذا در این پژوهش، برای رفع محدودیت های روش های استفاده شده قبلی، به ارائه یک فرامدل هیبریدی سه گانه شامل شبکه عصبی تعمیم یافته (GRNN)، الگوریتم گیاهان مصنوعی (AF) و مدل خودرگرسیون میانگین متحرک (ARMA) به عنوان رویکردی نوین و ترکیبی از یادگیری غیرخطی، الگوریتم های فراکاوشی و مدل های سری زمانی ارائه شده است. همچنین، به کارگیری راهکار فیلتر کالمن تجمعی (EnKF) دقت پیش بینی و تحلیل طوفان های گرد و غبار را به طور قابل توجهی افزایش می دهد.

استفاده از GRNN به دلیل توانایی بالا در یادگیری روابط پیچیده و غیرخطی میان متغیرها و شناسایی الگوهای پنهان در داده ها، کمک می کند تا این مدل، به عنوان هسته ای قوی برای ترکیب با روش های دیگر مانند AF و ARMA عمل کند تا دقت پیش بینی شاخص FDSD افزایش یابد. مدل ARMA به دلیل قابلیت مدل سازی ساختارهای زمانی و پیش بینی روندهای خطی سری های داده ای، می تواند رفتار دینامیکی شاخص FDSD را به خوبی ثبت کرده و در ترکیب با GRNN و AF، جنبه های خطی و غیرخطی داده ها را به صورت همزمان در نظر گرفته و دقت پیش بینی را بهبود بخشد. بدین ترتیب، مطالعه حاضر می تواند به منظور ارائه یک الگوی نوین و دقیق تر جهت پیش بینی طوفان های گرد و غبار باشد. در حالی که پژوهش های پیشین غالباً به بررسی مدل های انفرادی یا مدل های تلفیقی حداکثر دو گانه پرداخته اند، در این پژوهش به کاربرد و ارزیابی عملکرد فرامدل هیبریدی سه گانه GRNN-AF-ARMA به صورت جامع تر و با رویکردی نوین پرداخته شده است. علاوه بر این، نتایج تحقیقات Kazemzadeh Varzaneh و همکاران (۲۰۲۴) به ارتقاء عملکرد مدل رگرسیونی با بهره گیری از EnKF اشاره دارد که انگیزه ای قوی برای بررسی تأثیر استفاده از راهکار فیلتر کالمن تجمعی را در این مطالعه فراهم کرده است تا علاوه بر افزایش دقت، قابلیت تعمیم پذیری مدل نیز ارتقاء یابد.

پژوهش حاضر با هدف افزایش توانایی مدل سازی طوفان های گرد و غبار و تلاش برای کاهش اثرات مخرب این پدیده حدی اقلیمی بر محیط زیست و سلامت موجودات زنده، چارچوبی نوین با استفاده از الگوریتم های هوش مصنوعی پیشرفته ارائه داده تا فقدان پژوهش های پیشین در زمینه مدل سازی کمی این پدیده با مدل های هیبریدی چندگانه پر شده و اساس خوبی برای پژوهش های آتی و استفاده در سامانه های پایش و پیش بینی طوفان های گردوغبار قرار گیرد.

۲- منطقه مورد مطالعه

در پژوهش حاضر به بررسی فرامدل هیبریدی سه گانه GRNN-AF-ARMA و مقایسه آن با مدل‌های انفرادی GRNN، ARMA و مدل‌های هیبریدی دو گانه GRNN-AF، ARMA-AF و همچنین بررسی راهکار فیلتر کالمن تجمعی به منظور 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 (۱۹۷۱-۲۰۱۹) پرداخته شده است (شکل ۱). بدین منظور، ۸۰٪ داده‌های موجود برای آموزش مدل و ۲۰٪ داده‌ها به منظور آزمون مدل‌های مورد پژوهش به کار گرفته شدند.



شکل ۱: منطقه مورد مطالعه و ایستگاه‌های منطقه

۳- 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 می‌شود (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). بدین ترتیب، در این مطالعه، از مؤلفه دید افقی کم‌تر از ۱۰۰۰ متر به‌منظور تشخیص طوفان‌های گرد و غبار، برای همه کدها استفاده شده‌است.

جدول ۱. 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 ساعت های 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 بیش تر- کاهش میدان دید به کم تر از ۱۰۰۰ ولی بیش تر از ۲۰۰ متر
۳۱	طوفان خفیف یا متوسط شن یا خاک بدون تغییر شدت طی ساعت گذشته- با سرعت باد ۱۵ متر بر ثانیه یا بیش تر- کاهش میدان دید به کم تر از ۱۰۰۰ ولی بیش تر 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 بیش تر- کاهش میدان دید به کم تر از ۱۰۰۰ ولی بیش تر از ۲۰۰ متر
۳۳	طوفان شدید شن یا خاک همراه با روند کاهشی طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیش تر- کاهش دید کم تر از ۲۰۰ متر
۳۴	طوفان شدید شن یا خاک همراه بدون تغییر شدت طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیش تر- کاهش دید کم تر از ۲۰۰ متر
۳۵	طوفان شدید شن یا خاک همراه با افزایش شدت طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیش تر- کاهش دید کم تر 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 بیان گر موقعیت مکانی آن در محیط است و فاصله پراکنش نشان دهنده فاصله ای است که دانه ها از گیاه اصلی جابه جا می شوند. در این الگوریتم، سه رفتار اصلی براساس روابط زیر مدل سازی می شود (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 دانه های خود را در محیطی دایره وار پراکنده می کند، به طوری که شعاع این دایره برابر با میزان فاصله پراکنش آن است (رابطه ۱). مقدار این فاصله از ترکیب داده های مربوط به فاصله پراکنش گیاه والد و گیاه جد محاسبه می شود (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 (مادر بزرگ)، d_{2j} فاصله پخش گیاه والد (مادر) و c_1 و c_2 ضریب های یادگیری می باشند. همچنین $rand(0,1)$ معادل عددی است که در بازه ذکر شده، توزیعی ثابت و یکنواخت دارد.

(۲) رفتار پخش: در گام نخست، الگوریتم فلور مصنوعی به صورت 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 تعریف شده 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 به عنوان معیاری برای ارزیابی زنده بودن یا نبودن گیاهان فرزند، به صورت رابطه ۳ مورد استفاده قرار می‌گیرد:

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

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 $F(\hat{P}_{i,j \times m})$ برازندگی جواب j ام را نشان می‌دهد.

۳-۳- شبکه عصبی رگرسیون تعمیم یافته (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 به صورت رابطه زیر استفاده می‌کند. این شبکه خروجی‌ای را محاسبه می‌کند که کمترین مقدار خطای میانگین مربعات^۱ (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 سری زمانی، $E(Y|X)$ مقدار خروجی Y که بستگی به بردار مشاهده‌های X دارد و $f(Y|X)$ تابع چگالی احتمالی Y و X 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 رگرسیون گیری باشد با استفاده از رابطه ۵ داریم:

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

^۱ Mean Squared Error

در رابطه بالا، a_i خروجی به ازای بردار x_i ، مرکز نورو و σ پارامتر هموارکننده (پارامتر تعیین کننده شکل تابع های هسته در لایه دوم) می باشد. خروجی شبکه عصبی رگرسیون عمومی (لایه چهارم)، معادل میانگین وزن دار مشاهده های Y_i پیرامون بردار ورودی است (رابطه ۶) که به شکل زیر محاسبه شده و قابل نمایش است:

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

برخلاف روش های آموزشی تکراری مانند الگوریتم پسانتشار، GRNN نیازی به فرآیند آموزش تکراری ندارد و محاسبات در آن به صورت مستقیم و به صورت پیشرو انجام می شود.

۳-۴- مدل خودهمبسته میانگین متحرک (ARMA)

این مدل یک مدل خطی برای سری های زمانی ایستا می باشد که توسط باکس و جنکینز مطرح شده و توسعه یافته اند. در مدل ARMA، پیش بینی ها براساس مشاهدات گذشته و خطاهای پیش بینی های گذشته انجام می شود. $ARMA(P, Q)$ به صورت رابطه ۷ نمایش داده می شود:

$$\phi(B)X_t = \theta(B)Z_t \quad (\text{رابطه ۷})$$

در رابطه بالا، B عملگر برگشت به عقب است که به صورت زیر محاسبه می شود:

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

اگر $\theta(Z) = 1$ باشد، آن گاه سری زمانی X_t یاد شده را فرآیند خودرگرسیون مرتبه p یا $AR(p)$ می نامند. در صورتی که $\phi(Z) = 1$ باشد، سری زمانی فوق فرآیند میانگین متحرک مرتبه q یا به عبارتی $MA(q)$ می باشد (Hoseinali Zadeh & Safabakhsh, 2008). این مدل تنها در صورت ایستایی سری زمانی، دارای کارایی لازم برای مدل سازی می باشد.

۳-۵- الگوریتم فیلتر کالمن تجمعی (EnKF)

فیلتر کالمن تجمعی یک الگوریتم فیلترینگ غیرخطی است که روش های مونت کارلو را با فیلتر کالمن ترکیب می کند. این فیلتر با استفاده از روش های تصادفی، مجموعه ای از پارامترها و متغیرهای حالت را تولید می کند تا وضعیت مدل را پیش بینی کند. این روش شامل دو بخش اصلی است: پیش بینی و به روزرسانی هم گرایی. در مرحله پیش بینی، هر عضو تجمعی براساس دینامیک مدل رو به جلو انتگرال گیری می شود تا حالت سیستم را برای حالت بعدی پیش بینی کند (معادله ۹) (Pang et al., 2024). فرآیند کلیدی فیلتر کالمن تجمعی، ایجاد معادله انتقال حالت (معادله پیش بینی) و معادله مشاهده برای سیستم مدل شده است. معادله عمومی انتقال حالت به صورت زیر تعریف می شود:

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

در این رابطه، x_{i+1} نشان دهنده متغیرهای حالت، f مدل هیدرولوژیکی و θ پارامترهای مدل می باشد. ε_i خطای مدل است که از توزیع نرمال تبعیت می کند.

۳- معیارهای ارزیابی مدل مناسب

در پژوهش حاضر، به منظور ارزیابی دقت و کارایی مدل‌ها، از ضریب همبستگی^۱ (R)، ریشه میانگین مربعات خطا^۲ (RMSE)، میانگین قدر مطلق خطا^۳ (MAE) و ضریب نش-ساتکلیف^۴ (NS) 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 مشاهده شده در زمان i ، f_i مقادیر پیش‌بینی شده در زمان i ، $\bar{f}$ میانگین مقادیر پیش‌بینی شده، $\bar{O}$ میانگین مقادیر مشاهده شده 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 (GRNN-AF-ARMA)EnKF

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 (۱۹۷۱-۲۰۲۰) در جدول زیر نمایش داده شده است. با توجه به نتایج حاصل از تحلیل و بررسی معیارهای نیکوئی برآزش در ایستگاه‌های مورد بررسی، 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 ترکیب‌های فصلی سه

^۱ Correlation Coefficient

^۲ Root Mean Square Error

^۳ Mean Absolute Error

^۴ Nash-Sutcliffe

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 فصل های اخیر محدود می شود و تأخیرهای زمانی طولانی تر نقش کمرنگ تری در پیش بینی این شاخص دارند. همچنین با توجه به نتایج به دست آمده از مدل GRNN، مشاهده می شود که ایستگاه هایی با فراوانی بالای طوفان های گرد و غبار (مانند آبادان و اهواز) عملکرد بهتری از نظر معیارهای آماری داشته اند. در مقابل، در ایستگاه هایی با فراوانی پایین تر (مانند صفی آباد 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 می دهد که مدل GRNN توانسته است به خوبی تعمیم پذیری خود را حفظ کند و تفاوت مقادیر NS و R بین مجموعه داده آموزش و آزمایش کمتر از ۲ درصد بوده است، که نشان دهنده جلوگیری از بروز بیش برآزش^۱ در فرایند آموزش مدل است.

جدول ۲- نتایج آماری داده های ورودی مدل GRNN به منظور پیش بینی 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
مسجد سلیمان	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
بندر ماهشهر	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
صفی آباد	۱	۰/۸۱۵	۰/۴۳۹	۰/۳۸۶	۰/۷۸۵	۰/۷۹۷	۰/۴۵۷	۰/۴۰۰	۰/۷۶۹

^۱ Overfitting

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

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، به عنوان ترکیب منتخب شناسایی شده است. به عنوان مثال، مقدار RMSE در ایستگاه بستان از ۰/۴۳۵ روز در نتیجه پیش‌بینی گرد و غبار فصول آتی با استفاده از ۴ فصل قبل، به ۰/۴۳۲ روز در نتیجه 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. به طوری که در این ایستگاه‌ها مقادیر ضریب R به میزان قابل توجهی بالاتر از ایستگاه‌هایی با فراوانی کمتر نظیر صفی آباد و دزفول ثبت شده است. به عنوان 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 به منظور پیش‌بینی شاخص FDSD

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
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	۰/۳۳۳	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

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

۳-۴- نتایج مدل سازی با مدل GRNN-AF

نتایج مدل سازی با مدل GRNN-AF در جدول ۴ نشان می دهد که افزودن کاتالیزور گیاهان مصنوعی (AF) به مدل GRNN نه تنها باعث بهبود نتایج پیش بینی شاخص FDSD نشده، بلکه در اغلب موارد منجر به افزایش میزان خطا و کاهش دقت مدل شده است. این کاهش عملکرد به ویژه در ایستگاه هایی با فراوانی کمتر روزهای گرد و غبار، نظیر دزفول و صفی آباد، مشهودتر است؛ به گونه ای که در ایستگاه دزفول، مقدار RMSE داده های آزمایش از ۰/۴۶۱ روز در مدل GRNN به ۰/۵۰۴ روز در مدل GRNN-AF افزایش یافته است. بررسی تغییرات آماری نشان می دهد که افزودن متغیرهای مصنوعی (AF) موجب افزایش نویز و کاهش توان مدل در شناسایی الگوهای اصلی داده های واقعی شده است. به عبارت دیگر، ساختار ساده و غیر پارامتریک GRNN در مواجهه با داده های تقویت شده مصنوعی، به دلیل عدم تطابق ویژگی های افزوده شده با رفتار طبیعی سری های زمانی، دچار اختلال عملکرد شده است. این امر به ویژه در ایستگاه های با الگوهای زمانی پیچیده تر و پراکندگی کمتر (نظیر صفی آباد و مسجدسلیمان) منجر به افت دقت مدل شده است. بنابراین، می توان نتیجه گرفت که مدل GRNN به تنهایی عملکرد قابل قبولی در پیش بینی شاخص FDSD داشته و افزودن کاتالیزور مصنوعی AF نه تنها موجب بهبود مدل نشده، بلکه با افزایش خطاها، موجب کاهش کیفیت پیش بینی نیز شده است.

جدول ۴- نتایج آماری داده های ورودی مدل GRNN-AF به منظور پیش بینی شاخص FDSD

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

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

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-AF که 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 AF با 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 شاخص‌های NS و R شده است. برای مثال، در ایستگاه آبادان مقدار RMSE در داده‌های آزمایش به ۰/۴۰۱ روز کاهش

یافته است که نسبت به مدل ARMA ساده، نشان دهنده بهبود قابل توجهی در دقت پیش بینی است. همچنین در ایستگاه دزفول که به دلیل تعداد کمتر روزهای همراه با طوفان گردوغبار رفتار داده ها 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 انعطاف پذیری مدل تلفیقی ARMA-AF در مواجهه با رفتارهای غیرخطی و نوسانات ناگهانی داده ها است، به طوری که الگوریتم AF توانسته است تا حدودی نواقص ذاتی مدل ARMA در تطبیق با داده های پیچیده را جبران کند.

جدول ۵- نتایج آماری داده های ورودی مدل ARMA-AF به منظور پیش بینی شاخص FDSD

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

۴- نتایج مدل‌سازی با فرامدل هیبریدی GRNN-ARMA

بر اساس جدول ۶، نتایج حاصل از به کارگیری فرامدل هیبریدی GRNN-ARMA نشان می‌دهد که تلفیق این دو مدل، برخلاف انتظار، منجر به کاهش دقت پیش‌بینی شاخص FDS 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 قابل توجهی 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 به منظور پیش‌بینی شاخص FDS

ایستگاه	شماره ترکیب	داده آموزش				داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
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
بستگان	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
مسجد سلیمان	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
بندر ماهشهر	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

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

۷-۴- نتایج مدل سازی با فرامدل هیبریدی GRNN-AF-ARMA

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

جدول ۷- نتایج آماری داده های ورودی مدل GRNN-AF-ARMA به منظور پیش بینی شاخص FDSD

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

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
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
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
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
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
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

بستان

مسجد سلیمان

بندر ماهشهر

صفی آباد

دزفول

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

نتایج به دست آمده از جدول ۸ نشان دهنده بهبود چشمگیر دقت پیش‌بینی شاخص FDSD پس از ادغام فیلتر کالمن تجمعی با فرامدل هیبریدی سه گانه GRNN-AF-ARMA است. به وضوح 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 نظیر NS 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 به صورت معناداری افزایش یافته است.

از منظر علمی، فیلتر کالمن تجمعی به عنوان یک الگوریتم بهینه‌سازی و تصحیح گر به روزرسانی 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 تعمیم یافته، الگوریتم بهینه‌سازی AF و مدل سری زمانی ARMA

است، کارایی مدل را در مواجهه با پویایی های پیچیده و تغییرات ناگهانی اقلیمی افزایش می دهد. فلوچارت مراحل مدل سازی فرامدل هیبریدی $(GRNN-AF-ARMA)_{EnKF}$ در شکل ۳ نمایش داده شده است که به صورت گام به گام فرآیند تلفیق مدل های پایه و فیلتر کالمن تجمعی را برای دستیابی به دقت پیش بینی بهینه، ترسیم می کند. بنابراین، می توان نتیجه گرفت که ترکیب مدل های هیبریدی سه گانه با فیلتر کالمن تجمعی، رویکردی بسیار مناسب و اثربخش برای پیش بینی دقیق تر شاخص فراوانی روزهای همراه با طوفان گرد و غبار (FDSD) در استان خوزستان است که قابلیت تعمیم به سایر مناطق با شرایط مشابه مانند استان های غربی کشور ایران نظیر استان ایلام که طوفان های گردوغبار متشدد خارجی دارند را نیز داراست.

جدول ۸- نتایج آماری داده های ورودی مدل هیبریدی $(GRNN-AF-ARMA)_{EnKF}$ به منظور پیش بینی 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
مسجد سلیمان	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
صفی آباد	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

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

۵- بحث


در این پژوهش، از معیارهای نیکوئی برازش R ، $RMSE$ ، NS و MAE به منظور بررسی عملکرد مدل‌های انفرادی و فرامدل‌های هیبریدی تشریح شده در بخش‌های قبلی، جهت پیش‌بینی شاخص $FDSD$ در استان خوزستان طی بازه زمانی ۵۰ ساله (۱۹۷۱-۲۰۲۰) استفاده شده است. علاوه بر این، از فیلتر کالمن تجمعی ($EnKF$) به منظور بهبود و تدقیق خروجی‌های مدل منتخب از میان ۶ مدل بررسی شده 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 سه گانه $EnKF(GRNN-AF-ARMA)$ در هفت ایستگاه بررسی شده در استان خوزستان بود. به عنوان مثال، پس از اعمال فیلتر $EnKF$ بر مدل هیبریدی سه گانه $GRNN-AF-ARMA$ ، 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، به ویژه 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، به ویژه 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 ، به خصوص در همراهی با فیلترهای تطبیقی مانند $EnKF$ ، نشان داد که می‌توان از مزایای هر دو روش خطی و غیرخطی به طور 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 به ترتیب به فرامدل هیبریدی سه گانه ($GRNN-AF-ARMA$)، مدل‌های

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

به طور کلی، مدل های کلاسیک باکس-جنکینز (ARMA) و مدل هیبریدی ARMA-AF عملکرد بهتری نسبت به مدل شبکه عصبی GRNN و ترکیب GRNN-AF داشته اند. با این حال، تلفیق مدل های باکس-جنکینز با شبکه عصبی در این پژوهش (GRNN-ARMA) کم ترین دقت و ضریب همبستگی و بیش ترین خطای نسبی را داشته است که نشان می دهد ترکیب دو مدل به تنهایی تضمین کننده بهبود عملکرد نیست و ماهیت و سازگاری الگوریتم ها نقش تعیین کننده دارد. مقایسه با مطالعات پیشین نشان داد که نتایج این پژوهش با یافته های Ansari Ghojghar و همکاران (۲۰۲۰) و Qing-Dao-Er-Ji Ren و همکاران (۲۰۲۲) مطابقت دارد؛ این پژوهش ها نیز بر اهمیت استفاده از مدل های بهینه سازی شده و ترکیبی در بهبود پیش بینی رخداد های گرد و غبار تأکید داشته اند. 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 پیش بینی ها استفاده شده باشد. همچنین، مقایسه میانگین مقادیر مشاهده شده و پیش بینی شده شاخص فراوانی روزهای همراه با طوفان گرد و غبار با استفاده از آزمون t نشان داد که تفاوت معناداری بین میانگین های سری های زمانی مشاهداتی و پیش بینی شده وجود ندارد (جدول ۹)، که این موضوع بیانگر اعتبار و معناداری کلیه مدل های بررسی شده است.





شکل ۴: مقایسه مقادیر مشاهده شده و پیش‌بینی شده شاخص FDSD با استفاده از مدل‌های GRNN، ARMA، GRNN-AF، ARMA-AF، و مدل ترکیبی ۳ گانه GRNN-AF-ARMA

جدول ۹: آزمون مقایسه میانگین سری‌های زمانی FDSD مشاهده شده و پیش‌بینی شده

ایستگاه	مشاهده شده	Mean														t-statistic	
		(G-AF-A) EnKF	G-AF-A	ARMA	GRNN	G-AF	G-A	(G-AF-A) EnKF	G-AF-A	A-AF	ARMA	GRNN	G-AF	G-A	A-AF	ARMA	G-AF
آبادان	923/0	۰/۹۱۳	۰/۹۰۱	۰/۸۸۳	۰/۸۸۱	۰/۸۷۹	۰/۸۷۳	۰/۸۷۲	۲/۳۳۳	۲/۳۲۱	۲/۲۲۱	۲/۲۲۱	۲/۲۲۴	۲/۱۵۶	۲/۰۹۹	۱/۹۲۳	G-A
اهواز	۰/۹۱۳	۰/۹۰۱	۰/۸۹۸	۰/۸۸۱	۰/۸۷۹	۰/۸۷۷	۰/۸۷۲	۰/۸۷۱	۲/۳۳۱	۲/۲۲۸	۲/۱۹۴	۲/۱۳۲	۲/۰۷۸	۱/۹۱۴	۲/۰۹۹	۱/۹۱۴	G-AF
بوستان	۰/۹۰۷	۰/۸۹۹	۰/۸۹۱	۰/۸۷۹	۰/۸۷۶	۰/۸۷۴	۰/۸۷۱	۰/۸۶۸	۲/۲۲۸	۲/۲۲۱	۲/۲۱۴	۲/۱۹۱	۲/۰۷۱	۱/۹۰۳	۲/۰۷۱	۱/۹۰۳	GRNN
مسجد سلیمان	۰/۹۰۲	۰/۸۹۲	۰/۸۸۸	۰/۸۷۵	۰/۸۷۳	۰/۸۷۱	۰/۸۷۰	۰/۸۶۷	۲/۲۲۱	۲/۲۱۹	۲/۲۰۶	۲/۱۸۴	۲/۰۰۱	۱/۸۵۶	۲/۰۰۱	۱/۸۵۶	ARMA
اهواز	۰/۸۹۷	۰/۸۸۱	۰/۸۸۰	۰/۸۷۳	۰/۸۷۲	۰/۸۶۹	۰/۸۶۸	۰/۸۶۳	۲/۲۱۹	۲/۲۱۴	۲/۲۰۴	۲/۱۸۳	۲/۱۰۶	۱/۸۳۲	۱/۹۹۸	۱/۸۳۲	A-AF
صفی آباد	۰/۸۸۵	۰/۸۷۷	۰/۸۷۳	۰/۸۷۱	۰/۸۶۸	۰/۸۶۵	۰/۸۶۳	۰/۸۶۱	۲/۲۰۳	۲/۲۰۲	۲/۲۰۰	۲/۱۴۱	۲/۱۰۲	۱/۷۰۶	۱/۹۹۶	۱/۷۰۶	G-AF-A
دزفول	۰/۸۸۴	۰/۸۷۱	۰/۸۶۹	۰/۸۶۸	۰/۸۶۴	۰/۸۶۲	۰/۸۶۱	۰/۸۵۹	۲/۲۰۱	۲/۲۰۰	۲/۱۹۱	۲/۱۳۵	۲/۰۵۹	۱/۶۹۶	۱/۹۷۳	۱/۶۹۶	GRNN

۵- نتیجه گیری

در پژوهش حاضر، نتایج حاصل از مقایسه مدل هیبریدی سه گانه (GRNN-AF-ARMA) با مدل های انفرادی GRNN و ARMA و همچنین فرامدل های هیبریدی GRNN-AF، ARMA-AF و GRNN-ARMA با توجه به نتایج حاصل از تحلیل شاخص های ارزیابی R، RMSE، NS و MAE نشان داد که فرامدل هیبریدی GRNN-AF-ARMA به عنوان مدل منتخب در میان سایر مدل های مورد بررسی، به منظور پیش بینی طوفان های گرد و غبار در استان خوزستان انتخاب شد. جهت بهبود عملکرد و افزایش دقت مدل سازی، از راهکار فیلتر کالمن تجمعی که از جمله روش های داده گواری است، استفاده شد. این فیلتر، با بروزرسانی داده های حاصل از فرامدل یادشده، عملکرد آن را در هر گام زمانی بهبود داده است. بدین ترتیب فرامدل هیبریدی (GRNN-AF-ARMA)_{EnKF} بهترین عملکرد را به نسبت سایر مدل های ذکر شده به منظور مدل سازی طوفان های گرد و غبار در استان خوزستان نمایش داده است. ایستگاه آبادان با بیش ترین میانگین روزهای همراه با طوفان گرد و غبار در مقیاس فصلی، بیش ترین دقت را در پیش بینی شاخص مذکور نمایش داده است. بدین ترتیب درمی یابیم که دقت مدل سازی نهایی طوفان های گرد و غبار، با کمیت داده های ورودی به منظور پیش بینی پدیده مذکور، رابطه مستقیمی دارد. تمامی مدل های بررسی شده در مطالعه حاضر، بالاترین عملکرد خود را در ترکیب های یک و دو ارائه دادند. لذا می توان نتیجه گرفت که استفاده از مدل های ساده، که از یک یا دو فصل گذشته جهت پیش بینی فصل های آینده استفاده می کنند، در پیش بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار در استان خوزستان، نسبت به مدل های پیچیده، با افزایش غنای مدل سازی، عملکرد بهتری را به نمایش می گذارد. با توجه به موارد ذکر شده و ماهیت غیرخطی و پیچیده طوفان های 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 طرح های مدیریت یکپارچه منابع آب به منظور بهره برداری پایدار و بهینه از منابع آبی، به ویژه در مناطق خشک و نیمه خشک، می باشد. این امر نه تنها به حفظ و تقویت منابع آب زیرزمینی کمک می کند، بلکه موجب کاهش فرسایش خاک و تثبیت آن در برابر وزش بادهای شدید می شود. با عنایت به مشکلات تنفسی، پوستی و ... ناشی از این طوفان ها در مناطق بحرانی و مستعد فرسایش بادی، کاشت گیاهان مقاوم با اقلیم منطقه به منظور کاهش سرعت باد و جلوگیری از پراکندگی ذرات گرد و غبار، می تواند به عنوان یک راهکار زیست محیطی مؤثر برای کاهش اثرات منفی طوفان های گرد و غبار مطرح شود. همچنین، یافته های این مطالعه تأکید می کند که بهره گیری از فیلتر کالمن تجمعی (EnKF) در بهبود پایداری و دقت پیش بینی مدل های هیبریدی، نقش مهمی ایفاء می کند و می تواند به عنوان راهکاری پیشرفته در مدل سازی پدیده های اقلیمی پیچیده، مانند طوفان های گرد و غبار، مورد استفاده قرار گیرد. علاوه بر این، نتایج نشان می دهد که مدل های ساده تر با ورودی های کم عمق تر زمانی در برخی شرایط می توانند عملکرد بهتری نسبت به مدل های پیچیده تر داشته باشند، که این موضوع اهمیت انتخاب مدل مناسب را برای شرایط اقلیمی و داده های موجود برجسته می سازد. پیشنهاد می گردد در پژوهش های آتی، ترکیب مدل هیبریدی سه گانه همراه با فیلتر کالمن تجمعی پیشنهادی با مدل های یادگیری عمیق و ترکیب آن ها مقایسه شده تا دقت مطالعاتی بالایی به منظور پیش بینی طوفان های گردوغبار و بهبود سامانه های پایش و پیش بینی این پدیده مخرب به ثبت رسد.

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 ghoghghar, 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 Ghoghghar, 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 poudesh, H., Younesi, H. & SHahinejad, B. (2020). Application 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.

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., Chaboureaud, 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.