



A comparison of the ELM algorithm and XBeach model in developing a hybrid XBeach-ELM method for dust storm prediction (Case study: Lorestan Province)

Mohammad Ansari ghoghghar¹ | Paria Pourmohammad²

1. Corresponding Author, Department of Reclamation of Arid and Mountainous Regions Engineering, Faculty of Natural Resources, University of Tehran, Iran. Email: Ansari.ghoghghar@ut.ac.ir

2. Department of Reclamation of Arid and Mountainous Regions Engineering, Faculty of Natural Resources, University of Tehran, Iran. Email: Paria.pormohamad7@ut.ac.ir

Article Info	ABSTRACT
Article type: Research Article	This study aims to assess and compare the performance of the Extreme Learning Machine (ELM) rapid learning algorithm with the open-source numerical model XBeach across ten synoptic stations in Lorestan Province (including Nurabad, Alishtar, Borujerd, Kuhdasht, Khorramabad, Pol-e Dokhtar, Nojian, Dorud, Azna, and Aligudarz) over a 50-year period (1971–2020), with the objective of proposing a hybrid XBeach-ELM method for predicting the Frequency of Dust Storm Days (FDSD) index. The findings revealed a statistically significant and meaningful difference in the modeling results when using the hybrid XBeach-ELM approach compared to other methods examined. The hybrid XBeach-ELM method outperformed the ELM and XBeach models, showing the lowest values for the NRMSE and MAPE error metrics. A t-test comparison of the observed and predicted mean values confirmed the acceptance of the null hypothesis, indicating no significant difference between the observed and predicted time series for the FDSD index when applying the hybrid XBeach-ELM method in Lorestan Province. This equivalence was not observed with the individual ELM or XBeach models. These results suggest that only the hybrid model effectively preserved the mean of the observed time series in predicting the FDSD index. The outcomes of this study have substantial implications for the enhancement of early warning systems, enabling more accurate dust storm forecasting, reducing human and economic losses, supporting urban and infrastructure planning to bolster resilience in high-risk areas, informing local and national policy-making on dust storm management, and advancing the development of sustainable solutions to improve the accuracy of predictive models.
Article history:	
Received: Feb. 1, 2025	
Revised: Apr. 17, 2025	
Accepted: Apr. 21, 2025	
Published online: July. 2025	
Keywords: Horizontal Visibility, Machine Learning, FDSD, Numerical Modeling, Goodness-of-fit Criteria.	

Cite this article: Ansari Ghoghghar, M., & Pourmohammad, P. (2025) A comparison of the ELM algorithm and XBeach model in developing a hybrid XBeach-ELM method for dust storm prediction (Case study: Lorestan Province), *Iranian Journal of Soil and Water Research*, 56 (5), 1201-1218. <https://doi.org/10.22059/ijswr.2025.389735.669875>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2025.389735.669875>



EXTENDED ABSTRACT

Introduction

Dust storms are recognized as one of the most serious environmental hazards in arid and semi-arid regions worldwide. These storms not only affect human health but also have harmful impacts on wildlife and vegetation. The human health effects of dust storms include increased air pollution, the spread of diseases such as asthma and other respiratory issues, disruption of economic activities, damage to machinery and equipment, contamination of water resources, and gastrointestinal illnesses. Wind speed is the main factor responsible for the formation of dust storms. When wind speed exceeds the threshold for soil erosion, a significant amount of particles is lifted from deserts and dry areas into the atmosphere, causing problems for surrounding regions. Therefore, modeling dust storms is essential for understanding the complex mechanisms behind their formation, spread, and consequences. Numerical models and advanced analytical methods play an important role in simulating the dynamic behavior of dust storms and are crucial for predicting their temporal and spatial variations. While many individual, dual, and triple hybrid models have been used to accurately model the Frequency of Dust Storm Days (FDSD) index, no studies have combined a numerical model with artificial intelligence models for dust storm prediction. Thus, this study, for the first time, combines a rapid learning algorithm with an open-source numerical model to model dust storms and compares the performance of the Extreme Learning Machine (ELM) algorithm with the open-source XBeach model.

Method

This study compares the performance of the Extreme Learning Machine (ELM) rapid learning algorithm with the open-source XBeach model to propose a hybrid XBeach-ELM method, applied to ten synoptic stations in Lorestan Province (including Nurabad, Alishtar, Borujerd, Kuhdasht, Khorramabad, Pol-e Dokhtar, Nojian, Dorud, Azna, and Aligudarz), as shown in Figure 1. The analysis covers a 50-year long-term period (1971–2020). Hourly data on horizontal visibility and World Meteorological Organization (WMO) codes were used for this purpose. A day with a dust storm is defined as a day when, in at least one of the eight reporting periods, one of the dust-related codes (06, 07, 08, 09, 30, 31, 32, 33, 34, 35, or 98) appears in the weather report. This is assuming that the corresponding horizontal visibility data for the reported code is less than 1000 meters. In this study, a horizontal visibility threshold of ≤ 1000 meters was used for all dust-related codes to identify dust storm days. Extreme Learning Machine (ELM) is an advanced variant of feedforward neural networks, recognized for its fast training speed, which significantly reduces computational time compared to traditional methods. Unlike conventional approaches that rely on iterative optimization of weights (such as backpropagation), ELM randomly initializes the hidden layer weights and determines the output layer weights by solving a matrix equation. This method is widely employed in various practical fields such as classification, prediction, and pattern recognition, thanks to its efficiency, minimal tuning requirements, and satisfactory accuracy. XBeach is an open-source numerical model initially developed to simulate the effects of hydrodynamic processes on sandy coastlines. It has since been extended to other coastal types and applications. The model is capable of simulating coastal bed changes using bed update equations, which are based on sediment changes and the movement of sand driven by currents and waves. This allows XBeach to simulate the effects of erosion and deposition caused by storms and strong waves, as well as predict morphological changes in the coastal bed.

Results

The evaluation indices R, NRMSE, MAPE, and NS were used to assess and compare the performance of the XBeach, ELM, and XBeach-ELM models in predicting the frequency of dust storm days in Lorestan province over a 50-year period. The results indicate that the hybrid XBeach-ELM method provides a much higher accuracy in estimating the frequency of dust storm days across ten stations in Lorestan compared to the ELM and XBeach models. The results from the ELM and XBeach models were almost identical, as there was no significant difference between the two. The results demonstrate that the ELM and XBeach models, when used individually, were not particularly effective in predicting the FDSD index, as their predicted values deviated considerably from the observed values. However, the hybrid XBeach-ELM method succeeded in reducing the gap between the predicted and observed values, significantly improving the accuracy of dust storm predictions. This method has proven to be a valuable tool for simulating and forecasting dust storms in Lorestan province. These findings emphasize the significance of employing hybrid approaches in modeling dust storms—complex and nonlinear phenomena—and could play a crucial role in enhancing disaster management and mitigating the impact of dust storms.

Author Contributions

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data available on request from the authors.

Acknowledgements

The authors would like to thank the reviewers and editor for their critical comments that helped to improve the paper. The authors gratefully acknowledge the support and facilities provided by the Department of Reclamation of arid and mountainous regions, Faculty of Natural Resources, University of Tehran, Iran.

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

مقایسه عملکرد الگوریتم یادگیری سریع ELM با مدل عددی کد باز XBeach به منظور ارائه روش تلفیقی XBeach-ELM جهت پیش‌بینی طوفان‌های گرد و غبار (مطالعه موردی: استان لرستان)

محمد انصاری قوجقار^۱ | پریا پورمحمد^۲^۱. نویسنده مسئول، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: Ansari.ghoighar@ut.ac.ir^۲. گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران، رایانامه: Paria.pormohamad7@ut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	هدف از این پژوهش ارزیابی و مقایسه کارکرد روش یادگیری سریع ELM با مدل عددی کد باز XBeach در ده ایستگاه سینوپتیک استان لرستان (نورآباد، الشتر، بروجرد، کوهدشت، خرم آباد، پل دختر، نوژیان، درود، ازنا و الیگودرز) در طول دوره آماری ۵۰ ساله (۱۹۷۱-۲۰۲۰) به منظور ارائه روش تلفیقی XBeach-ELM برای پیش‌بینی شاخص FDSD بود. نتایج حاکی از وجود تفاوت چشم‌گیر و معنادار در نتایج مدل‌سازی با روش تلفیقی XBeach-ELM نسبت به سایر روش‌های مورد بررسی بود. روش تلفیقی XBeach-ELM با کم‌ترین مقدار معیارهای خطای NRMSE و MAPE، عملکرد بهتری را نسبت به روش یادگیری سریع ELM و مدل عددی XBeach نشان داد. مقایسه میانگین مقادیر مشاهداتی و پیش‌بینی‌شده با استفاده از آزمون t نشان‌دهنده پذیرش فرض صفر مبنی بر برابری میانگین‌های سری‌های زمانی مشاهداتی و پیش‌بینی‌شده شاخص فراوانی روزهای طوفان گرد و غبار در روش هیبریدی XBeach-ELM در استان لرستان بود. بدین ترتیب می‌توان بیان کرد که فقط مدل هیبریدی بررسی شده به‌طور مؤثر میانگین سری زمانی مشاهداتی را در پیش‌بینی شاخص FDSD حفظ کرده است در حالی که در دو روش انفرادی ELM و XBeach این برابری نشان داده نشده است. نتایج این مطالعه می‌تواند در توسعه سیستم‌های هشدار زود هنگام برای پیش‌بینی دقیق‌تر طوفان‌های گرد و غبار و کاهش خسارات انسانی و اقتصادی، برنامه‌ریزی شهری و زیرساختی برای مقاوم‌سازی مناطق پرخطر، حمایت از سیاست‌گذاری‌های محلی و ملی در زمینه مدیریت گرد و غبار، طراحی راهکارهای پایدار و توسعه مدل‌های پیش‌بینی، تأثیر به‌سزایی داشته باشد.
واژه‌های کلیدی: دید افقی، یادگیری ماشین، FDSD، روش‌های عددی، معیار نیکویی برازش.	

استناد: انصاری قوجقار؛ محمد، پورمحمد؛ پریا، (۱۴۰۴) مقایسه عملکرد الگوریتم یادگیری سریع ELM با مدل عددی کد باز XBeach به منظور ارائه روش تلفیقی

XBeach-ELM جهت پیش‌بینی طوفان‌های گرد و غبار (مطالعه موردی: استان لرستان)، مجله تحقیقات آب و خاک ایران، ۵۶ (۵)، ۱۲۱۸-۱۲۰۱.

<https://doi.org/10.22059/ijswr.2025.389735.669875>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2025.389735.669875>

مقدمه

طوفان‌های گرد و غبار^۱ به‌عنوان یکی از جدی‌ترین مخاطرات محیط‌زیستی در مناطق خشک و نیمه‌خشک جهان شناخته می‌شوند (Anselin et al., 2009). گرد و غبار عمدتاً شامل ذرات معلق جوی با اندازه ۰/۵ تا ۰/۱ میلی‌متر است که می‌توانند از سطح زمین به ارتفاعات بالاتر انتقال یافته و در مسافت‌های هزاران کیلومتری جابه‌جا شوند. این پدیده می‌تواند تمام شهرهای یک کشور یا حتی کشورهای یک قاره را تحت تأثیر قرار دهد (Ansari Renani et al., 2011). طوفان‌های گرد و غبار نه تنها بر سلامت انسان‌ها، بلکه بر حیات وحش و پوشش گیاهی نیز اثرات مخربی دارند. اثرات انسانی این پدیده شامل افزایش آلودگی هوا، شیوع بیماری‌هایی نظیر آسم و سایر اختلالات تنفسی، اختلال در فعالیت‌های اقتصادی، خرابی تجهیزات و ماشین‌آلات، آلودگی منابع آبی و بروز بیماری‌های گوارشی است (Marsafari et al., 2011). مهم‌ترین عامل در شکل‌گیری این پدیده سرعت باد است. هنگامی که سرعت باد از آستانه فرسایش خاک فراتر رود، حجم قابل توجهی از ذرات از بیابان‌ها و مناطق خشک وارد جو می‌شوند و مشکلات فراوانی برای مناطق اطراف ایجاد می‌کنند (Atay et al., 201). طوفان‌های گرد و غبار با توجه به ویژگی‌هایی مانند اندازه ذرات خاک، رطوبت خاک، بافت و ساختمان خاک، چسبندگی موجود میان ذرات و پوشش گیاهی و با رسیدن سرعت باد به سرعت آستانه ذرات برای حمل آن‌ها براساس اندازه، شکل و چگالی ایجاد می‌شوند (شاهسونی و همکاران، ۱۳۹۲).

استان‌های غربی و جنوب‌غربی ایران مانند خوزستان، ایلام، کرمانشاه و لرستان به‌شدت تحت تأثیر گرد و غبار ناشی از بیابان‌های شمال غرب عراق، غرب سوریه و شرق و جنوب شرق عربستان سعودی قرار دارند. همچنین بخش‌های خشک تالاب هورالعظیم در مرز ایران و عراق و تالاب‌های استان خوزستان از منابع داخلی تولید گرد و غبار در ایران به‌شمار می‌روند (Turkashvand et al., 2017). در این میان، مدل‌سازی این پدیده به‌عنوان ابزاری ضروری برای درک سازوکارهای پیچیده شکل‌گیری، گسترش و پیامدهای طوفان‌های گرد و غبار مطرح است. مدل‌های عددی و روش‌های تحلیل پیشرفته، با فراهم آوردن امکان شبیه‌سازی رفتار دینامیکی این پدیده‌ها، در پیش‌بینی تغییرات زمانی و مکانی طوفان‌ها نقشی کلیدی ایفا می‌کنند. این ابزارها نه تنها امکان تحلیل تأثیر عوامل محیطی و انسانی بر شدت و توزیع طوفان‌ها را فراهم می‌آورند، بلکه بستری برای توسعه راهکارهای مدیریتی و طراحی اقدامات پیشگیرانه و کاهش‌دهنده خسارات فراهم می‌سازند (Mei et al., 2024). Haiawi و همکاران (۲۰۲۴) به ارزیابی روش‌های یادگیری ماشین برای مدل‌سازی و پیش‌بینی طوفان‌های گرد و غبار در عراق پرداختند. مدل رگرسیون افزایشی، با استفاده از الگوریتم تنبل^۲ (IBk) برای مناطق بصره و نینوا و الگوریتم تنبل^۳ (KStar) برای بغداد، از دیگر روش‌ها در زمینه دقت، پیشی گرفته است. انصاری قوجقار و همکاران (۱۴۰۳) به ارزیابی مدل‌سازی طوفان‌های گرد و غبار با استفاده از مدل هیبریدی سه‌گانه GRNN- SVM- LSTM در استان سیستان و بلوچستان پرداختند. نتایج این پژوهش نشان داد که مدل هیبرید سه‌گانه پیشنهادی نسبت به سایر روش‌ها بهترین عملکرد را داشته است. همچنین بیش‌ترین دقت این مدل در ترکیبات فصلی ۱ و ۲ آن به‌منظور پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار (FDSD)^۴ حاصل شده است. پس از آن، فرامدل انفرادی ماشین بردار پشتیبان^۵ SVM در رتبه‌بندی از لحاظ عملکرد قرار گرفت. یارمحمدی و همکاران (۱۴۰۲) به پیش‌بینی مسیرهای انتقال طوفان‌های گرد و غبار با استفاده از شبکه عصبی کانولوشن^۶ و زمینه جغرافیایی برای سازگاری و کاهش اثرات در مناطق شهری پرداختند. نتایج نشان داد که مدل شبکه عصبی کانولوشن توانایی بالایی در پیش‌بینی مسیر انتقال طوفان‌های گرد و غبار دارد. علاوه بر این، افزایش ۰/۲ در معیار ضریب کاپا در تمام ساعات پیش‌بینی نشان می‌دهد که مدل CNN-LSTM در مقایسه با مدل ConvLSTM، هنگام در نظر گرفتن اطلاعات متنی، عملکرد بهتری دارد. درگاهیان و همکاران (۱۴۰۳) به تعیین پتانسیل تولید گرد و غبار در کانون‌های داخلی خوزستان با استفاده از مدل عددی^۷ WRF و مدل جفت شده WRF- Chem پرداختند. نتایج مطالعات آنان نشان داد که هر یک از کانون‌ها در طول طوفان‌های ۲۰ سال گذشته، سبب افزایش گرد و غبار و سامانه‌های مهاجر به منطقه شده‌اند. با توجه خسارات اجتماعی، اقتصادی، سلامت و زیست محیطی طوفان‌های گرد و غبار لذا مدل‌سازی و پیش‌بینی این پدیده مخرب زیست محیطی که می‌تواند منجر به ایجاد سامانه هشدار و به تبع آن کاهش خسارات ناشی از این پدیده شود، امری ضروری است. از سوی دیگر و از

1 Dust storms

2 Instance-Based k-nearest neighbor

3 KStar Lazy Algorithm

4 Frequency of Dust Storm Days

5 Support Vector Machine

6 Convolutional Neural Network

7 Weather Research and Forecasting

بررسی پژوهش‌های مختلف می‌توان دریافت که مدل‌های انفرادی و هیبریدی دوگانه بر پایه یادگیری ماشین و الگوریتم‌های فراابتکاری بهینه‌سازی برای مدل‌سازی دقیق شاخص FDSI مورد استفاده قرار گرفته است اما تاکنون هیچ یک از مطالعات به بررسی تاثیر یک مدل عددی و ترکیب آن با مدل‌های یادگیری ماشین یا یادگیری عمیق به منظور پیش‌بینی طوفان‌های گرد و غبار نپرداخته‌اند لذا هدف از این پژوهش، مقایسه عملکرد یک الگوریتم یادگیری سریع با مدل ریاضی کد باز XBeach برای ارائه روش ترکیبی و هوشمند برای پیش‌بینی طوفان‌های گرد و غبار در ده ایستگاه سینوپتیک استان لرستان (نورآباد، الشتر، بروجرد، کوهدشت، خرم‌آباد، پل دختر، نوژیان، درود، ازنا و الیگودرز) است تا بتوان با استفاده از یک مدل تلفیقی و هوشمند به مدل‌سازی زمانی و مکانی طوفان‌های گرد و غبار در این استان پرداخت. مدل‌سازی‌های یکپارچه علاوه بر اینکه باعث پیش‌بینی دقیق متغیرهای هیدرولوژیکی می‌شوند، خسارات ناشی از آن را نیز تا حد زیادی کاهش می‌دهند بنابراین از نتایج آن می‌توان در استان‌هایی که از نظر اقلیمی شباهت زیادی با منطقه مورد مطالعه دارند نیز استفاده نمود. هدف دیگری که برای مدل‌سازی‌های تلفیقی می‌توان متصور شد، ارائه سامانه‌های هوشمند با استفاده از مدل‌های هیبریدی و به منظور مدل‌سازی و پیش‌بینی‌های دقیق طوفان‌های گرد و غبار است تا بتوان خسارات متعدد زیست محیطی، بهداشت و سلامت، اجتماعی، اقتصادی و... را به حداقل رساند. لذا در پژوهش حاضر، برای اولین بار یک روش یادگیری سریع با یک مدل عددی کد باز به منظور مدل‌سازی طوفان‌های گرد و غبار ترکیب شده است و به تبع آن با عملکرد الگوریتم انفرادی یادگیری سریع^۱ ELM و مدل عددی کد باز XBeach مورد مقایسه قرار گرفته است. روش یادگیری ماشین سریع ELM به دلیل سرعت بالا و دقت مناسب در مدل‌سازی پدیده‌های غیرخطی، ابزاری کارآمد برای پیش‌بینی طوفان‌های گرد و غبار محسوب می‌شود. این روش با آموزش سریع شبکه‌های عصبی و توانایی پردازش داده‌های چندمنبعی، امکان تحلیل دقیق‌تر و سریع‌تر این پدیده‌ها را فراهم می‌کند. همچنین، ELM به دلیل عدم نیاز به تنظیم دوباره وزن‌ها و استفاده از الگوریتم‌های تکراری، هزینه محاسباتی کمتری نسبت به سایر روش‌های هوش مصنوعی دارد و می‌تواند به‌صورت ترکیبی با مدل‌های عددی برای بهبود پیش‌بینی استفاده شود. از سوی دیگر، مدل عددی کد باز XBeach به دلیل دقت بالا در شبیه‌سازی فرآیندهای پیچیده و قابلیت انعطاف در تنظیمات مختلف، یکی از ابزارهای قدرتمند در مدل‌سازی است. این مدل می‌تواند به‌طور مؤثر اثرات تغییرات محیطی را در مقیاس‌های زمانی و مکانی مختلف پیش‌بینی کند. همچنین، XBeach به دلیل توانایی شبیه‌سازی همزمان چندین فرآیند فیزیکی، مانند جریان‌ها، فرسایش و انتقال رسوبات، امکان ارزیابی همه‌جانبه از شرایط مختلف را فراهم می‌آورد. علاوه بر این، استفاده از XBeach می‌تواند زمان و هزینه‌های محاسباتی را کاهش دهد و به پژوهشگران این امکان را می‌دهد که راهکارهای بهینه‌تری برای مسائل پیچیده پیدا کنند.


روش‌شناسی پژوهش

منطقه مورد مطالعه

در این پژوهش به مقایسه عملکرد الگوریتم یادگیری سریع ELM با مدل کد باز XBeach به منظور ارائه روش تلفیقی XBeach-ELM در ده ایستگاه سینوپتیک استان لرستان (نورآباد، الشتر، بروجرد، کوهدشت، خرم‌آباد، پل دختر، نوژیان، درود، ازنا و الیگودرز)، مطابق شکل ۱، با جامعه آماری بلندمدت ۵۰ ساله (۲۰۲۰-۱۹۷۱) پرداخته شده است. بدین منظور از داده‌های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی استفاده شد. مشاهدات پدیده‌های هواشناسی در هشت سینوپ در طول شبانه‌روز ثبت می‌شوند. در این مشاهدات، پدیده‌های بصری آب و هوا طبق دستورالعمل سازمان جهانی هواشناسی در ۱۰۰ کد مانند جدول ۱، 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). روز همراه با طوفان‌های گرد و غبار روزی است که در آن، حداقل در یکی از هشت نوبت ثبت، 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، کمتر از ۱۰۰۰ متر ثبت شده باشد (Mohammadi, 2015). در پژوهش حاضر، از مولفه دید افقی ≤ 1000 متر برای تمامی کدهای گرد و غبار برای تشخیص طوفان‌های گرد و غبار، استفاده شده‌است.

جدول ۱- کدهای سازمان جهانی هواشناسی مرتبط با فرسایش بادی و پدیده‌های گرد و غبار (O'Loingsigh et al., 2014)

توضیحات	کد
Dust haze	۰۶
Raised dust or sand	۰۷
Well-developed dust whirls (dust devils)	۰۸
Distant or past dust storm (distant at time of obs or past station in the past hour)	۰۹
DECREASED slight or moderate sand or dust storm with visibility <1000 m but >200 m	۳۰
STABLE slight or moderate sand or dust storm with visibility <1000 m but >200 m	۳۱
BEGUN or INCREASING slight or moderate sand or dust storm with visibility <1000 m but >200 m	۳۲
DECREASED severe dust storm with visibility <200 m	۳۳
Stable severe dust storm with visibility <200 m	۳۴
BEGUN or INCREASING severe dust storm with visibility <200 m	۳۵
Thunderstorm with dust or sand storm	۹۸



شکل ۱- معرفی ایستگاه‌های مورد مطالعه در پژوهش حاضر

مدل یادگیری سریع ELM

ELM یک الگوریتم یادگیری ماشین است که به‌طور خاص برای شبکه‌های عصبی تک‌لایه^۱ (SLFN) توسعه یافته است (توفیقی و همکاران، ۱۴۰۲). یادگیری سریع یکی از مشتقات شبکه‌های عصبی پیش‌خور است و برای آموزش شبکه‌های عصبی سرعت بالایی دارد و یکی از مزایای اصلی آن کاهش زمان محاسباتی در مقایسه با روش‌های سنتی است. برخلاف روش‌های متداول که از بهینه‌سازی تکراری برای وزن‌ها استفاده می‌کنند (مانند پس‌انتشار خطا)، در ELM وزن‌های لایه پنهان به‌صورت تصادفی مقداردهی اولیه می‌شوند و فقط وزن‌های لایه خروجی با حل یک مسئله ماتریسی به‌دست می‌آیند (Al-Haija et al., 2024). این الگوریتم به‌دلیل سرعت بالا، نیاز به

تنظیمات کم‌تر و دقت مناسب در بسیاری از مسائل کاربردی مانند دسته‌بندی، پیش‌بینی و بازشناسی الگو استفاده می‌شود. ساختار کلی ELM شامل یک لایه ورودی است که داده‌ها وارد می‌شوند، یک لایه پنهان که وزن‌های آن به‌صورت تصادفی مقداردهی شده و یک لایه خروجی که وزن‌های آن از طریق حل یک مسئله خطی تعیین می‌گردند. نوع تابع فعال‌سازی و تعداد نورون‌ها از جمله مهم‌ترین عوامل تعمیم و ارزیابی شبکه یادگیری سریع است (Zhang et al., 2024). مقدار اولیه و وزن ورودی نورون‌ها در این مدل به شکل تصادفی انتخاب می‌شود و تا انتهای کار نیز ثابت باقی می‌ماند. در این بین، فقط وزن میان نورون‌ها و لایه خروجی به‌منظور کاهش خطا و دستیابی به کارکردی نزدیک به آنچه در واقعیت است، توسط سیستم تغییر پیدا می‌کند (توفیقی و همکاران، ۱۴۰۲). به‌دلیل عملکرد سریع و کارایی مناسب، ELM در تحلیل داده‌های بزرگ و مدل‌های بلادرنگ بسیار مورد توجه قرار گرفته است (Gelvez-Almeida et al., 2024).

مدل عددی کدباز XBeach

XBeach یک مدل عددی کدباز است که در ابتدا برای شبیه‌سازی اثرات فرآیندهای هیدرودینامیکی در سواحل ماسه‌ای طراحی شد. این مدل در ادامه توسعه یافت و برای شبیه‌سازی واکنش سواحل شنی به شرایط متغیر طوفانی در طول زمان و اهداف دیگر نیز مورد استفاده قرار گرفت (ملکی و همکاران، ۱۴۰۳). XBeach (Roelvink et al., 2009 & 2010). از روش تقریب اختلافات محدود برای شبیه‌سازی تغییرات رسوب استفاده می‌کند (Berard et al., 2017). این مدل به‌طور هم‌زمان معادلات مربوط به امواج کوتاه، انرژی غلتان، جریان‌های کم‌عمق، انتقال رسوب و تغییرات بستر را حل می‌کند (Roelvink et al., 2009; Bolle et al., 2011)، که امکان شبیه‌سازی دقیق اثرات پیچیده و تعاملی این فرآیندها را فراهم می‌سازد. یکی از قابلیت‌های کلیدی XBeach، انعطاف‌پذیری آن در تعریف شرایط مرزی است. این مدل می‌تواند شرایط مرزی را به‌صورت سری‌های زمانی از ارتفاع موج لحظه‌ای یا به‌صورت پایدار برای شرایط ثابت تنظیم کند، که این ویژگی به‌ویژه برای شبیه‌سازی محیط‌های پیچیده و پویای ساحلی بسیار سودمند است (Roelvink et al., 2019). XBeach همچنین از معادلات انتقال-پخش برای محاسبه میزان جابه‌جایی رسوب استفاده می‌کند. در این معادلات، رسوب به‌عنوان متغیری هم‌زمان با جریان‌های آب و امواج در نظر گرفته می‌شود، و اثرات جریان‌های ناشی از طوفان‌ها، امواج و جزر و مد بر رسوبات ساحلی را شبیه‌سازی می‌کند. این قابلیت به مدل امکان می‌دهد که فرآیندهای فرسایش و رسوب‌گذاری را با دقت بالایی بازنمایی کند. علاوه بر این، XBeach قادر به شبیه‌سازی تغییرات بستر ساحلی است. این مدل از معادلات به‌روزرسانی بستر بهره می‌برد که تغییرات رسوب و جابه‌جایی شن و ماسه را بر اثر جریان‌ها و امواج محاسبه می‌کند. بدین ترتیب، XBeach می‌تواند اثرات فرسایش و رسوب‌گذاری ناشی از طوفان‌ها و امواج شدید را شبیه‌سازی کرده و تغییرات مورفولوژی بستر ساحلی را پیش‌بینی کند (Kolokythas et al., 2016). در این مطالعه، از مدل عددی کدباز XBeach به‌منظور مدل‌سازی فراوانی روزهای همراه با طوفان گرد و غبار استفاده شده است.

مدل‌های پیش‌بینی


در این پژوهش، متغیر مدنظر، تعداد فصل یا فصل‌های گذشته به‌منظور پیش‌بینی فصل یا فصل‌های آینده است. تعداد فصول قابل پیش‌بینی می‌تواند شامل یک، دو، سه و چهار فصل قبل‌تر از متغیر FDSD باشد. در مدل شماره یک، به‌منظور پیش‌بینی FDSD برای فصل بعدی، از سری زمانی فراوانی روزهای همراه با طوفان گرد و غبار با یک گام تأخیر استفاده شده است. به بیانی دیگر، به‌منظور پیش‌بینی در زمان $t+1$ ، از مقدار آن در زمان t استفاده شده است. در مدل شماره دو، پیش‌بینی در فصل بعدی با استفاده از مقادیر FDSD تا دو فصل قبلی آن صورت گرفته است. این مدل‌ها به‌منظور در نظر گرفتن تأثیر فصول گذشته بر فراوانی طوفان‌های گرد و غبار در پیش‌بینی‌های فصول آینده طراحی شده‌اند. در مدل‌های ۳ و ۴ نیز پیش‌بینی‌ها براساس مقادیر FDSD در سه و چهار فصل قبل انجام شده است. روابط زیر، پیش‌بینی‌های انجام‌شده در مدل‌های یک تا چهار را نمایش می‌دهد.

$$FDSD_{(t+1)} = f(FDSD_{(t)}) \quad \text{مدل یک}$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)}) \quad \text{مدل دو}$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)}, FDSD_{(t-2)}) \quad \text{مدل سه}$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)}, FDSD_{(t-2)}, FDSD_{(t-3)}) \quad \text{مدل چهار}$$



شکل ۲- بلوک دیاگرام مدل تلفیقی XBeach- ELM

معیارهای ارزیابی

در این پژوهش، برای سنجش دقت و عملکرد مدل‌ها، از شاخص‌های ضریب همبستگی^۱ (R)، خطای جذر میانگین مربعات نرمال شده^۲ ($NRMSE$)، میانگین درصد قدر مطلق خطا^۳ ($MAPE$) و ضریب نش- ساتکلیف^۴ (NS) استفاده شده است. این شاخص‌ها میزان انطباق خروجی مدل با داده‌های واقعی را نشان داده و بر اساس رابطه‌های ۱ تا ۴ محاسبه شده‌اند.

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (f_i - o_i)^2}{N}}}{o_i}$$

رابطه ۱)

1 Correlation

2 Root Mean Square Error

3 Mean Absolute Percentage Error

4 Nash- Sutcliffe

$$MAPE = \frac{100}{n} \times \sum_{i=1}^n \left| \frac{f_i - O_i}{f_i} \right| \quad \text{رابطه ۲}$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad \text{رابطه ۳}$$

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad \text{رابطه ۴}$$

در رابطه‌های ۱ تا ۴، 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.

نتایج

شاخص‌های ارزیابی R ، $NRMSE$ ، $MAPE$ و NS برای بررسی و مقایسه عملکرد مدل‌های $XBeach$ ، ELM و $XBeach-ELM$ برای پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار در استان لرستان در طول دوره آماری ۵۰ ساله استفاده شده است. در جداول ۲، ۳ و ۴، مقادیر معیارهای ارزیابی مرتبط با مراحل آموزش و آزمون مدل‌های $XBeach$ ، ELM و $XBeach-ELM$ به‌منظور پیش‌بینی طوفان‌های گرد و غبار در ده ایستگاه استان لرستان شامل کوه‌دشت، پلدختر، نوژیان، خرم‌آباد، الشتر، نورآباد، درود، بروجرد، الیگودرز و ازنا نشان داده شده است. همان‌طور که در جدول ۲ نشان داده شده است، تمامی ایستگاه‌ها، در ترکیب‌های اول و دوم عملکرد بهتری را نسبت به سایر ترکیب‌ها نشان می‌دهند بدین معنی که استفاده از داده‌های یک الی دو فصل قبلی، نتایج بهتری در مدل‌سازی را به همراه داشته است و استفاده از سه یا چهار فصل قبل، از دقت پیش‌بینی می‌کاهد. به‌عنوان مثال در ایستگاه کوه‌دشت، مقدار ضریب همبستگی و خطای نش-ساتکلیف به ترتیب از ۰/۵۰۹ و ۰/۵۹۰ روز در ترکیب چهارم، به ۰/۵۱۲ و ۰/۵۹۱ روز در ترکیب اول افزایش یافته است. در ایستگاه‌های درود، بروجرد و الیگودرز نیز مقدار میانگین درصد قدرمطلق خطا پس از پیش‌بینی طوفان‌های گرد و غبار با استفاده از ترکیب اول به‌جای چهارم، به‌ترتیب از ۴۷/۵۱، ۴۸/۱۷ و ۴۸/۵۴ روز به ۴۷/۲۴، ۴۷/۸۷ و ۴۸/۲۳ درصد کاهش یافته است. نتایج این قسمت با نتایج کارگر شورکی و همکاران (۱۳۹۵) و Kongsorot et al. (2014) مطابقت دارد.

جدول شماره ۳ نتایج مدل‌سازی طوفان‌های گرد و غبار را با استفاده از مدل عددی کدباز $XBeach$ نشان می‌دهد. همان‌طور که مشخص است، در ایستگاه‌های نوژیان و خرم‌آباد، مقادیر خطای $NRMSE$ و $MAPE$ از ۰/۳۲۷ و ۳۸/۳۴ درصد و ۰/۳۳۲ و ۳۸/۹۹ درصد، پس از استفاده از چهار فصل گذشته برای پیش‌بینی، به ۰/۳۲۵ و ۳۷/۹۵ درصد و ۰/۳۲۸ و ۳۸/۴۲ درصد، در نتیجه استفاده از داده‌های یک فصل گذشته برای مدل‌سازی طوفان‌های گرد و غبار، به‌طور نسبی کاهش پیدا کرده است. این روند نشان می‌دهد که استفاده از داده‌های اخیر (یک فصل گذشته) نسبت به داده‌های بلندمدت‌تر (چهار فصل گذشته) در کاهش میزان خطا تأثیر نسبی داشته است. از سوی دیگر، مقدار خطا در همه ایستگاه‌های مورد مطالعه به‌ازای تمامی ترکیب‌ها، نسبت به مدل یادگیری سریع ELM ، کاهش یافته است. همچنین ضرایب همبستگی و نش-ساتکلیف نیز نسبت به نتایج مدل‌سازی با ELM ، افزایش یافته است. نتایج این قسمت با نتایج Harter et al. (2017) و Roelvink et al. (2010) مطابقت دارد. با توجه به نتایج در ایستگاه کوه‌دشت (که بیش‌ترین فراوانی روزهای همراه با طوفان گرد و غبار در مقیاس فصلی را در استان دارد) و ایستگاه ازنا (با کم‌ترین فراوانی فصلی)، می‌توان نتیجه گرفت که هر چه از تعداد روزهای گرد و غباری در ایستگاه‌های مورد بررسی کاسته می‌شود، از دقت پیش‌بینی طوفان‌های گرد و غبار در این استان کاسته می‌شود. این روند احتمالاً به محدودیت داده‌های موجود در ایستگاه‌های با تعداد روزهای گرد و غباری کمتر و کاهش دقت مدل در شرایط داده‌های کم مرتبط است.

در جدول ۴، نتایج مرتبط با روش ترکیبی $XBeach-ELM$ نمایش داده شده است. مقدار خطای حاصل شده در تمامی ایستگاه‌ها، تغییر محسوس و چشم‌گیری نسبت به دو مدل قبلی داشته است. علاوه بر این، ضریب همبستگی و نش-ساتکلیف نیز در مقایسه با مدل یادگیری سریع ELM و مدل عددی $XBeach$ ، افزایش قابل ملاحظه‌ای داشته است. به‌عنوان مثال، در ایستگاه نورآباد، مقدار $NRMSE$ برای ترکیب شماره یک از ۰/۴۱۳ در مدل ELM به ۰/۳۳۸ در روش عددی $XBeach$ و در نهایت به ۰/۱۲۳ با روش تلفیقی $XBeach-ELM$ کاهش یافته است. در ایستگاه پلدختر نیز مقدار $MAPE$ از ۴۴/۴۱ درصد در مدل ELM به ۳۷/۵۶ درصد در روش عددی $XBeach$ و در نهایت به ۰/۳۷۴ درصد با روش تلفیقی $XBeach-ELM$ به‌مقدار چشم‌گیری کاهش یافته است. بدین ترتیب، نتایج به‌دست آمده

جدول ۲- نتایج پیش‌بینی شاخص FDS با مدل یادگیری سریع ELM

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	NS	MAPE	NRMSE	R	NS	MAPE	NRMSE
کوه‌دشت	۱	-۰/۳۶۲	۳۸/۰۴	-۰/۶۱۷	-۰/۵۳۱	-۰/۳۹۷	۴۳/۲۰	-۰/۵۹۱	-۰/۵۱۲
	۲	-۰/۳۶۳	۳۸/۱۲	-۰/۶۱۶	-۰/۵۲۹	-۰/۳۹۷	۴۳/۶۱	-۰/۵۹۲	-۰/۵۱۳
	۳	-۰/۳۶۴	۳۸/۲۷	-۰/۶۱۵	-۰/۵۳۲	-۰/۳۹۸	۴۴/۱۲	-۰/۵۹۰	-۰/۵۱۱
	۴	-۰/۳۶۵	۳۸/۳۲	-۰/۶۱۴	-۰/۵۳۲	-۰/۳۹۹	۴۴/۳۳	-۰/۵۹۰	-۰/۵۰۹
پلدختر	۱	-۰/۳۶۶	۳۸/۴۲	-۰/۶۱۳	-۰/۵۲۹	-۰/۴۰۱	۴۴/۴۱	-۰/۵۸۹	-۰/۵۰۹
	۲	-۰/۳۶۷	۳۸/۵۴	-۰/۶۱۲	-۰/۵۲۸	-۰/۴۰۲	۴۴/۷۱	-۰/۵۸۸	-۰/۵۰۹
	۳	-۰/۳۶۸	۳۸/۶۱	-۰/۶۱۱	-۰/۵۲۷	-۰/۴۰۲	۴۴/۸۲	-۰/۵۸۷	-۰/۵۰۸
	۴	-۰/۳۶۹	۳۸/۷۳	-۰/۶۱۰	-۰/۵۲۶	-۰/۴۰۳	۴۴/۹۳	-۰/۵۸۸	-۰/۵۰۷
نوزیان	۱	-۰/۳۷۱	۳۸/۸۱	-۰/۶۰۹	-۰/۵۲۵	-۰/۴۰۴	۴۴/۹۷	-۰/۵۸۹	-۰/۵۰۹
	۲	-۰/۳۷۲	۳۹/۰۴	-۰/۶۱۱	-۰/۵۲۴	-۰/۴۰۴	۴۵/۱۲	-۰/۵۹۱	-۰/۵۱۱
	۳	-۰/۳۷۳	۳۹/۲۳	-۰/۶۱۰	-۰/۵۲۳	-۰/۴۰۵	۴۵/۱۶	-۰/۵۹۳	-۰/۵۰۶
	۴	-۰/۳۷۴	۳۹/۴۲	-۰/۶۰۸	-۰/۵۲۳	-۰/۴۰۶	۴۵/۱۹	-۰/۵۸۸	-۰/۵۰۵
خرم آباد	۱	-۰/۳۷۴	۳۹/۵۷	-۰/۶۰۷	-۰/۵۲۲	-۰/۴۰۷	۴۶/۳۱	-۰/۵۸۷	-۰/۵۰۴
	۲	-۰/۳۷۵	۳۹/۶۳	-۰/۶۰۵	-۰/۵۲۱	-۰/۴۰۸	۴۶/۳۴	-۰/۵۸۷	-۰/۵۰۳
	۳	-۰/۳۷۱	۳۹/۷۴	-۰/۶۰۴	-۰/۵۲۰	-۰/۴۰۹	۴۶/۳۷	-۰/۵۸۶	-۰/۵۰۳
	۴	-۰/۳۷۵	۳۹/۹۹	-۰/۶۰۳	-۰/۵۱۹	-۰/۳۹۹	۴۶/۳۹	-۰/۵۸۵	-۰/۵۰۳
الشتر	۱	-۰/۳۷۵	۳۹/۸۷	-۰/۶۰۲	-۰/۵۱۸	-۰/۳۹۹	۴۶/۴۱	-۰/۵۸۵	-۰/۵۰۶
	۲	-۰/۳۷۵	۴۱/۲۳	-۰/۶۰۲	-۰/۵۱۸	-۰/۴۱۰	۴۶/۵۷	-۰/۵۸۴	-۰/۵۰۴
	۳	-۰/۳۷۶	۴۰/۷۸	-۰/۶۰۱	-۰/۵۱۷	-۰/۴۱۱	۴۶/۵۹	-۰/۵۸۳	-۰/۵۰۲
	۴	-۰/۳۷۷	۴۱/۳۳	-۰/۶۰۱	-۰/۵۱۷	-۰/۴۱۲	۴۶/۶۱	-۰/۵۸۳	-۰/۵۰۲
نورآباد	۱	-۰/۳۷۸	۴۱/۳۴	-۰/۶۰۱	-۰/۵۱۶	-۰/۴۱۳	۴۶/۷۲	-۰/۵۸۲	-۰/۵۰۱
	۲	-۰/۳۷۹	۴۱/۴۲	-۰/۵۹۹	-۰/۵۱۶	-۰/۴۱۳	۴۶/۷۵	-۰/۵۸۱	-۰/۴۹۷
	۳	-۰/۳۸۱	۴۱/۵۱	-۰/۵۹۸	-۰/۵۱۴	-۰/۴۱۴	۴۶/۷۹	-۰/۵۷۹	-۰/۴۹۹
	۴	-۰/۳۸۲	۴۱/۵۹	-۰/۵۹۷	-۰/۵۱۷	-۰/۴۱۵	۴۷/۱۲	-۰/۵۷۹	-۰/۴۹۸
درود	۱	-۰/۳۸۳	۴۱/۶۷	-۰/۵۹۶	-۰/۵۱۶	-۰/۴۱۶	۴۷/۲۴	-۰/۵۷۸	-۰/۴۹۶
	۲	-۰/۳۸۴	۴۱/۷۸	-۰/۵۹۵	-۰/۵۱۳	-۰/۴۱۷	۴۷/۳۶	-۰/۵۷۷	-۰/۴۹۶
	۳	-۰/۳۸۵	۴۱/۸۴	-۰/۵۹۴	-۰/۵۱۲	-۰/۴۱۸	۴۷/۴۲	-۰/۵۷۶	-۰/۴۹۶
	۴	-۰/۳۸۶	۴۱/۸۵	-۰/۵۹۳	-۰/۵۱۱	-۰/۴۱۹	۴۷/۵۱	-۰/۵۷۵	-۰/۴۹۵
بروجرد	۱	-۰/۳۸۶	۴۱/۹۳	-۰/۵۹۲	-۰/۵۰۹	-۰/۴۲۱	۴۷/۸۷	-۰/۵۷۴	-۰/۴۹۴
	۲	-۰/۳۸۷	۴۲/۰۷	-۰/۵۹۱	-۰/۵۰۸	-۰/۴۲۲	۴۷/۹۴	-۰/۵۷۹	-۰/۴۹۳
	۳	-۰/۳۸۸	۴۳/۱۲	-۰/۵۹۱	-۰/۵۰۷	-۰/۴۲۳	۴۸/۰۳	-۰/۵۷۳	-۰/۴۹۲
	۴	-۰/۳۸۹	۴۲/۵۶	-۰/۵۹۱	-۰/۵۰۶	-۰/۴۲۴	۴۸/۱۷	-۰/۵۷۲	-۰/۴۹۱
الیگودرز	۱	-۰/۳۹۱	۴۴/۱۲	-۰/۵۹۰	-۰/۵۰۵	-۰/۴۲۵	۴۸/۲۳	-۰/۵۷۱	-۰/۴۸۹
	۲	-۰/۳۹۲	۴۴/۵۶	-۰/۵۸۹	-۰/۵۰۴	-۰/۴۲۶	۴۸/۴۹	-۰/۵۶۹	-۰/۴۸۹
	۳	-۰/۳۹۲	۴۵/۱۳	-۰/۵۸۸	-۰/۵۰۳	-۰/۴۲۷	۴۸/۵۱	-۰/۵۶۸	-۰/۴۸۹
	۴	-۰/۳۹۳	۴۵/۲۷	-۰/۵۸۷	-۰/۵۰۳	-۰/۴۲۸	۴۸/۵۴	-۰/۵۶۹	-۰/۴۸۸
ازنا	۱	-۰/۳۹۴	۴۵/۳۶	-۰/۵۸۶	-۰/۵۰۲	-۰/۴۲۹	۴۸/۵۷	-۰/۵۷۱	-۰/۴۸۷
	۲	-۰/۳۹۵	۴۵/۴۴	-۰/۵۸۵	-۰/۴۹۸	-۰/۴۳۱	۴۸/۶۱	-۰/۵۶۶	-۰/۴۸۷
	۳	-۰/۳۹۶	۴۵/۵۱	-۰/۵۸۴	-۰/۵۰۴	-۰/۴۳۲	۴۸/۷۸	-۰/۵۶۵	-۰/۴۸۶
	۴	-۰/۳۹۷	۴۶/۰۳	-۰/۵۸۳	-۰/۴۹۷	-۰/۴۳۳	۴۸/۹۳	-۰/۵۶۴	-۰/۴۸۵

نشان می‌دهد که دقت روش ترکیبی XBeach- ELM برای پیش‌بینی طوفان گرد و غبار در ده ایستگاه استان لرستان در مقایسه با روش یادگیری سریع ELM و روش عددی XBeach به مراتب بیش‌تر است. با توجه به معنادار نبودن اختلاف میان نتایج دو مدل و همان‌طور که در جدول‌های ۲ و ۳ نمایش داده شده است، مدل‌های ELM و XBeach نتایج تقریباً یکسانی را نشان داده‌اند. در شکل ۳ مقادیر مشاهده‌شده و پیش‌بینی شده شاخص FDS در مرحله ارزیابی نمایش داده شده است. بدین ترتیب، می‌توان دریافت که ترکیب مدل‌های عددی و یادگیری ماشین منجر به بهبود دقت پیش‌بینی می‌شود. این امر به دلیل وجود نوری‌های لایه پنهان و ساختار پیچیده‌ای است که



این نوره‌ها در آن قرار دارند، از جمله چندضلعی‌های منتظم و نامنتظم، و همچنین نحوه پردازش ورودی و خروجی در مدل‌های ترکیبی. مطالعات پیشین نیز بر این برتری تأکید داشته‌اند. با این حال، یکی از چالش‌های اساسی این مدل‌ها، حجم بالای محاسبات مورد نیاز است. از سوی دیگر، مدل‌های عددی به دلیل سادگی ساختار، به محاسبات کمتری نیاز دارند اما دقت پایین‌تری نسبت به مدل‌های یادگیری ماشین در پیش‌بینی متغیرهای اقلیمی و تصادفی دارند. بنابراین، ترکیب این دو دسته مدل، نواقص هر یک را پوشش داده و منجر به بهبود هم‌زمان دقت و سرعت در فرایند پیش‌بینی می‌شود. بر این اساس، می‌توان نتیجه گرفت که تلفیق مدل‌های عددی و یادگیری ماشین، راهکاری کارآمد برای دستیابی به مدلی بهینه با دقت و سرعت مناسب در پیش‌بینی متغیرهای اقلیمی و هیدرولوژیکی است.

جدول ۳- نتایج پیش‌بینی شاخص FDS با مدل عددی کد باز XBeach

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	NS	MAPE	NRMSE	R	NS	MAPE	NRMSE
کوه‌دشت	۱	-۰/۶۸۴	-۰/۶۹۲	۳۳/۰۳	-۰/۳۰۳	-۰/۶۵۲	-۰/۶۸۷	۳۷/۱۰	-۰/۳۱۹
	۲	-۰/۶۸۳	-۰/۶۹۱	۳۳/۱۴	-۰/۳۰۳	-۰/۶۵۱	-۰/۶۸۷	۳۷/۱۷	-۰/۳۱۹
	۳	-۰/۶۸۲	-۰/۶۹۱	۳۳/۲۳	-۰/۳۰۱	-۰/۶۵۰	-۰/۶۸۶	۳۷/۳۴	-۰/۳۲۱
	۴	-۰/۶۸۱	-۰/۶۸۹	۳۳/۵۲	-۰/۳۰۱	-۰/۶۴۹	-۰/۶۸۵	۳۷/۴۲	-۰/۳۲۲
پلدختر	۱	-۰/۶۸۰	-۰/۶۸۸	۳۳/۶۱	-۰/۳۰۴	-۰/۶۵۳	-۰/۶۸۴	۳۷/۵۶	-۰/۳۲۳
	۲	-۰/۶۷۹	-۰/۶۸۷	۳۳/۷۳	-۰/۳۰۴	-۰/۶۴۷	-۰/۶۸۴	۳۷/۶۴	-۰/۳۱۹
	۳	-۰/۶۷۸	-۰/۶۸۶	۳۳/۸۲	-۰/۳۰۵	-۰/۶۴۷	-۰/۶۸۴	۳۷/۷۱	-۰/۳۲۱
	۴	-۰/۶۷۷	-۰/۶۸۵	۳۳/۸۵	-۰/۳۰۶	-۰/۶۴۷	-۰/۶۸۳	۳۷/۸۳	-۰/۳۲۴
نوژیان	۱	-۰/۶۷۶	-۰/۶۸۴	۳۳/۹۱	-۰/۳۰۷	-۰/۶۴۵	-۰/۶۸۲	۳۷/۹۵	-۰/۳۲۵
	۲	-۰/۶۸۱	-۰/۶۸۴	۳۳/۹۴	-۰/۳۰۸	-۰/۶۴۵	-۰/۶۸۱	۳۸/۱۲	-۰/۳۲۵
	۳	-۰/۶۷۹	-۰/۶۸۳	۳۴/۰۷	-۰/۳۰۹	-۰/۶۴۴	-۰/۶۸۰	۳۸/۲۳	-۰/۳۲۶
	۴	-۰/۶۷۵	-۰/۶۸۲	۳۴/۰۹	-۰/۳۱۰	-۰/۶۴۷	-۰/۶۷۹	۳۸/۳۴	-۰/۳۲۷
خرم آباد	۱	-۰/۶۸۲	-۰/۶۸۲	۳۴/۲۳	-۰/۳۱۱	-۰/۶۴۴	-۰/۶۷۸	۳۸/۴۲	-۰/۳۲۸
	۲	-۰/۶۸۲	-۰/۶۸۲	۳۴/۳۵	-۰/۳۱۲	-۰/۶۴۳	-۰/۶۷۷	۳۸/۵۶	-۰/۳۲۹
	۳	-۰/۶۸۱	-۰/۶۸۱	۳۴/۳۹	-۰/۳۱۳	-۰/۶۴۲	-۰/۶۷۶	۳۸/۹۳	-۰/۳۳۱
	۴	-۰/۶۸۷	-۰/۶۸۳	۳۴/۴۳	-۰/۳۱۴	-۰/۶۴۱	-۰/۶۷۵	۳۸/۹۹	-۰/۳۳۲
الشتر	۱	-۰/۶۸۴	-۰/۶۷۲	۳۴/۵۶	-۰/۳۱۵	-۰/۶۳۹	-۰/۶۷۴	۳۹/۰۴	-۰/۳۳۴
	۲	-۰/۶۸۱	-۰/۶۷۱	۳۴/۶۳	-۰/۳۱۶	-۰/۶۳۸	-۰/۶۷۳	۳۹/۱۳	-۰/۳۳۵
	۳	-۰/۶۸۱	-۰/۶۷۱	۳۴/۸۲	-۰/۳۱۴	-۰/۶۳۷	-۰/۶۷۲	۳۹/۲۳	-۰/۳۳۶
	۴	-۰/۶۸۱	-۰/۶۶۹	۳۴/۹۲	-۰/۳۱۳	-۰/۶۳۶	-۰/۶۷۱	۳۹/۳۷	-۰/۳۳۷
نورآباد	۱	-۰/۶۸۵	-۰/۶۶۹	۳۵/۱۲	-۰/۳۱۵	-۰/۶۳۵	-۰/۶۷۱	۳۹/۴۶	-۰/۳۳۸
	۲	-۰/۶۸۰	-۰/۶۶۸	۳۵/۲۵	-۰/۳۱۵	-۰/۶۳۴	-۰/۶۶۹	۳۹/۵۷	-۰/۳۳۹
	۳	-۰/۶۷۹	-۰/۶۶۷	۳۵/۴۲	-۰/۳۱۶	-۰/۶۳۳	-۰/۶۶۸	۳۹/۶۶	-۰/۳۴۱
	۴	-۰/۶۷۸	-۰/۶۶۶	۳۵/۴۷	-۰/۳۱۷	-۰/۶۳۲	-۰/۶۶۷	۳۹/۷۳	-۰/۳۴۲
درود	۱	-۰/۶۷۶	-۰/۶۶۵	۳۵/۵۳	-۰/۳۱۸	-۰/۶۳۱	-۰/۶۶۷	۳۹/۸۴	-۰/۳۴۳
	۲	-۰/۶۷۵	-۰/۶۶۴	۳۵/۷۳	-۰/۳۱۹	-۰/۶۳۰	-۰/۶۶۵	۳۹/۹۳	-۰/۳۴۴
	۳	-۰/۶۷۵	-۰/۶۶۳	۳۵/۷۹	-۰/۳۲۱	-۰/۶۳۰	-۰/۶۶۴	۴۰/۰۶	-۰/۳۴۵
	۴	-۰/۶۷۴	-۰/۶۶۲	۳۴/۹۳	-۰/۳۲۲	-۰/۶۳۰	-۰/۶۶۳	۴۰/۱۲	-۰/۳۴۶
بروجرد	۱	-۰/۶۷۳	-۰/۶۶۱	۳۵/۸۶	-۰/۳۲۳	-۰/۶۲۹	-۰/۶۶۲	۴۰/۲۸	-۰/۳۴۷
	۲	-۰/۶۷۲	-۰/۶۶۰	۳۵/۹۷	-۰/۳۲۴	-۰/۶۲۸	-۰/۶۶۱	۴۰/۳۱	-۰/۳۴۸
	۳	-۰/۶۷۱	-۰/۶۵۹	۳۶/۲۳	-۰/۳۲۵	-۰/۶۲۷	-۰/۶۶۰	۴۰/۳۹	-۰/۳۴۹
	۴	-۰/۶۷۰	-۰/۶۵۸	۳۶/۴۴	-۰/۳۲۶	-۰/۶۲۶	-۰/۶۵۹	۴۰/۵۲	-۰/۳۴۴
الیگودرز	۱	-۰/۶۷۰	-۰/۶۵۷	۳۶/۷۸	-۰/۳۲۷	-۰/۶۲۵	-۰/۶۵۸	۴۰/۷۸	-۰/۳۴۵
	۲	-۰/۶۶۹	-۰/۶۵۷	۳۶/۹۴	-۰/۳۲۸	-۰/۶۲۵	-۰/۶۵۷	۴۱/۲۲	-۰/۳۵۱
	۳	-۰/۶۶۸	-۰/۶۵۶	۳۷/۰۷	-۰/۳۲۹	-۰/۶۲۴	-۰/۶۵۶	۴۱/۵۳	-۰/۳۵۲
	۴	-۰/۶۶۷	-۰/۶۶۱	۳۷/۸۷	-۰/۳۳۱	-۰/۶۲۳	-۰/۶۵۶	۴۲/۰۳	-۰/۳۵۳
ازنا	۱	-۰/۶۶۶	-۰/۶۶۱	۳۸/۱۱	-۰/۳۳۲	-۰/۶۲۱	-۰/۶۶۱	۴۲/۷۸	-۰/۳۵۴
	۲	-۰/۶۶۵	-۰/۶۵۴	۳۸/۱۴	-۰/۳۳۳	-۰/۶۲۴	-۰/۶۵۴	۴۲/۹۴	-۰/۳۵۵
	۳	-۰/۶۶۵	-۰/۶۵۳	۳۸/۱۷	-۰/۳۳۴	-۰/۶۱۹	-۰/۶۵۴	۴۳/۰۱	-۰/۳۵۶
	۴	-۰/۶۶۴	-۰/۶۵۲	۳۸/۱۹	-۰/۳۳۵	-۰/۶۱۸	-۰/۶۵۳	۴۳/۳۴	-۰/۳۵۷

جدول ۴- نتایج پیش‌بینی شاخص FDSD با مدل XBeach-ELM

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	NS	MAPE	NRMSE	R	NS	MAPE	NRMSE
کوه‌دشت	۱	-۰/۹۷۳	-۰/۹۸۵	-۰/۳۴۱	-۰/۱۰۷	-۰/۹۹۲	-۰/۹۹۷	-۰/۳۰۴	-۰/۰۸۴
	۲	-۰/۹۷۵	-۰/۹۸۴	-۰/۳۵۲	-۰/۱۰۸	-۰/۹۹۱	-۰/۹۹۶	-۰/۳۰۵	-۰/۰۸۵
	۳	-۰/۹۷۲	-۰/۹۸۳	-۰/۳۵۵	-۰/۱۰۸	-۰/۹۸۹	-۰/۹۹۵	-۰/۳۰۵	-۰/۰۸۶
	۴	-۰/۹۷۲	-۰/۹۸۳	-۰/۳۶۳	-۰/۱۰۸	-۰/۹۸۸	-۰/۹۹۵	-۰/۳۰۵	-۰/۰۸۷
پلدختر	۱	-۰/۹۷۱	-۰/۹۸۲	-۰/۳۷۴	-۰/۱۰۹	-۰/۹۸۷	-۰/۹۹۵	-۰/۳۰۷	-۰/۰۸۹
	۲	-۰/۹۷۰	-۰/۹۸۱	-۰/۳۷۵	-۰/۱۰۴	-۰/۹۸۷	-۰/۹۹۴	-۰/۳۰۸	-۰/۰۸۹
	۳	-۰/۹۶۹	-۰/۹۸۴	-۰/۳۷۶	-۰/۱۱۰	-۰/۹۸۶	-۰/۹۹۶	-۰/۳۰۹	-۰/۰۸۹
	۴	-۰/۹۶۹	-۰/۹۸۳	-۰/۳۷۹	-۰/۱۱۱	-۰/۹۸۵	-۰/۹۹۳	-۰/۳۱۱	-۰/۰۹۱
نوزیان	۱	-۰/۹۶۸	-۰/۹۸۳	-۰/۳۸۱	-۰/۱۱۲	-۰/۹۸۴	-۰/۹۹۳	-۰/۳۱۲	-۰/۰۹۲
	۲	-۰/۹۶۷	-۰/۹۸۳	-۰/۳۸۲	-۰/۱۱۳	-۰/۹۸۴	-۰/۹۹۲	-۰/۳۱۴	-۰/۰۹۳
	۳	-۰/۹۶۷	-۰/۹۷۹	-۰/۳۸۳	-۰/۱۱۴	-۰/۹۸۳	-۰/۹۹۱	-۰/۳۱۵	-۰/۰۹۴
	۴	-۰/۹۶۷	-۰/۹۷۸	-۰/۳۸۵	-۰/۱۱۵	-۰/۹۸۲	-۰/۹۸۹	-۰/۳۱۷	-۰/۰۹۶
خرم آباد	۱	-۰/۹۷۱	-۰/۹۷۷	-۰/۳۸۶	-۰/۱۱۶	-۰/۹۸۲	-۰/۹۹۴	-۰/۳۱۷	-۰/۰۹۷
	۲	-۰/۹۶۶	-۰/۹۷۶	-۰/۳۹۱	-۰/۱۱۷	-۰/۹۸۱	-۰/۹۹۳	-۰/۳۱۷	-۰/۰۹۹
	۳	-۰/۹۶۵	-۰/۹۷۵	-۰/۴۰۱	-۰/۱۱۸	-۰/۹۸۱	-۰/۹۸۸	-۰/۳۱۹	-۰/۱۰۱
	۴	-۰/۹۶۴	-۰/۹۷۴	-۰/۴۰۳	-۰/۱۱۸	-۰/۹۷۹	-۰/۹۸۷	-۰/۳۲۱	-۰/۱۰۲
الشت	۱	-۰/۹۶۳	-۰/۹۷۳	-۰/۴۰۴	-۰/۱۱۸	-۰/۹۷۸	-۰/۹۸۶	-۰/۳۲۲	-۰/۱۰۲
	۲	-۰/۹۶۲	-۰/۹۷۲	-۰/۳۸۷	-۰/۱۱۹	-۰/۹۷۶	-۰/۹۸۵	-۰/۳۲۴	-۰/۱۰۲
	۳	-۰/۹۶۱	-۰/۹۷۱	-۰/۴۰۶	-۰/۱۲۱	-۰/۹۷۶	-۰/۹۸۴	-۰/۳۲۵	-۰/۱۰۳
	۴	-۰/۹۶۱	-۰/۹۷۳	-۰/۴۰۷	-۰/۱۲۲	-۰/۹۷۵	-۰/۹۸۳	-۰/۳۲۷	-۰/۱۰۴
نورآباد	۱	-۰/۹۶۱	-۰/۹۷۲	-۰/۴۰۹	-۰/۱۲۳	-۰/۹۷۴	-۰/۹۸۲	-۰/۳۲۸	-۰/۱۰۵
	۲	-۰/۹۵۹	-۰/۹۷۲	-۰/۴۱۳	-۰/۱۲۴	-۰/۹۷۳	-۰/۹۸۱	-۰/۳۲۹	-۰/۱۰۶
	۳	-۰/۹۵۸	-۰/۹۷۲	-۰/۴۱۷	-۰/۱۲۵	-۰/۹۷۲	-۰/۹۸۱	-۰/۳۳۱	-۰/۱۰۲
	۴	-۰/۹۵۷	-۰/۹۶۹	-۰/۴۱۹	-۰/۱۲۶	-۰/۹۷۱	-۰/۹۷۹	-۰/۳۳۴	-۰/۱۰۲
درود	۱	-۰/۹۵۷	-۰/۹۶۸	-۰/۴۲۳	-۰/۱۲۷	-۰/۹۶۹	-۰/۹۷۸	-۰/۳۳۵	-۰/۱۰۷
	۲	-۰/۹۵۶	-۰/۹۶۷	-۰/۴۲۴	-۰/۱۲۸	-۰/۹۶۸	-۰/۹۷۶	-۰/۳۳۷	-۰/۱۰۷
	۳	-۰/۹۵۵	-۰/۹۶۷	-۰/۴۲۵	-۰/۱۲۸	-۰/۹۶۷	-۰/۹۷۵	-۰/۳۳۹	-۰/۱۰۷
	۴	-۰/۹۵۴	-۰/۹۶۶	-۰/۴۲۷	-۰/۱۲۹	-۰/۹۶۶	-۰/۹۷۵	-۰/۳۴۱	-۰/۱۰۹
بروجرد	۱	-۰/۹۵۳	-۰/۹۷۲	-۰/۴۲۹	-۰/۱۳۱	-۰/۹۶۵	-۰/۹۷۴	-۰/۳۴۵	-۰/۱۱۳
	۲	-۰/۹۵۲	-۰/۹۶۵	-۰/۴۳۱	-۰/۱۳۲	-۰/۹۶۴	-۰/۹۷۳	-۰/۳۴۹	-۰/۱۱۲
	۳	-۰/۹۵۱	-۰/۹۶۴	-۰/۴۳۲	-۰/۱۳۳	-۰/۹۶۳	-۰/۹۷۲	-۰/۳۵۲	-۰/۱۱۱
	۴	-۰/۹۴۹	-۰/۹۶۳	-۰/۴۳۵	-۰/۱۳۴	-۰/۹۶۲	-۰/۹۷۱	-۰/۳۶۴	-۰/۱۱۴
الیگودرز	۱	-۰/۹۴۸	-۰/۹۶۲	-۰/۴۳۶	-۰/۱۳۵	-۰/۹۶۱	-۰/۹۷۱	-۰/۳۶۸	-۰/۱۱۵
	۲	-۰/۹۴۷	-۰/۹۶۱	-۰/۴۳۷	-۰/۱۳۶	-۰/۹۵۹	-۰/۹۷۱	-۰/۳۷۳	-۰/۱۱۶
	۳	-۰/۹۴۶	-۰/۹۶۱	-۰/۴۳۹	-۰/۱۳۷	-۰/۹۶۲	-۰/۹۶۹	-۰/۳۷۹	-۰/۱۱۷
	۴	-۰/۹۴۵	-۰/۹۵۹	-۰/۴۴۲	-۰/۱۳۸	-۰/۹۶۱	-۰/۹۶۸	-۰/۳۸۴	-۰/۱۱۸
ازنا	۱	-۰/۹۴۴	-۰/۹۵۸	-۰/۴۴۴	-۰/۱۳۸	-۰/۹۵۸	-۰/۹۶۷	-۰/۳۸۹	-۰/۱۱۹
	۲	-۰/۹۴۳	-۰/۹۵۷	-۰/۴۴۷	-۰/۱۳۴	-۰/۹۵۷	-۰/۹۶۷	-۰/۳۹۳	-۰/۱۲۱
	۳	-۰/۹۴۳	-۰/۹۵۶	-۰/۴۴۸	-۰/۱۳۶	-۰/۹۵۶	-۰/۹۶۶	-۰/۳۹۷	-۰/۱۲۲
	۴	-۰/۹۴۲	-۰/۹۵۴	-۰/۴۵۱	-۰/۱۳۹	-۰/۹۵۵	-۰/۹۶۵	-۰/۴۰۷	-۰/۱۲۳


بحث

هزینه و پیچیدگی مدل سازی طوفان های گرد و غبار مستقیماً به انتخاب مدل و روش پیش بینی وابسته است. مدل ELM به دلیل ساختار ساده و یادگیری سریع، گزینه ای کم هزینه و مناسب برای پیش بینی پدیده های پیچیده محسوب می شود، به ویژه زمانی که پردازش سریع مورد نیاز است. این مدل به منابع محاسباتی کمتری نیاز دارد و در مقایسه با مدل های پیچیده تر، هزینه اجرای آن کمتر است. با این حال، دقت پیش بینی آن در برخی شرایط ممکن است پایین تر باشد. بنابراین، در پروژه هایی که سرعت بالا و هزینه کمتر اولویت دارد، ELM می تواند انتخابی کارآمد باشد. در مقابل، مدل عددی کد باز XBeach نسبت به ELM محاسبات کمتری نیاز دارد، اما در شرایطی که دقت پیش بینی اهمیت بالایی دارد، مدل های ترکیبی می توانند عملکرد بهتری داشته باشند. ترکیب مدل های ELM و XBeach (روش XBeach-ELM) باعث افزایش هزینه و پیچیدگی مدل سازی می شود، زیرا اجرای آن نیازمند نیروی متخصص، سیستم های پردازشی قوی تر و منابع مالی بیشتر است. این مدل ترکیبی با بهره گیری از مزایای هر دو مدل، دقت پیش بینی را بهبود می بخشد، اما به منابع محاسباتی بیشتری نیاز دارد و زمان پردازش آن نیز طولانی تر خواهد بود. در پدیده های پیچیده و غیرخطی مانند گرد و غبار، که دقت بالا ضروری است، این روش می تواند عملکرد مناسبی ارائه دهد. با این حال، محدودیت های زمانی و محاسباتی باید در نظر گرفته شوند. اگر منابع محاسباتی محدود باشد یا زمان پیش بینی کوتاه باشد، مدل های ساده تر مانند XBeach توصیه می شود، اما در صورت نیاز به دقت بالاتر، ترکیب این مدل ها می تواند پیش بینی را بهبود بخشیده و نتایج بهتری ارائه دهد.


مقایسه میانگین مقادیر مشاهداتی و پیش بینی شده با استفاده از آزمون t نشان می دهد که فرض صفر، مبنی بر برابری میانگین سری های زمانی مشاهداتی و پیش بینی شده شاخص فراوانی روزهای طوفان گرد و غبار، در روش هیبریدی XBeach-ELM برای استان لرستان پذیرفته شده است (جدول ۵). بنابراین، تنها مدل هیبریدی توانسته است میانگین سری زمانی مشاهداتی را در پیش بینی طوفان گرد و غبار در استان لرستان حفظ کند، در حالی که این برابری در دو مدل انفرادی ELM و XBeach مشاهده نشده است. در تمامی ایستگاه های مورد بررسی، مقادیر مشاهداتی و پیش بینی شده دارای رابطه ای خطی با شیب تقریباً ۴۵ درجه هستند. در میان همه مدل ها، روش ترکیبی XBeach-ELM بیشترین میزان تطابق با نیم سازه ربع اول را نشان داده و بالاترین دقت را داشته است. شکل ۴ شاخص های ارزیابی مدل های مورد استفاده در مدل سازی طوفان های گرد و غبار را نمایش می دهد. در این شکل، معیارهای R ، $RMSE$ و NS برای ۱۰ ایستگاه سینوپتیک استان لرستان ارائه شده است. نتایج نشان می دهد که مدل ترکیبی XBeach-ELM با بالاترین مقدار ضریب همبستگی (نزدیک به یک) و کمترین میزان خطا در میان مدل های انفرادی، دقیق ترین عملکرد را در تمامی ایستگاه ها برای مدل سازی شاخص فراوانی روزهای همراه با طوفان گرد و غبار داشته است. این نتایج با یافته های دهشیری و همکاران (1402)، Abouhalima et al. (2024)، توفیقی و همکاران (۱۴۰۲) و عراقی نژاد و همکاران (۱۳۹۸) همخوانی دارد.

جدول ۵- آزمون مقایسه میانگین سری زمانی مشاهداتی و پیش بینی شده شاخص FDS

ایستگاه	مشاهداتی	میانگین				آماره t	
		ELM	XBeach	XBeach-ELM	ELM	XBeach	XBeach-ELM
کوه دشت	۰/۹۹۷	۰/۳۱۲	۰/۳۲۲	۰/۹۹۶	۰/۷۲۳	۰/۸۹۴	۲/۹۹۵
پلدختر	۰/۹۹۴	۰/۳۰۳	۰/۳۱۷	۰/۹۹۳	۰/۷۲۱	۰/۸۹۳	۲/۹۹۱
نورآباد	۰/۹۹۱	۰/۲۹۶	۰/۳۱۳	۰/۹۸۹	۰/۷۱۴	۰/۸۹۱	۲/۸۹۴
خرم آباد	۰/۹۸۶	۰/۲۹۳	۰/۳۰۳	۰/۹۸۵	۰/۷۱۲	۰/۸۸۶	۲/۸۹۳
الشت	۰/۹۸۵	۰/۲۹۱	۰/۲۹۹	۰/۹۸۳	۰/۷۰۶	۰/۸۸۴	۲/۷۲۶
نورآباد	۰/۹۸۳	۰/۲۹۴	۰/۲۹۸	۰/۹۸۱	۰/۷۰۲	۰/۸۸۳	۲/۷۱۳
درود	۰/۹۸۲	۰/۲۸۹	۰/۲۹۴	۰/۹۷۹	۰/۶۹۵	۰/۸۸۲	۲/۷۰۶
بروجرد	۰/۹۷۸	۰/۲۸۷	۰/۲۹۳	۰/۹۷۶	۰/۶۹۳	۰/۸۷۸	۲/۷۰۳
الیگودرز	۰/۹۷۳	۰/۲۷۷	۰/۲۸۴	۰/۹۷۲	۰/۶۸۶	۰/۸۷۶	۲/۶۹۵
ازنا	۰/۹۷۱	۰/۲۷۳	۰/۲۸۳	۰/۹۶۹	۰/۶۸۳	۰/۸۷۵	۰/۶۹۳



شکل ۳- مقایسه مقادیر مشاهده شده و پیش بینی شده شاخص FDSD در استان لرستان



شکل ۴- مقایسه شاخص‌های ارزیابی مدل بهینه برای مدل‌سازی طوفان گرد و غبار

نتیجه‌گیری

هدف از این پژوهش، مقایسه عملکرد الگوریتم یادگیری سریع ELM با مدل ریاضی کد باز XBeach برای ارائه روش ترکیبی XBeach-ELM برای پیش‌بینی طوفان‌های گرد و غبار در ده ایستگاه سینوپتیک استان لرستان بود. نتایج نشان داد که روش‌های یادگیری سریع ELM و مدل ریاضی کد باز XBeach هر یک به تنهایی عملکرد چندان خوبی را در مدل‌سازی طوفان‌های گرد و غبار در استان لرستان نشان ندادند. مقادیر خطای مدل‌سازی در همه ایستگاه‌های مورد مطالعه به‌ازای تمامی ترکیب‌ها، در روش عددی XBeach نسبت به مدل یادگیری سریع ELM، کاهش یافته است. همچنین ضرایب همبستگی و نش-ساتکلیف نیز افزایش یافته است.

با توجه به نبود اختلاف معنادار بین نتایج دو مدل ELM و XBeach، این مدل‌ها عملکردی مشابه داشتند اما نتوانستند برآورد دقیقی از شاخص فراوانی روزهای طوفانی ارائه دهند. در مقابل، نتایج این مطالعه نشان می‌دهد که دقت روش ترکیبی XBeach-ELM در پیش‌بینی این شاخص در ایستگاه‌های استان لرستان، به‌مراتب بیشتر از روش‌های انفرادی ELM و XBeach است. بهبود عملکرد این مدل ترکیبی ناشی از ترکیب توانمندی مدل عددی XBeach در شبیه‌سازی فرآیندهای فیزیکی و قابلیت الگوریتم ELM در تحلیل داده‌های پیچیده و شناسایی روابط غیرخطی است. مدل ELM، به دلیل ساختار ساده خود و قدرت پردازشی بالا سبب افزایش قدرت پیش‌بینی طوفان گرد و غبار می‌شود. این مدل، در مقایسه با سایر الگوریتم‌های یادگیری ماشین، به‌ویژه به دلیل سرعت بالای یادگیری، باعث کاهش زمان و حجم محاسبات شده بنابراین استفاده از آن در پیش‌بینی طوفان‌های گرد و غبار می‌تواند به بهبود مدیریت بحران و کاهش خسارات کمک کند. با این حال، در تمامی ایستگاه‌های مورد بررسی، مقادیر آماره t برای مدل ELM پایین‌تر از مقادیر مشاهداتی

بود که نشان‌دهنده اختلاف قابل‌توجه میان داده‌های پیش‌بینی‌شده و واقعی است. این امر حاکی از عملکرد ضعیف مدل ELM در برآورد شاخص FDSD است. مدل XBeach، اگرچه عملکرد بهتری نسبت به ELM داشت، اما همچنان دقت کافی برای پیش‌بینی این شاخص را نداشت. در مقابل، روش ترکیبی XBeach-ELM در تمامی ایستگاه‌ها عملکرد بهتری نشان داد. این بهبود ناشی از ترکیب مزایای مدل عددی XBeach در شبیه‌سازی طوفان‌های گردوغبار و قدرت الگوریتم ELM در تحلیل داده‌های پیچیده است. نتایج نشان می‌دهد که مدل‌های انفرادی ELM و XBeach، به‌تنهایی توانایی پیش‌بینی دقیق شاخص FDSD را ندارند، درحالی‌که مدل ترکیبی XBeach-ELM با کاهش اختلاف میان مقادیر پیش‌بینی‌شده و مشاهداتی، دقت بالاتری ارائه می‌دهد. به‌طور کلی، یافته‌های این پژوهش بر اهمیت استفاده از رویکردهای ترکیبی در مدل‌سازی طوفان‌های گردوغبار تأکید دارد. این روش می‌تواند به بهبود پیش‌بینی، مدیریت بحران، و کاهش خسارات ناشی از این پدیده کمک کند.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

منابع

- انصاری قوجقار، محمد و پورمحمد، پریا. (۱۴۰۳). مدل‌سازی طوفان‌های گرد و غبار با استفاده از مدل هیبریدی سه‌گانه GRNN- SVM- LSTM (مطالعه موردی: استان سیستان و بلوچستان). *تحقیقات آب و خاک ایران*. ۵۵ (۱۰). ۱۹۶۱-۱۹۷۹. doi: 10.22059/ijswr.2025.385882.669844
- درگاهیان، فاطمه؛ جلیلی، عادل؛ بالالان فرد، علیرضا و آقازاده، طاهره. (۱۴۰۳). تعیین پتانسیل تولید گرد و غبار در کانون‌های داخلی استان خوزستان با استفاده از مدل عددی WRF و مدل جفت شده WRF-Chem. *مخاطرات محیط طبیعی*. ۱۳ (۴۲). ۱۲۳-۱۴۰. doi: 10.22111/jneh.2024.47865.2026
- ملکی، سپهر؛ عجمی، مهدی و احمدی، احمد. (۱۴۰۳). مدل‌سازی عددی فرآیندهای موفولوژیکی ناحیه سواش در سواحل درشت‌دانه با مدل کد باز XBeach. *مجله ی مهندسی عمران شریف*.
- توفیقی، فرشاد؛ آرمانی، پرویز؛ چهارزی، علی و علی مرادی، اندیشه. (۱۴۰۲). مقایسه کارکرد مدل‌های ELM و RBF برای برآورد تخلخل سازند آسماری، در یکی از میدان‌های فراکرانه‌ای شمال باختری خلیج فارس. *پژوهش‌های چینه نگاری و رسوب شناسی*. ۳۹ (۲). ۴۵-۵۸. doi: 10.22108/jssr.2023.137083.1256

REFERENCES

- Abouhalima, M., das Neves, L., Taveira-Pinto, F., & Rosa-Santos, P. (2024). Machine Learning in Coastal Engineering: Applications, Challenges, and Perspectives. *Journal of Marine Science and Engineering*, 12(4), 638.
- Al-Haija, Q. A., Altamimi, S., & AlWadi, M. (2024). Analysis of Extreme Learning Machines (ELMs) for intelligent intrusion detection systems: A survey. *Expert Systems with Applications*, 124317.
- Ansari ghoghhar, M. and Pourmohammad, P. (2024). Dust Storm Modeling Using the Triple Hybrid Model GRNN-SVM-LSTM (Case Study: Sistan and Baluchestan Province). *Iranian Journal of Soil and Water Research*, 55(10), 1961-1979. doi: 10.22059/ijswr.2025.385882.669844. (In Persian).
- Anselin L, Syabri I, Kho Y (2009) An Introduction to Spatial Data Analysis. In Fischer MM, Getis A (eds) *Handbook of applied spatial analysis*, Berlin, Heidelberg and New York, Springer.
- Atay H, Ahmadi F (2010) Study of dust as one of the environmental problems of the Islamic world. Case study of Khuzestan province. *The Fourth International Congress of Geographers of the Islamic World*. Zahedan 138.
- Berard, N. A., Mulligan, R. P., da Silva, A. M. F., & Dibajnia, M. (2017). Evaluation of XBeach performance for the erosion of a laboratory sand dune. *Coastal Engineering*, 125, 70-80.
- Bolle, A., Mercelis, P., Roelvink, D., Haerens, P., & Trouw, K. (2011). Application and validation of XBeach for three different field sites. *Coastal Engineering Proceedings*, (32), 40-40.
- Buttò, S., Faraci, C. L., Corradino, M., Iuppa, C., Colica, E., & Pepe, F. (2024). Evaluating longshore sediment transport: A comparison between empirical formulas and XBeach 2DH numerical model. *Marine Geology*, 107471.
- D. Roelvink, A. Reniers, A. van Dongeren, J. van Thiel de Vries, R. McCall, J. Lescinski, *Modelling storm impacts on beaches, dunes and barrier islands*, Coast.
- D. Roelvink, A. Reniers, J. Ap van Dongeren, T. van, J.L. de Vries, R. McCall, *XBeach Model Description and Manual - v6*, Deltares, Delft, The Netherlands, 2010, p. 108.



- Dargahian, F. , Jalili, A. , Balalan Fard, A. and Aghazadeh, T. (2024). Determining the potential of dust production in the inner centers of Khuzestan province using the WRF numerical model and the WRF-Chem coupled model. *Journal of Natural Environmental Hazards*, 13(42), 123-140. doi: 10.22111/jneh.2024.47865.2026. Eng. 56 (11-12) (2009) 1133-1152. (In A comparison of the ELM algorithm and XBeach model Persian)
- Gelvez-Almeida, E., Mora, M., Barrientos, R. J., Hernández-García, R., Vilches-Ponce, K., & Vera, M. (2024). A Review on Large-Scale Data Processing with Parallel and Distributed Randomized Extreme Learning Machine Neural Networks. *Mathematical and Computational Applications*, 29(3), 40.
- Harter, C., & Figlus, J. (2017). Numerical modeling of the morphodynamic response of a low-lying barrier island beach and foredune system inundated during Hurricane Ike using XBeach and CSHORE. *Coastal Engineering*, 120, 64-74. <https://doi.org/10.1016/j.coastaleng.2016.11.005>.
- Hayawi, H., Al-Hashimi, M., & Alawjar, M. (2024). Machine learning methods for modelling and predicting dust storms in Iraq. *Statistics, Optimization & Information Computing*.
- Kolokythas, G. A., Raquel, S., & Blanco, M. R. D. (2016, June). Morphological evolution of a bed profile induced by a storm event at the Belgian coast predicted by Xbeach model. In *ISOPE International Ocean and Polar Engineering Conference* (pp. ISOPE-I). ISOPE.
- Maleki, S. , Adjami, M. and Ahmadi, A. (2024). Numerical Modeling of Swash Zone Morphological Processes in Coarse-Grained Beaches with XBeach Open-Source Model. *Sharif Journal of Civil Engineering*, (), -. doi: 10.24200/j30.2024.63280.3266. (In Persian).
- Mei, S., You, W., Zhong, W., Zang, Z., Guo, J., & Xiang, Q. (2024). Optimizing the Numerical Simulation of the Dust Event of March 2021: Integrating Aerosol Observations through Multi-Scale 3D Variational Assimilation in the WRF-Chem Model. *Remote Sensing*, 16(11), 1852.
- 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.
- Roelvink, D., & Costas, S. (2019). Coupling nearshore and aeolian processes: XBeach and duna process-based models. *Environmental Modelling & Software*, 115, 98-112.
- Roelvink, D., Reniers, A., Van Dongeren, A. P., De Vries, J. V. T., McCall, R., & Lescinski, J. (2009). Modelling storm impacts on beaches, dunes and barrier islands. *Coastal engineering*, 56(11-12), 1133-1152.
- Tofighi, F. , Armani, P. , Chehrazi, A. and Alimoradi, A. (2023). Comparison of the function of ELM and RBF models for estimating the porosity of the Asmari Formation, in one of the offshore fields of the northwest Persian Gulf. *Journal of Stratigraphy and Sedimentology Researches*, 39(2), 45-58. doi: 10.22108/jssr.2023.137083.1256. (In Persian).
- Turkashvand M, Kayani Gh (2017) Analysis of Air Pollution Situation Due to the Climatic Effects of Fragrances and Hurricanes in the Southern Regions of Hamadan Province. *Journal of Environmental Science and Technology*, 19 (4).
- Y. Kongsorot, P. Horata, and K. Sunat, "Applying Regularization Least Squares Canonical Correlation Analysis in Extreme Learning Machine for Multi-label Classification Problems," in *Proceedings of ELM-2014 Volume 1*, Springer, 2015, pp. 377-396.
- 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.
- Yarmohamadi, M., Alesheikh, A. A., Sharif, M., & Vahidi, H. (2023). Predicting dust-storm transport pathways using a convolutional neural network and geographic context for impact adaptation and mitigation in urban areas. *Remote Sensing*, 15(9), 2468.
- Zhang, R., Su, J., & Feng, J. (2024). An extreme learning machine model based on adaptive multi-fusion chaotic sparrow search algorithm for regression and classification. *Evolutionary Intelligence*, 17(3), 1567-1586.