

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

ABSTRACT

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.

Keywords: *Horizontal visibility, Machine Learning, FDSD, Numerical modeling, Goodness-of-fit criteria.*

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 FDSI 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)

چکیده

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، خرم‌آباد، پل دختر، نوژیان، درود، ازنا و الیگودرز) در طول دوره آماری ۵۰ ساله (۲۰۲۰-۱۹۷۱) به منظور ارائه روش تلفیقی XBeach- ELM جهت 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 زودهنگام 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 ماشینی، FDSD، روش‌های عددی، معیار نیکویی برازش.

مقدمه

طوفان‌های گرد و غبار 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 قابل‌توجهی 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 شمال‌غرب عراق، غرب سوریه و شرق و جنوب‌شرق 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

¹ Dust storms

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^۱ (IBk) برای مناطق بصره و نینوا و الگوریتم تنبل^۲ (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)^۳ حاصل شده است. پس از آن، فرامدل انفرادی ماشین بردار پشتیبان^۴ 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^۵ 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 درصدی 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 WRF^۶ 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 بررسی پژوهش‌های مختلف می‌توان دریافت که مدل‌های انفرادی و هیبریدی دوگانه بر پایه یادگیری ماشین و الگوریتم‌های فراابتکاری بهینه‌سازی برای مدل‌سازی دقیق شاخص FDSD مورد استفاده قرار گرفته است اما تاکنون هیچ یک از مطالعات به بررسی تأثیر یک مدل عددی و ترکیب آن با مدل‌های یادگیری ماشین یا یادگیری عمیق به‌منظور پیش‌بینی طوفان‌های گرد و غبار نپرداخته‌اند لذا هدف از این پژوهش، مقایسه عملکرد یک الگوریتم یادگیری سریع با مدل ریاضی کد باز XBeach جهت 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 کدباز جهت مدل‌سازی طوفان‌های گرد و

¹ Instance-Based k-nearest neighbor

² KStar Lazy Algorithm

³ Frequency of Dust Storm Days

⁴ Support Vector Machine

⁵ Convolutional Neural Network

⁶ Weather Research and Forecasting

غبار ترکیب شده است و به تبع آن با عملکرد الگوریتم انفرادی یادگیری سریع^۱ ELM و مدل عددی کدباز XBeach مورد مقایسه قرار گرفته است. روش یادگیری ماشین سریع ELM به دلیل سرعت بالا و دقت مناسب در مدل سازی پدیده های غیرخطی، ابزاری کارآمد برای پیش بینی طوفان های گرد و غبار محسوب می شود. این روش با آموزش سریع شبکه های عصبی و توانایی پردازش داده های چندمنبعی، امکان تحلیل دقیق تر و سریع تر این پدیده ها را فراهم می کند. همچنین، ELM به دلیل عدم نیاز به تنظیم دوباره وزن ها و استفاده از الگوریتم های تکراری، هزینه محاسباتی کمتری نسبت به سایر روش های هوش مصنوعی دارد و می تواند به صورت ترکیبی با مدل های عددی برای بهبود پیش بینی استفاده شود. از سوی دیگر، مدل عددی کدباز XBeach به دلیل دقت بالا در شبیه سازی فرآیندهای پیچیده و قابلیت انعطاف در تنظیمات مختلف، یکی از ابزارهای قدرتمند در مدل سازی است. این مدل می تواند به طور مؤثر اثرات تغییرات محیطی را در مقیاس های زمانی و مکانی مختلف پیش بینی کند. همچنین، XBeach به دلیل توانایی شبیه سازی همزمان چندین فرآیند فیزیکی، مانند جریان ها، فرسایش و انتقال رسوبات، امکان ارزیابی همه جانبه از شرایط مختلف را فراهم می آورد. علاوه بر این، استفاده از XBeach می تواند زمان و هزینه های محاسباتی را کاهش دهد و به پژوهشگران این امکان را می دهد که راهکارهای بهینه تری برای مسائل پیچیده پیدا کنند.

روش شناسی پژوهش

منطقه مورد مطالعه

در این پژوهش به مقایسه عملکرد الگوریتم یادگیری سریع ELM با مدل کد باز XBeach به منظور ارائه روش تلفیقی ELM-XBeach در ده ایستگاه سینوپتیک استان لرستان (نورآباد، الشتر، بروجرد، کوهدشت، خرم آباد، پل دختر، نوژیان، درود، ازنا و الیگودرز)، مطابق شکل ۱، با جامعه آماری بلندمدت ۵۰ ساله (۲۰۲۰-۱۹۷۱) پرداخته شده است. بدین منظور از داده های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی استفاده شد. مشاهدات پدیده های هواشناسی در هشت سینوپ در طول شبانه روز ثبت می شوند. در این مشاهدات، پدیده های بصری آب و هوا طبق دستورالعمل سازمان جهانی هواشناسی در ۱۰۰ کد مانند جدول ۱، تعریف شده اند. از مجموع این ۱۰۰ کد، به طور کلی ۱۱ کد، طبق جدول ۱، برای ثبت و گزارش پدیده گرد و غبار در ایستگاه های مختلف هواشناسی استفاده می شود (O'Loingsigh et al., 2014). روز همراه با طوفان های 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 و ۳۵) در بخش گزارش هوای حاضر اعلام شده باشد. مشروط بر این که، داده های قدرت دید افقی متناظر با کد اعلام شده، کم تر از ۱۰۰۰ متر ثبت شده باشد (Mohammadi, 2015). در پژوهش حاضر، از مولفه دید افقی ۱۰۰۰ م برای تمامی کدهای گرد و غبار جهت تشخیص طوفان های گرد و غبار، استفاده شده است.


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

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

^۱ Extreme Learning Machine

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

فیلد



شکل ۱- معرفی ایستگاه های 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؛ 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 غلطان، 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

¹ Single-Layer Feedforward Neural Networks

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 سری‌زمانی 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.


$$FDSD_{(t+1)} = f(FDSD_{(t)})$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)})$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)}, FDSD_{(t-2)})$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)}, FDSD_{(t-2)}, FDSD_{(t-3)})$$

مدل یک
مدل دو
مدل سه
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 (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.

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (f_i - O_i)^2}{N}}}{O_i} \quad \text{رابطه ۱}$$

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

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

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

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 جهت 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

¹ Correlation

² Root Mean Square Error

³ Mean Absolute Percentage Error

⁴ Nash- Sutcliffe

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 ۲- نتایج پیش‌بینی شاخص FDSD با مدل یادگیری سریع ELM

ایستگاه	شماره ترکیب	مجموعه داده آموزش			مجموعه داده آزمون		
		R	NRMSE	MAPE	NS	R	NRMSE
کوه‌دشت	۱	۰/۳۶۲	۳۸/۰۲	۰/۶۱۷	۰/۵۳۱	۰/۳۹۷	۴۳/۲۰
	۲	۰/۳۶۳	۳۸/۱۲	۰/۶۱۶	۰/۵۲۹	۰/۳۹۷	۴۳/۶۱
	۳	۰/۳۶۴	۳۸/۲۷	۰/۶۱۵	۰/۵۳۴	۰/۳۹۸	۴۴/۱۲
	۴	۰/۳۶۵	۳۸/۳۲	۰/۶۱۴	۰/۵۳۲	۰/۳۹۹	۴۴/۳۳
پلدختر	۱	۰/۳۶۶	۳۸/۴۲	۰/۶۱۳	۰/۵۲۹	۰/۴۰۱	۴۴/۴۱
	۲	۰/۳۶۷	۳۸/۵۴	۰/۶۱۲	۰/۵۲۸	۰/۴۰۲	۴۴/۷۱
	۳	۰/۳۶۸	۳۸/۶۱	۰/۶۱۱	۰/۵۲۷	۰/۴۰۲	۴۴/۸۲
	۴	۰/۳۶۹	۳۸/۷۳	۰/۶۱۰	۰/۵۲۶	۰/۴۰۳	۴۴/۹۳
نوژیان	۱	۰/۳۷۱	۳۸/۸۱	۰/۶۰۹	۰/۵۲۵	۰/۴۰۴	۴۴/۹۷
	۲	۰/۳۷۲	۳۹/۰۴	۰/۶۱۱	۰/۵۲۴	۰/۴۰۴	۴۵/۱۲
	۳	۰/۳۷۳	۳۹/۲۳	۰/۶۱۰	۰/۵۲۳	۰/۴۰۵	۴۵/۱۶
	۴	۰/۳۷۴	۳۹/۴۲	۰/۶۰۸	۰/۵۲۳	۰/۴۰۶	۴۵/۱۹
خرم‌آباد	۱	۰/۳۷۴	۳۹/۵۷	۰/۶۰۷	۰/۵۲۲	۰/۴۰۷	۴۶/۳۱
	۲	۰/۳۷۵	۳۹/۶۳	۰/۶۰۵	۰/۵۲۱	۰/۴۰۸	۴۶/۳۴
	۳	۰/۳۷۱	۳۹/۷۴	۰/۶۰۴	۰/۵۲۰	۰/۴۰۹	۴۶/۳۷
	۴	۰/۳۷۵	۳۹/۹۹	۰/۶۰۳	۰/۵۱۹	۰/۳۹۹	۴۶/۳۹
الشتر	۱	۰/۳۷۵	۳۹/۸۷	۰/۶۰۲	۰/۵۱۸	۰/۳۹۹	۴۶/۴۱
	۲	۰/۳۷۵	۴۱/۲۳	۰/۶۰۲	۰/۵۱۸	۰/۴۱۰	۴۶/۵۷
	۳	۰/۳۷۶	۴۰/۷۸	۰/۶۰۱	۰/۵۱۷	۰/۴۱۱	۴۶/۵۹
	۴	۰/۳۷۷	۴۱/۳۳	۰/۶۰۱	۰/۵۱۷	۰/۴۱۲	۴۶/۶۱
نورآباد	۱	۰/۳۷۸	۴۱/۳۴	۰/۶۰۱	۰/۵۱۶	۰/۴۱۳	۴۶/۷۲
	۲	۰/۳۷۹	۴۱/۴۲	۰/۵۹۹	۰/۵۱۶	۰/۴۱۳	۴۶/۷۵
	۳	۰/۳۸۱	۴۱/۵۱	۰/۵۹۸	۰/۵۱۴	۰/۴۱۴	۴۶/۷۹
	۴	۰/۳۸۲	۴۱/۵۹	۰/۵۹۷	۰/۵۱۷	۰/۴۱۵	۴۷/۱۲
درود	۱	۰/۳۸۳	۴۱/۶۷	۰/۵۹۶	۰/۵۱۶	۰/۴۱۶	۴۷/۲۴
	۲	۰/۳۸۴	۴۱/۷۸	۰/۵۹۵	۰/۵۱۳	۰/۴۱۷	۴۷/۳۶
	۳	۰/۳۸۵	۴۱/۸۴	۰/۵۹۴	۰/۵۱۲	۰/۴۱۸	۴۷/۴۲
	۴	۰/۳۸۶	۴۱/۸۵	۰/۵۹۳	۰/۵۱۱	۰/۴۱۹	۴۷/۵۱
بروجرد	۱	۰/۳۸۶	۴۱/۹۳	۰/۵۹۲	۰/۵۰۹	۰/۴۲۱	۴۷/۸۷

۰/۴۹۳	۰/۵۷۹	۴۷/۹۴	۰/۴۲۲	۰/۵۰۸	۰/۵۹۱	۴۲/۰۷	۰/۳۸۷	۲	الیگودرز
۰/۴۹۲	۰/۵۷۳	۴۸/۰۳	۰/۴۲۳	۰/۵۰۷	۰/۵۹۱	۴۳/۱۲	۰/۳۸۸	۳	
۰/۴۹۱	۰/۵۷۲	۴۸/۱۷	۰/۴۲۴	۰/۵۰۶	۰/۵۹۱	۴۲/۵۶	۰/۳۸۹	۴	
۰/۴۸۹	۰/۵۷۱	۴۸/۲۳	۰/۴۲۵	۰/۵۰۵	۰/۵۹۰	۴۴/۱۲	۰/۳۹۱	۱	
۰/۴۸۹	۰/۵۶۹	۴۸/۴۹	۰/۴۲۶	۰/۵۰۴	۰/۵۸۹	۴۴/۵۶	۰/۳۹۲	۲	ازنا
۰/۴۸۹	۰/۵۶۸	۴۸/۵۱	۰/۴۲۷	۰/۵۰۳	۰/۵۸۸	۴۵/۱۳	۰/۳۹۲	۳	
۰/۴۸۸	۰/۵۶۹	۴۸/۵۴	۰/۴۲۸	۰/۵۰۳	۰/۵۸۷	۴۵/۲۷	۰/۳۹۳	۴	
۰/۴۸۷	۰/۵۷۱	۴۸/۵۷	۰/۴۲۹	۰/۵۰۲	۰/۵۸۶	۴۵/۳۶	۰/۳۹۴	۱	
۰/۴۸۷	۰/۵۶۶	۴۸/۶۱	۰/۴۳۱	۰/۴۹۸	۰/۵۸۵	۴۵/۴۴	۰/۳۹۵	۲	
۰/۴۸۶	۰/۵۶۵	۴۸/۷۸	۰/۴۳۲	۰/۵۰۴	۰/۵۸۴	۴۵/۵۱	۰/۳۹۶	۳	
۰/۴۸۵	۰/۵۶۴	۴۸/۹۳	۰/۴۳۳	۰/۴۹۷	۰/۵۸۳	۴۶/۰۳	۰/۳۹۷	۴	

جدول شماره ۳ نتایج مدل سازی طوفان های گرد و غبار را با استفاده از مدل عددی کد باز XBeach نشان می دهد. همان طور که مشخص است، در ایستگاه های نوژیان و خرم آباد، 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 پیش بینی، به ۰/۳۲۵ و ۳۷/۹۵ درصد و ۰/۳۲۸ و ۳۸/۴۲ درصد، در نتیجه استفاده از داده های یک فصل گذشته جهت مدل سازی طوفان های گرد و غبار، به طور نسبی کاهش پیدا کرده است. این روند نشان می دهد که استفاده از داده های اخیر (یک فصل گذشته) نسبت به داده های بلندمدت تر (چهار فصل گذشته) در کاهش میزان خطا تأثیر نسبی داشته است. از سوی دیگر، مقدار خطا در همه ایستگاه های مورد مطالعه به ازای تمامی ترکیب ها، نسبت به مدل یادگیری سریع ELM، کاهش یافته است. همچنین ضرایب همبستگی و نش-ساتکلیف نیز نسبت به نتایج مدل سازی 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 بیش ترین فراوانی روزهای همراه با طوفان گرد و غبار در مقیاس فصلی را در استان دارد) و ایستگاه ازنا (با کم ترین فراوانی فصلی)، می توان نتیجه گرفت که هر چه از تعداد روزهای گرد و غباری در ایستگاه های مورد بررسی کاسته می شود، از دقت پیش بینی طوفان های گرد و غبار در این استان کاسته می شود. این روند احتمالاً به محدودیت داده های موجود در ایستگاه های با تعداد روزهای گرد و غباری کمتر و کاهش دقت مدل در شرایط داده های کم مرتبط است.

جدول ۳- نتایج پیش بینی شاخص FDSO با مدل عددی کد باز XBeach

ایستگاه	شماره ترکیب	مجموعه داده آموزش			مجموعه داده آزمون		
		NRMSE	MAPE	NS	R	NRMSE	MAPE
کوهدشت	۱	۰/۳۰۳	۳۳/۰۳	۰/۶۹۲	۰/۶۸۴	۰/۳۱۹	۳۷/۱۰
	۲	۰/۳۰۳	۳۳/۱۴	۰/۶۹۱	۰/۶۸۳	۰/۳۱۹	۳۷/۱۷
	۳	۰/۳۰۱	۳۳/۲۳	۰/۶۹۱	۰/۶۸۲	۰/۳۲۱	۳۷/۳۴
	۴	۰/۳۰۱	۳۳/۵۲	۰/۶۸۹	۰/۶۸۱	۰/۳۲۲	۳۷/۴۲
پلدختر	۱	۰/۳۰۴	۳۳/۶۱	۰/۶۸۸	۰/۶۸۰	۰/۳۲۳	۳۷/۵۶
	۲	۰/۳۰۴	۳۳/۷۳	۰/۶۸۷	۰/۶۷۹	۰/۳۱۹	۳۷/۶۴
	۳	۰/۳۰۵	۳۳/۸۲	۰/۶۸۶	۰/۶۷۸	۰/۳۲۱	۳۷/۷۱
	۴	۰/۳۰۶	۳۳/۸۵	۰/۶۸۵	۰/۶۷۷	۰/۳۲۴	۳۷/۸۳
نوژیان	۱	۰/۳۰۷	۳۳/۹۱	۰/۶۸۴	۰/۶۷۶	۰/۳۲۵	۳۷/۹۵
	۲	۰/۳۰۸	۳۳/۹۴	۰/۶۸۴	۰/۶۸۱	۰/۳۲۵	۳۸/۱۲

۰/۶۴۴	۰/۶۸۰	۳۸/۲۳	۰/۳۲۶	۰/۶۷۹	۰/۶۸۳	۳۴/۰۷	۰/۳۰۹	۳	خرم آباد
۰/۶۴۷	۰/۶۷۹	۳۸/۳۴	۰/۳۲۷	۰/۶۷۵	۰/۶۸۲	۳۴/۰۹	۰/۳۱۰	۴	
۰/۶۴۴	۰/۶۷۸	۳۸/۴۲	۰/۳۲۸	۰/۶۷۵	۰/۶۸۲	۳۴/۲۳	۰/۳۱۱	۱	
۰/۶۴۳	۰/۶۷۷	۳۸/۵۶	۰/۳۲۹	۰/۶۷۵	۰/۶۸۲	۳۴/۳۵	۰/۳۱۲	۲	
۰/۶۴۲	۰/۶۷۶	۳۸/۹۳	۰/۳۳۱	۰/۶۷۴	۰/۶۸۱	۳۴/۳۹	۰/۳۱۳	۳	
۰/۶۴۱	۰/۶۷۵	۳۸/۹۹	۰/۳۳۲	۰/۶۷۳	۰/۶۸۷	۳۴/۴۳	۰/۳۱۴	۴	الشتر
۰/۶۳۹	۰/۶۷۴	۳۹/۰۴	۰/۳۳۴	۰/۶۷۲	۰/۶۸۴	۳۴/۵۶	۰/۳۱۵	۱	
۰/۶۳۸	۰/۶۷۳	۳۹/۱۳	۰/۳۳۵	۰/۶۷۱	۰/۶۸۱	۳۴/۶۳	۰/۳۱۶	۲	
۰/۶۳۷	۰/۶۷۲	۳۹/۲۳	۰/۳۳۶	۰/۶۷۱	۰/۶۸۱	۳۴/۸۲	۰/۳۱۴	۳	
۰/۶۳۶	۰/۶۷۱	۳۹/۳۷	۰/۳۳۷	۰/۶۶۹	۰/۶۸۱	۳۴/۹۲	۰/۳۱۳	۴	
۰/۶۳۵	۰/۶۷۱	۳۹/۴۶	۰/۳۳۸	۰/۶۶۹	۰/۶۸۵	۳۵/۱۲	۰/۳۱۵	۱	نورآباد
۰/۶۳۴	۰/۶۶۹	۳۹/۵۷	۰/۳۳۹	۰/۶۶۸	۰/۶۸۰	۳۵/۲۵	۰/۳۱۵	۲	
۰/۶۳۳	۰/۶۶۸	۳۹/۶۶	۰/۳۴۱	۰/۶۶۷	۰/۶۷۹	۳۵/۴۲	۰/۳۱۶	۳	
۰/۶۳۲	۰/۶۶۷	۳۹/۷۳	۰/۳۴۲	۰/۶۶۶	۰/۶۷۸	۳۵/۴۷	۰/۳۱۷	۴	
۰/۶۳۱	۰/۶۶۷	۳۹/۸۴	۰/۳۴۳	۰/۶۶۵	۰/۶۷۶	۳۵/۵۳	۰/۳۱۸	۱	
۰/۶۳۰	۰/۶۶۵	۳۹/۹۳	۰/۳۴۴	۰/۶۶۴	۰/۶۷۵	۳۵/۷۳	۰/۳۱۹	۲	درد
۰/۶۳۰	۰/۶۶۴	۴۰/۰۶	۰/۳۴۵	۰/۶۶۳	۰/۶۷۵	۳۵/۷۹	۰/۳۲۱	۳	
۰/۶۳۰	۰/۶۶۳	۴۰/۱۲	۰/۳۴۶	۰/۶۶۲	۰/۶۷۴	۳۴/۹۳	۰/۳۲۲	۴	
۰/۶۲۹	۰/۶۶۲	۴۰/۲۸	۰/۳۴۷	۰/۶۶۱	۰/۶۷۳	۳۵/۸۶	۰/۳۲۳	۱	
۰/۶۲۸	۰/۶۶۱	۴۰/۳۱	۰/۳۴۸	۰/۶۶۰	۰/۶۷۲	۳۵/۹۷	۰/۳۲۴	۲	
۰/۶۲۷	۰/۶۶۰	۴۰/۳۹	۰/۳۴۹	۰/۶۵۹	۰/۶۷۱	۳۶/۲۳	۰/۳۲۵	۳	الیگودرز
۰/۶۲۶	۰/۶۵۹	۴۰/۵۲	۰/۳۴۴	۰/۶۵۸	۰/۶۷۰	۳۶/۴۴	۰/۳۲۶	۴	
۰/۶۲۵	۰/۶۵۸	۴۰/۷۸	۰/۳۴۵	۰/۶۵۷	۰/۶۷۰	۳۶/۷۸	۰/۳۲۷	۱	
۰/۶۲۵	۰/۶۵۷	۴۱/۲۲	۰/۳۵۱	۰/۶۵۷	۰/۶۶۹	۳۶/۹۴	۰/۳۲۸	۲	
۰/۶۲۴	۰/۶۵۶	۴۱/۵۳	۰/۳۵۲	۰/۶۵۶	۰/۶۶۸	۳۷/۰۷	۰/۳۲۹	۳	
۰/۶۲۳	۰/۶۵۶	۴۲/۰۳	۰/۳۵۳	۰/۶۶۱	۰/۶۶۷	۳۷/۸۷	۰/۳۳۱	۴	ازنا
۰/۶۲۱	۰/۶۶۱	۴۲/۷۸	۰/۳۵۴	۰/۶۶۱	۰/۶۶۶	۳۸/۱۱	۰/۳۳۲	۱	
۰/۶۲۴	۰/۶۵۴	۴۲/۹۴	۰/۳۵۵	۰/۶۵۴	۰/۶۶۵	۳۸/۱۴	۰/۳۳۳	۲	
۰/۶۱۹	۰/۶۵۴	۴۲/۰۱	۰/۳۵۶	۰/۶۵۳	۰/۶۶۵	۳۸/۱۷	۰/۳۳۴	۳	
۰/۶۱۸	۰/۶۵۳	۴۳/۳۴	۰/۳۵۷	۰/۶۵۲	۰/۶۶۴	۳۸/۱۹	۰/۳۳۵	۴	

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-سانکلیف نیز در مقایسه با مدل یادگیری سریع ELM و مدل عددی XBeach، افزایش قابل ملاحظه‌ای داشته است. به عنوان 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 ۰/۰۳۷۴ درصد با روش تلفیقی XBeach- ELM به مقدار چشم‌گیری کاهش یافته است. بدین ترتیب، نتایج به دست آمده نشان می‌دهد که دقت روش ترکیبی XBeach- ELM جهت 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 FDSD 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 نوروهای لایه پنهان و ساختار پیچیده‌ای است که این نوروها 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 ۴- نتایج پیش‌بینی شاخص FDS با مدل XBeach-ELM

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	NS	MAPE	NRMSE	R	NS	MAPE	NRMSE
کوه‌دشت	۱	۰/۹۹۲	۰/۹۹۷	۰/۳۰۴	۰/۰۸۴	۰/۹۷۳	۰/۹۸۵	۰/۳۴۱	۰/۱۰۷
	۲	۰/۹۹۱	۰/۹۹۶	۰/۳۰۵	۰/۰۸۵	۰/۹۷۵	۰/۹۸۴	۰/۳۵۲	۰/۱۰۸
	۳	۰/۹۸۹	۰/۹۹۵	۰/۳۰۵	۰/۰۸۶	۰/۹۷۲	۰/۹۸۳	۰/۳۵۵	۰/۱۰۸
	۴	۰/۹۸۸	۰/۹۹۵	۰/۳۰۵	۰/۰۸۷	۰/۹۷۲	۰/۹۸۳	۰/۳۶۳	۰/۱۰۸
پلدختر	۱	۰/۹۸۷	۰/۹۹۵	۰/۳۰۷	۰/۰۸۹	۰/۹۷۱	۰/۹۸۲	۰/۳۷۴	۰/۱۰۹
	۲	۰/۹۸۷	۰/۹۹۴	۰/۳۰۸	۰/۰۸۹	۰/۹۷۰	۰/۹۸۱	۰/۳۷۵	۰/۱۰۴
	۳	۰/۹۸۶	۰/۹۹۶	۰/۳۰۹	۰/۰۸۹	۰/۹۶۹	۰/۹۸۴	۰/۳۷۶	۰/۱۱۰
	۴	۰/۹۸۵	۰/۹۹۳	۰/۳۱۱	۰/۰۹۱	۰/۹۶۹	۰/۹۸۳	۰/۳۷۹	۰/۱۱۱
نورآباد	۱	۰/۹۸۴	۰/۹۹۳	۰/۳۱۲	۰/۰۹۲	۰/۹۶۸	۰/۹۸۳	۰/۳۸۱	۰/۱۱۲
	۲	۰/۹۸۴	۰/۹۹۲	۰/۳۱۴	۰/۰۹۳	۰/۹۶۷	۰/۹۸۳	۰/۳۸۲	۰/۱۱۳
	۳	۰/۹۸۳	۰/۹۹۱	۰/۳۱۵	۰/۰۹۴	۰/۹۶۷	۰/۹۷۹	۰/۳۸۳	۰/۱۱۴
	۴	۰/۹۸۲	۰/۹۸۹	۰/۳۱۷	۰/۰۹۶	۰/۹۶۷	۰/۹۷۸	۰/۳۸۵	۰/۱۱۵
خرم‌آباد	۱	۰/۹۸۲	۰/۹۹۴	۰/۳۱۷	۰/۰۹۷	۰/۹۷۱	۰/۹۷۷	۰/۳۸۶	۰/۱۱۶
	۲	۰/۹۸۱	۰/۹۹۳	۰/۳۱۷	۰/۰۹۹	۰/۹۶۶	۰/۹۷۶	۰/۳۹۱	۰/۱۱۷
	۳	۰/۹۸۸	۰/۳۱۹	۰/۱۰۱	۰/۹۶۵	۰/۹۷۵	۰/۴۰۱	۰/۱۱۸	۰/۱۱۸
	۴	۰/۹۸۷	۰/۳۲۱	۰/۱۰۲	۰/۹۶۴	۰/۹۷۳	۰/۴۰۳	۰/۱۱۸	۰/۱۱۸
الشت	۱	۰/۹۸۶	۰/۳۲۲	۰/۱۰۲	۰/۹۶۳	۰/۹۷۳	۰/۴۰۴	۰/۱۱۸	۰/۱۱۸
	۲	۰/۹۸۵	۰/۳۲۴	۰/۱۰۲	۰/۹۶۲	۰/۹۷۲	۰/۳۸۷	۰/۱۱۹	۰/۱۱۹
	۳	۰/۹۸۴	۰/۳۲۵	۰/۱۰۳	۰/۹۶۱	۰/۹۷۱	۰/۴۰۶	۰/۱۲۱	۰/۱۲۱
	۴	۰/۹۸۳	۰/۳۲۷	۰/۱۰۴	۰/۹۶۱	۰/۹۷۳	۰/۴۰۷	۰/۱۲۲	۰/۱۲۲
نورآباد	۱	۰/۹۸۲	۰/۳۲۸	۰/۱۰۵	۰/۹۶۱	۰/۹۷۲	۰/۴۰۹	۰/۱۲۳	۰/۱۲۳
	۲	۰/۹۸۱	۰/۳۲۹	۰/۱۰۶	۰/۹۵۹	۰/۹۷۲	۰/۴۱۳	۰/۱۲۴	۰/۱۲۴
	۳	۰/۹۸۱	۰/۳۳۱	۰/۱۰۲	۰/۹۵۸	۰/۹۷۲	۰/۴۱۷	۰/۱۲۵	۰/۱۲۵
	۴	۰/۹۷۹	۰/۳۳۴	۰/۱۰۲	۰/۹۵۷	۰/۹۶۹	۰/۴۱۹	۰/۱۲۶	۰/۱۲۶
درود	۱	۰/۹۷۸	۰/۳۳۵	۰/۱۰۷	۰/۹۵۷	۰/۹۶۸	۰/۴۲۳	۰/۱۲۷	۰/۱۲۷
	۲	۰/۹۷۶	۰/۳۳۷	۰/۱۰۷	۰/۹۵۶	۰/۹۶۷	۰/۴۲۴	۰/۱۲۸	۰/۱۲۸
	۳	۰/۹۷۵	۰/۳۳۹	۰/۱۰۷	۰/۹۵۵	۰/۹۶۷	۰/۴۲۵	۰/۱۲۸	۰/۱۲۸
	۴	۰/۹۷۵	۰/۳۴۱	۰/۱۰۹	۰/۹۵۴	۰/۹۶۶	۰/۴۲۷	۰/۱۲۹	۰/۱۲۹

بروجرد	۱	۰/۱۱۳	۰/۳۴۵	۰/۹۷۴	۰/۹۶۵	۰/۱۳۱	۰/۴۲۹	۰/۹۷۲	۰/۹۵۳
	۲	۰/۱۱۲	۰/۳۴۹	۰/۹۷۳	۰/۹۶۴	۰/۱۳۲	۰/۴۳۱	۰/۹۶۵	۰/۹۵۲
	۳	۰/۱۱۱	۰/۳۵۳	۰/۹۷۲	۰/۹۶۳	۰/۱۳۳	۰/۴۳۲	۰/۹۶۴	۰/۹۵۱
	۴	۰/۱۱۴	۰/۳۶۴	۰/۹۷۱	۰/۹۶۲	۰/۱۳۴	۰/۴۳۵	۰/۹۶۳	۰/۹۴۹
الیگودرز	۱	۰/۱۱۵	۰/۳۶۸	۰/۹۷۱	۰/۹۶۱	۰/۱۳۵	۰/۴۳۶	۰/۹۶۲	۰/۹۴۸
	۲	۰/۱۱۶	۰/۳۷۳	۰/۹۷۱	۰/۹۵۹	۰/۱۳۶	۰/۴۳۷	۰/۹۶۱	۰/۹۴۷
	۳	۰/۱۱۷	۰/۳۷۹	۰/۹۶۹	۰/۹۶۲	۰/۱۳۷	۰/۴۳۹	۰/۹۶۱	۰/۹۴۶
	۴	۰/۱۱۸	۰/۳۸۴	۰/۹۶۸	۰/۹۶۱	۰/۱۳۸	۰/۴۴۲	۰/۹۵۹	۰/۹۴۵
ازنا	۱	۰/۱۱۹	۰/۳۸۹	۰/۹۶۷	۰/۹۵۸	۰/۱۳۸	۰/۴۴۴	۰/۹۵۸	۰/۹۴۴
	۲	۰/۱۲۱	۰/۳۹۳	۰/۹۶۷	۰/۹۵۷	۰/۱۳۴	۰/۴۴۷	۰/۹۵۷	۰/۹۴۳
	۳	۰/۱۲۲	۰/۳۹۷	۰/۹۶۶	۰/۹۵۶	۰/۱۳۶	۰/۴۴۸	۰/۹۵۶	۰/۹۴۳
	۴	۰/۱۲۳	۰/۴۰۷	۰/۹۶۵	۰/۹۵۵	۰/۱۳۹	۰/۴۵۱	۰/۹۵۴	۰/۹۴۲

بحث



هزینه و پیچیدگی مدل‌سازی طوفان‌های گرد و غبار مستقیماً به انتخاب مدل و روش پیش‌بینی وابسته است. مدل ELM به دلیل ساختار ساده و یادگیری سریع، گزینه‌ای کم‌هزینه و مناسب برای پیش‌بینی پدیده‌های پیچیده محسوب می‌شود، به‌ویژه زمانی که پردازش سریع موردنیاز است. این مدل به منابع محاسباتی کمتری نیاز دارد و در مقایسه با مدل‌های پیچیده‌تر، هزینه اجرای آن کمتر است. با این حال، دقت پیش‌بینی آن در برخی شرایط ممکن است پایین‌تر باشد. بنابراین، در پروژه‌هایی که سرعت بالا و هزینه کمتر اولویت دارد، ELM می‌تواند انتخابی کارآمد باشد. در مقابل، مدل عددی کدباز XBeach نسبت به ELM محاسبات کمتری نیاز دارد، اما در شرایطی که دقت پیش‌بینی اهمیت بالایی دارد، مدل‌های ترکیبی می‌توانند عملکرد بهتری داشته باشند. ترکیب مدل‌های ELM و XBeach (XBeach-ELM) باعث افزایش هزینه و پیچیدگی مدل‌سازی می‌شود، زیرا اجرای آن نیازمند نیروی متخصص، سیستم‌های پردازشی قوی‌تر و منابع مالی بیشتر است. این مدل ترکیبی با بهره‌گیری از مزایای هر دو مدل، دقت پیش‌بینی را بهبود می‌بخشد، اما به منابع محاسباتی بیشتری نیاز دارد و زمان پردازش آن نیز طولانی‌تر خواهد بود. در پدیده‌های پیچیده و غیرخطی مانند گرد و غبار، که دقت بالا ضروری است، این روش می‌تواند عملکرد مناسبی ارائه دهد. با این حال، محدودیت‌های زمانی و محاسباتی باید در نظر گرفته شوند. اگر منابع محاسباتی محدود باشد یا زمان پیش‌بینی کوتاه باشد، مدل‌های ساده‌تر مانند XBeach توصیه می‌شود، اما در صورت نیاز به دقت بالاتر، ترکیب این مدل‌ها می‌تواند پیش‌بینی را بهبود بخشیده و نتایج بهتری ارائه دهد.


مقایسه میانگین مقادیر مشاهداتی و پیش‌بینی‌شده با استفاده از آزمون t نشان می‌دهد که فرض صفر، مبنی بر برابری میانگین سری‌های زمانی مشاهداتی و پیش‌بینی‌شده 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 پیش‌بینی 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 ایستگاه‌های مورد بررسی، مقادیر مشاهداتی و پیش‌بینی‌شده دارای رابطه‌ای خطی با شیب تقریباً ۴۵ درجه هستند. در میان همه مدل‌ها، روش ترکیبی XBeach-ELM بیشترین میزان تطابق با نیم‌ساز ربع اول را نشان داده و بالاترین دقت را داشته است. شکل ۴ شاخص‌های ارزیابی مدل‌های مورد استفاده در مدل‌سازی طوفان‌های گرد و غبار را نمایش می‌دهد. در این شکل، معیارهای R ، $RMSE$ و NS برای ۱۰ ایستگاه سینوپتیک استان لرستان ارائه شده است. نتایج نشان می‌دهد که مدل ترکیبی XBeach-ELM با بالاترین مقدار ضریب همبستگی (نزدیک به یک) و کمترین میزان خطا در میان مدل‌های انفرادی، دقیق‌ترین عملکرد را در تمامی ایستگاه‌ها برای مدل‌سازی

شاخص فراوانی روزهای همراه با طوفان گرد و غبار داشته است. این نتایج با یافته‌های دهشیری و همکاران (1402)، Abouhalima et al. (2024)، توفیقی و همکاران (۱۴۰۲) و عراقی‌نژاد و همکاران (۱۳۹۸) همخوانی دارد.


جدول ۵- آزمون مقایسه میانگین سری زمانی مشاهداتی و پیش‌بینی شده شاخص FDSD

میانگین			آماره t			
مشاهداتی	ELM	XBeach	XBeach-ELM	ELM	XBeach	XBeach-ELM
کوه‌دشت	۰/۳۱۲	۰/۳۲۲	۰/۹۹۶	۰/۷۲۳	۰/۸۹۴	۲/۹۹۵
پلدختر	۰/۳۰۳	۰/۳۱۷	۰/۹۹۳	۰/۷۲۱	۰/۸۹۳	۲/۹۹۱
نوزیان	۰/۲۹۶	۰/۳۱۳	۰/۹۸۹	۰/۷۱۴	۰/۸۹۱	۲/۸۹۴
خرم‌آباد	۰/۲۹۳	۰/۳۰۳	۰/۹۸۵	۰/۷۱۲	۰/۸۸۶	۲/۸۹۳
الشت	۰/۲۹۱	۰/۲۹۹	۰/۹۸۳	۰/۷۰۶	۰/۸۸۴	۲/۷۲۶
نورآباد	۰/۲۹۴	۰/۲۹۸	۰/۹۸۱	۰/۷۰۲	۰/۸۸۳	۲/۷۱۳
درود	۰/۲۸۶	۰/۲۹۴	۰/۹۷۹	۰/۶۹۵	۰/۸۸۲	۲/۷۰۶
بروجرد	۰/۲۸۷	۰/۲۹۳	۰/۹۷۶	۰/۶۹۳	۰/۸۷۸	۲/۷۰۳
الیگودرز	۰/۲۶۱	۰/۲۸۴	۰/۹۷۲	۰/۶۸۶	۰/۸۷۶	۲/۶۹۵
ازنا	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 جهت مدل‌سازی طوفان گرد و غبار

نتیجه‌گیری

هدف از این پژوهش، مقایسه عملکرد الگوریتم یادگیری سریع ELM با مدل ریاضی کد باز XBeach جهت 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 چندانی 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 قابل توجه میان داده‌های پیش‌بینی شده 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 پیش‌بینی شده 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 توسط نویسندگان وجود ندارد."

مراجع

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 ghoghghar, 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 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. , Chehrazai, 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.

پایگاه استنادی نشریات