



Dust Storm Modeling Using the Triple Hybrid Model GRNN-SVM-LSTM (Case Study: Sistan and Baluchestan Province)

Mohammad Ansari ghojghar¹ | Paria Pourmohammad²

1. Corresponding Author, Department of Reclamation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Iran. Email: Ansari.ghojghar@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

Article type: Research Article

Article history:

Received: Nov. 23, 2024

Revised: Dec. 22, 2024

Accepted: Jan. 8, 2024

Published online: Dec. 2024

Keywords:

Dust,
Prediction,
Support Vector Machine (SVM),
Generalized Regression Neural
Network (GRNN),
Sistan and Baluchestan.

ABSTRACT

Dust storms pose significant environmental and economic challenges, particularly in arid regions like Sistan-Baluchestan Province, Iran. This study aims to compare the performance of individual models (GRNN and SVM) with a triple hybrid model (GRNN-SVM-LSTM) for forecasting the frequency of dust storm days (FDSD). Using hourly dust data from eight SYNOP codes of the World Meteorological Organization across five synoptic stations, spanning a 40-year period (1980–2020), the models were evaluated based on key performance metrics: Correlation Coefficient (R), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Nash-Sutcliffe Efficiency (NS). The triple hybrid model outperformed all other approaches, achieving the highest predictive accuracy in seasonal combinations 1 and 2. The SVM model ranked second, while the GRNN model performed relatively better in combinations 1 and 2 compared to combination 4. Overall, the GRNN-SVM-LSTM model demonstrated superior predictive performance for FDSD, with RMSE = 0.523–0.501, R = 0.999–0.989, MAE = 0.441–0.421, and NS = 0.907–0.893. These findings highlight the potential of the proposed model for improving dust storm forecasting and developing early warning systems.

Cite this article: Ansari Ghojghar, M., & 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. <https://doi.org/10.22059/ijswr.2025.385882.669844>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2025.385882.669844>



EXTENDED ABSTRACT

Introduction

Dust storms are among the most significant natural hazards affecting arid and semi-arid regions, particularly in Iran, where they cause considerable environmental, health, and economic damage. These phenomena are driven by a combination of climatic factors and human activities, including land-use changes and deforestation. This study aims to evaluate the performance of a hybrid machine learning model that integrates General Regression Neural Network (GRNN), Support Vector Machine (SVM), and Long Short-Term Memory (LSTM) for predicting the frequency of dust storm days (FDSD). The analysis focuses on five meteorological stations in Sistan and Baluchestan Province, utilizing a 40-year dataset (1980–2020) comprising hourly visibility and weather codes defined by the World Meteorological Organization (WMO). The increasing frequency and intensity of dust storms in arid and semi-arid regions, particularly in Iran, necessitates accurate forecasting tools to mitigate their adverse environmental, economic, and health impacts. Traditional methods often fail to capture the complex nonlinear relationships between climatic variables and dust storm occurrences. By integrating advanced machine learning techniques, the GRNN-SVM-LSTM model addresses this limitation, offering a robust framework for improved planning, resource management, and policy development to reduce the negative impacts of these natural hazards. This study enhances the understanding of dust storm dynamics and provides actionable insights for policymakers and environmental managers to formulate effective mitigation strategies. The primary objective is to develop and assess the hybrid GRNN-SVM-LSTM model for predicting FDSD in Sistan and Baluchestan Province. Furthermore, the study compares the hybrid model's performance with individual GRNN and SVM models to improve forecasting accuracy and reliability based on climatic and meteorological variables.

Method

The study investigates the GRNN-SVM-LSTM hybrid model and compares its performance with individual GRNN and SVM models for predicting the FDSD index across five meteorological stations: Zabol, Zahedan, Khash, Iranshahr, and Saravan. The analysis utilizes a 40-year dataset (1980–2020) that includes hourly horizontal visibility data and WMO weather codes. Meteorological observations were recorded every three hours, resulting in eight synoptic reports per day. Three distinct models were employed to predict FDSD: two standalone models, GRNN and SVM, and a hybrid GRNN-SVM-LSTM model. The models' performances were assessed using goodness-of-fit metrics, with the prediction horizon varying from one to four past seasons. Initially, the performance of the individual GRNN and SVM models was analyzed. The next step involved evaluating recurrent neural networks (RNNs) for processing time series and sequential data. Long Short-Term Memory (LSTM) networks, a specialized RNN architecture designed to learn and retain patterns in long-term time series data, were then integrated into the hybrid model. The LSTM architecture includes memory units capable of preserving information over time, making it particularly effective for complex sequential data. Given the multifaceted nature of dust storms, adopting a hybrid model is essential for accurately capturing both linear and nonlinear variables influencing these phenomena. Therefore, this study employs the GRNN-SVM-LSTM hybrid model to provide a novel and comprehensive forecasting approach.

Results

The General Regression Neural Network (GRNN) model, implemented in R, demonstrated the best performance when using FDSD data from two previous seasons. The Root Mean Squared Error (RMSE) improved significantly across all five stations when compared to using data from four prior seasons. Similarly, the Support Vector Machine (SVM) model, also implemented in R, achieved optimal performance with FDSD data from one or two previous seasons. The GRNN-SVM-LSTM hybrid model outperformed both standalone models in predicting the FDSD index across all five stations. The hybrid model exhibited substantial improvements in the correlation coefficient and Nash-Sutcliffe efficiency, highlighting its superior forecasting capabilities. In conclusion, the hybrid GRNN-SVM-LSTM model delivered the most accurate predictions for FDSD in the Sistan and Baluchestan region, surpassing the standalone GRNN and SVM models. This superior performance underscores the potential of integrating advanced machine learning techniques for effective dust storm forecasting.

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.

مدل سازی طوفان های گرد و غبار با استفاده از مدل هیبریدی سه گانه GRNN- SVM- LSTM (مطالعه موردی: استان سیستان و بلوچستان)

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.ghojghar@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

تاریخ دریافت: ۱۴۰۳/۹/۳

تاریخ بازنگری: ۱۴۰۳/۱۰/۲

تاریخ پذیرش: ۱۴۰۳/۱۰/۱۹

تاریخ انتشار: دیماه ۱۴۰۳

واژه های کلیدی:

گرد و غبار،

پیش بینی،

ماشین بردار پشتیبان،

شبکه عصبی رگرسیون تعمیم یافته،

سیستان و بلوچستان.

هدف از این پژوهش مقایسه عملکرد فرامدل های انفرادی GRNN و SVM با مدل هیبریدی سه گانه GRNN- SVM- LSTM به منظور پیش بینی فراوانی روزهای همراه با طوفان گرد و غبار در فصل آبی می باشد. بدین منظور از داده های ساعتی گرد و غبار در هشت سینوپ و کدهای سازمان جهانی هواشناسی در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان در طول دوره آماری ۴۰ ساله (۱۹۸۰-۲۰۲۰) استفاده شده است. معیارهای MAE, RMSE, R و NS به منظور ارزیابی و مقایسه مدل ها استفاده شدند. نتایج این پژوهش نشان داد که مدل هیبریدی سه گانه پیشنهادی نسبت به سایر روش ها بیشترین عملکرد را داشته است. همچنین بیشترین دقت این مدل در ترکیبات فصلی ۱ و ۲ آن به منظور پیش بینی شاخص FDSM حاصل شده است. پس از آن، فرامدل انفرادی SVM در رتبه بندی از لحاظ عملکرد قرار گرفت. این مدل نیز در ترکیبات یک و دو بهترین عملکرد را داشت. مدل شبکه عصبی رگرسیون تعمیم یافته نیز در ترکیبات ۱ و ۲ عملکرد نسبتاً بهتری را در مقایسه با ترکیب چهارم نمایش داده است. مدل هیبریدی سه گانه GRNN- SVM- LSTM با ریشه میانگین مربعات خطا ($RMSE=0.523-0.501$)، ضریب همبستگی ($R=0.999-0.989$)، میانگین قدرمطلق خطا ($MAE=0.441-0.421$) و ضریب نش-سانتکیف ($0.893-0.907$) بهترین عملکرد را نسبت به سایر مدل های استفاده شده برای پیش بینی شاخص FDSM نمایش داده است.

استناد: انصاری قوجقار؛ محمد، پورمحمد؛ پریا (۱۴۰۳) مدل سازی طوفان های گرد و غبار با استفاده از مدل هیبریدی سه گانه GRNN- SVM- LSTM (مطالعه موردی: استان سیستان و بلوچستان)، مجله تحقیقات آب و خاک ایران، ۵۵ (۱۰)، ۱۹۷۹-۱۹۶۱. <https://doi.org/10.22059/ijswr.2025.385882.669844>

ناشر: مؤسسه انتشارات دانشگاه تهران.

© نویسندگان.



DOI: <https://doi.org/10.22059/ijswr.2025.385882.669844>

مقدمه

طوفان‌های گرد و غبار و ماسه و وزش بادهای شدید یکی از مخرب‌ترین بلایای طبیعی مناطق خشک، نیمه‌خشک و بیابانی دنیا است که هرساله خسارت‌های بی‌شمار و جبران‌ناپذیری به انسان‌ها، محیط‌زیست و سایر موجودات زنده وارد می‌کند (حیدرنژاد و همکاران، ۱۳۹۲؛ خوش کیش، ۱۳۹۰). این طوفان‌ها سالیانه حدوداً ۲۰۰۰ میلیون تن خاک به جو وارد می‌کند که از این مقدار ۵ درصد در خشکی‌ها و ۲۵ درصد در اقیانوس‌ها ترسیب می‌شوند (Shao et al., 2011). فراوانی رخداد این پدیده در مناطق خشک و نیمه‌خشک و به‌ویژه در عرض‌های جنب حاره‌ای بسیار بیش‌تر از سایر مناطق در جهان است (عباسی و همکاران، ۱۳۷۸). هرچه اقلیم حاکم بر منطقه‌ای خشک‌تر باشد، احتمال وقوع خشک‌سالی در آن بیش‌تر و به طبع رخداد گرد و غبار متحمل‌تر است (شاکر سوره و اسدی، ۱۳۹۸؛ انصاری قوجقار و همکاران، ۱۳۹۹). 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). منابع انتشاردهنده گرد و غبار به دو دسته به‌صورت زیر تقسیم‌بندی می‌شوند. در دسته اول، شرایط ناپایدار و خشک حاکم بر محیط به‌همراه وزش باد سبب ایجاد گرد و غبار می‌شوند که این شرایط عمدتاً در کمربند بیابانی جهان بیش‌تر از سایر نقاط است. کشور ایران نیز با فرارگیری در کمربند بیابانی جهان، جزو مناطق خشک و نیمه‌خشک محسوب می‌شود و تقریباً ۲۵ درصد از مساحت ایران در مناطق فراخشک و در سیطره این طوفان‌ها قرار دارد (Goudie et al., 2006). اگرچه بیشتر طوفان‌های گردوغبار، به‌ویژه در ایران، خاستگاه منطقه‌ای دارند، اما کانون‌های محلی در کمربند گردوغبار و به‌ویژه در ایران، نقشی چشمگیر دارند. تعداد روزهای غبارآلود در ایران با روزهای بارانی رابطه‌ای معکوس دارد؛ بنابراین، گردوغبار به‌طور عمده در مناطق گرم و کم‌بارش کشور دیده می‌شود (حیدری نژاد و همکاران، ۱۴۰۱). در دسته دوم، انسان و دخالت‌های انسانی صورت‌گرفته در منابع طبیعی و محیط‌زیست شامل تغییر کاربری اراضی، مدیریت ضعیف و ناکارآمد منابع آبی (رمضانی و همکاران، ۱۳۸۹)، جنگل‌زدایی و ... از جمله مهم‌ترین منابع تولید گرد و غبار محسوب می‌شوند (راشکی و همکاران، ۱۳۹۱). وقوع پدیده خشک‌سالی در جنوب، مرکز و غرب ایران و همچنین کشورهای عراق، عربستان و سوریه، با کاهش رطوبت سطحی و زیر سطحی خاک و نابودی پوشش گیاهی همراه می‌باشد. لذا پهنه‌های رسوبی برجای مانده که حاوی ذرات ریزدانه هستند، اصلی‌ترین علت تشدید گرد و غبار در مناطق ذکرشده می‌باشند (ولی و همکاران، ۱۳۹۸).

گرد و غبار براساس قابلیت مشاهده و همچنین شدت آن، به سه دسته طوفان گرد و غبار^۱، گرد و غبار وزشی^۲ و گرد و غبار معلق^۳ دسته‌بندی می‌شود. طوفان‌های گرد و غبار شدیدترین نوع از وقوع گرد و غبار است که کاملاً هوا را آلوده کرده و سبب کاهش دید افقی را به کم‌تر از ۱۰۰۰ متر می‌شود. در صورتی که این طوفان‌ها بسیار شدید باشند، شعاع دید افقی حدوداً به صفر می‌رسد. در دسته دوم، گرد و غبار با شدتی متوسط رخ داده که به آن گرد و غبار وزشی می‌گویند. ارتفاع زیاد بادهای حامل مقداری گرد و غبار و شن، این نوع از گرد و غبار را با کاهش دید افقی از ۱۰۰۰ تا ۱۰۰۰۰ متر ایجاد می‌کند. کم‌ترین شدت وقوع گرد و غبار نیز به گرد و غبار معلق نسبت داده می‌شود که در آن دید افقی تا کم‌تر از ۱۰۰۰۰ متر محدود می‌شود (شاهسونی و همکاران، ۱۳۸۹). در سال‌های اخیر، به‌دلیل افزایش رخداد طوفان‌های گرد و غبار، شناسایی، پایش و پیش‌بینی روند تکامل آن‌ها ضروری می‌باشد. شبکه عصبی مصنوعی نوعی ساختار ریاضی می‌باشد که می‌تواند فرآیندها و ترکیب‌های غیرخطی دلخواه برای ارتباط میان ورودی و خروجی هر سیستم را نشان دهد (انصاری قوجقار و همکاران، ۱۳۹۹). شبکه عصبی مصنوعی با دریافت داده‌های موجود در فرآیند یادگیری، تحت آموزش قرار گرفته و از آن‌ها برای پیش‌بینی در آینده استفاده می‌کند. بدین ترتیب درمی‌یابیم که این شبکه دارای ویژگی‌هایی چون توانایی یادگیری، قابلیت تعمیم و پردازش موازی می‌باشد (Dahiya et al., 2007). در دهه‌های اخیر، روش‌های هوش مصنوعی و شبکه‌های عصبی مصنوعی (جعبه سیاه)، مانند شبکه عصبی مصنوعی^۴، ماشین بردار پشتیبان^۵، منطق فازی^۶، الگوریتم ژنتیک^۷ و ... به‌طور گسترده‌ای در مباحث هیدرولوژی و اقلیم مورد استفاده قرار گرفته‌اند. شبکه‌های عصبی یکی از پرکاربردترین روش‌ها در پیش‌بینی است. در سال‌های اخیر کاربرد تکنیک‌های هوش مصنوعی و شبکه‌های عصبی گسترش زیادی داشته و به‌منظور مدل‌سازی و پیش‌بینی طوفان‌های گرد و غبار مورد استفاده قرار گرفته‌اند که در ادامه

1 Dust storm

2 Blowing dust

3 Floating dust

4 Artificial Neural Network (ANN)

5 Support Vector Machine (SVM)

6 Fuzzy Logic

7 Genetic Algorithm

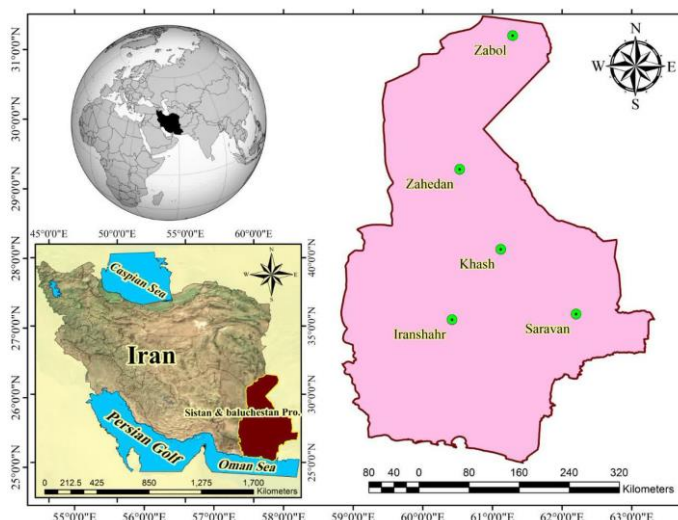
به پاره‌ای از این مطالعات اشاره شده است. Aili و همکاران (۲۰۲۳) به بررسی حرکت و رسوب‌گذاری گرد و غبار تحت تاثیر گردش جوی در شمال شرق بیابان، با استفاده از مدل HYSPLIT پرداختند. نتایج نشان می‌دهد که توده‌های هوایی از جنوب با بیشترین فراوانی (۴۶ روز) و بیشترین وقوع طوفان گرد و غبار (۹۱/۳ درصد) اصلی‌ترین عامل ورود ذرات گرد و غبار به منطقه مطالعه هستند. نرخ رسوب‌گذاری گرد و غبار بر روی سطوح زیرین مختلف روند کاهشی قابل توجهی از بیابان به واحه را نشان داد و رسوب‌گذاری گرد و غبار در تمام سطوح زیرین با افزایش ارتفاع کاهش یافت. رسوب‌گذاری گرد و غبار در جهت باد جنوبی بیشترین مقدار را داشت و مقدار ذرات گرد و غبار ریز با افزایش ارتفاع مخازن جمع‌آوری گرد و غبار افزایش یافت. نتایج این مطالعه می‌تواند برای پیش‌بینی وقوع بالقوه و مسیر حرکت طوفان‌های گرد و غبار مفید باشد و مبنایی برای کاهش اثرات منفی آن بر محیط زیست فراهم کند.

انصاری قوجقار و همکاران (۱۴۰۰) به بررسی کارایی مدل هیبریدی GRU- LSTM به منظور پیش‌بینی طوفان گرد و غبار در استان خوزستان در طول دوره آماری ۳۰ ساله (۲۰۱۹-۱۹۹۰) پرداختند. آن‌ها در مطالعه خود نوعی رویکرد ترکیبی به منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار (FSD) در مقیاس فصلی را به کار گرفتند که در آن از ترکیب شبکه‌های عصبی LSTM و GRU استفاده شده است. سپس عملکرد مدل هیبریدی فوق با شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF) و ماشین بردار پشتیبان (SVM) مقایسه شده است. نتایج معیارهای ارزیابی در مرحله آموزش و آزمایش مدل‌ها نشان‌دهنده عملکرد بهتر مدل GRU- LSTM نسبت به سایر مدل‌های استفاده شده به منظور پیش‌بینی FSD بود. پس از آن مدل SVM بهترین نتیجه را نشان داد. لذا در این پژوهش به مقایسه کارایی مدل هیبریدی سه‌گانه GRNN- SVM- LSTM با مدل‌های انفرادی GRNN و SVM به منظور پیش‌بینی شاخص FSD پرداخته خواهد شد. سبحانی و صفریان (۱۳۹۹) در پژوهشی به پیش‌بینی گرد و غبار در جنوب ایران پرداختند. آن‌ها از داده‌های ۲۷ ساله گرد و غبار (دوره زمانی ۲۰۱۷-۱۹۹۰) در ۱۴ ایستگاه سینوپتیک در جنوب غرب ایران استفاده کردند. آن‌ها از مدل‌های شبکه عصبی مصنوعی هیبرید- پانل دیتا و شبکه عصبی فازی- تطبیقی (ANFIS) در MATLAB به منظور پیش‌بینی پدیده گرد و غبار استفاده کردند. نتیجه پژوهش آن‌ها نشان‌دهنده میزان اطمینان بیش‌تر مدل‌های خط‌سنجی (شبکه عصبی مصنوعی هیبرید- پانل) نسبت به ANFIS بود. عراقی نژاد و همکاران (۱۳۹۹) در پژوهش‌های خود به بررسی شدت همبستگی و مدل‌سازی رابطه FSD (فراوانی روزهای همراه با طوفان گرد و غبار) با متغیرهای حدی و میانگین دما در نیمه‌غربی ایران پرداختند. نتایج پژوهش آن‌ها نشان داد که بیش‌ترین ضریب همبستگی با شاخص FSD متعلق به بیشینه دما در آبادان با مقدار ۰/۸۷۵ و کم‌ترین دما نیز در اهواز با مقدار ۰/۸۹۳ است. براساس نتایج مدل‌های رگرسیونی، متغیرهای حدی دما در بندر ماهشهر ۷۹/۳ درصد و در آبادان ۸۱/۲ درصد از تغییرات FSD را تبیین می‌کنند. انتظار می‌رود همکاران (۱۳۹۶) به پیش‌بینی گرد و غبار در استان خوزستان از سال ۱۳۹۸ تا ۱۴۰۲ با استفاده از مدل‌های سری زمانی پرداختند. بدین منظور، از داده‌های گرد و غبار سالانه هشت ایستگاه هواشناسی در استان خوزستان، در طول دوره آماری ۱۳۶۹ تا ۱۳۸۹ استفاده کردند. نتایج بررسی‌های آن‌ها نشان داد که بهترین و مناسب‌ترین مدل سری زمانی پیش‌بینی گرد و غبار برای اهواز، مسجد سلیمان و بهبهان مدل Holt- Winters، شهر دزفول مدل ARIMA و رامهرمز، آبادان، آغاچاری و امیدیه مدل نمو همواره ساده است. کبودوند پور و همکاران (۱۳۹۴) در مطالعه خود به بررسی دقت پیش‌بینی مدل ANFIS با مدل‌های شبکه عصبی مصنوعی و مدل‌های رگرسیون چندگانه به منظور پیش‌بینی طوفان گرد و غبار در سنجند در دوره زمانی ۱۳۹۱-۱۳۸۸ پرداختند. نتایج پژوهش آن‌ها نشان‌دهنده عملکرد بالاتر مدل ANFIS در مقایسه با مدل‌های MLR و ANN بود. همچنین آن‌ها به این نتیجه رسیدند که مدل ANFIS با استفاده از متغیرهای هواشناسی منطقه ایجاد طوفان‌های گرد و غبار در بیابان‌های سوریه، پتانسیل پیش‌بینی رخداد طوفان گرد و غبار در غرب ایران را دارد. جمالی‌زاده و همکاران (۱۳۸۶) قابلیت روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان را در پیش‌بینی طوفان‌های گرد و غبار زابل با طول دوره آماری ۲۶ ساله (۲۰۰۵-۱۹۸۰) بررسی کردند. براساس نتایج حاصل از پژوهش آن‌ها، استفاده از f-SVR و تابع کرنل پایه شعاعی (RBF) بهترین خروجی و جواب‌ها را ارائه می‌دهد. مدیران و سیاست‌گذاران با شناسایی مناطق مستعد و آسیب‌پذیر، اقدام به توسعه فعالیت‌هایی همچون تثبیت خاک و ارائه سیستم‌های هشدار می‌کنند. بدین ترتیب و با توجه به خسارت‌های ناشی از وقوع طوفان‌های گرد و غبار، مدل‌سازی این وقایع جهت فراهم‌آوردن اطلاعات دقیقی از زمان، مکان، شدت و مسیر حرکت این طوفان‌ها، امری ضروری است. علاوه بر این، بیش‌تر مطالعات به بررسی عملکرد مدل‌های انفرادی و نهایتاً هیبریدی دوگانه به منظور پیش‌بینی وقوع طوفان‌های گرد و غبار پرداخته‌اند. لذا در پژوهش حاضر برای نخستین بار به مدل‌سازی طوفان‌های گرد و غبار با استفاده از مدل هیبریدی سه‌گانه GRNN- SVM- LSTM در استان سیستان و بلوچستان پرداخته شده است.

روش شناسی پژوهش

منطقه مورد مطالعه

در این پژوهش به بررسی مدل هیبریدی سه گانه GRNN- SVM- LSTM و مقایسه آن با مدل های انفرادی GRNN و SVM به منظور پیش بینی شاخص FDSD در پنج ایستگاه استان سیستان و بلوچستان (زابل، زاهدان، خاش، ایرانشهر و سراوان)، مطابق شکل ۱، با جامعه آماری بلندمدت ۴۰ ساله (۱۹۸۰-۲۰۲۰) پرداخته شده است. بدین منظور از داده های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی (WMO) استفاده شد. مشاهده های پدیده های هواشناسی هر سه ساعت یک بار و در مجموع 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 از ۰۰ تا ۹۹ 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). براساس تعریف سازمان جهانی هواشناسی، روز همراه با طوفان های گرد و غبار روزی است که در آن، حداقل در یکی از هشت سینوپ، یکی از کدهای مرتبط با گرد و غبار (۰۶، ۰۷، ۰۸، ۰۹، ۳۰، ۳۱، ۳۲، ۳۳، ۳۴، ۳۵ و ۹۸) در بخش گزارش هوای حاضر اعلام شده باشد. مشروط بر این که، داده های قدرت دید افقی متناظر با کد اعلام شده، در کم تر از ۱۰۰۰ متر ثبت شده باشد (Mohammadi, 2015). لذا در این مطالعه، به منظور تشخیص طوفان های گرد و غبار، از مولفه دید افقی ≤ 1000 متر برای تمامی کدهای گرد و غبار استفاده شده است.




شکل ۱- معرفی ایستگاه های مورد مطالعه در پژوهش حاضر

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

توضیحات	کد
Dust haze	06
Raised dust or sand	07
Well-developed dust whirls (dust devils)	08
Distant or past dust storm (distant at time of obs or past station in the past hour)	09
DECREASED slight or moderate sand or dust storm with visibility <1000 m but >200 m	30
STABLE slight or moderate sand or dust storm with visibility <1000 m but >200 m	31
BEGUN or INCREASING slight or moderate sand or dust storm with visibility <1000 m but >200 m	32
DECREASED severe dust storm with visibility <200 m	33
Stable severe dust storm with visibility <200 m	34
BEGUN or INCREASING severe dust storm with visibility <200 m	35
Thunderstorm with dust or sand storm	98

ماشین بردار پشتیبان^۱ (SVM)

ماشین بردار پشتیبان روشی نسبتاً جدید و نوعی سیستم یادگیری کارآمد مبتنی بر تئوری بهینه‌سازی است که از اصل کمینه‌سازی خطای ساختاری به منظور دستیابی به جوابی بهینه استفاده می‌کند (Vapnik, 1995؛ انصاری قوجقار و همکاران، ۱۴۰۱). در واقع ماشین بردار پشتیبان نوعی الگوریتم یادگیری نظارت‌شده پیچیده است که به طور گسترده در مسائل دسته‌بندی و رگرسیون استفاده می‌شود. هدف اصلی ماشین بردار پشتیبان، یافتن ابرصفحه‌ای است که حاشیه‌ی بین کلاس‌ها را به حداکثر برساند. الگوریتم SVM یک روش مبتنی بر حداکثرسازی حاشیه است که با استفاده از اصول بهینه‌سازی مقید، ضرایب لاگرانژ و تکنیک هسته، به دسته‌بندی دقیق و مؤثر داده‌ها می‌پردازد و در مسائل واقعی با ساختار پیچیده به خوبی عمل می‌کند.



شکل ۲- مدل رگرسیون ماشین بردار پشتیبان (Lu et al., 2006)

در مدل رگرسیونی ماشین بردار پشتیبان، تابعی مرتبط با متغیر وابسته Y که خودش تابعی از چندین متغیر مستقل X است (رابطه ۱)، برآورد می‌شود (شکل ۲). رابطه بین متغیرهای وابسته و مستقل مانند سایر مسئله‌های رگرسیونی، با یک تابع جبری مانند $f(X)$ به علاوه مقدار خطای مجاز (ϵ) مشخص می‌شود (رابطه ۲) (Vapnik, 1995).

$$f(x) = W^T \phi(x) + b \quad \text{رابطه ۱}$$

$$y = f(x) + \epsilon \quad \text{رابطه ۲}$$

اگر W^T ترانهاده بردار ضریب و b ثابت مشخصه‌های تابع رگرسیونی و ϕ تابع کرنل باشد، بدین ترتیب هدف یافتن فرم تابعی برای $f(x)$ می‌باشد (انصاری قوجقار و همکاران، ۱۴۰۰). این امر با آموزش دادن مدل SVM توسط مجموعه‌ای از داده‌ها تحت عنوان مجموعه آموزش، انجام می‌شود (Misra et al., 2009). به منظور یافتن مقادیر W و b در معادله بالا، ابتدا باید تابع خطای رابطه ۳، در مدل SVM - ϵ با لحاظ کردن قیود بیان شده (رابطه ۴ و ۵)، کمینه شود (Hamel, 2009).

$$\text{تابع خطا} = \frac{1}{2} W^T W + c \sum_{i=1}^N \epsilon_i + c \sum_{i=1}^N \epsilon_i^* \quad \text{رابطه ۳}$$

$$\text{شرط یک} = W^T \phi(x_i) + b - y_i \leq \epsilon + \epsilon_i^* \quad \text{رابطه ۴}$$

$$\text{شرط دو} = y_i - W^T \phi(x_i) - b \leq \epsilon + \epsilon_i \epsilon_i^* . \epsilon_i^* \geq 0 . i = 1.2. \dots N \quad \text{رابطه ۵}$$

در رابطه ۵، C عددی صحیح و مثبت است که جریمه در زمان رخداد خطای آموزش در مدل‌ها را تعیین می‌کند. ϕ تابع کرنل، N تعداد نمونه‌ها و ϵ_i و ϵ_i^* متغیرهای کمبود هستند. بدین ترتیب، تابع رگرسیونی SVM را می‌توان به صورت رابطه ۶ بازنویسی کرد:

$$f(x) = \sum_{i=1}^N \bar{a}_1 \phi(x_i)^T \phi(x) + b \quad \text{رابطه ۶}$$

در رابطه ۶، \bar{a}_1 میانگین ضرایب لاگرانژ است. به دلیل پیچیدگی محاسبه $\phi(x)$ در فضای مشخصه خود، به منظور انتخاب یک تابع کرنل در در مدل ماشین بردار پشتیبان، رابطه ۷ عمل می‌شود:

$$K(X_j, X) = \phi(x_i)^T \sqrt{b^2 - 4ac} \quad \text{رابطه ۷}$$

انواع مختلفی از تابع کرنل شامل کرنل چند جمله ای^۱ (رابطه ۸)، کرنل توابع پایه شعاعی (رابطه ۹) و کرنل خطی (رابطه ۱۰)، به منظور ساخت انواع متفاوت SVM - ε قابل استفاده است. با توجه به این که این سه تابع کرنل از جمله پرکاربردترین توابع کرنل می باشند، لذا در این پژوهش، از این سه تابع کرنل استفاده شده است. لازم به ذکر است که در این بین، کرنل توابع پایه شعاعی که عملکرد بهتری نسبت به سایرین از خود نشان داده، مورد استفاده قرار گرفته است. فرآیند محاسبات SVM مبتنی بر کدنویسی در محیط زبان برنامه نویسی R صورت گرفته است و پارامترهای تابع های کرنل از طریق آزمون و خطا بهینه شده اند.

رابطه ۸) $K(X, X_j) = (t + X_i X_j)^b$:تابع کرنل چند جمله ای

رابطه ۹) $K(X, X_j) = \exp\left(-\frac{\|X - X_i\|^2}{2\sigma^2}\right)$:تابع کرنل پایه شعاعی


رابطه ۱۰) $K(X, X_j) = X_i X_j$:تابع کرنل خطی

شبکه عصبی رگرسیون تعمیم یافته (GRNN)

شبکه عصبی رگرسیون تعمیم یافته نوعی شبکه عصبی مصنوعی است که برای حل مسائل رگرسیون و پیش بینی پیوسته طراحی شده و از مفهوم شبکه عصبی شعاعی (RBF) الهام گرفته است. این شبکه براساس نظریه تخمین ناداریا- واتسون (Nadaraya-Watson)، به منظور تخمین تابع چگالی احتمالی داده ها مورد استفاده قرار می گیرد. این شبکه عصبی به دلیل ساختار ساده و توانایی تخمین توابع غیرخطی بسیار پرکاربرد می باشد. همچنین به دلیل استفاده از تخمین چگالی هسته، برای داده های کم تر نیز عملکرد قابل قبولی ارائه می دهد. بنابراین، شبکه عصبی رگرسیون تعمیم یافته روشی ساده و کارآمد به منظور تخمین توابع پیچیده است که از تکنیک ها و روش های آماری برای پیش بینی مسائل مختلف استفاده می کند. علاوه بر این، به دلیل عملکرد این شبکه مبتنی بر توابع هسته ای غیرخطی، قابلیت کار با داده های پیچیده و غیرخطی را نیز دارد (شکل ۳). ساختار این شبکه دارای چهار لایه اصلی می باشد. اولین لایه لایه ورودی است که تعداد گره های موجود در این لایه با تعداد داده های ورودی (تعداد مطالعات) مطابقت دارد. لایه دوم (لایه الگو) براساس داده های آموزشی تشکیل شده و برای محاسبه شباهت داده های ورودی با داده های آموزشی مورد استفاده قرار می گیرد. لایه سوم، لایه جمع بندی است که دو نوع گره دارد؛ یکی برای محاسبه مجموع وزنی شباهت ها و گره دوم برای مجموع وزنی خروجی ها. در لایه خروجی نیز، خروجی شبکه را به عنوان مقدار تخمین زده شده یا پیش بینی شده نمایش می دهد. GRNN نیز مانند تابع RBF در لایه میانی خود از تابع گوسی استفاده می کند ولی در لایه خروجی، بخشی اضافه تر از تابع RBF دارد. برای محاسبه مقدار خروجی در شبکه عصبی رگرسیون تعمیم یافته، از رابطه ۱۱ استفاده می شود.

رابطه ۱۱)
$$y_i = \frac{1}{\sum_{b=1}^n f(x_i, b)} \sum_{b=1}^n [f(x_i, b) \times T_b]$$

در رابطه ۱۱، T_b هدف مرتبط با مشاهده b ام و n تعداد مشاهدات است (Araghinejad, 2013).



شکل ۳- الگوریتم شبکه عصبی رگرسیون تعمیم یافته (Heddum, 2017)



شبکه‌های حافظه بلند مدت - کوتاه مدت^۱

نوعی از شبکه‌های عصبی بازگشتی (RNN) هستند که به منظور مدل‌سازی سری‌های زمانی و روابط طولانی مدت در داده‌ها طراحی شده‌اند. ساختار خاص این شبکه‌ها سبب حل مشکل محوشدگی در RNNهای ساده، که در یادگیری سری‌های بلندمدت نتایج ضعیفی داشتند، شده است.

ساختار LSTM شامل واحدهای حافظه‌ای است که اطلاعات را در طول زمان حفظ و ذخیره می‌کند. هر واحد این شبکه دارای سه گیت اصلی است. گیت ورودی^۲ مشخص کننده مقدار اطلاعات ورودی فعلی است که می‌تواند وارد حافظه شود. گیت فراموشی^۳ مقدار اطلاعات موجود در حافظه که باید فراموش شود را نشان می‌دهد و گیت خروجی^۴ نیز مشخص کننده مقدار اطلاعات ذخیره شده در حافظه است که به خروجی منتقل می‌شود.

روش پیشنهادی - مدل هیبریدی سه‌گانه GRNN- SVM- LSTM

در فرآیند ترکیب، خروجی لایه GRNN به لایه SVM ارسال می‌شود. خروجی لایه SVM نیز به لایه LSTM ارسال می‌شود. در نهایت خروجی لایه LSTM پس از ترکیب و ادغام، به لایه‌های تمام متصل می‌رسد. پس از این مرحله، خروجی نهایی به منظور انجام و شروع فرآیند پیش‌بینی، وارد لایه رگرسیون می‌شود (شکل ۴). لذا روش پیشنهادی دارای ساختاری پنج لایه (لایه ورودی، GRNN، SVM، LSTM، لایه خروجی) می‌باشد. در لایه اول که لایه ورودی است، تمامی داده‌ها و ویژگی‌های ورودی مرتبط با پیش‌بینی مدنظر، به‌عنوان ورودی به لایه GRNN وارد می‌شوند. ورودی‌ها در این لایه در واقع بردارهایی هستند که از لایه ورودی دریافت شده‌اند. این بردارها به صورت $Out_{embed} = [x_1, x_2, \dots, x_n]$ نمایش داده می‌شود. محاسبات این بردارها با استفاده از روابط ۱۲ تا ۱۵ صورت می‌گیرد:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad \text{رابطه ۱۲}$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad \text{رابطه ۱۳}$$

$$h'_t = \sigma(W_z x_t + U_n(r_t h_{t-1})) + b_n \quad \text{رابطه ۱۴}$$

$$h_t = (1 - z)h_{t-1} + z h'_t \quad \text{رابطه ۱۵}$$

در رابطه‌های ۱۲ تا ۱۵، بردارها به ترتیب، گیت Update، گیت Reset، گیت شرطی و خروجی فعال هستند. در لایه بعدی که لایه SVM است، ورودی‌ها بردارهایی هستند که از لایه GRNN حاصل شده‌اند. در لایه LSTM، ورودی‌ها بردارهای دریافت شده از لایه قبلی هستند.

$$i_t = \sigma(W_i [h_t - 1x_t] + b_i) \quad \text{رابطه ۱۶}$$

$$f_t = \sigma(W_f [h_t - 1x_t] + b_f) \quad \text{رابطه ۱۷}$$

$$g_t = \tanh(W_g [h_t - 1x_t] + b_g) \quad \text{رابطه ۱۸}$$

$$O_t = \sigma(W_o [h_t - 1x_t] + b_o) \quad \text{رابطه ۱۹}$$

در رابطه‌های ۱۶ تا ۱۹، گیت ورودی، f_t گیت فراموشی، g_t گیت بروزسانی و O_t گیت خروجی است. b بردارهای با قابلیت یادگیری در شبکه عصبی، W ماتریس قابل یادگیری در شبکه عصبی، x_t مقدار ورودی، $h_t - 1$ مقدار مخفی قبلی و σ تابع فعال سازی به کار رفته می‌باشد. در نهایت در لایه آخر یا لایه خروجی، خروجی دریافتی از شبکه LSTM ابتدا Flatten می‌شود. در مدل هیبریدی سه‌گانه پیشنهادی، عملیات نرمال‌سازی روی داده‌ها، پس از دریافت مجموعه داده موردنیاز پژوهش، انجام می‌شود. در مرحله بعدی، داده‌ها به دو دسته آموزش^۵ و آزمون^۶، به ترتیب به صورت ۷۰٪، ۳۰٪ تقسیم‌بندی می‌شوند. پس از طی مراحل بالا، فرآیند یادگیری مدل با استفاده از

1 Long Short- Term Memory (LSTM)

2 Input Gate

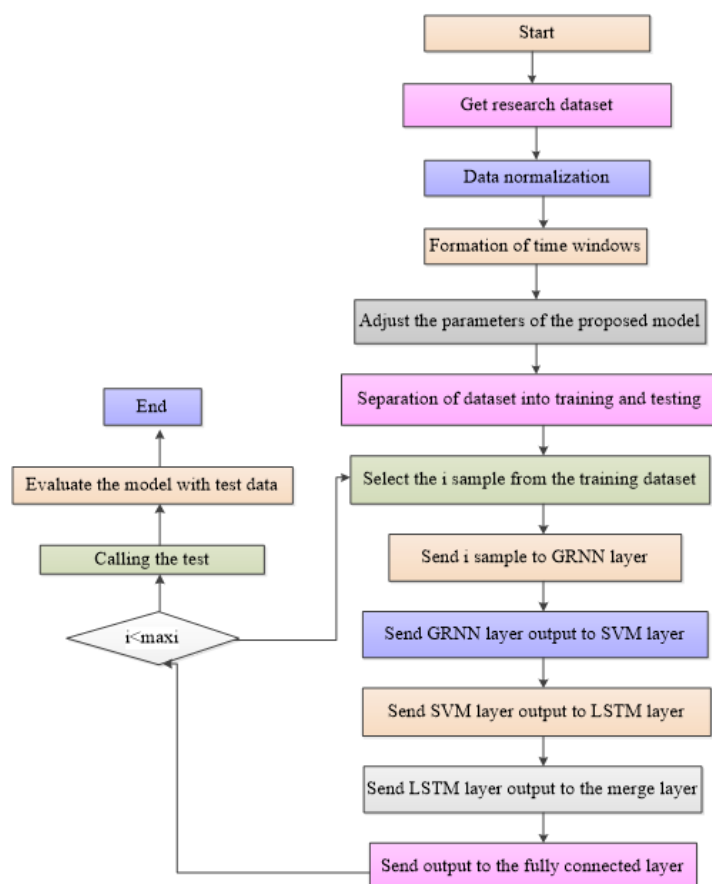
3 Forget Gate

4 Output Gate

5 Train

6 Test

شبکه هیبریدی GRNN- SVM- LSTM آغاز می شود. در این مرحله، به ازای هر یک از ویژگی های مجموعه داده، یک بلوک GRNN در نظر گرفته می شود. مثلاً اگر مجموعه داده مورد استفاده دارای ۹ ویژگی باشد، ۹ بلوک برای یادگیری مدل مورد نیاز است. این بلوک ها به طور همزمان وزن هر ویژگی را نسبت به ویژگی قبلی خود فرا گرفته و بدین صورت نوسان های ایجاد شده برای فراوانی روزهای همراه با طوفان گرد و غبار را پیش بینی می کنند. در مرحله بعدی، خروجی این لایه به لایه SVM ارسال می شود و در این لایه پس از پردازش، داده های ورودی به لایه بعدی ارسال می شود. در لایه LSTM، پس از عملیات پردازش روی داده های ورودی به این لایه، نتیجه را به لایه آخر (لایه تمام متصل) ارسال می کند.

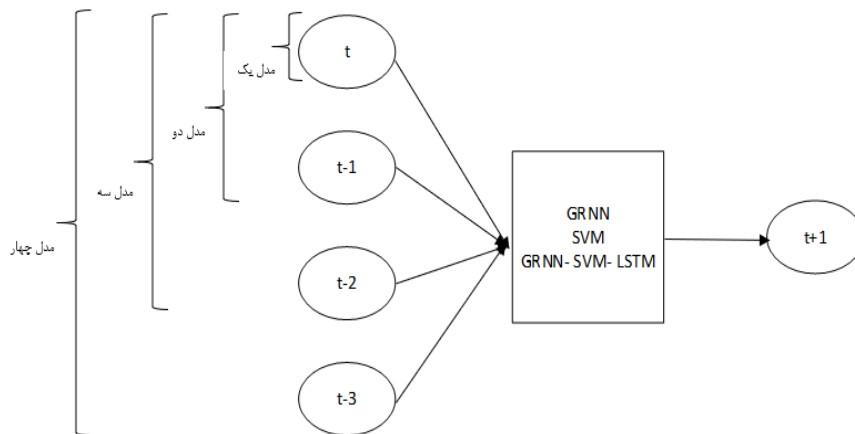


شکل ۴- بلوک دیاگرام مدل هیبرید سه گانه GRNN- SVM- LSTM (انصاری قوجقار و همکاران، ۱۴۰۰)

مدل های پیش بینی

این پژوهش، متغیر مدنظر، تعداد فصل یا فصل های گذشته به منظور پیش بینی فصل یا فصل های آینده است. تعداد فصول قابل پیش بینی می تواند شامل یک، دو، سه و چهار فصل قبل تر از متغیر FDS D باشد. در مدل شماره یک، به منظور پیش بینی FDS D برای فصل بعدی، از سری زمانی فراوانی روزهای همراه با طوفان گرد و غبار با یک گام تاخیر استفاده شده است. به بیانی دیگر، به منظور پیش بینی در زمان $t+1$ ، از مقدار آن در زمان t استفاده شده است. در مدل شماره دو، پیش بینی در فصل بعدی با استفاده از مقادیر FDS D تا دو فصل قبلی آن صورت گرفته است. در مدل های ۳ و ۴ نیز پیش بینی ها براساس مقادیر FDS D در سه و چهار فصل قبل انجام شده است. روابط زیر، پیش بینی های انجام شده در مدل های یک تا چهار را نمایش می دهد. همچنین مدل های استفاده شده در انتخاب فصل یا فصل های قبلی، برای پیش بینی در فصول آینده، در شکل ۵ نمایش داده شده است.

$FDS D_{(t+1)} = f(FDS D_{(t)})$	مدل یک
$FDS D_{(t+1)} = f(FDS D_{(t)}, FDS D_{(t-1)})$	مدل دو
$FDS D_{(t+1)} = f(FDS D_{(t)}, FDS D_{(t-1)}, FDS D_{(t-2)})$	مدل سه
$FDS D_{(t+1)} = f(FDS D_{(t)}, FDS D_{(t-1)}, FDS D_{(t-2)}, FDS D_{(t-3)})$	مدل چهار



شکل ۵- ساختارهای مورد استفاده در پیش بینی گرد و غبار (انصاری فوجقار و همکاران، ۱۴۰۱)

معیارهای ارزیابی (شاخص‌های نیکویی برازش)

در پژوهش حاضر، به منظور ارزیابی دقت و کارایی مدل‌ها، از ضریب همبستگی^۱ (R)، ریشه میانگین مربعات خطا^۲ (RMSE)، میانگین قدر مطلق خطا^۳ (MAE) و ضریب نش- ساتکلیف^۴ (NS) براساس رابطه‌های ۲۰ تا ۲۳، استفاده شده است. بهترین مقدار برای این چهار نمایه، به ترتیب، یک، صفر، صفر و یک است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad \text{رابطه ۲۰}$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad \text{رابطه ۲۱}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad \text{رابطه ۲۲}$$

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad \text{رابطه ۲۳}$$

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

نتایج مدل‌سازی با GRNN

پایه‌سازی فرامدل انفرادی شبکه عصبی رگرسیون تعمیم‌یافته برای پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار (FDSD)، با استفاده از زبان برنامه‌نویسی R انجام شده است. در جدول ۲، نتایج مرتبط با مدل‌سازی شاخص فراوانی روزهای همراه با طوفان گرد و غبار با استفاده از فرامدل انفرادی GRNN نمایش داده شده است. با توجه به نتایج معیارهای نیکویی برازش شامل ضریب همبستگی (R)، میانگین قدر مطلق خطا (MAE)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش- ساتکلیف (NS) در هر پنج ایستگاه مورد مطالعه، به‌طور نسبی ترکیب‌های شماره ۱ و ۲ نسبت به سایر ترکیب‌های مورد بررسی، نتایج بهتری را نمایش دادند. بدین ترتیب، نتیجه می‌گیریم که استفاده از سابقه‌های فراوانی FDSD در فصول قبل، در ساختار مدل‌سازی با شبکه عصبی رگرسیون تعمیم‌یافته، سبب بهبود یافتن نتایج مدل‌سازی نمی‌شود. همان‌طور که در جدول ۲ قابل مشاهده است، با به‌کارگیری شاخص FDSD از چهار فصل قبل به دو فصل

قبلی، شاخص RMSE برای هر پنج ایستگاه زابل، زاهدان، خاش، ایرانشهر و سراوان به ترتیب از مقادیر ۰/۵۰۴، ۰/۵۱۲، ۰/۵۱۵، ۰/۵۱۸ و ۰/۵۲۳ روز به ۰/۵۰۳، ۰/۵۰۹، ۰/۵۱۴، ۰/۵۱۷ و ۰/۵۱۹ روز کاهش پیدا کرده است. از طرف دیگر، در ایستگاه های زابل، زاهدان و سراوان، با اعمال شاخص FSD از دو فصل به یک فصل قبلی، شاخص RMSE از ۰/۵۴۱، ۰/۵۴۴ و ۰/۵۵۷ روز به ۰/۵۳۹، ۰/۵۴۳ و ۰/۵۵۴ روز بهبود یافته است. بدین ترتیب می توان نتیجه گرفت که با توجه به شرایط آب و هوایی حاکم بر منطقه مورد مطالعه، تاثیر مقدار شاخص فراوانی روزهای همراه با طوفان گرد و غبار در فصل های قبلی، در فصل آینده چندان قابل قبول و موثر نیست. نتایج این قسمت با مطالعات (Cao et al. (2014) و Yarmoradi et al. (2018) مطابقت دارد.

نتایج مدل سازی با SVM

پایه سازی فرامدل انفرادی ماشین بردار پشتیبان به منظور پیش بینی فراوانی روزهای همراه با طوفان گرد و غبار در محیط زبان برنامه نویسی R صورت گرفته است. جدول ۳ نتایج مرتبط با فرامدل ماشین بردار پشتیبان را نمایش می دهد. برای محاسبه مقادیر مناسب پارامترهای (C, σ, ε)، از شاخص RMSE به منظور بهینه سازی پارامترها در تمامی پنج ایستگاه مطالعاتی، استفاده شده است. در روش مدل سازی SVM نیز مانند روش شبکه عصبی رگرسیون تعمیم یافته، نتایج با اعمال تاثیرات شاخص فراوانی روزهای همراه با طوفان گرد و غبار در یک و دو فصل بهبود یافته و با اعمال تاثیر فصول بیش تر، مقادیر مطلوبی با توجه به افزایش روند خطا حاصل نشده است. نتایج این بخش با مطالعات Shi et al. (2020) مطابقت دارد. مثلاً در ایستگاه ایرانشهر، با به کارگیری شاخص FSD در چهار فصل قبل، مقدار RMSE معادل ۰/۵۳۶ روز بوده است که با اعمال این شاخص در یک و دو فصل قبلی، این شاخص به کم ترین مقدار خود در این ایستگاه، یعنی ۰/۵۳۳ روز رسیده است.

نتایج مدل سازی با مدل هیبرید سه گانه GRNN- SVM- LSTM

در جدول ۴، نتایج مرتبط با فرامدل هیبریدی سه گانه GRNN- SVM- LSTM نمایش داده شده است. همان طور که در این جدول مشخص است، مقدار خطای برآورد شده در تمامی پنج ایستگاه مورد مطالعه و برای تمامی چهار ترکیب، تغییر محسوس و چشم گیری داشته است. علاوه بر این، ضریب همبستگی و نش- ساتکلیف نیز در مقایسه با فرامدل های انفرادی بررسی شده در بالا، برای پیش بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار، افزایش قابل ملاحظه و مطلوبی داشته است. در ادامه به مقایسه چند نمونه پرداخته شده است. در ایستگاه زابل، مقدار RMSE در مرحله تست (آزمون) برای ترکیب شماره یک (بررسی تاثیر یک فصل قبل به منظور پیش بینی FSD) از ۰/۵۳۹ در روش GRNN به ۰/۵۲۳ در روش SVM و در نهایت به ۰/۵۰۱ در روش هیبریدی سه گانه GRNN- SVM- LSTM کاهش یافته است. در همین ایستگاه و برای ترکیب شماره چهار، مقدار فوق از ۰/۵۴۳ در روش GRNN به ۰/۵۲۵ در روش SVM و در نهایت به ۰/۵۰۴ در روش هیبریدی سه گانه GRNN- SVM- LSTM بهبود یافته است. در ایستگاه سراوان نیز مقدار RMSE در مرحله آزمون برای ترکیب شماره یک از ۰/۵۵۴ در روش GRNN به ۰/۵۳۷ در روش SVM و در نهایت به ۰/۵۱۸ در روش هیبریدی سه گانه GRNN- SVM- LSTM کاهش یافته است. به طور مشابه، برای ترکیب شماره چهار، مقدار فوق از ۰/۵۵۸ در روش GRNN به ۰/۵۳۸ در روش SVM و در نهایت به ۰/۵۲۳ در روش هیبریدی سه گانه GRNN- SVM- LSTM بهبود یافته است. بدین ترتیب، با توجه به نتایج به دست آمده واضح است که دقت فرامدل هیبریدی سه گانه GRNN- SVM- LSTM به منظور برآورد شاخص FSD پنج ایستگاه استان سیستان و بلوچستان در مقایسه با دو فرامدل انفرادی GRNN و SVM بیش تر است. همچنین در میان دو فرامدل انفرادی بررسی شده، فرامدل ماشین بردار پشتیبان نسبت به شبکه عصبی رگرسیون تعمیم یافته عملکرد بهتری را نمایش داده است. در شکل ۶ مقادیر مشاهده شده و پیش بینی شده شاخص FSD در مرحله ارزیابی به روش GRNN- SVM- LSTM نمایش داده شده است. مدل هیبرید سه گانه نیز مانند دو فرامدل انفرادی بررسی شده، در ترکیب های یک و دو عملکرد بهتری و دقت بالاتری را به منظور پیش بینی شاخص FSD، نشان داده است. نتایج این قسمت با مطالعات انصاری قوجقار و همکاران (۱۴۰۰)، (Zhen et al. (2024) و Dalal et al. (2024) مطابقت دارد.



جدول ۲- نتایج آماری داده‌های ورودی به مدل GRNN به منظور پیش‌بینی FDSD

Train Dataset				Test Dataset				Combination number	Station
NS	RMSE	MAE	R	NS	RMSE	MAE	R		
۰/۸۸۶	۰/۵۲۱	۰/۴۵۲	۰/۹۷۵	۰/۸۷۷	۰/۵۳۹	۰/۴۶۱	۰/۹۶۷	۱	Zabol
۰/۸۸۵	۰/۵۲۲	۰/۴۵۳	۰/۹۷۴	۰/۸۷۶	۰/۵۴۱	۰/۴۶۲	۰/۹۶۷	۲	
۰/۸۸۴	۰/۵۲۳	۰/۴۵۴	۰/۹۷۴	۰/۸۷۶	۰/۵۴۲	۰/۴۶۳	۰/۹۶۶	۳	
۰/۸۸۴	۰/۵۲۴	۰/۴۵۶	۰/۹۷۴	۰/۸۷۵	۰/۵۴۳	۰/۴۶۴	۰/۹۶۵	۴	
۰/۸۸۳	۰/۵۲۵	۰/۴۵۷	۰/۹۷۳	۰/۸۷۵	۰/۵۴۳	۰/۴۶۵	۰/۹۶۵	۱	Zahedan
۰/۸۸۲	۰/۵۲۶	۰/۴۵۷	۰/۹۷۲	۰/۸۷۴	۰/۵۴۴	۰/۴۶۶	۰/۹۶۵	۲	
۰/۸۸۱	۰/۵۲۷	۰/۴۵۷	۰/۹۷۱	۰/۸۷۴	۰/۵۴۵	۰/۴۶۷	۰/۹۶۴	۳	
۰/۸۷۹	۰/۵۲۷	۰/۴۵۸	۰/۹۶۹	۰/۸۷۳	۰/۵۴۶	۰/۴۶۸	۰/۹۶۳	۴	
۰/۸۷۸	۰/۵۲۸	۰/۴۵۹	۰/۹۶۸	۰/۸۷۳	۰/۵۴۷	۰/۴۶۹	۰/۹۶۳	۱	Khash
۰/۸۷۷	۰/۵۲۹	۰/۴۵۸	۰/۹۶۸	۰/۸۷۱	۰/۵۴۷	۰/۴۶۹	۰/۹۶۳	۲	
۰/۸۷۶	۰/۵۳۱	۰/۴۶۱	۰/۹۶۸	۰/۸۷۱	۰/۵۴۸	۰/۴۶۹	۰/۹۶۲	۳	
۰/۸۷۵	۰/۵۳۲	۰/۴۶۲	۰/۹۶۸	۰/۸۶۹	۰/۵۴۸	۰/۴۷۱	۰/۹۶۲	۴	
۰/۸۷۵	۰/۵۳۳	۰/۴۶۲	۰/۹۶۷	۰/۸۶۹	۰/۵۴۹	۰/۴۷۱	۰/۹۶۱	۱	Iranshahr
۰/۸۷۴	۰/۵۳۴	۰/۴۶۳	۰/۹۶۷	۰/۸۶۸	۰/۵۴۹	۰/۴۷۱	۰/۹۶۱	۲	
۰/۸۷۳	۰/۵۳۵	۰/۴۶۴	۰/۹۶۶	۰/۸۶۷	۰/۵۵۱	۰/۴۷۲	۰/۹۵۹	۳	
۰/۸۷۲	۰/۵۳۶	۰/۴۶۵	۰/۹۶۵	۰/۸۶۶	۰/۵۵۲	۰/۴۷۳	۰/۹۵۸	۴	
۰/۸۷۲	۰/۵۳۷	۰/۴۶۵	۰/۹۶۴	۰/۸۶۵	۰/۵۵۴	۰/۴۷۳	۰/۹۵۸	۱	Saravan
۰/۸۷۲	۰/۵۳۸	۰/۴۶۶	۰/۹۶۳	۰/۸۶۴	۰/۵۵۷	۰/۴۷۴	۰/۹۵۷	۲	
۰/۸۷۱	۰/۵۳۹	۰/۴۶۷	۰/۹۶۲	۰/۸۶۳	۰/۵۵۶	۰/۴۷۵	۰/۹۵۶	۳	
۰/۸۶۹	۰/۵۴۱	۰/۴۶۸	۰/۹۵۹	۰/۸۶۲	۰/۵۵۸	۰/۴۷۶	۰/۹۵۵	۴	

جدول ۳- نتایج آماری داده‌های ورودی به مدل SVM به منظور پیش‌بینی FDSD

Train Dataset				Test Dataset				Combination number	Station
NS	RMSE	MAE	R	NS	RMSE	MAE	R		
۰/۸۹۷	۰/۵۱۳	۰/۴۳۷	۰/۹۸۸	۰/۸۹۳	۰/۵۲۳	۰/۴۴۳	۰/۹۸۸	۱	Zabol
۰/۸۹۶	۰/۵۱۴	۰/۴۳۸	۰/۹۸۹	۰/۸۹۲	۰/۵۲۳	۰/۴۴۴	۰/۹۸۸	۲	
۰/۸۹۶	۰/۵۱۴	۰/۴۳۸	۰/۹۸۹	۰/۸۹۱	۰/۵۲۴	۰/۴۴۵	۰/۹۸۸	۳	
۰/۸۹۶	۰/۵۱۴	۰/۴۳۸	۰/۹۸۹	۰/۸۹۱	۰/۵۲۵	۰/۴۴۶	۰/۹۸۷	۴	
۰/۸۹۶	۰/۵۱۵	۰/۴۳۹	۰/۹۸۸	۰/۸۹۰	۰/۵۲۶	۰/۴۴۷	۰/۹۸۷	۱	Zahedan
۰/۸۹۵	۰/۵۱۶	۰/۴۳۹	۰/۹۸۷	۰/۸۸۹	۰/۵۲۷	۰/۴۴۷	۰/۹۸۶	۲	
۰/۸۹۴	۰/۵۱۷	۰/۴۳۸	۰/۹۸۶	۰/۸۸۹	۰/۵۲۷	۰/۴۴۸	۰/۹۸۵	۳	
۰/۸۹۴	۰/۵۱۸	۰/۴۴۰	۰/۹۸۵	۰/۸۸۸	۰/۵۲۸	۰/۴۴۹	۰/۹۸۴	۴	
۰/۸۹۳	۰/۵۱۸	۰/۴۴۰	۰/۹۸۵	۰/۸۸۷	۰/۵۲۹	۰/۴۵۱	۰/۹۸۳	۱	Khash
۰/۸۹۲	۰/۵۱۸	۰/۴۴۱	۰/۹۸۵	۰/۸۸۷	۰/۵۳۱	۰/۴۵۲	۰/۹۸۲	۲	
۰/۸۹۲	۰/۵۱۹	۰/۴۴۲	۰/۹۸۴	۰/۸۸۶	۰/۵۳۱	۰/۴۵۲	۰/۹۸۱	۳	
۰/۸۹۱	۰/۵۲۳	۰/۴۴۳	۰/۹۸۳	۰/۸۸۵	۰/۵۳۲	۰/۴۵۳	۰/۹۷۹	۴	
۰/۸۹۱	۰/۵۲۴	۰/۴۴۴	۰/۹۸۲	۰/۸۸۴	۰/۵۳۳	۰/۴۵۴	۰/۹۷۸	۱	Iranshahr
۰/۸۹۰	۰/۵۲۷	۰/۴۴۵	۰/۹۸۱	۰/۸۸۳	۰/۵۳۴	۰/۴۵۴	۰/۹۷۶	۲	
۰/۸۸۹	۰/۵۲۷	۰/۴۴۶	۰/۹۸۲	۰/۸۸۳	۰/۵۳۵	۰/۴۵۴	۰/۹۷۶	۳	
۰/۸۸۸	۰/۵۲۶	۰/۴۴۷	۰/۹۸۱	۰/۸۸۲	۰/۵۳۶	۰/۴۵۵	۰/۹۷۵	۴	
۰/۸۸۷	۰/۵۲۸	۰/۴۴۸	۰/۹۷۹	۰/۸۸۱	۰/۵۳۷	۰/۴۵۶	۰/۹۷۴	۱	Saravan
۰/۸۷۶	۰/۵۲۹	۰/۴۴۹	۰/۹۷۸	۰/۸۸۱	۰/۵۳۸	۰/۴۵۷	۰/۹۷۳	۲	
۰/۸۷۵	۰/۵۳۱	۰/۴۵۱	۰/۹۷۷	۰/۸۷۹	۰/۵۳۸	۰/۴۵۸	۰/۹۷۲	۳	
۰/۸۷۴	۰/۵۳۲	۰/۴۵۲	۰/۹۷۶	۰/۸۷۹	۰/۵۳۸	۰/۴۵۹	۰/۹۷۲	۴	

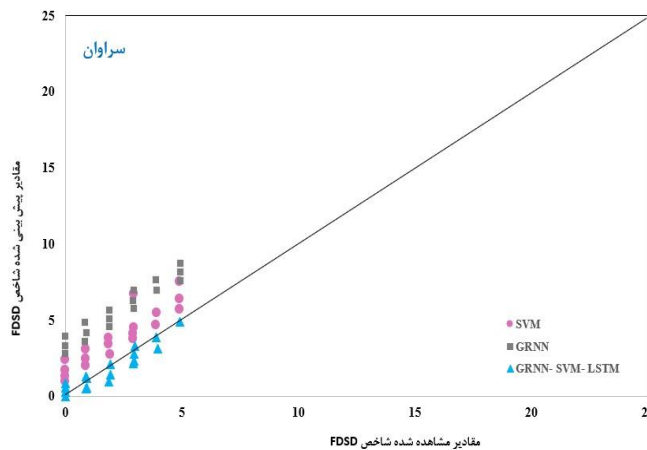
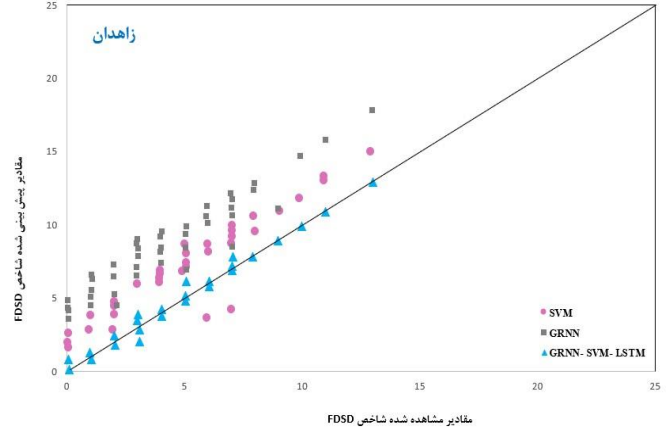

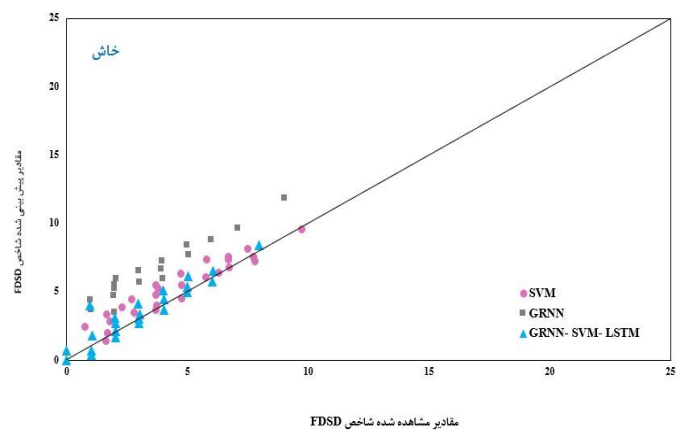
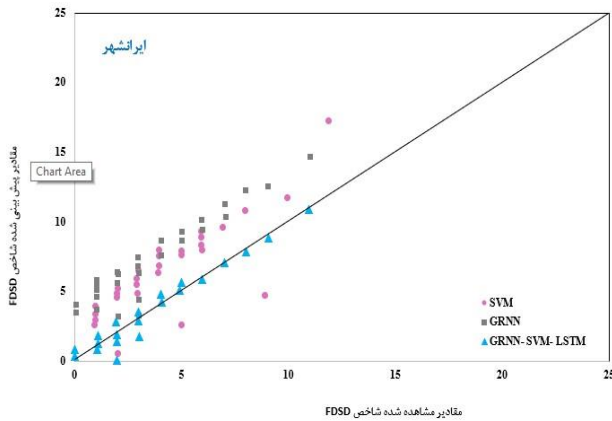
جدول ۴- نتایج آماری داده های ورودی به مدل هیبریدی GRNN- SVM- LSTM به منظور پیش بینی FDSD

Train Dataset				Test Dataset				Combination number	Station
NS	RMSE	MAE	R	NS	RMSE	MAE	R		
۰/۹۲۱	۰/۴۹۱	۰/۴۱۶	۰/۹۹۹	۰/۹۰۷	۰/۵۰۱	۰/۴۲۱	۰/۹۹۹	۱	Zabol
۰/۹۱۹	۰/۴۸۹	۰/۴۱۶	۰/۹۹۹	۰/۹۰۴	۰/۵۰۳	۰/۴۲۲	۰/۹۹۹	۲	
۰/۹۱۸	۰/۴۹۳	۰/۴۱۵	۰/۹۹۹	۰/۹۰۴	۰/۵۰۳	۰/۴۲۳	۰/۹۹۸	۳	
۰/۹۱۸	۰/۴۹۴	۰/۴۱۵	۰/۹۹۸	۰/۹۰۳	۰/۵۰۴	۰/۴۲۴	۰/۹۹۸	۴	
۰/۹۱۸	۰/۴۹۵	۰/۴۱۶	۰/۹۹۷	۰/۹۰۳	۰/۵۰۷	۰/۴۲۴	۰/۹۹۴	۱	Zahedan
۰/۹۱۷	۰/۴۹۶	۰/۴۱۵	۰/۹۹۵	۰/۹۰۲	۰/۵۰۹	۰/۴۲۳	۰/۹۹۳	۲	
۰/۹۱۶	۰/۴۹۷	۰/۴۱۷	۰/۹۹۵	۰/۹۰۲	۰/۵۱۱	۰/۴۲۵	۰/۹۹۳	۳	
۰/۹۱۴	۰/۴۹۸	۰/۴۱۸	۰/۹۹۳	۰/۹۰۱	۰/۵۱۲	۰/۴۲۷	۰/۹۹۳	۴	
۰/۹۱۴	۰/۴۹۹	۰/۴۱۹	۰/۹۹۴	۰/۹۰۱	۰/۵۱۳	۰/۴۲۹	۰/۹۹۳	۱	Khash
۰/۹۱۴	۰/۴۹۹	۰/۴۲۱	۰/۹۹۵	۰/۹۰۰	۰/۵۱۴	۰/۴۳۱	۰/۹۹۳	۲	
۰/۹۱۳	۰/۵۰۱	۰/۴۲۲	۰/۹۹۴	۰/۹۰۰	۰/۵۱۴	۰/۴۳۱	۰/۹۹۲	۳	
۰/۹۱۲	۰/۵۰۲	۰/۴۲۳	۰/۹۹۳	۰/۹۰۰	۰/۵۱۵	۰/۴۳۲	۰/۹۹۱	۴	
۰/۹۱۲	۰/۵۰۲	۰/۴۲۴	۰/۹۹۲	۰/۸۹۸	۰/۵۱۶	۰/۴۳۲	۰/۹۹۱	۱	Iranshahr
۰/۹۱۱	۰/۵۰۳	۰/۴۲۵	۰/۹۹۲	۰/۸۹۷	۰/۵۱۷	۰/۴۳۳	۰/۹۹۰	۲	
۰/۹۰۹	۰/۵۰۴	۰/۴۲۶	۰/۹۹۱	۰/۸۹۷	۰/۵۱۸	۰/۴۳۵	۰/۹۸۹	۳	
۰/۹۰۷	۰/۵۰۵	۰/۴۲۷	۰/۹۹۰	۰/۸۹۶	۰/۵۱۸	۰/۴۳۶	۰/۹۹۱	۴	
۰/۹۰۶	۰/۵۰۶	۰/۴۲۸	۰/۹۸۹	۰/۸۹۵	۰/۵۱۸	۰/۴۳۷	۰/۹۸۹	۱	Saravan
۰/۹۰۶	۰/۵۰۷	۰/۴۲۹	۰/۹۸۹	۰/۸۹۴	۰/۵۱۹	۰/۴۳۸	۰/۹۸۸	۲	
۰/۹۰۵	۰/۵۰۷	۰/۴۳۱	۰/۹۸۹	۰/۸۹۴	۰/۵۲۱	۰/۴۳۹	۰/۹۸۹	۳	
۰/۹۰۴	۰/۵۰۸	۰/۴۳۲	۰/۹۸۸	۰/۸۹۳	۰/۵۲۳	۰/۴۴۱	۰/۹۸۹	۴	

بحث

مقایسه عملکرد مدل های GRNN و SVM با مدل هیبریدی GRNN- SVM- LSTM

به منظور ارزیابی کارایی و عملکرد مدل ها از شاخص های نیکویی برازش R، RMSE، NS و MAE استفاده شده است. مقادیر حاصل از برآورد شاخص های نیکویی برازش به منظور تعیین بهترین مدل برای برآورد فراوانی روزهای همراه با طوفان گرد و غبار در استان سیستان و بلوچستان، برای فرامدل های انفرادی GRNN، SVM و مدل هیبریدی سه گانه GRNN- SVM- LSTM در جداول مربوطه نمایش داده شده است. نتایج پیش بینی شاخص FDSD حاکی از عملکرد مناسب مدل هیبریدی سه گانه برای هر پنج ایستگاه (سراوان، خاش، زابل، ایرانشهر و زاهدان) می باشد. در شکل شماره ۵، مقادیر مشاهده شده و پیش بینی شده شاخص FDSD برای داده های آزمون پنج ایستگاه مورد بررسی نمایش داده شده است. در واقع این شکل، روند مثبت و بهبود کارایی روش های استفاده شده به منظور پیش بینی FDSD را به خوبی نمایش می دهد. همان طور که در شکل زیر می بینید، ایستگاه زابل به عنوان ایستگاهی با بیشترین فراوانی شاخص FDSD در منطقه مورد مطالعه، بهترین مطابقت را در میان مقادیر مشاهده شده و پیش بینی شده دارد. ارتباط میان مقادیر مشاهده شده و پیش بینی شده در همه پنج ایستگاه مورد مطالعه، خطی است که دارای شیب تقریبی ۴۵ درجه می باشد. از میان مدل های بررسی شده، فرامدل انفرادی GRNN دارای بیشترین پراکندگی و مدل هیبریدی سه گانه GRNN- SVM- LSTM کمترین پراکندگی (بیشترین دقت لذا بیشترین مطابقت) را با نیمساز ربع اول ($y = x$) دارد. بدین ترتیب می توان بیان داشت که این مطابقت تأکیدی بر راندمان بالا و همچنین کارایی موثر این مدل، نسبت به فرامدل های انفرادی بررسی شده دارد. نتایج این قسمت با مطالعات Goudie and Middleton (2006) و Jiao et al. (2021) مطابقت دارد.



شکل ۶ - مقایسه مقادیر مشاهده شده و پیش بینی شده شاخص FDSO با استفاده از فرامدل‌های انفرادی GRNN و SVM و مدل هیبریدی سه‌گانه GRNN-SVM-LSTM

نتیجه‌گیری

در سال‌های اخیر، طوفان‌های گرد و غبار و شن و ماسه بسیاری از مناطق جهان را در بر گرفته و به معضلی اساسی در زندگی مردم تبدیل شده و مشکلات اقتصادی، اجتماعی و محیط‌زیستی فراوانی ایجاد کرده است. یکی از رویکردهای اساسی به منظور کاهش تلفات ناشی از طوفان‌های گرد و غبار و شن، ایجاد یک سیستم پیش‌بینی طوفان گرد و غبار است. در این راستا، هوش مصنوعی و شبکه‌های عصبی مصنوعی از مهم‌ترین و پرکاربردترین روش‌های موجود به منظور پیش‌بینی گرد و غبار و کاهش تلفات ناشی از این پدیده مخرب هستند. لذا در این پژوهش به مقایسه عملکرد مدل هیبریدی سه‌گانه پیشنهادی GRNN-SVM-LSTM و مقایسه آن با فرامدل‌های انفرادی

ماشین بردار پشتیبان و شبکه عصبی رگرسیون تعمیم‌یافته پرداخته شده است. هدف پژوهش حاضر، ارزیابی عملکرد مدل هیبریدی سه‌گانه GRNN- SVM- LSTM در مقایسه با فرامدل‌های انفرادی شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) و ماشین بردار پشتیبان (SVM) به منظور پیش‌بینی شاخص FDS (فراوانی روزهای همراه با طوفان گرد و غبار) در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان در طول ۴۰ ساله (۲۰۲۰-۱۹۸۰) بود. ورودی مدل‌ها، مقادیر FDS در گام‌های زمانی تاخیری قبلی (حداکثر چهار فصل) و خروجی شامل مقادیر فصلی FDS بود. شاخص‌های نیکویی برازش به منظور ارزیابی عملکرد مدل‌های ذکر شده استفاده شدند. نتایج حاصل از این شاخص‌ها در دو مرحله آموزش و آزمایش داده‌ها، نشان‌دهنده دقت بیش‌تر و نتایج بهتر مدل پیشنهادی هیبریدی در مقایسه با سایر فرامدل‌های انفرادی بود. در همه روش‌های بررسی شده به منظور پیش‌بینی شاخص FDS، مدلی که از یک یا دو گام تاخیر (ترکیبات یک و دو) در پیش‌بینی استفاده کرده بود، بهترین عملکرد را از خود نشان داد. با افزایش شاخص فراوانی روزهای همراه با طوفان گرد و غبار در ایستگاه‌های مورد بررسی، دقت پیش‌بینی همه مدل‌ها نیز افزایش یافت. بدین صورت که در ایستگاه زابل که بیش‌ترین فراوانی روزهای با طوفان گرد و غبار را داشت، مدل‌های مورد بررسی و همچنین مدل پیشنهادی منتخب بهترین نتیجه و عملکرد خود را نشان دادند. خاش و سراوان نیز کم‌ترین فراوانی روزهای همراه با طوفان گرد و غبار را داشتند. مدل‌سازی طوفان‌های گرد و غبار به عنوان ابزاری کارآمد و راهبردی، نقش مهمی در بهبود مدیریت و تصمیم‌گیری‌های مبتنی بر داده در مواجهه با این پدیده‌های طبیعی ایفا می‌کند. این ابزار پیشرفته، امکان پیش‌بینی دقیق زمان، مکان، شدت و مسیر طوفان‌ها را فراهم می‌سازد و به مدیران و سیاست‌گذاران اجازه می‌دهد تا برنامه‌ریزی‌های همدفند و اقدامات پیشگیرانه مؤثری را اجرا کنند. مدل‌سازی طوفان‌های گرد و غبار به‌ویژه در مدیریت بحران، به آماده‌سازی زیرساخت‌ها، تخصیص منابع و کاهش اثرات مخرب این پدیده‌ها کمک می‌کند. در سطح تصمیم‌گیری کلان، نتایج مدل‌سازی می‌تواند به تدوین و اجرای سیاست‌هایی نظیر تثبیت خاک، احیای پوشش گیاهی، مدیریت پایدار منابع آب و خاک و ارتقای تاب‌آوری زیست‌بوم‌های حساس منجر شود. این رویکرد نه تنها اثرات کوتاه‌مدت طوفان‌های گرد و غبار را کاهش می‌دهد، بلکه زمینه‌ساز توسعه سیاست‌های پایدار برای مقابله بلندمدت با این پدیده‌ها است. از نظر کاربرد، مدل‌سازی طوفان‌های گرد و غبار در حوزه‌های گوناگون نقش‌آفرینی می‌کند. در بخش حمل‌ونقل، این ابزار می‌تواند برای مسیریابی جایگزین، برنامه‌ریزی پروازها و مدیریت بندرها و فرودگاه‌ها در زمان وقوع طوفان مورد استفاده قرار گیرد. در بخش کشاورزی، مدل‌سازی به کشاورزان و مدیران منابع طبیعی امکان می‌دهد تا با اتخاذ تدابیر حفاظتی نظیر تغییر الگوی کشت، ایجاد پوشش‌های گیاهی و تثبیت خاک، اثرات نامطلوب طوفان‌ها را به حداقل برسانند. همچنین در حوزه سلامت، پیش‌بینی‌های مدل‌سازی به صدور هشدارهای بهداشتی، آماده‌سازی مراکز درمانی و کاهش اثرات بیماری‌های مرتبط با گرد و غبار کمک می‌کند.

علاوه بر این، مدل‌سازی طوفان‌های گرد و غبار ابزاری موثر برای ارتقای آگاهی عمومی و توانمندسازی جوامع در مقابله با این مخاطرات طبیعی است. به‌طور کلی، این فناوری با ارائه داده‌های دقیق و کاربردی، چارچوبی علمی و عملیاتی برای مدیریت یکپارچه و تصمیم‌گیری‌های مبتنی بر شواهد در برابر طوفان‌های گرد و غبار فراهم می‌آورد و به بهبود تاب‌آوری جوامع انسانی و اکوسیستم‌های آسیب‌پذیر کمک شایانی می‌کند. پیاده‌سازی مدل‌های هیبریدی سه‌گانه جهت پیش‌بینی و مدل‌سازی شاخص FDS با چالش‌هایی نیز همراه است. کمبود داده‌های دقیق، ناسازگاری یا وجود نویز در داده‌ها و دشواری در یکپارچه‌سازی اطلاعات از منابع این فرایند محسوب می‌شوند. همچنین، پیچیدگی محاسباتی این مدل‌ها و نیاز به تنظیم و بهینه‌سازی دقیق پارامترها می‌تواند مشکلات فنی و اجرایی را به همراه داشته باشد. دشواری در تفسیر نتایج نیز ممکن است پذیرش این مدل‌ها را از سوی سیاست‌گذاران و کارشناسان کاهش دهد. محدودیت در تعمیم‌پذیری مدل‌ها به مناطق یا شرایط مختلف، نیاز به به‌روزرسانی مداوم برای حفظ دقت پیش‌بینی‌ها و هزینه‌های بالای زیرساخت‌های محاسباتی نیز از چالش‌های دیگر موجود در این زمینه می‌باشند. علاوه بر این، عواملی مانند تغییرات اقلیمی و تأثیر فعالیت‌های انسانی بر الگوهای گرد و غبار، همراه با ضرورت زمان‌بندی دقیق پیش‌بینی‌ها، بر پیچیدگی اجرای این مدل‌ها می‌افزایند. با این وجود، شناسایی دقیق چالش‌ها و بهره‌گیری از روش‌های پیشرفته برای مدیریت داده‌ها و بهینه‌سازی مدل‌ها می‌تواند مسیر را برای پیاده‌سازی کارآمد این رویکرد هیبریدی هموار کند.

"هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد"

منابع

انصاری قوجقار، محمد؛ بذرافشان، جواد و عراقی نژاد، شهاب. (۱۴۰۱). ارزیابی کارایی فرامدل‌های هیبریدی یادگیری ماشین و باکس جنکینز به‌منظور



- مدل سازی طوفان های گرد و غبار (مطالعه موردی: استان خوزستان). *تحقیقات آب و خاک ایران*. ۵۳ (۸)، ۱۷۱۴-۱۶۹۵.
- انصاری قوجقار، محمد؛ بذرافشان، جواد؛ عراقی نژاد، شهاب؛ پارسی، احسان و سلطانی، شکور. (۱۳۹۹). بررسی عملکرد مدل هیبریدی ماشین بردار پشتیبان - مویک در پیش بینی توفان های گردوغبار (مطالعه موردی: استان سیستان و بلوچستان). *مدیریت مخاطرات محیطی*. ۷ (۴)، ۳۵۱-۳۳۱.
- انصاری قوجقار، محمد؛ پورغلام آمیجی، مسعود؛ بذرافشان، جواد؛ عراقی نژاد، شهاب؛ لیاقت، عبدالمجید و حسینی موغاری، سید محمد. (۱۳۹۹). ارزیابی کارایی الگوریتم ژنتیک و روش هیبریدی GA-SA در پیش بینی طوفان های گردوغبار (مطالعه موردی: استان خوزستان). *تحقیقات آب و خاک ایران*. ۵۱ (۱۰)، ۲۶۳۹-۲۶۲۳.
- انصاری قوجقار، محمد؛ پورغلام آمیجی، مسعود؛ بذرافشان، جواد؛ لیاقت، عبدالمجید و عراقی نژاد، شهاب. (۱۳۹۹). مقایسه کارایی شبکه های عصبی آماری، فازی و پرسپترون در پیش بینی طوفان های گردوغبار در نواحی بحرانی کشور. *تحقیقات آب و خاک ایران* ۵۱ (۸)، ۲۰۵۱-۲۰۶۳.
- انصاری قوجقار، محمد؛ پورغلام آمیجی، مسعود؛ عراقی نژاد، شهاب؛ باباییان، ایمان؛ لیاقت، عبدالمجید و سلاجقه، علی. (۱۴۰۰). تأثیر فاز گرم پدیده ENSO بر شکل گیری طوفان های گردوغبار در استان های خوزستان و سیستان و بلوچستان. *نشریه علمی - پژوهشی مرتع و آبخیزداری*. ۷۴ (۲)، ۲۷۱-۲۵۷.
- پورغلام آمیجی، مسعود؛ انصاری قوجقار، محمد؛ بذرافشان، جواد؛ لیاقت، عبدالمجید و عراقی نژاد، شهاب. (۱۳۹۹). مقایسه عملکرد مدل های سری زمانی SARIMA و Holt-Winters با روش های هوش مصنوعی در پیش بینی طوفان های گردوغبار (مطالعه موردی: استان سیستان و بلوچستان). *پژوهش های جغرافیای طبیعی*. ۵۲ (۴)، ۵۸۷-۵۶۷.
- پورغلام آمیجی، مسعود؛ انصاری قوجقار، محمد و احمدالی، خالد. (۱۴۰۰). پیش بینی طوفان های گردوغبار در استان خوزستان با استفاده از شبکه های عصبی مصنوعی. *نیوار*. ۴۵، ۱۱۵-۱۱۴.
- خوش کیش، اسدالله؛ علیجانی، بهلول و حجازی زاده، زهرا. (۱۳۹۰). تحلیل سینوپتیکی سامانه های گردوغبار در استان لرستان. *نشریه تحقیقات کاربردی علوم جغرافیایی* ۱۱ (۲۱)، ۱۱۰-۹۱.
- سبحانی، بهروز؛ صفریان زنگیر، وحید و فیض اله زاده، سینا. (۱۳۹۹). مدل سازی و پیش بینی گرد و غبار در غرب ایران. *پژوهش های جغرافیای طبیعی*. ۵۲ (۱)، ۳۵-۱۷.
- نوبی، سید سعید؛ مرادی، حمیدرضا و شریفی کیا، محمد. (۱۳۹۸). ارزیابی توزیع زمانی توفان های ریزگرد و ارتباط عوامل مؤثر با فراوانی وقوع این پدیده در استان خوزستان طی سال های ۲۰۰۰ تا ۲۰۱۵. *فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (سپهر)*. ۲۸ (۱۱۱)، ۲۰۳-۱۹۱.

REFERENCES

- Aili, A., Xu, H., Xu, Q., & Liu, K. (2023). Aeolian dust movement and deposition under local atmospheric circulation in a desert-oasis transition zone of the northeastern Taklimakan desert. *Ecological Indicators*, 157, 111289. <https://doi.org/10.1016/j.ecolind.2023.111289>.
- Ansari Ghojghar, M., Araqi Nejad, S., & Bazrafshan, J. (2021). Evaluating the efficiency of the GRU-LSTM hybrid model in predicting dust storms (Case study: Khuzestan Province). *Iranian Journal of Soil and Water Research*, 53(8), 1695-1714. (In Persian).
- Ansari Ghojghar, M., Bazrafshan, J., & Araqi Nejad, S. (2022). Evaluating the efficiency of hybrid meta-models combining machine learning and Box-Jenkins for dust storm modeling (Case study: Khuzestan Province). *Iranian Journal of Water and Soil Research*, 53(8), 1695-1714. (In Persian).
- Ansari Ghojghar, M., Bazrafshan, J., Araqi Nejad, S., Parsi, E., & Soltani, S. (2020). Performance analysis of the hybrid Support Vector Machine-Wavelet model in predicting dust storms (Case study: Sistan and Baluchestan Province). *Environmental Hazards Management*, 7(4), 331-351. (In Persian).
- Ansari Ghojghar, M., Pourgholam Amiji, M., Araqi Nejad, S., Babaeian, I., & Salajegheh, A. (2021). The impact of the warm phase of ENSO on the formation of dust storms in Khuzestan and Sistan and Baluchestan provinces. *Rangeland and Watershed Management Scientific-Research Journal*, 74(2), 257-271. (In Persian).
- Ansari Ghojghar, M., Pourgholam Amiji, M., Bazrafshan, J., Araqi Nejad, S., Liaqat, A., & Hoseini Moghari, S. M. (2020). Evaluating the efficiency of Genetic Algorithm and the GA-SA hybrid method in predicting dust storms (Case study: Khuzestan Province). *Iranian Journal of Water and Soil Research*, 51(10), 2623-2639. (In Persian).
- Ansari Ghojghar, M., Pourgholam Amiji, M., Bazrafshan, J., Liaqat, A., & Araqi Nejad, S. (2020). Comparing the efficiency of statistical, fuzzy, and perceptron neural networks in predicting dust storms in critical regions of Iran. *Iranian Journal of Water and Soil Research*, 51(8), 2051-2063. (In Persian).
- Dalal, S., Lilhore, U. K., Faujdar, N., Samiya, S., Jaglan, V., Alroobaea, R., ... & Ahmad, F. (2024). Optimising air quality prediction in smart cities with hybrid particle swarm optimization-long-short term memory-

- recurrent neural network model. *IET Smart Cities*. <https://doi.org/10.1049/smc2.12040>.
- Heddam, S. (2017). Generalized regression neural network based approach as a new tool for predicting total dissolved gas (TDG) downstream of spillways of dams: A case study of Columbia River Basin dams, USA. *Environmental Processes*, 4(1), 235–253. <https://doi.org/10.1007/s40710-017-0207-9>.
- Khosh Kish, A., Alijani, B., & Hejazi Zadeh, Z. (2011). Synoptic analysis of dust systems in Lorestan province. *Journal of Applied Research in Geographic Sciences*, 11(21), 91–110. (In Persian).
- Li, N., & Zhang, W. (2022). Research on sand-dust storm forecasting based on deep neural network with stacking ensemble learning. *IEEE Access*, 10, 111855–111863. <https://doi.org/10.1109/ACCESS.2022.3193653>
- Lu, Z. Y., Zhang, Q. M., & Zhao, Z. C. (2006, August). SVM in the sand-dust storm forecasting. In *2006 International Conference on Machine Learning and Cybernetics* (pp. 3677–3681). IEEE. <https://doi.org/10.1109/ICMLC.2006.258206>.
- Pourgholam-Amiji, M., Ansari Ghojghar, M., & Ahmadali, K. (2021). Predicting dust storms in Khuzestan Province using artificial neural networks. *Nivar*, 45(114–115), 52–69. (In Persian).
- Pourgholam-Amiji, M., Ansari Ghojghar, M., Bazrafshan, J., Liaqat, A., & Araqi Nejad, S. (2020). Comparison of SARIMA and Holt-Winters time series models with artificial intelligence methods in predicting dust storms (Case study: Sistan and Baluchestan Province). *Geographical Natural Research*, 52(4), 567–587. (In Persian).
- Shi, L., Zhang, J., Zhang, D., Igbawua, T., & Liu, Y. (2020). Developing a dust storm detection method combining Support Vector Machine and satellite data in typical dust regions of Asia. *Advances in Space Research*, 65(4), 1263–1278. <https://doi.org/10.1016/j.asr.2019.11.015>
- Nabavi, S. S., Moradi, H., & Shrifikia, M. (2019). Evaluation of dust storm temporal distribution and the relation of the effective factors with the frequency of occurrence in Khuzestan Province from 2000 to 2015. *Scientific-Research Quarterly of Geographical Data (SEPEHR)*, 28(111), 191–203. <https://doi.org/10.22131/sepehr.2019.37518>. (In Persian).
- Zhen, Z., Li, Z., Wang, F., Xu, F., Li, G., Zhao, H., ... & Li, J. (2024). CNN-LSTM networks-based sand and dust storms monitoring model using FY-4A satellite data. *IEEE Transactions on Industry Applications*. <https://doi.org/10.1109/TIA.2024.3124567>.