

Evaluating the Performance of GRU-LSTM Hybrid Model in Predicting the Dust Storms Events (Case Study: Khuzestan Province in Southwest of Iran)

M. Ansari Ghojghar¹, Sh. Araghinejad²,
J. Bazrafshan³, B. Zahraie^{4*}, and E. Parsi⁵

Abstract

Understanding the frequency of dust storms in each area and being mindful of temporal-spatial variation of this event can help to monitor and reduce the damages induced by dust events. Due to the increasing development of metamodels and their combination with optimization algorithms used to model and predict hydrological variables, machine learning models due to high accuracy in forecasting, in the form of a black box, have received a lot of attention. Therefore, in the present study, a hybrid approach is proposed to predict the Frequency of Dust Storm Days (FDS) on a seasonal scale, which uses a combination of Long Short Term Memory (LSTM) and Gated Recurrent Unit (GRU) neural networks. In this study, the performance of the proposed hybrid model was compared with a neural network based on Radial Basis Functions (RBF) and Support Vector Machine (SVM). For this purpose, hourly dust data and codes of the World Meteorological Organization were used on a seasonal scale with a statistical period of 30 years (1990-2019) for seven synoptic stations in Khuzestan province. The results of the evaluation criteria in the training and testing Stages showed that the GRU-LSTM hybrid model offered better performance than other models used to predict the frequency of days with dust storms; The proposed hybrid model with correlation coefficient (R) of 0.905-0.988, Root Mean Square Error (RMSE) of 0.313-0.402 day, Mean Absolute Error (MAE) of 0.144-0.236 day, and Nash-Sutcliffe (NS) of 0.819-0.903 had better performance compared to the other models used in predicting the FDS index. In general, comparing the models used in this study, the GRU-LSTM hybrid method and the SVM model, respectively, provided the best prediction skills. As a result, application of the proposed hybrid model can be used as a suitable tool to predict the FDS index and adopting management decisions to reduce the dust storms damages in the study area.

Keywords: Prediction, Dust Storm, SVM, GRU-LSTM Method, Khuzestan Province.

Received: December 14, 2020

Accepted: March 24, 2021

ارزیابی کارایی مدل هیبریدی GRU-LSTM در پیش‌بینی طوفان‌های گرد و غبار (مطالعه موردی: استان خوزستان)

محمد انصاری قوجقار^۱، شهاب عراقی نژاد^۲، جواد بذرافشان^۳،
بنفشه زهرایی^{۴*} و احسان پارسی^۵

چکیده

درک صحیح از وقوع طوفان‌های گرد و غبار در هر منطقه و آگاهی از تغییرات زمانی - مکانی این پدیده به مدیریت و کاهش خسارت‌های ناشی از گرد و غبار کمک شایانی می‌کند. در سال‌های اخیر، توسعه فرامدل‌ها و ترکیب آن‌ها با الگوریتم‌های بهینه‌سازی به منظور مدل‌سازی و پیش‌بینی متغیرهای آب و هوایی، مورد توجه زیادی قرار گرفته است. از این رو در مطالعه حاضر، نوعی رویکرد ترکیبی به منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار (FDS) در مقیاس فصلی پیشنهاد شده که در آن از ترکیب شبکه‌های عصبی LSTM و GRU استفاده می‌شود. در این پژوهش، عملکرد مدل هیبریدی پیشنهادی با شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF) و ماشین بردار پشتیبان (SVM) مورد مقایسه قرار گرفته است. بدین منظور، از داده‌های ساعتی گرد و غبار و کدهای سازمان جهانی هواشناسی در مقیاس فصلی با طول دوره آماری ۳۰ ساله (۱۹۹۰-۲۰۱۹) در هفت ایستگاه سینوپتیک استان خوزستان استفاده شد. نتایج معیارهای ارزیابی در مرحله آموزش و آزمایش مدل‌ها نشان داد که مدل هیبریدی GRU-LSTM عملکرد بهتری نسبت به سایر مدل‌های مورد استفاده به منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار ارائه می‌نماید؛ به طوری که مدل هیبریدی پیشنهادی با ضریب همبستگی (R=۰/۹۰۵-۰/۹۸۸)، ریشه میانگین مربعات خطا (RMSE=۰/۳۱۳-۰/۴۰۲ day)، میانگین قدر مطلق خطا (MAE=۰/۱۴۴-۰/۲۳۶ day) و ضریب نش-ساتکلایف (NS=۰/۸۱۹-۰/۹۰۳)، عملکرد بهتری نسبت به سایر مدل‌های مورد استفاده در پیش‌بینی شاخص FDS داشته است. در مجموع با مقایسه مدل‌های مورد استفاده، روش هیبریدی GRU-LSTM بهترین عملکرد و بعد از آن مدل SVM بهترین نتیجه را ارائه نمود. لذا مدل هیبریدی پیشنهادی می‌تواند به عنوان ابزاری مناسب جهت پیش‌بینی شاخص FDS و به تبع آن اتخاذ تصمیمات مدیریتی به منظور کاهش خسارت طوفان‌های گرد و غبار، در منطقه مطالعاتی مورد استفاده قرار گیرد.

کلمات کلیدی: پیش‌بینی، طوفان گرد و غبار، روش ماشین بردار پشتیبان، روش GRU-LSTM، خوزستان.

تاریخ دریافت مقاله: ۹۹/۹/۲۴

تاریخ پذیرش مقاله: ۱۴۰۰/۱/۴

1- Ph.D. Candidate, Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran.
2- Associate Professor, Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran.
3- Associate Professor, School of Civil Engineering, College of Engineering, University of Tehran, Tehran, Iran. Email: bzahraie@ut.ac.ir
4- Ph.D. Candidate, Department of Water Science and Engineering, Faculty of Agriculture and Natural Resources, Islamic Azad University Ahwaz, Ahwaz, Iran.

*- Corresponding Author

DOI: [20.1001.1.17352347.1400.17.1.2.3](https://doi.org/10.1001.1.17352347.1400.17.1.2.3)

۱- دانشجوی دکتری گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران.
۲- دانشیار گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران.
۳- دانشیار دانشکده مهندسی عمران، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران.
۴- دانشجوی دکتری علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه آزاد اسلامی واحد اهواز، اهواز، ایران.
*- نویسنده مسئول
بحث و مناظره (Discussion) در مورد این مقاله تا پایان تابستان ۱۴۰۰ امکانپذیر است.

۱- مقدمه

درک صحیح از وقوع طوفان‌های گرد و غبار در هر منطقه و آگاهی از تغییرات زمانی و مکانی این پدیده به مدیریت و کاهش خسارت‌های ناشی از گرد و غبار کمک شایانی می‌کند. پدیده گرد و غبار یکی از مخاطره‌های طبیعی است و سالانه خسارت‌های زیادی در جنوب غرب و جنوب شرق کشور ایجاد می‌کند (Abdolshahnejad et al., 2020). همچنین وقوع خشکسالی در یک منطقه با تأمین آب در آن منطقه رابطه تنگاتنگی دارد و هر چه اقلیم منطقه خشک‌تر باشد، احتمال وقوع خشکی و خشکسالی بیشتر شده و رخداد پدیده گرد و غبار محتمل‌تر است (Shaker Sureh and Asadi, 2019). حجم فراوان ذرات گرد و غبار حمل شده به تروپوسفر، بیان انرژی را هم تحت تأثیر قرار داده و در پی آن شرایط آب‌وهوایی ناحیه نیز تحت تأثیر قرار می‌گیرد (Kim et al., 2017). این ذرات بر روی شرایط جوی، تولیدات کشاورزی و سلامت انسان و اکوسیستم اثر می‌گذارد (Hahnenberger et al., 2014). ذرات ریز گرد و غبار تحت تأثیر عوامل گوناگونی از جمله شرایط جوی (باد، بارش و دما)، مشخصات سطح زمین (توپوگرافی، رطوبت سطح، طول زبری و پوشش گیاهی) و ویژگی‌های خاک (بافت، تراکم، ترکیب و کاربری اراضی) وارد جو می‌شوند (Karegar et al., 2017). شبکه‌های عصبی مصنوعی نوعی ساختار ریاضی هستند که توانایی نشان دادن آثار غیرخطی برای ارتباط بین ورودی و خروجی‌های هر سیستمی را دارند. این شبکه‌ها با داده‌های موجود طی فرآیند یادگیری، آموزش دیده و برای پیش‌بینی در آینده استفاده می‌شوند که دارای ویژگی‌های قابلیت یادگیری، قابلیت تعمیم و پردازش موازی هستند (Dahiya et al., 2007).

در سال‌های اخیر، روش‌های هوش مصنوعی و شبکه‌های عصبی که به صورت جعبه سیاه عمل می‌کنند، مانند شبکه‌های عصبی مصنوعی^۱ (ANN)، ماشین‌های بردار پشتیبان^۲ (SVM)، منطق فازی^۳ (FL) و الگوریتم ژنتیک^۴ (GA) به طور گسترده در مباحث هیدرولوژی و اقلیمی استفاده شده‌اند که در ادامه به برخی از این پژوهش‌ها اشاره می‌شود. He et al. (2014) در مطالعه‌ای برای پیش‌بینی جریان رودخانه‌ای در چین، از ماشین بردار پشتیبان استفاده کردند و نتایج نشان داد که این مدل عملکرد مناسب‌تری نسبت به شبکه عصبی مصنوعی و سیستم استنتاج فازی دارد. Hussain and Khan (2020) در پژوهشی جریان ماهیانه رودخانه هونرا^۵ واقع در پاکستان را بر اساس روش‌های یادگیری ماشینی با ارائه روش‌های RF^۶، SVR^۷، MLP^۸ مدل‌سازی کردند. به این منظور، در این پروژه برای تهیه یک مدل پیش‌بینی دقیق، داده‌های جریان ماهانه رودخانه بر اساس تابع خودهمبستگی^۹ (ACF) و تابع خودهمبستگی جزئی^{۱۰} (PACF) با

مقادیر پیشین جریان رودخانه برای شناسایی پیش‌بینی‌های مناسب بررسی و مقایسه شد. نتایج این پژوهش نشان داد که رویکرد RF بهترین دقت در مدل‌سازی جریان ماهانه رودخانه را داشته است.

در سال‌های اخیر کاربرد تکنیک‌های هوش مصنوعی و شبکه‌های عصبی گسترش بی‌نظیری داشته و در موضوعاتی همچون مدل‌سازی و پیش‌بینی طوفان‌های گرد و غبار نیز از آن‌ها استفاده می‌شود که در ادامه به برخی از این موارد اشاره خواهد شد. Jamalizadeh et al. (2008) توانایی دو روش شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان را در پیش‌بینی طوفان‌های گرد و غبار شهر زابل با طول دوره آماری ۲۶ ساله (۲۰۰۵-۱۹۸۰) بررسی کردند. از آن‌جا که استفاده از نوع f-SVR و تابع کرنل پایه شعاعی^{۱۱} (RBF) بهترین جواب‌ها را داده است، توصیه شده که در مطالعات دیگر نیز قابلیت‌های این روش‌ها مورد بررسی قرار گیرد. Sobhani et al. (2015) به بررسی گرد و غبار و ارزیابی امکان پیش‌بینی آن بر اساس روش‌های آماری و مدل سیستم استنتاج عصبی- فازی تطبیقی (ANFIS) در زابل با آمار ۱۴ ساله پرداختند. نتایج نشان داد در طول دوره آماری مورد مطالعه، ماه‌های جولای و آگوست گرد و غباری‌ترین ماه‌های سال می‌باشند. بر اساس تحلیل خوشه‌ای انجام‌شده، ماه‌های جولای و آگوست با بیشترین روزهای گرد و غباری در یک خوشه مجزا قرار گرفته‌اند. روند سری ماهانه، فصلی و سالانه‌ی گرد و غبار در این ایستگاه، افزایشی می‌باشد. نتایج پیش‌بینی گرد و غبار با مدل ANFIS، نشان از قابلیت بالای آن در پیش‌بینی گرد و غبار در این ایستگاه دارد. ساختار سیستم استنتاج فازی^{۱۲} (FIS) تعیین‌شده با چهار تابع عضویت به شکل قوسی با روش آموزش هیبرید، با اطمینان حدود ۹۳ درصد گرد و غبار ایستگاه زابل را پیش‌بینی می‌کند. Araghinejad et al. (2018) در تحقیقی تأثیر نوسانات پارامترهای اقلیمی بر فراوانی طوفان‌های گرد و غبار در ایران مورد بررسی قرار دادند. نتایج این تحقیق بیانگر افزایش روند طوفان‌های گرد و غبار در غرب و جنوب غرب، قسمت‌هایی از شمال غرب و جنوب شرق کشور است. Shaiba et al. (2018) در پژوهشی به بررسی روشی جهت پیش‌بینی طوفان گرد و غبار در بازه زمانی ۲۴ ساعت آینده پرداختند. نتایج این پژوهش نشان داد که روش درخت تصمیم CART عملکرد بهتری نسبت به دو روش بایز ساده و رگرسیون لجستیک دارد. Araghinejad et al. (2020) در پژوهشی به بررسی شدت همبستگی و مدل‌سازی رابطه فراوانی روزهای همراه با طوفان گردوغبار (FDS) با متغیرهای حدی و متوسط دما در نیمه غربی کشور پرداختند. نتایج این پژوهش نشان داد که بالاترین ضریب همبستگی با شاخص FDS مربوط به متغیر دمای بیشینه در ایستگاه

گفته می‌شود که حداقل در یکی از هشت سینوپ (گزارش‌های سه ساعته دیده‌بانی)، یکی از کدهای مربوط به گرد و غبار (۰۶، ۰۷، ۰۸، ۰۹، ۳۰ تا ۳۵ و ۹۸) در بخش هوای حاضر گزارش شده باشد. بنابراین طوفان‌های گرد و غبار یک متغیر اقلیمی است و می‌تواند در پژوهش‌های منابع آب مورد ارزیابی قرار گیرد (Araghinejad et al., 2018). از بررسی پژوهش‌های مختلف چنین برمی‌آید که برای مدل‌سازی دقیق متغیرهای اقلیمی علی‌الخصوص شاخص^{۱۴} FDSDD (روز) که یکی از چالش‌های مهم در فرآیند مدیریت و مهندسی محیط‌زیست محسوب می‌شود، روش‌های چندانی وجود ندارد. ضمن اینکه همین روش‌های اندک نیز، هر یک ایرادها و معایب خاص خود را دارند و از دقت بالایی به منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار برخوردار نیستند. لذا در مطالعه حاضر برای رفع نواقص و معایب روش‌های استفاده شده پیشین، سعی بر ارائه نوعی مدل ترکیبی جدید از شبکه‌های عصبی بازگشتی به منظور پیش‌بینی شاخص FDSDD بوده است که در آن از ترکیب شبکه‌های عصبی LSTM و GRU استفاده شده است. LSTM نوعی شبکه عصبی یادگیری عمیق است که توانایی اضافه کردن مفهوم زمان به مدل‌سازی را دارد. لذا در پژوهش حاضر به دلیل ماهیت سری زمانی داده‌های گرد و غبار، مورد توجه قرار گرفته است. این شبکه به دلیل داشتن دروازه‌های زیاد، بسیار کند عمل می‌کند که برای جبران آن از لایه‌های GRU که نمونه دیگری از شبکه‌های یادگیری عمیق هستند، استفاده می‌شود. طبق مطالعات (Ansari ghoghghar et al., 2020) میزان کارایی مدل RBF به منظور پیش‌بینی شاخص FDSDD نشان داده شده است (هر چند میزان آن نسبت به سایر فرامدل‌های انفرادی مورد مقایسه کمتر بوده است). لذا در این پژوهش به مقایسه عملکرد مدل هیبریدی توسعه داده شده با فرامدل‌های انفرادی شامل شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF) و ماشین بردار پشتیبان (SVM) جهت پیش‌بینی شاخص FDSDD، پرداخته خواهد شد. بنابراین این تحقیق می‌تواند راهنما و الگوی جدیدی به منظور پیش‌بینی پدیده طوفان‌های گرد و غبار باشد. لازم به ذکر است که نتایج تحقیق (Liaghat et al., 2020) نشان می‌دهد مدل‌های ساده سری زمانی در مقایسه با هوش مصنوعی کارایی مناسبی ندارند به همین علت در پژوهش حاضر مدل‌های هیبریدی با مدل‌های هوش مصنوعی مقایسه شده است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

در این پژوهش به بررسی عملکرد مدل هیبریدی پیشنهادی GRU-LSTM و مقایسه آن با فرامدل‌های انفرادی RBF و SVM به منظور

آبادان با مقدار ۰/۸۷۵ و دمای کمینه در ایستگاه اهواز با مقدار ۰/۸۹۳ می‌باشد. همچنین در این تحقیق مدل‌سازی رگرسیون چند متغیره بین گردوغبار و پارامترهای مختلف دما در نیمه غربی کشور نیز نشان داد که تأثیر متغیرهای حدی دما در وقایع گردوغبار بیشتر از دمای متوسط است و مدل‌های رگرسیونی نیز نشان داد که در بهترین حالت، متغیرهای حدی دما در آبادان ۸۱/۲ درصد و در بندرماهشهر ۷۹/۳ درصد از تغییرات شاخص FDSDD را تبیین می‌کنند. Liaghat et al. (2020) در تحقیقی به مقایسه عملکرد مدل‌های سری زمانی SARIMA و Holt-Winters با روش‌های هوش مصنوعی شامل شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF) و سیستم استنباط عصبی- فازی تطبیقی (ANFIS) به منظور پیش‌بینی فراوانی روزهای همراه با طوفان گردوغبار (FDSDD) در فصل آبی پرداختند. نتایج تحقیق آن‌ها نشان داد که روش هوش مصنوعی ANFIS بهترین و مدل‌های سری زمانی SARIMA و Holt-Winters بدترین عملکرد را داشتند. (Baghbanan et al., 2020) در پژوهشی با استفاده از داده‌های ماهانه فراوانی روزهای طوفان گرد و غبار (FDSDD) در ۴۴ ایستگاه سینوپتیک ایران طی دوره ۵۰ ساله (۲۰۱۷-۱۹۶۸) به بررسی تغییرات زمانی در طوفان‌های گرد و غبار با استفاده از سه روش تحلیل خوشه سلسله مراتبی، روش رگرسیون خطی و آزمون غیر پارامتری من‌کنندال پرداختند. نتایج این پژوهش نشان داد که بیشترین فراوانی وقوع این پدیده در ماه‌های ژوئیه، ژوئن و مه و در دوره فصلی، اوج طوفان‌های گرد و غبار در بهار و تابستان متمرکز شده است. علاوه بر این، از نظر تجزیه و تحلیل مکانی، در دوره‌های ماهانه، فصلی و سالانه، حداکثر FDSDD در جنوب شرقی و مناطق جنوبی بسیار شدیدتر از سایر مناطق ایران می‌باشد. همچنین در این تحقیق شیب تغییرات طوفان‌های گرد و غبار ایران نشان داد که روند تغییرات در کل دوره‌های ماهانه، فصلی و سالانه افزایشی است و طبق نتایج، آزمون مان-کنندال، قابل توجه است. (Ansari Ghoghghar et al., 2020) با استفاده از چهار روش هوش مصنوعی شامل شبکه عصبی پرسپترونیک چندلایه (MLP)، سیستم استنتاج عصبی- فازی تطبیقی (ANFIS)، شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF) و شبکه عصبی رگرسیون تعمیم‌یافته^{۱۳} (GRNN)، اقدام به پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار در یک فصل بعد کردند. آن‌ها با مقایسه مدل‌های مورد استفاده، دریافتند که ANFIS بهترین عملکرد و بعد از آن GRNN بهترین نتیجه را ارائه نموده است که این موضوع کارایی نامطلوب مدل RBF را نشان می‌دهد.

در بحث پیش‌بینی طوفان‌های گرد و غبار از داده‌های دید افقی و کدهای سازمان هواشناسی استفاده می‌شود و طبق تعریف سازمان جهانی هواشناسی روزهای همراه با طوفان‌های گرد و غبار به روزی

هواشناسی محاسبه و در جدول ۲ نشان داده شده است. ضمن اینکه ایستگاه‌های هواشناسی در استان مربوطه، طول و عرض جغرافیایی، میانگین فصلی FDS و مجموع FDS به ترتیب نزولی قابل مشاهده است. شکل ۱ موقعیت جغرافیایی ایستگاه‌های سینوپتیک مورد مطالعه در استان خوزستان را نشان می‌دهد.

۲-۲- شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF)

شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF)، دارای پایه ریاضیاتی بسیار قوی بر مبنای فرضیه منظم‌سازی برای حل مسائل مشکل می‌باشد. به طور کلی این شبکه از سه لایه شامل لایه ورودی، مخفی و خروجی تشکیل شده است (Chen et al., 1991). در این شبکه، تابع انتقال گوسی در لایه مخفی استفاده می‌شود و در لایه خروجی تابع انتقال، خطی است RBF. پایه و اساس نوع خاصی از شبکه‌های عصبی به نام شبکه‌های عصبی آماری است. در شکل ۲ یک شبکه RBF نشان داده شده است. همان‌طور که در شکل مشخص است، نورون RBF یک تابع گوسی است. ورودی این تابع، فاصله اقلیدسی بین هر ورودی به نورون با بردار مشخص شده هم‌اندازه بردار ورودی است. این تابع گوسی از رابطه (۱) استفاده می‌کند (Araghinejad, 2013):

$$f(X_r, b) = e^{-I^2} \quad (1)$$

$$I = \frac{\|X_r - X_b\| * 0.8326}{h}$$

در این رابطه X_r ورودی شبکه با خروجی نامعلوم، X_b ورودی مشاهداتی در زمان یا مکان b و h پارامتری است که پهنای تابع گوسی را کنترل می‌کند. خروجی این تابع بین صفر تا یک متغیر است (Araghinejad, 2013). محاسبه خروجی Y_r بر اساس متغیر مستقل X_r به صورت رابطه (۲) به دست می‌آید:

$$Y_r = LW * f(X_r, b) + Bias \quad (2)$$

پیش‌بینی شاخص FDS در هفت ایستگاه سینوپتیک استان خوزستان (آبادان، اهواز، بستان، بندرماهشهر، مسجدسلیمان، صفی‌آباد و دزفول) با جامعه آماری بلند مدت ۳۰ ساله (۲۰۱۹-۱۹۹۰) پرداخته شد. بدین منظور از داده‌های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی^{۱۵} (WMO) در مقیاس فصلی استفاده شد. مشاهدات پدیده‌های هواشناسی به فاصله سه ساعت یک‌بار و در مجموع هشت بار در شبانه‌روز ثبت می‌گردد. در این مشاهدات، پدیده‌های بصری آب و هوا بر اساس دستورالعمل سازمان جهانی هواشناسی در ۱۰۰ کد (۹۹-۰۰) تعریف شده که از این ۱۰۰ کد به‌طور کلی به‌منظور ثبت و گزارش پدیده گرد و غبار در ایستگاه‌های مختلف هواشناسی از ۱۱ کد استفاده می‌شود (O'Loingsigh et al., 2014). کدهای مربوط به طوفان‌های گرد و غبار در جدول ۱ ارائه شده است. با توجه به اینکه داده‌های گرد و غبار به‌صورت تفکیک نشده از سایر پدیده‌های هواشناسی از سازمان هواشناسی در اختیار قرار می‌گیرد، بنابراین در وهله اول کدهای مربوط به گرد و غبار از سایر پدیده‌های اقلیمی در ساعات مختلف هم‌دید جدا گردید (Goudie and Middleton, 2006). بر اساس تعریف سازمان جهانی هواشناسی روزهای همراه با طوفان‌های گرد و غبار به روزی گفته می‌شود که حداقل در یکی از هشت سینوپ (گزارش‌های سه‌ساعته دیده‌بانی)، یکی از کدهای مربوط به گرد و غبار (۰۶، ۰۷، ۰۸، ۰۹، ۳۰ تا ۳۵ و ۹۸) در بخش هوای حاضر گزارش شده باشد. البته به شرط اینکه داده‌های قدرت دید افقی متناظر با آن کد گرد و غبار کمتر از ۱۰۰۰ متر به ثبت رسیده باشد (Mohammadi, 2015). در این مطالعه برای تشخیص طوفان‌های گرد و غباری از فاکتور قدرت دید افقی ≤ 1000 متر برای همه کدهای هواشناسی گرد و غبار استفاده شده است. بعد از انتخاب ایستگاه‌ها و بررسی داده‌های ۳۰ ساله (۲۰۱۹-۱۹۹۰)، تعداد روزهای همراه با طوفان گرد و غباری برای هفت ایستگاه سینوپتیک واقع در استان خوزستان با استفاده از داده‌های دید افقی و کدهای سازمان

Table 1- Word Meteorological Organization (WMO) codes related to wind erosion and dust phenomena (O'Loingsigh et al., 2014)

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

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

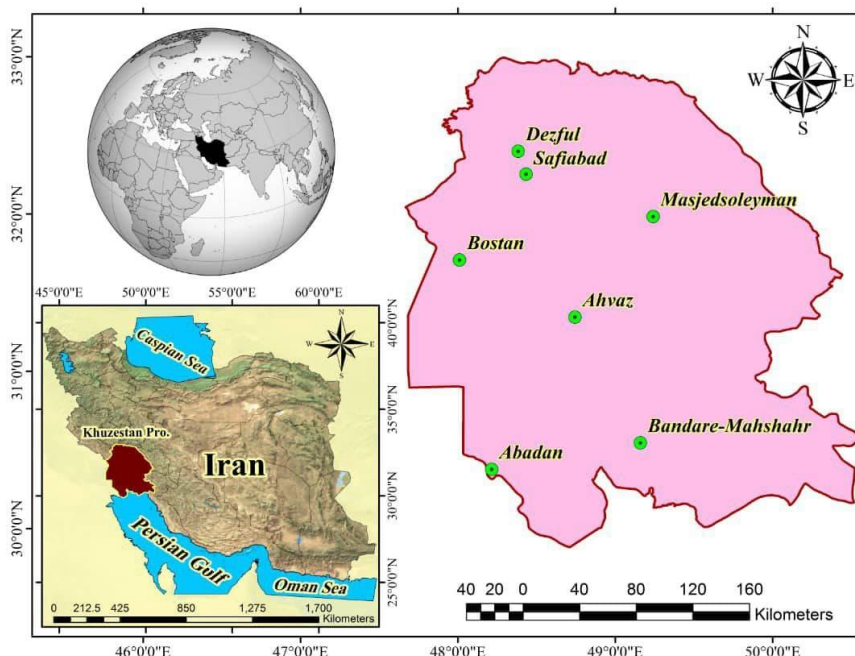


Fig. 1- Introduction of the studied stations in the present study

شکل ۱- معرفی ایستگاه‌های مورد مطالعه در پژوهش حاضر

Table 2- Frequency of Dust Stormy Days (1990-2019)

جدول ۲- فراوانی روزهای همراه با طوفان‌های گرد و غبار استان خوزستان (۱۹۹۰-۲۰۱۹)

Station	Latitude (degrees)	Longitude (degrees)	Seasonal average FDS (days)	Total FDS (days)
Abadan	30.38	48.21	4.36	524
Ahwaz	31.34	48.74	3.69	443
Bostan	31.71	48.01	3.26	391
Bandare-Mahshahr	30.55	49.16	2.90	348
MasjedSoleyman	31.98	49.24	2.86	344
Safiabad	32.25	48.43	2.21	265
Dezful	32.40	48.38	2.02	243

مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری اغتشاش (خطای مجاز (ε)) مشخص شود (Vapnik, 1995):

$$f(x) = W^T \cdot \phi(x) + b \quad (3)$$

$$y = f(x) + \varepsilon \quad (4)$$

چنانچه W^T ترانهاده بردار ضرایب و b ثابت مشخصه‌های تابع رگرسیونی و ϕ نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با آموزش مدل SVM توسط مجموعه‌ای از داده‌ها (مجموعه آموزش) محقق می‌شود (Misra et al., 2009). برای محاسبه W و b لازم است تابع خطا (رابطه ۵) در مدل SVM- ε با در نظر گرفتن شرایط مندرج (قیود) در روابط ۶ و ۷ کمینه شود (Hamel, 2009):

در این رابطه LW و Bias به ترتیب وزن ماتریس ارتباطات بین لایه مخفی و لایه خروجی و ماتریس بایاس لایه خروجی است (Araghinejad, 2013).

۳-۲- ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد (Vapnik, 1995). در مدل رگرسیون SVM تابعی مرتبط با متغیر وابسته Y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود. مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای




Fig. 2- Schematic of Radial Basis Function
شکل ۲- شماتیک RBF (Araghinejad, 2013)

کرنل از طریق سعی و خطا بهینه گردیدند.

$$K(x, x_j) = (t + x_i \times x_j)^d \quad (10)$$

$$K(x, x_j) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (11)$$

$$K(x, x_j) = x_i \times x_j \quad (12)$$

$$\frac{1}{2} W^T \cdot W + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* \quad (5)$$

$$W^T \cdot \phi(X_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad (6)$$

$$y_i - W^T \cdot \phi(X_i) - b \leq \varepsilon + \varepsilon_i \cdot \varepsilon_i \quad (7)$$

$$\varepsilon_i^* \geq 0, i = 1.2. \dots N$$

۲-۴- روش پیشنهادی؛ ترکیب شبکه LSTM و GRU

به منظور دستیابی به نتایج دقیق تر و کامل تر در مدل سازی متغیرهای هیدرولوژیکی و اقلیمی باید روش های خطی و غیرخطی با یکدیگر ادغام شوند. به تازگی رویکردهای مبتنی بر شبکه های عصبی بازگشتی و یادگیری عمیق برای این منظور پیشنهاد شده است. در میان نتایج برگرفته از روش های مبتنی بر شبکه های عصبی بازگشتی، عملکرد روش LSTM نسبت به سایر روش ها بهتر بوده است. LSTM نسخه بهبود یافته شبکه های بازگشتی است و به تازگی الگوریتم GRU برای بهبود این شبکه ها پیشنهاد شده است. با توجه به کارایی مناسب شبکه های GRU، در تحقیق حاضر سعی شده است با ترکیب شبکه های LSTM و GRU دقت پیش بینی این مدل بهبود داده شود. در فرآیند ترکیب، خروجی لایه GRU به لایه LSTM ارسال می شود و خروجی لایه LSTM پس از ادغام به لایه های تمام متصل می رسد. خروجی لایه های تمام متصل نیز به لایه رگرسیون فرستاده می شود تا فرآیند پیش بینی انجام گیرد. شکل ۳ کلیات روش پیشنهادی را نشان می دهد. در واقع، روش پیشنهادی یک ساختار چهار لایه است. این چهار لایه عبارتند از: Input layer، GRNN، LSTM و Output. در لایه Input layer هر یک از ویژگی های ورودی که مربوط به یک پیش بینی هستند، به ورودی های GRU داده می شوند. در لایه GRU، ورودی لایه بردارهایی هستند که از لایه Input گرفته شده اند. در لایه LSTM ورودی لایه بردارهایی هستند که از لایه GRU گرفته

در معادلات بالا C عددی صحیح و مثبت است، که عامل تعیین جرمه در هنگام رخ دادن خطای آموزش مدل است. ϕ تابع کرنل، N تعداد نمونه ها و دو مشخصه ε_i و ε_i^* متغیرهای کمبود هستند. در نهایت تابع SVM رگرسیونی را می توان به صورت رابطه ۸ بازنویسی کرد:

$$f(x) = \sum_{i=1}^N \alpha_i \phi(x_i)^T \phi(x) + b \quad (8)$$

در معادله ۸، α_i میانگین ضرایب لاگرانژ می باشد. محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد (Yoon et al., 2011). برای حل این مشکل، روند معمول در مدل SVM رگرسیونی انتخاب یک تابع کرنل به صورت رابطه ۹ است:

$$K(X_j, X) = \phi(x_i)^T \sqrt{b^2 - 4ac} \quad (9)$$

می توان از توابع مختلف کرنل برای ساخت انواع مختلف ε -SVM استفاده کرد. انواع توابع کرنل قابل استفاده در مدل SVM رگرسیونی عبارتند از: کرنل چندجمله ای^{۱۶} و کرنل توابع پایه شعاعی (RBF) و کرنل خطی، که به ترتیب طبق روابط ۱۰ تا ۱۲ محاسبه می گردند. با توجه به اینکه از پرکاربردترین توابع کرنل، کرنل پایه شعاعی، خطی و چند جمله ای می باشد (Vapnik, 2007; Basak, 2007). در این پژوهش از این سه تابع کرنل استفاده شده است و در این بین کرنل توابع پایه شعاعی که از عملکرد بهتری نسبت به سایر کرنل ها برخوردار بود، استفاده گردید. قابل ذکر است فرآیند محاسبات ماشین بردار پشتیبان براساس کدنویسی در محیط R انجام، و پارامترهای توابع

گام‌های زمانی گذشته استفاده می‌شود. برای نمونه، به منظور پیش‌بینی شاخص FDSO زمانی t_{11} از تمامی مقادیر قبلی از زمان t_1 تا t_{10} به عنوان ورودی استفاده شده و به همین ترتیب، برای پیش‌بینی t_{12} مقادیر قبلی از زمان t_2 تا t_{12} به عنوان ورودی در نظر گرفته می‌شوند. این عمل برای تمامی داده‌ها از جمله داده‌های آموزشی و آزمون استفاده می‌شود.

۲-۴-۲- ارسال ورودی به لایه GRU

پس از آنکه عملیات پیش‌پردازش روی مجموعه داده‌های پژوهشی انجام گرفت، پنجره‌های لغزان (زمانی) تشکیل شده و داده‌ها در قالب پنجره‌های لغزان و به عنوان ورودی به لایه GRU ارسال می‌شوند. در این گام، تعداد بلوک‌های لایه GRU به اندازه ویژگی‌های مجموعه داده‌های پژوهش خواهد بود. شکل ۵ چگونگی این فرآیند را نشان می‌دهد.

ورودی لایه GRU بردارهایی هستند که از لایه Input گرفته شده‌اند. این بردارها را به صورت $out_{embed} = [X_1, X_2, \dots, X_n]$ می‌توان نمایش داد. این بردارها با رابطه ۱۳ محاسبه می‌شوند:

$$\begin{aligned} z_t &= \sigma(W_z x_t + U_z h_{t-1} + b_z) \\ r_t &= \sigma(W_r x_t + U_r h_{t-1} + b_r) \\ \hat{h}_t &= \sigma(W_h x_t + U_h (r_t h_{t-1})) + b_h \\ h_t &= (1 - z_t) h_{t-1} + z_t \hat{h}_t \end{aligned} \quad (13)$$

که در آن بردارهای به ترتیب گیت Update، گیت Rest، گیت شرطی و خروجی فعال است. $W_R, W_r, W_N, W_z, W_R, W_N$ به ترتیب ماتریس‌های قابل یادگیری، بایاس‌های قابل یادگیری، تابع فعال‌ساز و علامت ضرب نقطه‌ای بین عناصر هستند.

شده‌اند. در لایه Output خروجی شبکه LSTM ابتدا Flatten می‌شود. در مدل پیشنهادی پس از دریافت مجموعه داده پژوهش، عملیات نرمال‌سازی داده‌ها انجام می‌شود. در ادامه، داده‌ها به دسته آموزش و آزمون تقسیم می‌شوند. پیشنهاد اولیه ۸۰ درصد برای داده‌های آموزش و ۲۰ درصد برای داده‌های آزمون است. سپس، فرآیند یادگیری مدل با استفاده از شبکه ترکیبی GRU-LSTM شروع می‌شود. در این گام به ازای هر ویژگی از مجموعه داده پژوهش، یک بلوک GRU در نظر گرفته می‌شود. به طور مثال، اگر مجموعه داده شامل ۷ ویژگی باشد، تعداد ۷ بلوک GRU برای یادگیری نیاز خواهد بود. بلوک‌های GRU هم‌زمان وزن و ویژگی نسبت به ویژگی ماقبل را یاد می‌گیرند تا با بهره‌گیری از آن بتوانند نوسان‌های به‌وجود آمده برای شاخص FDSO را پیش‌بینی کنند. در گام بعدی، خروجی لایه GRU به لایه LSTM می‌رسد و LSTM پس از پردازش روی داده‌های ورودی، نتیجه را به لایه تمام‌متصل ارسال می‌کند که تابع فعال‌ساز آن تابع سیگموئید است. این لایه وظیفه پیش‌بینی را به عهده دارد. لایه‌های تمام‌متصل همانند همتایان خود در شبکه‌های عصبی سنتی عمل می‌کنند و تقریباً ۹۰ درصد از پارامترهای یک شبکه عمیق را شامل می‌شوند. لایه تمام‌متصل این امکان را فراهم می‌کند که خروجی شبکه در قالب یک بردار با اندازه مشخص ارائه شود. شکل ۴ بلوک دیاگرام کلی روش پیشنهادی را نشان می‌دهد.

۲-۴-۱- تشکیل پنجره‌های لغزان (SW)

در این گام پنجره‌های لغزان برای پیش‌بینی شاخص FDSO تشکیل می‌شود. در شکل ۵ چگونگی این فرآیند نمایش داده شده است. اساس پنجره‌های لغزان این است که برای پیش‌بینی گام n ام، از اطلاعات

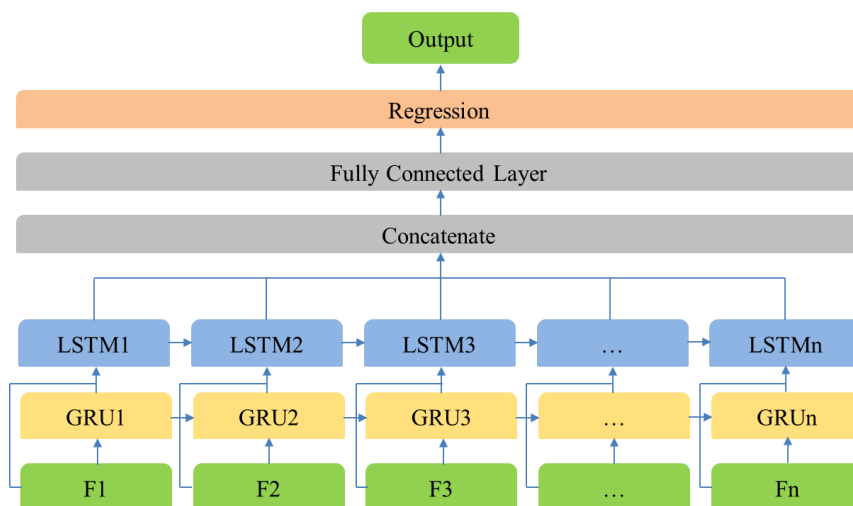


Fig. 3- The structure of the proposed algorithm

شکل ۳- ساختار الگوریتم پیشنهادی

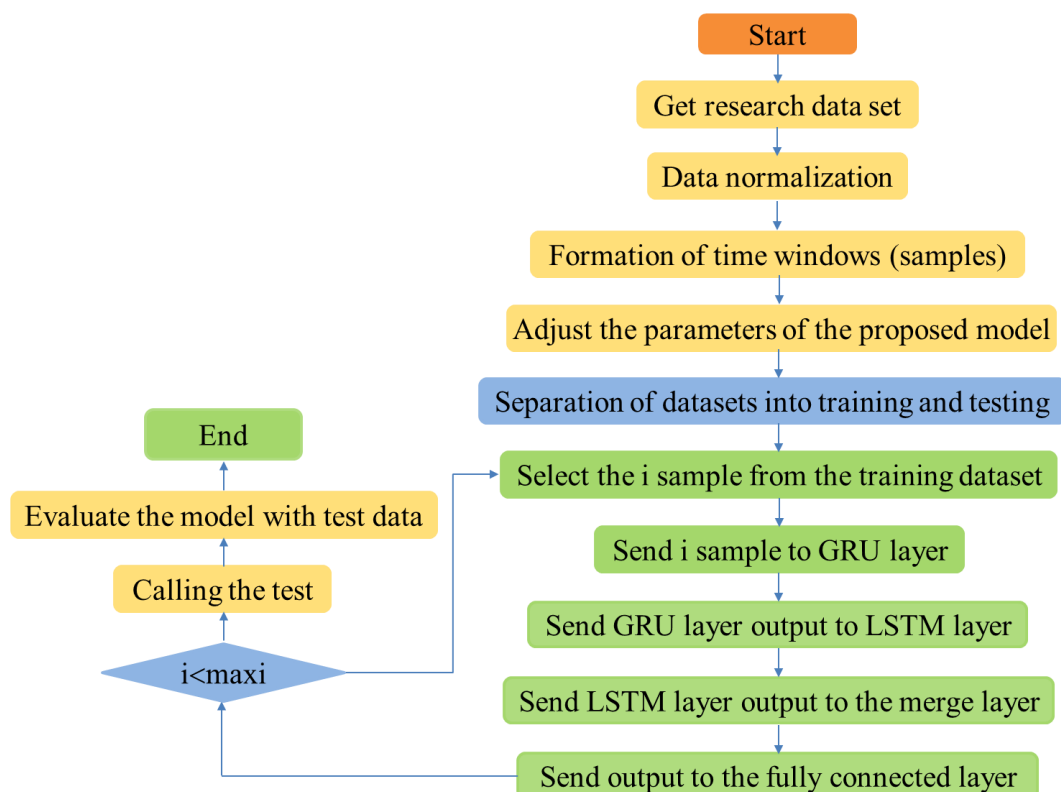


Fig. 4- Block diagram of the proposed method GRU-LSTM
 شکل ۴- بلوک دیاگرام روش پیشنهادی GRU-LSTM




Fig. 5- How to create model inputs based on the idea of a slider window
 شکل ۵- چگونگی ایجاد ورودی‌های مدل براساس ایده پنجره لغزان

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$$

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$$

$$g_t = \tanh(W_g[h_{t-1}, x_t] + b_g)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$
 (۱۴)

که در این روابط i_t گیت Input، f_t گیت Forget، g_t گیت Update و O_t گیت Output هستند. همچنین W ماتریس‌های قابل یادگیری در شبکه عصبی، b بردارهای قابل یادگیری در شبکه عصبی، h_{t-1} مقدار Hidden State قبل و نیز x_t مقدار ورودی و σ تابع فعال‌سازی استفاده شده است.

۲-۴-۳- ارسال خروجی لایه GRU به LSTM
 گام بعدی در روش پیشنهادی برای پیش‌بینی شاخص FDS، ارسال خروجی لایه GRU به عنوان ورودی به لایه LSTM است. شکل ۶ چگونگی این فرآیند را نشان می‌دهد.

ورودی LSTM در گام T بردار $X \in \mathbb{R}^E$ است که دنباله بردارهای مخفی^{۱۸} در LSTM را نشان می‌دهد. این بردار از طریق رابطه ۱۴ محاسبه می‌شود:




Fig. 6- The process of sending the output of the LSTM layer to the GRU

شکل ۶- فرآیند ارسال خروجی لایه LSTM به GRU

بیان شده ارائه می‌شود؛ روش‌های پیش‌بینی به کار رفته در این پژوهش شامل فرامدل‌های انفرادی RBF و SVM و مدل هیبریدی GRU-LSTM می‌باشد.

$$FSDS_{(t+1)} = f(FSDS_{(t)}) \quad \text{مدل ۱ (۱۵)}$$

$$FSDS_{(t+1)} = f(FSDS_{(t)}, FSDS_{(t-1)}) \quad \text{مدل ۲ (۱۶)}$$

$$\text{مدل ۳ (۱۷)}$$

$$FSDS_{(t+1)} = f(FSDS_{(t)}, FSDS_{(t-1)}, FSDS_{(t-2)}) \quad \text{مدل ۴ (۱۸)}$$

$FSDS_{(t+1)} = f(FSDS_{(t)}, FSDS_{(t-1)}, FSDS_{(t-2)}, FSDS_{(t-3)})$
 پس از بررسی و کنترل کیفی آمار ایستگاه‌ها و رفع نواقص آماری، همگنی داده‌ها با استفاده از آزمون Run Test ارزیابی و تصادفی بودن داده‌ها در سطح اطمینان ۹۵ درصد پذیرفته شد. در ادامه با توجه به وجود سری زمانی متغیر فراوانی روزهای همراه با طوفان‌های گرد و غبار، اقدام به پیش‌بینی آن با استفاده از مدل هیبریدی GRU-LSTM و فرامدل‌های انفرادی RBF و SVM شد. ۸۰ درصد داده‌ها برای مرحله آموزش و ۲۰ درصد آن برای آزمون مورد استفاده قرار گرفت. پارامترهای مناسب روش‌های مختلف از طریق آزمون و خطا تعیین شد. همچنین به منظور جلوگیری از بیش برآزش از صحت‌سنجی متقاطع استفاده شد. در روش صحت‌سنجی متقاطع^{۱۹} در هر بار اجرای مدل برای پیش‌بینی با یک پارامتر مشخص، یک یا تعدادی از داده‌های مجموعه آموزش کنار گذاشته می‌شوند (به عنوان داده‌های صحت‌سنجی) و مدل بر اساس داده‌های باقیمانده آموزش می‌بیند. سپس داده‌های کنار گذاشته‌شده به مجموعه آموزش برگردانده شده و داده یا مجموعه دیگری از داده‌های آموزش به عنوان داده صحت‌سنجی از این مسیر جدا می‌شوند و بار دیگر شبکه آموزش داده می‌شود. این فرایند تا زمانی که تمام داده‌های آموزش در قسمت صحت‌سنجی استفاده شوند، ادامه می‌یابد. پس از آن بر اساس میانگین خطای مدل در تخمین داده‌های صحت‌سنجی، پارامتر(های) مناسب شبکه عصبی تعیین می‌شوند. برای پیش‌بینی از سه مدل معرفی‌شده فوق‌الذکر استفاده شد. مدل مناسب بر اساس معیارهای ارزیابی که در بخش بعد معرفی شده‌اند، انتخاب شده‌اند.

این لایه می‌تواند به صورت تک‌لایه یا به صورت پشته‌ای از لایه‌ها به کار گرفته شود. در حالت چند لایه به اصطلاح به آن LSTM عمیق یا پشته‌ای از LSTM‌ها گفته می‌شود.

۴-۴-۲- ارسال خروجی به لایه تمام‌متصل

در آخرین لایه از روش پیشنهادی، لایه‌های تمام‌متصل وجود دارند که برای ادامه فرآیند نمایش ویژگی‌ها تبدیل می‌کنند. از سویی، این لایه وظیفه محاسبه امتیاز دسته‌های کلاس‌های اشیا را به عهده دارد. لایه‌های تمام‌متصل همانند همتایان خود در شبکه‌های عصبی سنتی عمل می‌کنند و تقریب ۹۰ درصد از پارامترهای یک شبکه عمیق باور را شامل می‌شوند. لایه تمام‌متصل این امکان را می‌دهد که خروجی شبکه در قالب یک بردار با اندازه مشخص ارائه شود. از این بردار برای رده‌بندی اشیا و یا ادامه فرآیند پردازش نیز استفاده می‌شود.

۵-۲- مدل‌های پیش‌بینی

به منظور پیش‌بینی کمی فراوانی روزهای همراه با طوفان‌های گرد و غبار (FSDS) یک مدل هیبریدی پیشنهادی و دو فرامدل انفرادی شامل RBF و SVM مورد استفاده قرار گرفت. سپس بر اساس معیارهای ارزیابی بهترین مدل در هر پیش‌بینی انتخاب شد. متغیر تعداد فصل(های) گذشته برای پیش‌بینی فصل آتی به کار گرفته شد که می‌تواند شامل یک، دو، سه و چهار فصل قبل از متغیر فراوانی روزهای همراه با طوفان‌های گرد و غبار باشد. در مدل ۱، برای پیش‌بینی متغیر فراوانی روزهای همراه با طوفان‌های گرد و غبار در فصل بعد، از سری زمانی FSDS با یک گام تأخیر استفاده شد. بدین صورت که برای پیش‌بینی در زمان $t+1$ ، از مقدار آن در زمان t استفاده شد. در مدل ۲، پیش‌بینی در فصل بعد بر اساس مقادیر فراوانی روزهای همراه با طوفان‌های گرد و غبار تا دو فصل قبل استفاده شد و به طور مشابه در مدل ۳ و ۴، پیش‌بینی‌ها بر اساس مقادیر متغیر مورد نظر تا سه و چهار فصل قبل صورت پذیرفت. روابط ۱۵ تا ۱۸ در تکمیل توضیحات

۲-۶- معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب همبستگی (R) ریشه میانگین مربعات خطا (RMSE) میانگین قدر مطلق خطا (MAE) و ضریب نش- ساتکلیف (NS) طبق روابط زیر استفاده گردید. بهترین مقدار برای این چهار معیار به ترتیب یک، صفر، و یک می‌باشد:

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (19)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2} \quad 0 \leq RMSE < \infty \quad (20)$$

$$MAE = \frac{1}{n} \sum_{i=1}^N |x_i - y_i| \quad 0 \leq MAE < \infty \quad (21)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad -\infty < NS \leq 1 \quad (22)$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام‌های زمانی i ام، N تعداد گام‌های زمانی، \bar{x} و \bar{y} نیز ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد (Zhu, 2007).

۳- نتایج و بحث

شکل ۷ تغییرات شاخص FDSDD را در مقیاس فصلی در ایستگاه‌های مورد مطالعه واقع در استان خوزستان نشان می‌دهد. بر اساس این شکل، فراوانی روزهای همراه با طوفان گرد و غبار در ایستگاه‌های آبادان، اهواز و بستان که رکورددار شاخص FDSDD در استان هستند، به صورت متمرکز در کنار یکدیگر مشاهده می‌شود که حکایت از وقوع طوفان‌های گرد و غبار متوالی در این سه ایستگاه از سال ۲۰۰۸ به بعد دارد. با توجه به شکل ۸ وجود فصول متوالی عاری از طوفان‌های گرد و غبار، انقطاع و داشتن یک سری زمانی منفصل و به تبع آن تشکیل

طوفان‌هایی با فاصله زمانی بیشتر نسبت به ایستگاه‌های آبادان اهواز و بستان از سال ۱۹۹۰ تا ۲۰۰۳ در ایستگاه‌های دزفول، صفی‌آباد، مسجد سلیمان و بندر ماهشهر مشهود است. با توجه به شکل ۸ می‌توان سه دوره طولانی مدت اوج طوفان‌های گرد و غبار مربوط به سال‌های ۲۰۰۲-۱۹۹۲، ۲۰۱۳-۲۰۰۸، و ۲۰۱۹-۲۰۱۶ را در تمام ایستگاه‌های مورد مطالعه تشخیص داد.

۳-۱- نتایج مدل‌سازی با روش RBF

پایه‌سازی فرامدل انفرادی شبکه عصبی مبتنی بر توابع پایه شعاعی به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار با استفاده از داده‌های آموزشی از طریق محیط برنامه‌نویسی R انجام شده است. در جدول ۳ نتایج مربوط به مدل‌سازی شاخص FDSDD با استفاده از فرامدل انفرادی RBF آورده شده است. در این جدول با توجه به معیارهای ارزیابی ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE)، میانگین قدرمطلق خطا (MAE) و ضریب نش ساتکلیف (NS)، در تمامی ایستگاه‌های مورد مطالعه، ترکیب شماره ۱ و ۲ نسبت به سایر ترکیب‌های مورد بررسی، به‌طور نسبی دارای نتایج بهتری است. این امر نشان می‌دهد که در ساختار شبکه عصبی مبتنی بر توابع پایه شعاعی، استفاده از سوابق فراوانی روزهای همراه با طوفان گرد و غبار در فصل‌های قبل، موجب بهبود نتایج پیش‌بینی نمی‌شود به طوری که در ایستگاه‌های دزفول، صفی‌آباد، مسجد سلیمان، بندرماهشهر، بستان، اهواز و آبادان برای دوره آزمون، با اعمال شاخص FDSDD از چهار به دو فصل قبل، شاخص RMSE به ترتیب از مقادیر ۰/۶۴۹، ۰/۶۴۵، ۰/۶۴۳، ۰/۶۴۳، ۰/۶۴۳، ۰/۶۴۳، ۰/۶۳۹، و ۰/۶۳۷ روز به ۰/۶۴۱، ۰/۶۳۵، ۰/۶۳۲، ۰/۶۳۲، ۰/۶۳۲، ۰/۶۳۲، ۰/۶۲۹ و ۰/۶۲۴ روز کاهش یافته است.

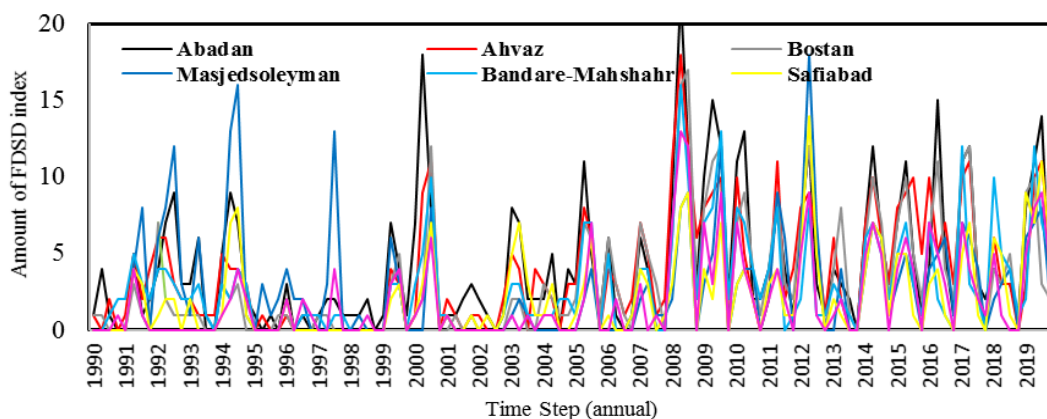


Fig. 7- Time series of FDSDD index in seasonal time scale for the studied stations located in Khuzestan Province

شکل ۷- سری زمانی شاخص FDSDD در مقیاس زمانی فصلی برای ایستگاه‌های مورد مطالعه واقع در استان خوزستان

این درحالی است که در ایستگاه‌های بندر ماهشهر، بستان و اهواز، حتی با اعمال شاخص FDSDD از دو به یک فصل قبل، معیار ارزیابی RMSE به ترتیب از مقادیر ۰/۶۳۷، ۰/۶۳۲ و ۰/۶۲۹ روز به ۰/۶۳۱، ۰/۶۳۰ و ۰/۶۲۸ روز بهبود می‌یابد. به نظر می‌رسد با توجه به شرایط آب و هوایی در منطقه مورد مطالعه، تأثیر شاخص FDSDD فصل‌های قبل به منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار در فصل آینده، آنچنان قابل قبول نیست. با توجه به این که در جدول ۳ ترتیب ایستگاه‌ها به لحاظ شاخص FDSDD از ایستگاه دزفول تا آبادان صعودی بوده و متوسط فراوانی روزهای همراه با طوفان گرد و غبار در مقیاس فصلی ۲/۰۲ تا ۴/۳۶ روز متغیر است، می‌توان نتیجه گرفت که عملکرد فرامدل انفرادی RBF به‌منظور پیش‌بینی شاخص FDSDD با افزایش تعداد روزهای همراه با طوفان گرد و غبار رابطه مستقیمی دارد. بدین معنی که با افزایش فراوانی روزهای همراه با طوفان گرد و غبار، مقادیر معیارهای ارزیابی همگی بهبود می‌یابند.

۳-۲- نتایج مدل‌سازی با روش SVM

مدل SVM با استفاده از کدنویسی در محیط R انجام شده است. در این پژوهش از کرنل RBF با پارامترهای (ϵ, σ, C) برای مدل‌سازی فراوانی روزهای همراه با طوفان گرد و غبار استفاده شد که طرح جستجوی پارامترهای به کار رفته، الگوریتم تکامل SCE-UA^{۲۰} است که طبق پیشنهاد Rosin and Belew (1995) در آنالیزهای هیدرولوژی با موفقیت پیاده سازی شده است. جدول ۴ بیانگر نتایج مربوط به فرامدل انفرادی ماشین بردار پشتیبان (SVM) است. برای به دست آوردن مقادیر مناسب پارامترهای (ϵ, σ, C) ، معیار RMSE برای بهینه‌سازی پارامترها، در همه ایستگاه‌های مورد مطالعه واقع در استان خوزستان استفاده شد. بهترین خروجی‌های سه‌تایی مرتب (ϵ, σ, C) در ایستگاه‌های دزفول، صفی‌آباد، مسجدسلیمان، بندرماهشهر، بستان، اهواز و آبادان به ترتیب مربوط به پارامترهای $(2100, 16/5, 0/212)$ ، $(39000, 56/1, 0/125)$ ، $(90000, 36, 0/412)$ ، $(6000, 31, 0/321)$ ، $(13000, 4/1, 0/412)$ ، $(120000, 10/5, 0/451)$ و $(60000, 13, 0/122)$ بوده که نسبت به سایر ترکیب‌ها، بهترین عملکرد را داشته‌اند.

در این روش نیز همانند روش RBF در همه ایستگاه‌های مورد مطالعه، نتایج با اعمال تأثیر شاخص FDSDD یک یا دو فصل قبل بهبود یافته و با اعمال تأثیر فصل‌های بیشتر مقادیر خطا روند افزایشی داشته است. به عنوان مثال در ایستگاه‌های اهواز و آبادان، مقدار RMSE با اعمال تأثیر شاخص FDSDD چهار فصل قبل در مرحله‌ی آزمون به ترتیب برابر ۰/۵۱۷ و ۰/۵۰۹ روز بوده است که به ترتیب با اعمال تأثیر شاخص

FDSDD یک و دو فصل قبل، به کمترین مقدار خود یعنی ۰/۴۹۸ و ۰/۴۸۲ روز رسیده است. لازم به ذکر است، مقادیر مربوط به پارامترهای سه‌گانه مدل SVM مقادیر بهینه هستند که با استفاده از روش GRU-LSTM بهینه‌سازی شده است.

۳-۳- نتایج مدل‌سازی با شبکه ترکیبی GRU-LSTM

شبکه‌های GRU و LSTM سه پارامتر اصلی برای تنظیم دارند؛ تعداد دوره‌ها یا تعداد گذرهای کامل در مجموعه داده‌ها طی فاز آموزش، تعداد نرون‌ها در شبکه عصبی و طول پنجره (w) . این پارامترها با بهینه‌سازی در حین پیش‌بینی شاخص FDSDD مدنظر، انتخاب می‌شوند. انتخاب تعداد دوره‌ها و تعداد نرون‌ها تأثیر چندانی بر روی نتایج نمی‌گذارد لذا این دو پارامتر بررسی و صحت‌سنجی نمی‌شوند. در پژوهش حاضر، یک نرون و دو هزار دوره انتخاب شده است؛ تعداد یک نرون به دلیل ماهیت مسأله که از نوع رگرسیون است، انتخاب شده و تعداد دو هزار دوره توسط الگوریتم جستجوی شبکه‌ای^{۲۱} انتخاب شده است. طبیعی است که هر چه این دو پارامتر بزرگ‌تر باشند، زمان محاسبات نیز طولانی‌تر خواهد بود. علاوه بر موارد یاد شده نوع تابع فعال‌ساز در لایه تمام متصل نیز می‌تواند جزء پارامترهای روش پیشنهادی باشد؛ چرا که انواع مختلفی برای آن وجود دارد و هر یک به صورت مستقل می‌تواند در خروجی نهایی تأثیرگذار باشد. در پژوهش حاضر، تابع فعال‌ساز سیگموئید به کار گرفته شده است. در جدول ۵ نتایج مربوط به فرامدل هیبریدی GRU-LSTM آورده شده است. همانطور که در این جدول مشهود است، مقدار خطا در همه ایستگاه‌های مورد مطالعه به ازای تمام ترکیب‌ها نسبت به فرامدل‌های انفرادی RBF و SVM، تغییر محسوسی داشته است. همچنین ضرائب همبستگی و NS نیز نسبت به سایر مدل‌های مورد استفاده به‌منظور پیش‌بینی شاخص FDSDD، افزایش چشمگیری داشته است.

به طور نمونه در ایستگاه آبادان، مقدار RMSE در مرحله‌ی آزمون برای ترکیب شماره یک از ۰/۶۲۷ روز در روش RBF به ۰/۴۹۱ روز در روش SVM و در نهایت به ۰/۳۱۹ روز در روش ترکیبی GRU-LSTM کاهش یافته است و برای ترکیب شماره چهار از ۰/۶۳۷ روز در روش RBF به ۰/۵۰۹ روز در روش SVM و به ۰/۳۳۸ روز در روش GRU-LSTM بهبود یافته است. در تبیین این نتایج می‌توان بیان نمود که دقت این فرامدل هیبریدی در مقایسه با دو فرامدل انفرادی RBF و SVM بسیار زیاد است. در شکل ۱۱، مقایسه مقادیر مشاهداتی و پیش‌بینی شده شاخص FDSDD در مرحله‌ی ارزیابی به روش GRU-LSTM نمایش داده شده است.

Table 3- Statistical results of RBF model input patterns in predicting FSD index

جدول ۳- نتایج آماری الگوهای ورودی مدل RBF در پیش‌بینی شاخص FSD

Station	Combination number	Test				Training			
		R	RMSE	MAE	NS	R	RMSE	MAE	NS
Dezful	1	0.725	0.645	0.595	0.711	0.807	0.614	0.531	0.748
	2	0.793	0.641	0.592	0.714	0.811	0.611	0.523	0.756
	3	0.713	0.648	0.597	0.707	0.793	0.617	0.537	0.743
	4	0.698	0.649	0.603	0.702	0.785	0.623	0.541	0.739
Safiabad	1	0.728	0.64	0.588	0.714	0.813	0.605	0.527	0.753
	2	0.795	0.635	0.586	0.721	0.819	0.603	0.511	0.764
	3	0.715	0.644	0.593	0.711	0.803	0.609	0.533	0.749
	4	0.699	0.645	0.594	0.704	0.794	0.614	0.538	0.742
Masjedsoleyman	1	0.731	0.639	0.562	0.725	0.823	0.601	0.518	0.764
	2	0.798	0.632	0.555	0.732	0.827	0.598	0.503	0.773
	3	0.717	0.642	0.567	0.719	0.821	0.605	0.527	0.752
	4	0.701	0.643	0.571	0.713	0.809	0.612	0.531	0.749
Bandare-Mahshahr	1	0.803	0.631	0.547	0.748	0.834	0.586	0.498	0.781
	2	0.756	0.637	0.551	0.739	0.829	0.595	0.505	0.775
	3	0.743	0.642	0.564	0.722	0.825	0.598	0.515	0.765
	4	0.722	0.643	0.569	0.718	0.813	0.603	0.526	0.755
Bostan	1	0.817	0.63	0.542	0.757	0.842	0.574	0.481	0.785
	2	0.772	0.632	0.547	0.746	0.837	0.576	0.495	0.779
	3	0.756	0.641	0.561	0.733	0.833	0.593	0.503	0.774
	4	0.734	0.643	0.563	0.725	0.828	0.597	0.511	0.765
Ahvaz	1	0.837	0.628	0.538	0.766	0.849	0.561	0.475	0.789
	2	0.777	0.629	0.544	0.752	0.842	0.574	0.481	0.781
	3	0.761	0.637	0.553	0.744	0.838	0.585	0.494	0.776
	4	0.742	0.639	0.559	0.732	0.831	0.589	0.503	0.769
Abadan	1	0.785	0.627	0.524	0.765	0.852	0.557	0.472	0.795
	2	0.834	0.624	0.531	0.752	0.854	0.545	0.456	0.787
	3	0.766	0.634	0.546	0.747	0.846	0.563	0.485	0.783
	4	0.747	0.637	0.551	0.739	0.837	0.579	0.493	0.774

Table 4- Statistical results of SVM model input patterns and optimal parameters in predicting FDSI index

جدول ۴- نتایج آماری الگوهای ورودی مدل SVM و پارامترهای بهینه در پیش‌بینی شاخص FDSI

Station	Combination number	Test Dataset				Train Dataset				Parameters		
		R	RMSE	MAE	NS	R	RMSE	MAE	NS	C*10 ⁵	σ	ϵ
Dezful	1	0.837	0.545	0.437	0.752	0.865	0.489	0.395	0.801	12.0	4.5	0.325
	2	0.844	0.542	0.431	0.756	0.874	0.486	0.392	0.803	16.5	0.021	0.212
	3	0.833	0.547	0.441	0.748	0.859	0.492	0.398	0.796	78.2	5.6	0.421
	4	0.831	0.551	0.447	0.746	0.852	0.497	0.402	0.791	53.0	17.6	0.378
Safiabad	1	0.844	0.538	0.431	0.759	0.875	0.479	0.391	0.807	48.0	14.3	0.122
	2	0.849	0.528	0.422	0.764	0.883	0.471	0.381	0.811	56.1	3.9	0.125
	3	0.838	0.541	0.438	0.751	0.864	0.485	0.394	0.794	102.0	0.6	0.011
	4	0.833	0.544	0.441	0.748	0.859	0.491	0.396	0.796	84.0	4.1	0.256
Masjed soleyman	1	0.849	0.531	0.425	0.769	0.881	0.466	0.374	0.819	31.0	3.5	0.298
	2	0.855	0.522	0.413	0.783	0.894	0.457	0.365	0.825	36.0	0.9	0.412
	3	0.843	0.538	0.431	0.771	0.879	0.471	0.381	0.802	34.0	7.8	0.511
	4	0.839	0.541	0.44	0.756	0.868	0.485	0.392	0.799	55.0	32.12	0.396
Bandare-Mahshahr	1	0.867	0.515	0.402	0.798	0.899	0.441	0.345	0.834	31.0	0.06	0.321
	2	0.858	0.523	0.417	0.784	0.887	0.453	0.356	0.827	67.0	4.7	0.422
	3	0.849	0.531	0.421	0.779	0.873	0.465	0.369	0.811	9.4	9.11	0.566
	4	0.844	0.538	0.434	0.765	0.871	0.471	0.378	0.804	7.6	12.15	0.721
Bostan	1	0.875	0.503	0.394	0.812	0.905	0.431	0.327	0.845	4.1	0.13	0.412
	2	0.866	0.508	0.397	0.802	0.901	0.448	0.331	0.833	5.5	4.7	0.309
	3	0.855	0.522	0.403	0.785	0.898	0.455	0.346	0.819	13.0	3.9	0.122
	4	0.848	0.529	0.419	0.774	0.884	0.467	0.354	0.808	12.0	12.1	0.023
Ahvaz	1	0.884	0.498	0.376	0.821	0.914	0.419	0.311	0.863	10.5	1.2	0.451
	2	0.873	0.502	0.384	0.813	0.907	0.431	0.321	0.852	11.0	4.3	0.235
	3	0.869	0.513	0.397	0.796	0.903	0.442	0.334	0.823	12.0	7.2	0.422
	4	0.853	0.517	0.401	0.783	0.893	0.455	0.341	0.817	5.6	11	0.196
Abadan	1	0.889	0.491	0.371	0.824	0.912	0.412	0.302	0.875	4.8	2.7	0.201
	2	0.895	0.482	0.362	0.837	0.921	0.403	0.307	0.861	13.0	0.6	0.122
	3	0.874	0.505	0.384	0.807	0.905	0.431	0.324	0.854	14.4	9.7	0.325
	4	0.866	0.509	0.399	0.794	0.897	0.439	0.333	0.831	15.6	14	0.512

Table 5- Statistical results of input patterns of GRU-LSTM hybrid model in predicting FDSI index

جدول ۵- نتایج آماری الگوهای ورودی مدل ترکیبی GRU-LSTM در پیش‌بینی شاخص FDSI

Station	Combination number	Test Dataset				Train Dataset			
		R	RMSE	MAE	NS	R	RMSE	MAE	NS
Dezful	1	0.921	0.385	0.225	0.828	0.947	0.322	0.178	0.873
	2	0.923	0.382	0.223	0.833	0.954	0.317	0.171	0.879
	3	0.917	0.387	0.229	0.824	0.936	0.329	0.186	0.865
	4	0.905	0.402	0.236	0.819	0.932	0.336	0.195	0.861
Safiabad	1	0.932	0.369	0.219	0.837	0.963	0.319	0.171	0.891
	2	0.941	0.365	0.217	0.846	0.967	0.303	0.162	0.893
	3	0.927	0.376	0.223	0.831	0.948	0.324	0.182	0.888
	4	0.913	0.384	0.231	0.826	0.946	0.331	0.193	0.874
Masjedsoleyman	1	0.944	0.361	0.209	0.852	0.967	0.297	0.152	0.901
	2	0.956	0.353	0.203	0.861	0.972	0.292	0.143	0.905
	3	0.933	0.357	0.214	0.848	0.953	0.305	0.164	0.894
	4	0.921	0.363	0.226	0.833	0.951	0.314	0.173	0.888
Bandare-Mahshahr	1	0.961	0.342	0.196	0.873	0.979	0.281	0.126	0.914
	2	0.957	0.351	0.201	0.864	0.976	0.287	0.138	0.908
	3	0.941	0.354	0.206	0.852	0.966	0.299	0.153	0.899
	4	0.933	0.355	0.214	0.847	0.959	0.303	0.166	0.892
Bostan	1	0.967	0.331	0.181	0.881	0.984	0.269	0.104	0.923
	2	0.963	0.341	0.192	0.874	0.981	0.279	0.117	0.917
	3	0.955	0.347	0.201	0.865	0.975	0.284	0.132	0.902
	4	0.942	0.351	0.206	0.853	0.966	0.296	0.141	0.896
Ahvaz	1	0.973	0.324	0.156	0.894	0.987	0.244	0.097	0.934
	2	0.971	0.329	0.167	0.888	0.985	0.261	0.103	0.926
	3	0.965	0.338	0.174	0.874	0.979	0.273	0.116	0.919
	4	0.954	0.343	0.183	0.862	0.971	0.285	0.125	0.902
Abadan	1	0.988	0.319	0.152	0.901	0.993	0.226	0.087	0.946
	2	0.979	0.313	0.144	0.903	0.989	0.234	0.095	0.951
	3	0.973	0.325	0.167	0.886	0.986	0.251	0.102	0.923
	4	0.965	0.338	0.179	0.874	0.975	0.267	0.113	0.907

۴- نتیجه گیری

هدف از این پژوهش، مقایسه عملکرد مدل هیبریدی پیشنهادی GRU-LSTM با فرامدل‌های انفرادی شبکه عصبی مبتنی بر توابع شعاعی (RBF) و ماشین بردار پشتیبان (SVM) به منظور مدل‌سازی فراوانی روزهای همراه با طوفان‌های گرد و غبار (FDS) در هفت ایستگاه سینوپتیک استان خوزستان بود. ورودی مدل‌ها، مقادیر فراوانی روزهای همراه با طوفان‌های گرد و غبار در تأخیرهای قبل (حداکثر تا ۴ فصل) و خروجی شامل مقادیر فصلی فراوانی روزهای همراه با طوفان گرد و غبار بود. بدین منظور از داده‌های ساعتی گرد و غبار و کدهای سازمان جهانی هواشناسی در مقیاس فصلی با طول دوره آماری ۳۰ ساله (۱۹۹۰-۲۰۱۹) استفاده شد.

نتایج شاخص‌های نیکویی برازش در مرحله آموزش و آزمایش نشان داد که مدل هیبریدی مورد استفاده، نتایج قابل قبولی در مدل‌سازی شاخص FDS ارائه می‌نماید؛ به طوری که مدل هیبریدی GRU-LSTM بهترین عملکرد و بعد از آن فرامدل انفرادی SVM بالاترین دقت را به خود اختصاص داد. همچنین فرامدل انفرادی RBF در مقایسه با دو روش مذکور کمترین راندمان و کارایی را داشت.

با توجه به نتایج می‌توان به این نکته نیز اشاره کرد که اگر چه دقت فرامدل هیبریدی GRU-LSTM نسبت به فرامدل ماشین بردار پشتیبان بیشتر بوده اما روش SVM به مراتب ساده‌تر از مدل ترکیبی GRU-LSTM است و می‌تواند به عنوان یک روش کاربردی به منظور پیش‌بینی شاخص FDS به کار گرفته شود که البته، انتخاب پارامترهای بهینه در این فرامدل بسیار اهمیت دارد. در تمامی روش‌های مورد استفاده جهت پیش‌بینی شاخص FDS، مدلی که از یک یا دو گام تأخیر در پیش‌بینی استفاده کرد، بهترین مدل پیش‌بینی کننده بوده است؛ با این توضیح که با حرکت از ایستگاه‌های مرزی به سمت مناطق مرکزی و شرقی استان خوزستان، استفاده از دو گام تأخیر در پیش‌بینی، نتایج بهتری را حاصل کرد که علت آن را می‌توان در تغییر وضعیت منشأ طوفان‌های گرد و غبار به سمت مناطق داخلی و شرق استان جستجو کرد. بی‌شک به منظور اعتبارسنجی نتایج بدست آمده از این تحقیق، پژوهش‌های بیشتری برای کاربرد فرامدل‌های ترکیبی در مدل‌سازی و پیش‌بینی زمانی- مکانی طوفان‌های گرد و غبار در مناطق تحت تأثیر این پدیده، می‌بایست انجام شود.

این مدل هیبریدی نیز همانند دو فرامدل انفرادی RBF و SVM، در ترکیب‌های شماره یک و دو به منظور پیش‌بینی شاخص FDS، از دقت بالاتری برخوردار است.

۳-۴- مقایسه عملکرد مدل‌های RBF، SVM و GRU-LSTM

شکل ۸ مقادیر مشاهداتی و پیش‌بینی شده شاخص FDS را برای داده‌های آزمون نشان می‌دهد. این شکل بهبود عملکرد روش‌های مورد استفاده با افزایش فراوانی روزهای همراه با طوفان گرد و غبار را به خوبی بیان می‌کند؛ به طوری که ایستگاه آبادان به عنوان فراوان‌ترین ایستگاه موجود در منطقه مورد مطالعه، بهترین مطابقت را بین مقادیر مشاهداتی و پیش‌بینی شده شاخص FDS دارا می‌باشد.

همانطور که در شکل ۱۲ مشخص است، ارتباط بین مقادیر مشاهداتی و پیش‌بینی شده در تمام ایستگاه‌های مورد مطالعه خطی با شیب تقریباً ۴۵ درجه می‌باشد و در بین مدل‌های مورد بررسی فرامدل انفرادی RBF بیشترین پراکندگی و مدل هیبریدی GRU-LSTM کمترین پراکندگی و بیشترین مطابقت را با نیمساز ربع اول ($f(x)=x$) به خود اختصاص داده است که این ویژگی می‌تواند تأکیدی بر راندمان بالا و کارایی موثر فرامدل هیبریدی GRU-LSTM در مقایسه با فرامدل‌های انفرادی RBF و SVM به منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار باشد.

این در حالی است که مقایسه میانگین مقادیر مشاهداتی و پیش‌بینی شده شاخص FDS بر اساس آزمون t نشان داد که فرض صفر مبنی بر برابر بودن میانگین سری مقادیر مشاهداتی و پیش‌بینی شده در هیچ‌کدام از ایستگاه‌های منطقه و با هیچ‌کدام از مدل‌های مورد بررسی در پژوهش حاضر، در سطح خطای یک درصد رد نمی‌شود بنابراین می‌توان نتیجه گرفت با وجود اینکه مدل هیبریدی پیشنهادی بهترین عملکرد را داشته است، دو مدل انفرادی دیگر نیز، جهت پیش‌بینی شاخص FDS، میانگین سری زمانی را حفظ کرده‌اند (جدول ۶). نتایج این قسمت با مطالعات Goudie and Middleton, (2006)، Cao et al. (2014)، Zeinali et al. (2016)، Yarmoradi et al. (2018)، Araghejad et al. (2019) و Ansari ghojghar et al. (2020) مطابقت دارد.

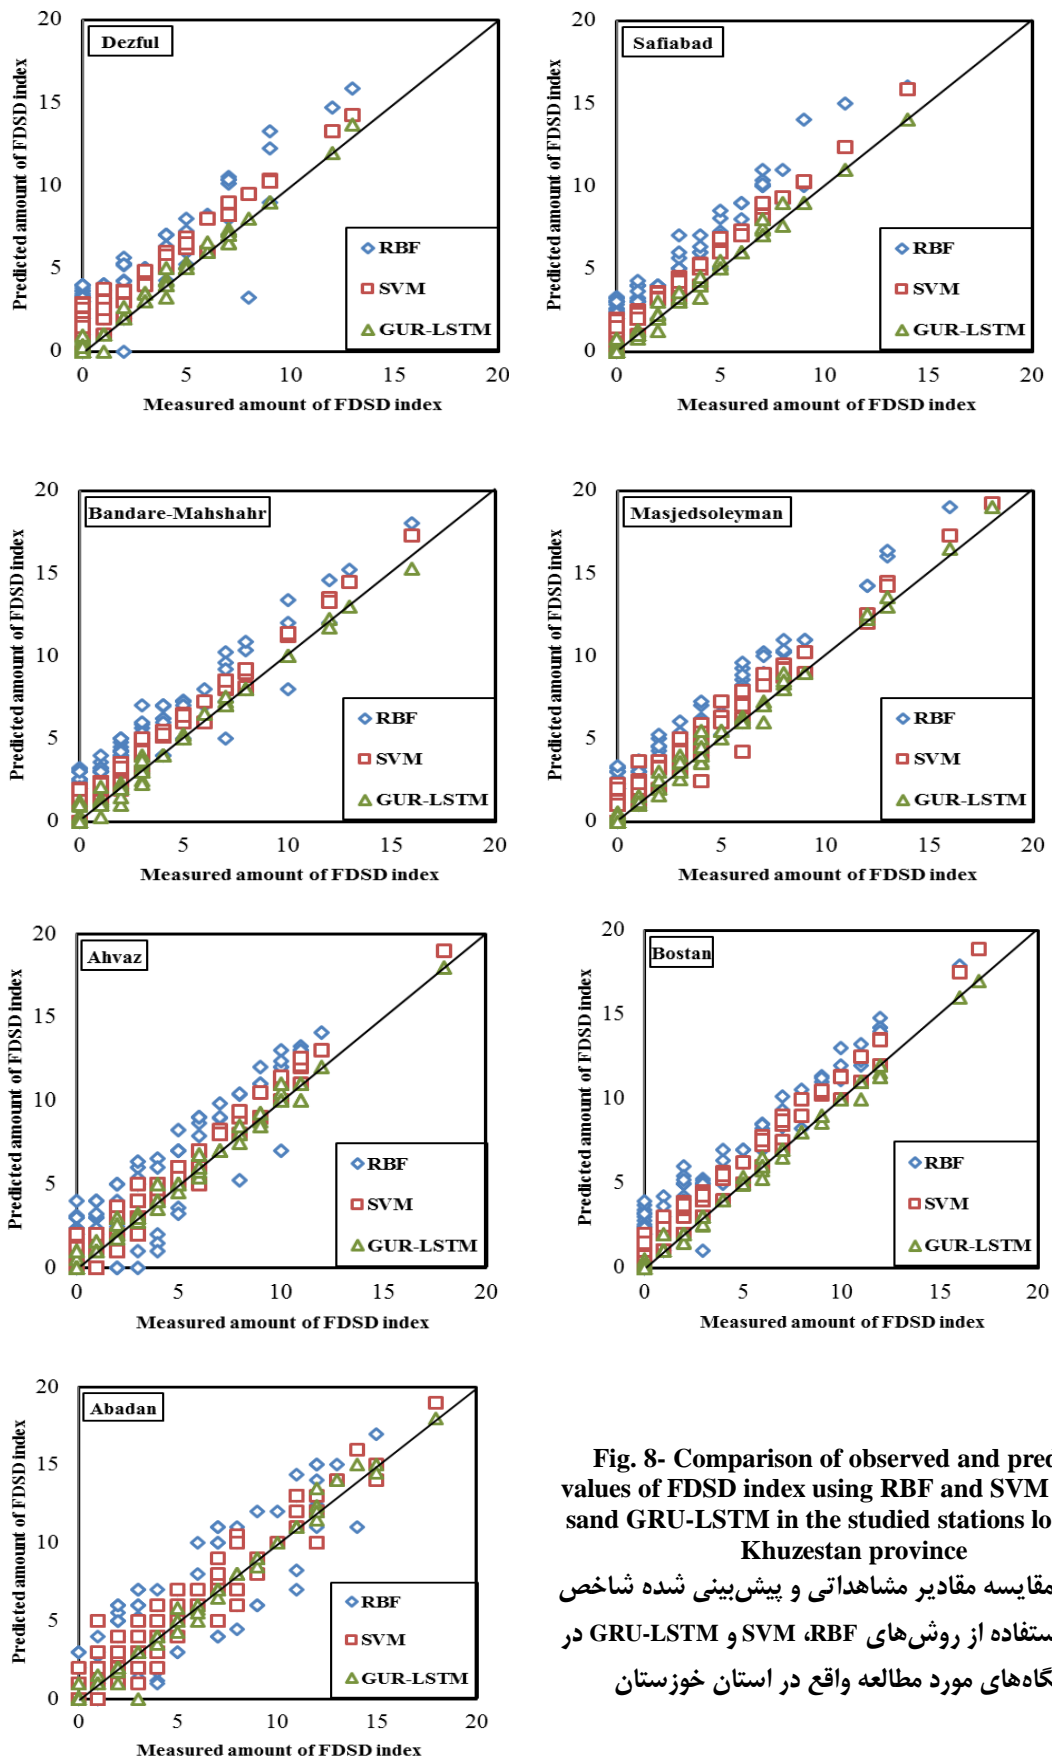


Fig. 8- Comparison of observed and predicted values of FDSI index using RBF and SVM method sand GRU-LSTM in the studied stations located in Khuzestan province

شکل ۸- مقایسه مقادیر مشاهداتی و پیش‌بینی شده شاخص FDSI با استفاده از روش‌های RBF، SVM و GRU-LSTM در ایستگاه‌های مورد مطالعه واقع در استان خوزستان

Table 6- Comparison of the average measured and predicated time series of FDSI index

جدول ۶- آزمون مقایسه میانگین مقادیر مشاهداتی و پیش‌بینی شده شاخص FDSI

Station	Combination No.	Average				t Statistics		
		Measured	RBF	SVM	GRU-LSTM	RBF	SVM	GRU-LSTM
Abadan	1	0.944	0.913	0.932	0.935	0.870	0.891	0.823
	2	0.947	0.924	0.931	0.932	0.865	0.861	0.823
	3	0.942	0.916	0.935	0.930	0.862	0.866	0.827
	4	0.939	0.912	0.937	0.927	0.891	0.869	0.833
Ahvaz	1	0.936	0.919	0.933	0.931	0.886	0.871	0.885
	2	0.940	0.921	0.933	0.925	0.882	0.874	0.883
	3	0.935	0.914	0.928	0.925	0.873	0.878	0.883
	4	0.933	0.907	0.931	0.925	0.871	0.878	0.876
Bostan	1	0.937	0.903	0.926	0.923	0.852	0.856	0.874
	2	0.938	0.906	0.923	0.927	0.854	0.853	0.874
	3	0.924	0.914	0.918	0.919	0.857	0.857	0.871
	4	0.917	0.902	0.916	0.914	0.861	0.857	0.875
Bandare-Mahshahr	1	0.916	0.894	0.924	0.913	0.852	0.859	0.879
	2	0.922	0.886	0.931	0.911	0.850	0.871	0.862
	3	0.904	0.992	0.926	0.918	0.850	0.852	0.858
	4	0.893	0.995	0.937	0.922	0.855	0.831	0.846
Masjedsoleyman	1	0.902	0.881	0.922	0.922	0.856	0.872	0.848
	2	0.894	0.879	0.917	0.916	0.847	0.886	0.843
	3	0.892	0.904	0.920	0.914	0.832	0.852	0.844
	4	0.901	0.915	0.924	0.919	0.837	0.850	0.832
Safiabad	1	0.876	0.904	0.927	0.910	0.834	0.837	0.851
	2	0.882	0.897	0.917	0.910	0.833	0.832	0.856
	3	0.896	0.888	0.913	0.913	0.845	0.844	0.837
	4	0.897	0.872	0.911	0.907	0.851	0.841	0.836
Dezful	1	0.892	0.861	0.911	0.906	0.858	0.838	0.834
	2	0.902	0.859	0.912	0.911	0.853	0.899	0.834
	3	0.874	0.853	0.905	0.904	0.862	0.827	0.828
	4	0.896	0.834	0.903	0.905	0.866	0.825	0.826

۵- مراجع

پی‌نوشت‌ها

- Abdolshahnejad M, Khosravi H, Nazari Samani A A, Zehabian G R, and Alambaigi M (2020) Determining the conceptual framework of dust risk based on evaluating resilience (Case study: Southwest of Iran). Strategic Research Journal of Agricultural Sciences and Natural Resources 5(1):33-44 (In Persian)
- Ansari ghoghghar M, Pourgholam-Amiji M, Bazrafshan J, Liaghat A, Araghinejad S (2020) Performance comparison of statistical, fuzzy and perceptron neural network models in forecasting dust storms in critical regions in Iran. Iranian Journal of Soil and Water Research 51(8):2051-2063
- Araghinejad S (2013) Data-driven modeling: Using MATLAB® in water resources and environmental engineering (Vol. 67). Springer Science & Business Media
- Araghinejad Sh, Ansari Ghoghghar M, Pourgholam-Amiji Liaghat A, and Bazrafshan J (2018) The effect of climate fluctuation on frequency of dust storms in Iran. Desert Ecosystem Engineering Journal 7(21):13-32 (In Persian)
- 1- Artificial Neural Network (ANN)
 - 2- Support Vector Machine (SVM)
 - 3- Fuzzy Logic
 - 4- Genetic Algorithm
 - 5- Honra River
 - 6- Random Forest (RF)
 - 7- Support Vector Regression (SVR)
 - 8- Multi-Layer Perceptron (MLP)
 - 9- Auto Correlation (ACF)
 - 10- Partial Auto-Correlation (PACF)
 - 11- Radial Basis Function
 - 12- Fuzzu Inference System
 - 13- Generalized Regression Neural Network
 - 14- Frequency of Dust Stormy Days
 - 15- World Meteorological Organization
 - 16- Polynomial
 - 17- Sliding Windows
 - 18- Hidden Vector Sequence
 - 19- Cross Validation
 - 20- Shuffled Complex Evolution Algorithm
 - 21- Grid Search Algorithm

- East. Journal of Spatial Analysis Environmental Hazards 3(4):101-119 (In Persian)
- Kim D, Chin M, Kemp E M, Tao Z, Peters-Lidard C D, and Giroux P (2017) Development of high-resolution dynamic dust source function-A case study with a strong dust storm in a regional model. *Atmospheric Environment* 159:11-25
- Liaghat A, Araghinejad Sh, Ansari Ghojghar M, Pourgholam Amiji M (1399) Comparing the performance of SARIMA and holt-winters time series models with artificial intelligence methods in forecasting dust storms (Case study: Sistan and Baluchistan Province). *Physical Geography Research Quarterly*, DOI: 10.22059/jphgr.2021.303847.1007524.
- Misra D, Oommen T, Agarwa A, Mishra S K, Thompson A M (2009) Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering* 103(3):527-535
- Mohammadi G H (2015) Analysis of atmospheric mechanisms in dust transport over west of Iran. Ph.D. Thesis, Tabriz University, 142 pp. (In Persian)
- O'Loingsigh T, McTainsh G H, Tews E K, Strong C L, Leys J F, Shinkfield P, and Tapper N J (2014) The Dust Storm Index (DSI): A method for monitoring broadscale wind erosion using meteorological records. *Aeolian Research* 12:29-40
- Shaiba H, Alaashoub N S, Alzahrani A A (2018) Applying machine learning methods for predicting sand storms. 2018 1st International Conference on Computer Applications & Information Security (ICCAIS), Riyadh, Saudi Arabia
- Shaker Sureh F and Asadi E (2019) Meteorological and hydrological drought communication in Salmas Plain. *Desert Ecosystem Engineering Journal* 8(22):89-100 (In Persian)
- Sobhani B, Salahi B, and Goldust A (2015) Study the dust and evaluation of its possibility prediction based on statistical methods and ANFIS model in Zabol University. *Geography and Development Iranian Journal* 13(38):123-138 (In Persian)
- Vapnik VN (1995) The nature of statistical learning theory. Springer, New York
- Zeinali B (2016) Investigation of frequency changes trend of days with dust storms in western half of Iran. *Journal of Natural Environment Hazards* 5(7):100-87 (In Persian)
- Zhu YM, Lu XX, Zhou Y (2007) Suspended sediment flux modeling with artificial neural network: An example of the longchuanjiang river in the upper yangtze catchment. *Geomorphology* 84(4):111-125
- Araghinejad Sh, Ansari Ghojghar M, Pourgholam Amiji M, Babaeian I (2020) Modeling the relationship between dust storms and extreme and average temperature variables in the western half of Iran. *Journal of Climate Research* 8(31-32)
- Baghbanan P, Ghavidel Y, Farajzadeh M (2020) Temporal long-term variations in the occurrence of dust storm days in Iran. *Meteorology and Atmospheric Physics* (2020) 132:885-898
- Basak D, Pal S, Patranabis D C (2007) Support vector regression. *Neural Information Processing* 11:203-225
- Cao R, Jiang W, Yuan L, Wang W, Lv Z, and Chen Z (2014) Inter-annual variations in vegetation and their response to climatic factors in the upper catchments of the Yellow River from 2000 to 2010. *Journal of Geographical Sciences* 24(6):963-979
- Chen S, Cowan C F N, and Grant P M (1991) Orthogonal least squares learning algorithm for radial basis function networks. *IEEE Transactions on Neural Networks* 2(2):302-309
- Dahiya S, Singh B, Gaur S, Garg V K, and Kushwaha H S (2007) Analysis of groundwater quality using fuzzy synthetic evaluation. *Journal of Hazardous Materials* 147(3):938-946
- Goudie A S and Middleton N J (2006) Desert dust in the global system. Springer Science & Business Media
- Hahnenberger M and Nikoul K (2014) Geomorphic and land cover identification of dust sources in the eastern Great Basin of Utah, U.S.A. *Journal of Geomorphology* 204(2):657-672
- He Z, Wen X, Liu H, Du J A (2014) Comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology* 509:379-386
- Hamel L (2009) Knowledge discovery with support vector machines. Hoboken, N.J. John Wiley
- Hussain D and Khan A A (2020) Machine learning techniques for monthly river flow forecasting of Hunza River, Pakistan. *Earth Science Informatics*, DOI: 10.1007/s12145-020-00450-z.
- Jamalizadeh Tajabadi M R, Moghaddamnia A R, Piri J, and Ekhtesasi M R (2010) Application of artificial neural networks in dust storm prediction (Case study: Zabol city). *Iranian journal of Range and Desert Research* 17(2):205-220 (In Persian)
- Karegar M E, Bodagh Jamali J, Ranjbar Saadat Abadi A, Moeenoddini M, and Goshtasb H (2017) Simulation and numerical analysis of severe dust storms Iran