



Evaluating the Efficiency of Hybrid Metamodels of Machine Learning and Box Jenkins in Order to Model Dust Storms (Case Study: Khuzestan Province)

Mohammad Ansari Ghojghar¹, Javad Bazrafshan^{*2}, Shahab Araghinejad

1. Department of Irrigation & Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. Email: M.ansari2014m@gmail.com

2. Corresponding Author, Department of Irrigation & Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. Email: jbazr@ut.ac.ir

3. Department of Irrigation & Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. Email: araghinejad@ut.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Aug. 16, 2022

Revised: Aug. 30, 2022

Accepted: Sep. 3, 2022

Published online: Oct. 23, 2022

Keywords:

Prediction,
FDSI Index,
AF-SVM,
W-ANFIS,
Box Jenkins hybrid algorithms.

ABSTRACT

The impact of dust phenomenon in Iran is so vast that it has involved more than half of the country's provinces in some way with the issues and limitations of this natural phenomenon. In addition to the environmental effects, it has disrupted the implementation of national sustainable development plans and so far, it has had many negative consequences. This research tries to present a new hybrid model using artificial intelligence hybrid metamodels as well as Box Jenkins hybrid metamodels to predict and model the FDSI index (frequency of days with dust storms), in seven synoptic stations of Khuzestan province with length The statistical period has been 40 years (1981-2020). The hybrid prediction algorithms used in this research include W-ANFIS, AF-SVM, ARIMA-NARX and SARIMA-SETAR. The prediction results showed that the decrease in the performance of hybrid models to predict the FDSI index has a direct relationship with the decrease in the frequency of days with dust storms. So that the correlation coefficient for experimental data in AF-SVM and W-ANFIS hypermodels from 0.991 and 0.985 to 0.985 and 0.958, respectively, and Nash Sutcliffe coefficient has also decreased from 0.977 and 0.960 to 0.973 and 0.952, respectively. Also, the RMSE coefficient from Abadan station to Dezful for the two metamodels from 0.135 and 0.151 to 0.140 and 0.179 respectively, And the MAE coefficient has also increased from 0.054 and 0.068 to 0.060 and 0.093, respectively. Correlation coefficient for test data in Box Jenkins SARIMA-SETAR and ARIMA-NARX hypermodels also from 0.967 and 0.951 to 0.958 and 0.941 respectively and the Nash Sutcliffe coefficient has also decreased from 0.945 and 0.923 to 0.938 and 0.913, respectively, which indicates the weakening of the performance of hybrid metamodels with the decrease in the frequency of dust storms in Khuzestan province. Also, by fitting four hybrid hypermodels on the FDSI index, it was shown that AF-SVM hybrid hypermodel had better performance than other methods. In a way, in all studied stations, the correlation coefficient and Nash-Sutcliffe coefficient are higher and the root mean square error coefficient and the mean absolute value of the error are lower, which shows the superiority of this hybrid meta-model over other meta-models for predicting the FDSI index in Khuzestan province. The results of this study can be used to model dust storms in other western regions of the country.

Cite this article Ansari Ghojghar, M., Bazrafshan, J., & Araghinejad, Sh. (2022) Evaluating the efficiency of hybrid metamodels of machine learning and Box Jenkins in order to model dust storms (case study: Khuzestan province). *Iranian Journal of Soil and Water Research*, 53 (8), 1695-1714.

© The Author(s).

Publisher: University of Tehran Press.

DOI: <http://doi.org/10.22059/ijswr.2022.346694.669335>



ارزیابی کارایی فرامدل‌های هیبریدی یادگیری ماشین و باکس جنکینز به منظور مدل‌سازی طوفان‌های گرد و غبار (مطالعه موردی: استان خوزستان)

محمد انصاری قوجقار^۱، جواد بذرافشان^۲، شهاب عراقی نژاد^۳

۱. گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. ایمیل: M.ansari2014m@gmail.com

۲. نویسنده مسئول، گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. ایمیل: jbazr@ut.ac.ir

۳. گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. ایمیل: araghinejad@ut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	تأثیر پدیده گردوغبار در ایران آن قدر وسیع است که بیش از نیمی از استان‌های کشور را به نحوی با مسائل و محدودیت‌های این پدیده طبیعی درگیر کرده است که، علاوه بر اثرهای زیست محیطی، موجب اختلال در اجرای طرح‌های توسعه پایدار ملی شده و تاکنون پیامدهای منفی زیادی به دنبال داشته و خواهد داشت. این پژوهش سعی بر ارائه نوعی مدل ترکیبی جدید با استفاده از فرامدل‌های هیبریدی هوش مصنوعی و همچنین فرامدل‌های هیبریدی باکس جنکینز جهت پیش‌بینی و مدل‌سازی شاخص FDS (فراوانی روزهای همراه با طوفان‌های گردوغبار)، در هفت ایستگاه سینوپتیک استان خوزستان با طول دوره آماری ۴۰ سال (۲۰۲۰-۱۹۸۱) داشته است. الگوریتم‌های هیبریدی پیش‌بینی به کار رفته در این پژوهش شامل W-ANFIS، AF-SVM، ARIMA-NARX، SARIMA-SETAR می‌باشند. نتایج پیش‌بینی نشان داد که کاهش عملکرد مدل‌های هیبریدی جهت پیش‌بینی شاخص FDS با کاهش فراوانی روزهای همراه با طوفان‌های گرد و غبار رابطه مستقیمی دارد. به نحوی که ضریب همبستگی برای داده‌های آزمایشی در فرامدل‌های AF-SVM و W-ANFIS به ترتیب از ۰/۹۷۷ و ۰/۹۶۰ به ۰/۹۷۳ و ۰/۹۵۲ کاهش یافته است. همچنین ضریب RMSE به ترتیب از ایستگاه آبادان تا دزفول برای دو فرامدل ذکر شده از مقدار ۰/۱۳۵ و ۰/۱۵۱ به ۰/۱۴۰ و ۰/۱۷۹ و ضریب MAE نیز به ترتیب از مقدار ۰/۰۵۴ و ۰/۰۶۸ به ۰/۰۶۰ و ۰/۰۹۳ افزایش یافته است. ضریب همبستگی برای داده‌های آزمایشی در فرامدل‌های باکس جنکینز SARIMA-SETAR و ARIMA-NARX نیز به ترتیب از مقادیر ۰/۹۶۷ و ۰/۹۵۱ به ۰/۹۴۱ و ۰/۹۴۵ و ضریب نش ساتکلیف نیز به ترتیب از ۰/۹۲۳ و ۰/۹۳۸ و ۰/۹۱۳ کاهش یافته است که نشان‌دهنده ضعیف شدن عملکرد فرامدل‌های هیبریدی با کاهش فراوانی طوفان‌های گرد و غبار در استان خوزستان می‌باشد. همچنین با برآزش چهار فرامدل هیبریدی بر روی شاخص FDS نشان داده شد که فرامدل هیبریدی AF-SVM نسبت به سایر روش‌ها از عملکرد بهتری برخوردار بود. به نحوی که در همه ایستگاه‌های مورد مطالعه دارای ضریب همبستگی و نش ساتکلیف بیشتر و ضریب ریشه میانگین مربعات خطا و میانگین قدرمطلق خطا کمتری می‌باشد که نشان‌دهنده برتری این فرامدل هیبریدی نسبت به سایر فرامدل‌ها برای پیش‌بینی شاخص FDS در استان خوزستان می‌باشد. نتایج این مطالعه می‌تواند جهت مدل‌سازی طوفان‌های گرد و غبار در سایر مناطق کشور نیز مورد استفاده قرار گیرد.
واژه‌های کلیدی: پیش‌بینی، شاخص FDS، AF-SVM، W-ANFIS، الگوریتم‌های هیبریدی باکس جنکینز	
تاریخ دریافت: ۱۴۰۱/۵/۲۵	
تاریخ بازنگری: ۱۴۰۱/۶/۸	
تاریخ پذیرش: ۱۴۰۱/۶/۱۲	
تاریخ انتشار: ۱۴۰۱/۸/۱	

استاد: انصاری قوجقار، محمد؛ بذرافشان، جواد؛ عراقی نژاد، شهاب (۱۴۰۱). ارزیابی کارایی فرامدل‌های هیبریدی یادگیری ماشین و باکس جنکینز به منظور مدل‌سازی طوفان

های گرد و غبار (مطالعه موردی: استان خوزستان)، *مجله تحقیقات آب و خاک ایران*، ۵۳ (۸)، ۱۶۹۵-۱۷۱۴.

DOI: <http://doi.org/10.22059/ijswr.2022.346694.669335>



© نویسنده‌گان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

مقدمه

پدیده گردوغبار 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). قرار گرفتن کشور ایران در کمربند بیابانی سبب افزایش رخدادهای طبیعی در جهت ایجاد گرد و غبار، به‌ویژه در نواحی جنوب‌شرقی آن شده و تأثیرات نامطلوبی بر محیط‌زیست دربرداشته است. مدیریت کارآمد این رویدادهای مخرب به شناخت ویژگی‌ها و میزان گستردگی آن‌ها نیاز دارد. دو کانون اصلی منطقه غرب بغداد و موصول تا بحرالملح و هورالعظیم منشأ گرد و غبار در استان خوزستان می‌باشند (Atai and Ahmadi, 2010). همچنین با بررسی منشأ و جهت طوفان‌های گرد و غبار در خوزستان مشخص شد که بادهای فرساینده در منطقه از سمت غرب و شمال غرب وزیده و رسوبات را به سمت تپه‌های ماسه‌ای حمل می‌کند. مطالعات ژئومورفولوژی و رسوب‌شناسی نیز نشان داد که منشأ تل‌ماسه‌های محلی نزدیک بوده و شامل اراضی کشاورزی، مسیل رودخانه کرخه و به میزان کمتر شامل سازند آغاچاری و بختیاری در غرب و شمال غرب می‌شود. به‌طور کلی می‌توان گفت که منشأ اصلی از بستر خشک شده تالاب هورالعظیم تا مسیل رودخانه کرخه ادامه دارد (Jokar et al., 2012). منشأ ۷۰٪ از گرد و غبارهای موجود در غرب ایران کشور عراق است به‌طور کلی چهار کانون اصلی در عراق و دو کانون در شمال شرق سوریه و شرق عربستان شناسایی شده است (Jacquelyn, 2009). در سال‌های اخیر با افزایش فراوانی طوفان‌های گرد و غبار، شناسایی؛ پایش و پیش‌بینی تکامل آن‌ها امری ضروری گردیده است. در نتیجه توجه محققان را در این زمینه جلب کرده است و مطالعات زیادی از دیدگاه‌های مختلف در زمینه پدیده گرد و غبار انجام شده است.

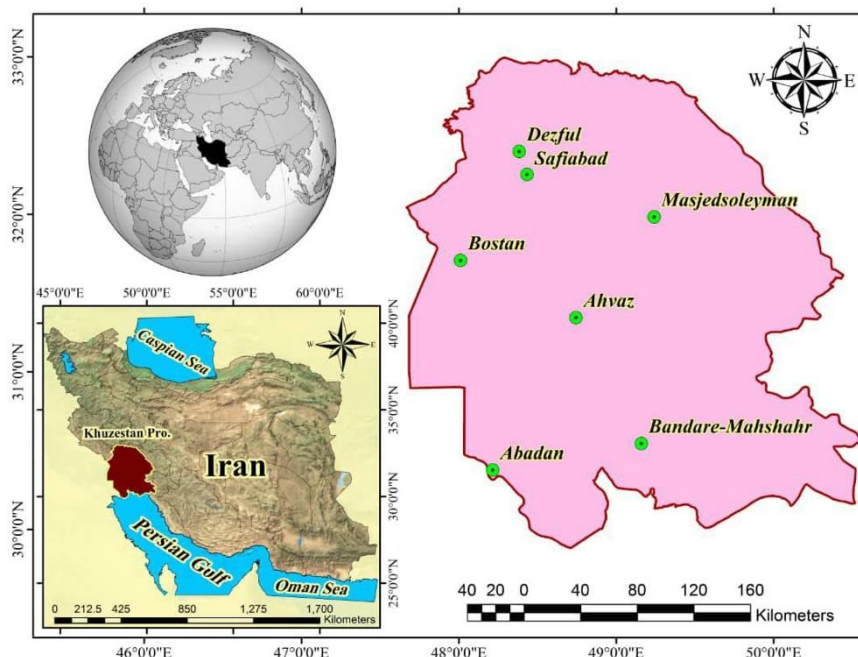
سبحانی و صفریان در پژوهشی به واکاوی و پیش‌بینی پدیده گرد و غبار در جنوب غرب ایران پرداختند. بدین منظور از داده‌های ۲۷ ساله گرد و غبار در ۱۴ ایستگاه سینوپتیک در جنوب غرب ایران در بازه زمانی ۲۰۱۷-۱۹۹۰ استفاده کردند. با استفاده از مدل‌های شبکه عصبی هیبرید-پانل دیتا و شبکه عصبی فازی تطبیقی ANFIS^۱ در نرم افزار MATLAB اقدام به پیش‌بینی پدیده گرد و غبار کردند. در نهایت برای اولویت‌سنجی ایستگاه‌های در معرض گرد و غبار از مدل‌های تصمیم‌گیری چند متغیره^۲ TOPSIS و^۳ SAW بهره بردند. نتیجه پژوهش نشان داد که میزان اطمینان حاصل از مدل‌های خطاسنجی یعنی شبکه عصبی هیبرید-پانل نسبت به ANFIS بیشتر می‌باشد. مدل SAW بیشترین احتمال رخداد گرد و غبار پیش‌بینی‌شده در ۲۳ سال آینده را در ایستگاه آبادان با ۰/۹۹ و مدل TOPSIS ایستگاه اسلام آباد غرب با مقدار ۰/۹۷ به خود اختصاص دادند (Sobhani and Safarian, 2020). کیخسروی و همکاران در مطالعه‌ای با استفاده از شبکه‌های عصبی پرسپترون (MLP) و پایه شعاعی (RBF) اقدام به پیش‌بینی گرد و غبار خروجی از دودکش اصلی کارخانه سیمان سبزوار واقع در استان خراسان رضوی کردند. مقادیر حاصل از اجرای مدل‌ها، با نتایج اندازه‌گیری‌های میدانی به عنوان انتخاب مدل برتر، مورد مقایسه قرار گرفت. در بررسی نمودارها و پارامترهای آماری، مقادیر میانگین مربعات خطا برای دو مدل شبکه‌های عصبی پرسپترون و پایه شعاعی به ترتیب برابر ۱/۷۸۷ و ۲۱/۲۶۳ و مقادیر ضریب همبستگی به ترتیب برابر ۰/۹۹۶۹۳ و ۰/۹۵۸۱۱ بود که نشانگر خطای کمتر و همبستگی بیشتر مدل شبکه‌های عصبی پرسپترون نسبت به مدل پایه شعاعی در پیش‌بینی میزان غلظت گردوغبار بود (keykhosravi et al., 2019). سلاجقه و همکاران نیز عملکرد مدل‌های سری زمانی (ARIMA) و شبکه عصبی (پرسپترون چندلایه) در پیش‌بینی مقادیر SPI مورد مقایسه قرار گرفت. نتایج نشان داد که مدل‌های سری زمانی عملکرد بهتری در پیش‌بینی مقادیر SPI نسبت به شبکه عصبی داشته و همچنین مقادیر SPI نه و دوازده ماهه بهتر از مقادیر SPI سه و شش ماهه پیش‌بینی گردید (Selajgh et al., 2008). در تحقیقی دیگر برای پیش‌بینی سرعت باد از مدل‌های ARIMA چندمتغیره و مدل‌های عصبی برگشتی استفاده کردند. نتایج نشان داد مدل‌های چند متغیره نسبت به مدل‌های تک متغیره و شبکه عصبی برگشتی کارایی بهتری دارند (Qing et al, 2012). (Jamalizadeh et al., 2010) توانایی دو روش شبکه‌های عصبی مصنوعی (ANN) و ماشین‌های بردار پشتیبان (SVM) در پیش‌بینی طوفان‌های گردوغبار شهر زابل را با طول دوره آماری ۲۶ ساله (۲۰۰۵-۱۹۸۰) بررسی کردند. از آنجا که استفاده از نوع f-SVR و تابع کرنل پایه شعاعی (RBF) بهترین جواب‌ها را داده است، توصیه شده در مطالعات دیگر نیز قابلیت‌های این روش‌ها بررسی شود. در پژوهشی 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 روزهای همراه با طوفان گرد و غبار (FDS) در فصل آبی پرداختند. بدین منظور، از داده‌های ساعتی گرد و غبار و کدهای سازمان جهانی هواشناسی در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان با طول دوره آماری ۲۵ ساله (۲۰۱۴-۱۹۹۰) استفاده شد. نتایج تحقیق آن‌ها نشان داد که روش هوش مصنوعی ANFIS بهترین عملکرد را داشته است و معیارهای ارزیابی R ، $RMSE$ ، MAE و NS آن به ترتیب از ۰/۷۲، ۰/۵۷، ۰/۴۲ و ۰/۷۱ تا ۰/۹۵، ۰/۵۱، ۰/۴۰ و ۰/۹۶ متغیر بود و مدل‌های سری زمانی SARIMA و Holt-Winters بدترین عملکرد را داشتند (Pourgholam Amiji et al., 2020). در مطالعه حاضر برای رفع نواقص و معایب روش‌های استفاده شده پیشین، سعی بر ارائه نوعی مدل ترکیبی جدید با استفاده از فرامدل‌های هیبریدی هوش مصنوعی و همچنین فرامدل‌های هیبریدی سری زمانی به منظور پیش‌بینی و مدل‌سازی شاخص FDS (فراوانی روزهای همراه با طوفان‌های گردوغبار)، در استان خوزستان به‌عنوان گرد و غبارخیزترین استان (شامل ۷ ایستگاه سینوپتیک) با جمعیت آماری بلندمدت ۴۰ ساله (۲۰۲۰-۱۹۸۱) شده است. لذا از فرامدل‌های هیبریدی موجک-سیستم استنباط عصبی فازی تطبیقی^۱، الگوریتم گیاهان مصنوعی-ماشین‌بردار پشتیبان^۲ و فرامدل‌های هیبریدی سری زمانی شامل مدل خود همبسته میانگین متحرک تلفیق شده-شبکه عصبی دینامیک^۳ و مدل ترکیبی فصلی خطی و غیرخطی آستانه^۴ استفاده شده تا در نهایت با مقایسه این روش‌ها، بتوان مدل ترکیبی مناسبی به منظور پیش‌بینی شاخص FDS در استان خوزستان ارائه کرد.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد بررسی استان خوزستان است که با مساحت ۶۴۷۶۴ کیلومتر مربع، بین ۴۷ درجه و ۴۱ دقیقه تا ۵۰ درجه و ۳۹ دقیقه طول شرقی و ۲۹ درجه و ۵۸ دقیقه تا ۳۳ درجه و ۴ دقیقه عرض شمالی واقع شده است. این منطقه دارای اقلیم خشک و نیمه‌خشک بوده و از لحاظ توپوگرافی به دو بخش کوهستانی و جلگه‌ای تقسیم می‌شود (شکل ۱). در این پژوهش به بررسی عملکرد فرامدل‌های هیبریدی هوش مصنوعی و باکس جنکینز به منظور پیش‌بینی شاخص FDS در هفت ایستگاه سینوپتیک استان خوزستان (آبادان، اهواز، بستان، بندرماهشهر، مسجدسلیمان، صفی‌آباد و دزفول) با جامعه آماری ۴۰ ساله (۲۰۲۰-۱۹۸۱) پرداخته شد. بدین منظور از داده‌های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی (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 به منظور 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. بنابراین در وهله اول کدهای مربوط به گرد و غبار از سایر پدیده‌های اقلیمی در ساعات مختلف هم‌دیدگی 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 ۱۰۰۰ متر برای همه کدهای هواشناسی گرد و غبار استفاده شده است. بعد از انتخاب ایستگاه‌ها و بررسی داده‌های ۴۰ ساله (۲۰۲۰-۱۹۸۱)، 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 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.



شکل ۱. موقعیت جغرافیایی ایستگاه‌های موقعیت جغرافیایی ایستگاه‌های سینوپتیک مورد مطالعه در استان خوزستان

جدول ۱. کدهای سازمان جهانی هواشناسی مرتبط با پدیده‌های گردوغبار (O'Loingsigh et al, 2014)

توضیح	کد
رخداد طوفان گردوغبار گسترده در خارج از ایستگاه هواشناسی	۰۶
خاک یا شن برخاسته از زمین در محدوده ایستگاه هواشناسی	۰۷
مشاهده گردباد در محدوده ایستگاه هواشناسی یا خارج از آن در زمان دیدبانی یا طی ساعت گذشته	۰۸
طوفان شن یا خاک در زمان دیدبانی در خارج از ایستگاه یا طی ساعت گذشته در محدوده ایستگاه هواشناسی	۰۹
طوفان خفیف یا متوسط شن یا خاک با روند کاهشی طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر، همراه با کاهش میدان دید به کمتر از ۱۰۰۰ اما بیشتر از ۲۰۰ متر	۳۰
طوفان خفیف یا متوسط شن یا خاک بی تغییر شدت طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر و کاهش میدان دید به کمتر از ۱۰۰۰ ولی بیش از ۲۰۰ متر	۳۱
طوفان خفیف یا متوسط شن یا خاک با افزایش شدت طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر همراه با کاهش میدان دید به کمتر از ۱۰۰۰ اما بیشتر از ۲۰۰ متر	۳۲
طوفان شدید شن یا خاک همراه با روند کاهشی طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر و کاهش دید کمتر از ۲۰۰ متر	۳۳
طوفان شدید شن یا خاک بی تغییر شدت طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر همراه با کاهش دید به کمتر از ۲۰۰ متر	۳۴
طوفان شدید شن یا خاک با افزایش شدت طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر و کاهش دید به کمتر از ۲۰۰ متر	۳۵
رعدوبرق بدون بارش همراه با طوفان شن یا خاک (هبوب)	۹۸

جدول ۲. مشخصات جغرافیایی ایستگاه‌های مورد بررسی و فراوانی روزهای همراه با طوفان‌های گرد و غبار

نام ایستگاه	طول جغرافیایی (درجه)	عرض جغرافیایی (درجه)	میانگین فصلی FDS (روز)	مجموع FDS (روز)
آبادان	۴۸/۲۱	۳۰/۳۸	۳/۹۵	۶۳۳
اهواز	۴۸/۲۴	۳۱/۳۴	۳/۱۰	۴۹۷
بستان	۴۸/۰۱	۳۱/۷۱	۳/۰۰	۴۸۱
مسجد سلیمان	۴۹/۲۴	۳۱/۹۸	۲/۵۱	۴۰۲
بندر ماهشهر	۴۹/۱۶	۳۰/۵۵	۲/۵۱	۴۰۳
صفی آباد	۴۸/۴۳	۳۲/۲۵	۲/۰۳	۳۲۵
دزفول	۴۸/۳۸	۳۲/۴۰	۱/۸۱	۲۹۰

تبدیل موجک^۱

تبدیل موجک به عنوان روشی جایگزین برای تبدیل فوریه‌ی زمان کوتاه ارائه شده است و هدف از ارائه‌ی آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوریه‌ی زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه‌ی زمان کوتاه، سیگنال مورد نظر به پنجره‌هایی تقسیم شده و تبدیل موجک بر روی هر کدام از این پنجره‌ها به صورت جداگانه انجام می‌گیرد (Wang et al., 2000). اما مهم‌ترین تفاوت آن‌ها در این است که در تبدیل موجک علاوه بر اینکه قدرت تفکیک فرکانس‌های یک سیگنال یا طول پنجره، متناسب با نوع فرکانس تغییر می‌کند، هم‌زمان عرض پنجره یا مقیاس فرکانس نیز متناسب با نوع فرکانس تغییر می‌کند. تبدیل موجک به دو صورت پیوسته و گسسته تعریف می‌شود (Dehghani et al., 2020).

تبدیل موجک پیوسته^۲

تبدیل موجک پیوسته‌ی تابع $f(t)$ به صورت روابط ۱ و ۲ تعریف می‌شود (Dehghani et al., 2020):

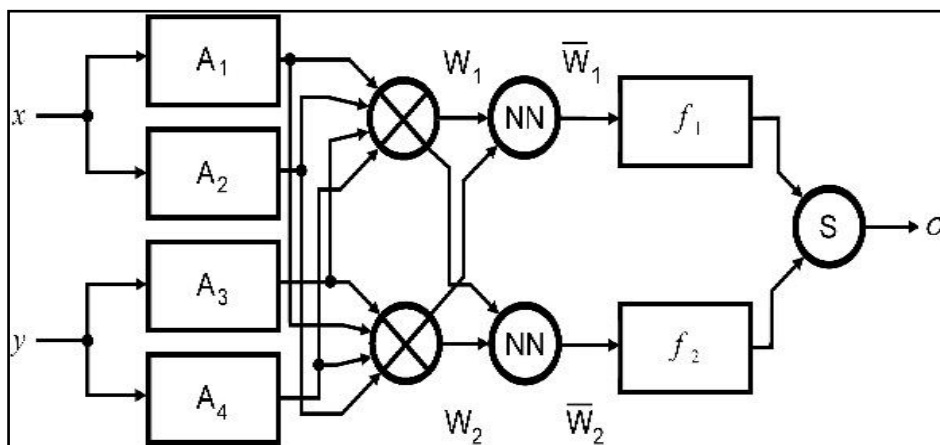
$$CWT_f^\psi(s, \tau) = \psi_{s,\tau}^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \psi^* \left(\frac{t-\tau}{s} \right) dt = \langle f(t), \psi_{s,\tau}(t) \rangle \quad \text{رابطه (۱)}$$

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi \left(\frac{t-\tau}{s} \right) \quad \text{رابطه (۲)}$$

رابطه‌ی ۲ یک رابطه با دو متغیر s و τ است که s پارامتر مقیاس (عکس فرکانس) و τ پارامتر انتقال می‌باشد. علامت * نیز نشان‌دهنده‌ی مزدوج مختلط است. ψ تابع پنجره یا موجک مادر و $\frac{1}{\sqrt{|s|}} \psi \left(\frac{t-\tau}{s} \right)$ موجک‌های حاصل از انتقال و تغییر مقیاس موجک مادر هستند. واژه‌ی مادر به این سبب به کار می‌رود که تمامی نسخه‌های انتقال یافته و مقیاس شده (موجک‌های دختر)، همگی از این تابع به دست می‌آیند. یعنی موجک مادر یک الگو برای سایر پنجره‌هاست (Dehghani et al., 2020).

سیستم استنباط عصبی-فازی تطبیقی^۳

ANFIS شبیه یک شبکه عصبی چند لایه است با این تفاوت که علاوه بر الگوریتم‌های یادگیری شبکه عصبی از منطق فازی نیز بهره می‌گیرد. یک مدل ANFIS از پنج لایه تشکیل شده است؛ این پنج لایه به ترتیب عبارت‌اند از: لایه ورود اطلاعات، لایه محاسبه وزن قوانین فازی، لایه نرمال‌سازی وزن‌های قوانین به دست آمده، لایه محاسبه قوانین، لایه جمع‌بندی و خروجی شبکه (Aragi Nejad, 2013; Jang, 1993). در این پژوهش تابع عضویت در نظر گرفته شده، تابع عضویت ذوزنقه‌ای و الگوریتم آموزش شبکه، روش هیبریدی در نظر گرفته شد. شکل ۲ شماتیکی از ANFIS را نشان می‌دهد.



شکل ۲. شماتیک سیستم استنباط عصبی-فازی تطبیقی (ANFIS)

1-Wavelet Transform (WT)

2-Continues Wavelet Transform (CWT)

3-Neural-Adaptive Fuzzy Inference System

الگوریتم گیاهان مصنوعی^۱

الگوریتم گیاهان مصنوعی از چهار عنصر اساسی تشکیل شده است: گیاه اصلی، گیاه فرزند، موقعیت گیاه و فاصله پخش. گیاهان اصلی به گیاهانی گفته می‌شود که آماده پخش دانه هستند. گیاهان فرزند دانه گیاهان اصلی بوده و در آن لحظه نمی‌توانند دانه پخش کنند. موقعیت گیاه همان محل استقرار گیاه است. فاصله پخش به میزان فاصله پخش دانه اشاره دارد. در این الگوریتم سه الگوی اصلی رفتاری وجود دارد رفتار تکامل، رفتار پخش و رفتار انتخاب (Pagie and Mitchell, 2002; Rosin and Belew, 1995; Wiegand and Sarma, 2004)، رفتار تکامل به معنی احتمال تکامل گیاه برای سازگاری با رفتارهای محیطی است (Cartlidge and Bulloc, 2004; Hillis, 1990; Williams and Mitchell, 2005). رفتار پخش به حرکت دانه‌ها اشاره دارد. این دانه‌ها می‌توانند از طریق خودگشتی یا دیگرگشتی حرکت کنند. رفتار انتخاب نیز به معنای بقاء یا انقراض گیاه به دلایل زیست‌محیطی است (Cheng et al., 2018; Dehghani et al., 2020).

ماشین بردار پشتیبان^۲

ماشین بردار پشتیبان یکی از روش‌های یادگیری با نظارت^۳ است. ماشین بردار پشتیبان، دسته‌بندی کننده‌ای است که جزء شاخه روش‌های کرنلی^۴ در یادگیری ماشین محسوب می‌شود. این نوع سیستم یادگیری هم برای دسته‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها به کار می‌رود. به طوری که کمترین خطا در دسته‌بندی داده‌ها و یا تابع برازش رخ دهد. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی از جمله شبکه‌های عصبی پرسپترون، داشته است. مبنای کاری دسته‌بندی کننده ماشین بردار پشتیبان، دسته‌بندی خطی داده‌ها است. در دسته‌بندی خطی داده‌ها سعی می‌شود خطی انتخاب گردد که حاشیه اطمینان بیشتری داشته باشد. حل معادله پیدا کردن خط بهینه برای داده‌ها به وسیله روش QP که روش‌های شناخته شده‌ای در حل مسائل محدودیت‌دار هستند صورت می‌گیرد. قبل از تقسیم خطی، برای اینکه ماشین بتواند داده‌های با پیچیدگی بالا را دسته‌بندی کند، داده‌ها به وسیله تابع phi به فضای با ابعاد خیلی بالاتر^۵ برده می‌شود. به منظور حل مساله با ابعاد بالا از قضیه دوگانگی لاگرانژ^۶ استفاده می‌شود. از این رو تابع هدف مربوطه به جای تابع پیچیده phi با ابعاد بالا، از تابع ساده‌تری به نام تابع هسته که ضرب برداری تابع phi می‌باشد، استفاده می‌شود (Eskandari et al., 2018).

مدل فصلی خطی^۷ (SARIMA)

مدل SARIMA اولین بار برای سری زمانی فصلی بکار برده شد (Box et al., 1994). اگر در یک سری زمانی رفتار تناوبی در فاصله‌های زمانی مشخص (S) مشخص شود، این سری زمانی دارای تناوب فصلی است و برای مدل سازی آن از SARIMA استفاده می‌شود. این مدل به شکل SARIMA (p,d,q)(P,D,Q)s مشخص می‌شود که در ساختار آن‌ها (p,d,q) جزء غیرفصلی مدل و (P,D,Q) جزء فصلی مدل و S طول دوره فصل است. با بکارگیری عملگر انتقال به عقب B، شکل کلی مدل به صورت زیر ارائه می‌شود.

$$\varphi_p(B)\theta_q(B^S)\nabla^d\nabla_S^D Z_t = \theta_q(B)\theta_Q(B^S)a_t \quad \text{رابطه ۳}$$

که $\theta_p(B^S)$ و $\varphi_p(B)$ به ترتیب چندجمله‌ای بر حسب B^S از درجه P و Q هستند. $\theta_q(B)$ و $\varphi_p(B)$ به ترتیب چندجمله‌ای‌های مرتبه p و q می‌باشند. ∇^d عملگر غیر فصلی و ∇_S^D عملگر فصلی است. p مرتبه خودهمبسته غیر فصلی، d تعداد تفاضل گیری غیرفصلی، q مرتبه میانگین متحرک غیرفصلی، P مرتبه خودهمبسته فصلی، D تعداد تفاضل گیری فصلی، Q مرتبه میانگین متحرک فصلی و S طول فصل می‌باشد.

مدل غیر خطی آستانه (SETAR)

این مدل شامل k بخش AR(p) می‌باشد و مرتبه مدل خودهمبسته در هر رژیم یا قطعه متفاوت است. به طوریکه، یک فرآیند بر طبق یک مقدار مشاهده شده (یک آستانه) به فرآیند دیگری تغییر می‌کند. یکی از حالت‌های خاص از مدل TAR مدل SETAR می‌باشد و در ابتدا توسط Tong (1983) ارائه گردید. مدل SETAR که دارای دو رژیم می‌باشد، SETAR(2;p, r) به صورت زیر ارائه می‌گردد (Ahmadpour et al., 2021).

1-Artificial Flora
 2-Support Vector Machine (SVM)
 3-Supervised learning
 4-Kernel Methods
 5-High dimensional space
 6-Lagrange Duality Theorems
 7-Seasonal Autoregressive Integrated Moving Average

$$Y_t = \begin{cases} \alpha_{10} + \sum_{i=1}^p \alpha_{1i} Y_{t-i} + \varepsilon_t & \text{if } Y_{t-d} \leq \tau \\ \alpha_{20} + \sum_{i=1}^r \alpha_{2i} Y_{t-i} + \varepsilon_t & \text{if } Y_{t-d} > \tau \end{cases} \quad \text{رابطه ۴}$$

که در آن ε_t نوفه سفید، p و r به ترتیب مرتبه‌های مدل AR رژیم‌های پایین ($Y_{t-d} \leq \tau$) و بالا ($Y_{t-d} > \tau$)، ضرایب معادله‌ها، مقدار آستانه و d زمان تأخیر معادله دو رژیمی بالا را مشخص می‌کند و با حداکثر کردن تابع درست‌نمایی، این مقادیر بدست می‌آید. به منظور برآورد یک مدل TAR، ابتدا باید پارامترهای آستانه (τ) و زمان تأخیر (d) برآورد می‌شوند. سپس، داده‌ها به دو رژیم پایین و بالا تقسیم می‌شوند و در آخر، ضرایب معادله‌های AR در هر رژیم به دست می‌آید. با حداکثر کردن تابع لگاریتم درست‌نمایی مقادیر τ و d از طریق رابطه ۵ محاسبه می‌شود:

$$l(\tau, d) = \frac{n-p}{2} \{1 + \log(2\pi)\} - \frac{n_1(\tau, d)}{2} \log\left((\hat{\sigma}_1(\tau, d))^2\right) - \frac{n_2(\tau, d)}{2} \log\left((\hat{\sigma}_2(\tau, d))^2\right) \quad \text{رابطه ۵}$$

که n تعداد کل داده‌ها، p مرتبه مدل AR، n_1 و n_2 به ترتیب عداد داده‌های واقع شده در رژیم‌های پایین و بالا، $\hat{\sigma}_1$ و $\hat{\sigma}_2$ نیز واریانس خطاها حاصل از مجموع مربعات باقیمانده می‌باشند. پس از آن، برای مقادیر τ و d ثابت شده و با حداقل رساندن معیار آکائیک اصلاح شده (AIC)، مرتبه‌های دو مدل پایین و بالا تخمین زده می‌شوند (رابطه ۶).

$$AIC(p, r, \tau, d) = -2l(\tau, d) + 2(p + r + 2) \quad \text{رابطه ۶}$$

مدل خود همبسته میانگین متحرک تلفیق شده^۱ (ARIMA)

انواع مدل‌های سری زمانی عبارتند از: مدل اتورگرسیون، مدل میانگین متحرک و مدل‌های ترکیبی. بنابراین اولین گام در مدل‌سازی، تعیین یا شناسایی مدل بر اساس ویژگی‌های سری مشاهداتی است. یکی از مدل‌های پرکاربرد در مدل‌سازی سری‌های زمانی، مدل‌های ARMA است که باکس و جنکینز، با معرفی آن، پایه‌ای مدرن از مدل‌سازی هیدرولوژیکی را بنا نهادند. فرمول ریاضی مدل ARMA به صورت رابطه ۷ است (Box and Jenkins, 1976):

$$y_t = \varphi_1 y_{t-1} + \dots + \varphi_p y_{t-p} + \alpha_t - \theta_1 \alpha_{t-1} - \dots - \theta_q \alpha_{t-q} \quad \text{رابطه ۷}$$

که در آن، y_t مجموعه‌ای وابسته به زمان، φ پارامترهای غیرفصلی AR، θ پارامترهای غیرفصلی MA و α_{t-q} متغیرهای تصادفی سری تصادفی محض و تأخیرهای مختلف آن می‌باشند. مدل‌های سری زمانی می‌تواند به صورت AR(p) و MA(q) و یا ترکیبی از هر دو ARMA(p,q) باشند و یا به صورت مدل یکپارچه متحرک ARMIA(p,d,q) استفاده شوند. یک مدل ARMA به عنوان ترکیبی از یک فرآیند میانگین متحرک و یک فرآیند خودکارآمدی، به جای یک مدل AR یا MA تنها به دست می‌آید. مدل خودهمبسته-میانگین متحرک تلفیق شده یا ARMIA(p,d,q) مدلی تشکیل شده از یک مقدار ثابت، یک ضریب از مقادیر قبلی داده‌ها، یک ضریب از خطاهای قبلی و یک نویز است که به صورت ریاضی در رابطه ۸ آورده شده است:

$$y_t = c + \sum_{i=1}^p \varphi_i y_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad \text{رابطه ۸}$$

که در آن c مقدار ثابت، φ_i ضریبی از مقادیر قبل، θ_i ضریبی از خطاهای قبل و ε_t مقدار نویز بوده و تعیین اندازه آن دلخواه است. P و q نیز به ترتیب تعدادی از مقادیر و خطاهای قبل هستند. طبق تعریف دیگر p ، درجه چندجمله‌ای اتورگرسیو پولی نومیال (AR) و q چندجمله‌ای میانگین حرکتی (MA) می‌باشند.


مدل شبکه عصبی دینامیک^۲ NARX

شبکه‌های عصبی مصنوعی دینامیک NARX، دسته مهمی از شبکه‌های عصبی دینامیکی بازگشتی غیرخطی هستند. برخلاف شبکه‌های انتشار مستقیم مانند پرسپترون چند لایه، در شبکه‌های بازگشتی از نورون‌های لایه‌های میانی یا لایه خروجی به لایه‌های قبل، یا همان لایه، پس‌خورد وجود دارد. این پس‌خورد معمولاً شامل یک واحد تأخیر زمانی است. همین ارتباطات تأخیردار به امکان به وجود آوردن حافظه در ساختار شبکه کمک می‌کند و شبکه‌های بازگشتی را به ابزاری پویا تبدیل می‌نماید. مدل NARX دسته‌ای از سامانه‌های

خودبرگشتی غیرخطی گسسته در زمان است که علاوه بر ورودی‌های درون‌زاد، دارای ورودی‌های برون‌زاد است و با رابطه ذیل توصیف می‌شود (Omidvar et al., 2015).

$$\hat{Y}(t+1) = f(y(t), \dots, y(t-D_y), u(t), \dots, u(t-D_u)) + \varepsilon_t \quad \text{رابطه ۹}$$

که در آن، $y(t)$ سری زمانی مورد علاقه است که باید پیش‌بینی شود و $u(t)$ سری زمانی دیگری است که جملات آن به طور متناظر با جملات $y(t)$ مرتبط هستند. جملات $u(t), \dots, u(t-D_u)$ ورودی‌های برون‌زاد هستند که توسط یک خط تأخیر با مرتبه D_u تولید می‌شوند. به طور مشابه $y(t), \dots, y(t-D_y)$ ورودی‌های درون‌زا را تشکیل می‌دهند و با خط تأخیری با مرتبه D_y خروجی شبکه NARX را تولید می‌کند. f یک تابع غیرخطی است که مقدار بعدی سری $y(t)$ را تخمین می‌زند. ε_t نویز جمع‌شونده تخمین است (شکل ۳). در شبکه NARX، می‌توان با افزایش تعداد تأخیرها در خط تأخیر خروجی شبکه، میرا شدن گرادیان را به تأخیر انداخت. مزیت شبکه NARX بر دیگر شبکه‌های بازگشتی آن است که پس‌خوردها به طور مستقیم، خروجی را به ورودی ارتباط می‌دهند (Bharlo, 2009).



شکل ۳. مدل بازگشتی غیرخطی با ورودی برون‌زاد (NARX)

مدل‌های پیش‌بینی

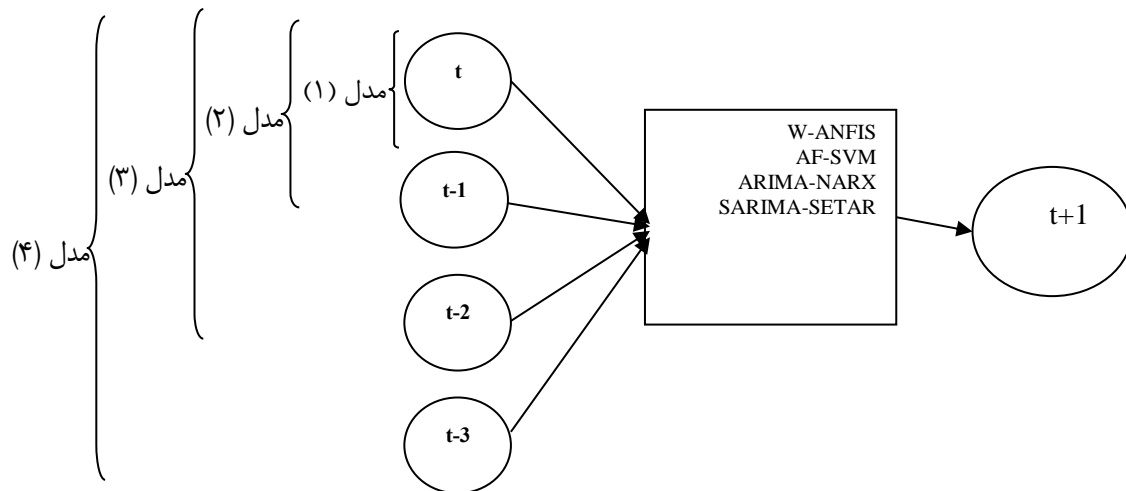
برای پیش‌بینی کمی فراوانی روزهای همراه با طوفان‌های گرد و غبار (FSDS) چهار فرامدل هیبریدی مختلف مورد استفاده قرار گرفت. سپس، بر اساس معیارهای ارزیابی بهترین مدل در هر پیش‌بینی انتخاب شد. متغیر تعداد فصل (های) گذشته برای پیش‌بینی فصل آتی به کار گرفته شد که می‌تواند شامل یک، دو، سه و چهار فصل قبل از متغیر 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 زیر در تکمیل توضیحات بیان شده ارائه می‌شود. شکل ۴، مدل‌های مورد استفاده در انتخاب فصل (های) گذشته برای پیش‌بینی در سال آتی را نشان می‌دهد. روش‌های هیبریدی پیش‌بینی به کار رفته در این پژوهش شامل SARIMA-SETAR، ARIMA-NARX، AF-SVM، W-ANFIS است.

$FSDS_{(t+1)} = f(FSDS_{(t)})$ رابطه (۱۰) مدل ۱

$FSDS_{(t+1)} = f(FSDS_{(t)}, FSDS_{(t-1)})$ رابطه (۱۱) مدل ۲

$FSDS_{(t+1)} = f(FSDS_{(t)}, FSDS_{(t-1)}, FSDS_{(t-2)})$ رابطه (۱۲) مدل ۳

$FSDS_{(t+1)} = f(FSDS_{(t)}, FSDS_{(t-1)}, FSDS_{(t-2)}, FSDS_{(t-3)})$ رابطه (۱۳) مدل ۴



شکل ۴. ساختارهای مورد استفاده در پیش‌بینی فراوانی روزهای همراه با طوفان‌های گرد و غبار

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٪ 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 فرامدل‌های هیبریدی شد. ۸۰٪ داده‌ها برای مرحله آموزش و ۲۰٪ آن برای آزمون مورد استفاده قرار گرفت. پارامترهای مناسب روش‌های مختلف از طریق آزمون و خطا تعیین شد. همچنین به منظور جلوگیری از بیش‌برازش از صحت سنجی^۱ متقاطع استفاده شد. در روش صحت‌سنجی متقاطع در هر بار اجرای مدل برای پیش‌بینی با یک پارامتر مشخص، یک یا تعدادی از داده‌های مجموعه آموزش کنار گذاشته می‌شوند (به عنوان داده‌های صحت سنجی) 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 صحت سنجی از این مسیر جدا می‌شوند و بار دیگر شبکه آموزش داده می‌شود. این فرایند تا زمانی که تمام داده‌های آموزش در قسمت صحت سنجی استفاده شوند، ادامه می‌یابد. پس از آن بر اساس میانگین خطای مدل در تخمین داده‌های صحت سنجی، پارامتر (های) مناسب شبکه عصبی تعیین می‌شوند.

آنالیز اولیه داده‌ها

پیش از هرگونه اقدام در جهت مدل‌سازی یا پیش‌بینی سری زمانی، تجزیه و تحلیل توصیفی اولیه‌ای از داده‌ها امری ضروری است. در این مطالعه آنالیز اولیه داده‌ها بر روی مجموعه داده‌های آموزشی صورت گرفت که شامل شناسایی ویژگی‌های مهمی نظیر همبستگی، الگوهای فصلی، تغییرات دوره‌ای تودرتو در الگوهای فصلی، روند، داده‌های پرت، و هر گونه نوسانات قابل توجه دیگر در این سری‌هاست. همچنین، ایستایی^۲ داده‌ها نیز باید بررسی شود. منظور از ایستایی این است که آیا خواص اساسی آماری مانند میانگین و واریانس سری زمانی در طول زمان ثابت باقی می‌ماند یا خیر؟ (Asplin et al., 2006). بیشتر مدل‌های پیش‌بینی فرض می‌کنند داده‌های سری زمانی ایستا می‌باشند؛ زیرا با این فرض پیچیدگی ریاضی مدل‌های برازش داده‌شده کاهش می‌یابد؛ حال آنکه اغلب در واقعیت چنین نیست. لذا در این مطالعه از آزمون Dickey-Fuller برای تشخیص ایستایی و نایستایی داده‌های آموزشی استفاده شد (Cochrane, 2005) (جدول ۳). در آزمون Dickey-Fuller، سطح معنی‌داری برای احتمال $P\text{-value} < 0.05$ در نظر گرفته شد. فرض H_0 این آزمون نایستایی سری زمانی را بررسی می‌کند. بر اساس این آزمون هیچکدام از ایستگاه‌های مورد مطالعه در استان خوزستان نایستا نیست.

جدول ۳. نتایج آزمون Dickey-Fuller

ایستگاه	P-value
آبادان	۰/۰۱۲
اهواز	۰/۰۱۷
بستان	۰/۰۲۳
مسجد سلیمان	۰/۰۴۶
بندر ماهشهر	۰/۰۳۱
صفی آباد	۰/۰۲۸
دزفول	۰/۰۱۷

معیارهای ارزیابی

برای ارزیابی مدل‌ها و مقایسه نتایج روش‌های مختلف، از چهار معیار ارزیابی یعنی ضریب همبستگی^۱ (R)، جذرمیانگین مربعات خطا^۲ (RMSE)، میانگین قدرمطلق خطا^۳ (MAE) و نش ساتکلایف^۴ (NS) استفاده شد. این معیارها به صورت زیر تعریف می‌شوند:

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad \text{رابطه ۱۴}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad \text{رابطه ۱۵}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad \text{رابطه ۱۶}$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad \text{رابطه ۱۷}$$

در این روابط O_i ، مقادیر مشاهده شده در گام زمانی i ام، f_i مقادیر پیش‌بینی شده در گام زمانی i ام، \bar{O} میانگین مقادیر مشاهده شده، \bar{f} میانگین مقادیر پیش‌بینی شده و n تعداد داده‌ها است. هر مدلی که دارای R و NS بیشتر و $RMSE$ و MAE کمتر باشد از مطلوبیت بیشتری برخوردار است.

نتایج و بحث

مدل‌سازی با فرامدل‌های هیبریدی یادگیری ماشین و باکس جنکینز

جدول ۴ تا ۷، نتایج مربوط به مدل‌سازی شاخص فراوانی روزهای همراه با طوفان‌های گرد و غبار با استفاده از فرامدل‌های هیبریدی هوش مصنوعی W-ANFIS و AF-SVM و مدل‌های سری زمانی ARIMA-NARX، SARIMA-SETAR را نشان می‌دهند. در روش هیبریدی AF-SVM 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^۵ SCE-UA است که طبق پیشنهاد Rosin and Belew (1995) در آنالیزهای هیدرولوژی با موفقیت پیاده سازی شده است. جدول ۴ بیانگر نتایج مربوط به فرامدل هیبریدی الگوریتم گیاهان مصنوعی-ماشین بردار پشتیبان (AF-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. با توجه به اینکه در این جداول ترتیب ایستگاه‌ها از آبادان تا دزفول به صورت نزولی بوده و متوسط مقدار فراوانی طوفان‌های گرد و غبار در مقیاس فصلی از ایستگاه آبادان تا دزفول به ترتیب از ۳/۹۵ تا ۱/۸۱ متغیر است، می‌توان دریافت که کاهش عملکرد روش‌های پیش‌بینی ذکر شده با کاهش فراوانی روزهای همراه با طوفان‌های گرد و غبار رابطه مستقیمی دارد.

1-Correlation

2-Root Mean Square Error

3-Mean Absolute Error

4-Nash-Sutcliffe

5-Shuffled Complex Evolution Algorithm



بدین معنی که با کاهش فراوانی روزهای همراه با طوفان‌های گرد و غبار، مقادیر معیارهای ارزیابی مورد استفاده نیز تقلیل می‌یابند. به نحوی که ضریب همبستگی برای داده‌های آزمایشی در فرامدل‌های AF-SVM و W-ANFIS به ترتیب از مقادیر ۰/۹۹۱ و ۰/۹۸۵ به ۰/۹۸۵ و ۰/۹۵۸ و ضریب نش ساتکلیف نیز به ترتیب از ۰/۹۷۷ و ۰/۹۶۰ به ۰/۹۷۳ و ۰/۹۵۲ کاهش یافته است. همچنین ضریب RMSE به ترتیب از ایستگاه آبادان تا دزفول برای دو فرامدل ذکر شده از مقدار ۰/۱۳۵ و ۰/۱۵۱ به ۰/۱۴۰ و ۰/۱۷۹ و ضریب MAE نیز به ترتیب از مقدار ۰/۰۵۴ و ۰/۰۶۸ به ۰/۰۶۰ و ۰/۰۹۳ افزایش یافته است که نشان‌دهنده ضعیف شدن عملکرد مدل هیبریدی با کاهش فراوانی طوفان‌های گرد و غبار در استان خوزستان می‌باشد. نتایج مدل‌های باکس جنکینز هم (جداول ۵ و ۶) همانند فرامدل‌های هیبریدی با کاهش فراوانی روزهای همراه با طوفان‌های گرد و غبار رابطه مستقیمی دارند. به نحوی که ضریب همبستگی برای داده‌های آزمایشی در مدل‌های SARIMA-SETAR و ARIMA-NARX به ترتیب از مقادیر ۰/۹۶۷ و ۰/۹۵۱ به ۰/۹۵۸ و ۰/۹۴۱ و ضریب نش ساتکلیف نیز به ترتیب از ۰/۹۴۵ و ۰/۹۲۳ به ۰/۹۳۸ و ۰/۹۱۳ و ضریب RMSE به ترتیب از ایستگاه آبادان تا دزفول برای دو فرامدل ذکر شده از مقدار ۰/۱۶۴ و ۰/۱۹۴ به ۰/۱۷۱ و ۰/۲۰۵ و ضریب MAE نیز به ترتیب از مقدار ۰/۰۸۳ و ۰/۱۰۴ به ۰/۰۸۸ و ۰/۱۱۲ افزایش یافته است که باز هم نشان‌دهنده کاهش عملکرد مدل‌های سری زمانی با کاهش فراوانی روزهای همراه با طوفان گرد و غبار در ایستگاه‌های مورد مطالعه می‌باشد. در جداول ۴ تا ۷ مدل‌های بهینه در پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار به ترتیب از ۱ تا ۴ شماره‌گذاری شده است. در نتیجه می‌توان استنباط کرد که انتخاب مدل ساده‌تر به‌عنوان مدل بهینه پیش‌بینی کننده در تمامی ایستگاه‌های مورد مطالعه نتیجه بهتری را از خود نشان می‌دهد. به نحوی که برای پیش‌بینی فراوانی روزهای همراه با طوفان‌های گرد و غبار در همه ایستگاه‌های مورد بررسی مدل شماره ۱ (با یک گام تأخیر) نتیجه بهتری را ارائه می‌دهد. این امر نشان می‌دهد که در ساختار فرامدل‌های هیبریدی هوش مصنوعی و مدل‌های سری زمانی، استفاده از سوابق فراوانی روزهای همراه با طوفان گرد و غبار در فصل‌های قبل، موجب بهبودی چشمگیری در نتایج پیش‌بینی نمی‌شود به طوری که در پیش‌بینی فرامدل AF-SVM در ایستگاه‌های آبادان، اهواز، بستان، مسجد سلیمان، بندر ماهشهر، صفی آباد و دزفول برای دوره آزمایش، با اعمال شاخص FDSO از چهار به یک فصل قبل، ضریب RMSE به ترتیب از مقادیر ۰/۱۵۴، ۰/۱۵۷، ۰/۱۶۰، ۰/۱۶۴، ۰/۱۶۹، ۰/۱۷۸ و ۰/۱۸۱ روز به ۰/۱۵۱، ۰/۱۵۴، ۰/۱۵۷، ۰/۱۶۲، ۰/۱۶۵، ۰/۱۷۵ و ۰/۱۷۹ روز کاهش یافته است. همچنین در پیش‌بینی مدل سری زمانی SARIMA-SETAR در ایستگاه‌های آبادان، اهواز، بستان، مسجد سلیمان، بندر ماهشهر، صفی آباد و دزفول برای دوره آزمایش، با اعمال شاخص FDSO از چهار به یک فصل قبل، ضریب RMSE به ترتیب از مقادیر ۰/۱۶۸، ۰/۱۶۸، ۰/۱۶۹، ۰/۱۷۱، ۰/۱۷۲، ۰/۱۷۴ و ۰/۱۷۵ روز به ۰/۱۶۴، ۰/۱۶۵، ۰/۱۶۶، ۰/۱۶۶، ۰/۱۶۷ و ۰/۱۶۹ و ۰/۱۷۱ روز کاهش یافته است. به نظر می‌رسد با توجه به شرایط آب و هوایی در منطقه مورد مطالعه، تأثیر شاخص FDSO فصل‌های قبل به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار در فصل آینده، آنچنان قابل قبول نیست. که دلیل آن را می‌توان عدم تأثیر ذرات به جامانده از طوفان‌های قبلی و فصل‌های گذشته بر شکل‌گیری طوفان‌های گرد و غبار فصل آینده جستجو کرد. نتایج این قسمت با مطالعات Goudie and Middleton, (2006) و Zeinali (2016) مطابقت دارد. با توجه نتایج ذکر شده و با مقایسه معیارهای ارزیابی در چهار روش پیش‌بینی طوفان‌های گرد و غبار می‌توان استنباط کرد که فرامدل هیبریدی AF-SVM نسبت به سایر روش‌ها از عملکرد بهتری برخوردار است. به نحوی که در همه ایستگاه‌های مورد مطالعه دارای ضریب همبستگی و نش ساتکلیف بیشتر و ضریب ریشه میانگین مربعات خطا و میانگین قدرمطلق خطا کمتری می‌باشد که نشان‌دهنده برتری این فرامدل هیبریدی نسبت به سایر فرامدل‌های ترکیبی برای پیش‌بینی شاخص FDSO در استان خوزستان می‌باشد. به طوریکه معیارهای ارزیابی R، RMSE، MAE و NS به ترتیب از ۰/۹۹۱، ۰/۱۳۵، ۰/۰۵۴ و ۰/۰۷۷ تا ۰/۹۸۵، ۰/۱۴۰، ۰/۰۶۰ و ۰/۹۷۳ متغیر بود. همچنین فرامدل هیبریدی ARIMA-NARX نیز بدترین عملکرد را بین فرامدل‌های هیبریدی به کار گرفته شده از آن خود کرد به طوریکه معیارهای ارزیابی R، RMSE، MAE و NS به ترتیب از ۰/۹۵۱، ۰/۱۹۴، ۰/۱۰۴ و ۰/۰۲۳ تا ۰/۹۴۱، ۰/۲۰۵، ۰/۱۱۲ و ۰/۹۱۳ متغیر بود. شایان ذکر است که فرامدل‌های هیبریدی W-ANFIS و SARIMA-SETAR نیز باتوجه به معیارهای ارزیابی اختصاص یافته به ترتیب در جایگاه دوم و سوم قرار می‌گیرند.

جدول ۴. نتایج آماری الگوهای ورودی مدل AF-SVM و پارامترهای بهینه در پیش‌بینی شاخص FSDS

ایستگاه	مدل بهینه	داده‌های آموزشی				داده‌های آزمایشی				پارامترها	
		NS	MAE	RMSE	R	NS	MAE	RMSE	R	ε	σ
آبادان	۱	۰/۹۹۱	۰/۱۳۵	۰/۰۵۴	۰/۹۷۷	۰/۹۹۳	۰/۱۳۳	۰/۰۵۲	۰/۹۷۹	۳/۲	۳/۵
	۲	۰/۹۹۱	۰/۱۳۶	۰/۰۵۴	۰/۹۷۶	۰/۹۹۲	۰/۱۳۴	۰/۰۵۲	۰/۹۸۱	۱۲	۲/۷
	۳	۰/۹۹۰	۰/۱۳۶	۰/۰۵۶	۰/۹۷۵	۰/۹۹۱	۰/۱۳۴	۰/۰۵۵	۰/۹۷۷	۱۱/۷	۰/۳۷
	۴	۰/۹۸۷	۰/۱۳۷	۰/۰۵۸	۰/۹۷۴	۰/۹۹۰	۰/۱۳۵	۰/۰۵۷	۰/۹۷۷	۱۴	۴/۵
اهواز	۱	۰/۹۹۰	۰/۱۳۵	۰/۰۵۴	۰/۹۷۷	۰/۹۹۳	۰/۱۳۴	۰/۰۵۳	۰/۹۷۸	۵/۲	۳
	۲	۰/۹۹۰	۰/۱۳۶	۰/۰۵۵	۰/۹۷۶	۰/۹۹۱	۰/۱۳۵	۰/۰۵۴	۰/۹۷۸	۱۱/۷	۲/۶
	۳	۰/۹۸۹	۰/۱۳۷	۰/۰۵۶	۰/۹۷۴	۰/۹۹۰	۰/۱۳۶	۰/۰۵۵	۰/۹۷۷	۱۳/۴	۰/۲۷
	۴	۰/۹۸۶	۰/۱۳۸	۰/۰۵۹	۰/۹۷۴	۰/۹۸۹	۰/۱۳۷	۰/۰۵۸	۰/۹۷۶	۱۱/۲	۰/۳۱
بستان	۱	۰/۹۸۹	۰/۱۳۶	۰/۰۵۵	۰/۹۷۶	۰/۹۹۱	۰/۱۳۵	۰/۰۵۴	۰/۹۷۷	۳/۹	۰/۲
	۲	۰/۹۸۸	۰/۱۳۶	۰/۰۵۶	۰/۹۷۵	۰/۹۸۹	۰/۱۳۵	۰/۰۵۵	۰/۹۷۷	۱۴/۵	۳/۵
	۳	۰/۹۸۷	۰/۱۳۷	۰/۰۵۷	۰/۹۷۴	۰/۹۸۹	۰/۱۳۶	۰/۰۵۶	۰/۹۷۶	۱۳/۷	۴/۲
	۴	۰/۹۸۵	۰/۱۳۹	۰/۰۵۹	۰/۹۷۳	۰/۹۸۸	۰/۱۳۸	۰/۰۵۸	۰/۹۷۶	۳/۴	۱۱
مسجد سلیمان	۱	۰/۹۸۹	۰/۱۳۶	۰/۰۵۵	۰/۹۷۶	۰/۹۹۰	۰/۱۳۵	۰/۰۵۴	۰/۹۷۷	۵/۶	۲/۶
	۲	۰/۹۸۷	۰/۱۳۷	۰/۰۵۷	۰/۹۷۴	۰/۹۸۸	۰/۱۳۶	۰/۰۵۶	۰/۹۷۵	۱۲	۲
	۳	۰/۹۸۶	۰/۱۳۸	۰/۰۵۷	۰/۹۷۳	۰/۹۸۸	۰/۱۳۷	۰/۰۵۶	۰/۹۷۴	۱۳	۳
	۴	۰/۹۸۴	۰/۱۳۹	۰/۰۶۱	۰/۹۷۲	۰/۹۸۷	۰/۱۳۸	۰/۰۵۹	۰/۹۷۳	۱۴/۲	۴/۱
بندر ماهشهر	۱	۰/۹۸۸	۰/۱۳۷	۰/۰۵۷	۰/۹۷۵	۰/۹۸۹	۰/۱۳۶	۰/۰۵۶	۰/۹۷۶	۷/۲	۹/۴
	۲	۰/۹۸۶	۰/۱۳۸	۰/۰۵۸	۰/۹۷۳	۰/۹۸۷	۰/۱۳۷	۰/۰۵۷	۰/۹۷۴	۸/۱	۹/۳
	۳	۰/۹۸۵	۰/۱۳۹	۰/۰۵۹	۰/۹۷۲	۰/۹۸۶	۰/۱۳۸	۰/۰۵۷	۰/۹۷۳	۹/۵	۷/۱
	۴	۰/۹۸۴	۰/۱۴۰	۰/۰۶۲	۰/۹۷۱	۰/۹۸۶	۰/۱۳۹	۰/۰۶۱	۰/۹۷۲	۱۳	۴/۷
صفی آباد	۱	۰/۹۸۶	۰/۱۳۹	۰/۰۵۹	۰/۹۷۴	۰/۹۸۷	۰/۱۳۸	۰/۰۵۸	۰/۹۷۵	۱۳	۴/۱
	۲	۰/۹۸۴	۰/۱۴۰	۰/۰۶۱	۰/۹۷۳	۰/۹۸۵	۰/۱۳۹	۰/۰۵۹	۰/۹۷۴	۱۲/۲	۳/۷
	۳	۰/۹۸۳	۰/۱۴۲	۰/۰۶۱	۰/۹۷۰	۰/۹۸۴	۰/۱۴۱	۰/۰۵۹	۰/۹۷۱	۱۱/۷	۴/۲
	۴	۰/۹۸۲	۰/۱۴۳	۰/۰۶۴	۰/۹۶۹	۰/۹۸۳	۰/۱۴۲	۰/۰۶۳	۰/۹۷۰	۳/۱	۴/۸
دزفول	۱	۰/۹۸۵	۰/۱۴۰	۰/۰۶۰	۰/۹۷۳	۰/۹۸۷	۰/۱۳۹	۰/۰۵۹	۰/۹۷۴	۱۲/۳	۳
	۲	۰/۹۸۴	۰/۱۴۲	۰/۰۶۲	۰/۹۷۲	۰/۹۸۵	۰/۱۴۱	۰/۰۶۱	۰/۹۷۳	۱۴/۹	۵
	۳	۰/۹۸۲	۰/۱۴۴	۰/۰۶۵	۰/۹۶۸	۰/۹۸۳	۰/۱۴۳	۰/۰۶۱	۰/۹۶۹	۱۷/۲	۲
	۴	۰/۹۸۲	۰/۱۴۵	۰/۰۶۵	۰/۹۶۷	۰/۹۸۳	۰/۱۴۴	۰/۰۶۴	۰/۹۶۸	۱۸/۲	۷/۱



جدول ۵. نتایج آماری الگوهای ورودی مدل W-ANFIS و پارامترهای بهینه در پیش‌بینی شاخص FDS

داده‌های آموزشی				داده‌های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	R	NS	MAE	RMSE	R		
۰/۹۶۱	۰/۰۶۷	۰/۱۴۹	۰/۹۸۷	۰/۹۶۰	۰/۰۶۸	۰/۱۵۱	۰/۹۸۵	۱	آبادان
۰/۹۶۰	۰/۰۶۹	۰/۱۵۱	۰/۹۸۵	۰/۹۵۹	۰/۰۷۱	۰/۱۵۲	۰/۹۸۴	۲	
۰/۹۵۷	۰/۰۷۱	۰/۱۵۲	۰/۹۸۴	۰/۹۵۶	۰/۰۷۲	۰/۱۵۳	۰/۹۸۳	۳	
۰/۹۵۵	۰/۰۷۲	۰/۱۵۳	۰/۹۸۱	۰/۹۵۴	۰/۰۷۳	۰/۱۵۴	۰/۹۷۹	۴	
۰/۹۵۹	۰/۰۷۲	۰/۱۵۳	۰/۹۸۱	۰/۹۵۸	۰/۰۷۳	۰/۱۵۴	۰/۹۸۰	۱	اهواز
۰/۹۵۹	۰/۰۷۳	۰/۱۵۴	۰/۹۷۹	۰/۹۵۸	۰/۰۷۴	۰/۱۵۵	۰/۹۷۸	۲	
۰/۹۵۶	۰/۰۷۴	۰/۱۵۵	۰/۹۷۸	۰/۹۵۵	۰/۰۷۵	۰/۱۵۶	۰/۹۷۷	۳	
۰/۹۵۴	۰/۰۷۵	۰/۱۵۶	۰/۹۷۷	۰/۹۵۳	۰/۰۷۶	۰/۱۵۷	۰/۹۷۶	۴	
۰/۹۵۸	۰/۰۷۵	۰/۱۵۶	۰/۹۷۶	۰/۹۵۷	۰/۰۷۷	۰/۱۵۷	۰/۹۷۵	۱	بستان
۰/۹۵۸	۰/۰۷۵	۰/۱۵۷	۰/۹۷۵	۰/۹۵۷	۰/۰۷۷	۰/۱۵۸	۰/۹۷۴	۲	
۰/۹۵۵	۰/۰۷۶	۰/۱۵۸	۰/۹۷۴	۰/۹۵۴	۰/۰۷۷	۰/۱۵۹	۰/۹۷۳	۳	
۰/۹۵۳	۰/۰۷۷	۰/۱۵۹	۰/۹۷۴	۰/۹۵۲	۰/۰۷۸	۰/۱۶۰	۰/۹۷۲	۴	
۰/۹۵۷	۰/۰۷۸	۰/۱۶۱	۰/۹۷۳	۰/۹۵۶	۰/۰۷۹	۰/۱۶۲	۰/۹۷۲	۱	مسجد سلیمان
۰/۹۵۶	۰/۰۷۹	۰/۱۶۲	۰/۹۷۲	۰/۹۵۵	۰/۰۸۱	۰/۱۶۳	۰/۹۷۱	۲	
۰/۹۵۴	۰/۰۸۰	۰/۱۶۲	۰/۹۷۱	۰/۹۵۳	۰/۰۸۲	۰/۱۶۳	۰/۹۷۰	۳	
۰/۹۵۲	۰/۰۸۱	۰/۱۶۳	۰/۹۷۱	۰/۹۵۱	۰/۰۸۲	۰/۱۶۴	۰/۹۶۹	۴	
۰/۹۵۶	۰/۰۸۲	۰/۱۶۴	۰/۹۶۹	۰/۹۵۴	۰/۰۸۳	۰/۱۶۵	۰/۹۶۸	۱	بندر ماهشهر
۰/۹۵۵	۰/۰۸۳	۰/۱۶۶	۰/۹۶۸	۰/۹۵۴	۰/۰۸۴	۰/۱۶۷	۰/۹۶۷	۲	
۰/۹۵۳	۰/۰۸۴	۰/۱۶۷	۰/۹۶۷	۰/۹۵۳	۰/۰۸۵	۰/۱۶۷	۰/۹۶۶	۳	
۰/۹۵۱	۰/۰۸۵	۰/۱۶۸	۰/۹۶۵	۰/۹۴۹	۰/۰۸۶	۰/۱۶۹	۰/۹۶۴	۴	
۰/۹۵۴	۰/۰۸۹	۰/۱۷۴	۰/۹۶۲	۰/۹۵۳	۰/۰۹۱	۰/۱۷۵	۰/۹۶۱	۱	صفی آباد
۰/۹۵۳	۰/۰۸۹	۰/۱۷۵	۰/۹۶۱	۰/۹۵۲	۰/۰۹۲	۰/۱۷۶	۰/۹۶۰	۲	
۰/۹۵۲	۰/۰۹۰	۰/۱۷۶	۰/۹۶۱	۰/۹۵۱	۰/۰۹۲	۰/۱۷۷	۰/۹۶۰	۳	
۰/۹۴۸	۰/۰۹۱۹	۰/۱۷۷	۰/۹۵۹	۰/۹۴۷	۰/۰۹۲	۰/۱۷۸	۰/۹۵۸	۴	
۰/۹۵۳	۰/۰۹۲	۰/۱۷۸	۰/۹۵۹	۰/۹۵۲	۰/۰۹۳	۰/۱۷۹	۰/۹۵۸	۱	دزفول
۰/۹۵۲	۰/۰۹۳	۰/۱۷۸	۰/۹۵۸	۰/۹۵۱	۰/۰۹۴	۰/۱۷۹	۰/۹۵۷	۲	
۰/۹۵۱	۰/۰۹۳	۰/۱۷۹	۰/۹۵۸	۰/۹۴۹	۰/۰۹۴	۰/۱۸۱	۰/۹۵۷	۳	
۰/۹۴۷	۰/۰۹۴	۰/۱۷۹	۰/۹۵۷	۰/۹۴۶	۰/۰۹۵	۰/۱۸۱	۰/۹۵۶	۴	

جدول ۶. نتایج آماری الگوهای ورودی مدل SARIMA-SETAR و پارامترهای بهینه در پیش‌بینی شاخص FDS

داده‌های آموزشی				داده‌های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	R	NS	MAE	RMSE	R		
۰/۹۴۷	۰/۰۸۲	۰/۱۶۳	۰/۹۷۱	۰/۹۴۵	۰/۰۸۳	۰/۱۶۴	۰/۹۶۷	۱	آبادان
۰/۹۴۵	۰/۰۸۳	۰/۱۶۴	۰/۹۶۹	۰/۹۴۴	۰/۰۸۴	۰/۱۶۵	۰/۹۶۵	۲	
۰/۹۴۵	۰/۰۸۵	۰/۱۶۵	۰/۹۶۷	۰/۹۴۴	۰/۰۸۶	۰/۱۶۶	۰/۹۶۳	۳	
۰/۹۴۳	۰/۰۸۶	۰/۱۶۷	۰/۹۶۷	۰/۹۴۲	۰/۰۸۷	۰/۱۶۸	۰/۹۶۱	۴	
۰/۹۴۶	۰/۰۸۳	۰/۱۶۴	۰/۹۶۸	۰/۹۴۵	۰/۰۸۴	۰/۱۶۵	۰/۹۶۷	۱	اهواز
۰/۹۴۴	۰/۰۸۴	۰/۱۶۵	۰/۹۶۷	۰/۹۴۳	۰/۰۸۵	۰/۱۶۶	۰/۹۶۵	۲	
۰/۹۴۴	۰/۰۸۶	۰/۱۶۶	۰/۹۶۷	۰/۹۴۳	۰/۰۸۷	۰/۱۶۷	۰/۹۶۲	۳	
۰/۹۴۲	۰/۰۸۷	۰/۱۶۷	۰/۹۶۶	۰/۹۴۱	۰/۰۸۸	۰/۱۶۸	۰/۹۶۱	۴	
۰/۹۴۵	۰/۰۸۳	۰/۱۶۵	۰/۹۶۷	۰/۹۴۴	۰/۰۸۴	۰/۱۶۶	۰/۹۶۶	۱	یستان
۰/۹۴۳	۰/۰۸۵	۰/۱۶۶	۰/۹۶۷	۰/۹۴۲	۰/۰۸۶	۰/۱۶۷	۰/۹۶۵	۲	
۰/۹۴۳	۰/۰۸۷	۰/۱۶۷	۰/۹۶۵	۰/۹۴۲	۰/۰۸۸	۰/۱۶۸	۰/۹۶۱	۳	
۰/۹۴۱	۰/۰۸۸	۰/۱۶۷	۰/۹۶۴	۰/۹۳۹	۰/۰۸۹	۰/۱۶۹	۰/۹۵۹	۴	
۰/۹۴۴	۰/۰۸۴	۰/۱۶۵	۰/۹۶۴	۰/۹۴۳	۰/۰۸۵	۰/۱۶۶	۰/۹۶۳	۱	مسجدسلیمان
۰/۹۴۲	۰/۰۸۶	۰/۱۶۶	۰/۹۶۴	۰/۹۴۱	۰/۰۸۷	۰/۱۶۷	۰/۹۶۳	۲	
۰/۹۴۲	۰/۰۸۸	۰/۱۶۸	۰/۹۶۳	۰/۹۴۱	۰/۰۸۹	۰/۱۶۹	۰/۹۶۱	۳	
۰/۹۴۰	۰/۰۸۹	۰/۱۶۹	۰/۹۶۲	۰/۹۳۹	۰/۰۹۱	۰/۱۷۱	۰/۹۵۹	۴	
۰/۹۴۳	۰/۰۸۵	۰/۱۶۶	۰/۹۶۴	۰/۹۴۲	۰/۰۸۶	۰/۱۶۷	۰/۹۶۲	۱	بندر ماهشهر
۰/۹۴۲	۰/۰۸۶	۰/۱۶۷	۰/۹۶۴	۰/۹۴۱	۰/۰۸۸	۰/۱۶۸	۰/۹۶۲	۲	
۰/۹۴۱	۰/۰۸۹	۰/۱۶۹	۰/۹۶۳	۰/۹۳۹	۰/۰۹۱	۰/۱۷۰	۰/۹۵۹	۳	
۰/۹۳۹	۰/۰۹۱	۰/۱۷۱	۰/۹۶۱	۰/۹۳۸	۰/۰۹۲	۰/۱۷۲	۰/۹۵۸	۴	
۰/۹۴۱	۰/۰۸۷	۰/۱۶۸	۰/۹۶۴	۰/۹۴۰	۰/۰۸۸	۰/۱۶۹	۰/۹۵۹	۱	صفی آباد
۰/۹۳۹	۰/۰۸۸	۰/۱۶۹	۰/۹۶۳	۰/۹۳۸	۰/۰۸۹	۰/۱۷۱	۰/۹۵۸	۲	
۰/۹۳۹	۰/۰۹۲	۰/۱۷۲	۰/۹۶۱	۰/۹۳۸	۰/۰۹۳	۰/۱۷۳	۰/۹۵۷	۳	
۰/۹۳۷	۰/۰۹۳	۰/۱۷۳	۰/۹۶۰	۰/۹۳۶	۰/۰۹۴	۰/۱۷۴	۰/۹۵۶	۴	
۰/۹۳۹	۰/۰۸۷	۰/۱۶۹	۰/۹۶۲	۰/۹۳۸	۰/۰۸۸	۰/۱۷۱	۰/۹۵۸	۱	دزفول
۰/۹۳۸	۰/۰۸۹	۰/۱۷۱	۰/۹۶۲	۰/۹۳۷	۰/۰۹۱	۰/۱۷۲	۰/۹۵۷	۲	
۰/۹۳۷	۰/۰۹۳	۰/۱۷۲	۰/۹۶۱	۰/۹۳۶	۰/۰۹۴	۰/۱۷۳	۰/۹۵۶	۳	
۰/۹۳۶	۰/۰۹۴	۰/۱۷۴	۰/۹۵۹	۰/۹۳۵	۰/۰۹۵	۰/۱۷۵	۰/۹۵۵	۴	



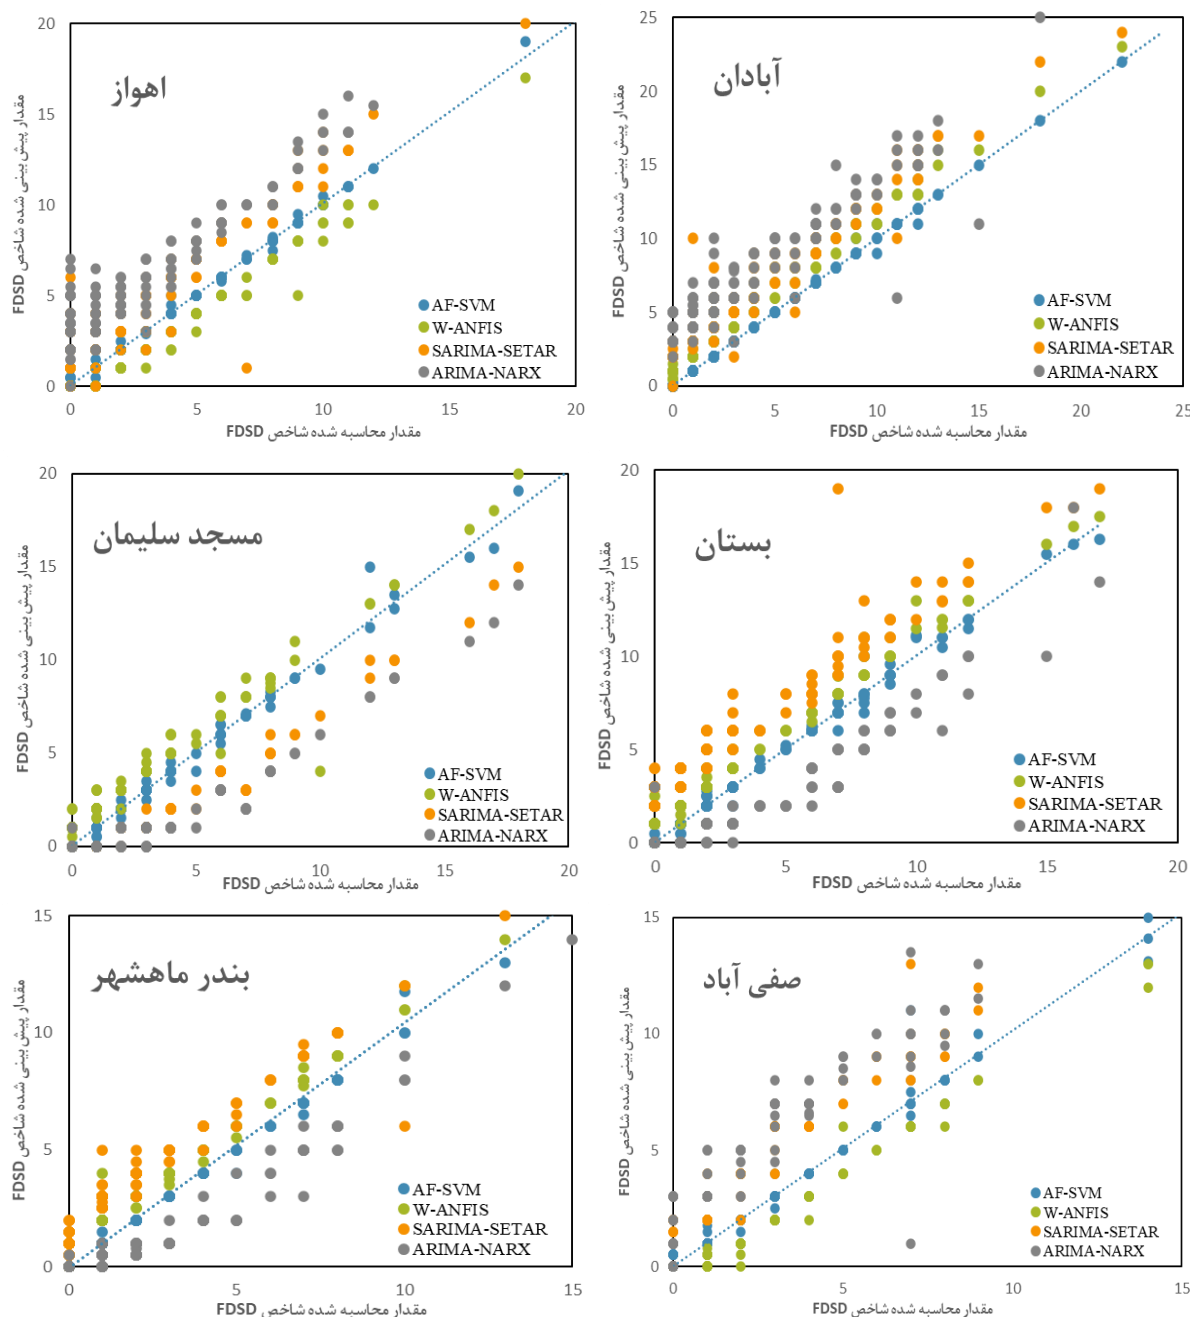
جدول ۷. نتایج آماری الگوهای ورودی مدل ARIMA-NARX و پارامترهای بهینه در پیش‌بینی شاخص FDS

داده‌های آموزشی				داده‌های آزمایشی				مدل بهینه	ایستگاه
NS	MAE	RMSE	R	NS	MAE	RMSE	R		
۰/۹۲۶	۰/۱۰۱	۰/۱۹۱	۰/۹۵۲	۰/۹۲۳	۰/۱۰۴	۰/۱۹۴	۰/۹۵۱	۱	آبادان
۰/۹۲۴	۰/۱۰۱	۰/۱۹۲	۰/۹۵۱	۰/۹۲۳	۰/۱۰۵	۰/۱۹۵	۰/۹۴۸	۲	
۰/۹۲۴	۰/۱۰۳	۰/۱۹۲	۰/۹۴۹	۰/۹۱۸	۰/۱۰۶	۰/۱۹۵	۰/۹۴۸	۳	
۰/۹۲۱	۰/۱۰۴	۰/۱۹۵	۰/۹۴۸	۰/۹۱۶	۰/۱۰۷	۰/۱۹۷	۰/۹۴۳	۴	
۰/۹۲۳	۰/۱۰۴	۰/۱۹۳	۰/۹۴۹	۰/۹۲۲	۰/۱۰۵	۰/۱۹۴	۰/۹۴۸	۱	اهواز
۰/۹۲۳	۰/۱۰۴	۰/۱۹۴	۰/۹۴۹	۰/۹۲۱	۰/۱۰۵	۰/۱۹۵	۰/۹۴۸	۲	
۰/۹۲۲	۰/۱۰۶	۰/۱۹۵	۰/۹۴۷	۰/۹۱۸	۰/۱۰۷	۰/۱۹۶	۰/۹۴۶	۳	
۰/۹۱۹	۰/۱۰۵	۰/۱۹۶	۰/۹۴۵	۰/۹۱۶	۰/۱۰۷	۰/۱۹۷	۰/۹۴۳	۴	
۰/۹۲۱	۰/۱۰۵	۰/۱۹۵	۰/۹۴۸	۰/۹۱۹	۰/۱۰۶	۰/۱۹۶	۰/۹۴۷	۱	بستان
۰/۹۲۱	۰/۱۰۵	۰/۱۹۶	۰/۹۴۸	۰/۹۲۰	۰/۱۰۶	۰/۱۹۷	۰/۹۴۷	۲	
۰/۹۱۹	۰/۱۰۷	۰/۱۹۷	۰/۹۴۵	۰/۹۱۸	۰/۱۰۸	۰/۱۹۸	۰/۹۴۴	۳	
۰/۹۱۸	۰/۱۰۷	۰/۱۹۸	۰/۹۴۴	۰/۹۱۵	۰/۱۰۹	۰/۱۹۹	۰/۹۴۳	۴	
۰/۹۱۹	۰/۱۰۶	۰/۱۹۸	۰/۹۴۷	۰/۹۱۸	۰/۱۰۷	۰/۱۹۹	۰/۹۴۶	۱	مسجدسلیمان
۰/۹۱۹	۰/۱۰۶	۰/۱۹۸	۰/۹۴۷	۰/۹۱۸	۰/۱۰۷	۰/۱۹۹	۰/۹۴۵	۲	
۰/۹۱۸	۰/۱۰۸	۰/۱۹۸	۰/۹۴۴	۰/۹۱۷	۰/۱۰۹	۰/۱۹۹	۰/۹۴۳	۳	
۰/۹۱۷	۰/۱۰۹	۰/۱۹۹	۰/۹۴۳	۰/۹۱۵	۰/۱۱۱	۰/۲۰۱	۰/۹۴۲	۴	
۰/۹۱۶	۰/۱۰۷	۰/۲۰۱	۰/۹۴۶	۰/۹۱۶	۰/۱۰۸	۰/۲۰۲	۰/۹۴۵	۱	بندر ماهشهر
۰/۹۱۴	۰/۱۰۷	۰/۲۰۱	۰/۹۴۵	۰/۹۱۴	۰/۱۰۸	۰/۲۰۲	۰/۹۴۳	۲	
۰/۹۱۳	۰/۱۰۹	۰/۲۰۲	۰/۹۴۱	۰/۹۱۲	۰/۱۱۱	۰/۲۰۳	۰/۹۴۰	۳	
۰/۹۱۲	۰/۱۱۱	۰/۲۰۴	۰/۹۴۱	۰/۹۱۱	۰/۱۱۲	۰/۲۰۵	۰/۹۴۰	۴	
۰/۹۱۵	۰/۱۰۹	۰/۲۰۳	۰/۹۴۳	۰/۹۱۴	۰/۱۱۱	۰/۲۰۴	۰/۹۴۲	۱	صفی آباد
۰/۹۱۳	۰/۱۰۹	۰/۲۰۴	۰/۹۴۲	۰/۹۱۱	۰/۱۱۲	۰/۲۰۵	۰/۹۴۱	۲	
۰/۹۱۱	۰/۱۱۳	۰/۲۰۵	۰/۹۳۸	۰/۹۱۰	۰/۱۱۴	۰/۲۰۶	۰/۹۳۷	۳	
۰/۹۰۹	۰/۱۱۴	۰/۲۰۶	۰/۹۳۶	۰/۹۰۸	۰/۱۱۵	۰/۲۰۷	۰/۹۳۵	۴	
۰/۹۱۴	۰/۱۱۱	۰/۲۰۴	۰/۹۴۲	۰/۹۱۳	۰/۱۱۲	۰/۲۰۵	۰/۹۴۱	۱	دزفول
۰/۹۱۲	۰/۱۱۲	۰/۲۰۵	۰/۹۴۱	۰/۹۰۹	۰/۱۱۳	۰/۲۰۶	۰/۹۳۹	۲	
۰/۹۰۹	۰/۱۱۴	۰/۲۰۶	۰/۹۳۵	۰/۹۰۸	۰/۱۱۵	۰/۲۰۷	۰/۹۳۴	۳	
۰/۹۰۸	۰/۱۱۵	۰/۲۰۷	۰/۹۳۳	۰/۹۰۷	۰/۱۱۶	۰/۲۰۸	۰/۹۳۲	۴	

مقایسه عملکرد فرامدل‌های هیبریدی یادگیری ماشین و باکس جنکینز

شکل ۵ مقادیر مشاهداتی و پیش‌بینی شده شاخص FDS را برای داده‌های آزمایشی 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 ۵ 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 مدل ARIMA-NARX بیشترین پراکندگی و فرامدل هیبریدی AF-SVM 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 مؤثر فرامدل هیبریدی AF-SVM در مقایسه با فرامدل‌های دیگر به کار گرفته شده 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 FSDS بر اساس آزمون t نشان داد که فرض صفر مبنی بر برابر بودن میانگین سری مقادیر مشاهداتی و پیش‌بینی شده در هیچکدام از ایستگاه‌های استان خوزستان و با هیچکدام از فرامدل‌های مورد بررسی در پژوهش حاضر، در سطح خطای یک درصد رد نمی‌شود بنابراین می‌توان نتیجه گرفت که هر چهار مدل پیشنهادی جهت پیش‌بینی شاخص FSDS عملکرد خوبی را داشته‌اند و میانگین سری زمانی را حفظ کرده‌اند (جدول ۸).



شکل ۵. مقایسه مقادیر مشاهداتی و پیش‌بینی شده شاخص FSDS با استفاده از روش‌های AF-SVM، W-ANFIS، SARIMA-SETAR و ARIMA-NARX در ایستگاه‌های مورد مطالعه واقع در استان خوزستان

جدول ۸. آزمون مقایسه میانگین مقادیر مشاهداتی و پیش‌بینی شده شاخص FSDS

میانگین								مدل بهینه	ایستگاه
آماره t									
SARIMA- SETAR	ARIMA- NARX	AF- SVM	W- ANFIS	SARIMA- SETAR	ARIMA- NARX	AF- SVM	W- ANFIS	مشاهداتی	
۰/۹۶۵	۰/۹۵۱	۰/۹۷۹	۰/۹۷۴	۰/۹۷۳	۰/۹۶۱	۰/۹۸۷	۰/۹۸۱	۰/۹۹۴	۱
۰/۹۶۴	۰/۹۵۱	۰/۹۷۹	۰/۹۷۴	۰/۹۷۲	۰/۹۶۱	۰/۹۸۶	۰/۹۸۱	۰/۹۹۳	۲
۰/۹۶۴	۰/۹۵۰	۰/۹۷۸	۰/۹۷۳	۰/۹۷۱	۰/۹۶۱	۰/۹۸۶	۰/۹۷۹	۰/۹۹۳	۳
۰/۹۶۳	۰/۹۴۹	۰/۹۷۷	۰/۹۷۲	۰/۹۶۹	۰/۹۵۸	۰/۹۸۶	۰/۹۷۸	۰/۹۹۳	۴
۰/۹۶۲	۰/۹۵۰	۰/۹۷۸	۰/۹۷۳	۰/۹۶۹	۰/۹۶۰	۰/۹۸۴	۰/۹۷۷	۰/۹۹۲	۱
۰/۹۶۲	۰/۹۵۰	۰/۹۷۶	۰/۹۷۲	۰/۹۶۸	۰/۹۵۹	۰/۹۸۴	۰/۹۷۷	۰/۹۹۱	۲
۰/۹۶۱	۰/۹۴۹	۰/۹۷۶	۰/۹۷۲	۰/۹۶۸	۰/۹۵۸	۰/۹۸۳	۰/۰۷۶	۰/۹۹۱	۳
۰/۹۵۹	۰/۹۴۸	۰/۹۷۵	۰/۹۷۱	۰/۹۶۶	۰/۹۵۷	۰/۹۸۳	۰/۹۷۵	۰/۹۹۲	۴
۰/۹۵۹	۰/۹۴۷	۰/۹۷۷	۰/۹۷۱	۰/۹۶۵	۰/۹۵۹	۰/۹۸۲	۰/۹۷۴	۰/۹۸۹	۱
۰/۹۵۸	۰/۹۴۷	۰/۹۷۶	۰/۹۶۹	۰/۹۶۵	۰/۹۵۹	۰/۹۸۱	۰/۹۷۳	۰/۹۸۸	۲
۰/۹۵۷	۰/۹۴۶	۰/۹۷۵	۰/۹۶۸	۰/۹۶۵	۰/۹۵۷	۰/۹۷۹	۰/۹۷۳	۰/۹۸۶	۳
۰/۹۵۶	۰/۹۴۵	۰/۹۷۵	۰/۹۶۸	۰/۹۶۳	۰/۹۵۶	۰/۹۷۸	۰/۹۷۲	۰/۹۸۵	۴
۰/۹۵۵	۰/۹۴۶	۰/۹۷۴	۰/۹۶۶	۰/۹۶۲	۰/۹۵۷	۰/۹۷۹	۰/۹۷۱	۰/۹۸۵	۱
۰/۹۵۴	۰/۹۴۵	۰/۹۷۳	۰/۹۶۵	۰/۹۶۱	۰/۹۵۶	۰/۹۷۹	۰/۹۷۱	۰/۹۸۵	۲
۰/۹۵۴	۰/۹۴۴	۰/۹۷۲	۰/۹۶۴	۰/۹۶۰	۰/۹۵۵	۰/۹۷۸	۰/۹۶۹	۰/۹۸۵	۳
۰/۹۵۳	۰/۹۴۳	۰/۹۷۲	۰/۹۶۳	۰/۹۵۹	۰/۹۵۴	۰/۹۷۷	۰/۹۶۹	۰/۹۸۴	۴
۰/۹۵۲	۰/۹۴۵	۰/۹۷۱	۰/۹۶۵	۰/۹۵۸	۰/۹۵۲	۰/۹۷۶	۰/۹۶۸	۰/۹۸۳	۱
۰/۹۵۱	۰/۹۴۴	۰/۹۶۹	۰/۹۶۴	۰/۹۵۷	۰/۹۵۲	۰/۹۷۵	۰/۹۶۷	۰/۹۸۵	۲
۰/۹۵۰	۰/۹۴۳	۰/۹۶۹	۰/۹۶۳	۰/۹۵۶	۰/۹۵۱	۰/۹۷۵	۰/۹۶۶	۰/۹۸۲	۳
۰/۹۵۰	۰/۹۴۲	۰/۹۶۸	۰/۹۶۲	۰/۹۵۵	۰/۹۴۹	۰/۹۷۴	۰/۹۶۵	۰/۹۸۱	۴
۰/۹۴۹	۰/۹۴۱	۰/۹۶۴	۰/۹۵۸	۰/۹۵۶	۰/۹۴۵	۰/۹۷۲	۰/۹۶۱	۰/۹۷۶	۱
۰/۹۴۸	۰/۹۳۹	۰/۹۶۳	۰/۹۵۸	۰/۹۵۵	۰/۹۴۴	۰/۹۷۲	۰/۹۶۱	۰/۹۷۶	۲
۰/۹۴۷	۰/۹۳۸	۰/۹۶۲	۰/۹۵۶	۰/۹۵۴	۰/۹۴۳	۰/۹۷۱	۰/۹۵۹	۰/۹۷۵	۳
۰/۹۴۶	۰/۹۳۸	۰/۹۶۱	۰/۹۵۵	۰/۹۵۳	۰/۹۴۲	۰/۹۷۱	۰/۹۵۸	۰/۹۷۵	۴
۰/۹۴۸	۰/۹۴۰	۰/۹۶۳	۰/۹۵۴	۰/۹۵۵	۰/۹۴۱	۰/۹۷۰	۰/۹۵۸	۰/۹۷۴	۱
۰/۹۴۷	۰/۹۴۰	۰/۹۶۲	۰/۹۵۳	۰/۹۵۴	۰/۹۴۱	۰/۹۷۰	۰/۹۵۷	۰/۹۷۳	۲
۰/۹۴۶	۰/۹۳۶	۰/۹۶۱	۰/۹۵۲	۰/۹۵۳	۰/۹۳۹	۰/۹۶۹	۰/۹۵۶	۰/۹۷۳	۳
۰/۹۴۶	۰/۹۳۴	۰/۹۶۱	۰/۹۵۱	۰/۹۵۲	۰/۹۳۸	۰/۹۶۸	۰/۹۵۶	۰/۹۷۲	۴

نتیجه‌گیری

هدف از این پژوهش انتخاب بهترین مدل ترکیبی جدید با استفاده از فرامدل‌های هیبریدی هوش مصنوعی و همچنین فرامدل‌های ترکیبی باکس جنکینز جهت پیش‌بینی و مدل‌سازی شاخص FSDS (فراوانی روزهای همراه با طوفان‌های گردوغبار)، در استان خوزستان به‌عنوان گرد و غبارخیزترین استان کشور بوده است. بدین منظور از داده‌های آماری هفت ایستگاه سینوپتیک استان خوزستان با جمعیت آماری بلندمدت ۴۰ ساله (۲۰۲۰-۱۹۸۱) استفاده گردید. نتایج استفاده از فرامدل‌های هیبریدی AF-SVM و W-ANFIS و فرامدل‌های سری زمانی شامل ARIMA-NARX و SARIMA-SETAR نشان داد که بهترین فرامدل پیش‌بینی گرد و غبار در استان خوزستان فرامدل هیبریدی AF-SVM می‌باشد که بهترین عملکرد را در تمامی ایستگاه‌های مورد مطالعه از خود نشان داد. همچنین نتایج نشان داد با افزایش فراوانی روزهای همراه با طوفان‌های گرد و غبار در ایستگاه‌های مورد مطالعه، عملکرد فرامدل‌های هیبریدی یادگیری ماشین و همچنین الگوریتم‌های ترکیبی باکس جنکینز افزایش می‌یابد. نتایج این مطالعه نشان داد، انتخاب مدل‌های ساده (با تأخیر زمانی یک فصل قبل) نسبت به مدل‌های پیچیده (با تأخیر زمانی سه یا چهار فصل قبل) در بهبود عملکرد معیارهای ارزیابی نقش شایانی دارد.

"هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد"

REFERENCES

- Abdolshahnejad, M., Khosravi, H., Nazari Samani, A., Zehtabian, G. and Alambaigi, A. (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 Farsi)
- Ahmadpour, A., Mirhashemi, S. and Panahi, M. (2021). Evaluation of neural network algorithms, and time-series models and SARIMA-SETAR hybrid model in Monthly wind speed prediction. *Journal of Arid Biome*, 10(2), 131-146. doi: 10.29252/aridbiom.2021.15523.1828. (in Farsi)
- AragiNejad, S.H. (2013). Data-driven modeling: using MATLAB® in water resources and environmental engineering (Vol. 67). *Springer Science & Business Media*, doi:10.1007/978-94-007-7506-0.
- Asplin, B. R., Flottemesch, T. J. and Gordon, B. D. (2006). Developing models for patient flow and daily surge capacity research. *Academic Emergency Medicine*, 13(11): 1109-1113.
- Atai, H. and Ahmadi, F. (2010). Investigating dust as one of the environmental problems of the Islamic world, a case study of Khuzestan province. *The 4th International Congress of Geographers of the Islamic World*, Zahedan. (In Farsi)
- Bharlo, R. (2009). Forecasting time series with long-term dependencies using Narx Recurrent Neural Network. *Twelfth Iranian Electrical Engineering Student Conference*, Tabriz.
- Box, G.E.P. and Jenkins, G.M. (1976). Time Series Analysis: Forecasting and Control. *Revised Edition*, Holden-Day, PP 324.
- Box, G.E.P., Jenkins, G.M. and Reinsel, G.C. (1994). Time series Analysis: Forecasting and Control. 3rdEd. prentice Hall, *Englewood Cliffs Inc., New Jersey*. 598p.
- Cartlidge, J.P. and Bulloc, S.G. (2004). Combating coevolutionary disengagement by reducing parasite virulence. *Evolutionary Computation*, 12(2), 193-222.
- Cheng, L., Wu, X. and Wang, Y. (2018). Artificial Flora (AF) optimization algorithm. *Applied Science*, 329(8), 2- 22.
- Cochrane, J. H. (2005). Time series for macroeconomics and finance. *Manuscript, University of Chicago*, 1-136.
- Dehghani, R., Torabi poudeh, H., Younesi, H. and SHahinejad, B. (2020). Application of the Hybrid Model of Support Vector Machine-Algorithm Artificial Flora in Estimating the Daily Flow of Rivers (Case study: Dez basin). *Iran-Water Resources Research*, 16(2), 132-149.
- Eskandari, A., Solgi, A. and Zarei, H. (2018). Simulating Fluctuations of Groundwater Level Using a Combination of Support Vector Machine and Wavelet Transform. *Irrigation Sciences and Engineering*, 41(1), 165-180. doi: 10.22055/jise.2018.13577.
- Goudie, A. S. and Middleton, N.J. (2006). Desert dust in the global system. *Springer Science & Business Media*.
- Hillis, W.D. (1990). Co-evolving parasites improve simulated evolution as an optimization procedure. *Physica D: Nonlinear Phenomena*, 42, 228-234.
- Jacquelyn, C. (2009). Climate analysis and longrange forecasting of dust storms in Iraq, (Dissertation for the degree of Master of Science), *Graduate college of Naval postgraduate academy*, Monterey California.
- Jamalizadeh Tajabadi, M., Moghadam nia, A., piri, J. and Ekhtesasi, M. (2010). Application of artificial neural networks in dust storm prediction (case study: Zabol city). *Iranian Journal of Rangeland and Desert Research*, 17(2), 205-220. (In Farsi)
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685. doi:10.1109/21.256541.
- Jokar, N., Charkhabi, A., Mohseni, H., Jafari, S. and Gandami, Z. (2012). Investigating the origin and direction of sandstorms in Khuzestan. *The first international conference on the phenomenon of dust and dealing with its harmful effects*, 15-17 February, Khuzestan. (In Farsi)
- keykhosravi, S., Nejadkoorki, F. and Amintoosi, M. (2019). Estimation of Artificial Neural Networks (MLP and RBF) Accuracy in Anticipation of the Dust of the Sabzevar Cement Factory. *Journal of Research in Environmental Health*, 5(1), 43-52. doi: 10.22038/jreh.2019.38083.1277. (In Farsi)
- Mohammadi, G. H., (2015). Analysis of Atmospheric Mechanisms in Dust Transport over West of Iran. *Ph.D. thesis*, Tabriz University, 142 pp. (in Farsi)
- 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.
- Omidvar, K., Nabavizadeh, M., Samarehghasem, M. (2015). Assessment of NARX Neural Network in Prediction of Daily Precipitation in Kerman Province. *Physical Geography Quarterly*, 8(27), 73-90.



- Pagie, L. and Mitchell, M.A. (2002). Comparison of evolutionary and coevolutionary search. *International Journal of Computational Intelligence and Application*, 2, 53–69.
- Pourgholam Amiji, M., Ansari Ghojghar, M., Bazrafshan, J., Liaghat, A. and Araghinejad, S. (2020). Comparing the Performance of SARIMA and Holt-Winters Time Series Models With Artificial Intelligence Methods in Dust Storms Forecasting (Case Study: Sistan and Baluchestan Province). *Physical Geography Research Quarterly*, 52(4), 567-587. doi: 10.22059/jphgr.2021.303847.1007524. (In Farsi)
- Qing, C., Ewing, B. T. and Thompson, M. A. (2012). Forecasting wind speed with recurrent neural networks. *European Journal of Operational Research*, Volume 221(1), 148-154.
- Rosin, C.D. and Belew, R.K. (1995). Methods for competitive co-evolution. Finding Opponents Worth Beating in Proceedings of the International Conference on Genetic Algorithms Pittsburgh, 373–381.
- Selajghah, A., Fathabadi, A. and Najafi Hajivar, M. (2008). Comparison of neural network and time series in drought forecasting (case study: Razavi Khorasan province). *Iranian Journal of Watershed Science and Engineering*, 2(4), 74-77. (In Farsi)
- Shaker Sureh, F. and Asadi, E. (2019). Meteorological and hydro-logical drought communication in Salmas Plain. *DEEJ*, 8 (22), 89-100. (In Farsi)
- Sobhani, B. and Safarian zengir, V. (2020). Analysis and prediction of Dust phenomenon in the southwest of Iran. *Journal of Natural Environmental Hazards*, 8(22), 179-198. doi: 10.22111/jneh.2019.28148.1481. (In Farsi)
- Tong, H. (1983). Threshold Models in Non-Linear Time Series Analysis. *Springer, New York*.
- Wang, D., Safavi, A.A. and Romagnoli, J.A. (2000). Wavelet based adaptive robust M-estimator for non-linear system identification. *AICHE Journal*, 46(4), 1607- 1615.
- Wiegand, R.P. and Sarma, J. (2004). Spatial Embedding and loss of gradient in cooperative coevolutionary algorithms. In *proceedings of the International Conference on Parallel Problem Solving from Nature*, Berlin Germany, 43, 912–921.
- Williams, N. and Mitchell, M. (2005). Investigating the success of spatial coevolution. In *Proceedings of the 7th Annual Conference on Genetic and Evolutionary Computation*, Washington, 46, 523–530.
- 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 Farsi)