

## مقایسه عملکرد مدل‌های سری زمانی SARIMA و Holt-Winters با روش‌های هوش مصنوعی در پیش‌بینی طوفان‌های گردوغبار (مطالعه موردی: استان سیستان و بلوچستان)

مسعود پورغلام آمیجی - دانشجوی دکتری گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران  
محمد انصاری قوجقار - دانشجوی دکتری گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران  
جواد بذرافشان - دانشیار گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران  
عبدالمجید لیاقت\* - استاد گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران  
شهاب عراقی نژاد - دانشیار گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

تاریخ دریافت: ۱۳۹۹/۰۳/۲۷ تاریخ پذیرش: ۱۳۹۹/۰۹/۰۲

### چکیده

هدف از این پژوهش 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 (FDS) در فصل آبی است. بدین منظور، از داده‌های ساعتی گردوغبار و کدهای سازمان جهانی هواشناسی در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان با طول دوره آماری ۲۵ ساله (۱۹۹۰-۲۰۱۴) استفاده شد. نتایج نشان داد روش ANFIS، نسبت به سایر روش‌ها، بهترین عملکرد را داشت و معیارهای ارزیابی  $R$ ،  $RMSE$ ،  $MAE$  و  $NS$  آن به ترتیب از  $0.57$ ،  $0.42$ ،  $0.71$  و  $0.95$  تا  $0.71$  تا  $0.95$ ،  $0.40$ ،  $0.51$  و  $0.96$  متغیر بود. همچنین، با افزایش شاخص متوسط FDS در ایستگاه‌ها (از  $1/06$  تا  $7/11$ )، دقت پیش‌بینی همه روش‌ها افزایش داشت. بر همین اساس، در سری زمانی SARIMA، ضریب همبستگی بین مقادیر مشاهداتی و پیش‌بینی شده شاخص FDS از  $0.64$  به  $0.79$  افزایش یافت. برای روش‌های Holt-Winters، RBF و ANFIS مقدار نیز ضریب همبستگی به ترتیب از  $0.70$  تا  $0.87$ ،  $0.69$  تا  $0.92$  و  $0.72$  تا  $0.95$  متغیر بود. در مجموع، با مقایسه روش‌های مورد استفاده، روش هوش مصنوعی ANFIS بهترین و مدل‌های سری زمانی SARIMA و Holt-Winters بدترین عملکرد را داشتند.

واژگان کلیدی: تحلیل سری زمانی، شبکه‌های عصبی، گردوغبار، ACF و PACF، نواحی بحرانی گردوغباری.

### مقدمه

پدیده گردوغبار یکی از مخاطره‌های طبیعی است و سالانه خسارت‌های زیادی در جنوب غرب و جنوب شرق کشور ایجاد می‌کند. گردوغبار یکی از منابع آلوده‌کننده هوای پاک و عاری از آلودگی است و علت افزایش طوفان‌های گردوغبار در ایران به دلیل موقعیت جغرافیایی کشور با توجه به قرارگیری در کمربند خشک و نیمه‌خشک جهان است و از سوی دیگر نزدیک بودن با کشورهای هم‌چون عربستان، عراق، و سوریه که دارای سطح وسیعی بیابان به دلیل عامل‌های مختلفی است، مانند کمبود پوشش گیاهی، بارش اندک، و دمای بالا (عبدالشاه‌نژاد و همکاران، ۱۳۹۹: ۳۴). 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 گردوغبار محتمل‌تر است (شاکر سوره و اسدی، ۱۳۹۸: ۹۰).

به طور کلی، منابع عمده گردوغبار عبارت‌اند از: سرزمین‌های کم‌ارتفاع و کم‌بارانی که از میانگین بارش سالیانه کمتر از ۲۵۰ میلی‌متر برخوردارند. کشور ایران نیز از این قاعده مستثنی نیست (گودی، ۲۰۱۴: ۱۰۱). ایران، به علت قرار گرفتن در کمربند خشک و نیمه‌خشک، در معرض سیستم‌های متعدد گردوغبار محلی و فرامنطقه‌ای است. همچنین، نیمه غربی کشور، به دلیل عرصه‌های بیابانی و بادهای منطقه‌ای، هرساله آسیب‌های زیادی از این مخاطره را تجربه می‌کند (حسین حمزه و همکاران، ۱۳۹۵: ۹۲).

در بین متغیرهای اقلیمی، بارش و دما از اهمیت بسزایی برخوردارند و شبیه‌سازی دقیق بارش و دما و ارتباط آن با گردوغبار در مطالعات هواشناسی و کشاورزی از اهمیت زیادی برخوردار است. با وجود شبیه‌سازی بارش و دما به دلیل وجود همبستگی درونی بین آن‌ها مشکل است (تانارته و همکاران، ۲۰۱۲). نتایج علمی مشابه توسط هرویجر و همکاران (۲۰۰۷) و هانبرگر و نیکول (۲۰۱۴) نشان داد با افزایش دما تعداد وقوع طوفان‌های گردوغبار نیز افزایش می‌یابد. همچنین، نتایج این تحقیق در ارتباط با همبستگی پارامترهای اقلیمی با طوفان‌های گردوغبار همسوست با نتایج مطالعات ژو و همکاران (۲۰۰۶) و آمگالان و همکاران (۲۰۱۷)، که افزایش دما، افزایش سرعت باد، و کاهش بارندگی را از مهم‌ترین دلایل افزایش رخداد پدیده گردوغبار معرفی کرده‌اند. آینگنگ و همکاران (۲۰۰۹)، با بررسی ارتباط گرمایش جهانی و تغییرات طوفان‌های گردوغباری چین، به این نتیجه رسیدند که گرمایش جهان سبب کاهش شیب عرضی دما و در نتیجه کاهش شدت باد می‌شود.

جمالی‌زاده تاج‌آبادی و همکاران (۱۳۸۶) توانایی دو روش شبکه‌های عصبی مصنوعی (ANN)<sup>۱</sup> و ماشین‌های بردار پشتیبان (SVM)<sup>۲</sup> در پیش‌بینی طوفان‌های گردوغبار شهر زابل را با طول دوره آماری ۲۶ ساله (۱۹۸۰-۲۰۰۵) بررسی کردند. از آنجا که استفاده از نوع  $f$ -SVR<sup>۳</sup> و تابع کرنل پایه شعاعی (RBF)<sup>۴</sup> بهترین جواب‌ها را داده است، توصیه شده در مطالعات دیگر نیز قابلیت‌های این روش‌ها بررسی شود.

سیحانی و همکاران (۱۳۹۴) به بررسی گردوغبار و ارزیابی امکان پیش‌بینی آن بر اساس روش‌های آماری و مدل ANFIS<sup>۵</sup> در زابل با آمار چهارده‌ساله پرداختند. نتایج پیش‌بینی گردوغبار با مدل ANFIS نشان‌دهنده قابلیت بالای آن در پیش‌بینی گردوغبار در این ایستگاه است. علی‌یاری و همکاران (۲۰۰۸) نیز به پیش‌بینی کوتاه‌مدت آلودگی هوا به کمک شبکه‌های عصبی پرسپترون چندلایه (MLP)<sup>۶</sup>، خط حافظه‌دار تأخیر (DLM)<sup>۷</sup>، گاما و سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) پرداختند. نتیجه نشان داد روش پیشنهادی ترکیبی بر اساس بهینه‌سازی ازدحام ذرات (PSO)<sup>۸</sup> و فیلتر کالمن برای آموزش شبکه ANFIS توانایی مناسبی در بهبود عملکرد پیش‌بینی دارد.

سروستان و فلاح قالهری (۱۳۹۹) به پیش‌بینی پدیده گردوغبار در هشت ایستگاه منتخب استان خوزستان با استفاده از مدل‌های سری زمانی باکس جنکینز پرداختند. نتیجه نشان داد الگوهای مناسب ماهانه به ترتیب برای رامهرمز (ARIMA (۲, ۰, ۱)(۱, ۱, ۱)، آغاچاری (ARIMA (۲, ۱, ۱)(۱, ۱, ۱)، بهبهان (ARIMA (۰, ۱, ۳)(۲, ۱, ۱)، آبادان (ARIMA (۰, ۱, ۱)(۲, ۱, ۱) و دزفول (ARIMA (۰, ۱, ۲)(۱, ۱, ۲)، امیدیه (ARIMA (۱, ۱, ۳)(۱, ۱, ۱)، اهواز (ARIMA (۰, ۱, ۳)(۱, ۱, ۱) و

1. Artificial Neural Network
2. Support Vector Machine
3. Support Vector Regression
4. Radial Basis Function
5. Adaptive Neuro-Fuzzy Inference System
6. Multi Layer Perceptron
7. Delay Line Memory
8. Particle Swarm Optimization

مسجدسلیمان (۱،۱،۱)(۰،۳،۴) ARIMA می‌باشند که این مدل‌ها از دقت بسیار خوبی برای پیش‌بینی گردوغبار برخوردار نبودند و همچنین پیش‌بینی تعداد روزهای طوفان گردوغبار برای سال‌های ۲۰۱۸ تا ۲۰۲۷ نشان داد که آغاجاری، آبادان، و مسجدسلیمان بیشتر با پدیده گردوغبار مواجه‌اند.

گودرزی و روزبهانی (۱۳۹۶) کارایی مدل‌های سری زمانی ARIMA و هالت وینترز در پیش‌بینی دما و بارش ماهانه ایستگاه لتیان را بررسی کردند. نتایج پیش‌بینی توسط مدل‌های فصلی ARIMA نشان از قابلیت بالای این مدل‌ها در پیش‌بینی دمای ماهانه داشت و مدل  $(0,0,1)$  ARIMA به‌عنوان مدل سری زمانی مناسب برای داده‌های دما تشخیص داده شد. اگرچه مدل هالت-وینترز نیز از دقت بالایی در پیش‌بینی دما برخوردار بود، نسبت به مدل ARIMA خطای بیشتری داشت. همچنین، نتایج نشان داد مدل‌های فصلی و مدل هالت-وینترز قابلیت بالایی در پیش‌بینی مقادیر بالای بارش ماهانه در ایستگاه لتیان ندارند. این مدل‌ها عمدتاً مقادیر بارش‌های پایین و متوسط را بهتر برآورد می‌کنند و تخمین‌گر مناسبی در بارش‌های بالا نیستند.

سبحانی و همکاران (۱۳۹۹) به بررسی مدل‌سازی و پیش‌بینی گردوغبار در غرب ایران پرداختند. بدین منظور از داده‌های گردوغبار، دما، و رطوبت ۲۸ ایستگاه مناطق درگیر شدید با گردوغبار در ایران در بازه زمانی ۲۹ ساله (۱۹۹۰-۲۰۱۸) استفاده شد. بر اساس نتایج پژوهش، در بهترین شرایط مقدار RMSE مدل ANFIS برابر با ۱۱/۶۷ و مدل RBF برابر با ۲/۱۹ است. بنابراین، قدرت دقت RBF در پیش‌بینی گردوغبار در سال‌های شبیه‌سازی شده بیشتر است. بر اساس نتایج خروجی مدل RBF در پیش‌بینی گردوغبار برای سال‌های آتی ایستگاه‌های مورد مطالعه، در هر دو مقیاس میانگین و حداکثر فراوانی گردوغبار، ایستگاه‌های غربی و جنوب غربی منطقه مورد مطالعه بیشتر در معرض گردوغبار در سال‌های آینده قرار گرفتند.

انتظاری و سروستان (۱۳۹۶) به بررسی گردوغبار و پیش‌بینی آن در استان خوزستان برای بازه زمانی ۲۰۱۹-۲۰۲۳ با استفاده از مدل‌های سری زمانی پرداختند. برای این منظور، از داده‌های گردوغبار سالانه هشت ایستگاه هواشناسی استان خوزستان در طول دوره آماری ۱۹۹۰-۲۰۱۰ استفاده شد. نتیجه یافته‌های مناسب‌ترین مدل‌های سری زمانی گردوغبار برای شهرهای مسجدسلیمان و بهبهان مدل پیش‌بینی هالت-وینترز، شهر دزفول به‌تنهایی از مدل  $(1, 0, 1)$  ARIMA و شهرهای اهواز، رامهرمز، آغاجاری، آبادان، و امیدیه دارای مدل نمو هموار ساده به‌دست آمد.

تغییر اقلیم و بررسی اثرهای آن بر منابع آب از موضوعات مهمی به‌شمار می‌رود که پژوهشگران زیادی هدف تحقیق خود را در این زمینه تعریف کرده‌اند. بنابراین، اهمیت پیش‌بینی وقوع پدیده‌های جوی نظیر گردوغبار، که بسیار حائر اهمیت است، بیش از پیش حس می‌شود. 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 زیست‌محیطی، موجب اختلال در اجرای طرح‌های توسعه پایدار ملی شده و تاکنون پیامدهای منفی زیادی به دنبال داشته و خواهد داشت. از طرفی، بیشتر مطالعات داخلی در این زمینه مربوط به روند پدیده‌های گردوغبار در محدوده‌های کوچک، مطالعات سینوپتیکی، و ماهواره‌ای آن است. بنابراین، با توجه به اینکه این پدیده اثرهای نامطلوب و پیامدهای منفی در زمینه‌های اجتماعی، اقتصادی، و سلامت مردم داشته است، مطالعه و پیش‌بینی و ارتباط‌سنجی آن با نوسانات اقلیمی ضروری است. در این مطالعه به مقایسه عملکرد مدل‌های سری زمانی SARIMA و Holt-Winters با روش‌های هوش مصنوعی RBF و ANFIS به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان گردوغبار (FDSD) پرداخته شده

است و بنابراین این تحقیق می‌تواند راهنما و الگوی جدیدی به‌منظور پیش‌بینی پدیده طوفان گردوغبار در کشور باشد؛ زیرا تا کنون چنین مطالعه‌ای با اهداف فوق‌الذکر انجام نشده است.

## مواد و روش‌ها

### منطقه مورد مطالعه و داده‌های مورد استفاده

در این پژوهش به بررسی مقایسه عملکرد روش‌های آماری کلاسیک (SARIMA و Holt-Winters) و مدل‌های هوش مصنوعی (RBF و ANFIS) به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان گردوغبار (FDS) در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان (زابل، زاهدان، ایرانشهر، خاش، و سراوان)، که بیشترین فراوانی روزهای همراه با طوفان‌های گردوغبار در کشور را شامل می‌شوند (عراقی‌نژاد و همکاران، ۱۳۹۷: ۲۱)، با جامعه آماری ۲۵ساله (۱۹۹۰-۲۰۱۴) در مقیاس فصلی پرداخته شد. بدین منظور، از داده‌های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی (WMO)<sup>۱</sup> استفاده شد. مشاهدات پدیده‌های هواشناسی به فاصله سه ساعت یک بار و در مجموع هشت بار در شبانه‌روز ثبت می‌شود. 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 گردوغبار در ایستگاه‌های مختلف هواشناسی از ۱۱ کد استفاده می‌شود (اولینگ‌سای و همکاران، ۲۰۱۴). کدهای مربوط به طوفان‌های گردوغبار در جدول ۱ ارائه شده است. با توجه به اینکه داده‌های گردوغبار به‌صورت تفکیک‌نشده از سایر پدیده‌های هواشناسی از سازمان هواشناسی در اختیار قرار می‌گیرد، در وهله اول کدهای مربوط به گردوغبار از سایر پدیده‌های اقلیمی در ساعات مختلف هم‌دیدگی جدا شد (گودی و میدلتون، ۲۰۰۶). بر اساس تعریف سازمان جهانی هواشناسی روزهای همراه با طوفان‌های گردوغبار به روزی گفته می‌شود که حداقل در یکی از هشت سینوپ (گزارش‌های سه‌ساعته دیده‌بانی) یکی از کدهای مربوط به گردوغبار (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 گردوغبار کمتر از ۱۰۰۰ متر به ثبت رسیده باشد (گودی و میدلتون، ۲۰۰۶). در این مطالعه، برای تشخیص طوفان‌های گردوغباری از عامل قدرت دید افقی  $\leq 1000$  متر برای همه کدهای هواشناسی گردوغبار استفاده شده است.

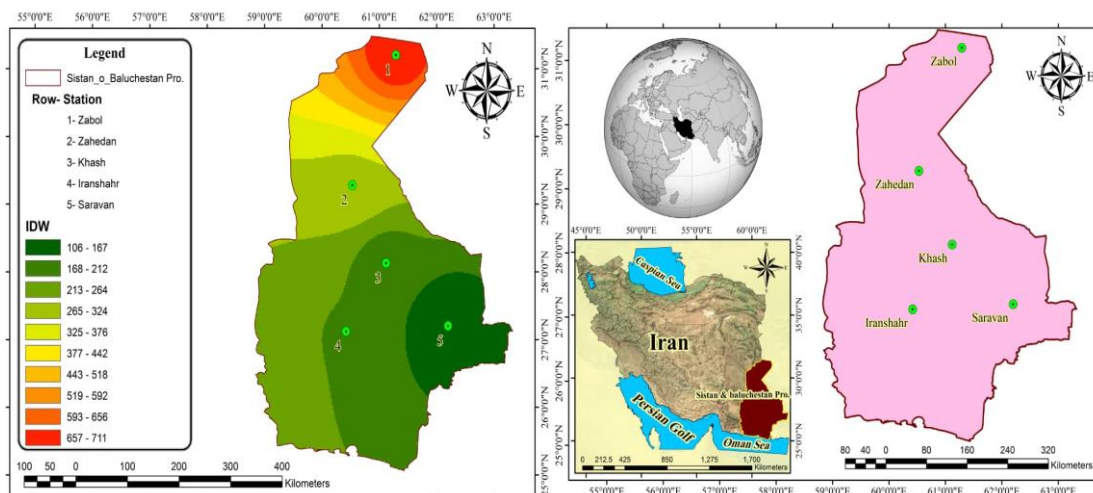
جدول ۱. کدهای سازمان جهانی هواشناسی مرتبط با فرسایش بادی و پدیده‌های گردوغبار (اولینگ‌سای و همکاران، ۲۰۱۴)

توضیحات	کد
مه ناشی از گردوغبار	۰۶
غبار یا شن برخاسته از زمین	۰۷
طوفان گردوغبار	۰۸
طوفان گردوغبار اتفاق افتاده در گذشته (اتفاق افتاده در یک ساعت قبل از مشاهده یا در ایستگاه)	۰۹
گردوغبار خفیف یا متوسط شن و ماسه همراه با کاهش میدان دید کمتر از ۱۰۰۰ متر اما بیشتر از ۲۰۰ متر	۳۰
گردوغبار پایدار یا متوسط شن و ماسه همراه با کاهش میدان دید کمتر از ۱۰۰۰ متر اما بیشتر از ۲۰۰ متر	۳۱
شروع یا افزایش گردوغبار خفیف یا متوسط شن و ماسه همراه با کاهش میدان دید کمتر از ۱۰۰۰ متر اما بیشتر از ۲۰۰ متر	۳۲
طوفان گردوغبار شدید همراه با کاهش میدان دید کمتر از ۲۰۰ متر	۳۳
طوفان گردوغبار پایدار شدید همراه با کاهش میدان دید کمتر از ۲۰۰ متر	۳۴
شروع یا افزایش طوفان گردوغبار شدید همراه با کاهش میدان دید کمتر از ۲۰۰ متر	۳۵
رعدوبرق با گردوغبار و یا طوفان شن و ماسه	۹۸

پس از انتخاب ایستگاه‌ها و بررسی داده‌ها در بازه زمانی ۲۵ ساله (۱۹۹۰-۲۰۱۴)، تعداد روزهای همراه با طوفان گردوغبار (FDSD) برای پنج ایستگاه هواشناسی مورد مطالعه در استان سیستان و بلوچستان با استفاده از داده‌های دید افقی و کدهای سازمان هواشناسی محاسبه و در جدول ۲ نشان داده شده است. ضمن اینکه ایستگاه‌های هواشناسی، طول و عرض جغرافیایی، ارتفاع از سطح دریا، متوسط شاخص FDSD در مقیاس فصلی و تعداد روزهای گردوغباری به ترتیب نزولی قابل مشاهده است. ایستگاه زابل، که در بین ایستگاه‌های مورد مطالعه در مرزی‌ترین نقطه استان سیستان و بلوچستان واقع شده، با ۷۱۱ روز در بازه زمانی ۲۵ ساله به‌عنوان رکورددار بیشترین روزهای همراه با طوفان گردوغبار در این استان ثبت شده است. بر این اساس، ایستگاه‌های خاش و سراوان به ترتیب با ۱۸۰ و ۱۰۶ روز کمترین فراوانی روزهای همراه با طوفان گردوغبار را در بین ایستگاه‌های مورد مطالعه به خود اختصاص داده‌اند. بر اساس این توضیحات، به صورت جغرافیایی می‌توان بیان کرد که با پیشروی از مناطق شرقی و شمالی استان (مناطق مرزی) به سمت جنوب و جنوب غرب استان از وقوع فراوانی روزهای همراه با طوفان گردوغبار کاسته شده است. علت آن را می‌توان در وزش بادهای ۱۲۰ روزه، که در نتیجه تشکیل سیستم پرفشار در شمال شرق دریای خزر و شکل‌گیری یک سامانه کم‌فشار در بیابان‌های شرق ایران و غرب افغانستان ایجاد می‌شود و همچنین متغیر اقلیم، عدم مدیریت صحیح منابع آب، و خشک‌شدن تالاب‌های منطقه جست‌وجو کرد. نتایج این بخش با مطالعات مهرابی و همکاران (۱۳۹۴)، انتظاری و سروستان (۱۳۹۶)، عراقی‌نژاد و همکاران (۱۳۹۷)، و انصاری قوجقار و همکاران (۱۳۹۹) همخوانی دارد. شکل ۱ موقعیت جغرافیایی ایستگاه‌های مورد مطالعه و پهنه‌بندی مقدار شاخص FDSD در استان سیستان و بلوچستان را نشان می‌دهد.

جدول ۲. فراوانی روزهای همراه با طوفان‌های گردوغبار استان سیستان و بلوچستان (۱۹۹۰-۲۰۱۴)

ایستگاه	عرض جغرافیایی (درجه)	طول جغرافیایی (درجه)	ارتفاع از سطح دریا (متر)	میانگین فصلی FDSD (روز)	FDSD (روز)
سراوان	۲۷٫۲۰	۶۲٫۲۰	۱۱۹۵	۱٫۰۶	۱۰۶
خاش	۲۸٫۱۳	۶۱٫۱۲	۱۳۹۴	۱٫۸۰	۱۸۰
ایرانشهر	۲۷٫۱۲	۶۰٫۴۲	۵۹۱	۲٫۱۱	۲۱۱
زاهدان	۲۹٫۲۸	۶۰٫۵۳	۱۳۷۰	۳٫۱۴	۳۱۴
زابل	۳۱٫۲۰	۶۱٫۲۹	۴۸۹	۷٫۱۱	۷۱۱



شکل ۱. معرفی منطقه و پهنه‌بندی مقدار شاخص FDSD در ایستگاه‌های مورد مطالعه

### آنالیز اولیه داده‌ها

برای آنالیز، مدل‌سازی، و پیش‌بینی از نرم‌افزارهای R و Matlab استفاده شد. 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 هرگونه نوسانات قابل توجه دیگر در این سری‌هاست. همچنین، ایستایی<sup>۱</sup> 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؟ (آسپلین و همکاران، ۲۰۰۶: ۱۱۱۰). 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. در این مطالعه از آزمون ریاضی Dickey-Fuller برای تشخیص ایستایی یا نایستایی داده‌ها استفاده شد (کوکران، ۲۰۰۵: ۲۷). آنگاه در مواردی که سری زمانی نایستا بود از تفاضل‌گیری<sup>۲</sup> و تبدیلات توان برای حذف نایستایی روند یا الگوهای فصلی استفاده شد. آنالیز اولیه داده‌ها نیز از طریق تجزیه و تحلیل بصری نمودارهای زمانی شامل  $ACF^3$ ،  $PACF^4$ ، و محاسبات آمار توصیفی پایه انجام گرفت. ضمناً، برای شناسایی الگوهای موجود در سری‌های زمانی از تابع Decompose در نرم‌افزار R استفاده شد که این تابع از روش میانگین متحرک برای تجزیه سری زمانی به اجزای فصلی، روند، و بخش نامنظم و تصادفی استفاده می‌کند.

### انتخاب و برازش مدل‌ها

روش‌های بسیاری برای مدل‌سازی و پیش‌بینی سری‌های زمانی توسعه یافته‌اند و انتخاب یک روش مناسب بسیار اهمیت دارد. تحقیقات گسترده‌ای انجام شده است که نشان می‌دهند یک روش پیش‌بینی برتر برای همه موارد و در حالت جامع در این زمینه وجود ندارد (آسپلین و همکاران، ۲۰۰۶؛ احمد و همکاران، ۲۰۱۰). بنابراین، برای به‌کارگیری یک مدل پیش‌بینی با صحت قابل قبول، باید روش‌های پیش‌بینی مختلفی مقایسه شود و توانایی هر یک در پیش‌بینی مشاهدات نمونه‌های آینده ارزیابی شود. به دلیل وجود الگوهای فصلی در داده‌های ایستگاه‌های مورد مطالعه، مدل‌های پُرکاربرد و دارای صحت بالاتر در مطالعات مشابه، که قابلیت پیش‌بینی الگوهای فصلی را نیز داشتند، به‌عنوان مدل‌های پیش‌بینی سری زمانی در این مطالعه در نظر گرفته شده‌اند که این مدل‌های آماری عبارت‌اند از مدل‌های سری زمانی Holt-Winters<sup>۵</sup> و SARIMA (ابوگی‌سارفو و همکاران، ۲۰۱۵) و مدل‌های یادگیری ماشین شامل دو روش RBF و ANFIS (سینگ و میشر، ۲۰۱۵).

### مدل SARIMA

مدل SARIMA گسترش یافته مدل  $ARIMA^6$  برای داده‌های فصلی است. منظور از سری‌های زمانی فصلی، سری‌هایی است که رفتار نسبتاً منظمی در فواصل زمانی با طول ثابت از خودشان نشان می‌دهند. در هنگام کار با داده‌های سری زمانی، که دارای الگوهای فصلی‌اند، نه‌تنها بررسی وجود همبستگی بین مشاهدات فعلی و مشاهدات اخیر ضروری است

1. Stationary
2. Differencing
3. Auto Correlation Function
4. Partial Autocorrelation Function
5. Seasonal Autoregressive Integrated Moving Average
6. Average Autoregressive Integrated Moving

که بایستی وجود همبستگی میان مشاهدات فعلی و مشاهدات قبلی در فصل‌های گذشته نیز بررسی شود که روشی برای شناسایی وجود یا فقدان الگوی فصلی در داده‌ها نیز هست. این مدل فرض می‌کند که سری زمانی در نظر گرفته شده خطی است و از یک توزیع آماری شناخته‌شده خاص، مانند توزیع نرمال، تبعیت می‌کند. محبوبیت مدل SARIMA عمدتاً به دلیل انعطاف‌پذیری آن در نمایش ساده انواع مختلفی از سری‌های زمانی برای فرایند ساخت مدل بهینه است. برای اجرای مدل SARIMA، از الگوریتم ارائه‌شده توسط هایندمن<sup>۱</sup> و خندکار<sup>۲</sup> استفاده شده است (هایندمن و خندکار، ۲۰۰۸).

### مدل Holt-Winters

این مدل یکی از محبوب‌ترین روش‌های هموارسازی نمایی<sup>۳</sup> است. این مدل بر اساس الگوهای فصلی و روند موجود در داده‌ها ایجاد می‌شود. محبوبیت این روش به دلیل مزایایی از قبیل نیاز محاسباتی کمتر، سادگی استفاده، و دقت پیش‌بینی این مدل به خصوص برای سری‌های دارای الگوی فصلی است. این روش دو گونه معادله (Additive و Multiplicative) دارد. از آنجا که نوسانات سری‌های زمانی این مطالعه نسبتاً ثابت بودند، از معادله Additive استفاده شد که برای سری زمانی  $\{x_t: t=1, \dots, n\}$  به صورت زیر است:

$$\hat{x}_{t+h/t} = l_t + hb_t + s_{t-m+h_m^+} \quad (۱)$$

که  $h$  افق پیش‌بینی است. برای مثال، در این مطالعه که پیش‌بینی برای فصل آتی (سه ماه آینده) است،  $h$  برابر با ۳ بوده و سایر پارامترها عبارتند از:

$$\text{Level: } l_t = \alpha(y_t - s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1})$$

$$\text{Trend: } b_t = \beta*(l_t - l_{t-1}) + (1-\beta*)b_{t-1} \quad (۲)$$

$$\text{Seasonality: } s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1-\gamma)s_{t-1}$$

که  $\alpha$ ،  $\beta^*$  و  $\gamma$  پارامترهای هموارسازی‌اند و مقدار آن به صورت  $0 \leq \alpha \leq 1$ ،  $0 \leq \beta^* \leq 1$  و  $0 \leq \gamma \leq 1$  بوده و همچنین  $m$  طول دوره فصلی است.

### 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 است. به طور کلی این شبکه از سه لایه شامل لایه ورودی، مخفی، و خروجی تشکیل شده است (چن و همکاران، ۱۹۹۱: ۳۰۳). 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 ۴ 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 ۳ زیر استفاده می‌کند:

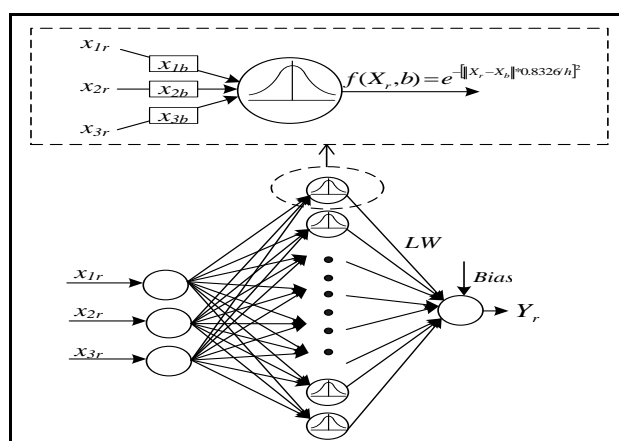
$$f(X_r, b) = e^{-I^2} \quad I = \|X_r - X_b\| * 0.8326/h \quad (۳)$$

1. Hyndman
2. Khandakar
3. Exponential Smoothing

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. محاسبه خروجی  $Y_r$  بر اساس متغیر مستقل  $X_r$  به صورت زیر به دست می‌آید:

$$Y_r = LW * f(X_r, b) + Bias \quad (4)$$

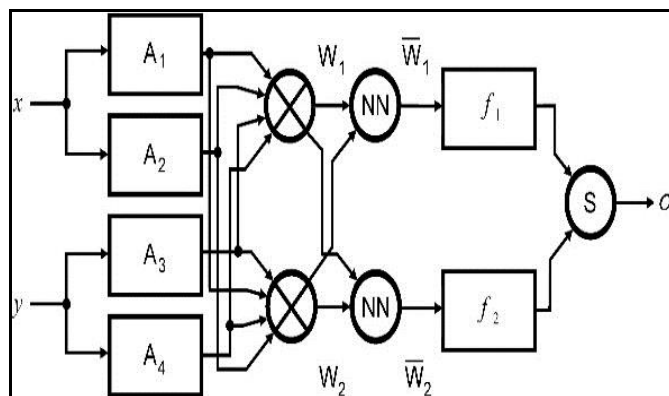
در این رابطه  $LW$  و  $Bias$  به ترتیب وزن ماتریس ارتباطات بین لایه مخفی و لایه خروجی و ماتریس بایاس لایه خروجی است.



شکل ۲. شماتیک RBF

### سیستم استنباط عصبی - فازی تطبیقی (ANFIS)

سیستم استنباط عصبی - فازی تطبیقی (ANFIS) توسط جانگ در سال ۱۹۹۳ معرفی شد (جانگ، ۱۹۹۳). ANFIS شبیه به یک شبکه عصبی چندلایه 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 عبارتند از: لایه ورود اطلاعات، لایه محاسبه وزن قوانین فازی، لایه نرمال‌سازی وزن‌های قوانین به دست آمده، لایه محاسبه قوانین، لایه جمع‌بندی و خروجی شبکه. در این تحقیق تابع عضویت در نظر گرفته شده تابع عضویت دوزنقه‌ای و الگوریتم آموزش شبکه روش هیبریدی در نظر گرفته شد. شکل ۳ شماتیکی از ANFIS را نشان می‌دهد.



شکل ۳. شماتیک سیستم استنباط عصبی - فازی تطبیقی (ANFIS)



### مدل‌های پیش‌بینی

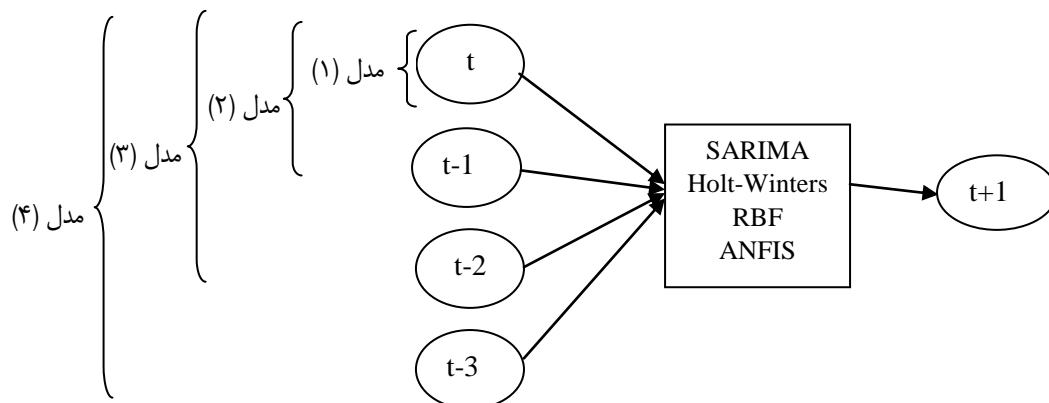
به منظور پیش‌بینی کمی فراوانی روزهای همراه با طوفان‌های گردوغبار (FDSD) چهار مدل مختلف استفاده شد. سپس، بر اساس معیارهای ارزیابی بهترین مدل در هر پیش‌بینی انتخاب شد. متغیر تعداد فصل (های) گذشته برای پیش‌بینی فصل آتی به کار گرفته شد که می‌تواند شامل یک، دو، سه، و چهار فصل قبل از متغیر فراوانی روزهای همراه با طوفان‌های گردوغبار باشد. در مدل ۱، برای پیش‌بینی متغیر فراوانی روزهای همراه با طوفان‌های گردوغبار در فصل بعد، از سری زمانی FDSD 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 گردوغبار 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 ۵-۸ زیر در تکمیل توضیحات بیان شده ارائه می‌شود. شکل ۶ مدل‌های مورد استفاده در انتخاب فصل (های) گذشته برای پیش‌بینی در فصل آتی را نشان می‌دهد. روش‌های پیش‌بینی به کاررفته در این پژوهش شامل SARIMA، Holt-Winters، RBF، و ANFIS است.

$$FDSD_{(t+1)} = f (FDSD_{(t)}) \quad \text{مدل ۱ (۵)}$$

$$FDSD_{(t+1)} = f (FDSD_{(t)}, FDSD_{(t-1)}) \quad \text{مدل ۲ (۶)}$$

$$FDSD_{(t+1)} = f (FDSD_{(t)}, FDSD_{(t-1)}, FDSD_{(t-2)}) \quad \text{مدل ۳ (۷)}$$

$$FDSD_{(t+1)} = f (FDSD_{(t)}, FDSD_{(t-1)}, FDSD_{(t-2)}, FDSD_{(t-3)}) \quad \text{مدل ۴ (۸)}$$



شکل ۴. ساختارهای مورد استفاده در پیش‌بینی گردوغبار

### آماده‌سازی داده‌ها

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 گردوغبار، اقدام به پیش‌بینی آن با استفاده از روش‌های SARIMA، Holt-Winters، RBF، و ANFIS به منظور استفاده از روش‌های هوش مصنوعی شد. از ۸۰ درصد داده‌ها برای مرحله آموزش و ۲۰ درصد آن برای آزمون استفاده شد. پارامترهای مناسب روش‌های مختلف از طریق آزمون و خطا تعیین شد. همچنین،

به منظور جلوگیری از بیش‌برازش از صحت‌سنجی 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 (به‌عنوان داده‌های صحت‌سنجی) و مدل بر اساس داده‌های باقی‌مانده آموزش می‌بیند. سپس، داده‌های کنارگذاشته‌شده به مجموعه آموزش برگردانده شده و داده یا مجموعه دیگری از داده‌های آموزش به‌عنوان داده صحت‌سنجی از این مسیر جدا می‌شود و بار دیگر شبکه آموزش داده می‌شود. این فرایند تا زمانی که همه 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 چهار مدل معرفی‌شده فوق‌الذکر استفاده شد. مدل مناسب بر اساس معیارهای ارزیابی برای هر روش در مقیاس فصلی استخراج شد. پس از آن، تحلیل نتایج بر پایه بهترین مدل برای هر یک از روش‌ها صورت پذیرفت.

### معیارهای ارزیابی

برای ارزیابی مدل‌ها و مقایسه نتایج روش‌های مختلف، از چهار معیار ارزیابی یعنی ضریب همبستگی<sup>۱</sup> (R)، جذر میانگین مربعات خطا<sup>۲</sup> (RMSE)، میانگین قدر مطلق خطا<sup>۳</sup> (MAE)، و نش‌ساتکلیف (NS)<sup>۴</sup> استفاده شد. این معیارها به‌صورت زیر تعریف می‌شوند:

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad (11)$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (12)$$

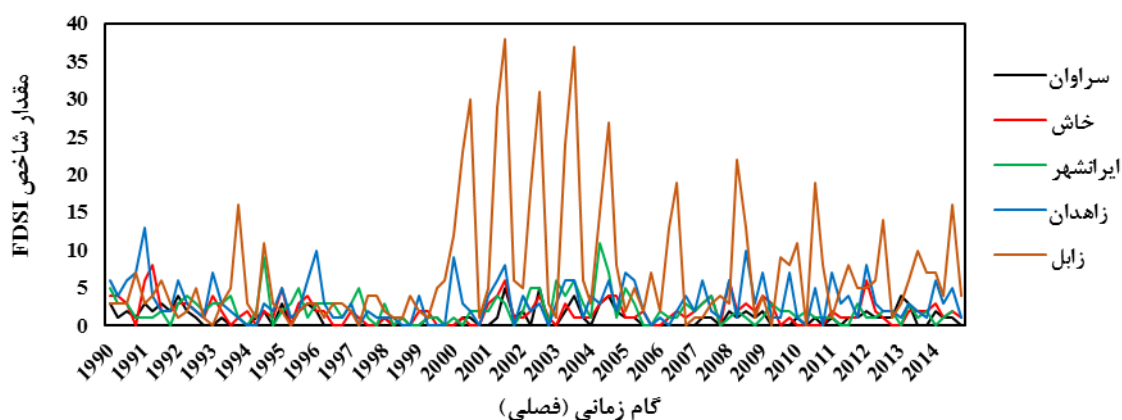
در این رابطه‌ها،  $O_i$  مقادیر مشاهداتی در گام زمانی  $i$ ام،  $f_i$  مقادیر پیش‌بینی‌شده در گام زمانی  $i$ ام،  $\bar{O}$  میانگین مقادیر مشاهداتی،  $\bar{f}$  میانگین مقادیر پیش‌بینی‌شده، و  $n$  تعداد داده‌هاست. هر مدل که دارای  $R$  و  $NS$  بیشتر و  $RMSE$  و  $MAE$  کمتر باشد از مطلوبیت بیشتری برخوردار است.

### نتایج و بحث

شکل ۵ تغییرات شاخص FDSD را در پنج ایستگاه سینوپتیک منتخب استان سیستان و بلوچستان از منظر فراوانی روزهای همراه با طوفان گردوغبار نشان می‌دهد. بر اساس این شکل، شاخص FDSD در ایستگاه‌های سراوان، خاش، ایرانشهر، و زاهدان دارای نوسانات نسبتاً کمی است که به صورت پراکنده در طول سری زمانی پخش شده، ولی با

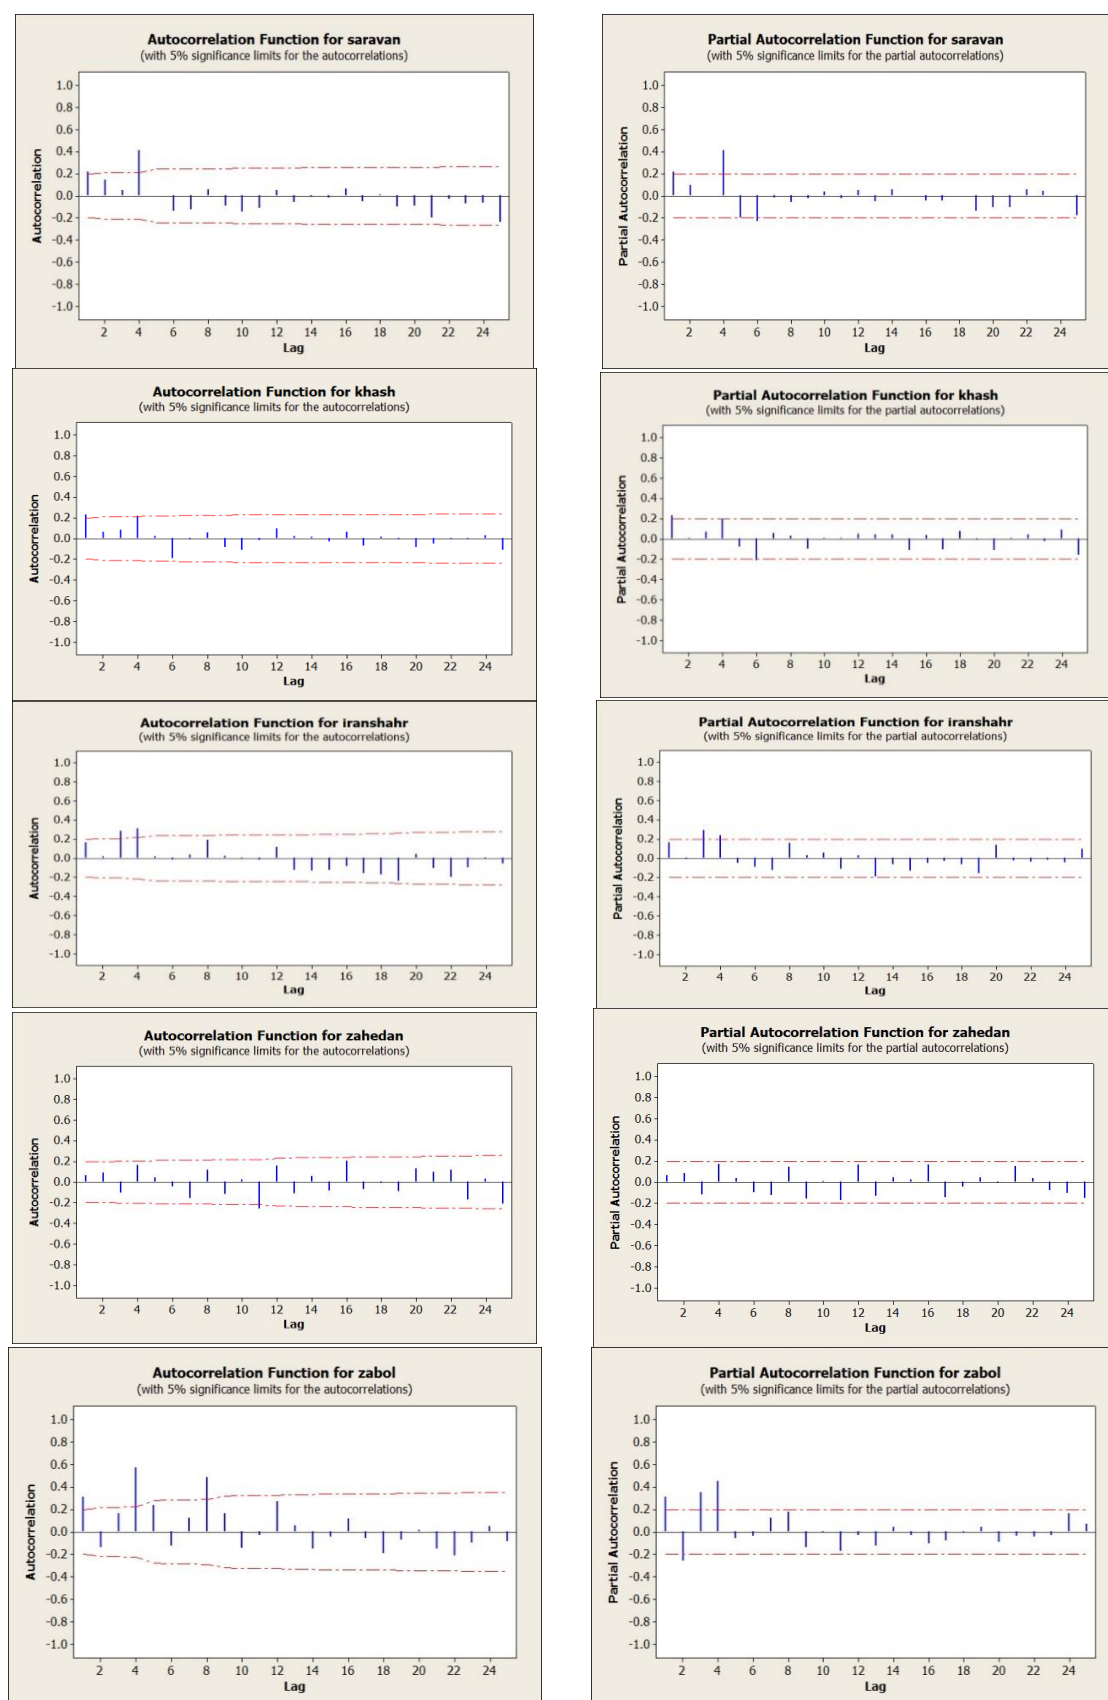
1. Correlation
2. Root Mean Square Error
3. Mean Absolute Error
4. Nash-Sutcliffe

افزایش تعداد روزهای گردوغباری در ایستگاه زابل از پراکندگی نوسانات کاسته شده و به شدت آن افزوده شده است و مقادیر اوج گردوغبار به صورت متمرکز در کنار یکدیگر مشاهده می‌شوند که حکایت از وقوع طوفان‌های گردوغبار پی‌درپی در این ایستگاه از سال ۲۰۰۰ به بعد دارد. با توجه به شکل ۵، وجود فصول متوالی عاری از طوفان‌های گردوغبار، انقطاع و داشتن یک سری زمانی منفصل، و به تبع آن تشکیل طوفان‌هایی با فاصله زمانی بیشتر نسبت به ایستگاه زابل در سال‌های ۱۹۹۳ تا ۲۰۰۱، در ایستگاه‌های سراوان، خاش، ایرانشهر، و زاهدان مشهود است. بر اساس شکل ۵، می‌توان سه دوره طولانی مدت اوج طوفان‌های گردوغبار مربوط به سال‌های ۱۹۹۳-۱۹۹۶، ۲۰۰۰-۲۰۰۴، و ۲۰۰۸-۲۰۱۲ را در ایستگاه‌های مورد مطالعه تشخیص داد. نتایج مشابهی از ویژگی‌های شاخص FSDS در مقیاس زمانی فصلی توسط زینالی (۱۳۹۵)، عراقی‌نژاد و انصاری قوجقار (۱۳۹۶)، و عراقی‌نژاد و همکاران (۱۳۹۷) ارائه شده است.



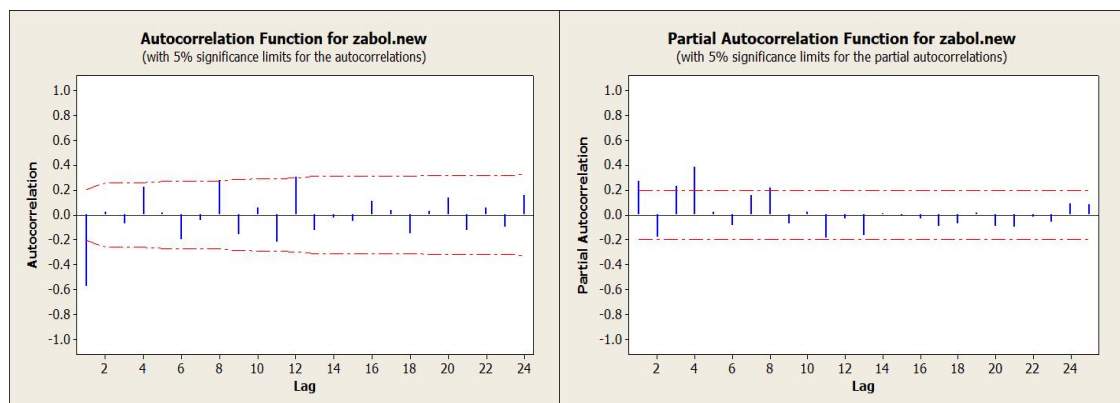
شکل ۵. سری زمانی شاخص FSDS در مقیاس زمانی فصلی برای ایستگاه‌های مورد مطالعه

اولین قدم در پیش‌بینی سری‌های زمانی، شناسایی ویژگی‌های مهمی نظیر همبستگی، الگوهای فصلی، تغییرات دوره‌ای در الگوهای فصلی، روند و ایستایی یا غیرایستایی داده‌هاست. وجود همبستگی در میان داده‌های سری زمانی، امکان اجرای مدل‌سازی و پیش‌بینی مقادیر بعدی سری زمانی را فراهم می‌کند. در این مطالعه، وجود همبستگی با رسم نمودارهای ACF و PACF برای هر ایستگاه با فاصله اطمینان ۹۵ درصد (خطوط نقطه‌چین) بررسی شد (شکل ۶). اگر مقدار همبستگی مشاهده‌شده در خارج از این محدوده واقع شود، مقدار همبستگی در سطح خطای ۵ درصد به طور معنی‌داری با صفر اختلاف دارد. همان‌طور که در نمودارهای ACF و PACF ایستگاه‌های مورد مطالعه مشاهده می‌شود، وقفه‌های زمانی معنی‌دار نشان‌دهنده وجود همبستگی بین مقادیر زمانی است که اجرای مدل‌سازی و پیش‌بینی مقادیر آینده (فصل آتی) شاخص FSDS را برای هر پنج ایستگاه مورد مطالعه ممکن می‌سازد. گام مهم در تجزیه و تحلیل سری‌های زمانی بررسی ایستایی یا غیرایستایی میانگین سری‌های زمانی است. با توجه به شکل ۶، نمودارهای ACF و PACF ایستگاه‌ها حکایت از ایستایی داده‌های همه سری‌های زمانی به غیر از ایستگاه زابل دارد.



شکل ۶. نمودار خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) شاخص FDSD در ایستگاه‌های مورد مطالعه

در داده‌های غیرفصلی و سالانه، معمولاً با یک بار تفاضل‌گیری درجه اول داده‌ها ایستا می‌شوند؛ ولی، با توجه به فصلی بودن و مقیاس داده‌ها، با تفاضل‌گیری درجه دوم ( $D=2$ ) داده‌های ایستگاه زابل ایستایی شدند که نمودار توابع خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) آن بعد از تفاضل‌گیری در شکل ۷ نشان داده شده است. با توجه به توابع خودهمبستگی و خودهمبستگی جزئی، محدوده تغییرات اتورگرسیون و میانگین متحرک تعیین و با استفاده از معیارهای ارزیابی مناسب بهترین مدل سری زمانی برای هر ایستگاه استخراج شد. همچنین، از آزمون Dickey-Fuller نیز برای تشخیص ایستایی یا نایستایی سری‌های زمانی بر روی مجموعه داده‌های آموزشی استفاده شد (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، صرفاً سری زمانی ایستگاه‌های زابل نایستاست که نتایج نمودارهای ACF و PACF ایستگاه‌های مورد مطالعه را تأیید می‌کند.



شکل ۷. نمودار خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) بعد از تفاضل‌گیری فصلی مرتبه دوم ( $D=2$ ) در ایستگاه زابل

جدول ۳. نتایج آزمون Dickey-Fuller

P-Value	ایستگاه
۰/۰۱	سراوان
۰/۰۳	خاش
۰/۰۱	ایران‌شهر
۰/۰۴	زاهدان
۰/۳۹	زابل

جدول ۴ مقادیر معیارهای ارزیابی مربوط به مرحله آزمایش روش‌های مختلف به منظور پیش‌بینی فراوانی روزهای همراه با طوفان گردوغبار را نشان می‌دهد. نتایج پیش‌بینی شاخص FDSH حاکی از عملکرد مناسب روش‌های سیستم استنباط عصبی- فازی تطبیقی (ANFIS) و شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF) در همه ایستگاه‌های مورد مطالعه (زابل، زاهدان، ایران‌شهر، خاش، و سراوان) است. بر اساس جدول ۴، در ایستگاه‌های زابل، زاهدان، و ایران‌شهر روش‌های سیستم استنباط عصبی- فازی تطبیقی (ANFIS)، شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF)، مدل‌های سری زمانی Holt-Winters، و SARIMA به ترتیب رتبه اول تا چهارم بهترین روش‌های پیش‌بینی شاخص FDSH را بر اساس معیارهای ارزیابی به خود اختصاص دادند. برخلاف ایستگاه‌های مذکور، در ایستگاه خاش بعد از روش ANFIS،

استفاده از مدل سری زمانی Holt-Winters برای پیش‌بینی شاخص FDSO عملکرد بهتری نسبت به روش RBF از خود نشان داد. به طوری که ضرایب همبستگی (R) و نش‌ساتکلیف (NS) بین مقادیر مشاهداتی فراوانی روزهای همراه با طوفان گردوغبار و مقادیر پیش‌بینی‌شده آن به ترتیب از ۰/۷۱ به ۰/۷۴ و ۰/۷۰ به ۰/۷۱ و همچنین معیارهای خطای RMSE و MAE به ترتیب از ۰/۷۰ به ۰/۶۹ و ۰/۵۶ به ۰/۵۵ بهبود یافت. همچنین، در ایستگاه سراوان نیز بعد از روش ANFIS، روش RBF و مدل سری زمانی Holt-Winters عملکرد تقریباً یکسانی از خود نشان دادند؛ به طوری که معیارهای ارزیابی R، RMSE، MAE و NS در روش RBF نسبت به روش Holt-Winters به ترتیب از ۰/۶۹، ۰/۷۱، ۰/۵۹ و ۰/۶۸ به ۰/۷۰، ۰/۷۳، ۰/۵۶ و ۰/۶۷ تغییر یافت. با توجه به اینکه معیارهای ارزیابی RMSE و NS نشان‌دهنده برتری روش RBF نسبت به مدل Holt-Winters و معیارهای ارزیابی R و MAE حکایت از برتری مدل Holt-Winters نسبت به روش RBF دارد، نمی‌توان قضاوت صحیحی از برتری هیچ یک از این دو مدل بعد از روش ANFIS در این ایستگاه داشت. علت بهبود نتایج مدل سری زمانی Holt-Winters در ایستگاه‌های خاش و سراوان را می‌توان در کاهش وقوع فراوانی روزهای همراه با طوفان گردوغبار جست‌وجو کرد؛ به طوری که این موضوع حاکی از قابلیت بالای مدل سری زمانی Holt-Winters در پیش‌بینی مقادیر کم شاخص FDSO است؛ ولی با توجه به اهمیت موضوع پیش‌بینی طوفان‌های گردوغبار در مناطق بحرانی کشور (پُر تعداد)، نمی‌توان چندان به توانایی‌های این مدل در پیش‌بینی فراوانی روزهای همراه با طوفان گردوغبار اتکا کرد. همچنین، نتایج نشان داد که مدل سری زمانی SARIMA نسبت به سایر روش‌ها قابلیت بالایی در پیش‌بینی شاخص FDSO در هیچ یک از ایستگاه‌های مورد مطالعه ندارد. نتایج این بخش با مطالعات گودرزی و روزبهرانی (۱۳۹۶)، انتظاری و سروستان (۱۳۹۶)، و سبحانی و همکاران (۱۳۹۹) مطابقت دارد.

جدول ۴. معیارهای ارزیابی محاسبه‌شده مدل‌های آماری کلاسیک سری زمانی و روش‌های هوش مصنوعی برای پیش‌بینی شاخص FDSO

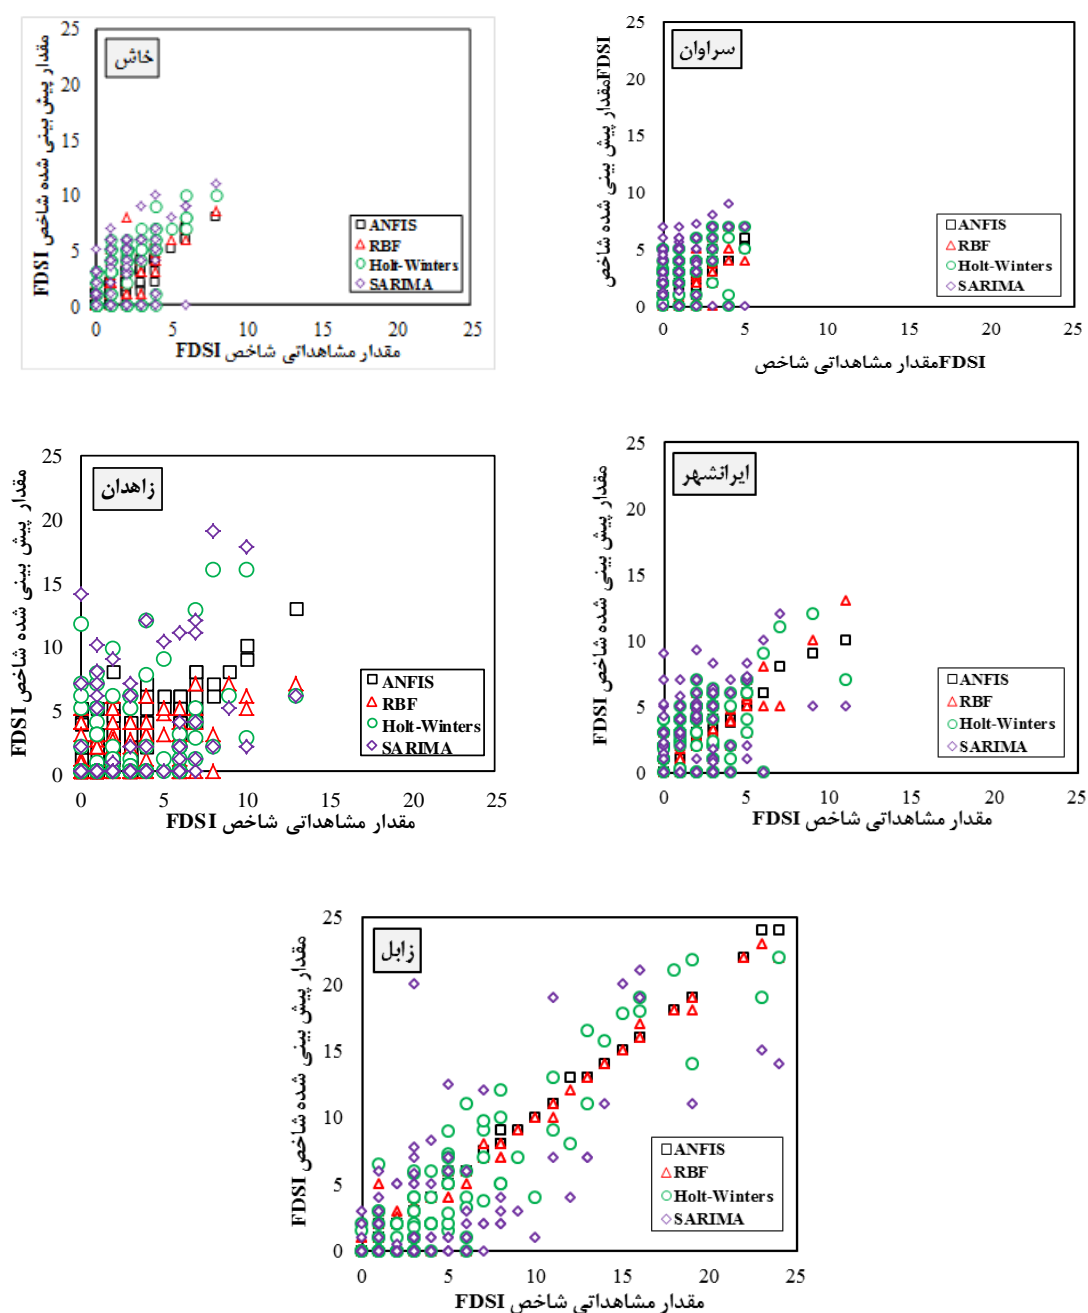
حالت	معیارهای ارزیابی	سراوان	خاش	ایرانشهر	زاهدان	زابل
SARIMA	مدل بهینه	۴	۴	۳	۴	۴
	R	۰/۶۶ (۴)	۰/۶۹ (۴)	۰/۷۰ (۴)	۰/۶۱ (۴)	۰/۷۹ (۴)
	RMSE	۰/۷۵ (۴)	۰/۷۲ (۴)	۰/۶۹ (۴)	۰/۷۹ (۴)	۰/۶۵ (۴)
	MAE	۰/۶۰ (۴)	۰/۵۷ (۴)	۰/۵۶ (۴)	۰/۵۷ (۴)	۰/۵۵ (۴)
NS	۰/۶۲ (۴)	۰/۶۵ (۴)	۰/۶۸ (۴)	۰/۶۰ (۴)	۰/۸۱ (۴)	
Holt-Winters	مدل بهینه	۳	۴	۴	۳	۴
	R	۰/۷۰ (۲)	۰/۷۴ (۲)	۰/۷۵ (۳)	۰/۶۳ (۳)	۰/۸۷ (۳)
	RMSE	۰/۷۳ (۳)	۰/۶۹ (۲)	۰/۶۷ (۳)	۰/۷۸ (۳)	۰/۶۳ (۳)
	MAE	۰/۵۶ (۲)	۰/۵۵ (۲)	۰/۵۲ (۳)	۰/۵۳ (۳)	۰/۵۱ (۳)
NS	۰/۶۷ (۳)	۰/۷۱ (۲)	۰/۷۰ (۳)	۰/۶۲ (۳)	۰/۸۵ (۳)	
RBF	مدل بهینه	۴	۴	۴	۳	۴
	R	۰/۶۹ (۳)	۰/۷۱ (۳)	۰/۷۶ (۲)	۰/۶۷ (۲)	۰/۹۲ (۲)
	RMSE	۰/۷۱ (۲)	۰/۷۰ (۳)	۰/۶۵ (۲)	۰/۷۳ (۲)	۰/۶۰ (۲)
	MAE	۰/۵۹ (۳)	۰/۵۶ (۳)	۰/۴۹ (۲)	۰/۵۰ (۲)	۰/۴۸ (۲)
NS	۰/۶۸ (۲)	۰/۷۰ (۳)	۰/۷۱ (۲)	۰/۶۵ (۲)	۰/۹۱ (۲)	
ANFIS	مدل بهینه	۴	۴	۳	۴	۳
	R	۰/۷۲ (۱)	۰/۷۶ (۱)	۰/۷۷ (۱)	۰/۷۸ (۱)	۰/۹۵ (۱)
	RMSE	۰/۵۷ (۱)	۰/۵۳ (۱)	۰/۵۲ (۱)	۰/۵۲ (۱)	۰/۵۱ (۱)
	MAE	۰/۴۲ (۱)	۰/۴۱ (۲)	۰/۴۱ (۱)	۰/۴۱ (۱)	۰/۴۰ (۱)
NS	۰/۷۱ (۱)	۰/۷۲ (۱)	۰/۷۳ (۱)	۰/۷۵ (۱)	۰/۹۶ (۱)	
متوسط روزهای همراه با طوفان گردوغبار در مقیاس فصلی						
	۱/۰۶	۱/۸۰	۲/۱۱	۳/۱۴	۷/۱۱	

با توجه به اینکه در جدول ۴ ترتیب ایستگاه‌ها به لحاظ شاخص FDS از ایستگاه سراوان تا زابل به صورت صعودی بوده و متوسط شاخص FDS در مقیاس فصلی از ۱/۰۶ تا ۷/۱۱ متغیر است، می‌توان دریافت که عملکرد همه روش‌های پیش‌بینی شاخص FDS با افزایش تعداد روزهای همراه با طوفان گردوغبار رابطه مستقیمی دارد. بدین معنی که با افزایش فراوانی روزهای همراه با طوفان گردوغبار، مقادیر همه معیارهای ارزیابی مورد استفاده بهبود می‌یابند؛ به نحوی که در روش SARIMA ضریب همبستگی بین مقادیر مشاهداتی و پیش‌بینی‌شده شاخص FDS از ۰/۶۶ به ۰/۷۹ افزایش می‌یابد. همچنین، برای روش‌های Holt-Winters، RBF و ANFIS نیز به ترتیب از ۰/۷۰ تا ۰/۸۷، ۰/۶۹ تا ۰/۹۲، و ۰/۷۲ تا ۰/۹۵ در ایستگاه‌های مورد مطالعه متغیر است. نتیجه دیگری که از جدول ۴ قابل استنتاج است عملکرد بهتر و مناسب همه روش‌های پیش‌بینی شاخص FDS بر اساس معیارهای ارزیابی در ایستگاه ایرانشهر نسبت به ایستگاه زاهدان است؛ این در حالی است که فراوانی روزهای همراه با طوفان‌های گردوغبار در ایستگاه ایرانشهر نسبت به ایستگاه زاهدان کمتر است. علت این موضوع را می‌توان در سری کامل و بدون انقطاع شاخص FDS در ایستگاه ایرانشهر نسبت به ایستگاه زاهدان جست‌وجو کرد؛ به طوری که در ایستگاه ایرانشهر تنها در دو مقطع زمانی تابستان و پاییز سال‌های ۲۰۰۵ و ۲۰۱۱ دو فصل متوالی بدون روزهای همراه با طوفان گردوغبار رخ داده است.

در جدول ۴ اعداد داخل پرانتز روبه‌روی مقادیر معیارهای ارزیابی رتبه‌بندی روش‌های مختلف پیش‌بینی فراوانی روزهای همراه با طوفان‌های گردوغبار را نشان می‌دهد. بر این مبنا، در همه ایستگاه‌های مورد مطالعه به‌منظور پیش‌بینی شاخص FDS، روش سیستم استنباط عصبی-فازی تطبیقی (ANFIS) بیشترین تعداد رتبه اول (بهترین حالت پیش‌بینی) را داشته است. با ترکیب تعداد معیارهای ارزیابی و تعداد ایستگاه‌های مورد مطالعه برای پیش‌بینی، برای هر روش ۲۰ رتبه (۴\*۵) وجود خواهد داشت. بدین ترتیب، مدل‌های سری زمانی SARIMA، Holt-Winters، و روش RBF اصلاً رتبه نخستی به خود اختصاص نداده‌اند؛ در حالی که روش ANFIS ۲۰ بار در رتبه نخست قرار گرفت. در مجموع و با این حساب، روش ANFIS با اختلاف زیادی بهتر از روش‌های دیگر پیش‌بینی بوده و بالاترین دقت پیش‌بینی را داشته است. نکته دیگری که باید به آن اشاره کرد عملکرد مناسب شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF) است. هرچند که این روش در دو ایستگاه خاش و سراوان به ترتیب عملکرد ضعیف‌تر و تقریباً یکسانی با مدل سری زمانی Holt-Winters داشت، در غیاب روش ANFIS، با ۱۴ بار قرارگیری در رتبه دوم، بهترین عملکرد را به خود اختصاص داد. همچنین، نتایج دیگری از جدول ۴ قابل برداشت است که انتخاب مدل‌های پیچیده‌تر به‌عنوان مدل بهینه پیش‌بینی‌کننده در ایستگاه‌های مورد مطالعه است؛ به نحوی که برای پیش‌بینی شاخص FDS در همه ایستگاه‌ها از مدل ۳ و ۴ (با سه و چهار گام تأخیر) استفاده شده است. با توجه به اینکه بادهای ۱۲۰ روزه عامل اصلی وقوع طوفان‌های گردوغبار در شرق و جنوب شرق کشورند، افزایش سرعت و گستره فعالیت بادهای منطقه‌ای سیستان از ۱۲۰ روز به ۱۶۵ روز و همچنین رسوب و ته‌نشین شدن این ذرات خود یک اهرم قدرتمند برای وقوع طوفان‌های بعدی بوده که در مطالعات فرج‌زاده اصل و علیزاده (۱۳۹۰)، راشکی و همکاران (۲۰۱۳)، سبحانی و همکاران (۱۳۹۴)، یارمرادی و همکاران (۱۳۹۷)، عراقی‌نژاد و همکاران (۱۳۹۷)، و قربانی و مدرس (۱۳۹۸) بدان اشاره شده است. این ذرات به‌جامانده از طوفان‌های قبلی می‌تواند دلیل مهمی برای تأثیر طوفان‌های گردوغباری چند فصل گذشته برای شکل‌گیری طوفان‌های گردوغبار در فصل آتی باشد.

شکل ۸ مقادیر مشاهداتی و پیش‌بینی شاخص FDS را برای داده‌های آزمایش نشان می‌دهد. این شکل بهبود عملکرد مدل‌های مورد استفاده به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان گردوغبار را با به‌کارگیری روش ANFIS در همه ایستگاه‌ها به‌خوبی بیان می‌کند. به طوری که در همه ایستگاه‌های سینوپتیک مورد مطالعه در استان

سیستان و بلوچستان، روش ANFIS بهترین مطابقت بین مقادیر پیش‌بینی و مشاهداتی شاخص FDSI را داراست. همان‌طور که در شکل ۸ مشخص است، ارتباط بین مقادیر مشاهداتی و پیش‌بینی‌شده از خطوط نسبتاً پراکنده و نزدیک به ۴۵ درجه (مدل‌های سری زمانی SARIMA و Holt-Winters و روش RBF) به یک خط دقیقاً ۴۵ درجه (روش ANFIS) در همه ایستگاه‌ها رسیده است. بر اساس شکل ۸، با افزایش وقوع شاخص FDSI در ایستگاه‌های مورد مطالعه (پیشروی از ایستگاه سراوان به سمت ایستگاه زابل)، ارتباط بین مقادیر مشاهداتی و پیش‌بینی‌شده در همه روش‌ها (مدل‌های سری زمانی و روش‌های هوش مصنوعی) مطابقت بیشتری با نیمساز ربع اول پیدا می‌کند.



شکل ۸. نتایج مقادیر مشاهداتی و پیش‌بینی‌شده شاخص FDSI در ایستگاه‌های مورد مطالعه



مقایسه میانگین مقادیر مشاهداتی و پیش‌بینی شده بر اساس آزمون Z (جدول ۵) نشان می‌دهد که فرض صفر مبنی بر برابری میانگین سری مقادیر مشاهداتی و پیش‌بینی شده شاخص FDSM در هیچ کدام از ایستگاه‌های مورد مطالعه بر اساس روش‌های ANFIS و RBF در سطح خطای ۱ درصد و بر اساس مدل‌های سری زمانی SARIMA و Holt-Winters در سطح خطای ۵ درصد رد نمی‌شود. بنابراین، می‌توان نتیجه گرفت که همه روش‌های استفاده شده (به‌ویژه روش‌های ANFIS و RBF) به‌منظور پیش‌بینی شاخص FDSM میانگین سری زمانی مشاهداتی را حفظ کرده‌اند (جدول ۵). این ویژگی می‌تواند تأکیدی بر کارایی روش‌های هوش مصنوعی در پیش‌بینی فراوانی روزهای همراه با طوفان گردوغبار باشد.

جدول ۵. آزمون مقایسه میانگین سری زمانی مشاهداتی و پیش‌بینی شده شاخص FDSM

ایستگاه	میانگین				آماره Z				
	مشاهداتی	SARIMA	Holt-Winters	RBF	ANFIS	RBF	Holt-Winters	SARIMA	ANFIS
سراوان	۰.۲۵۶	۰.۲۹۷	۰.۲۹۸	۰.۳۰۳	۰.۳۰۸	۰.۲۹۶	۰.۲۹۸	۰.۲۹۷	۰.۲۹۷
خاش	۰.۳۸۴	۰.۳۰۱	۰.۳۰۳	۰.۳۰۷	۰.۳۱۱	۰.۳۰۵	۰.۳۰۳	۰.۳۰۱	۰.۳۰۴
ایران‌شهر	۰.۴۱۲	۰.۴۰۲	۰.۴۵۵	۰.۴۲۳	۰.۴۹۸	۰.۴۱۵	۰.۴۱۱	۰.۴۰۲	۰.۴۲۲
زاهدان	۰.۵۰۲	۰.۴۹۸	۰.۴۵۷	۰.۴۶۰	۰.۵۳۱	۰.۴۴۱	۰.۴۳۳	۰.۴۹۸	۰.۵۰۲
زابل	۰.۹۱۱	۰.۵۱۲	۰.۶۹۸	۰.۷۷۴	۰.۷۹۳	۰.۶۱۵	۰.۵۰۱	۰.۴۹۷	۰.۷۰۵

### نتیجه‌گیری

هدف از این پژوهش 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) به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان‌های گردوغبار (FDSM) در مقیاس فصلی در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان با طول دوره آماری ۲۵ ساله (۱۹۹۰-۲۰۱۴) بود. نتایج نشان داد که در همه ایستگاه‌های مورد مطالعه روش ANFIS بهترین عملکرد را نسبت به سایر روش‌ها داشت. همچنین، با افزایش شاخص FDSM در ایستگاه‌های مورد مطالعه، دقت پیش‌بینی همه روش‌ها افزایش یافت. با این توضیح که همه روش‌ها در ایستگاه زابل، که با ۷۱۱ روز در بازه زمانی ۲۵ ساله (۱۹۹۰-۲۰۱۴) بیشترین فراوانی را به همراه داشت، بهترین عملکرد را از خود نشان دادند. غیر از ایستگاه‌های خاش و سراوان، که کمترین فراوانی روزهای همراه با طوفان گردوغبار را به ترتیب با مقادیر ۱۸۰ و ۱۰۶ روز در بازه زمانی ۲۵ ساله به خود اختصاص دادند، در دیگر ایستگاه‌های مورد مطالعه، روش‌های ANFIS، RBF، Holt-Winters و SARIMA به ترتیب رتبه اول تا چهارم را در پیش‌بینی شاخص FDSM به دست آوردند. با کاهش فراوانی روزهای همراه با طوفان گردوغبار در ایستگاه‌های سراوان و خاش، مدل سری زمانی Holt-Winters به ترتیب عملکرد تقریباً یکسان و بالاتری نسبت به روش RBF از خود نشان داد که حاکی از قابلیت بالای این مدل به‌منظور پیش‌بینی مقادیر کم شاخص FDSM بود. همچنین، نتایج بیانگر این موضوع بود که مدل سری زمانی SARIMA نسبت به سایر روش‌های پیش‌بینی قابلیت بالایی در پیش‌بینی شاخص FDSM در هیچ یک از ایستگاه‌های مورد مطالعه نداشت. همچنین، با وجود وقوع کمتر فراوانی روزهای همراه با طوفان گردوغبار در ایستگاه ایران‌شهر نسبت به ایستگاه زاهدان، همه روش‌های پیش‌بینی شاخص FDSM بر اساس معیارهای ارزیابی، عملکرد بهتر و دقیق‌تری نسبت به ایستگاه زاهدان داشتند که علت آن را می‌توان در وجود سری کامل و بدون انقطاع شاخص FDSM در ایستگاه ایران‌شهر جست‌وجو کرد؛

به طوری که در ایستگاه ایرانشهر فقط در دو مقطع زمانی تابستان و پاییز سال‌های ۲۰۰۵ و ۲۰۱۱ دو فصل متوالی عاری از روزهای همراه با طوفان گردوغبار رخ داد. از طرفی، در پیش‌بینی شاخص FDSD در استان سیستان و بلوچستان، مدل بهینه پیش‌بینی‌کننده مدل پیچیده‌ای بوده است. به صورتی که برای همه ایستگاه‌های مورد مطالعه، مدلی که از سه یا چهار گام تأخیر در پیش‌بینی استفاده کرد به‌عنوان بهترین مدل پیش‌بینی‌کننده شناخته شد. از این رو، ذرات به‌جامانده از طوفان‌های قبلی می‌تواند دلیل مهمی بر تأثیر طوفان‌های چند فصل گذشته بر شکل‌گیری طوفان‌های گردوغبار در فصل‌های آینده باشد. یعنی طوفان شکل‌گرفته‌شده در حال حاضر ممکن است به خاطر ذرات رسوب‌کرده و ته‌نشین‌شده از سه یا چهار فصل گذشته باشد که اکنون به خیزش درآمده است. همین دلیل علمی که اکنون بیان شد در دیگر مطالعات به آن اشاره نشده و حلقه مفقوده بیشتر مطالعات بوده است. ضمن اینکه این دلیل فیزیکی و عملی هم باعث سنجش صحیح عملکرد مدل‌ها در پیش‌بینی شده هم علت شکل‌گیری طوفان گردوغبار در مناطق مستعد این پدیده را آشکار کرد؛ زیرا ذرات به‌جامانده از طوفان‌های گردوغبار قبلی خود عاملی بر شکل‌گیری طوفان‌های گردوغبار فعلی و آتی هستند.

## منابع

- انتظاری، ع. و سروستان، ر. (۱۳۹۶). بررسی گردوغبار و پیش‌بینی آن در شهرهای استان خوزستان با استفاده از مدل‌های سری زمانی، مطالعات علوم محیط زیست، ۲(۴): ۵۳۵-۵۴۵.
- انصاری قوجقار، م؛ پورغلام آمیجی، م؛ بذرافشان، ج؛ لیاقت، ع. و عراقی‌نژاد، ش. (۱۳۹۹). مقایسه کارایی شبکه‌های عصبی آماری، فازی، و پرسپترون در پیش‌بینی طوفان‌های گردوغبار در نواحی بحرانی کشور، تحقیقات آب و خاک ایران (آماده انتشار).
- جمالی‌زاده تاج‌آبادی، م. ر؛ مقدم‌نیا، ع. ر. و پیری، ج. (۱۳۸۶). بررسی توانایی دو روش شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان در پیش‌بینی طوفان‌های گردوخاک شهر زابل، چهارمین همایش ملی علوم و مهندسی آبخیزداری ایران، مدیریت حوزه‌های آبخیز، دانشکده منابع طبیعی دانشگاه تهران، ۱ اسفند.
- حسین حمزه، ن؛ فتاحی، ا؛ ذوالجودی، م؛ غفاریان، پ. و رنجبر، ع. (۱۳۹۵). تحلیل همبندی و دینامیکی پدیده گردوغبار و شبیه‌سازی آن در جنوب غرب ایران در تابستان ۱۳۸۴، تحلیل فضایی مخاطرات محیطی، ۳(۱): ۹۱-۱۰۲.
- زینالی، ب. (۱۳۹۵). بررسی روند تغییرات فراوانی روزهای همراه با طوفان‌های گردوغباری نیمه غربی ایران، مخاطرات محیط طبیعی، ۵(۷): ۸۷-۱۰۰.
- سبحانی، ب؛ صفریان زنگیر، و. و فیض‌الله‌زاده، س. (۱۳۹۹). مدل‌سازی و پیش‌بینی گردوغبار در غرب ایران، پژوهش‌های جغرافیای طبیعی، ۵۲(۱): ۱۷-۳۵.
- سبحانی، ب؛ صلاحی، ب. و گل‌دوست، ا. (۱۳۹۴). بررسی گردوغبار و ارزیابی امکان پیش‌بینی آن بر اساس روش‌های آماری و مدل ANFIS در ایستگاه زابل، جغرافیا و توسعه پایدار، ۱۳(۳۸): ۱۲۳-۱۳۸.
- سروستان، ر. و فلاح‌قاله‌ری، غ. (۱۳۹۹). بررسی و پیش‌بینی پدیده گردوغبار در استان خوزستان با استفاده از مدل‌های سری زمانی باکس جنکینز، مهندسی و مدیریت آبخیز.
- شاکر سوره، ف. و اسدی، ا. (۱۳۹۸). ارتباط بین خشک‌سالی‌های هواشناسی و هیدرولوژیکی در دشت سلماس، مهندسی اکوسیستم بیابان، ۸(۲۲): ۸۹-۱۰۰.
- عبدالله‌نژاد، م؛ خسروی، ح؛ نظری سامانی، ع. ک؛ زهتابیان، غ. و علم‌بیگی، ا. (۱۳۹۹). تعیین چهارچوب مفهومی ریسک گردوغبار بر مبنای سنجش تاب‌آوری (بررسی موردی: جنوب غرب کشور)، پژوهش‌های راهبردی در علوم کشاورزی و منابع طبیعی، ۵(۱): ۳۳-۴۴.
- عراقی‌نژاد، ش. و انصاری قوجقار، م. (۱۳۹۶). بررسی تأثیر سرعت بیشینه باد بر روند فراوانی روزهای همراه با طوفان‌های گردوغباری (مطالعه موردی: استان لرستان)، چهارمین همایش ملی فرسایش بادی و طوفان‌های گردوغبار، انجمن علمی مدیریت و کنترل مناطق بیابانی ایران، پژوهشکده مناطق خشک و بیابانی، دانشگاه یزد، ۱۶-۱۷ اسفند.
- عراقی‌نژاد، ش؛ انصاری قوجقار، م؛ پورغلام آمیجی، م؛ لیاقت، ع. و بذرافشان، ج. (۱۳۹۷). تأثیر نوسانات اقلیمی بر فراوانی طوفان‌های گردوغبار در ایران، مهندسی اکوسیستم بیابان، ۷(۲۱): ۱۳-۳۲.
- فرج‌زاده، م. و علیزاده، خ. (۱۳۹۰). تحلیل زمانی و مکانی طوفان‌های گردوخاک در ایران، برنامه‌ریزی و آمایش فضا، ۱۵(۱): ۶۵-۸۴.
- قربانی، س. و مدرس، ر. (۱۳۹۸). مدل‌سازی رابطه فراوانی طوفان‌های گردوغبار با متغیرهای اقلیمی فصل تابستان در مناطق بیابانی ایران، علوم آب و خاک، ۲۳(۳): ۱۲۵-۱۴۰.

- گودرزی، ل. و روزبهانی، ع. (۱۳۹۶). بررسی کارایی مدل‌های سری زمانی آرپما و هالت-وینترز در پیش‌بینی دما و بارش ماهانه (مطالعه موردی: ایستگاه لتیان)، علوم و مهندسی آبیاری، ۴۰(۳): ۱۳۷-۱۴۹.
- مهرابی، ش؛ سلطانی، س. و جعفری، ر. (۱۳۹۴). بررسی رابطه بین پارامترهای اقلیمی و وقوع ریزگردها (مطالعه موردی: استان خوزستان)، علوم آب و خاک، ۱۹(۷۱): ۶۹-۸۰.
- یارمرادی، ز؛ نصیری، ب؛ کرم‌پور م. و محمی، غ. ح. (۱۳۹۷). تحلیل روند فراوانی روزهای گردوغباری در نیمه شرقی ایران در ارتباط با نوسانات اقلیمی، مهندسی اکوسیستم بیابان، ۷(۱۸): ۱-۱۴.
- Aboagye-Sarfo, P.; Mai, Q.; Sanfilippo, F. M.; Preen, D. B.; Stewart, L. M. and Fatovich, D. M. (2015). A comparison of multivariate and univariate time series approaches to modelling and forecasting emergency department demand in Western Australia. *Journal of biomedical informatics*, 57: 62-73.
- Ahmed, N. K.; Atiya, A. F.; Gayar, N. E. and El-Shishiny, H. (2010). An empirical comparison of machine learning models for time series forecasting. *Econometric Reviews*, 29(5-6): 594-621.
- Aigang, L.; Tianming, W.; Shichang, K. and Deqian, P. (2009). On the relationship between global warming and dust storm variation in China. In 2009 International Conference on Environmental Science and Information Application Technology (Vol. 2, pp. 59-62). IEEE.
- Aliyari, M.; Teshnehlab, M. and Khaki Sedigh, A. (2008). Short-term forecast of air pollution by neural networks, delayed memory line, gamma and ANFIS with PSO-based educational methods. *Control journal*, 2(1): 1-19.
- Amgalan, G.; Liu, G. R.; Lin, T. H. and Kuo, T. H. (2017). Correlation between dust events in Mongolia and surface wind and precipitation, *Terr. Journal of Atmospheric & Ocean Science*, 28 (1): 23-32.
- 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.
- 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.
- Cochrane, J. H. (2005). Time series for macroeconomics and finance. *Manuscript, University of Chicago*, 1-136.
- Goudie, A. (2014). Review Desert dust and human health disorders. *Journal of Environment International*, 63(3): 101-113.
- Goudie, A. S. and Middleton, N. J. (2006). Desert dust in the global system. Springer Science & Business Media.
- Hahnenberger, M. and Nicoll, K. (2014). Geomorphic and land cover identification of dust sources in the eastern Great Basin of Utah, USA. *Geomorphology*, 204: 657-672.
- Herweijer, C.; Seager, R.; Cook, E. R. and Emile-Geay, J. (2007). North American droughts of the last millennium from a gridded network of tree-ring data. *Journal of Climate*, 20(7): 1353-1376.
- Hyndman, R. J. and Khandakar, Y. (2008). Automatic time series forecasting: the forecast package for R. *Journal of Statistical Software*, 27(3): 1-22.
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3): 665-685.

- 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.
- Rashki, A.; Kaskaoutis, D. G.; Goudie, A. S. and Kahn, R. A. (2013). Dryness of ephemeral lakes and consequences for dust activity: the case of the Hamoun drainage basin, southeastern Iran. *Science of the Total Environment*, 463: 552-564.
- Singh, A. and Mishra, G. C. (2015). Application of Box-Jenkins method and Artificial Neural Network procedure for time series forecasting of prices. *Statistics in Transition new series*, 1(16): 83-96.
- Tanarhte, M.; Hadjinicolaou, P. and Lelieveld, J. (2012). Intercomparison of temperature and precipitation data sets based on observations in the Mediterranean and the Middle East. *Journal of Geophysical Research: Atmospheres*, 117(D12).
- Xu, X.; Levy, J. K.; Zhaohui, L. and Hong, C. (2006). An investigation of sand-dust storm events and land surface characteristics in China using NOAA NDVI data. *Global and Planetary Change*, 52 (1-4): 182-196.