

## بررسی عملکرد مدل هیبریدی ماشین بردار پشتیبان - موجک در پیش‌بینی توفان‌های گردوغبار (مطالعه موردی: استان سیستان و بلوچستان)

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، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی،  
دانشگاه تهران، کرج، ایران

شهاب عراقی‌نژاد

دانشیار گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی،  
دانشگاه تهران، کرج، ایران

احسان پارسی

کارشناس مطالعات، شرکت مهندسی مشاور آب و انرژی اروند، اهواز، ایران

شکور سلطانی

کارشناس آب وزارت نیرو، تهران، ایران

تاریخ دریافت ۱۳۹۹/۸/۱۰ تاریخ پذیرش ۱۳۹۹/۱۱/۱

### چکیده

به منظور کنترل و مدیریت صحیح توفان‌های گردوغبار، آگاهی از تغییرات زمانی این پدیده و لزوم پیش‌بینی و مدل‌سازی آن ضروری است. در این پژوهش به منظور پیش‌بینی متغیر فراوانی روزهای همراه با توفان گردوغبار (FDS) نتایج دو روش هیبریدی با نام ماشین بردار پشتیبان - موجک (W-SVM) و ماشین بردار پشتیبان - الگوریتم گیاهان مصنوعی (AF-SVM) به همراه مدل انفرادی ماشین بردار پشتیبان (SVM)، مقایسه شد. بدین منظور از داده‌های ساعتی گردوغبار و کدهای سازمان جهانی هواشناسی در مقیاس فصلی با طول دوره آماری چهل‌ساله (۲۰۱۸-۱۹۸۰) در پنج ایستگاه سینوپتیک منتخب استان سیستان و بلوچستان استفاده شد. معیارهای ضریب تبیین، ریشه میانگین مربعات خطا، میانگین قدرمطلق خطا و ضریب نش‌ساختکیف برای ارزیابی و مقایسه مدل‌ها، استفاده شد. نتایج در مرحله آموزش و آزمایش نشان داد که ساختارهای ترکیبی استفاده‌شده، نتایج قابل قبولی در مدل‌سازی شاخص FDS ارائه می‌کنند. مدل هیبریدی ماشین بردار پشتیبان - موجک با ضریب همبستگی  $(R^2=0.911-0.984)$ ، ریشه میانگین مربعات خطا  $(RMSE=0.397-0.314 \text{ day})$ ، میانگین قدرمطلق خطا  $(MAE=0.236-0.335)$  و ضریب نش‌ساختکیف  $(NS=0.924-0.965)$ ، عملکرد بهتری نسبت به دیگر مدل‌های استفاده‌شده در پیش‌بینی شاخص FDS داشته است. نتایج این تحقیق می‌تواند در مدیریت پیامدهای ناشی از توفان‌های گردوغبار و برنامه‌های مقابله با بیابان‌زایی در مناطق تحت مطالعه مؤثر واقع شود.

**واژه‌های کلیدی:** الگوریتم گیاهان مصنوعی، پیش‌بینی، سیستان و بلوچستان، ماشین بردار پشتیبان.

## مقدمه

توفان گردوغبار از مخاطرات طبیعی و انسانی است که هر ساله در حدود ۲۰۰۰ میلیون تن خاک به اتمسفر وارد می‌کند که ۷۵ درصد آن در خشکی و ۲۵ درصد آن در اقیانوس ترسیب می‌شود [۲۶]. حدود ۲۵ درصد از مساحت ایران به دلیل قرار گرفتن روی کمربند خشک و بیابانی جهان، تحت سیطره توفان‌های گردوغباری است [۱۶]. مهم‌ترین منابع گردوغباری وارد شده به غرب کشور، صحرای سوریه، صحرای نفوذ در شمال شبه جزیره عربستان و بیابان‌های جنوب عراق هستند و نقش صحرای بزرگ آفریقا در این میان بسیار ناچیز است. نتایج بررسی‌ها حاکی از آن است که منشأ اصلی ایجاد توفان‌های گردوغبار سال‌های اخیر در جنوب غرب و غرب کشور، خارجی و قسمت‌هایی از سرزمین‌های عراق، سوریه و عربستان است [۱۴، ۱۸]. در جنوب شرق ایران نیز مهم‌ترین منبع تغذیه مواد معلق توفان‌ها، بستر خشک هامون است. اقلیم دشت سیستان دارای ویژگی‌هایی همچون زیاد بودن درجه حرارت طی دوره وزش بادهای ۱۲۰ روزه، قطع منابع بارش و خشکی فیزیکی محیط است. این عوامل موجب مهیا شدن شرایط جوی مناسب برای وزش بادهای می‌شود و با وجود کاهش رطوبت خاک، امکان تغذیه توفان‌های گردوغباری را فراهم می‌سازد. همچنین اختلاف فشار هوا بین افغانستان و دشت سیستان و وجود مراکز پرفشار در سبیری از عوامل پیدایش و تشدید بادهای گردوغباری در دشت سیستان است [۲۱].

دامنه وسیعی از مدل‌ها شامل مدل‌های عددی مبتنی بر فیزیک مسئله و فرامدل‌های هوشمند (جعبه سیاه) و ترکیب آنها با الگوریتم‌های بهینه‌سازی (به‌ویژه نوع فراکوشی)، کاربرد زیادی در علوم هیدرولوژی و هیدروژئولوژی دارند. به همین دلیل در سال‌های اخیر بهره‌گیری از ترکیب فرامدل‌ها با الگوریتم‌های بهینه‌سازی به‌منظور پیش‌بینی متغیرهای هیدرولوژیکی و هواشناسی افزایش یافته است که در ادامه به برخی از این پژوهش‌ها اشاره می‌شود. در پژوهشی کارایی روش‌های هیبریدی ژنتیک-تبرید (GA-SA<sup>۱</sup>) و الگوریتم ژنتیک به‌منظور انتخاب متغیرهای ورودی بهینه در پیش‌بینی فراوانی روزهای همراه با توفان گردوغبار استان خوزستان بررسی شد. نتایج این تحقیق نشان داد که روش هیبریدی ژنتیک-تبرید (GA-SA) در بین همه حالت‌های انتخاب متغیرهای ورودی، بهترین عملکرد را دارد؛ به طوری که در این حالت معیارهای ارزیابی R، MAE<sup>۲</sup> و RMSE به ترتیب از ۰/۲۹ تا ۰/۹۱ و ۰/۴۴ تا ۰/۹۹ و ۰/۱۳ تا ۰/۱۷ در ایستگاه‌های تحت بررسی متغیر بود. همچنین با افزایش شاخص فراوانی روزهای همراه با توفان

1. Genetic Annealing Algorithm  
2. Mean Absolute Error

گردوغبار در ایستگاه‌های بررسی‌شده، دقت پیش‌بینی همه حالت‌ها افزایش داشت [۱۵]. در پژوهشی دیگر برای تخمین جریان روزانه رودخانه خیاوچای، از مدل‌های شبکه‌های عصبی مصنوعی، هیبرید موجک-عصبی، برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان استفاده شد. نتایج این تحقیق نشان داد که مدل هیبرید موجک-عصبی با بیشترین ضریب همبستگی ( $R=0/877$ )، کمترین ریشه میانگین مربعات خطا ( $RMSE=0/696$ )، و ضریب نش ساتکلیف برابر  $0/767$  در مرحله صحت‌سنجی، نسبت به دیگر مدل‌های به‌کاررفته برتری دارد [۸]. بررسی عملکرد مدل‌های هیبریدی شبکه عصبی مصنوعی و ماشین بردار پشتیبان در تخمین دبی رودخانه زرنه رود نشان داد که مدل هیبریدی شبکه عصبی مصنوعی دقت بیشتری از ماشین بردار پشتیبان دارد [۱۷]. در پژوهشی بارندگی درازمدت شهر انزلی در یک دوره زمانی ۶۷ ساله توسط مدل عددی موجک-سیستم استنباط فازی عصبی تطبیقی ( $W-ANFIS^1$ ) ارزیابی شد. نتایج این پژوهش نشان داد که مدل  $W-ANFIS$  با مقادیر ضریب همبستگی، شاخص پراکندگی و نش ساتکلیف به ترتیب مساوی با  $0/962$ ،  $0/258$  و  $0/899$  توانایی خوبی در شبیه‌سازی پدیده بارندگی دارد [۲]. نتایج استفاده از روش هیبریدی ماشین بردار پشتیبان-الگوریتم گیاهان مصنوعی برای برآورد دبی رودخانه‌های حوضه آبریز دز نشان داد که ساختار ترکیبی استفاده‌شده با ضریب همبستگی ( $0/985$ ) -  $0/933$ ،  $R=0/933$ ، ریشه میانگین مربعات خطا ( $RMSE=0/008-0/088$ )، و ضریب نش ساتکلیف برابر ( $NS=0/951-0/995$ ) نتایج قابل قبولی در مدل‌سازی دبی رودخانه ارائه می‌کند [۳]. با مقایسه مدل ترکیبی موجک-برنامه‌ریزی بیان ژن و رویکرد منفرد آن در پیش‌بینی جریان روزانه رودخانه خشک‌رود واقع در استان گیلان روشن شد که رویکرد ترکیبی موجک-برنامه‌ریزی بیان ژن در ترکیب با پارامترهای هواشناسی، می‌تواند با کارایی زیادی در پیش‌بینی جریان به‌کار رود [۱]. در پژوهشی جریان ماهانه رودخانه ایستگاه هواکسی<sup>۲</sup> چین با استفاده از ماشین بردار پشتیبان پیش‌بینی شد و نتایج نشان داد که مدل ماشین بردار پشتیبان دقت زیادی در پیش‌بینی جریان ماهانه رودخانه دارد [۲۰]. مدل هیبریدی ماشین بردار پشتیبان-موجک برای پیش‌بینی جریان روزانه رودخانه سوریس<sup>۳</sup> واقع در شمال ایالات متحده بررسی شد و نتایج نشان داد که مدل هیبریدی ماشین بردار پشتیبان-موجک کارایی و دقت مناسبی در پیش‌بینی جریان روزانه رودخانه از خود نشان داده است [۱۰].

با توجه به اهمیت توفان‌های گردوغبار در غرب و جنوب غرب کشور، نیاز به تحقیقات جامع

1. Wavelet- Adaptive Network Based Fuzzy Inference System  
 2. Huaxian  
 3. Souris

در این زمینه بسیار محسوس است. از این رو با توجه به اینکه این پدیده اثرهای مخرب و پیامدهای نامطلوب در زمینه‌های اجتماعی، اقتصادی و سلامت مردم داشته است، مطالعات و پیش‌بینی آن ضروری است. در مجموع با توجه به پژوهش‌های صورت‌گرفته (که به برخی از آنها در بالا اشاره شده است)، قابلیت فرامدل‌ها و نوع ترکیبی آنها در پیش‌بینی زمانی-مکانی متغیرهای هیدرولوژیکی روشن شده و به اثبات رسیده است؛ این در حالی است که تحقیقات بسیار محدودی به منظور پیش‌بینی شاخص<sup>۱</sup> FDSD با استفاده از ترکیب فرامدل‌های هوشمند صورت گرفته است. حال سؤال اساسی اینجاست که با توجه به ساختار هر یک از این دسته مدل‌ها و الزامات و شرایط مورد نیاز از داده‌های اولیه، ترکیب فرامدل ماشین بردار پشتیبان<sup>۲</sup> (SVM) با الگوریتم‌های بهینه‌سازی هوشمند که توسعه هرروزه آنها را شاهدیم، تا چه اندازه می‌تواند کارایی این فرامدل را در پیش‌بینی شاخص FDSD، بهبود دهند؟ برای پاسخ به این پرسش، در این پژوهش فرامدل SVM و نوع ترکیبی آن با الگوریتم‌های گیاهان مصنوعی<sup>۳</sup> (AF) و موجک<sup>۴</sup> (W) به منظور پیش‌بینی شاخص FDSD در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان ارزیابی خواهد شد. از این رو این پژوهش می‌تواند رویکردی جدید در نحوه استفاده از روش‌های هیبریدی هوشمند به منظور پیش‌بینی شاخص FDSD در منطقه تحت بررسی باشد.

## مواد و روش‌ها

### منطقه تحقیق و روش‌ها

منطقه و موقعیت جغرافیایی ایستگاه‌های بررسی شده در استان سیستان و بلوچستان در شکل ۱ نشان داده شده است. در این پژوهش دو روش هیبریدی با نام ماشین بردار پشتیبان-موجک (W-SVM) و ماشین بردار پشتیبان-الگوریتم گیاهان مصنوعی (AF-SVM) به همراه مدل انفرادی ماشین بردار پشتیبان (SVM) به منظور پیش‌بینی فراوانی روزهای همراه با توفان گردوغبار (FDSD) در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان (زابل، زاهدان، ایرانشهر، خاش و سراوان) با جامعه آماری بلندمدت چهل‌ساله (۲۰۱۹-۱۹۸۰) در مقیاس فصلی مقایسه شدند. بدین منظور از داده‌های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی<sup>۵</sup> (WMO) استفاده شد. مشاهدات پدیده‌های هواشناسی به فاصله سه ساعت یک‌بار

1. Frequency of Days With Dust Storm
2. Support Vector Machines
3. Artificial Flora
4. Wavelet
5. World Meteorological Organization

و در مجموع هشت بار در شبانه‌روز ثبت می‌شود. در این مشاهدات، پدیده‌های بصری آب‌وهوا براساس 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 [۲۲]. کدهای مربوط به توفان‌های گردوغبار در جدول ۱ ارائه شده است. با توجه به اینکه داده‌های گردوغبار به‌صورت تفکیک‌نشده از دیگر پدیده‌های هواشناسی از سازمان هواشناسی در اختیار قرار می‌گیرد، در وهله اول کدهای مربوط به گردوغبار از دیگر پدیده‌های اقلیمی در ساعات مختلف همدیدی جدا شد [۱۶]. براساس تعریف سازمان جهانی هواشناسی روزهای همراه با توفان‌های گردوغبار به روزی گفته می‌شود که دست‌کم در یکی از هشت سینوپ (گزارش‌های سه‌ساعته دیدبانی)، 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 [۱۶]. در این مطالعه برای تشخیص توفان‌های 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 [۲۱].

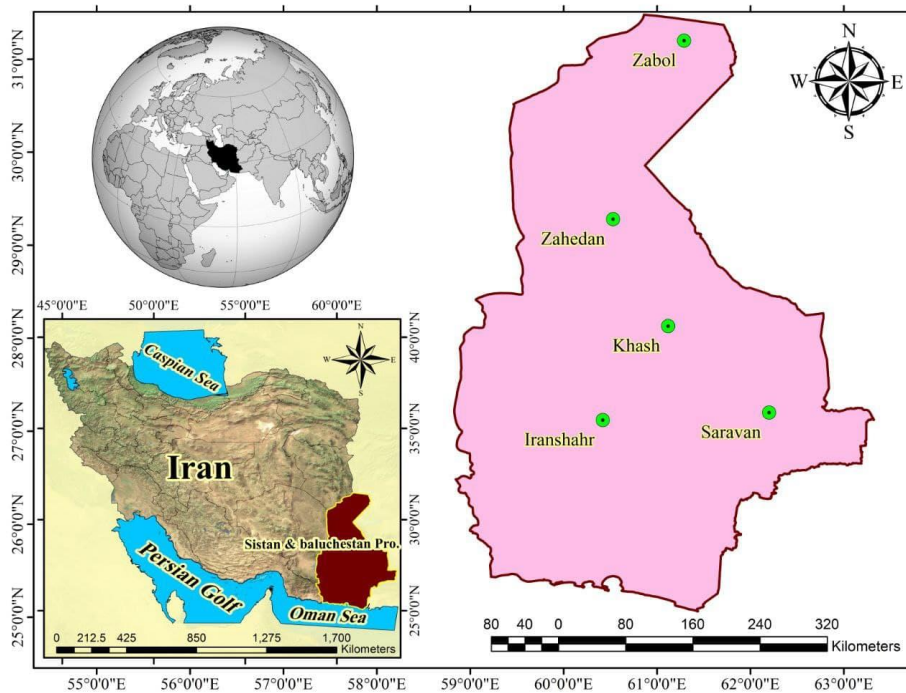
کد	توضیحات
۰۶	مه ناشی از گردوغبار
۰۷	غبار یا شن برخاسته از زمین
۰۸	توفان گردوغبار
۰۹	توفان گردوغبار اتفاق افتاده در گذشته (اتفاق افتاده در یک ساعت قبل از مشاهده یا در ایستگاه)
۳۰	گردوغبار خفیف یا متوسط شن و ماسه همراه با کاهش میدان دید کمتر از ۱۰۰۰ متر اما بیشتر از ۲۰۰ متر
۳۱	گردوغبار پایدار یا متوسط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

بعد از انتخاب ایستگاه‌ها و بررسی داده‌ها در دوره زمانی چهل‌ساله (۲۰۱۹-۱۹۸۰)، تعداد روزهای همراه با توفان گردوغبار (FDSD) برای پنج ایستگاه هواشناسی 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 FDS در مقیاس فصلی و تعداد روزهای گردوغباری به ترتیب صعودی قابل مشاهده است.

جدول ۲. فراوانی روزهای همراه با توفان‌های گردوغبار استان سیستان و بلوچستان (۲۰۱۹-۱۹۸۰)

ایستگاه	عرض جغرافیایی (درجه)	طول جغرافیایی (درجه)	ارتفاع از سطح دریا (متر)	میانگین فصلی FDS (روز)	مجموع FDS (روز)
سراوان	۲۷/۲۰	۶۲/۲۰	۱۱۹۵	۱/۳۸	۲۲۱
خاش	۲۸/۱۳	۶۱/۱۲	۱۳۹۴	۲/۲۵	۳۶۰
ایران‌شهر	۲۷/۱۲	۶۰/۴۲	۵۹۱	۲/۶۸	۴۲۹
زاهدان	۲۹/۲۸	۶۰/۵۳	۱۳۷۰	۳/۵۱	۵۶۲
زابل	۳۱/۲۰	۶۱/۲۹	۴۸۹	۷/۳۴	۱۱۷۵



شکل ۱. معرفی ایستگاه‌های بررسی شده در پژوهش حاضر

### ماشین بردار پشتیبان

ماشین بردار پشتیبان، نوعی سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده می‌کند و به یک جواب بهینه کلی می‌رسد [۲۷]. در مدل رگرسیون SVM تابعی مرتبط با متغیر وابسته  $Y$  که خود تابعی از چند متغیر مستقل  $x$  است، برآورد می‌شود. مشابه دیگر مسائل رگرسیونی فرض می‌شود که رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند  $f(x)$  به علاوه مقداری اغتشاش (خطای مجاز  $(\varepsilon)$ ) مشخص شود [۲۷، ۴].

$$f(x) = W^T \cdot \phi(x) + b \quad (1)$$

$$y = f(x) + noise \quad (2)$$

چنانچه  $W^T$  ترانهاده بردار ضرایب و  $b$  ثابت مشخصه‌های تابع رگرسیونی و  $\phi$  نیز تابع کرنل باشد، هدف یافتن فرم تابعی برای  $f(x)$  است. این مهم با آموزش مدل SVM توسط مجموعه‌ای از داده‌ها (مجموعه آموزش) محقق می‌شود [۲۱، ۴]. برای محاسبه  $W$  و  $b$  باید تابع خطا (معادله ۳) در مدل  $\varepsilon$ -SVM با در نظر گرفتن شرایط مندرج (قیود) در معادله‌های ۴ و ۵ کمینه شود [۲۳، ۴].

$$\frac{1}{2} W^T \cdot W + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* \quad (3)$$

$$W^T \cdot \phi(X_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad (4)$$

$$y_i - W^T \cdot \phi(X_i) - b \leq \varepsilon + \varepsilon_i, \varepsilon_i^* \geq 0, i = 1, 2, \dots, N \quad (5)$$

در معادلات بالا  $C$  عددی صحیح و مثبت است، که عامل تعیین جریمه در هنگام رخ دادن خطای آموزش مدل است.  $\phi$  تابع کرنل،  $N$  تعداد نمونه‌ها و دو مشخصه  $\varepsilon_i$  و  $\varepsilon_i^*$  متغیرهای کمبود هستند. در نهایت تابع SVM رگرسیونی را می‌توان به فرم زیر بازنویسی کرد [۴]:

$$f(x) = \sum_{i=1}^N \overline{\alpha}_i \phi(x_i)^T \cdot \phi(x) + b \quad (6)$$

در معادله ۶،  $\overline{\alpha}_i$  میانگین ضرایب لاگرانژ است. محاسبه  $\phi(x)$  در فضای مشخصه آن ممکن است بسیار پیچیده باشد [۳۱]. برای حل این مشکل روند معمول در مدل SVM رگرسیونی انتخاب یک تابع کرنل به صورت رابطه زیر است [۴]:

$$K(X_j, X) = \phi(X_i)^T \sqrt{b^2 - 4ac} \quad (7)$$

می‌توان از توابع مختلف کرنل برای ساخت انواع مختلف  $\epsilon$ -SVM استفاده کرد. انواع توابع کرنل قابل استفاده در مدل SVM رگرسیونی عبارت‌اند از: کرنل چندجمله‌ای<sup>۱</sup> و کرنل توابع پایه شعاعی<sup>۲</sup> (RBF) و کرنل خطی، به ترتیب براساس رابطه‌های ۸ تا ۱۰ محاسبه می‌شوند. با توجه به اینکه کرنل پایه شعاعی، خطی و چندجمله‌ای از پرکاربردترین توابع کرنل هستند [۲۷، ۱۱]، در این پژوهش از این سه تابع کرنل استفاده شد که کرنل توابع پایه شعاعی عملکردی بهتر از دیگر کرنل‌ها داشت. شایان ذکر است که فرایند محاسبات ماشین بردار پشتیبان براساس کدنویسی در محیط R انجام گرفت و پارامترهای توابع کرنل از طریق سعی و خطا بهینه شدند [۴].

$$K(x, x_j) = (t + x_i \times x_j)^d \quad (8)$$

$$K(x, x_j) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (9)$$

$$K(x, x_j) = x_i \times x_j \quad (10)$$

### الگوریتم گیاهان مصنوعی

#### - مبانی بیولوژیکی

گیاهان از دو روش خودگشنی<sup>۳</sup> و دگرگشنی<sup>۴</sup> برای پخش دانه‌های خود استفاده می‌کنند. در روش خودگشنی، گیاهان دانه‌ها را خودشان پخش می‌کنند و در دگرگشنی آنها را با استفاده از نیروهای خارجی انتشار می‌دهند. خودگشنی، شرایط مهاجرت مستقل گیاهان به محیط مناسب‌تر را فراهم می‌کند [۱۳، ۳]. از طرف دیگر، دگربرافشانی شرایط مهاجرت گیاهان به مناطق دورتر و نامعلوم را فراهم می‌کند. این روش‌های پخش دانه دامنه جست‌وجوی فلور را گسترش داده و احتمال انقراض آن را کاهش می‌دهد [۱۳، ۳].

#### - نظریه الگوریتم گیاهان مصنوعی<sup>۵</sup>

الگوریتم گیاهان مصنوعی از چهار عنصر اساسی تشکیل شده است: گیاه اصلی، گیاه فرزند، موقعیت

1. Polynomial
2. Radial Basis Functions (RBF)
3. Self-pollinated
4. Cross pollination
5. Artificial Flora



گیاه و فاصلهٔ پخش. گیاهان اصلی به گیاهانی گفته می‌شود که آمادهٔ پخش دانه هستند. گیاهان فرزند دانهٔ گیاهان اصلی هستند و در آن لحظه نمی‌توانند دانه پخش کنند. موقعیت گیاه همان محل استقرار گیاه است. منظور از فاصلهٔ پخش هم میزان فاصلهٔ انتشار دانه است. در این الگوریتم سه الگوی اصلی رفتاری وجود دارد: رفتار تکامل، رفتار پخش و رفتار انتخاب [۲۹، ۲۵، ۲۳]، رفتار تکامل به معنای احتمال تکامل گیاه برای سازگاری با رفتارهای محیطی است [۳۰، ۱۹، ۱۲]. رفتار پخش به حرکت دانه‌ها اشاره دارد. این دانه‌ها می‌توانند از طریق خودگشایی یا دیگرگشایی حرکت کنند. رفتار انتخاب نیز به معنای بقا یا انقراض گیاه به دلایل زیست‌محیطی است [۱۳، ۳].

#### - رفتار تکامل

گیاه اصلی دانه‌ها را در دایره‌ای با شعاعی برابر فاصلهٔ پخش پراکنده می‌کند. این فاصله پخش از فاصلهٔ پخش گیاه مادر [والدین] و گیاه مادربزرگ [جد] به دست می‌آید [۳].

$$d_j = d_{1j} \times \text{rand}(0,1) \times C_1 + d_{2j} \times \text{rand}(0,1) \times C_2 \quad (11)$$

$d_{1j}$  فاصلهٔ پخش گیاه مادر بزرگ،  $d_{2j}$  فاصلهٔ پخش گیاه مادر،  $C_1$  و  $C_2$  ضرایب یادگیری هستند.  $\text{rand}(0,1)$  عددی با توزیع یکنواخت مستقل در بازهٔ (0,1) است. فاصلهٔ پخش مادربزرگ جدید برابر است با [۳]:

$$d'_{1j} = d_{2j} \quad (12)$$

فاصلهٔ پخش والدین جدید، انحراف معیار بین موقعیت گیاه اصلی و موقعیت گیاه فرزند است [۳].

$$d'_{2j} = \sqrt{\frac{\sum_{i=1}^N (P_{i,j} - P'_{i,j})}{N}} \quad (13)$$

#### - رفتار پخش

ابتدا، الگوریتم فلور مصنوعی به طور تصادفی فلور اصلی را با  $N$  جواب تولید می‌کند، یعنی  $N$  گیاه در فلور وجود دارد. موقعیت گیاهان اصلی توسط ماتریس  $P_{i,j}$  بیان می‌شود که در آن  $i$  بُعد و  $j$  تعداد گیاهان فلور است [۳]:

$$P_{i,j} = \text{rand}(0,1) \times d \times 2 - d \quad (14)$$

$d$  بیشترین حد منطقه و  $\text{rand}(0,1)$  مجموعه‌ای از اعداد تصادفی است که به طور یکنواخت بین (0,1) توزیع شده‌اند. موقعیت گیاه فرزند با توجه به تابع پخش و به شرح زیر تولید می‌شود [۳]:

$$P'_{i,j \times m} = D_{i,j \times m} + P_{i,j} \quad (15)$$

که در آن  $m$  تعداد دانه‌هایی است که یک گیاه می‌تواند پخش کند،  $P'_{i,j}$  موقعیت گیاهان فرزند،  $P_{i,j}$  موقعیت گیاه اصلی و  $D_{i,j \times m}$  یک عدد تصادفی با توزیع گاوسی با میانگین صفر و واریانس  $d_j$  هستند. اگر هیچ گیاه فرزندی زنده نماند، مطابق معادله (۱۴) گیاه اصلی جدید تولید می‌شود [۳].

#### - رفتار انتخاب

این که گیاهان فرزند زنده هستند یا نه، با استفاده از احتمال بقا و به شرح زیر تعیین می‌شود [۳]:

$$P = \left| \frac{F(P'_{i,j \times m})}{F_{max}} \right| \times Q_x^{(i \times m - 1)} \quad (16)$$

که در آن  $Q_x^{(i \times m - 1)}$  برابر  $Q_x$  به توان  $(j \times m - 1)$  بوده و  $Q_x$  احتمال انتخابی است. این مقدار باید بین صفر تا 1 باشد. می‌توان دید که برازندگی گیاهان فرزند دورتر از گیاه اصلی، کمتر است.  $Q_x$  توانایی جست‌وجوی الگوریتم را تعیین می‌کند.  $Q_x$  باید برای مسئله‌ای که به راحتی می‌تواند به جواب بهینه محلی برسد، بزرگ‌تر باشد.  $F_{max}$  حداکثر برازندگی در فلور این نسل و  $F(P'_{i,j \times m})$  برازندگی جواب ژام است [۳].

#### - تبدیل موجک

تبدیل موجک روشی جایگزین برای تبدیل فوری زمان کوتاه و هدف از ارائه آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوری زمان کوتاه است. در تبدیل موجک همانند تبدیل فوری زمان کوتاه، سیگنال مورد نظر به پنجره‌هایی تقسیم شده و تبدیل موجک روی هر کدام از این پنجره‌ها جداگانه انجام می‌گیرد [۲۸]. 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 [۳].

#### - تبدیل موجک پیوسته (CWT)

تبدیل موجک پیوسته تابع  $f(t)$  به صورت رابطه‌های ۱۷ و ۱۸ تعریف می‌شود [۳]:

$$CWT_f^\psi(s, \tau) = \psi_f^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-\tau}{s}\right) dt = \langle f(t), \psi_{s,\tau}(t) \rangle \quad (17)$$

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right) \quad (18)$$

رابطه ۱۸ رابطه‌ای با دو متغیر  $s$  و  $\tau$  است که  $s$  پارامتر مقیاس (عکس فرکانس) و  $\tau$  پارامتر انتقال هستند. علامت \* نیز نشان‌دهنده مزدوج مختلط است.  $\psi$  تابع پنجره یا موجک مادر و موجک‌های حاصل از انتقال و تغییر مقیاس موجک مادر هستند. واژه مادر به این سبب به کار می‌رود که همه نسخه‌های انتقال یافته و مقیاس شده (موجک‌های دختر)، از این تابع به دست می‌آیند، یعنی موجک مادر یک الگو برای دیگر پنجره‌هاست. علامت  $\langle \dots \rangle$  نیز نشان‌دهنده ضرب برداری دو تابع در فضای سیگنال است [۳].

#### - مدل‌های پیش‌بینی

به منظور پیش‌بینی کمی فراوانی روزهای همراه با توفان‌های گردوغبار (FDSD) از دو مدل هیبریدی مختلف و یک مدل انفرادی استفاده شد. سپس براساس 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 توفان‌های گردوغبار باشد. در مدل ۱، برای پیش‌بینی متغیر فراوانی روزهای همراه با توفان‌های 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 براساس مقادیر فراوانی روزهای همراه با توفان‌های گردوغبار تا دو فصل قبل استفاده شد و به طور مشابه در مدل‌های ۳ و ۴، پیش‌بینی‌ها براساس مقادیر متغیر مورد نظر تا سه و چهار فصل قبل صورت پذیرفت. روابط زیر در تکمیل توضیحات بیان شده ارائه می‌شود. روش‌های پیش‌بینی به کاررفته در این پژوهش شامل SVM، AF-SVM و W-SVM است.

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

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

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

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

در این پژوهش یک روش پیشنهادی هیبریدی حاصل از مدل ماشین بردار پشتیبان-موجک بررسی می‌شود. ابتدا به منظور کاهش دامنه تغییرات داده‌های گردوغبار ایستگاه سینوپتیک واقع در استان سیستان و بلوچستان و همچنین نیاز به همسان‌سازی اطلاعات ورودی و خروجی، استانداردسازی داده‌ها صورت پذیرفت. در مرحله بعد، مقادیر بهینه مشخصه‌های مدل SVM شامل  $\epsilon$  و  $C$  تعیین می‌شود. همچنین در این پژوهش کرنل‌های متفاوتی بررسی و با توجه به عملکرد کرنل‌ها، تابع RBF به عنوان تابع کرنل انتخاب شد، چراکه از دقت بهتری در برآورد داده‌های گردوغبار برخوردار است [۱۶]. در این تابع نیز پارامتر  $\gamma$  باید تعیین شود. بنابراین در حالت کلی برای پیش‌بینی توفان‌های گردوغبار به وسیله مدل SVM، باید مقادیر بهینه سه مشخصه مذکور محاسبه شود که بدین منظور سه مشخصه  $\epsilon$ ،  $C$  و  $\gamma$  توسط الگوریتم موجک به بهترین مقادیر برازش داده می‌شوند. حال می‌توان از بین مدل‌های توسعه داده شده مدلی با کمترین خطا را تعیین و مشخصه‌های آن را به عنوان مقادیر بهینه  $\epsilon$ ،  $C$  و  $\gamma$  انتخاب کرد که در جدول ۳ مقادیر بهینه پارامترهای مدل ماشین بردار پشتیبان که توسط الگوریتم موجک بهینه‌سازی شده است، نشان داده شد.

جدول ۳. مقادیر بهینه مدل ماشین بردار پشتیبان

Algorithm	SVM Parameters		
	$\gamma$	$\epsilon$	C
Wavelet (W)	۱۷	۰/۲	۰/۳۴

پس از بررسی و کنترل کیفی آمار ایستگاه‌ها و رفع کاستی‌های آماری، همگنی داده‌ها با استفاده از 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 توفان‌های گردوغبار، پیش‌بینی آن با استفاده از فرامدل SVM و ترکیب آن با الگوریتم‌های بهینه‌سازی AF و W صورت گرفت. ۷۰ درصد داده‌ها برای مرحله آموزش و ۳۰ 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<sup>۱</sup> 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 براساس 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 می‌شوند و شبکه بار دیگر آموزش داده می‌شود. این فرایند تا زمان استفاده از همه داده‌های آموزش در قسمت صحت‌سنجی ادامه می‌یابد. پس از آن براساس میانگین خطای مدل در تخمین داده‌های صحت‌سنجی، پارامتر (های) مناسب شبکه عصبی تعیین می‌شود. برای پیش‌بینی از سه مدل یادشده استفاده شد. مدل مناسب براساس معیارهای ارزیابی  $R^2$ ، RMSE، MAE و NS برای هر روش در مقیاس فصلی استخراج شد. پس از آن، تحلیل نتایج برپایه بهترین مدل برای هر یک از روش‌ها صورت پذیرفت.

#### - معیارهای ارزیابی

در این تحقیق به‌منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب تبیین ( $R^2$ ) ریشه میانگین مربعات خطا (RMSE) میانگین قدر مطلق خطا (MAE) و ضریب نش ساتکلیف (NS) طبق روابط زیر استفاده شد. بهترین مقدار برای این چهار معیار به‌ترتیب یک، صفر، صفر و یک است.

$$R^2 = \frac{\left[ \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) \right]^2}{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2} \quad 0 \leq R^2 \leq 1 \quad (19)$$

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

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

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

در روابط بالا،  $x_i$  و  $y_i$  به ترتیب مقادیر مشاهداتی و محاسباتی در گام‌های زمانی  $i$  ام،  $N$  تعداد گام‌های زمانی، و  $\bar{x}$  و  $\bar{y}$  به ترتیب میانگین مقادیر مشاهداتی و محاسباتی است [۳۲].

### بحث

جدول ۴ مقادیر معیارهای نیکویی برازش مربوط به مرحله آزمایش مدل‌های هیبریدی AF-SVM و W-SVM و همچنین مدل انفرادی SVM را به منظور پیش‌بینی فراوانی روزهای همراه با توفان گردوغبار در استان سیستان و بلوچستان نشان می‌دهد. نتایج پیش‌بینی شاخص FDSH حاکی از عملکرد مناسب هر دو روش هیبریدی AF-SVM و W-SVM در همه ایستگاه‌ها (زابیل، زاهدان، ایرانشهر، خاش و سراوان) است. نکته دیگری که از جدول ۴ استنتاج می‌شود، عملکرد ضعیف مدل انفرادی ماشین بردار پشتیبان نسبت به هر دو روش هیبریدی است. در جدول ۴، اعداد داخل پرانتز روبه‌روی مقادیر معیارهای ارزیابی، رتبه‌بندی هر روش براساس معیارهای ارزیابی مورد نظر در پیش‌بینی فراوانی روزهای همراه با توفان گردوغبار را نشان می‌دهد. بر این مبنای، در همه ایستگاه‌ها مدل هیبریدی W-SVM بیشترین مقدار رتبه اول (بهترین پیش‌بینی) را داشته است. با ترکیب مقدار معیارهای ارزیابی و تعداد ایستگاه‌های تحت بررسی برای پیش‌بینی فراوانی روزهای همراه با توفان گردوغبار، ۲۰ رتبه (۴×۵) برای هر روش وجود دارد. بدین ترتیب مدل انفرادی ماشین بردار پشتیبان هیچ رتبه نخست را به خود اختصاص نداده است، در حالی که مدل‌های هیبریدی W-SVM و AF-SVM به ترتیب هجده و دو بار در رتبه نخست قرار گرفتند. در مجموع، عملکرد مدل هیبریدی W-SVM بهتر از روش‌های دیگر است و در غیاب این روش، مدل هیبریدی AF-SVM با دو بار قرارگیری در رتبه اول و هجده بار قرارگیری در رتبه دوم بهترین عملکرد را داشته است.

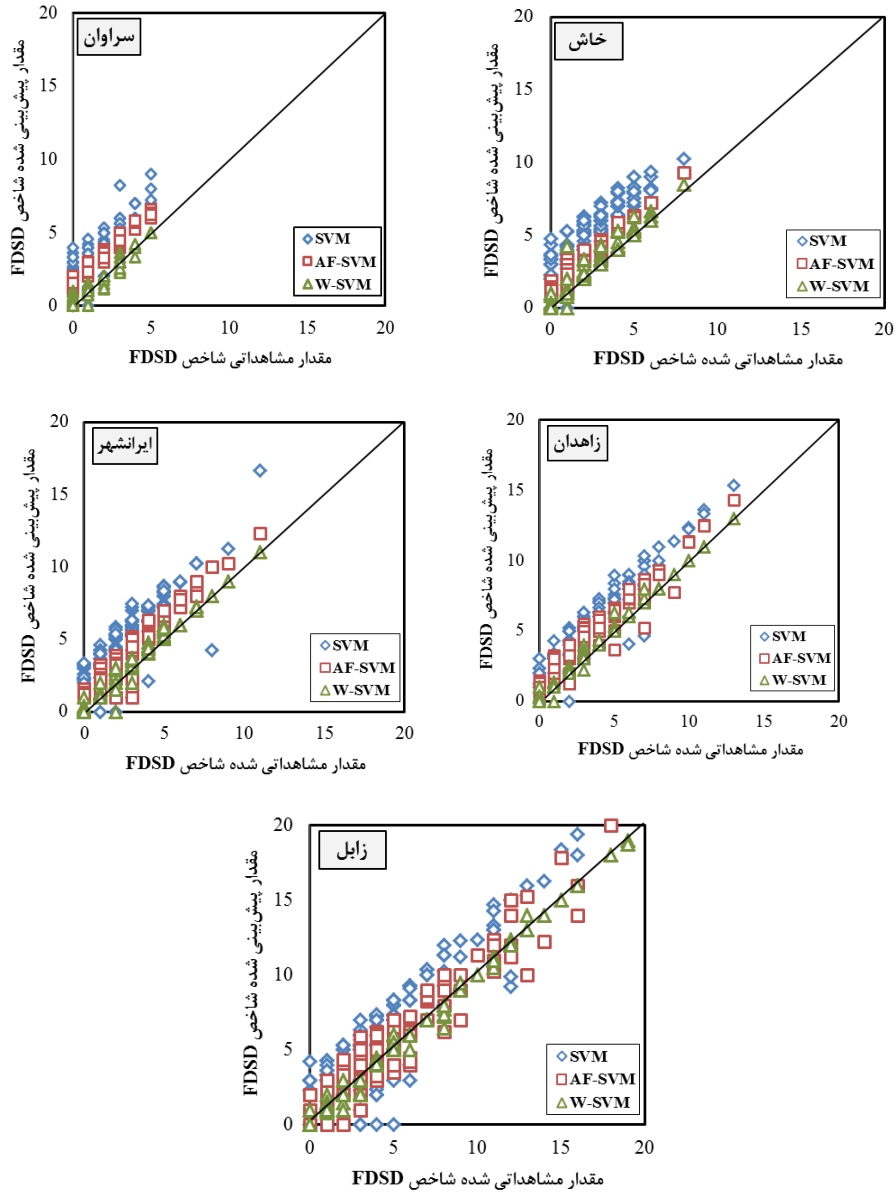
نتیجه دیگری که از جدول ۴ برمی‌آید، انتخاب مدل‌های پیچیده‌تر به‌عنوان مدل بهینه پیش‌بینی‌کننده در ایستگاه‌هاست؛ به‌نحوی که برای پیش‌بینی شاخص FDSH در همه ایستگاه‌ها از مدل‌های ۳ و ۴ (با سه و چهار گام تأخیر) استفاده شد که دلیل آن را می‌توان تأثیر ذرات به‌جامانده از توفان‌های قبلی و فصل‌های گذشته بر شکل‌گیری توفان‌های گردوغبار فصل آینده دانست. نتایج این قسمت با تحقیقات انجام‌گرفته در این زمینه مطابقت دارد [۲۴، ۹، ۷، ۶، ۵]. با توجه به اینکه در جدول ۴ ترتیب ایستگاه‌ها به‌لحاظ تعداد روزهای گردوغباری از ایستگاه سراوان تا زابل صعودی بوده و متوسط شاخص FDSH در مقیاس فصلی از ۱/۳۸ تا ۷/۳۴ متغیر است، می‌توان نتیجه گرفت که عملکرد همه روش‌ها به‌منظور پیش‌بینی شاخص FDSH با افزایش تعداد روزهای همراه با توفان گردوغبار رابطه مستقیمی دارد. نتایج این بخش با تحقیقات پیشین همسوست [۷، ۹، ۱۶]. شکل ۲ مقادیر مشاهداتی و پیش‌بینی‌شده شاخص FDSH را برای داده‌های

آزمایش نشان می‌دهد. این شکل بهبود عملکرد روش‌های استفاده‌شده با افزایش فراوانی روزهای همراه با توفان گردوغبار را به‌خوبی بیان می‌کند؛ به‌طوری که ایستگاه زابل به‌عنوان فراوان‌ترین ایستگاه در منطقه، بهترین مطابقت را بین مقادیر مشاهداتی و پیش‌بینی‌شده FDSO دارد. همان‌طور که در شکل ۲ مشخص است، ارتباط بین مقادیر مشاهداتی و پیش‌بینی‌شده در همه ایستگاه‌ها، خطی با شیب ۴۵ درجه است. مقایسه میانگین مقادیر مشاهداتی و پیش‌بینی‌شده شاخص FDSO براساس آزمون  $t$  نشان داد که فرض صفر مبنی بر برابر بودن میانگین سری مقادیر مشاهداتی و پیش‌بینی‌شده در هیچ‌کدام از ایستگاه‌های منطقه در سطح خطای ۱ درصد رد نمی‌شود. بنابراین می‌توان نتیجه گرفت که همه مدل‌های استفاده‌شده برای پیش‌بینی شاخص FDSO، میانگین سری زمانی را حفظ کرده‌اند (جدول ۵) که این ویژگی نیز می‌تواند تأکیدی بر کارایی فرامدل ماشین بردار پشتیبان و به‌ویژه ترکیب این فرامدل با الگوریتم موجک و گیاهان مصنوعی به‌منظور پیش‌بینی شاخص FDSO باشد.

جدول ۴. معیارهای ارزیابی محاسبه‌شده مدل‌های هیبریدی AF-SVM و W-SVM در مقایسه با مدل انفرادی SVM به‌منظور پیش‌بینی فراوانی روزهای همراه با توفان گردوغبار

حالت	معیارهای ارزیابی	سراوان	خاش	ایران‌شهر	زاهدان	زابل
	مدل بهینه	۴	۴	۳	۴	۴
SVM	$R^2$	۰/۷۶۱ (۳)	۰/۷۸۲ (۳)	۰/۷۹۳ (۳)	۰/۸۲۱ (۳)	۰/۸۵۴ (۳)
	RMSE	۰/۵۱۷ (۳)	۰/۵۱۳ (۳)	۰/۴۸۷ (۳)	۰/۴۷۶ (۳)	۰/۴۵۲ (۳)
	MAE	۰/۴۶۳ (۳)	۰/۴۲۷ (۳)	۰/۴۲۵ (۳)	۰/۳۸۲ (۳)	۰/۳۲۹ (۳)
	NS	۰/۷۸۱ (۳)	۰/۸۱۳ (۳)	۰/۸۱۷ (۳)	۰/۸۳۲ (۳)	۰/۸۳۹ (۳)
	مدل بهینه	۳	۴	۴	۳	۴
AF-SVM	$R^2$	۰/۷۹۱ (۲)	۰/۸۲۳ (۲)	۰/۸۶۷ (۲)	۰/۹۱۳ (۲)	۰/۹۳۵ (۲)
	RMSE	۰/۴۸۵ (۲)	۰/۴۸۲ (۲)	۰/۴۶۳ (۲)	۰/۴۲۲ (۲)	۰/۳۸۶ (۲)
	MAE	۰/۳۳۱ (۱)	۰/۳۲۷ (۱)	۰/۳۱۸ (۲)	۰/۳۱۱ (۲)	۰/۳۰۲ (۲)
	NS	۰/۸۹۱ (۲)	۰/۹۰۵ (۲)	۰/۹۰۹ (۲)	۰/۹۲۵ (۲)	۰/۹۳۷ (۲)
	مدل بهینه	۴	۴	۴	۳	۴
W-SVM	$R^2$	۰/۹۱۱ (۱)	۰/۹۳۴ (۱)	۰/۹۳۶ (۱)	۰/۹۶۷ (۱)	۰/۹۸۴ (۱)
	RMSE	۰/۳۹۷ (۱)	۰/۳۷۳ (۱)	۰/۳۷۱ (۱)	۰/۳۴۵ (۱)	۰/۳۱۴ (۱)
	MAE	۰/۳۳۵ (۲)	۰/۳۳۲ (۲)	۰/۲۸۵ (۱)	۰/۲۵۷ (۱)	۰/۲۳۶ (۱)
	NS	۰/۹۲۷ (۱)	۰/۹۲۴ (۱)	۰/۹۴۳ (۱)	۰/۹۵۹ (۱)	۰/۹۶۵ (۱)
متوسط روزهای همراه با توفان گردوغبار در مقیاس فصلی						
۱/۳۸      ۲/۲۵      ۲/۶۸      ۳/۵۱      ۷/۳۴						

توجه: اعداد داخل پرانتز رتبه مدل را از نظر معیار ارزیابی معین نشان می‌دهد.



شکل ۲. نتایج مقادیر مشاهداتی و پیش‌بینی شده شاخص FSDS در ایستگاه‌های تحت بررسی واقع در استان سیستان و بلوچستان



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

ایستگاه	مشاهداتی	میانگین			آماره t		
		SVM	AF-SVM	W-SVM	SVM	AF-SVM	W-SVM
سراوان	۰/۶۹۵	۰/۶۷۱	۰/۶۸۱	۰/۶۹۴	۰/۵۸۴	۰/۵۹۳	
خاش	۰/۷۰۶	۰/۶۷۴	۰/۶۸۲	۰/۶۹۶	۰/۵۸۶	۰/۵۹۳	
ایرانشهر	۰/۷۳۱	۰/۶۹۳	۰/۶۹۸	۰/۷۰۲	۰/۵۹۸	۰/۶۰۴	
زاهدان	۰/۸۳۳	۰/۷۰۱	۰/۷۱۱	۰/۷۲۳	۰/۶۰۲	۰/۶۷۶	
زابل	۰/۹۵۴	۰/۷۰۵	۰/۷۹۳	۰/۸۲۵	۰/۶۰۵	۰/۷۲۷	

### نتیجه‌گیری

هدف این پژوهش، بررسی عملکرد مدل هیبریدی ماشین بردار پشتیبان- موجک (W-SVM) در مقایسه با مدل هیبریدی ماشین بردار پشتیبان- الگوریتم گیاهان مصنوعی (AF-SVM) و همچنین مدل انفرادی ماشین بردار پشتیبان (SVM) به منظور پیش‌بینی فراوانی روزهای همراه با توفان گردوغبار (FDS) در پنج ایستگاه سینوپتیک استان سیستان و بلوچستان بود. ورودی مدل‌ها، مقادیر فراوانی روزهای همراه با توفان گردوغبار در تأخیرهای قبل (حداکثر چهار فصل) و خروجی شامل مقادیر فصلی فراوانی روزهای همراه با توفان گردوغبار بود. نتایج شاخص‌های نیکویی برازش در مرحله آموزش و آزمایش نشان داد که مدل‌های هیبریدی به کاررفته، نتایج قابل قبولی در مدل‌سازی شاخص FDS ارائه می‌کنند. مدل هیبریدی پیشنهادی ماشین بردار پشتیبان- موجک، دقت بیشتر و خطای کمتری از مدل هیبریدی ماشین بردار پشتیبان- گیاهان مصنوعی و مدل انفرادی ماشین بردار پشتیبان از خود نشان داد. در مجموع می‌توان گفت دقت زیاد مدل‌های هیبریدی ناشی از بهینه‌سازی پارامترهای مدل ماشین بردار پشتیبان مطابق الگوریتم‌های موجک و گیاهان مصنوعی به بهترین مقادیر ممکن است. این الگوریتم‌ها ترکیبی از بهینه‌سازی پیوسته و گسسته‌اند که در مسائل با دامنه بزرگ، زمان دستیابی به جواب بهینه سراسری را کاهش می‌دهند و از جواب‌های بهینه محلی خارج می‌شوند که این ویژگی، سبب توانایی قابل قبول این الگوریتم‌ها در حل مسائل غیرخطی با ابعاد بزرگ و سرعت زیاد در همگرایی به جواب بهینه می‌شود. در مجموع این تحقیق نشان داد که استفاده از مدل ترکیبی ماشین بردار پشتیبان- موجک می‌تواند در زمینه پیش‌بینی فراوانی روزهای همراه با توفان گردوغبار بسیار مؤثر باشد. همچنین در همه روش‌های مورد استفاده برای پیش‌بینی شاخص FDS، مدلی که از سه یا چهار گام تأخیر در پیش‌بینی

استفاده کرد، بهترین مدل پیش‌بینی‌کننده بوده است که علت آن را می‌توان تأثیر ذرات به‌جامانده از توفان‌های قبلی و فصل (های) گذشته بر شکل‌گیری توفان‌های گردوغبار فصل آینده دانست. با توجه به اینکه تصمیم‌گیری برای کنترل توفان‌های گردوغبار و اجرای راهبردهای مدیریتی در بسیاری از مناطق بحرانی کشور به برآورد دقیق توفان‌های گردوغبار وابسته است، استفاده از مدل هیبریدی پیشنهادی برای پیش‌بینی شاخص FDSD، می‌تواند ابزاری مناسب در اتخاذ تصمیمات مدیریتی باشد. بدون شک به‌منظور اعتبارسنجی نتایج به‌دست‌آمده از این پژوهش، تحقیقات بیشتری در زمینه کاربرد فرامدل‌های ترکیبی در مدل‌سازی و پیش‌بینی زمانی توفان‌های گردوغبار در مناطق تحت تأثیر این پدیده باید انجام گیرد. همچنین پیشنهاد می‌شود از مدل‌های هیبریدی ماشین بردار پشتیبان با الگوریتم‌های بهینه‌سازی جدید همچون اسکی، ازدحام مرغ، ازدحام گربه، تفنگدار خلاق و غیره استفاده و یافته‌ها با نتایج مدل پیشنهادی مقایسه شود.

## منابع

- [۱]. آذرپیرا، فریبا؛ و شهابی، سجاد (۱۳۹۹). «پیش‌بینی جریان با استفاده از رویکرد تلفیقی موجک- برنامه‌ریزی بیان ژن و ارزیابی تأثیر پارامترهای هواشناسی بر کارایی آن»، مدیریت آب و آبیاری، دوره ۱۰، شماره ۲، ص ۲۷۹-۲۶۵.
- [۲]. پسندیده، ایرج؛ ایزدبخش، محمدعلی؛ و شعبانلو، سعید (۱۳۹۸). «برآورد بارش درازمدت شهر انزلی توسط مدل ترکیبی سیستم‌های استنتاج فازی عصبی تطبیقی و تبدیل موجک»، تحقیقات آب و خاک ایران، دوره ۵۰، شماره ۷، ص ۱۷۴۵-۱۷۳۳.
- [۳]. دهقانی، رضا؛ ترابی‌پوده، حسن؛ یونسی، حجت‌الله؛ و شاه‌نژاد، بابک (۱۳۹۹). «بررسی عملکرد مدل هیبریدی ماشین بردار پشتیبان- الگوریتم گیاهان مصنوعی در تخمین جریان روزانه رودخانه‌ها؛ مطالعه موردی: حوضه دز، تحقیقات منابع آب ایران، دوره ۱۶، شماره ۲، ص ۱۴۹-۱۳۲.
- [۴]. شاه‌نژاد، بابک؛ و دهقانی، رضا (۱۳۹۷). «مقایسه مدل‌های شبکه عصبی موجک، ماشین بردار پشتیبان و برنامه‌ریزی بیان ژن در تخمین میزان اکسیژن محلول در آب رودخانه‌ها»، تحقیقات منابع آب ایران، دوره ۱۴، شماره ۳، ص ۲۳۸-۲۲۶.
- [۵]. عبدالشاه‌نژاد، مهسا؛ خسروی، حسن؛ نظری‌سامانی، علی‌اکبر؛ زهتابیان، غلامرضا؛ و علم‌بیگی، امیر (۱۳۹۹). «تعیین چارچوب مفهومی ریسک گردوغبار بر مبنای سنجش تاب‌آوری (بررسی موردی: جنوب غرب کشور)»، پژوهش‌های راهبردی در علوم کشاورزی و منابع طبیعی، سال پنجم شماره ۱، ص ۳۳.
- [۶]. عراقی‌نژاد، شهاب؛ انصاری قوجقار، محمد؛ پورغلام‌امیجی، مسعود؛ لیاقت، عبدالحمید؛ و بذرافشان، جواد (۱۳۹۷). «تأثیر نوسانات اقلیمی بر فراوانی توفان‌های گردوغبار در ایران»، مهندسی اکوسیستم بیابان، دوره ۷، شماره ۲۱، ص ۳۲-۱۳.
- [۷]. فرج‌زاده اصل، منوچهر؛ و علی‌زاده، خاطره (۱۳۹۰). «تحلیل زمانی و مکانی توفان‌های گردوخاک در ایران»، برنامه‌ریزی و آمایش فضا، دوره ۱۵، شماره ۱، ص ۸۴-۶۵.
- [۸]. نیک‌پور، محمدرضا؛ ثانی‌خانی، هادی؛ محمودی بابلان، سجاد؛ و محمدی، عارف (۱۳۹۶). «کاربرد مدل‌های ANN، LS-SVM، WNN و GEP در شبیه‌سازی بارش - رواناب رودخانه خیاوچای». اکوهیدرولوژی، دوره ۴، شماره ۲، ص ۶۳۹-۶۲۷.

- [۹]. یارمرادی، زهرا؛ نصیری، بهروز؛ کرمپور، مصطفی؛ و حسن محمدی، غلام (۱۳۹۷). «تحلیل روند فراوانی روزهای گردوغباری در نیمه شرقی ایران در ارتباط با نوسانات اقلیمی»، مهندسی اکوسیستم بیابان، دوره ۷، شماره ۱۸، ص ۱۴-۱.
- [10]. Alizadeh, F.; Gharamaleki, A.; Jalilzadeh, M.; & Akhoundzadeh, A. (2020). "Prediction of river stage discharge process based on a conceptual model using EEMD-WT-LSSVM approach", *Water Resources*, 47, pp: 41-53.
- [11]. Basak, D.; Pal, S.; & Patranabis, D.C. (2007). "Support vector regression", *Neural Information Processing* 11, pp: 203- 225.
- [12]. Cartlidge, J. P.; & Bulloc, S.G. (2004). "Combating coevolutionary disengagement by reducing parasite virulence", *Evolutionary Computation*, 12(2), pp: 193-222.
- [13]. Cheng, L.; Wu, X.; & Wang, Y. (2018). "Artificial Flora (AF) optimization algorithm", *Applied Science*, 329(8), pp: 2- 22.
- [14]. Darvishi-Bolloorani, A.; Nabavi, S.; Azizi, R.; & Bahrami, H. (2013). "Characterization of dust storm sources in western Iran using a synthetic approach", *Advances in Meteorology, Climatology and Atmospheric Physics*, Springer, Part of the series Springer Atmospheric Sciences, pp: 415-420.
- [15]. Ekhtesasi, M.; & Gohari, Z. (2013). "Determining area affected by dust storms in different wind speeds, using satellite images (case study: Sistan plain, Iran)", *Desert*, 17, pp: 193-202.
- [16]. Goudie, A. S.; & Middleton, N. J. (2006). "Desert dust in the global system", *Springer Science & Business Media*.
- [17]. Ghorbani, M.A.; Khatibi, R.; Karimi, V.; Yaseen, Z.M.; & Zounemat-Kermani, M. (2018). "Learning from multiple models using artificial intelligence to improve model prediction accuracies: Application to River Flows", *Water Resour Management*, 32(13), pp: 4201-4215.
- [18]. Hamidi, M.; Kavianpour, M.R.; & Shao, Y. (2014). "Numerical simulation of dust events in the Middle East", *Aeolian Research*, 13, pp: 59-70.
- [19]. Hillis, W. D. (1990). "Co-evolving parasites improve simulated evolution as an optimization procedure", *Physica D: Nonlinear Phenomena*, 42, pp: 228-234.
- [20]. Huang, S.; Chang, J.; Huang, Q.; & Chen, Y. (2014). "Monthly streamflow prediction using modified emd-based support vector machine", *Journal of Hydrology*, 511(4), pp: 764-775.
- [21]. Misra, D.; Oommen, T.; Agarwa, A.; Mishra, S.K.; & Thompson, A. M. (2009). "Application and analysis of support vector machine based simulation for runoff and sediment yield", *Biosystems Engineering*, 103(3), pp: 527-535.
- [22]. O'Loingsigh, T.; McTainsh, G. H.; Tews, E. K.; Strong, C. L.; Leys, J. F.; Shinkfield, P.; & Tapper, N. J. (2014). "The Dust Storm Index (DSI): a method for monitoring broadscale wind erosion using meteorological records", *Aeolian Research*, 12, pp: 29-40.
- [23]. Pagie, L.; & Mitchell, M. A. (2002). "Comparison of evolutionary and coevolutionary search", *International Journal of Computational Intelligence and Application*, 2, pp: 53-69.

- [24]. Rashki, A.; Kaskaoutis, D. G.; Goudie, A. S.; & 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.
- [25]. Rosin, C. D.; & 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.
- [26]. Shao, Y.; Wyrwoll, K. H.; Chappell, A.; Huang, J.; Lin, Z.; McTainsh, G. H.; & Yoon, S. (2011). "Dust cycle: An emerging core theme in Earth system science", *Aeolian Research*, 2(4), pp: 181-204.
- [27]. Vapnik V. N. (1995). *The nature of statistical learning theory*, Springer, New York.
- [28]. Wang, D.; Safavi, A. A.; & Romagnoli, J. A. (2000). "Wavelet based adaptive robust M-estimator for non-linear system identification", *AICHE Journal*, 46(4), pp:1607- 1615.
- [29]. Wiegand, R. P.; & Sarma, J. (2004). "Spatial Embedding and loss of gradient in cooperative coevolutionary algorithms", In roceedings of the International Conference on Parallel Problem Solving from Nature, Berlin Germany 43, pp: 912-921.
- [30]. Williams, N.; & Mitchell, M. (2005). "Investigating the success of spatial coevolution", In Proceedings of the 7th Annual Conference on Genetic and Evolutionary Computation Washington, 46, pp: 523-530.
- [31]. Yoon, H.; Jun, S. C.; Hyun, Y.; Bae, G.O. & Lee, K. K. (2011). "Acomparative study of artificial neural networks andsupport vector machines for predicting groundwaterlevels in a coastal aquifer", *Journal of Hydrology*, 396(4), pp:128-138
- [32]. Zhu, Y. M.; Lu, X. X.; & Zhou, Y. (2007). "Suspended sediment flux modeling with artificial neural network: An example of the longchuanjiang river in the upper yangtze catchment", *Geomorphology*, 84(4), pp:111-125.