



مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی فارس

# پژوهش‌های آبخیزداری

شاپا: ۲۰۳۸-۲۹۸۱



سازمان تحقیقات، آموزش و ترویج کشاورزی

## ارزیابی اثرات شاخص‌های پیوند از دور بر غلظت PM2.5 با استفاده از مدل‌های یادگیری ماشین در استان سیستان و بلوچستان

- ابوالفضل داوری<sup>۱</sup>، رسول مهدوی نجف‌آبادی<sup>۲\*</sup>، مرضیه رضایی<sup>۳</sup>، ام‌البنین بذرافشان<sup>۴</sup>، علیرضا شهریاری<sup>۵</sup>
- ۱- دانشجوی دکتری گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران
  - ۲- دانشیار گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران
  - ۳- استاد گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران
  - ۴- دانشیار گروه فضای سبز، دانشکده جغرافیا و برنامه‌ریزی محیطی، دانشگاه سیستان و بلوچستان، زاهدان، ایران

### چکیده مبسوط

#### مقدمه و هدف

در سال‌های گذشته، آلودگی هوا، به‌ویژه افزایش غلظت ذرات معلق PM2.5، به‌عنوان یکی از چالش‌های مهم زیست‌محیطی مطرح‌شده است. استان سیستان و بلوچستان به‌دلیل موقعیت جغرافیایی ویژه و قرارگیری در مسیر بادهای ۱۲۰ روزه سیستان، همراه با کاهش بارندگی‌های سالانه، شرایط مساعدی برای شکل‌گیری و تشدید پدیده گرد و غبار دارد. در این راستا، پدیده‌های پیوند از دور (S) بر تغییرات اقلیمی و به تبع آن بر کیفیت هوا نقش مهمی دارند. هدف اصلی این پژوهش، ارزیابی اثرات شاخص‌های پیوند از دور بر تغییرات غلظت PM2.5 در استان سیستان و بلوچستان با استفاده از مدل‌های پیشرفته یادگیری ماشین بود. از این‌رو، داده‌های هواشناسی و غلظت PM2.5 در دو دهه از ایستگاه‌های زاهدان و خاش جمع‌آوری و با شاخص‌های پیوند از دور تلفیق شدند. سپس، با به‌کارگیری روش‌های تحلیل همبستگی و انتخاب ویژگی، پنج مدل یادگیری ماشین ارزیابی شدند و بهترین مدل برای برآورد غلظت ذرات معلق PM2.5 شناسایی شدند. نتایج این پژوهش، هم به درک بهتر روابط پیچیده میان نوسانات اقلیمی و کیفیت هوا منجر شد و هم با ارائه یک چارچوب تحلیلی دقیق، ابزار کاربردی برای سیاست‌گذاران در مدیریت آلودگی هوا فراهم آورد.

نوع مقاله: پژوهشی

\*مسئول مکاتبات: ra\_mahdavi2000@hormozgan.ac.ir

استناد: داوری، ا.، مهدوی‌نجف‌آبادی، ر.، رضایی، م.، بذرافشان، ا.، شهریاری، ع.ر. ۱۴۰۵. ارزیابی اثرات شاخص‌های پیوند از دور بر غلظت PM2.5 با استفاده از مدل‌های یادگیری ماشین در استان سیستان و بلوچستان. پژوهش‌های آبخیزداری. ۳۹(۱): ۱-۲۵.

شناسه دیجیتال: 10.22092/wmrj.2025.369570.1624

تاریخ دریافت: ۱۴۰۴/۰۶/۲۰، تاریخ بازنگری: ۱۴۰۴/۰۷/۱۴، تاریخ پذیرش: ۱۴۰۴/۰۹/۳۰، تاریخ انتشار: ۱۴۰۵/۰۱/۰۱  
پژوهش‌های آبخیزداری، سال ۱۴۰۵، دوره ۳۹، شماره ۱، شماره پیاپی ۱۵۰، بهار ۱۴۰۵، صفحه‌های ۱ تا ۲۵.

© نویسندگان

ناشر: مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان فارس



## مواد و روش‌ها

در این پژوهش از یک چارچوب تحلیلی چندمرحله‌ای جامع بهره‌گرفته شد و داده‌های هواشناسی و غلظت ذرات PM2.5 از ایستگاه‌های زاهدان و خاش در دوره ۲۰۰۰ تا ۲۰۲۱ جمع‌آوری شد و با داده‌های شاخص پیوند از دور مرکز پیش‌بینی اقلیم NOAA تکمیل شد. پس از پیش‌پردازش دقیق داده‌ها که شامل بررسی کیفیت داده‌ها (بررسی اندازه‌های غیرممکن یا ناهنجار PM2.5 و اصلاح یا حذف اندازه‌های مشکوک)، همزمان‌سازی زمانی داده‌ها (تطبیق داده‌های PM2.5 و شاخص‌های پیوند از دور بر اساس تاریخ برای اطمینان از همزمانی اندازه‌های مستقل و وابسته) و جایگزینی داده‌های مفقود (با استفاده از نزدیک‌ترین اندازه معتبر، میانگین‌گیری زمانی و درون‌یابی‌های آماری برای حفظ توزیع اصلی داده‌ها) بود، یک رویکرد تحلیلی دوگانه اجرا شد. ابتدا از تحلیل همبستگی پیرسون برای سنجش روابط خطی میان شاخص‌های پیوند از دور و سطوح PM2.5 استفاده شد. سپس، با کاربرد الگوریتم Boruta موثرترین ویژگی‌ها با تأخیرهای زمانی صفر تا ۶ ماهه شناسایی شد. پنج مدل پیشرفته یادگیری ماشین شامل Bagged CART، LightGBM، Gradient Boosting، Random Forest و XGBoost ارزیابی شدند که ۷۰٪ داده‌ها برای آموزش و ۳۰٪ برای اعتبارسنجی مدل استفاده شد. ارزیابی عملکرد با سه معیار ریشه میانگین مربعات خطا (RMSE)، میانگین درصد خطای مطلق (MAPE) و ضریب تبیین ( $R^2$ ) انجام شد و برای تفسیرپذیری مدل‌ها، چهار روش پیشرفته شامل اهمیت ویژگی‌های جایگشتی (PFI)، اندازه‌های SHAP مبتنی بر تئوری بازی‌ها، تحلیل حساسیت Sobol و نمودارهای وابستگی جزئی (PDP) به کار گرفته شد. کلیه تحلیل‌ها در محیط نرم‌افزار R (نسخه ۴،۲،۰) انجام شد.

## نتایج و بحث

نتایج نشان داد که اثر شاخص‌های پیوند از دور بر غلظت ذرات PM2.5 در ایستگاه‌های زاهدان و خاش معنادار بود. در ایستگاه زاهدان، بیشترین همبستگی مثبت مربوط به شاخص PDO (۰/۱۵۸) با تأخیر ۵ ماهه) و شاخص AMO (۰/۲۱۲) با تأخیر صفر ماهه) بود. از سوی دیگر، بیشترین همبستگی منفی مربوط به شاخص AMM (۰/۳۳۶) با تأخیر ۲ ماهه) و شاخص WHWP (۰/۴۲۰) با تأخیر ۴ ماهه) بود. در ایستگاه خاش، بیشترین همبستگی مثبت مربوط به شاخص PDO (۰/۱۵۹) با تأخیر ۲ ماهه) و بیشترین همبستگی منفی مربوط به WHWP (۰/۳۸۵) با تأخیر ۴ ماهه) بود. تحلیل اهمیت ویژگی‌ها با روش Boruta نشان داد بیشترین نقش پیش‌بینی‌کننده PM2.5 مربوط به شاخص WHWP با میانگین اهمیت ۱۳/۶۳ با تأخیر ۶ ماهه در زاهدان و با میانگین اهمیت ۱۰/۵۱ با تأخیر ۵ ماهه در خاش بود. در ارزیابی مدل‌ها، XGBoost به‌عنوان برترین مدل با دقت استثنایی ( $R^2=0/989$ ) در زاهدان و ( $R^2=0/993$ ) در خاش) و حداقل خطا ( $MAPE=2/36-3/07$ ) در زاهدان و ( $MAPE=1/5-1/8$ ) در خاش) شناخته شد. نتایج تحلیل‌های حساسیت نشان داد بیشترین اثر مربوط به شاخص AMM (با امتیاز اهمیت ۶۸۵ در زاهدان و ۵۶۱ در خاش) بود. از سوی دیگر، با زمان‌های تأخیر خاص، رفتار شاخص‌های WHWP و AMO غیرخطی و پیچیده بود. به‌طور کلی نتایج بیانگر اثرات قابل توجه نوسانات اقیانوسی-جوی (با ضریب‌های همبستگی میان ۰/۱۵ تا ۰/۴۲) و امتیازهای اهمیت متغیر میان ۵/۶ تا ۱۳/۶) بر کیفیت هوای منطقه بود. دقت عملکرد مدل XGBoost در پیش‌بینی بلندمدت PM2.5 در منطقه مطالعه شده بسیار زیاد بود.

## نتیجه‌گیری و پیشنهادها

نتایج این پژوهش نشان داد که بیشترین همبستگی مثبت با غلظت PM2.5 در ایستگاه زاهدان مربوط به شاخص‌های PDO و AMO بود و بیشترین همبستگی منفی مربوط به شاخص‌های AMM و WHWP بود. مدل XGBoost به‌عنوان بهترین مدل پیش‌بینی با بیشترین دقت و کمترین خطا شناخته شد. همچنین، نتایج تحلیل‌های SHAP و PDP نشان داد که اثرات شاخص‌های AMM و WHWP بر غلظت PM2.5 پیچیده و غیرخطی است و تأخیر زمانی نیز بسیار مهم است. در ایستگاه خاش نیز مهم‌ترین نقش در پیش‌بینی PM2.5 مربوط به شاخص‌های AMM، AMO، PDO و WHWP بود که بیانگر اثرات قابل توجه نوسانات اقلیمی بر کیفیت هوا است. این یافته‌ها بیانگر

اهمیت روابط غیرخطی و آستانه‌های بحرانی در مدل‌سازی کیفیت هوا بود. بر پایه نتایج این پژوهش، به‌منظور تصمیم‌ها و اقدامات پیشگیرانه پیشنهاد می‌شود شاخص‌های پیوند از دور در پیش‌بینی دوره‌های با غلظت زیاد ذرات معلق، پیوسته پایش شوند. همچنین، پیشنهاد می‌شود بر اساس تفاوت‌های مشاهده‌شده میان دو ایستگاه (زاهدان و خاش)، به ویژگی‌های محلی و منطقه‌ای در مدل‌سازی کیفیت هوا بیشتر توجه شود.

## واژگان کلیدی

ارزش SHAP، پیوند از دور، تحلیل حساسیت Sobol، PM2.5، همبستگی پیرسون

## مقدمه

پستی‌بلندی وجود دارد. از این رو، الگوهای مختلف توزیع گرد و غبار و مسیرهای حمل و نقل معمولاً در رویدادهای بزرگ گرد و غبار که از این منطقه منشأ می‌گیرند، مشاهده می‌شود (پروسپرو و همکاران ۲۰۰۲). ایران به دلیل قرارگیری در کمربند گرد و غبار جهانی، به طور قابل توجهی تحت تأثیر طوفان‌های گرد و غبار است و شرایط آب و هوایی بیش از نیمی از کشور خشک و نیمه‌خشک است (شمسی‌پور و صفرراد ۲۰۱۲). استان سیستان و بلوچستان، در جنوب شرقی ایران، به دلیل آب و هوای خشک و ویژگی‌های جغرافیایی منحصر به فرد، شرایط مساعدی برای پدیده طوفان‌های گرد و غبار دارد (جهان‌تیغ و همکاران ۲۰۲۳). این پدیده‌ها فقط بر کیفیت هوا و سلامت عمومی اثرگذار نیستند بلکه چالش‌های مهمی برای کشاورزی، زیرساخت‌ها و اقتصادهای محلی ایجاد می‌کنند. با توجه به اینکه تغییرات اقلیمی مانند تغییرات سرعت باد، بارش، دما و الگوهای رطوبت، سبب تشدید شرایط طوفان گرد و غبار می‌شود، درک عامل‌هایی که در ایجاد طوفان‌های گرد و غبار نقش دارند، ضروری‌تر از گذشته به نظر می‌رسد (ژانگ و همکاران ۲۰۱۹). در میان این عامل‌ها، نقش پیوند از دور (الگوهای آب و هوایی در مقیاس بزرگ که تغییرات آب و هوایی را در مناطق دوردست به هم مرتبط می‌کنند) بر شرایط محلی مهم و اثرگذار است (مارتینز-آلوارادو و همکاران ۲۰۰۹). با وجود پیشرفت‌های چشمگیر در پژوهش‌های هواشناسی، پیش‌بینی دقیق طوفان‌های گرد و غبار همچنان به‌عنوان یک چالش بزرگ باقی‌مانده است. مدل‌های

طوفان گرد و غبار از پدیده‌های طبیعی در مناطق خشک و نیمه‌خشک جهان به‌شمار می‌آید که عمدتاً در فصل‌های گرم سال رخ می‌دهند. چرخه گرد و غبار به جنبه‌های بسیاری از اقلیم زمین ارتباط دارد و بر آن اثرگذار است. آئروسول‌های گرد و غبار می‌توانند بر اقلیم‌های منطقه‌ای و حتی جهانی اثرات قابل توجهی داشته باشند. به‌عنوان مثال، آئروسول‌های گرد و غبار ممکن است با کاهش تضاد حرارتی زمین-اقیانوس، گردش‌های موسمی آسیا را تعدیل کنند (لی و همکاران ۲۰۱۶) و بر بارش، ویژگی‌های ابر و بودجه انرژی زمین اثرگذار باشند و به‌عنوان هسته‌های تراکم عمل کنند (کریمین و همکاران ۲۰۱۳). گرد و غبار می‌تواند مسافت‌های طولانی را طی کند و بر چرخه‌های بیوژئوشیمیایی جهانی اثرگذار باشد (ریزولو و همکاران ۲۰۱۷). کمربند گرد و غبار، که به منطقه‌ای خشک و نیمه‌خشک اشاره دارد که از سواحل غربی شمال آفریقا تا شرق آسیا کشیده شده است (واشنگتن و همکاران ۲۰۰۳)، به‌عنوان بزرگ‌ترین منبع آئروسول گرد و غبار معدنی در زمین شناخته شده است. این کمربند شامل بسیاری از بیابان‌های بزرگ جهان است که خطرات قابل توجهی را برای جمعیت‌های انسانی ایجاد می‌کند، به طوری که تنوع طوفان‌های گرد و غبار در درجه اول به‌وسیله فرآیندهای طبیعی از جمله بارندگی و قدرت باد هدایت می‌شود تا فعالیت‌های انسانی (میدلتون ۲۰۱۹). به دلیل گستردگی زیاد آن، کمربند گرد و غبار در چندین منطقه اقلیمی با فرآیندها و الگوهای جوی متفاوت، انواع پوشش گیاهی و ویژگی‌های

شناسایی کردند. پیرا و همکاران (۲۰۲۴) نیز افزایش صد درصدی AOD پس از رویدادهای ال نینو در آمازون را گزارش کردند. نتایج پژوهش‌های پیشین در ایران نشان داده‌اند که پدیده گرد و غبار تحت تأثیر نوسانات اقلیمی و شاخص‌های پیوند از دور است. خسروی و همکاران (۲۰۰۴) با بررسی خشکسالی‌های متناوب در سیستان و بلوچستان نشان دادند که شاخص‌های PDO، MEI، POL و WHWP با اثرگذاری بر امواج جوی، موقعیت رودها و الگوهای فشار سطحی، در تداوم خشکسالی و کاهش بارش نقش مهمی دارند و بیش از ۷۰٪ از تغییرات اقلیمی سالانه استان را می‌توان با این شاخص‌ها تبیین کرد. در پژوهشی امیدوار و همکاران (۲۰۲۴) گرد و غبار استان کرمان را بررسی و گزارش کردند که بیشترین فراوانی روزهای گرد و غباری در فصل بهار و کمترین در پاییز رخ داد و با شاخص‌های AO، AMO، PDO و NINO می‌توان حدود ۲۵٪ از تغییرات روزهای گرد و غبار را توضیح داد. نتایج پژوهش وطن‌پرست و همکاران (۲۰۲۴) نیز نشان داد که شاخص‌های ENSO، IOD و QBO با اثرگذاری بر شدت و جهت باد، زمینه‌ساز بلند شدن ذرات گرد و غبار و رخداد طوفان‌های غباری در نیمه غربی ایران بود و بیشترین اثر بر افزایش فراوانی گرد و غبار بلندمدت مربوط به فاز سرد ENSO همراه با فاز منفی QBO بود. نتایج پژوهش‌های مروری درباره منشأ و مسیر ریزگردها در ایران بیانگر آن است که منابع داخلی در دشتهای خشک شرق و جنوب‌شرق کشور (به‌ویژه سیستان و بلوچستان)، غرب و جنوب‌غرب ایران (خوزستان، ایلام، کرمانشاه) و منابع خارجی در جنوب‌غربی افغانستان، عراق، عربستان و شمال آفریقا هستند (آرامی و همکاران ۲۰۱۸). نتایج تمام این پژوهش‌ها تأکید دارند که گرد و غبار در ایران پدیده‌ای چندعاملی است که باید با رویکرد جامع بررسی و مدل‌سازی شود. یادگیری ماشین به‌عنوان یک راهکار امیدوارکننده برای بهبود پیش‌بینی طوفان‌های گرد و غبار مطرح‌شده است، زیرا، با تجزیه و تحلیل مجموعه داده‌های گسترده و شناسایی الگوهای پیچیده‌ای که

سنتی معمولاً از رویکردهای خطی استفاده می‌کنند که نمی‌توانند تعاملات پیچیده و غیرخطی میان عامل‌های مختلف آب و هوایی و شرایط محلی را نشان دهند. افزون بر این، بسیاری از پژوهش‌های موجود عمدتاً بر متغیرهای منطقه‌ای مانند رطوبت خاک و الگوهای باد متمرکز است (علی‌زاده چوباری و همکاران ۲۰۱۴) و اثرات بالقوه پیوند از دور و نوسانات جوی در مقیاس بزرگ نادیده گرفته می‌شود. این شکاف در پژوهش‌ها، اثربخشی راهبردهای پیش‌بینی گرد و غبار و مدیریت آن را به شدت محدود می‌کند. از این‌رو، به توسعه مدل‌های جدید و جامع‌تری نیاز مبرمی است تا بتوان اثرات همه جانبه این پدیده را بررسی کرد. نتایج پژوهش‌های پرشماری نشان‌دهنده است که پدیده‌های پیوند از دور به‌ویژه الینو-نوسان جنوبی (ENSO) بر رخداد و شدت طوفان‌های گرد و غبار در مناطق مختلف جهان به‌طور قابل توجهی اثرگذار است. در ایران نتایج پژوهش اکبری و همکاران (۲۰۱۶) نشان داد که همبستگی شاخص‌های ENSO و MEI با فراوانی گرد و غبارهای فرامنطقه‌ای معنادار بود. انصاری قوجقار و همکاران (۲۰۲۱) با استفاده از شاخص ONI دریافتند که اثر فاز گرم ENSO بر استان‌های خوزستان و سیستان و بلوچستان متفاوت بود و باعث افزایش طوفان‌های گرد و غبار شد. وطن‌پرست قلعه‌جوق و همکاران (۲۰۲۴) نیز اثر همزمان ENSO، IOD و QBO را بر گرد و غبار در غرب ایران بررسی کردند و دریافتند که بیشترین اثر بر افزایش گرد و غبار مربوط به فاز سرد ENSO همراه با فاز منفی QBO بود. مائو و همکاران (۲۰۱۱) ارتباط میان فاز منفی نوسان شمالگان (AO) و افزایش طوفان‌های گرد و غبار در شمال چین را گزارش کردند در حالی که لیو و همکاران (۲۰۲۰) کاهش گرد و غبار در شمال چین را با تقویت قطب شمال مرتبط دانستند. پایوس و همکاران (۲۰۲۲) در بورنئو دریافتند که ژرفای نوری آئروسول (AOD) در طول رویدادهای ال نینو افزایش یافت. بین و همکاران (۲۰۲۲) الگوهای متفاوت اثر ENSO بر گرد و غبار در زیرمنطقه‌های مختلف کمربند گرد و غبار را

و بلوچستان، در جنوب شرقی ایران هستند و با توجه به موقعیت جغرافیایی، تحت تأثیر شرایط اقلیمی خاصی بوده که بر زندگی ساکنان و محیط طبیعی آن‌ها اثرگذار است. زاهدان به‌عنوان مرکز استان با آب و هوای بسیار گرم و خشک، تابستان‌های بسیار گرم و زمستان‌های نسبتاً سرد دارد (رزمجویی و حلییان ۲۰۱۱). از سوی دیگر، خاش که در فاصله‌ای نه‌چندان دور از زاهدان است، به‌دلیل موقعیت بلندتری در مقایسه با زاهدان آب و هوای ملایم‌تری دارد، اما همچنان با چالش‌هایی مانند کمبود منابع آبی و پدیده گرد و غبار روبه‌رو است (زینالی و اصغری ۲۰۱۸). افزون بر این، وزش بادهای ۱۲۰ روزه سیستان که یکی از ویژگی‌های اقلیمی برجسته این منطقه به‌شمار می‌آید، تأثیر بسزایی بر کیفیت زندگی مردم و فعالیت‌های اقتصادی دارد (علی‌صوفی و همکاران ۲۰۲۳).

#### روش پژوهش

در این پژوهش، داده‌های لازم از منابع چندگانه شامل ایستگاه‌های هواشناسی همدید محلی، محصولات سنجنش از دور سنجنده MODIS نصب‌شده روی ماهواره‌های Terra و Aqua، و شاخص‌های پیوند از دور بر اساس مبانی اقلیمی مرتبط با الگوهای اقیانوسی و جوی اثرگذار بر جنوب شرق ایران انتخاب شدند. شاخص‌هایی مانند AMO، PDO، AMM و WHWP به‌دلیل ارتباط فیزیکی‌شان با تغییرات دمای سطح دریا، شدت بادهای مونسونی، و انتقال توده‌های گرد و غبار استفاده شدند. داده‌های شاخص‌ها از پایگاه معتبر NOAA برای دوره ۲۰۰۰ تا ۲۰۲۱ استخراج شد. مراحل پردازش داده‌ها شامل بررسی کیفیت داده‌ها (بررسی اندازه‌های غیرممکن یا ناهنجار PM2.5 و اصلاح یا حذف اندازه‌های مشکوک)، همزمان‌سازی زمانی داده‌ها (تطبیق داده‌های PM2.5 و شاخص‌های پیوند از دور بر اساس تاریخ برای اطمینان از همزمانی اندازه‌های مستقل و وابسته) و جایگزینی داده‌های مفقود (با استفاده از نزدیک‌ترین اندازه معتبر، میانگین‌گیری زمانی و درون‌یابی‌های آماری برای حفظ توزیع اصلی داده‌ها) انجام شد و تحلیل روابط خطی میان شاخص‌های پیوند از دور و

ممکن است با روش‌های سنتی قابل مشاهده نباشند، می‌توان کارایی را افزایش داد (الشمیری و همکاران ۲۰۲۲). با استفاده از الگوریتم‌های یادگیری ماشین می‌توان ویژگی‌های ورودی مختلف، از جمله شاخص‌های پیوند از دور، داده‌های هواشناسی و تصویرهای ماهواره‌ای را پردازش کرد و مدل‌های پیش‌بینی کارآمدتری ایجاد کرد. با بهره‌گیری از توانایی‌های یادگیری ماشین، پژوهشگران قادر خواهند بود مدل‌هایی را توسعه دهند که هم پدیده طوفان‌های گرد و غبار را پیش‌بینی می‌کند و هم تأثیرات آب و هوایی را ارزیابی می‌کند. هدف این پژوهش، پیش‌بینی اثرات شاخص‌های پیوند از دور بر تغییرات غلظت ذرات معلق PM2.5 در استان سیستان و بلوچستان با استفاده از مدل‌های یادگیری ماشین بود. در این پژوهش داده‌های هواشناسی و آلودگی هوا جمع‌آوری شد و سپس با شاخص‌های اقلیمی جهانی تلفیق شدند. افزون بر این پنج مدل یادگیری ماشین ارزیابی شد و دقیق‌ترین مدل برای پیش‌بینی بلندمدت کیفیت هوا شناسایی شد. در این پژوهش سعی شد تا هم روابط پیچیده میان نوسانات اقلیمی و آلودگی هوا تحلیل شود و هم با ارائه یک چارچوب تحلیلی دقیق، ابزار علمی کارآمدی برای سیاست‌گذاران در مدیریت و کاهش آلودگی هوا فراهم آید.

#### مواد و روش‌ها

##### معرفی منطقه مطالعه‌شده

استان سیستان و بلوچستان، دومین استان پهناور کشور و در جنوب شرقی ایران و در همسایگی استان‌های خراسان جنوبی، کرمان و هرمزگان است. این استان از شرق با افغانستان و پاکستان مرز مشترک داشته و از جنوب به دریای عمان متصل است که در این بخش، بندر راهبردی چابهار به‌عنوان تنها پایانه اقیانوسی ایران می‌باشد (احسانی ۲۰۱۹). از دیدگاه مختصات جغرافیایی، سیستان میان عرض‌های ۲۵° ۳' تا ۲۸° ۳۱' شمالی و طول‌های ۵۸° ۴۷' تا ۶۳° ۱۹' شرقی گسترده شده است موقعیت راهبردی در مرزهای شرقی ایران دارد (جهان‌تیغ و همکاران ۲۰۲۳). زاهدان و خاش، دو شهر مهم استان سیستان

غلظت ذرات PM2.5 با استفاده از ضریب همبستگی پیرسون انجام شد. ضریب همبستگی پیرسون با استفاده از رابطه ۱ محاسبه شد (هائو و همکاران ۲۰۲۲).

$$r_{ij} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2} \sqrt{\sum(y_i - \bar{y})^2}} \quad (1)$$

$x_i$  و  $y_i$ : اندازه‌های مربوط به دو متغیر بررسی شده،  $\bar{x}$  و  $\bar{y}$ : میانگین این اندازه‌ها و  $\Sigma$  نماد جمع برای تمام داده‌ها است.

ضریب همبستگی پیرسون که با نماد  $r$  نمایش داده می‌شود، یک شاخص آماری برای اندازه‌گیری شدت و جهت رابطه خطی میان دو متغیر کمی است که اندازه آن میان ۱+ (همبستگی مثبت کامل) تا ۱- (همبستگی منفی کامل) متغیر است و اندازه صفر نشان‌دهنده نبود رابطه خطی است (شوبر و همکاران ۲۰۱۸). در فرآیند انتخاب ویژگی، از روش Boruta به‌عنوان یک روش انتخاب ویژگی مبتنی بر جنگل تصادفی استفاده شد که می‌توان با تکیه بر آزمون فرضیه آماری، ویژگی‌های معنادار را از مجموعه داده‌ها استخراج کرد (کورسا و همکاران ۲۰۱۰). فرآیند Boruta شامل ایجاد نسخه‌های تصادفی از هر ویژگی (ویژگی‌های سایه)، اجرای الگوریتم جنگل تصادفی و اندازه‌گیری اهمیت هر ویژگی واقعی و ویژگی‌های سایه است. ویژگی‌هایی که اهمیت‌شان به‌طور معناداری بیشتر از اهمیت ویژگی‌های سایه باشد، در دسته تأییدشده، و آن‌هایی که کمتر باشند در دسته رد شده گذاشته می‌شوند، در حالی که ویژگی‌های نامشخص در وضعیت آزمایشی باقی می‌مانند و در تکرارهای جایگشتی بعدی بررسی می‌شوند (کورسا و رودنیسکی ۲۰۱۰). در این پژوهش، این فرآیند در چندین تکرار اجرا شد تا صحت انتخاب ویژگی‌ها مشخص شود. همچنین این فرآیند برای شاخص‌های پیوند از دور در تأخیرهای زمانی صفر تا شش ماهه اعمال شد تا مشخص شود کدام شاخص‌ها و در چه بازه زمانی بیشترین اثر را بر پیش‌بینی PM2.5 دارند. همزمان، رویکردهای مبتنی بر سنج‌های اهمیت ویژگی نیز به‌کار گرفته شد تا اثرگذارترین متغیرهای

پیش‌بینی برای مدل‌سازی غلظت ذرات PM2.5 شناسایی شوند. در گام بعدی، پنج مدل مختلف یادگیری ماشین شامل Bagged CART, Random Forest, Gradient Boosting, LightGBM و XGBoost پیاده‌سازی شدند. برای این مدل‌ها پس از دریافت داده‌های پیش‌پردازش شده و ویژگی‌های انتخابی، فرآیند آموزش انجام شد و سنج‌های هر یک با روش‌های بهینه‌سازی نظام‌مند تنظیم شد تا بیشترین سطح کارایی پیش‌بینی به‌دست آمد. برای بهینه‌سازی عملکرد مدل‌های یادگیری ماشین، سنج‌های مهم هر مدل با استفاده از اعتبارسنجی متقابل تعیین شدند. برای مدل Random Forest، تعداد درختان ۵۰۰ و تعداد ویژگی‌های انتخابی در هر تقسیم (mtry) برابر با ۲ و ۳ و ۴ انتخاب شد. در Bagged CART نیز تعداد درختان ۵۰۰ و ژرفای درخت‌ها به‌گونه‌ای تعیین شد که از بیش‌برازش جلوگیری شود. برای مدل‌های Gradient Boosting و XGBoost، تعداد درختان ۳۰۰، نرخ یادگیری ۰/۰۵ و ژرفای درخت ۴ در نظر گرفته شد، و در LightGBM تعداد درختان ۵۰۰، نرخ یادگیری ۰/۰۵ و ژرفای درخت ۵ انتخاب شد. تمام این سنج‌ها با اعتبارسنجی متقابل پنج برابر بهینه‌سازی شدند تا بهترین تعادل میان دقت و قابلیت تعمیم مدل‌ها فراهم شود. ورودی‌های مدل شامل شاخص‌های پیوند از دور بودند که برای مدل‌سازی PM2.5 استفاده شدند. در فرآیند ارزیابی مدل‌ها، ابتدا داده‌ها به‌طور تصادفی به دو بخش آموزشی (۷۰٪) و آزمایشی (۳۰٪) تقسیم شدند (غلامی و همکاران ۲۰۱۸). سپس، عملکرد مدل‌های توسعه‌یافته با سه شاخص RMSE، MAPE و R2 ارزیابی شد. با این معیارها به‌شکل جامع توانایی پیش‌بینی مدل‌ها در شرایط مختلف سنجش شد (الشماری و همکاران ۲۰۲۴). معیارهای ارزیابی با استفاده از رابطه‌های ۲ تا ۴ محاسبه شد (شارما و همکاران ۲۰۲۲).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (2)$$

این روش‌ها به شکل جامع در محیط نرم‌افزار R با استفاده از کتابخانه‌های تخصصی پیاده‌سازی شدند تا امکان شناسایی دقیق مهم‌ترین عامل‌های اثرگذار بر غلظت PM2.5، درک روابط غیرخطی میان متغیرها، ارزیابی تعاملات پیچیده میان عامل‌های مختلف، و سرانجام ارائه نتایج قابل تفسیر و معتبر از عملکرد مدل‌ها فراهم آید. روند نمای مراحل انجام پژوهش در شکل ۱ ارائه شده است. با این رویکرد تفسیرپذیری می‌توان هم اعتبار نتایج را افزایش داد و هم اطلاعات ارزشمندی برای تصمیم‌گیری‌های زیست‌محیطی و سیاست‌گذاری‌های مرتبط با کیفیت هوا ارائه داد. در مرحله پایانی، خروجی‌های پیش‌بینی تمام مدل‌ها با دقت تحلیل و ارزیابی شد.

### نتایج و بحث

تحلیل همبستگی شاخص‌های پیوند از دور در تأخیرهای مختلف با PM2.5 در ایستگاه‌های زاهدان و خاش همبستگی میان شاخص‌های پیوند از دور و غلظت ذرات PM2.5 در ایستگاه‌های زاهدان و خاش در شکل ۲ نشان داده شده است. بر اساس شکل ۲، نتایج تحلیل همبستگی در ایستگاه زاهدان نشان داد بیشترین همبستگی مثبت با غلظت PM2.5 مربوط به شاخص PDO (۰/۱۵۸) با تأخیر ۵ ماهه) و شاخص AMO (۰/۲۱۲) با تأخیر صفر ماهه) بود. از سوی دیگر، بیشترین همبستگی منفی با غلظت PM2.5 مربوط به شاخص AMM (-۰/۳۳۶) با تأخیر ۲ ماهه) و شاخص WHWP (-۰/۴۲۰) با تأخیر ۴ ماهه) بود. در ایستگاه خاش نیز بیشترین همبستگی مثبت با غلظت PM2.5 مربوط به شاخص PDO (۰/۱۵۹) با تأخیر ۲ ماهه) و بیشترین همبستگی منفی با غلظت PM2.5 مربوط به شاخص WHWP (-۰/۳۸۵) با تأخیر ۴ ماهه) بود. این یافته‌ها بیانگر آن است که اثر نوسانات اقیانوسی-جوی در مقیاس‌های مختلف زمانی و مکانی بر تغییرات غلظت ذرات PM2.5 در منطقه مطالعه شده معنادار بود. از این رو، از الگوهای همبستگی مشاهده شده با تأخیرهای مختلف ماهانه می‌توان در پیش‌بینی بلندمدت کیفیت هوا و شناسایی عامل‌های

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100 \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

$\hat{y}_i$ : اندازه پیش‌بینی شده،  $y_i$ : ارزش واقعی برای  $i$ امین داده،  $n$ : تعداد مشاهده‌ها و  $\bar{y}$ : اندازه میانگین متغیر وابسته است.

در این پژوهش، به منظور افزایش تفسیرپذیری مدل‌های یادگیری ماشین، از چهار روش SHAP، Sobol، PFI و PDP استفاده شد. روش SHAP بر اساس الگوریتم TreeSHAP در مدل XGBoost پیاده‌سازی شد و اهمیت هر ویژگی با ۱۰۰۰ تکرار نمونه‌برداری محاسبه شد. با استفاده از رابطه ۵ ارزش Shapley محاسبه شد (لاندرگ و لی ۲۰۱۷).

$$\Phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(M-|S|-1)!}{M!} \Delta f(S, i) \quad (5)$$

اندازه  $\Phi_i$  اندازه SHAP برای ویژگی  $i$ ،  $N$ : مجموعه تمام ویژگی‌ها،  $S$ : زیرمجموعه‌ای از ویژگی‌ها به جز  $i$ ،  $M$ : تعداد کل ویژگی‌ها،  $\Delta f(S, i)$ : تغییر در پیش‌بینی مدل وقتی ویژگی  $i$  به مجموعه  $S$  اضافه شود.

تحلیل حساسیت Sobol با استفاده از روش Monte Carlo و ۱۰<sup>۴</sup> نمونه برای برآورد سهم نسبی و تعاملی متغیرها انجام شد. با استفاده از رابطه ۶ شاخص سوبول مرتبه اول  $S_i$  محاسبه شد. با استفاده از رابطه ۷ شاخص کل سوبول  $S_{Ti}$  تعیین شد (هوما و سالتلی ۱۹۹۶).

$$S_i = \frac{V_{X_i}(E_{X_{\sim i}}(Y|X_i))}{V(Y)} \quad (6)$$

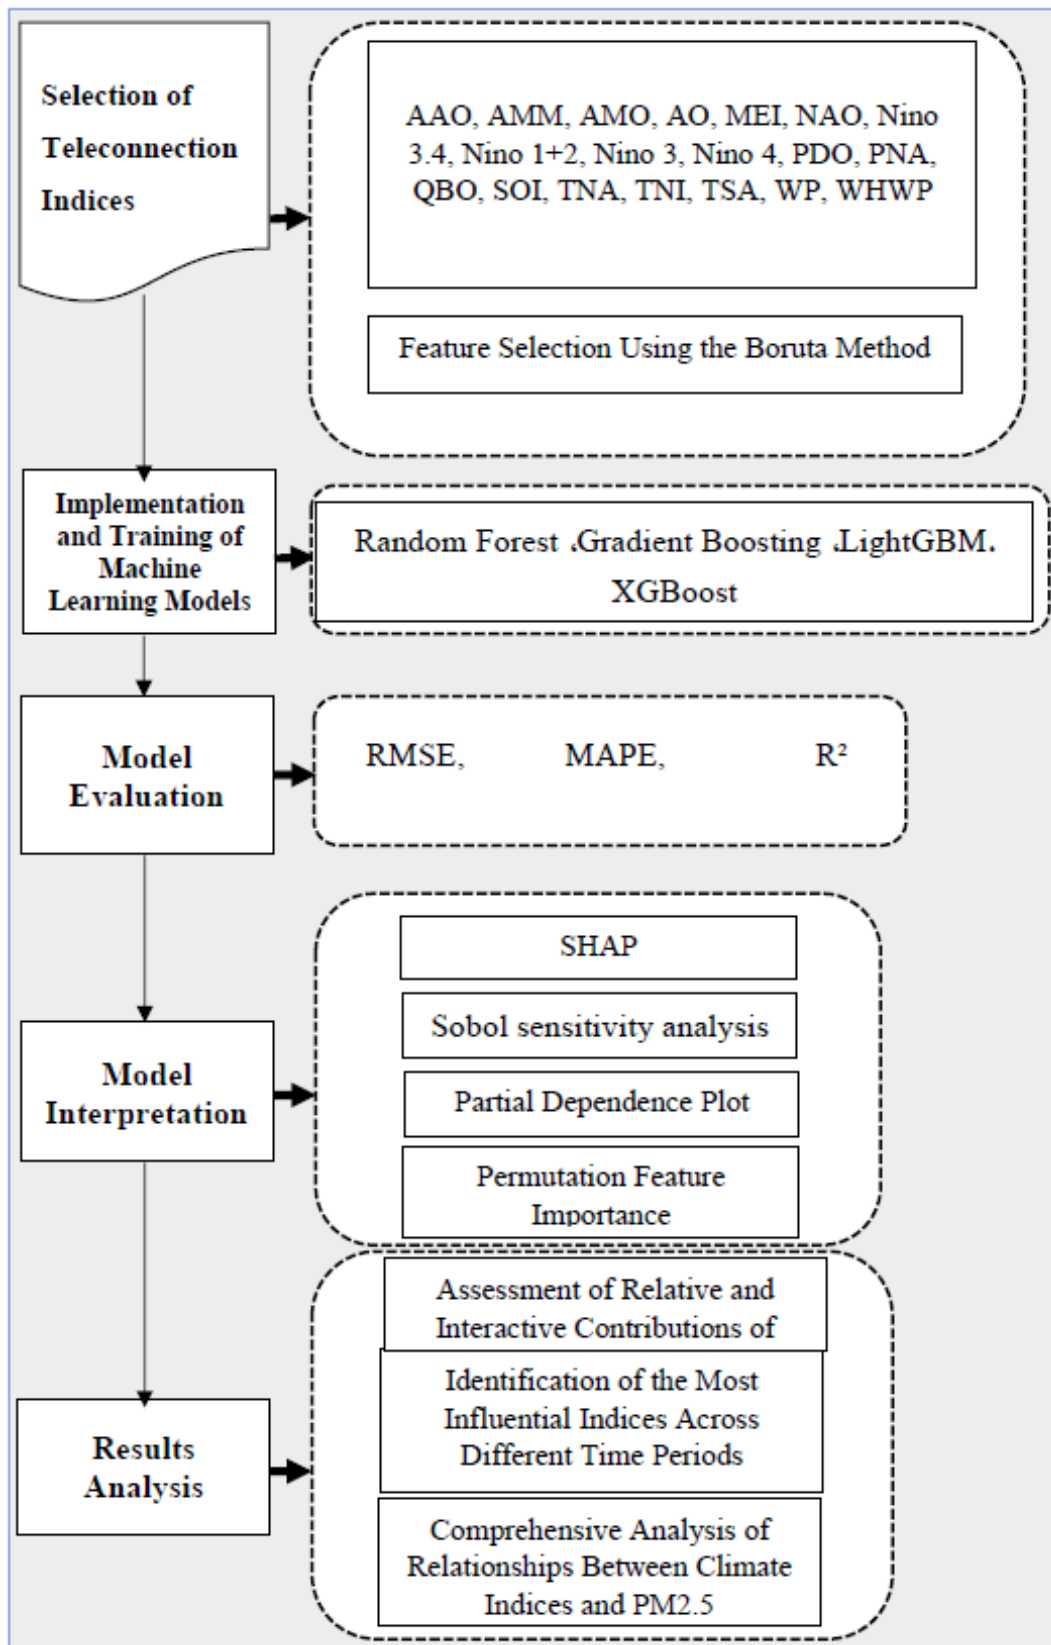
$$S_{Ti} = \frac{E_{X_i}(V_{X_i}(Y|X_{\sim i}))}{V(Y)} \quad (Y) = 1 - \frac{V_{X_{\sim i}}(E_{X_i}(Y|X_{\sim i}))}{V(Y)} \quad (7)$$

$V(Y)$ : پراکنش کل خروجی مدل،  $E_{X_{\sim i}}$ : امید ریاضی نسبت به تمام متغیرها به جز متغیر  $i$ ،  $V_{X_i}$ : پراکنش نسبت به متغیر  $i$ ،  $(Y|X_{\sim i})$ : خروجی مدل به شرط متغیر  $i$ ،  $X_i$  ویژگی مد نظر است.

روش PFI با جایگشت تصادفی ویژگی‌ها و اندازه‌گیری کاهش عملکرد مدل (RMSE) به کار گرفته شد. در پایان، نمودارهای PDP برای نمایش روابط غیرخطی میان شاخص‌های انتخاب شده و PM2.5 رسم شد.

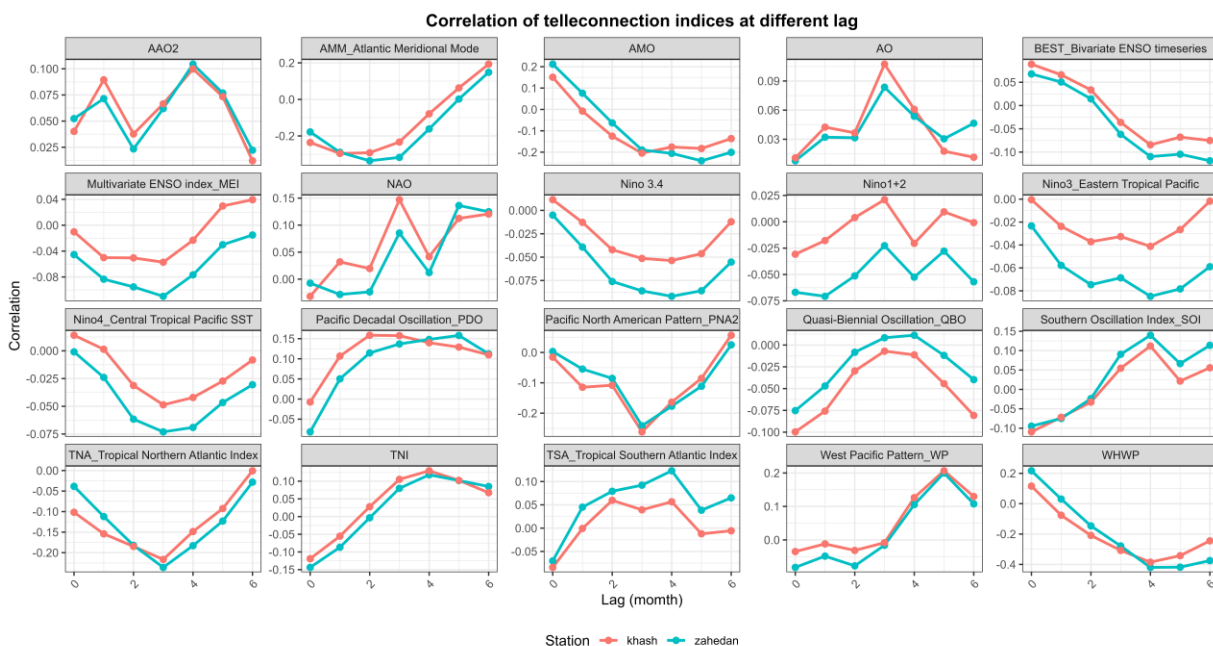
۴ Partial Dependence Plot (PDP)

مهم اثرگذار بر تغییرات غلظت ذرات معلق استفاده کرد.



شکل ۱- روند نمای مراحل پژوهش.

Figure 1- Flowchart of the research methodology steps.



شکل ۲- همبستگی شاخص‌های پیوند از دور با تأخیرهای مختلف با PM2.5 در ایستگاه‌های زاهدان و خاش.

Figure 2- Correlation of Teleconnections Indices at Different Lags with PM2.5 at the Zahedan and Khash Stations.


۰/۹۹ برای TNA با تأخیر ۴ ماهه) رد شدند. شاخص‌های WHWP و AMM با تأخیرهای خاص، در پیش‌بینی PM2.5 در ایستگاه زاهدان نقش مهمی داشتند. در حالی که AMO فقط با تأخیر صفر ماهه اثرگذار بود و دیگر شاخص‌ها تأثیر کم‌تری نشان دادند یا با برخی تأخیرها کاملاً بی‌اثر بودند. بیشترین تأثیر بر غلظت PM2.5 مربوط به شاخص WHWP (به‌ویژه با تأخیرهای بیشتر ۴ تا ۶ ماهه) بود که می‌تواند به دلیل اثرات ناهنجاری‌های دمایی در آب‌خیز اقیانوس اطلس غربی بر گردش عمومی جو و تغییر در موقعیت جت جنب‌حاره‌ای جنوب ایران باشد. این تغییرات سبب تعدیل شدت بادهای ۱۲۰ روزه سیستان و مسیر انتقال گرد و غبار از بستر هامون می‌شوند. از سوی دیگر، شاخص AMM بیانگر ناهمسانی‌های دمایی سطح دریا در اقیانوس اطلس شمالی بود که بر الگوهای همرفت استوایی و در نتیجه بر الگوهای فشار در جنوب غرب آسیا اثرگذار بود و موجب افزایش ناپایداری‌های جوی و خیزش گرد و غبار در بازه‌های زمانی کوتاه‌تر (تأخیرهای ۰ تا ۳ ماهه) شد. شاخص

تحلیل انتخاب ویژگی با روش Boruta در ایستگاه زاهدان

نتایج انتخاب ویژگی با روش Boruta در ایستگاه زاهدان در شکل ۳ نشان داده شده است. نتایج تحلیل نشان‌دهنده اهمیت متفاوت شاخص‌های پیوند از دور در پیش‌بینی PM2.5 بود. شاخص AMO فقط با تأخیر صفر ماهه و با میانگین اهمیت ۱۰/۵۷ و میانه ۱۰/۶۴ به‌عنوان ویژگی تأییدشده شناسایی شد، در حالی که با تأخیرهای ۳ تا ۶ ماهه رد شد. شاخص WHWP با تأخیرهای ۳ تا ۶ ماهه با بیشترین اهمیت تأیید شد، به‌ویژه با تأخیر ۶ ماهه با میانگین اهمیت ۱۳/۶۳ و میانه ۱۳/۵۵ بیشترین اهمیت را نشان داد. AMM با تأخیرهای ۰ تا ۳ ماهه، میانگین اهمیت میان ۳/۵۷ تا ۶/۶۴ را نشان داد و با بیشترین میانگین اهمیت با تأخیر ۲ ماهه ۶/۶۴ تأیید شد. از سوی دیگر، شاخص‌های Pacific North American Pattern (PNA) با تأخیرهای ۳ و ۴ ماهه، TNA با تأخیرهای ۲ تا ۴ ماهه، و West Pacific (WP) با تأخیر ۵ ماهه به دلیل اهمیت کم (به‌طور مثال میانگین اهمیت

یک از شاخص‌های اقلیمی نامبرده، با سازوکاری خاص بر انتقال جرم، تغییر الگوهای باد و نوسانات فشار، نقش متمایزی در مهار غلظت  $PM_{2.5}$  در منطقه سیستان اثرگذار بودند.

AMO نیز با تغییرات بلندمدت در دمای سطح اقیانوس اطلس شمالی بر وضعیت بارشی ایران و نواحی مجاور اثرگذار بود و با تأخیر صفر ماهه با افزایش رطوبت نسبی و کاهش موقت غلظت ذرات معلق، همبستگی مثبت ضعیفی نشان داد. از این رو، هر




شکل ۳- انتخاب ویژگی با روش Boruta در ایستگاه زاهدان.

Figure 3- Feature selection with Boruta method at Zahedan Station.

شاخص‌های PDO با تأخیرهای ۲ و ۳ ماهه با میانگین اهمیت ۵/۶۶ و ۵/۱۲ و شاخص PNA با تأخیر ۳ ماهه با میانگین اهمیت ۳/۶۲ نیز به‌عنوان ویژگی‌های تأییدشده شناخته شدند. شاخص WHWP با تأخیرهای ۲ تا ۶ ماهه تأیید شد. بیشترین میانگین اهمیت این شاخص با تأخیر ۵ ماهه با میانگین ۱۰/۵۱ و میانه ۱۰/۴۶ بود. از سوی دیگر، شاخص‌های TNA با تمام تأخیرها (۱، ۲ و ۳ ماهه) و WP با تأخیر ۵ ماهه به‌دلیل اهمیت کم (به‌طور مثال شاخص WP با میانگین اهمیت ۰/۷۷ با تأخیر ۵ ماهه) رد شدند. این نتایج بیانگر نقش مهم شاخص‌های AMO، PDO، AMM و WHWP در  $PM_{2.5}$  در ایستگاه خاش بود، در حالی که اثر دیگر شاخص‌ها کمتر بود.

تحلیل انتخاب ویژگی با روش Boruta در ایستگاه خاش

نتایج انتخاب ویژگی با روش Boruta در ایستگاه خاش در شکل ۴ نشان داده شده است. نتایج این شکل بیانگر اهمیت قابل توجه شاخص‌های پیوند از دور در پیش‌بینی  $PM_{2.5}$  بود. شاخص‌های AMM با تمام تأخیرهای بررسی‌شده (به جز تأخیرهای ۴ و ۵ ماهه) به‌عنوان ویژگی‌های تأییدشده شناسایی شد که بیشترین میانگین اهمیت این شاخص با تأخیر ۶ ماهه و میانگین ۴/۴۵ و میانه ۴/۶۲ بود. شاخص AMO فقط با تأخیر صفر ماهه با میانگین اهمیت ۵/۶۱ و میانه ۵/۶۱ به‌عنوان ویژگی تأییدشده انتخاب شد، در حالی که با تأخیرهای ۳، ۴ و ۵ ماهه رد شد.

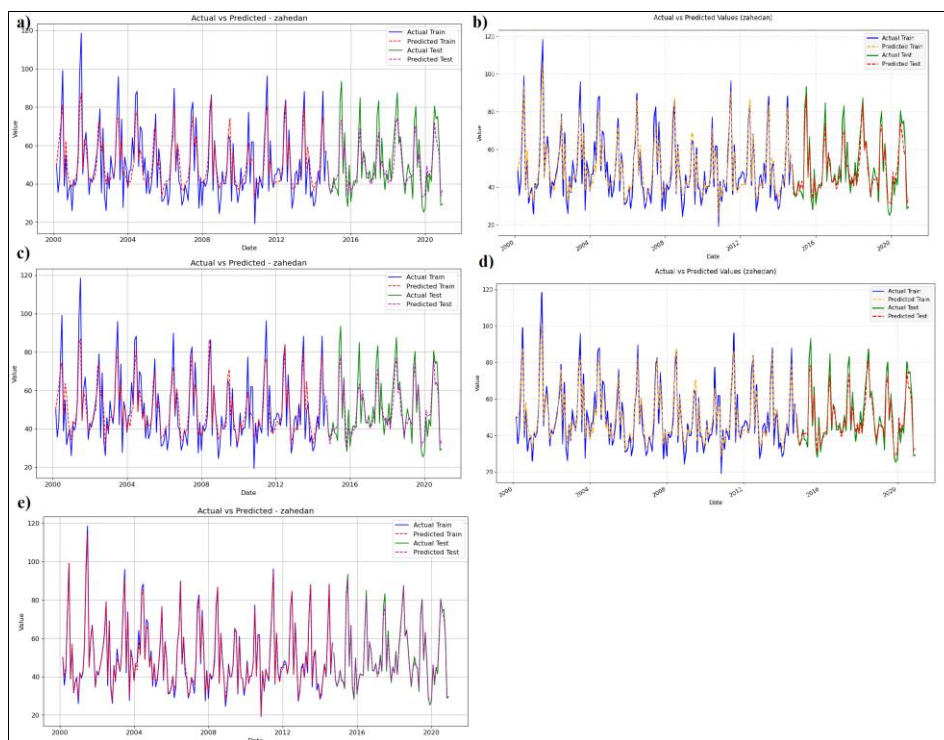


شکل ۴- انتخاب ویژگی با روش Boruta در ایستگاه خاش.

Figure 4-Feature selection with Boruta method at Khash Station.

بیش‌برآورد بود. عملکرد مدل Gradient Boosting در پیش‌بینی روند کلی خوب بود، اما در اندازه‌های حدی دچار خطا شد. عملکرد مدل Random Forest در سال‌های مختلف متغیر بود. به‌طور مثال دقت آن در ۲۰۱۴ خوب بود اما در ۲۰۱۵ برای اندازه‌های زیاد خطای بیشتری داشت. به‌طور کلی پایدارترین عملکرد با کمترین انحراف مربوط به مدل XGBoost بود، اگرچه در اندازه‌های بیش از ۷۰ کم‌برآورد بود. الگوی مشترک در تمام مدل‌ها آن بود که دقت آنها در پیش‌بینی اندازه‌های متوسط (۴۰-۷۰) در مقایسه با اندازه‌های حدی، زیاد بود و تمام مدل‌ها روند کلی تغییرات PM2.5 را با دقت‌های متفاوتی پیش‌بینی کردند. این موضوع بیانگر امکان استفاده از آنها با در نظر گرفتن محدودیت‌هایشان در سامانه‌های پایش کیفیت هوا است.

پیش‌بینی PM2.5 با استفاده از مدل‌های یادگیری ماشین در ایستگاه زاهدان مقایسه عملکرد مدل‌های مختلف یادگیری ماشین (Gradient Boosting, LightGBM, Bagged CART) در پیش‌بینی شاخص PM2.5 در ایستگاه زاهدان استان سیستان و بلوچستان در شکل ۵ نشان‌داده شده است. نتایج عملکرد مدل‌های مختلف در پیش‌بینی غلظت PM2.5 در ایستگاه زاهدان نشان داد که هر مدل نقاط قوت و ضعف ویژه‌ای دارد. دقت عملکرد مدل Bagged CART در پیش‌بینی اندازه‌های کم (۳۰-۵۰ میکروگرم بر مترمکعب) خوب بود (اختلاف کمتر از ۵ واحد)، اما در اندازه‌های زیاد (بیش از ۸۰) کم‌برآورد بود. عملکرد مدل LightGBM در بخش آموزش قابل قبول بود، اما در داده‌های آزمون به‌ویژه در اندازه‌های زیاد کم‌برآورد بود و در اندازه‌های کم



شکل ۵- پیش‌بینی PM2.5 با مدل‌های (a) Bagged CART (b) Gradient Boosting (c) Random Forest (d) LightGBM (e) XGBoost در ایستگاه زاهدان.

Figure 5- PM2.5 prediction with a) Bagged CART b) Gradient Boosting c) Random Forest d) LightGBM e) XGBoost models at Zahedan Station.

نتایج ارزیابی مدل‌های پیش‌بینی برای ایستگاه زاهدان در جدول ۱ ارائه شده است. این نتایج نشان داد که بهترین عملکرد با اختلاف قابل توجه با دیگر مدل‌ها بر اساس تمام معیارهای ارزیابی شده مربوط به مدل XGBoost بود. در هر دو مجموعه داده‌های آموزشی و آزمایشی ضریب تبیین این مدل ۰/۹۸۹ بود و کمترین اندازه خطای مربعات میانگین (RMSE) و کمترین درصد خطای مطلق میانگین (MAPE=۰/۳۰۷-۲/۳۶) مربوط به مدل XGBoost بود که این موضوع بیانگر دقت استثنایی و قابلیت تعمیم‌پذیری فوق‌العاده این مدل بود. مدل Random Forest (MAPE=۰/۱۵۲-۱۲/۱۸ و  $R^2=0/766-0/787$ ) به‌عنوان ضعیف‌ترین مدل شناخته شد و به‌رغم عملکرد نسبتاً مطلوب در داده‌های آزمایشی، برای استفاده عملی در ایستگاه زاهدان مناسب نیست. این نتایج هم بیانگر برتری مطلق مدل XGBoost در ایستگاه زاهدان بود و هم برخلاف برخی ایستگاه‌های دیگر، تفاوت محسوسی میان عملکرد Random Forest و Gradient Boosting مشاهده نشد. از این رو، می‌توان از هر دو مدل به‌عنوان گزینه‌های جایگزین مناسب بهره برد، هرچند نتایج آنها به اندازه مدل XGBoost دقت و پایداری ندارند.

در جدول ۱ ارائه شده است. این نتایج نشان داد که بهترین عملکرد با اختلاف قابل توجه با دیگر مدل‌ها بر اساس تمام معیارهای ارزیابی شده مربوط به مدل XGBoost بود. در هر دو مجموعه داده‌های آموزشی و آزمایشی ضریب تبیین این مدل ۰/۹۸۹ بود و کمترین اندازه خطای مربعات میانگین (RMSE) و کمترین درصد خطای مطلق میانگین (MAPE=۰/۳۰۷-۲/۳۶) مربوط به مدل XGBoost بود که این موضوع بیانگر دقت استثنایی و قابلیت تعمیم‌پذیری فوق‌العاده این مدل بود. مدل Random Forest (MAPE=۰/۱۵۲-۱۲/۱۸ و  $R^2=0/766-0/787$ ) به‌عنوان ضعیف‌ترین مدل شناخته شد و به‌رغم عملکرد نسبتاً مطلوب در داده‌های آزمایشی، برای استفاده عملی در ایستگاه زاهدان مناسب نیست. این نتایج هم بیانگر برتری مطلق مدل XGBoost در ایستگاه زاهدان بود و هم برخلاف برخی ایستگاه‌های دیگر، تفاوت محسوسی میان عملکرد Random Forest و Gradient Boosting مشاهده نشد. از این رو، می‌توان از هر دو مدل به‌عنوان گزینه‌های جایگزین مناسب بهره برد، هرچند نتایج آنها به اندازه مدل XGBoost دقت و پایداری ندارند.

جدول ۱- مقایسه مدل‌های یادگیری ماشین برای پیش‌بینی PM<sub>2.5</sub> در ایستگاه زاهدان.

Table 1- Comparison of machine learning models for PM<sub>2.5</sub> prediction at Zahedan Station.

Model	RMSE		MAPE		R <sup>2</sup>	
	Train	Test	Train	Test	Train	Test
Bagged CART	8.556	7.584	15.211	12.180	0.766	0.787
LightGBM	8.657	6.794	14.130	10.560	0.760	0.829
Gradient Boosting	5.493	5.097	9.548	8.187	0.904	0.904
Random Forest	5.395	4.769	9.678	7.256	0.907	0.916
XGBoost	1.896	1.724	3.073	2.355	0.989	0.989

پیش‌بینی PM<sub>2.5</sub> با استفاده از مدل‌های یادگیری

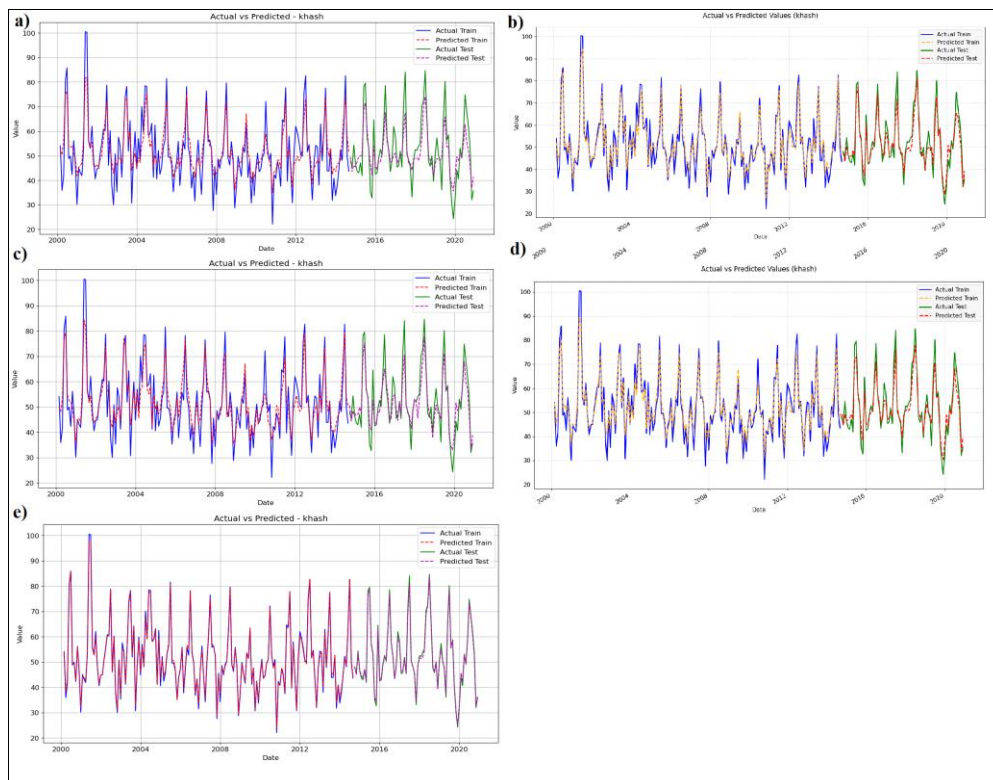
ماشین در ایستگاه خاش

نتایج عملکرد پنج مدل یادگیری ماشین ( Bagged CART, Gradient Boosting, LightGBM, Random Forest

در پیش‌بینی غلظت PM<sub>2.5</sub> در ایستگاه خاش در شکل ۶ نشان داده شده است. این نتایج بیانگر آن بود که دقت و کارایی این مدل‌ها با یکدیگر متفاوت بود. عملکرد مدل

Bagged CART در پیش‌بینی روند کلی تغییرات

نسبتاً خوب بود اما در تغییرات کوتاه‌مدت و سال‌های گذشته (۲۰۱۶-۲۰۲۰) دچار خطا شد. عملکرد مدل LightGBM در پیش‌بینی اندازه‌های متوسط (۴۰-۷۰ میکروگرم بر مترمکعب) با اختلاف کمتر از ۵ واحد بهتر بود و دقت آن در پیش‌بینی نوسانات کوتاه‌مدت مناسب بود.



شکل ۶- پیش‌بینی PM<sub>2.5</sub> با مدل‌های (a) Bagged CART (b) Gradient Boosting (c) Random Forest (d) LightGBM (e) XGBoost در ایستگاه خاش.

Figure 6- AOD prediction with a) Bagged CART b) Gradient Boosting c) Random Forest d) LightGBM e) XGBoost models at Khash Station.

کمترین اندازه خطا ( $RMSE=1/1$ ) و  $1/5-$   $(MAPE=1/18)$  در مقایسه با دیگر مدل‌ها به‌عنوان برترین مدل شناخته شد. عملکرد مدل Gradient Boosting ( $R^2=0/915$  و  $MAPE=0/618-6/0$ ) و مدل Random Forest ( $R^2=0/900-0/894$  و  $MAPE=0/7/5$ ) قابل قبول بود هرچند ضعیف‌تر از مدل XGBoost بودند. اگرچه عملکرد مدل LightGBM در مقایسه با دو مدل قبلی ضعیف‌تر ( $R^2=0/832-0/810$  و  $MAPE=0/9/9-8/3$ ) بود، اما همچنان از مدل Bagged CART ( $0/733-$   $R^2=0/755$  و  $MAPE=0/11/6-10/8$ ) که نتایج ضعیف‌تری را ثبت کرده بود، به‌مراتب بهتر بود. بر پایه نتایج این پژوهش بهترین عملکرد در پیش‌بینی بر اساس تمام معیارهای ارزیابی شده مربوط به مدل XGBoost در ایستگاه خاش بود. در حالی که مدل‌های Gradient Boosting و Random Forest گزینه‌های مناسبی برای شرایطی با محدودیت محاسباتی بودند. مدل Bagged CART به‌دلیل عملکرد ضعیف در تمام معیارها، گزینه مناسبی برای ایستگاه خاش نبود. نتایج ارزیابی مدل‌ها در این مرحله نیز بیانگر برتری الگوریتم‌های boosting به‌ویژه XGBoost در حل مسائل پیش‌بینی بود.

عملکرد مدل Gradient Boosting در یادگیری الگوهای داده‌های آموزشی خوب بود اما در مواجهه با اندازه‌های حدى در داده‌های آزمون دچار خطا شد. دقت مدل Random Forest در پیش‌بینی اندازه‌های متوسط خوب بود اما در اندازه‌های بسیار زیاد کم‌برآورد بود. بهترین عملکرد و بیشترین دقت در هر دو بخش آموزش و آزمون در میان تمام مدل‌ها مربوط به مدل XGBoost بود، به‌طوری که برای اندازه‌های اندازه‌های زیاد نتایج این مدل بسیار دقیق بود. الگوی مشترک در تمام مدل‌ها آن بود که دقت آنها در پیش‌بینی اندازه‌های متوسط در مقایسه با اندازه‌های حدى، بیشتر بود. بیشترین دقت و کمترین خطا در پیش‌بینی تغییرات ماهانه و فصلی مربوط به مدل XGBoost بود. از این رو این مدل به‌عنوان مناسب‌ترین مدل برای پیش‌بینی کیفیت هوا در منطقه خاش شناخته شد. نتایج ارزیابی مدل‌های پیش‌بینی برای ایستگاه خاش در جدول ۲ ارائه شده است. نتایج نشان داد که بهترین عملکرد هم در داده‌های آموزشی ( $R^2=0/993$ ) و هم در داده‌های آزمایشی ( $R^2=0/994$ ) مربوط به مدل XGBoost بود. دقت زیاد این مدل نتیجه پیش‌پردازش کامل داده‌ها و انتخاب ویژگی بهینه با Boruta بود. این مدل با

جدول ۲- مقایسه مدل‌های یادگیری ماشین برای پیش‌بینی  $PM_{2.5}$  در ایستگاه خاش.

Table 2- Comparison of machine learning models for  $PM_{2.5}$  prediction at Khash Station.

Model	RMSE		MAPE		$R^2$	
	Train	Test	Train	Test	Train	Test
Bagged CART	6.720	6.798	11.617	10.783	0.755	0.733
LightGBM	5.905	5.386	9.915	8.266	0.810	0.832
Gradient Boosting	3.963	3.937	6.751	6.007	0.915	0.911
Random Forest	4.420	4.163	7.542	6.463	0.894	0.900
XGBoost	1.099	1.020	1.786	1.489	0.993	0.994

مقایسه روش‌های تحلیل اهمیت و حساسیت متغیرها

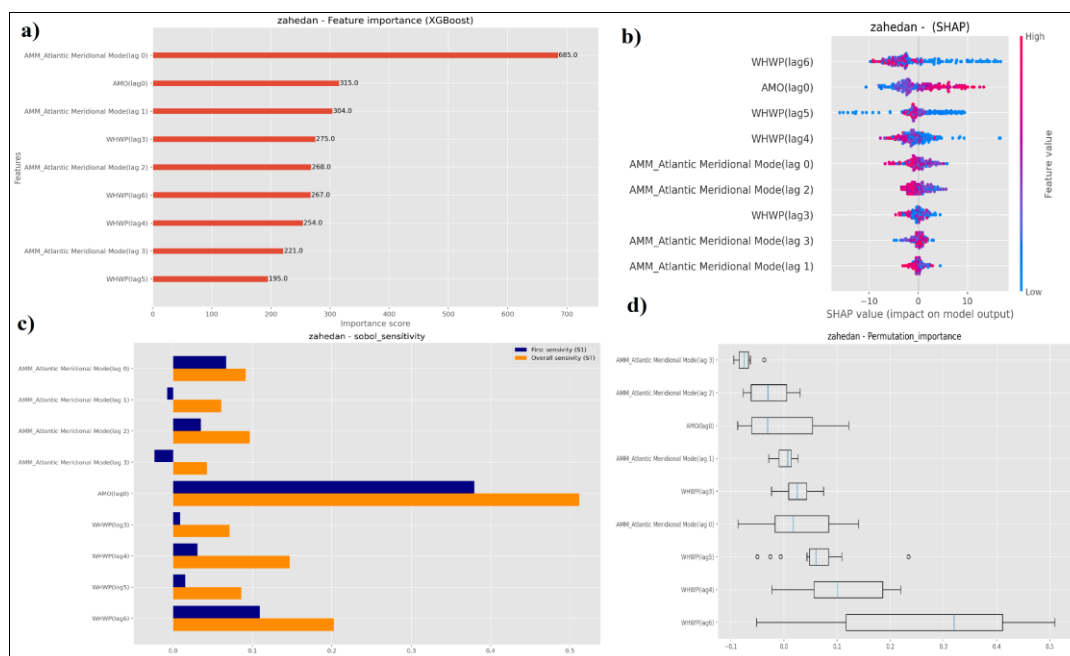
در پیش‌بینی مدل در ایستگاه زاهدان

AMM و AMO در پیش‌بینی کیفیت هوا اثرگذار و پیچیده بود. بر اساس نتایج تحلیل اهمیت ویژگی‌های XGBoost، شاخص AMM در حالت بدون تأخیر با امتیاز اهمیت ۶۸۵ به‌عنوان اثرگذارترین عامل

تحلیل جامع شاخص‌های اقلیمی اثرگذار بر پیش‌بینی  $PM_{2.5}$  در ایستگاه زاهدان با استفاده از روش‌های مختلف تفسیر مدل در شکل ۷ نشان‌دهنده شده است. نتایج تحلیل بیانگر آن بود که نقش شاخص‌های

نشان داد نقش شاخص‌های مرتبط با اقیانوس اطلس (AMM و AMO) در مقایسه با شاخص‌های اقیانوس آرام (WHWP) در پیش‌بینی PM<sub>2.5</sub> اثرگذارتر و مهم‌تر بود. اگرچه نقش WHWP با تأخیرهای مختلف در مدل قابل توجه بود. از این رو، می‌توان گفت در ایستگاه زاهدان روند پیش‌بینی PM<sub>2.5</sub> تحت تأثیر تعامل پیچیده‌ای از الگوهای اقلیمی هر دو اقیانوس اطلس و آرام است، با این حال در تمام روش‌های تحلیل شاخص‌های مرتبط با اقیانوس اطلس اثرگذارتر و پایدارتر بودند.

شناسایی شد، در حالی که شاخص AMO در حالت بدون تأخیر (۳۱۵) و شاخص AMM با تأخیر ۱ (۳۰۴) در رتبه‌های بعدی بودند. نتایج تحلیل SHAP نشان داد بیشترین اثر مثبت بر غلظت PM<sub>2.5</sub> مربوط به WHWP با تأخیر ۶ بود و اثر AMO در حالت بدون تأخیر نیز افزایشی بود. نتایج تحلیل حساسیت Sobol بیانگر آن بود که بیشترین حساسیت در حالت بدون تأخیر مربوط به AMO بود و WHWP با تأخیر ۶ در رتبه بعدی بود. بر اساس نتایج تحلیل اهمیت جایگشت اثرگذارترین متغیر WHWP با تأخیر ۶ شناسایی شد. در ایستگاه زاهدان این یافته‌ها



شکل ۷- (a) نمودار اهمیت ویژگی (b) تغییرات شاخص‌های اقلیمی با روش SHAP (c) تحلیل حساسیت شاخص‌ها با روش Sobol (d) تحلیل اهمیت جایگشت شاخص‌ها در ایستگاه زاهدان


Figure 7- a) Feature importance diagram b) Changes in climatic indicators using the SHAP method c) Sensitivity analysis of indicators using the Sobol method d) Analysis of the importance of permutation of indicators at Zahedan Station.

غیرخطی و شدید بود و در محدوده‌های خاصی از اندازه‌ها سبب تغییرات ناگهانی در پیش‌بینی‌های مدل شد که احتمالاً ناشی از آستانه‌های بحرانی در سامانه‌های اقلیمی منطقه است. از سوی دیگر، اثرات شاخص AMM (با تأخیرهای ۱ و ۳) تدریجی‌تر و پایدارتر بود که نشان‌دهنده شیوه‌های متفاوت اثرگذاری این شاخص بر کیفیت هوا بود، به طوری که

تحلیل وابستگی جزئی (PDP) شاخص‌های اقلیمی بر پیش‌بینی PM<sub>2.5</sub> در ایستگاه زاهدان در شکل ۸ ارائه شده است. نتایج این تحلیل نشان داد رابطه شاخص AMO (با تأخیر صفر) با غلظت PM<sub>2.5</sub> رابطه صعودی و یکنواخت بود و افزایش آن مستقیماً منجر به افزایش آلودگی شد، در حالی که رابطه شاخص‌های WHWP به‌ویژه در تأخیرهای ۳ و ۴

خروجی مدل مانند AMO خطی و مستقیم است، در حالی که اثرات برخی دیگر مانند WHWP محدوددهای خاصی از اندازه‌ها، ناگهانی و غیرقابل پیش‌بینی است. این موضوع بیانگر اهمیت تعاملات پیچیده اقلیمی و آستانه‌های بحرانی در مدل‌سازی کیفیت هوا است.

در برخی شرایط افزایش AMM منجر به کاهش PM2.5 شد که دلیل آن تغییرات الگوهای گردشی جو است. این یافته‌ها بیانگر آن است که با بهره‌گیری از مدل XGBoost می‌توان روابط غیرخطی و چند بعدی میان شاخص‌های اقلیمی و غلظت PM2.5 را شناسایی کرد، به طوری که اثر برخی شاخص‌ها بر



شکل ۸- بررسی عملکرد مدل در برابر تغییرات شاخص‌های اقلیمی با استفاده از تحلیل PDP در ایستگاه زاهدان.  
Figure 8- Investigating the behavior of the model against changes in climatic indicators using PDP analysis at Khash Station.

#### مقایسه روش‌های تحلیل اهمیت و حساسیت متغیرها

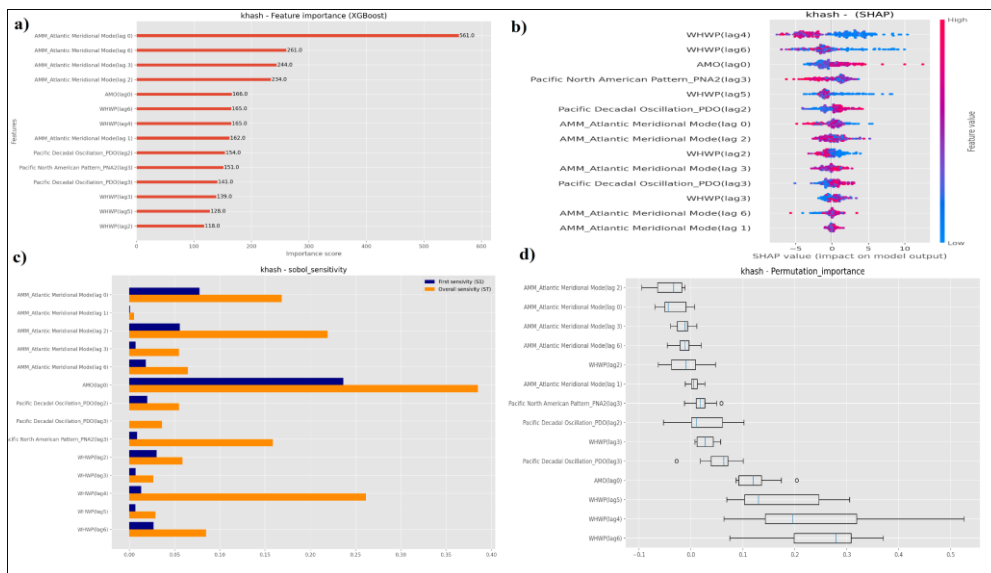
##### بر پیش‌بینی مدل در ایستگاه خاش

(امتیاز ۲۴۴) نیز قابل توجه بود. نتایج تحلیل SHAP نشان داد بیشترین اثر مثبت مربوط به WHWP با تأخیر ۴ و ۶ بود، در حالی که اثر AMO با تأخیر صفر بر غلظت PM2.5 نیز افزایشی بود. نتایج تحلیل حساسیت Sobol نشان داد بیشترین حساسیت مربوط به AMO با تأخیر صفر بود و در رتبه بعدی WHWP با تأخیر ۴ بود. بر اساس نتایج تحلیل PFI شاخص WHWP با تأخیر ۴ (امتیاز اهمیت ۰/۵) به‌عنوان اثرگذارترین متغیر شناسایی شد که حذف آن

تحلیل جامع شاخص‌های اقلیمی اثرگذار بر پیش‌بینی PM2.5 در ایستگاه خاش با استفاده از روش‌های مختلف تفسیر مدل در شکل ۹ ارائه شده است. نتایج این تحلیل نشان داد که نقش شاخص‌های AMM و WHWP در پیش‌بینی کیفیت هوا مهم و پیچیده بود. بر اساس تحلیل اهمیت ویژگی‌های XGBoost، شاخص AMM با تأخیر صفر و امتیاز اهمیت ۵۶۱ به‌عنوان اثرگذارترین عامل شناسایی شد، در حالی که اثر شاخص AMM با تأخیر ۶ (امتیاز ۲۶۱) و تأخیر ۳

WHWP) اثرگذارتر و پایدارتر بودند. می‌توان گفت این نتایج مبنای علمی مناسبی برای انتخاب بهینه متغیرهای ورودی در توسعه مدل‌های پیش‌بینی کیفیت هوا در منطقه مطالعه شده است.

سبب بیشترین کاهش دقت مدل می‌شود. یافته‌ها نشان داد پیش‌بینی PM<sub>2.5</sub> در خاش تحت تأثیر تعامل پیچیده‌ای از الگوهای اقلیمی هر دو اقیانوس اطلس و آرام است، با این حال در تمام روش‌های تحلیل شاخص‌های مرتبط با اقیانوس آرام (به‌ویژه

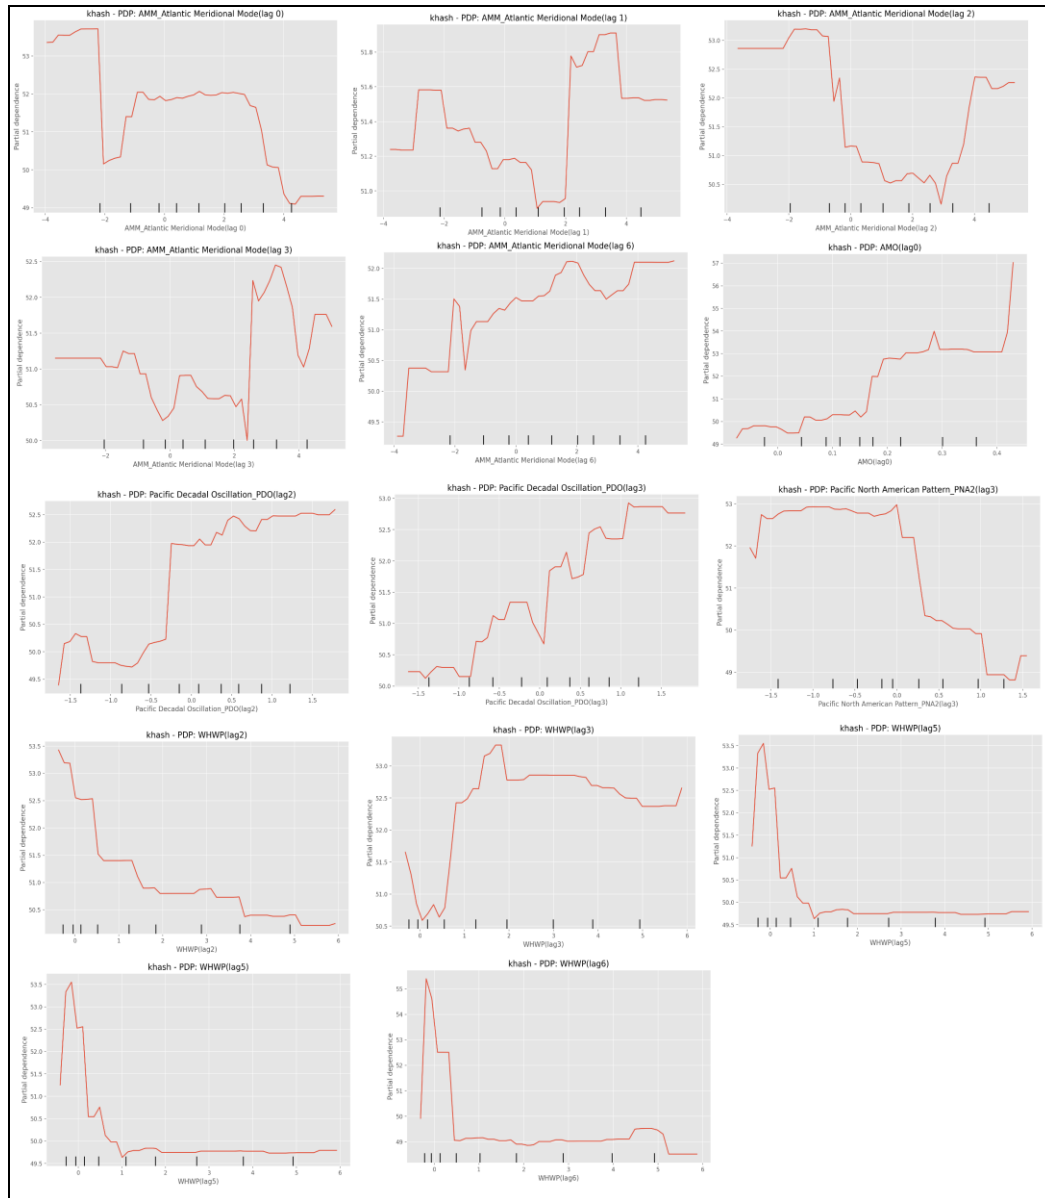


شکل ۹- a) نمودار اهمیت ویژگی (b) تغییرات شاخص‌های اقلیمی با روش SHAP (c) تحلیل حساسیت شاخص‌ها با روش Sobol (d) تحلیل اهمیت جایگشت شاخص‌ها در ایستگاه خاش.

Figure 9- a) Feature importance diagram b) Changes in climatic indicators using the SHAP method c) Sensitivity analysis of indicators using the Sobol method d) Analysis of the importance of permutation of indicators at Khash Station.

بر پیش‌بینی‌ها، کاهش غیرمنتظره‌ای بود. اثر شاخص WHWP بر غلظت PM<sub>2.5</sub> نیز با تأخیرهای متفاوت، متغیر بود. به طوری که اثر این شاخص با تأخیر ۵ ناگهان کاهش و با تأخیر ۳ ابتدا افزایشی و سپس کاهش بود. این موضوع گویای روابط پیچیده و وابسته به اندازه این شاخص‌ها است و سرانجام می‌توان نتیجه گرفت عملکرد مدل XGBoost در شناسایی و مدل‌سازی این روابط غیرخطی چندبعدی میان شاخص‌های اقلیمی و آلودگی هوا در منطقه خاش بسیار زیاد بود.

تحلیل نمودارهای PDP برای ایستگاه خاش در شکل ۱۰ ارائه شده است. نتایج نشان داد اثرات شاخص‌های اقلیمی مختلف بر پیش‌بینی غلظت PM<sub>2.5</sub> پیچیده و غیرخطی بود، به طوری که شاخص AMM بدون تأخیر ابتدا با افزایش اندازه‌های منفی سبب افزایش PM<sub>2.5</sub> شد اما پس از نقطه بحرانی روند معکوس شد، در حالی که با تأخیر ۱ این الگو با حساسیت متفاوتی تکرار شد و با تأخیرهای ۲، ۳ و ۶ اثری متفاوت و شدید مشاهده شد که بیانگر حساسیت مدل به اندازه‌های خاصی از این شاخص بود. از سوی دیگر، رابطه شاخص AMO در حالت بدون تأخیر با غلظت PM<sub>2.5</sub> مثبت و یکنواخت بود. در حالی که اثر شاخص‌های PDO با تأخیرهای ۲ و ۳ عموماً افزایشی بود و اثر PNA با تأخیر ۳ در برخی اندازه‌های خاص



شکل ۱۰- بررسی عملکرد مدل در برابر تغییرات شاخص‌های اقلیمی با استفاده از تحلیل PDP در ایستگاه خاش.  
**Figure 10- Investigating the behavior of the model against changes in climatic indicators using PDP analysis at the Khash Station.**

### نتیجه‌گیری و پیشنهادها

نتایج این پژوهش نشان داد روابط میان شاخص‌های پیوند از دور و غلظت PM2.5 در ایستگاه‌های زاهدان و خاش، پیچیده و معنادار بود که با تحلیل‌های جامع همبستگی، ویژگی‌ها انتخاب و مدل‌سازی شدند. نتایج تحلیل همبستگی نشان داد بیشترین اثر مثبت بر غلظت PM2.5 در زاهدان مربوط به شاخص‌های AMO و PDO بود که با یافته‌های شائو و همکاران

(۲۰۱۳) مبنی بر گزارش همبستگی منفی AMO با کاهش گرد و غبار آفریقا، متناقض است. در حالی که در زاهدان اثر شاخص‌های AMM و WHWP منفی بود. نتایج روش Boruta بیانگر نقش مهم شاخص‌های WHWP و AMM با تأخیرهای خاص در پیش‌بینی PM2.5 بود. در این راستا، بیشترین اثر شاخص WHWP با تأخیرهای زیاد ۴ تا ۶ ماهه بود. نتایج بررسی اثرات متفاوت شاخص‌های اقلیمی با تأخیرهای

مناطق متفاوت باشد. افزون بر این، کیفیت داده‌ها تحت تأثیر منابع آلاینده محلی و نویز اندازه‌گیری بود. تغییرات ساختاری محیطی و اقلیمی در دو دهه موجب یکنواخت نبودن مدل‌سازی می‌شود، و شاخص‌های اقلیمی استفاده‌شده محدود به شاخص‌های رایج بودند در حالی که ممکن است شاخص‌های دیگر اثرگذار باشند. با این حال، نتایج این پژوهش با ارائه چارچوب تحلیلی دقیق و تفسیر شاخص‌ها، مبنای علمی قابل اعتمادی برای مدیریت پیش‌بینی‌شده آلودگی هوا در استان سیستان و بلوچستان فراهم آورد که می‌تواند الگویی برای دیگر مناطق مشابه باشد. از این رو، پیشنهاد می‌شود که سیاست‌گذاران برای مدیریت آلودگی هوا از یافته‌های کاربردی و عملی مهم این پژوهش بهره ببرند. در این راستا، بر پایه نتایج این پژوهش، به منظور زمینه‌سازی برای برنامه‌ریزی‌های پیشگیرانه پیشنهاد می‌شود شاخص‌های پیوند از دور برای پیش‌بینی دوره‌های با غلظت زیاد ذرات معلق، پیوسته پایش شوند. افزون بر این پیشنهاد می‌شود طراحی سیاست‌های مدیریت منابع آب و زمین مانند تثبیت کانون‌های گرد و غبار و مهار برداشت خاک بر اساس پیش‌بینی‌های بلندمدت شاخص‌های اقلیمی انجام شود. در این راستا، پیشنهاد می‌شود تصمیم‌گیرندگان با بهره‌گیری از قابلیت‌های مدل‌های یادگیری ماشین مانند XGBoost همراه با تحلیل‌های حساسیت اثرات غیرخطی شاخص‌ها بر پیش‌بینی PM<sub>2.5</sub> بررسی کنند. از سوی دیگر، با برنامه‌های اطلاع‌رسانی عمومی درباره دوره‌های پر گرد و غبار و با بهره‌گیری از نتایج پیش‌بینی شاخص‌های پیوند از دور و غلظت PM<sub>2.5</sub> می‌توان آسیب‌های سلامت انسانی را کاهش داد.

#### تضاد منافع نویسندگان

نویسندگان مسئول این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در زمینه نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

مختلف، با یافته‌های انصاری قوجقار و همکاران (۲۰۲۱) مطابقت دارد. بر اساس نتایج مدل‌سازی مدل XGBoost با بیشترین دقت و کمترین خطا در شناسایی روابط غیرخطی میان شاخص‌های اقلیمی و غلظت PM<sub>2.5</sub> به‌عنوان برترین مدل شناسایی شد. این یافته با نتایج پن و همکاران (۲۰۱۸) مطابقت دارد. نتایج تحلیل‌های SHAP، Sobol و PDP در زاهدان نشان داد که اثر شاخص‌های مرتبط با اقیانوس اطلس (AMM و AMO) بسیار زیاد بود، در حالی که اثرات غیرخطی شاخص‌هایی مانند WHWP در محدوده‌های خاصی از اندازه‌های منجر به تغییرات ناگهانی در پیش‌بینی‌ها شد.

در ایستگاه خاش بیشترین همبستگی مثبت و منفی به ترتیب مربوط به شاخص PDO (۰/۱۵۹) با تأخیر ۲ ماهه) و شاخص WHWP (۰/۳۸۵) با تأخیر ۴ ماهه) بود که نشان‌دهنده اثرات قابل توجه نوسانات اقیانوسی بر کیفیت هوا بود. نتایج تحلیل اهمیت ویژگی‌ها با روش Boruta در ایستگاه خاش نشان داد که نقش شاخص‌های AMM، AMO، PDO و WHWP در پیش‌بینی غلظت PM<sub>2.5</sub> مهم بود، به طوری که بیشترین اثر مربوط به شاخص WHWP با تأخیر ۵ ماهه بود، در حالی که شاخص‌های TNA و WP به دلیل اهمیت کم رد شدند. این یافته‌ها با نتایج گونگ و همکاران (۲۰۰۶) مبنی بر اهمیت شاخص PDO مطابقت دارد. بر اساس نتایج مدل‌سازی مدل XGBoost به‌عنوان برترین مدل شناسایی شد. نتایج تحلیل‌های PDP نشان داد که اثرات شاخص‌های اقلیمی بر غلظت PM<sub>2.5</sub> غیرخطی و پیچیده بود، به طوری که اثرات AMM با تأخیرهای مختلف متغیر بود و اثرات شاخص WHWP با تأخیر ۵ ماهه بر غلظت PM<sub>2.5</sub> کاهشی و ناگهانی بود. این یافته‌ها بیانگر اهمیت نقش روابط غیرخطی و آستانه‌های بحرانی در مدل‌سازی کیفیت هوا است. نتایج بررسی روابط غیرخطی شاخص‌های اقلیمی و اثرات آن‌ها بر PM<sub>2.5</sub> در این پژوهش با یافته‌های پایوس و همکاران (۲۰۲۲) و بین و همکاران (۲۰۲۲) مطابقت دارد. این پژوهش در دو ایستگاه در استان سیستان و بلوچستان انجام شد و نتایج ممکن است در دیگر

## مشارکت نویسندگان

نویسنده اول: انجام تحلیل‌های نرم‌افزاری، نگارش نسخه اولیه مقاله  
 نویسنده دوم: راهنمایی، مفهوم‌سازی، ویرایش و بازبینی مقاله، بررسی نتایج  
 نویسنده سوم: مشاوره، بازبینی متن مقاله  
 نویسنده چهارم: مشاوره، بازبینی متن مقاله  
 نویسنده پنجم: مشاوره، بازبینی متن مقاله

## دسترسی به داده‌ها

داده‌ها و نتایج استفاده‌شده در این پژوهش، به‌وسیله مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

## فهرست منابع

- Ahsani N. 2019. Investigation and presentation of innovative strategies regarding the relationship between the role of shopping tourism and attracting tourists (domestic and international) for the development and advancement of the tourism industry of Chabahar Port, Iran. *Journal of Tourism and Sustainable Development Research*. 2(1): 27–39. (In Persian).  
<https://www.magiran.com/p1978191>
- Akbari M, Saligheh M, Fili A. 2016. Investigation of ENSO Phases Impact on Dust Storms in Khuzestan Province. 5<sup>th</sup> National Conference on Air and Noise Pollution Management. Tehran, Iran, 1–2 February 2017. (In Persian).
- Alisofi M, Asghari Lafmejani S, Heidary Mokarrar H, Pirani M. 2024. Analysis of the effects of 120-day winds and dust storms on the livability of rural settlements (Case study: Hirmand County). *Journal of Geographical Research on Desert Areas*. 11(2): 133–148. <https://www.magiran.com/p2745858>
- Alizadeh-Choobari O, Zavar-Reza P, Sturman A. 2014. The wind of 120 days and dust storm activity over the Sistan Basin. *Atmospheric Research*. 143: 328–341. <https://doi.org/10.1016/j.atmosres.2014.02.001>
- Alshammari RK, Alrwais O, Aksoy MS. 2022. Machine learning applications to dust storms: A meta-analysis. *Aerosol and Air Quality Research*. 22(12): 220183. 1–12. <https://doi.org/10.4209/aaqr.220183>
- Creamean JM, Suski KJ, Rosenfeld D, Cazorla A, DeMott PJ, Sullivan RC, Prather KA. 2013. Dust and biological aerosols from the Sahara and Asia influence precipitation in the western US. *Science*. 339(6127): 1572–1578. <https://doi.org/10.1126/science.1227279>
- Gong SL, Zhang XY, Zhao TL, Zhang XB, Barrie LA, McKendry IG, Zhao CS. 2006. A simulated climatology of Asian dust aerosol and its trans-Pacific transport. Part II: Interannual variability and climate connections. *Journal of Climate*. 19(1): 104–122. <https://doi.org/10.1175/JCLI3606.1>
- Hao N, Sun P, He W, Yang L, Qiu Y, Chen Y, Zhao W. 2022. Water resources allocation in the Tingjiang River Basin: construction of an interval-fuzzy two-stage chance-constraints model and its assessment through Pearson correlation. *Water*. 14(18): 2928. <https://doi.org/10.3390/w14182928>
- Liu J, Wu D, Liu G, Mao R, Chen S, Ji M, Wang X. 2020. Impact of Arctic amplification on declining spring dust events in East Asia. *Climate Dynamics*. 54: 1913–1935. <https://doi.org/10.1007/s00382-019-05094-4>
- Mao R, Ho CH, Shao Y, Gong DY, Kim J. 2011. Influence of Arctic Oscillation on dust activity over northeast Asia. *Atmospheric Environment*. 45(2): 326–337. <https://doi.org/10.1016/j.atmosenv.2010.10.020>
- Martinez-Alvarado O, Montabone L, Lewis SR, Moroz IM, Read PL. 2009. Transient teleconnection event at the onset of a planet-encircling dust storm on Mars. *Annales Geophysicae*. 27(9): 3663–3676. <https://doi.org/10.5194/angeo-27-3663-2009>
- Pan B. 2018. Application of XGBoost algorithm in hourly PM2.5 concentration prediction. *IOP Conference Series: Earth and Environmental Science*. 113: 012127. <https://doi.org/10.1088/1755-1315/113/1/012127>
- Payus C, Anuar SI, Nurashilah F, Sentian J. 2022. Induced impact of El Niño-Southern oscillation and haze events on aerosol optical

- depth (AOD) in the tropical climate of Borneo Island. Mediterranean Geosciences Union. pp. 171-173. [https://doi.org/10.1007/978-3-031-13810-2\\_41](https://doi.org/10.1007/978-3-031-13810-2_41)
- Pereira AG, Palácios R, Santos PC, Pereira RV S, Cirino G, Imbiriba B. 2024. Relationship between El Niño-Southern oscillation and atmospheric aerosols in the Legal Amazon. *Climate*. 12(2): 13. <https://doi.org/10.3390/cli12020013>
- Prospero JM, Ginoux P, Torres O, Nicholson S E, Gill TE. 2002. Environmental characterization of global sources of atmospheric soil dust identified with the Nimbus 7 Total Ozone Mapping Spectrometer (TOMS) absorbing aerosol product. *Reviews of Geophysics*. 40(1): 2-1. <https://doi.org/10.1029/2000RG000095>
- Rizzolo JA, Barbosa CG, Borillo GC, Godoi A F, Souza RA, Andreoli RV, Godoi RH. 2017. Soluble iron nutrients in Saharan dust over the central Amazon rainforest. *Atmospheric Chemistry and Physics*. 17(4): 2673-2687. <https://doi.org/10.5194/acp-17-2673-2017>
- Shao Y, Klose M, Wyrwoll KH. 2013. Recent global dust trend and connections to climate forcing. *Journal of Geophysical Research: Atmospheres*. 118(19): 11-107. <https://doi.org/10.1002/jgrd.50836>
- Sharma DK, Chatterjee M, Kaur G, Vavilala S. 2022. Deep learning applications for disease diagnosis. *Deep Learning for Medical Applications with Unique Data*. pp. 31-51. <https://doi.org/10.1016/B978-0-323-96172-9.00002-3>
- Washington R, Todd M, Middleton NJ, Goudie AS. 2003. Dust-storm source areas determined by the total ozone monitoring spectrometer and surface observations. *Annals of the Association of American Geographers*. 93(2): 297-313. <https://doi.org/10.1111/1467-8306.9302003>
- Alshammari RK, Alrwais O, Aksoy MS. 2024. Machine learning forecast of dust storm frequency in Saudi Arabia using multiple features. *Atmosphere* 15(5):520, 1-27. <https://doi.org/10.3390/atmos15050520>
- Ansari Ghojghar M, Pourgholam-Amiji M, Araghinejad S, Babaeian I, Liaghat A, Salajegheh A. 2021. The Effect of warm phase of ENSO phenomenon on the formation of dust storms in Khuzestan and Sistan and Baluchestan Provinces. *Journal of Range and Watershed Management*. 74(2): 257-271. <https://doi.org/10.22059/jrwm.2020.310647.1533>. (In Persian).
- Arami SA, Ownegh M, Mohammadian Behbahani A, Akbari M, Zarasvandi A. 2018. Statistical analysis of spatio-temporal pattern of dust storms in West and Southwest of Iran. *Water and Soil Conservation*. 25(1): 61-83. <https://www.magiran.com/p1834445>
- Gholamy A, Kreinovich V, Kosheleva O. 2018. Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation. Departmental Technical Reports (Computer Science), UTEP-CS-18-09, The University of Texas at El Paso. Departmental Technical Reports (CS) 1209. 18 pages.
- Homma T, Saltelli A. 1996. Importance measures in global sensitivity analysis of nonlinear models. *Reliability Engineering and System Safety*. 52(1):1-17. [https://doi.org/10.1016/0951-8320\(96\)00002-6](https://doi.org/10.1016/0951-8320(96)00002-6)
- Jahantigh M, Jahantigh M, Iranmanesh F. 2023. Identification of storms and centers of dust production in southeast of Iran (Case study: Sistan Region). *Environmental Erosion Researches* 13(3): 67-92. <https://www.magiran.com/p2631887>
- Jahantigh M, Jahantigh M, Iranmanesh F. Identification of Storms and Centers of Dust Production in Southeast of Iran (Case Study: Sistan Region). 2023. *Journal of Environmental Erosion Research*. 13 (3):67-92. <https://dor.isc.ac/dor/20.1001.1.22517812.1402.13.3.4.0>. (In Persian).
- Khosravi M. 2004. A survey on the relations of the Northern Hemisphere large scale circulation patterns with Sistan and Baluchestan annual droughts. *Geography and Development Iranian Journal*. 2(3): 167-188. <https://www.magiran.com/p266992>
- Kursa MB, Jankowski A, Rudnicki WR. 2010. Boruta—a system for feature selection. *Fundamenta Informaticae*. 101(4): 271-285. <https://doi.org/10.3233/FI-2010-288>
- Kursa MB, Rudnicki WR. 2010. Feature selection with the Boruta package. *Journal of Statistical Software*. 36(1): 1-13. <https://doi.org/10.18637/jss.v036.i11>
- Lundberg SM, Lee SI. 2017. A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*. 4765-4774.30. <https://doi.org/10.48550/arXiv.1705.07874>
- Middleton N. 2019. Variability and trends in dust storm frequency on decadal timescales: Climatic drivers and human impacts. *Geosciences*. 9(6):261, 1-12. <https://doi.org/10.3390/geosciences9060261>
- Omidvar K, Javidnia M, Mohammadi Ravari F. 2024. Examining of relationship

- between dust storms and teleconnection indicators in different seasons during the statistical period of 1988-2017 in Kerman Province. *Nivar*. 48(126): 1-17. <https://www.magiran.com/p2801868>
- Razmjooei F, Halabian AH. 2011. Recognition and Analysis of Zahedan Weather Types. *Geographic Space*. 11(34): 210\_231. <https://www.magiran.com/p882159>
- Schober P, Boer C, Schwarte LA. 2018. Correlation coefficients: Appropriate use and interpretation. *Anesthesia and Analgesia* 126(5): 1763-1768. <https://doi.org/10.1213/ANE.00000000000002864>
- Shamsipour A, Safarrad T. 2012. Satellite and synoptic analysis of dust storm in western half of Iran (Case Study: July 2009). *Physical Geography Research*. 44(1): 111-126. <https://doi.org/10.22059/jphgr.2012.24737>
- Vatanparast Galeh Juq F, Salahi B, Zeinali B, 2024. Simultaneous analysis of ENSO, IOD, and QBO cycles on dust storm oscillations in western Iran. *Journal of Natural Environmental Hazards*. 13(39): 109-126. (In Persian). <https://doi.org/10.22111/jneh.2023.45793.1966>
- Vatanparast Galeh Juq F, Salahi B, Zeinali B. 2024. Simultaneous analysis of ENSO, IOD, and QBO cycles on dust storm oscillations in western Iran. *Journal of Natural Environmental Hazards*. 13(39): 109-126. <https://www.magiran.com/p2706950>
- Zeinali B, Asghari S. 2018. Evaluation of some indicators to identify and monitor dust storm (Case study: dust storms 10 August 2008 East the Iran). *Journal of Geography and Planning*. 22(65): 73-91. <https://www.magiran.com/p1907936>
- Zhang C, GAO R, Wu J, Yang Z. 2019. Combating climate change, desertification and sandstorms: A collaborative approach. In Annual report on China's response to climate change (2017): Implementing the Paris Agreement. Springer Nature Singapore. pp. 145-153). [https://doi.org/10.1007/978-981-13-9660-1\\_13](https://doi.org/10.1007/978-981-13-9660-1_13).



## Assessment of the Teleconnection Effects on PM<sub>2.5</sub> Concentration using Machine Learning Models in the Sistan and Baluchestan Province

Abolfazl Davari <sup>1</sup>, Rasool Mahdavi Najafabadi <sup>2\*</sup>, Marzieh Rezai <sup>3</sup>, Ommolbanin  
Bazrafshan <sup>4</sup>, Ali Reza Shahriary <sup>5</sup>

1- Ph.D. Student, Department of Natural Resources Engineering, Faculty of Agriculture and  
Natural Resources, University of Hormozgan, Bandar Abbas, Iran

2 and 3- Associate Professor, Department of Natural Resources Engineering, Faculty of Agriculture and  
Natural Resources, University of Hormozgan, Bandar Abbas, Iran

4- Professor, Department of Natural Resources Engineering, Faculty of Agriculture and Natural  
Resources, University of Hormozgan, Bandar Abbas, Iran

5- Associate Professor, Department of Green Space, Faculty of Geography and Environmental Planning,  
University of Sistan and Baluchestan, Zahedan, Iran

### Extended Abstract

#### Introduction and Goal

In recent years, air pollution, especially the increase in the concentration of PM<sub>2.5</sub> particles matter, has been raised as one of the significant environmental challenges. Due to its specific geographical location, which is located in the path of the 120-day Sistan winds, along with the decrease in annual rainfall, Sistan and Baluchestan province provides favorable conditions for the formation and intensification of dust phenomena. In this regard, teleconnections play an important role in climate change and, consequently, in air quality. The main objective of this research is to evaluate the impact of teleconnection indices on PM<sub>2.5</sub> concentrations in Sistan and Baluchestan Province using advanced machine learning models. Therefore, meteorological data and PM<sub>2.5</sub> concentrations were collected from Zahedan and Khash stations over two decades and combined with teleconnection indices. Then, using correlation analysis and feature selection methods, five machine learning models were evaluated to identify the best model for long-term estimating PM<sub>2.5</sub> particulate matter concentrations was identified. The results of this research both led to a better understanding of the complex relationships between climate variability and air quality, by provided a detailed analytical framework, provided a practical tool for policymakers in air pollution management.

#### Materials and Methods

This study used a comprehensive multi-stage analytical framework, and meteorological data and PM<sub>2.5</sub> particle concentration were collected from Zahedan and Khash stations during the period

**Article Type:** Research Article

**\*Corresponding Authors' E-mail:** ra\_mahdavi2000@hormozgan.ac.ir

**Citation:** Davari, A., Mahdavi Najafabadi, R., Rezai, M., Bazrafshan, O., Shahriary, A.R. 2026. Assessment of the Teleconnection Effects on PM<sub>2.5</sub> Concentration using Machine Learning Models in the Sistan and Baluchestan Province. *Watershed Management Research*. 39(1): 1-25.

**DOI:** 10.22092/wmrj.2025.369570.1624

**Received:** 11 September 2025, **Received in revised form:** 06 October 2025, **Accepted:** 21 December 2025

**Published online:** 21 March 2026

*Watershed Management Research*, Vol. 39, No.1, Ser. No: 150, Spring 2026, pp. 1-25.

**Publisher:** Fars Agricultural and Natural Resources and Education Center

©Author(s)



2000 to 2021 and supplemented with teleconnection index data from the NOAA Climate Prediction Center. After careful data preprocessing, which included quality control (checking for impossible or anomalous PM<sub>2.5</sub> measurements and correcting or removing suspicious measurements), data temporal synchronization (matching PM<sub>2.5</sub> data and remote linkage indices based on history to ensure the synchronization of independent and dependent measurements), and missing data replacement (using the nearest valid measurement, temporal averaging, and statistical interpolations to preserve the original data distribution), a dual analytical approach was implemented. First, Pearson correlation analysis was used to measure linear relationships between teleconnection index and PM<sub>2.5</sub> levels. Then the Boruta algorithm identified the most effective features at time lags of 0 to 6 months. Five advanced machine learning models including Bagged CART, LightGBM, Gradient Boosting, Random Forest, and XGBoost were evaluated, with 70% of the data used for model training and the rest for validation. Performance evaluation was performed using three criteria: root mean square error (RMSE), mean absolute percentage error (MAPE), and coefficient of determination ( $R^2$ ), and for interpretability of the models, four advanced techniques were used, including permutation feature importance (PFI), SHAP values based on game theory, Sobol sensitivity analysis, and partial dependency diagrams (PDP). All analyses were performed in the R software environment (4.2.0).

### Results and Discussion

The results showed that the effect of teleconnection indices on PM<sub>2.5</sub> particles concentrations at Zahedan and Khash stations was significant. At Zahedan station, the highest positive correlation was related to the PDO index (0.158 with a 5-month lag) and the AMO index (0.212 with a 0-month lag). On the other hand, the highest negative correlation was related to the AMM index (0.336 with a 2-month lag) and the WHWP index effect (-0.420 with a 4-month lag). At Khash station, the highest positive correlation was related to the PDO index (0.159 with a 2-month lag) and the highest negative correlation was related to WHWP (-0.385 with a 4-month lag). Analysis of the importance of features using the Boruta method showed that the greatest predictive role of PM<sub>2.5</sub> was related to the WHWP index with an average importance of 13.63 with a 6-month lag in Zahedan and with an average importance of 10.51 at 5-month lag in Khash. In the evaluation of the models, XGBoost was identified as the best model with exceptional accuracy ( $R^2=0.989$  in Zahedan and  $R^2=0.993-0.994$  in Khash) and minimal error (MAPE=2.36-3.07 in Zahedan and MAPE=1.5-1.8 in Khash). The results of sensitivity analyses showed that the greatest effect was related to the AMM index (with a significance score of 685 in Zahedan and 561 in Khash). On the other hand, with certain lag times, the behavior of the WHWP and AMO indices were nonlinear and complex. Overall, the results indicate significant effects of ocean-atmosphere oscillations (with correlation coefficients ranging from 0.15 to 0.42 and significance scores ranging from 5.6 to 13.6) on regional air quality. The performance of the XGBoost model in long-term PM<sub>2.5</sub> forecasting in the study region was very accurate.

### Conclusion and Suggestions

The results of this study showed that the highest positive correlation with PM<sub>2.5</sub> concentrations at Zahedan station was related to PDO and AMO indices, and the highest negative correlation was related to AMM and WHWP indices. The XGBoost model was identified as the best prediction model, which had high accuracy with the lowest error. Also, the results of SHAP and PDP analyses showed that the effects of the AMM and WHWP indices on PM<sub>2.5</sub> concentrations were complex and nonlinear, and the time lag in these effects was very important. At Khash station, the AMM, AMO, PDO and WHWP indices also played an important role in predicting PM<sub>2.5</sub> and indicated the significant effects of climate fluctuations on air quality. These findings indicate the importance of nonlinear relationships and critical thresholds in air quality modeling. Based on the results of this study, it is suggested that remote sensing indices be continuously monitored to predict periods of high particulate matter concentrations for the purpose of preventive decisions and actions. Also, it is suggested that, based on the differences observed between the two stations (Zahedan and Khash), more attention be paid to local and regional characteristics in air quality modeling.

**Keywords:** Pearson correlation, PM2.5, Shapley value, Sobol sensitivity analysis, teleconnections

**Article Type:** Research Article

**Conflicts of interest**

The authors of this article declare that they have no conflicts of interest regarding the writing and publication of the contents and results of this research.

**Data Availability Statement**

The data and results used in this research will be made available upon reasonable request to the corresponding author.

**Authors' Contribution**

Author 1: Conducting software analyses, writing the initial draft of the article.

Author 2: Guidance, conceptualization, editing and reviewing the article, reviewing the results.

Author 3: Consulting, reviewing the article text

Author 4: Consulting, reviewing the article text.

Author 5: Consulting, reviewing the article text.