

The role of data-driven classification models in distinguishing jet-stream-dependent and jet-stream-independent dust events in western and southwestern Iran

Jafari Hajiabadi, E.¹  | Rezazadeh, M.¹   | Bazrafshan, O.² 

1. Department of Marine and Atmospheric Science (Non-Biologic), Faculty of Marine Science and Technology, University of Hormozgan, Bandar Abbas, Iran.

2. Department of Nature Resources Engineering, Faculty of Agricultural and Natural Resources, University of Hormozgan, Bandar Abbas, Iran.

Corresponding Author E-mail: rezazadeh@hormozgan.ac.ir

(Received: 30 Dec 2025, Revised: 10 Feb 2026, Accepted: 30 Dec 2026, Published online: 5 Sep 2026)

Summary

Dust outbreaks are among the most critical environmental and meteorological hazards in western and southwestern Iran. Because dust occurrence and intensity are controlled by interacting synoptic-scale dynamics and near-surface conditions, improving dust monitoring and decision support benefits from combining a dynamical perspective with data-driven classification methods. The present study evaluates the performance of machine-learning classifiers in identifying and separating dust events that are dependent on versus independent of upper-level jet-stream conditions, with specific attention to the 250-hPa jet-stream level.

Hourly observations from 29 synoptic meteorological stations in the study region were compiled for the period 2010–2024. Dust occurrences were not identified solely based on reduced visibility, instead, dust events were first detected using dust-related present-weather codes reported in synoptic (SYNOP/WMO) observations. Horizontal visibility was then used as an auxiliary quantitative indicator to classify event intensity/type and to define the classification labels (e.g., separating dust-storm conditions associated with marked visibility reduction such as 200–1000 m from cases of suspended dust). To describe the atmospheric environment, dynamical–thermodynamic predictors were extracted from global reanalysis products over the same period. Upper-level circulation and jet-stream conditions were characterized at 250 hPa using geopotential height and horizontal wind (u and v components, or their derived wind speed as a jet indicator). Near-surface predictors included surface pressure, 2-m air temperature, and 10-m wind, representing the meteorological controlling parameters most directly linked to dust emission and transport. Reanalysis variables were collocated to station locations and temporally aligned with station reports.

Each dust-related sample was assigned to one of two synoptic regimes: “jet-stream present” and “jet-stream absent,” determined from the concurrent 250-hPa flow. For each regime, feature selection was performed using the Boruta algorithm to retain truly informative predictors while eliminating weak and noisy variables. The selected predictors were then used to train and test several supervised classification models, including Random Forest, XGBoost, Support Vector Machine (SVM), neural networks, and logistic regression. Model performance was assessed using Accuracy, AUC, and F1 score, and comparative diagnostics were summarized via radar plots (Where applicable in the analysis workflow, SHAP-based interpretation was used to support physical understanding of the dominant predictors.)

The findings reveal a strong regime dependence in both the dominant predictors and the most skillful classifiers. In the jet-present regime, predictors describing upper-level dynamics and the pressure field were consistently emphasized, including 250-hPa geopotential height and 250-hPa horizontal wind, together with surface pressure and near-surface wind. In this regime, ensemble tree-based models, particularly XGBoost and Random Forest, showed the highest skill for the binary (two-class) discrimination between dust-storm conditions (e.g., 200–1000 m visibility) and suspended dust. This performance is consistent with the more organized synoptic patterns typically associated with jet-stream influence, which enhance the learnability of nonlinear links between upper-level circulation, pressure configuration, and near-surface wind forcing. In contrast, in the jet-absent regime and in the four-class formulation, the relative contribution of upper-level dynamical predictors decreased, and the primary weight shifted toward near-surface variables, particularly surface pressure, 2-m temperature, and 10-m wind. Under these conditions, SVM with an RBF kernel exhibited the most stable performance across the four dust conditions, indicating that a smooth nonlinear decision boundary driven by near-surface thermodynamic–dynamic structure can be advantageous when upper-level jet constraints are weaker.

Overall, the results demonstrate that explicitly separating synoptic regimes and then using regime-appropriate predictors and model families can improve both the accuracy and the physical interpretability of dust-event classification in western and southwestern Iran. This regime-based, data-driven framework provides practical guidance for developing regional dust monitoring and decision-support systems, while also clarifying how upper-level jet-stream variability modulates the relative importance of upper-level versus near-surface meteorological controls.

Keywords: event classification; Classification Models; Dust Storms; Jet Stream.

Cite this article: Jafari Hajiabadi, E., Rezazadeh, M., & Bazrafshan, O. (2026). The role of data-driven classification models in distinguishing jet-stream-dependent and jet-stream-independent dust events in western and southwestern Iran. *Journal of the Earth and Space Physics*, 52(2), 313-333. DOI: <http://doi.org/10.22059/jesphys.2026.408828.1007748>

E-mail: (1) e.jafari.stu@hormozgan.ac.ir (2) o.bazrafshan@hormozgan.ac.ir



© Authors Retain the Copyright and Full Publishing Rights.

Publisher: University of Tehran Press.

DOI: <http://doi.org/10.22059/jesphys.2026.408828.1007748>

Print ISSN: 2538-371X
Online ISSN: 2538-3906

نقش مدل‌های طبقه‌بندی داده‌محور در تفکیک رخدادهای گردوغبار وابسته و غیروابسته به جریان جتی در غرب و جنوب غرب ایران

احترام جعفری حاجی‌آبادی^۱ | مریم رضازاده^۱ ✉ | ام‌البنین بذرافشان^۲

۱. گروه علوم غیرزیستی جوی و اقیانوسی، دانشکده علوم و فنون دریایی، دانشگاه هرمزگان، بندرعباس، ایران.

۲. گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران.

رایانامه نویسنده مسئول: rezazadeh@hormozgan.ac.ir

(دریافت: ۱۴۰۴/۱۰/۹، بازنگری: ۱۴۰۴/۱۱/۲۱، پذیرش نهایی: ۱۴۰۵/۴/۹، انتشار آنلاین: ۱۴۰۵/۶/۱۴)

چکیده

گردوغبار یکی از مهم‌ترین مخاطرات غرب و جنوب غرب ایران است و بررسی آن نیازمند ترکیب دید دینامیکی و روش‌های داده‌محور است. در این پژوهش، با بهره‌گیری از داده‌های ۲۹ ایستگاه هواشناسی همدیدی و متغیرهای دینامیکی-ترمودینامیکی بازتحلیل‌های جهانی طی دوره ۲۰۲۴-۲۰۱۰، کارایی مدل‌های طبقه‌بندی داده‌محور در شناسایی و تفکیک رخدادهای گردوغبار وابسته و غیروابسته به جریان جتی بررسی شد. رخدادهای گردوغبار بر پایه کدهای وضعیت جوی گردوغبار در گزارش‌های همدیدی شناسایی و سپس با استفاده از دید افقی، به کلاس‌های شدت/نوع تفکیک شدند. داده‌ها همچنین به دو رژیم «همراه با جریان جتی» و «بدون جریان جتی» دسته‌بندی شدند. در هر دو رژیم، انتخاب ویژگی با الگوریتم Boruta انجام و سپس طبقه‌بندی با چند مدل یادگیری ماشین (SVM, XGBoost, Random Forest)، شبکه عصبی و وایزش لجستیک) و با شاخص‌های Accuracy، AUC و F1 ارزیابی شد. در رژیم همراه جریان جتی، متغیرهای تراز بالا و میدان فشار (ارتفاع ژئوپتانسیل و سرعت باد افقی تراز ۲۵۰ هکتوپاسکال، به همراه فشار و باد سطحی) در تفکیک طوفان‌های با دید ۱۰۰۰-۲۰۰ متر از گردوغبار معلق نقش غالبی داشتند و XGBoost و Random Forest بالاترین مهارت را در طبقه‌بندی دوکلاسی ارائه کردند. در رژیم بدون جریان جتی و در مسئله چهارکلاسی، وزن اصلی به متغیرهای نزدیک سطح (فشار سطحی، دمای ۲ متری و باد ۱۰ متری) منتقل شد و SVM با کرنل RBF پایدارترین عملکرد را نشان داد. نتایج بیانگر آن است که تفکیک رژیم‌های همدیدی و انتخاب متغیرها و مدل‌های متناسب با هر رژیم، می‌تواند دقت و تفسیرپذیری سامانه‌های هشدار گردوغبار را افزایش دهد.

واژه‌های کلیدی: طبقه‌بندی رخداد، مدل‌های طبقه‌بندی، گردوغبار، جت‌استریم.

۱. مقدمه

(۲۰۱۳). پیامد این طوفان‌ها در استان خوزستان و نواحی مجاور شامل کاهش شدید دید افقی، آلودگی قابل ملاحظه هوا و افزایش بیماری‌های تنفسی گزارش شده است (مبارک‌حسن و همکاران، ۲۰۱۹؛ آقابابائیان و همکاران، ۲۰۲۱؛ جلالی و گودرزی، ۲۰۲۴).

از دید هواشناسی، شکل‌گیری و گسترش طوفان‌های گردوغبار به عواملی نظیر سرعت باد سطحی (تندی)، خشکی و شرایط سطح خاک، دما، فشار و ساختار سامانه‌های جوی وابسته است. پویایی و انتقال غبار در مقیاس‌های مختلف زمانی و مکانی تحت تأثیر فرایندهای

پدیده گردوغبار یکی از مهم‌ترین مخاطرات اقلیمی و زیست‌محیطی در نواحی خشک و نیمه‌خشک، به‌ویژه خاورمیانه و ایران است و تأثیر زیادی را بر غرب و جنوب غرب کشور (به‌خصوص خوزستان، ایلام و کرمانشاه) گذاشته است. در دهه‌های اخیر، فراوانی و شدت رویدادهای گردوغبار افزایش یافته و ترکیبی از منابع درون‌مرزی و برون‌مرزی-به‌ویژه کانون‌های فعال در عراق و حوضه‌های خشک‌شونده مجاور-در تغذیه ذرات معلق نقش دارند (طلاتی و همکاران، ۲۰۲۴؛ نوتارو و همکاران، ۲۰۱۳؛ حمیدی و همکاران، ۲۰۱۳؛ رشکی و همکاران،

استناد: جعفری حاجی‌آبادی، احترام؛ رضازاده، مریم و بذرافشان، ام‌البنین (۱۴۰۵). نقش مدل‌های طبقه‌بندی داده‌محور در تفکیک رخدادهای گردوغبار وابسته و غیروابسته به جریان جتی در غرب و جنوب غرب ایران. مجله فیزیک زمین و فضا، ۵۲(۲)، ۳۱۱-۳۳۳. DOI: <http://doi.org/10.22059/jesphys.2026.408828.1007748>

رایانامه: (۱) e.jafari.stu@hormozgan.ac.ir (۲) o.bazrafshan@hormozgan.ac.ir

پژوهش‌های ملی و منطقه‌ای بر متغیرهای سطحی (مانند باد دهمتری، دید افقی و شاخص‌های پوشش گیاهی) و روش‌های سنتی تکیه دارند و ادغام منظم شاخص‌های جت‌استریم با این داده‌ها هنوز محدود است (محمودی و ایکه‌گایا، ۲۰۲۳؛ ضغیر و همکاران، ۲۰۲۵).

بر این اساس، این پژوهش در پی آن است که یک چارچوب داده‌محور/هوش مصنوعی برای شناسایی و تفکیک رخدادهای گردوغبار ارائه کند که در آن، موقعیت و ویژگی‌های جریان جتی (جت‌استریم) تراز ۲۵۰ هکتوپاسکال به‌عنوان ورودی‌های کلیدی، همراه با متغیرهای نزدیک سطح و شاخص‌های دینامیکی-ترمودینامیکی بازتحلیل و مشاهدات ایستگاهی، برای تمایز رخدادهای گردوغبار وابسته و غیروابسته به جریان جتی در غرب و جنوب‌غرب ایران به‌کار گرفته شوند. هدف، پر کردن سه خلأ اصلی است: (۱) ادغام سیستماتیک شاخص‌های جریان جتی با داده‌های نزدیک سطح، (۲) استفاده از مدل‌های یادگیری ماشین برای یادگیری روابط غیرخطی میان جریان جتی و رخدادهای گردوغبار و (۳) ارزیابی این مدل‌ها بر داده‌های بومی منطقه طی دوره ۲۰۲۴-۲۰۱۰. نتایج این کار می‌تواند به بهبود سامانه‌های هشدار و تصمیم‌یار گردوغبار، مدیریت بحران و کاهش پیامدهای زیست‌محیطی آن کمک کند.

۲. مواد و روش تحقیق

۲-۱. منطقه مورد مطالعه و جمع‌آوری داده‌ها

منطقه مورد مطالعه شامل استان‌های خوزستان، ایلام، لرستان، کرمانشاه و همدان در دامنه‌های زاگرس (۳۵-۳۰ درجه شمالی، ۵۱-۴۶ درجه شرقی) است که به مرز عراق و جلگه دجله-فرات متصل می‌شود؛ ناحیه‌ای که در پژوهش‌های متعدد به‌عنوان یکی از اصلی‌ترین کانون‌های گردوغبار خاورمیانه شناخته شده است (شاو و همکاران، ۲۰۲۲؛ بلورانی و همکاران، ۲۰۱۴؛ حمیدی و همکاران، ۲۰۱۳). گزارش‌های UNEP و تحلیل‌های بلندمدت نشان می‌دهند که دشت خوزستان و به‌طور کلی غرب و جنوب‌غرب ایران هسته اصلی طوفان‌های گردوغبار

همرفتی محلی (مانند جت سطح‌پایین) و نیز ساختارهای همدیدی و جریان‌های تراز بالا از جمله جت‌استریم‌هاست (پرنو و همکاران، ۲۰۲۴؛ کنیپرتز و تاد، ۲۰۱۲؛ فرانسیس و همکاران، ۲۰۲۲). جابه‌جایی یا تغییر شدت جت‌استریم‌ها می‌تواند با تقویت سامانه‌های کم‌فشار، ایجاد ناپایداری‌های بزرگ مقیاس و افزایش شدت باد، شرایط را برای خیزش و انتقال گردوغبار مهیا کند؛ موضوعی که در مطالعات دینامیک جو نیز بر آن تأکید شده است (برومندی و همکاران، ۲۰۲۳؛ هولتون و حکیم، ۲۰۱۳؛ اوچلینی و جانسون، ۱۹۷۹). با این حال، رابطه کمی و نظام‌مند بین ویژگی‌های جت تراز بالا (موقعیت، شدت و ساختار آن) و وقوع گردوغبار در غرب ایران کمتر به‌طور هدفمند بررسی شده است (محمودی و ایکه‌گایا، ۲۰۲۳؛ ضغیر و همکاران، ۲۰۲۵).

به‌طور موازی، پیشرفت‌های اخیر در یادگیری ماشین و یادگیری عمیق نشان داده‌اند که مدل‌های داده‌محور-مانند شبکه‌های عصبی، مدل‌های بازگشتی (RNN/LSTM/TCN) و درخت‌های تصمیم‌تجمیعی-در ترکیب با داده‌های ماهواره‌ای، ایستگاه‌های سطحی و خروجی مدل‌های عددی می‌توانند مهارت پیش‌بینی فراوانی و توزیع گردوغبار را به‌طور قابل‌توجهی افزایش دهند (فنگ و همکاران، ۲۰۱۵؛ لی و همکاران، ۲۰۱۷؛ هه و هوانگ، ۲۰۱۸؛ مک‌گاورن و همکاران، ۲۰۱۹؛ شولتز و همکاران، ۲۰۲۱). این رویکرد، به‌ویژه هنگامی که با شناخت دینامیک گردوغبار و سامانه‌های همدیدی مسئول آن تلفیق شود، زمینه توسعه سامانه‌های هشدار زود هنگام در مناطق خشک و نیمه‌خشک را فراهم می‌کند (شائو و دونگ، ۲۰۰۶؛ حمیدی و همکاران، ۲۰۱۳؛ نوتار و همکاران، ۲۰۱۳؛ الشماری و همکاران، ۲۰۲۴). در ایران نیز مطالعات متعددی به شناسایی کانون‌های غبار و مسیرهای انتقال آن با استفاده از تصاویر ماهواره‌ای و تحلیل‌های همدیدی پرداخته‌اند و نشان داده‌اند که بخش عمده غبار جنوب‌غرب کشور از کانون‌های فعال در غرب عراق و جلگه بین‌النهرین سرچشمه می‌گیرد (بلورانی و همکاران، ۲۰۱۴؛ برومندی و همکاران، ۲۰۱۷). با این حال، بیشتر


شد تا شرایط هواشناسی مرتبط با وقوع طوفان‌های گرد و غبار در غرب و جنوب غربی ایران در طول سال‌های ۲۰۱۰ تا ۲۰۲۴ مشخص شود.

مشاهدات ساعتی دید افقی و کدهای وضعیت جوی مرتبط با گردوغبار از ۲۹ ایستگاه هواشناسی همدیدی در منطقه مطالعاتی (شکل ۱) از سازمان هواشناسی ایران دریافت شد و برای شناسایی رخداد‌های گردوغبار به کار رفت. متغیرهای ورودی نزدیک سطح شامل سرعت باد سطحی (تندی) و جهت باد از پایگاه داده NASA (power.larc.nasa.gov) و دمای سطح زمین از پایگاه کوپرنیک (ERA5) برای دوره ۲۰۲۴-۲۰۱۰ استخراج شد؛ این متغیرها به عنوان جایگزین داده‌های دمایی/بادی ایستگاه‌ها استفاده شدند. افزون بر این، متغیرهای تراز بالا از NCEP/NCAR Reanalysis 2 شامل مؤلفه‌های باد افقی در تراز ۲۵۰ هکتوپاسکال (شاخص جریان جتی) و سایر متغیرهای دینامیکی استخراج شد. به منظور هم‌مکان‌سازی داده‌های شبکه‌ای با ایستگاه‌ها، برای هر ایستگاه مقادیر متغیرهای بازتحلیل/شبکه‌ای در مختصات ایستگاه با روش نزدیک‌ترین یاخته شبکه (nearest grid point) استخراج و سپس سری زمانی متناظر هر ایستگاه تشکیل شد. برای هم‌گام‌سازی زمانی نیز داده‌های بازتحلیل با نزدیک‌ترین گام زمانی موجود به زمان مشاهده ایستگاه منطبق شد.

کشورند و در روزهای طوفانی، غلظت ذرات معلق (PM) در شهرهایی مانند اهواز به شدت افزایش یافته و با پیامدهای جدی برای سلامت تنفسی و قلبی-عروقی همراه است (طلائی و همکاران، ۲۰۲۴؛ رنجبر سعادت‌آبادی و همکاران، ۲۰۲۵).

بررسی‌های سنجش‌ازدور و تحلیل‌های همدیدی نشان داده‌اند که بخش عمده گردوغبار ورودی به این ناحیه از تالاب‌ها و دریاچه‌های خشک‌شونده غرب عراق و جلگه میان‌رودان- مانند هورالعظیم/ هورالهویزه، هورالحمار، رزازه و هبانه- منشأ می‌گیرد و ترکیب تغییر اقلیم، خشکسالی و مدیریت نامناسب آب، این پهنه‌ها را به کانون‌های فعال گردوغبار تبدیل کرده است (بیرانوند و همکاران، ۲۰۲۳؛ برومندی و همکاران، ۲۰۱۷). از نظر اقلیمی، منطقه به طور مکرر تحت تأثیر بادهای سطحی شدید و الگوهای همدیدی قرار می‌گیرد که این کانون‌ها را فعال و ذرات را به داخل ایران منتقل می‌کنند (بلورانی و همکاران، ۲۰۱۴). در نتیجه، طراحی و استقرار سامانه‌های پیش‌بینی و هشدار زودهنگام در این پهنه برای کاهش خسارات اقتصادی، زیست‌محیطی و بهداشتی ضرورتی اساسی دارد.

در این مطالعه، مجموعه داده‌های جامعی از مشاهدات همدیدی زمینی و محصولات بازتحلیل جهانی گردآوری



شکل ۱. منطقه مورد مطالعه و توزیع ایستگاه‌های همدیدی مورد استفاده در این پژوهش.

جدول ۱. منابع داده، متغیرها و تفکیک زمانی-مکانی.

تفکیک مکانی	تفکیک زمانی	تراز/ارتفاع	متغیر(ها) استخراج شده	منبع داده
نقطه‌ای	ساعتی	سطح زمین	دید افقی، کدهای گردوغبار/وضعیت جوی (همیدی)، فشار ایستگاه، فشار سطح دریا	سازمان هواشناسی ایران (ایستگاه‌های همیدی)
$0/5^{\circ} \times 0/5^{\circ}$	ساعتی	۱۰-۰ متری	سرعت باد سطحی (تندی) و جهت باد	NASA (NASA POWER)
$0/25^{\circ} \times 0/25^{\circ}$	ساعتی	۲ متری	دمای سطح زمین	Copernicus (ERA5)
$2/5^{\circ} \times 2/5^{\circ}$	۶ ساعته (00/06/12/18 UTC)	۲۵۰ hPa	u و v (یا سرعت باد افقی) در ۲۵۰ hPa؛ ارتفاع ژئوپتانسیل ۲۵۰ hPa، دمای هوای ۲ متری، دمای کمینه (۲ متری)، دمای بیشینه (۲ متری)، دمای هوا (۱۰-۲۰۰ cm)	NCEP/NCAR Reanalysis 2

۲-۲. روش شناسایی جریان جت‌استریم

برای بررسی نقش جریان تروپوسفر بالایی در طوفان‌های گردوغبار غرب و جنوب‌غرب ایران، از یک رویکرد «مبتنی بر رخداد» استفاده شد. در گام نخست، ساعات گردوغبار در ایستگاه‌های همیدی بر اساس ترکیب سه معیار به‌طور هم‌زمان شناسایی شدند: ثبت کد هواشناسی گردوغبار، کاهش دید افقی به کمتر از ۱۰۰۰ متر و افزایش محسوس سرعت باد سطحی؛ ترکیبی که با تعاریف عملیاتی و روش‌های مطالعات مروری گردوغبار در شرق آسیا و خاورمیانه هم‌راستاست (شائو و دونگ، ۲۰۰۶؛ حمیدی و همکاران، ۲۰۱۳). برای هر رویداد، چند روز بدون گردوغبار ولی از نظر فصل و پس‌زمینه اقلیمی مشابه نیز به‌عنوان نمونه شاهد انتخاب شد تا امکان مقایسه رخداد/عدم رخداد فراهم شود.

مجموعه داده‌های ترکیبی شامل پارامترهای زیر بود: تندی (ff)، جهت باد (dd)، جهت باد ۱۰ متری (dd10)، سرعت باد ۱۰ متری (ff10)، دمای کمینه (Tmin)، دمای بیشینه (Tmax)، دمای هوا (۱۰-۲۰۰ cm) (t)، دمای هوای ۲ متری (t2)، دمای سطح زمین (tsoil)، سرعت مداری باد تراز بالا (Uwnd)، سرعت نصف‌النهاری باد تراز بالا (Vwnd)، دید افقی (vv)، فشار سطح دریا (P)، فشار ایستگاه (P0) و ارتفاع ژئوپتانسیل ۲۵۰ hPa (geops).

فصل وقوع از روی تاریخ هر نمونه استخراج و به‌عنوان ویژگی زمانی به مجموعه داده افزوده شد. برای جلوگیری از وابستگی به تعداد رکوردهای ۴ ساعته، فراوانی فصلی رخدادها بر اساس «تعداد روزهای رخداد» (حداقل یک گزارش گردوغبار در روز) محاسبه و به تفکیک کلاس‌ها و به‌صورت جداگانه برای رژیم‌های «با جریان جتی» و «بدون جریان جتی» ارائه شد (جدول ۲).

جدول ۲. فراوانی فصلی رخدادهای گردوغبار به تفکیک کلاس‌ها طی دوره ۲۰۱۰-۲۰۲۴.

فراوانی فصلی گردوغبار در عدم حضور جریان جتی		فراوانی فصلی گردوغبار در حضور جریان جتی				
کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۱	کلاس ۴	فصل
۴۵۷	۱۱۰	۶۰۳۱	۲۱۲	۳۱	۳۸۴	بهار
۱۴۱	۲۰	۳۷۸۱	۱۹۳	۰	۲۳	تابستان
۳۶۸	۱۸۸	۱۰۹۲	۸۹	۰	۱۹	پاییز
۷۸۸	۲۹۲	۲۴۵۷	۱۱۴	۳	۴۹	زمستان

* کلاس ۱: طوفان ملایم گردوغبار با دید افقی ۱۰۰۰-۲۰۰ متر، کلاس ۲: طوفان شدید گردوغبار با دید افقی کمتر از ۲۰۰ متر، کلاس ۳: گردوغبار برخاسته با باد (مه ناشی از گردوغبار) و کلاس ۴: گردوغبار معلق با دید افقی کمتر از ۱۰ کیلومتر.

الگوریتم Boruta، تشریح می‌شوند.

جنگل تصادفی یک روش Ensemble مبتنی بر مجموعه‌ای از درختان تصمیم است که با نمونه‌گیری بوت‌استرپ از داده‌ها و انتخاب تصادفی زیرمجموعه‌ای از ویژگی‌ها در هر گره، درخت‌های نسبتاً مستقل تولید می‌کند (بریمن، ۲۰۰۱). پیش‌بینی نهایی با تجمیع خروجی درخت‌ها (رأی‌گیری برای طبقه‌بندی) به‌دست می‌آید. RF علاوه بر مهارت مناسب در داده‌های غیرخطی و دارای نوسان زیاد، امکان محاسبه «اهمیت نسبی ویژگی‌ها» را نیز فراهم می‌کند؛ معیاری که در این مطالعه برای تحلیل نقش متغیرهای همدیدی، به‌ویژه شاخص‌های جت‌استریم، در وقوع طوفان گردوغبار استفاده شده است.

برای کاهش ابعاد داده و بیرون کشیدن تمام متغیرهای واقعاً مؤثر بر وقوع گردوغبار، از الگوریتم Boruta استفاده شد. این روش که بر پایه جنگل تصادفی است، به‌جای انتخاب یک «مجموعه حداقلی» از ویژگی‌ها، تلاش می‌کند همه متغیرهایی را که به‌طور معنادار در توضیح متغیر هدف نقش دارند، شناسایی کند (کورسا و رودنیک، ۲۰۱۰). در Boruta برای هر متغیر واقعی، یک نسخه تصادفی‌سازی‌شده (Shadow) ساخته می‌شود؛ سپس در هر تکرار، جنگل تصادفی روی مجموعه کامل ویژگی‌های واقعی و سایه اجرا شده و اهمیت هر متغیر محاسبه می‌شود. اگر اهمیت یک متغیر واقعی به‌طور معنادار از حداکثر اهمیت متغیرهای سایه بیشتر باشد، به‌عنوان «پذیرفته‌شده» در نظر گرفته می‌شود و در غیر این صورت رد یا به‌صورت «نامشخص» علامت‌گذاری می‌شود. برای کاهش اثر نوسانات تصادفی، تصمیم نهایی با استفاده از آزمون فرض و رویه کمکی TentativeRoughFix انجام می‌گیرد (بریمن، ۲۰۰۱؛ کورسا و رودنیک، ۲۰۱۰).

ویژگی اصلی Boruta در این پژوهش آن است که بدون فرض خطی بودن روابط، می‌تواند در میان ترکیبی از متغیرهای همدیدی، ترمودینامیکی و سطح‌زمین، همه متغیرهای واقعاً اثرگذار-حتی متغیرهایی با نقش نسبتاً ضعیف اما معنادار مانند برخی شاخص‌های جت‌استریم-را حفظ کرده و در عین حال متغیرهای کم‌اهمیت یا دارای

در گام بعد، برای همین زمان‌ها میدان باد تراز بالا از بازتحلیل NCEP-DOE Reanalysis 2 با تفکیک زمانی ۶ ساعته و افقی $2.5^\circ \times 2.5^\circ$ ، روی ناحیه‌ای شامل غرب و جنوب‌غرب ایران و کانون‌های غبار عراق و شبه‌جزیره عربستان استخراج شد (کانامیتسو و همکاران، ۲۰۰۲؛ نوتارو و همکاران، ۲۰۱۳؛ حمیدی و همکاران، ۲۰۱۳). با توجه به تمرکز جت جنب‌حاره‌ای در لایه ۳۰۰-۲۰۰ هکتوپاسکال، تراز ۲۵۰ هکتوپاسکال به‌عنوان سطح مرجع انتخاب شد (آلچر و کالدیریا، ۲۰۰۸؛ هولتون و حکیم، ۲۰۱۳) و در آن، سرعت کل باد از مؤلفه‌های u و v محاسبه و نواحی با $V \geq 25 \text{ m/s}$ به‌عنوان «منطقه جتی» تعریف شد (وولینگز و همکاران، ۲۰۱۰؛ کوخ و همکاران، ۲۰۰۶). سپس سه شاخص اصلی برای هر زمان به‌دست آمد: بیشینه سرعت باد درون منطقه جتی (شدت هسته جت)، مختصات عرض و طول همین بیشینه (موقعیت هسته جت) و میانگین سرعت باد روی کل ناحیه جتی به‌عنوان معیاری از قدرت و گستره کلی جت. این شاخص‌ها همراه با داده‌های سطحی ایستگاه‌ها (باد، فشار، دما و دید افقی) به‌عنوان ورودی مدل‌های یادگیری ماشین به‌کار گرفته شد تا وضعیت هم‌زمان جریان جتی در چارچوب طبقه‌بندی وارد شود و بتوان نقش تغییرات جریان جتی در تعدیل میدان فشار سطحی و همچنین تغییرات بادهای نزدیک سطح خیزاننده گردوغبار را به‌صورت کمی (بر مبنای اهمیت ویژگی‌ها و عملکرد مدل‌ها) ارزیابی کرد؛ رویکردی که با مطالعات دینامیکی انجام‌شده در جنوب‌غرب آسیا سازگار است (عبدی ویشکایی و همکاران، ۲۰۱۲؛ نوتارو و همکاران، ۲۰۱۳؛ شائو و دونگ، ۲۰۰۶).

۲-۳. مدل‌ها

۲-۳-۱. روش انتخاب ویژگی بروتا (Boruta)

با توجه به این‌که برخی از روش‌های انتخاب ویژگی و تفسیرپذیری مورد استفاده در این پژوهش بر پایه الگوریتم جنگل تصادفی توسعه یافته‌اند، ابتدا چارچوب کلی Random Forest به‌عنوان یک مدل Ensemble غیرخطی معرفی می‌شود و سپس روش‌های مشتق‌شده از آن، از جمله

ویژگی از هم جدا می‌کند یا در مسائل وایازشی تابعی با پیچیدگی حداقلی را به داده‌ها برازش می‌دهد. در نسخه وایازشی ϵ -SVR، تابع $f(x)$ جست‌وجو می‌شود که خطاهای کوچک‌تر از ϵ را نادیده گرفته و تنها انحراف‌های بزرگ‌تر را به وسیله متغیرهای کمکی $\tilde{y}_i$ و $\tilde{y}_i^*$ جریمه می‌کند؛ این سازوکار «حاشیه‌نرم» امکان کار با داده‌های دارای نویسان را فراهم می‌سازد (کورتس و واپنیک، ۱۹۹۵؛ واپنیک، ۱۹۹۵؛ اسمولا و شولکوف، ۲۰۰۴).

برای مدل‌سازی روابط غیرخطی بین متغیرهای ورودی و وقوع طوفان گردوغبار، از کرنل شعاعی پایه (RBF) استفاده شد. در این حالت، شباهت بین دو بردار x_i و x_j به صورت

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \quad \gamma > 0 \quad (1)$$

تعریف شده و بدون محاسبه صریح نگاشت $\phi(x)$ ، یک مرز تصمیم‌گیری انعطاف‌پذیر در فضای ویژگی ایجاد می‌شود. این ساختار در بسیاری از کاربردهای هواشناسی برای مدل‌سازی نگاشت‌های غیرخطی بین عناصر همدیدی و رخدادهای حدی مؤثر گزارش شده است (واپنیک، ۱۹۹۵). در بخش طبقه‌بندی، از تابع زیان کلاسیک Hinge برای آموزش مدل استفاده شد.

۲-۳-۴. مدل تقویت‌گرادیانی XGBoost (eXtreme Gradient Boosting)

XGBoost نسخه‌ای کارآمد و مقیاس‌پذیر از الگوریتم Gradient Boosting است که مجموعه‌ای از درخت‌های تصمیم ضعیف را به صورت افزایشی ترکیب می‌کند. در هر تکرار، درخت جدید برای کاهش خطای باقیمانده مدل قبلی آموزش داده می‌شود و به کمک بسط مرتبه دوم تابع زیان (استفاده هم‌زمان از گرادیان و هسین) بهینه‌سازی به سرعت انجام می‌شود (چن و گوسترین، ۲۰۱۶). تابع هدف شامل جزء خطا و یک جمله منظم‌ساز است که پیچیدگی درخت‌ها را کنترل کرده و از بیش‌برازش جلوگیری می‌کند. قابلیت مدیریت داده‌های ناقص، کنترل دقیق ساختار درخت‌ها و وجود تنظیم‌گرهای قوی، XGBoost را برای مدل‌سازی پدیده‌های اقلیمی

نویسان زیاد را حذف کند. با توجه به پیچیدگی سامانه‌های همدیدی در خاورمیانه و چندمنبعی بودن داده‌های اقلیمی، این رویکرد برای تنظیم ورودی مدل‌های یادگیری ماشین در این مطالعه مناسب ارزیابی شد (بومرت و همکاران، ۲۰۲۰).

۲-۳-۲. ارزیابی عملکرد مدل‌های هوش مصنوعی با استفاده از ماتریس درهم‌ریختگی و شاخص‌های طبقه‌بندی

خروجی مدل‌ها به صورت طبقه‌بندی دودویی «وقوع طوفان گردوغبار» (کلاس ۱) و «عدم وقوع» (کلاس ۰) در نظر گرفته شد. برای سنجش مهارت مدل‌ها، از ماتریس درهم‌ریختگی به عنوان چارچوب اصلی استفاده شد؛ ابزاری که در یادگیری ماشین و اعتبارسنجی پیش‌بینی‌های رخدادمحور هواشناسی متداول است (بیشاپ، ۲۰۰۶؛ ویلکس، ۲۰۱۱؛ جولیف و استفنسون، ۲۰۱۲).

در ماتریس 2×2 ، چهار مؤلفه اصلی شامل رخدادهای درست تشخیص داده شده (TP)، رخدادهای از دست‌رفته (FN)، اختطارهای کاذب (FP) و عدم‌وقوع‌های درست (TN) محاسبه شد. بر اساس این چهار مقدار، شاخص‌های دقت کلی (Accuracy)، دقت پیش‌بینی طوفان (Precision)، قابلیت آشکارسازی طوفان (Recall) یا حساسیت (Sensitivity) و شاخص $F1$ به دست آمدند (سوکولووا و لاپالم، ۲۰۰۹؛ پاورز، ۲۰۱۱). تمرکز تحلیل بر رفتار مدل نسبت به کلاس ۱ بود تا مشخص شود چه نسبتی از طوفان‌های واقعی به درستی شناسایی می‌شوند و چه نسبتی از آنها به صورت خطای از دست‌رفته در کلاس بدون طوفان قرار می‌گیرند. استفاده هم‌زمان از این چهار شاخص، به ویژه در شرایط نامتوازن بودن تعداد روزهای طوفانی و غیرطوفانی، تصویر دقیق‌تری از عملکرد مدل‌ها نسبت به تکیه صرف بر Accuracy فراهم کرد.

۲-۳-۳. ماشین بردار پشتیبان (SVM)

SVM یکی از روش‌های شناخته‌شده یادگیری نظارت‌شده است که با تعریف یک حاشیه بهینه، داده‌ها را در فضای

پیچیده مانند طوفان‌های گردوغبار مناسب می‌سازد.

۲-۳-۵. شبکه عصبی با تابع پایه شعاعی (RBFNN)

شبکه RBF یک شبکه پیش‌خور سه‌لایه است که در لایه میانی خود از نورون‌هایی با تابع پایه شعاعی استفاده می‌کند. هر نورون پنهان، فاصله ورودی x تا مرکز خود c_i را محاسبه و آن را از طریق یک تابع گاوسی:

$$\varphi_i(r) = \exp\left(-\frac{r^2}{\sigma_i^2}\right) \quad (2)$$

به خروجی تبدیل می‌کند. در مرحله آموزش، ابتدا مراکز و عرض‌های σ_i معمولاً با روش‌هایی مانند K-means برآورد و سپس وزن‌های لایه خروجی با روش حداقل مربعات تنظیم می‌شوند (برومهد و لوی، ۱۹۸۸؛ هایکین، ۲۰۰۹؛ بیشاپ، ۲۰۰۶). خروجی نهایی شبکه به صورت ترکیب خطی فعال‌سازی‌های φ_i و یک بایاس نوشته می‌شود. به دلیل ماهیت محلی و توانایی در تقریب توابع غیرخطی، RBFNN برای پیش‌بینی سری‌های زمانی اقلیمی و متغیرهایی مانند غلظت گردوغبار و PM به طور گسترده استفاده شده است (پارک و سندبرگ، ۱۹۹۱).

۲-۳-۶. مدل آماری وایزش لجستیک (Log-Logistic)

برای پیش‌بینی وقوع طوفان گردوغبار

برای فراهم کردن یک خط مبنای آماری ساده و تفسیرپذیر، در کنار مدل‌های یادگیری ماشین از وایزش لجستیک دودویی نیز استفاده شد. در این مدل، احتمال وقوع طوفان گردوغبار برای هر نمونه i به صورت:

$$p_i = \frac{1}{1 + \exp(-(\beta_0 + \sum_{j=1}^k \beta_j x_{ij}))} \quad (3)$$

مدل می‌شود که در آن x_{ij} متغیرهای ورودی (شاخص‌های جت و عناصر همدیدی سطحی) و β_j ضرایب وایزش هستند (هوسمر و همکاران، ۲۰۱۳؛ جیمز و همکاران، ۲۰۱۳). ضرایب با روش بیشینه‌سازی درست‌نمایی برآورد


شده و در مقیاس لجیت، تغییر در لگاریتم نسبت شانس وقوع طوفان را به‌ازای یک واحد تغییر در هر متغیر بیان می‌کنند (ویلکس، ۲۰۱۱). خروجی احتمالاتی مدل با یک آستانه تصمیم به کلاس‌های ۰ و ۱ تبدیل و همانند سایر مدل‌ها در قالب ماتریس درهم‌ریختگی و شاخص‌های Accuracy، Precision، Recall و FI ارزیابی شد (جولیف و استفسون، ۲۰۱۲؛ پاورز، ۲۰۱۱). این مدل علاوه بر فراهم کردن مرجع مقایسه، امکان تفسیر مستقیم نقش هر شاخص جت و متغیر همدیدی در افزایش یا کاهش احتمال وقوع طوفان را فراهم کرد.

۲-۳-۷. تفسیرپذیری مدل با استفاده از SHAP

برای افزایش تفسیرپذیری مدل‌های یادگیری ماشین و بررسی سهم هر متغیر در پیش‌بینی وقوع طوفان گردوغبار، از چارچوب SHAP (SHapley Additive) استفاده شد. SHAP (exPlanations) بر پایه مقادیر SHapley در نظریه بازی‌های مشارکتی بنا شده و برای هر نمونه، یک مقدار φ_i به هر ویژگی i نسبت می‌دهد که اثر حاشیه‌ای آن ویژگی را بر خروجی مدل (نسبت به مقدار میانگین) نشان می‌دهد (لوندبرگ و لی، ۲۰۱۷؛ لوندبرگ و همکاران، ۲۰۲۰).

در این مطالعه، پس از آموزش هر مدل، مقادیر SHAP برای همه ویژگی‌ها و همه نمونه‌ها محاسبه شد و از نمودارهای خلاصه (summary plot) و نمودارهای وابستگی (dependence plot) برای نمایش اهمیت کلی ویژگی‌ها و جهت اثر آنها بر احتمال وقوع طوفان استفاده شد. این رویکرد امکان مقایسه ساختاری مدل‌ها و ارتباط پیش‌بینی‌های آنها با سازوکارهای فیزیکی گردوغبار را فراهم می‌کند (مولنار، ۲۰۲۰).

شکل ۳ نمایی خلاصه از مراحل اجرای پژوهش، از گردآوری داده‌ها تا ارزیابی مدل‌ها را نشان می‌دهد.



شکل ۲. فلوچارت مراحل انجام پژوهش و فرایند مدل‌سازی.

۳. نتایج

۳-۱. عملکرد مدل‌ها در طبقه‌بندی رخدادهای گردوغبار متناظر با دید افقی کمتر از ۱۰۰۰ متر در شرایط متأثر از جریان جتی (جت‌استریم)

۳-۱-۱. انتخاب ویژگی با استفاده از روش بروتا


در حالت «همراه با جت‌استریم»، نتایج Boruta (شکل ۳) نشان می‌دهد که ارتفاع ژئوپتانسیل تراز ۲۵۰hPa (geops) مهم‌ترین متغیر در بین همه ویژگی‌هاست و اهمیت آن به مراتب از سایر متغیرها بیشتر است؛ یعنی وضعیت میدان تراز بالا و به‌ویژه ناوه‌ها و هسته جت، قوی‌ترین سیگنال را برای تمایز روزهای طوفان از روزهای بدون طوفان در اختیار مدل قرار می‌دهد.

پس از geops، گروهی از متغیرها با اهمیت متوسط قرار می‌گیرند: سرعت باد ۱۰ متری (ff10)، مؤلفه مداری باد تراز بالا (uwnd) و سپس فشار سطح دریا و فشار ایستگاه (p0 و P) و دمای هوا (۱۰-۲۰۰cm). این ترکیب نشان می‌دهد که در کنار ساختار تراز بالا، شدت بادهای سطحی و میدان فشار سطحی نیز در رژیم جتی برای تفکیک دو کلاس نقش کلیدی دارند. سایر متغیرها مانند دمای بیشینه و کمینه، جهت باد (dd)، دمای هوای ۲ متری، دمای سطح زمین و مؤلفه نصف‌النهاری باد (vwnd) سهم بسیار کمتری در اهمیت کلی دارند و نقش آنها در مقایسه با متغیرهای فوق ثانویه است.


۳-۱-۲. ارزیابی کمی عملکرد مدل‌ها در طبقه‌بندی رخدادهای گردوغبار (متر >۱۰۰۰ دید افقی) در شرایط متأثر از جریان جتی (جت‌استریم)

منحنی‌های ROC (شکل ۴) نشان می‌دهند که در حضور جت‌استریم، قدرت تشخیص «روزهای طوفانی/غیرطوفانی» بین مدل‌ها تفاوت زیادی دارد. شاخص AUC که مستقل از آستانه است، روی داده آزمون بیانگر برتری مدل‌های درختی تجمیعی است؛ به‌طوری‌که Random Forest (AUC=0.931) و XGBoost (AUC=0.925) مهارت «بسیار بالا»، RBFNN (AUC=0.855) عملکرد «خوب» و SVM و Logistic (AUC=0.641) در مقابل، (AUC=0.667) تنها کمی بهتر از حد تصادفی عمل می‌کنند. مقایسه با داده آموزش (شکل الف) (AUC≈0.975 برای RF و XGBoost، ۰/۸۷۳ برای RBFNN و مقادیر پایین‌تر برای Logistic و SVM) نشان می‌دهد افت نسبتاً کم AUC در RF، XGBoost و RBFNN بیانگر تعمیم‌پذیری مناسب این مدل‌ها و استفاده مؤثر این مدل‌های غیرخطی از اطلاعات دینامیکی جریان جتی (جت‌استریم) است، در حالی که فاصله بیشتر آموزش-آزمون در مدل لجستیک بیانگر ناتوانی آن در بازنمایی روابط غیرخطی بین شاخص‌های جت و رخداد طوفان گردوغبار است.

Boruta Feature Selection Importance



شکل ۳. نمودار وزن متغیرهای مورد استفاده در پیش‌بینی‌کننده‌های هواشناسی در شرایط متأثر از جریان جتی.



شکل ۴. منحنی‌های ROC و مقادیر مساحت زیر منحنی (AUC) برای مدل‌های Logistic، SVM، RBFNN، Random Forest و XGBoost در پیش‌بینی وقوع طوفان گردوغبار در حضور جت‌استریم؛ (الف) دوره آموزش، (ب) دوره آزمون. محور افقی: اختصاصیت (Specificity) و محور عمودی: حساسیت (Sensitivity).


در حضور شاخص‌های جت‌استریم تعمیم‌پذیری خوبی دارند. در مقابل، SVM با وجود دقت قابل قبول (۰/۸۲) به دلیل حساسیت پایین (۰/۴۰) و F1 حدود ۰/۴۹ تعداد زیادی از طوفان‌ها را در کلاس ۲ قرار می‌دهد. وضعیت برای RBFNN و وایزش لجستیک نامناسب‌تر است؛ هرچند دقت آنها در آزمون حدود ۰/۷۵-۰/۷۸ است، اما تنها حدود ۱۰-۸ درصد طوفان‌های کلاس ۱ را شناسایی می‌کنند و عملاً بیشتر رخدادهای مهم را از دست می‌دهند؛ الگویی که در داده‌های نامتوازن گمراه‌کننده است. در مجموع، در حضور جت‌استریم، مدل‌های RF و XGBoost به مراتب کارآمدتر از SVM، RBFNN و لجستیک در تفکیک طوفان گردوغبار متوسط از تعلیق گردوغبار هستند و برای سامانه‌های هشدار و پایش دید افقی پایین مناسب‌تر به نظر می‌رسند.

در ماتریس‌های درهم‌ریختگی (شکل ۵)، کلاس ۱ به عنوان «کلاس هدف» طوفان گردوغبار با دید ۲۰۰ تا ۱۰۰۰ متر و کلاس ۲ به عنوان تعلیق گردوغبار با دید افقی کمتر از ۱۰ کیلومتر در نظر گرفته شده است. به دلیل نامتوازن بودن داده‌ها، اتکا به دقت کلی نیست و ارزیابی باید بر شاخص‌هایی مانند حساسیت، دقت و F1 برای کلاس ۱ متمرکز باشد.

نتایج نشان می‌دهد مدل‌های درختی تجمیعی (Random Forest و XGBoost) در دوره آزمون بهترین توازن را بین شناسایی طوفان و کاهش هشدارهای کاذب دارند: RF با دقت حدود ۰/۹۰، حساسیت ۰/۸۰ و $F1 \approx 0.77$ و XGBoost با حساسیت ۰/۷۲ و $F1 \approx 0.71$ بخش زیادی از رخدادهای واقعی طوفان را شناسایی می‌کنند و افت شاخص‌ها نسبت به آموزش نیز کم است؛ یعنی این دو مدل

جدول ۳. مقادیر شاخص‌های ارزیابی به دست آمده از ماتریس درهم‌ریختگی (Accuracy، Precision، Recall و F1-score) برای مدل‌های Random Forest، XGBoost، SVM، RBFNN و وایزش لجستیک در طبقه‌بندی دوکلاسی طوفان گردوغبار متوسط (کلاس ۱) و تعلیق گردوغبار (کلاس ۲) در حضور جریان جت‌استریم.


مدل	آموزش				آزمون			
	Accuracy	Precision	Recall	F1-score	Accuracy	Precision	Recall	F1-score
RF	۰/۹۴	۰/۷۵	۰/۹۸	۰/۸۵	۰/۹۰	۰/۷۴	۰/۸۰	۰/۷۷
XGBoost	۰/۹۴	۰/۷۵	۰/۹۷	۰/۸۵	۰/۸۶	۰/۶۹	۰/۷۲	۰/۷۱
SVM	۰/۸۸	۰/۶۹	۰/۵۷	۰/۶۲	۰/۸۲	۰/۶۲	۰/۴۰	۰/۴۹
RBFNN	۰/۸۵	۰/۶۴	۰/۲۳	۰/۳۴	۰/۷۵	۰/۶۰	۰/۰۹	۰/۱۶



شکل ۵. ماتریس‌های درهم‌ریختگی مدل‌های Random Forest، XGBoost، SVM، RBFNN و وایزش لجستیک در دوره‌های آموزش (الف) و آزمون (ب) برای دو کلاس: (۱) طوفان گردوغبار ملایم با دید افقی ۲۰۰ تا ۱۰۰۰ متر، (۲) تعلیق گردوغبار با دید افقی کمتر از ۱۰ کیلومتر، در شرایط حضور جت‌استریم.

هنوز خطاهای قابل‌توجهی، به‌ویژه در کلاس ۱، دارند. کوچک‌ترین سطح مربوط به وایزش لجستیک است که ضعیف‌ترین دقت طبقه‌بندی را نشان می‌دهد و بیشترین برچسب‌گذاری نادرست را تولید می‌کند. این الگو با نتایج AUC و ماتریس‌های درهم‌ریختگی هم‌خوان است و دوباره بر برتری مدل‌های درختی تجمیعی، به‌ویژه XGBoost و RF، در حضور اطلاعات دینامیکی جت‌استریم تأکید می‌کند.

نمودار رادارپلات دقت (شکل ۶) نشان می‌دهد هرچه چندضلعی یک مدل بزرگ‌تر و به مرکز بیرونی نزدیک‌تر باشد، توان آن در تفکیک طوفان گردوغبار (کلاس ۱) از تعلیق گردوغبار (کلاس ۲) بیشتر است. در این نمودار، XGBoost و سپس Random Forest در اغلب محورها بالاترین Precision را برای هر دو کلاس دارند و در نتیجه، نرخ اخطار کاذب آنها پایین است. SVM و RBFNN در حد میانی قرار می‌گیرند و



شکل ۶. مقایسه دقت طبقاتی (Precision) مدل‌های Random Forest، XGBoost، SVM، RBFNN و وایزش لجستیک با استفاده از نمودار رادار برای دو کلاس: (۱) طوفان گردوغبار ملایم با دید افقی ۲۰۰ تا ۱۰۰۰ متر، (۲) تعلیق گردوغبار با دید افقی کمتر از ۱۰ کیلومتر در شرایط حضور جت‌استریم.


۳-۱-۳. تفسیر مدل برتر در شناسایی پدیده‌های

تحت تأثیر جریان جت‌استریم با تحلیل SHAP

نمودار نهایی SHAP مدل XGBoost (شکل ۷) نشان می‌دهد همان متغیرهایی که در مرحله انتخاب ویژگی بر اساس Boruta مهم تشخیص داده شدند، در مدل نهایی نیز بیشترین نقش را در خروجی دارند؛ موضوعی که با نتایج AUC و رادارپلات هم‌خوان است. میانگین قدرمطلق SHAP برای متغیرها (به ترتیب $\text{geops} \approx 0.218$ ، $\text{ff.10} \approx 0.011$ ، $\text{p0} \approx 0.023$ ، $\text{uwnd} \approx 0.014$ ، $\text{t} \approx 0.012$ و $\text{p} \approx 0.009$) اهمیت کلی آنها را نشان می‌دهد. با توجه به آستانه ۰/۰۱۱، دقیقاً همان متغیرهای geops ، p0 ، uwnd و ff.10 که به‌عنوان هسته اطلاعاتی انتخاب شده بودند، بالاترین |SHAP| را در مدل آموزش‌دیده نیز دارند؛ یعنی XGBoost واقعاً بر این اطلاعات تکیه می‌کند نه بر نوسان. از نظر فیزیکی، geops (ارتفاع ژئوپتانسیل hPa ۲۵۰) مهم‌ترین نقش را دارد؛ به گونه‌ای که کاهش آن احتمال قرارگیری نمونه در کلاس «دید کمتر از ۱۰۰۰ متر» را افزایش می‌دهد و این نتیجه با نقش ناوه‌ها و هسته‌های جریان جتی در تشدید رخدادهای گردوغبار در منطقه سازگار است. متغیرهای p0 و p نیز نشان می‌دهند فشارهای

پایین‌تر با SHAP مثبت و افزایش احتمال رخداد طوفان همراه‌اند؛ امری که با تقویت میدان فشار سطحی (الگوی کم‌فشاری) و در پی آن افزایش بادهای نزدیک سطح برانگیزاننده گردوغبار هم‌خوانی دارد. برای uwnd و ff.10 نیز مقادیر بالاتر سرعت باد در تراز بالا و در سطح، به‌طور منظم با افزایش احتمال کاهش دید همراه‌اند؛ رفتاری مطابق با نتایج مطالعات همدیدی گردوغبار.

از نظر عملکرد، XGBoost در حضور جت‌استریم روی داده آزمون به $\text{AUC} \approx 0.925$ رسیده که در محدوده «بسیار خوب» برای جداسازی کلاس «طوفان گردوغبار ملایم» از «تعلیق گردوغبار» است و رادارپلات نیز نشان می‌دهد این مدل (در کنار RF) بالاترین Precision را برای هر دو کلاس دارد و نرخ هشدار کاذب آن پایین است. هم‌خوانی ساختار SHAP با این شاخص‌ها نشان می‌دهد ویژگی‌های غالب مدل (geops ، p0 ، uwnd ، ff.10 و ...) همان مؤلفه‌های دینامیکی و ترمودینامیکی‌اند که دو کلاس را از هم جدا می‌کنند؛ بنابراین XGBoost در حضور اطلاعات دینامیکی جت‌استریم، هم از نظر آماری و هم از نظر تبیین فیزیکی، مدلی معتبر و تفسیرپذیر برای طوفان‌های گردوغبار است.



شکل ۷. تبیین مدل XGBoost با استفاده از SHAP در شرایط دید افقی کمتر از ۱۰۰۰ متر ناشی از طوفان گردوغبار متأثر از جت‌استریم.

۲-۳. عملکرد مدل‌ها در طبقه‌بندی رخدادهای گردوغبار
متناظر با دید افقی کمتر از ۱۰۰۰ متر در شرایط عدم حضور جریان جتی (جت‌استریم)

در این بخش، عملکرد مدل‌ها برای رخدادهای کاهش دید افقی کمتر از ۱۰۰۰ متر در غیاب جت‌استریم تراز بالا بررسی می‌شود. همان رویه پیشین به کار رفته است: ابتدا با الگوریتم Boruta مهم‌ترین متغیرها استخراج شده، سپس چهار مدل Random Forest، XGBoost، SVM و RBFNN با این ورودی‌ها آموزش داده و با استفاده از ماتریس درهم‌ریختگی و شاخص‌هایی مانند Accuracy، Precision، Recall، F1 و رادارپلات ارزیابی شدند تا میزان پایداری و تعمیم‌پذیری آنها در شرایطی که نقش اصلی با فرایندهای سطحی و محلی است، سنجیده شود.

در این رژیم، مسئله از دو کلاسی به چهار کلاسی تبدیل شده است: کلاس ۱ طوفان ملایم، کلاس ۲ طوفان شدید، کلاس ۳ گردوغبار برخاسته با باد (کد همدیدی ۰۶) و کلاس ۴ گردوغبار معلق (کد همدیدی ۰۷). توزیع داده‌ها نیز نامتوازن است و کلاس ۳ فراوانی بسیار بیشتری دارد. در نتیجه، کاهش Accuracy نسبت به حالت دودویی امری طبیعی است و این شاخص به‌تنهایی برای قضاوت کافی نیست؛ بنابراین تحلیل باید با تکیه بر معیارهایی مانند حساسیت، F1 و kappa انجام شود تا تصویر واقع‌بینانه‌تری از توان مدل در تفکیک هر چهار کلاس ارائه شود. جدول


۴ نشان‌دهنده توزیع نمونه‌ها در هر کلاس است.
این توزیع نشان می‌دهد که داده‌ها از نظر کلاس طوفان گردوغبار نسبتاً نامتعادل هستند، که می‌تواند بر عملکرد مدل‌های طبقه‌بندی تأثیر بگذارد (به ویژه کلاس‌هایی که کمتر نمایندگی دارند).

۳-۲-۱. انتخاب پیش‌بینی‌کننده بروتا و رفتار همگرایی در غیاب جریان جریان جتی (جت‌استریم)

در رژیم «بدون جت‌استریم»، نتایج Boruta (شکل ۸) نشان می‌دهد که سه متغیر تندی (ff)، فشار سطح ایستگاه (p_0) و ارتفاع ژئوپتانسیل ۲۵۰ hPa (geops) بیشترین نقش را در جداسازی چهار کلاس گردوغبار دارند و به‌طور محسوسی بالاتر از سایر متغیرها قرار می‌گیرند. پس از این سه، متغیرهای با اهمیت متوسط شامل سرعت باد ۱۰ متری (ff10) و مؤلفه مداری باد تراز بالا (uwnd) و سپس فشار سطح دریا (P) و دمای هوا (۱۰-۲۰۰ cm) (t) قرار می‌گیرند. سایر ویژگی‌ها مانند دمای بیشینه و کمینه، جهت باد، دمای ۲ متری، دمای سطح زمین و مؤلفه نصف‌النهاری باد تراز بالا سهم ناچیزی در اهمیت کلی دارند. به‌طور خلاصه، در غیاب جریان جتی (جت‌استریم)، ترکیب باد سطحی و میدان فشار، ستون فقرات اطلاعاتی مورد نیاز برای تفکیک شدت و نوع گردوغبار را تشکیل می‌دهد و اطلاعات تراز بالا نقش کم اهمیت‌تری دارند.

جدول ۴. توزیع نمونه‌ها در هر کلاس.

کلاس طوفان گردوغبار	محدوده دید افقی	تعداد نمونه	درصد از کل
کلاس ۱	۲۰۰ تا ۱۰۰۰ متر	۱۷۵۴	۱۱
کلاس ۲	کمتر از ۲۰۰ متر	۶۱۰	۴
کلاس ۳	مه ناشی از گردوغبار	۱۳۳۶۱	۸۲
کلاس ۴	کمتر از ۱۰ کیلومتر	۶۰۸	۳



شکل ۸. الگوریتم Boruta برای انتخاب فراوانی پیش‌بینی‌کننده‌های هواشناسی در غیاب جریان جت استریم.


است؛ یعنی از نظر تعمیم‌پذیری و پایداری بهترین مدل در این رژیم به‌شمار می‌آید. RBFNN نیز با دقت نزدیک به نرخ پایه ($\sim 0/82$) و حساسیت تقریباً صفر برای کلاس‌های ۱، ۲ و ۴، عملاً بیشتر نمونه‌ها را به کلاس ۳ نسبت می‌دهد و برای کاربردهای هشداردهنده مناسب نیست. در نتیجه، با توجه به چندکلاسی و نامتوازن بودن داده‌ها، انتخاب SVM به‌عنوان مدل برتر در شرایط بدون جت‌استریم منطقی است، در حالی که در رژیم «با جت‌استریم» و مسئله دوکلاسی، مدل‌های درختی تجمیعی (RF و XGBoost) به دلیل استفاده از اطلاعات دینامیکی قوی جریان جتی عملکرد مناسب‌تری داشتند.

در مسئله چهارکلاسی «بدون جت‌استریم» (شکل ۹)، اگرچه RF و XGBoost روی داده آموزش دقت بسیار بالایی (حدود $0/98$ و $0/94$) به‌دست می‌آورند، اما کاهش دقت آنها در آزمون به حدود $0/84$ و کاهش شدید حساسیت برای کلاس‌های ۱، ۲ و ۴ نشان می‌دهد که این دو مدل عمدتاً کلاس غالب یعنی گردوغبار برخاسته با باد (کلاس ۳) را خوب تشخیص می‌دهند و در شناسایی طوفان‌های ملایم، شدید و گردوغبار معلق عملکرد ضعیفی دارند. در مقابل، SVM با هسته RBF با وجود دقت آموزشی پایین‌تر ($\sim 0/86$)، روی آزمون به بالاترین Accuracy (حدود $0/85$) می‌رسد و شکاف آموزش-آزمون آن بسیار کم ($\sim 0/006$)

جدول ۵. مقادیر شاخص‌های ارزیابی به‌دست‌آمده از ماتریس درهم‌ریختگی (Accuracy, Precision, Recall و F1-score) برای مدل‌های

Random Forest, XGBoost, SVM و RBFNN در طبقه‌بندی چهارکلاسی طوفان گردوغبار در غیاب جریان جت‌استریم


آزمون				آموزش				کلاس	مدل
F1-score	Recall	Precision	Accuracy	F1-score	Recall	Precision	Accuracy		
0/45	0/34	0/65	0/85	0/50	0/38	0/72	0/86	کلاس ۱	SVM
0/17	0/10	0/52		0/18	0/11	0/70		کلاس ۲	
0/92	0/99	0/87		0/93	0/99	0/87		کلاس ۳	
0/05	0/02	1/00		0/02	0/01	0/71		کلاس ۴	
0/01	0/00	0/66	0/82	0/01	0/00	0/66	0/82	کلاس ۱	RBFN
NA	0/00	NA		NA	0/00	NA		کلاس ۲	
0/90	0/99	0/82		0/90	0/99	0/82		کلاس ۳	
NA	0/00	NA		NA	0/00	NA		کلاس ۴	
0/49	0/45	0/54	0/84	0/92	0/89	0/95	0/98	کلاس ۱	Random Forest
0/24	0/18	0/35		0/94	0/92	0/96		کلاس ۲	
0/92	0/95	0/88		0/98	0/99	0/98		کلاس ۳	
0/17	0/11	0/45		0/99	0/98	1/00		کلاس ۴	
0/47	0/40	0/58	0/84	0/80	0/68	0/97	0/94	کلاس ۱	XGBoost
0/19	0/14	0/30		0/85	0/74	0/98		کلاس ۲	
0/92	0/97	0/88		0/96	0/99	0/93		کلاس ۳	
0/17	0/11	0/48		0/78	0/64	0/98		کلاس ۴	



شکل ۹. ماتریس‌های درهم‌ریختگی مدل‌های Random Forest، XGBoost، SVM و RBFNN برای طبقه‌بندی چهارکلاسی وضعیت گردوغبار در غیاب جریان جت‌استریم؛ (الف) دوره آموزش، (ب) دوره آزمون.

غالب (گردوغبار برخاسته با باد) دقت بالایی دارند و وقتی طوفان یا گردوغبار برخاسته را پیش‌بینی می‌کنند، نسبت خطای کاذب بیشتری دارند. RBFNN نیز در اغلب محورها نزدیک مرکز قرار می‌گیرد و کمترین Precision را در تفکیک چهار کلاس نشان می‌دهد. این نتایج با دقت کلی و ماتریس‌های درهم‌ریختگی سازگار است و تأیید می‌کند که در رژیم بدون حضور جت‌استریم، SVM پایدارترین و قابل‌اعتمادترین مدل برای طبقه‌بندی چهار وضعیت گردوغبار است.

رادارپلات دقت طبقه‌بندی (شکل ۱۰) نشان می‌دهد در غیاب جت‌استریم، SVM متعادل‌ترین و گسترده‌ترین چندضلعی را دارد؛ یعنی برای سه کلاس رخدادمحور (طوفان ملایم، طوفان شدید و گردوغبار معلق) بالاترین یا نزدیک به بالاترین Precision را کسب کرده و فقط در گردوغبار برخاسته با باد کمی ضعیف‌تر از RF و XGBoost است. به عبارت دیگر، این مدل کمترین اخطار کاذب را در مهم‌ترین وضعیت‌های مخاطره‌آمیز تولید می‌کند. در مقابل، Random Forest و XGBoost فقط برای کلاس



شکل ۱۰. مقایسه دقت طبقه‌بندی (Precision) چهار مدل Random Forest، XGBoost، SVM و RBFNN با استفاده از نمودار رادار برای طبقه‌بندی چهارکلاسی وضعیت گردوغبار (کلاس ۱: طوفان ملایم گردوغبار، کلاس ۲: طوفان شدید گردوغبار، کلاس ۳: گردوغبار برخاسته با باد، کلاس ۴: گردوغبار معلق) در غیاب جریان جت‌استریم.

است. از نظر عملکرد نیز SVM با Accuracy حدود ۰/۸۵ و فاصله بسیار کم آموزش-آزمون، بهترین تعمیم‌پذیری را در میان مدل‌ها دارد؛ در حالی که RF و XGBoost با وجود دقت آموزشی بالا روی آزمون کاهش بیشتری نشان می‌دهند. تکیه SVM بر متغیرهای نسبتاً پایدارتر فشار-دما می‌تواند یکی از دلایل قابل اعتماد بودن آن در مسئله چهار کلاسی نامتوازن باشد.


۴. بحث

نتایج این پژوهش نشان می‌دهد که ساختار دینامیکی جو نه تنها بر وقوع و نوع طوفان‌های گردوغبار اثر می‌گذارد، بلکه الگوی انتخاب متغیرها و نوع مدلی را که بهترین کارایی را دارد نیز تعیین می‌کند. مقایسه دو رژیم «با جت‌استریم» و «بدون جت‌استریم» نشان داد که در حضور جت، اطلاعات تراز بالای جو و میدان فشار سطحی نقش غالب دارند، در حالی که در غیاب جت، کنترل اصلی گردوغبار بیشتر به فرایندهای ترمودینامیکی و نزدیک به سطح واگذار می‌شود؛ موضوعی که هم در خروجی Boruta و هم در تفسیرهای SHAP به‌روشنی دیده شد.

۳-۲-۲. تفسیر مدل برتر با تحلیل SHAP در غیاب جریان جت‌استریم

نمودار SHAP مدل SVM (شکل ۱۱) در حالت چهارظرفیتی بدون حضور جریان جت‌استریم نشان می‌دهد که این مدل برای تفکیک کلاس‌ها بیشتر به متغیرهای فشار و دما متکی است. مهم‌ترین ویژگی‌ها به ترتیب t (دمای هوا (۲۰۰-۱۰ cm))، p_0 (فشار ایستگاه)، p (فشار سطح دریا)، geops (ارتفاع ژئوپتانسیل تراز ۲۵۰ hPa)، t_{soil} (دمای سطح زمین) و T_{max} هستند. الگوی رنگی نمودار نشان می‌دهد دماهای بالاتر همراه با فشار و ژئوپتانسیل پایین‌تر، نمونه‌ها را به سمت کلاس‌های رخدادمحور (۱، ۲ و ۴) سوق می‌دهد، در حالی که شرایط سردتر و پرفشارتر بیشتر به کلاس گردوغبار برخاسته با باد (۳) مربوط است؛ که با نقش گرمایش سطحی، خشکی خاک و کاهش فشار در خیزش گردوغبار از نظر فیزیکی سازگار است.

مقایسه با نتایج Boruta نشان می‌دهد هسته مشترک p ، p_0 و geops در هر دو روش به عنوان متغیرهای کلیدی باقی می‌ماند، هرچند Boruta (بر پایه RF) باد سطحی را پررنگ‌تر و SHAP در SVM، دما و دمای سطح را برجسته‌تر می‌کند. این تفاوت با ماهیت دو مدل هماهنگ



شکل ۱۱. توضیح مدل برتر (SVM) با استفاده از SHAP در غیاب جریان جت‌استریم.

در رژیم همراه با جت، Boruta متغیرهایی مانند ارتفاع ژئوپتانسیل تراز ۲۵۰hPa (geops)، سرعت باد ۱۰ متری (ff10)، مؤلفه مداری باد تراز بالا (uwnd)، فشار سطح دریا و ایستگاه (p0, p) و دمای هوا (۱۰-۲۰۰cm) (t) را به عنوان مهم ترین ورودی ها برای تفکیک دو کلاس «طوفان با دید ۱۰۰۰-۲۰۰ متر» و «گردوغبار معلق» انتخاب کرد. تحلیل SHAP مدل برتر XGBoost این تصویر را تأیید کرد و نشان داد که مقادیر کم geops و فشار، به همراه بادهای قوی تر در تراز بالا و سطح، به طور نظام مند احتمال کاهش دید را افزایش می دهند؛ الگویی سازگار با نقش ناهای عمیق و واگرایی خروجی جت در تقویت گرادیان فشار و بادهای خیزاننده گردوغبار در خاورمیانه (شائو و دونگ، ۲۰۰۶؛ نوتارو و همکاران، ۲۰۱۳؛ حمیدی و همکاران، ۲۰۱۳؛ کنیپرتز و تاد، ۲۰۱۲). در این شرایط، شاخص های ROC-AUC، F1 و رادارپلات نشان دادند که XGBoost و Random Forest با AUC حدود ۰/۹۳ و تعادل مناسب بین حساسیت و اختصاصیت، بهترین توان جداسازی را داشته و از SVM، RBFNN و وایازش لجستیک پیشی می گیرند.

در رژیم بدون جت، مسئله به چهار کلاس (طوفان ملایم، طوفان شدید، گردوغبار برخاسته با باد و گردوغبار معلق) گسترش یافت. در این حالت، Boruta تندی (ff)، فشار سطح دریا و ایستگاه (P0, P)، ارتفاع ژئوپتانسیل تراز hPa ۲۵۰ (geops) و تا حدی باد تراز بالا (uwnd, ff10) را به عنوان متغیرهای کلیدی معرفی کرد و دما و جهت باد را در مرتبه دوم اهمیت قرار داد؛ تصویری سازگار با طوفان های «غیرجتی» وابسته به گرادیان فشار و بادهای موضعی (کنیپرتز و تاد، ۲۰۱۲). با این حال، نمودار SHAP مدل برتر SVM نشان داد که این مدل در عمل بیشتر بر ترکیب دما (Tmax, t)، فشار (p0, p)، geops و دمای سطح زمین (tsoil) تکیه می کند و نقش باد را در مرزهای تصمیم خود کم رنگ تر می بیند؛ زیرا برای یک مسئله چهار کلاسی و نامتوازن، متغیرهای فشاری-گرمایی پایدارتر بوده و برای ساخت ابرصفحات SVM مناسب ترند (هستی و همکاران، ۲۰۰۹؛ مولنار، ۲۰۲۰). از نظر کارایی نیز RF و XGBoost

با وجود دقت آموزشی بالا، روی داده آزمون دچار کاهش Accuracy و F1 و خطای زیاد در کلاس های رخدادمحور شدند و به سمت برچسب زدن نمونه ها به کلاس غالب (گردوغبار برخاسته با باد) گرایش یافتند؛ در حالی که SVM با کرنل RBF به Accuracy حدود ۰/۸۵، شکاف بسیار اندک آموزش-آزمون (۰/۰۰۶) و چندضلعی متوازن تر در رادارپلات Precision دست یافت؛ رفتاری منطبق با اصل «کمینه سازی زبان ساختاری» و پایداری SVM در برابر نوسان و داده های محدود (واپنیک، ۱۹۹۵؛ بیشاپ، ۲۰۰۶؛ اشتول، ۱۹۸۸).

در جمع بندی، کاربرد هم زمان Boruta و SHAP در کنار شاخص های عملکردی (Accuracy، AUC، F1 و رادارپلات) نشان داد که این ابزارها صرفاً برای کاهش بُعد داده نیستند، بلکه می توانند به عنوان «آشکارساز فیزیکی» سازوکارهای حاکم بر طوفان های گردوغبار عمل کنند. در رژیم جتی، متغیرهای دینامیکی تراز بالا و فشار، ستون فقرات سامانه را شکل می دهند و مدل های درختی تجمیعی بیشترین بهره را از این نظم دینامیکی می برند؛ در رژیم بدون حضور جت، وزن سامانه به سوی متغیرهای ترمودینامیکی و نزدیک به سطح جابه جا می شود و در این فضا، SVM که به این اطلاعات متکی است، از نظر تعمیم پذیری و تفکیک طبقاتی عملکرد برتری نشان می دهد.

۵. نتیجه گیری

نتایج این پژوهش نشان داد که تفکیک همدیدی داده ها به دو رژیم «همراه با جت استریم» و «بدون جت استریم» برای فهم و پیش بینی طوفان های گردوغبار غرب و جنوب غرب ایران بسیار کلیدی است. در رژیم جتی، متغیرهای ارتفاع ژئوپتانسیل تراز ۲۵۰hPa، مؤلفه مداری باد تراز بالا و میدان فشار سطحی، به همراه سرعت بادهای سطحی، مهم ترین اطلاعات را برای تشخیص روزهای طوفان با دید ۱۰۰۰-۲۰۰ متر از شرایط صرفاً گردوغبار معلق فراهم کردند و مدل های درختی تجمیعی، به ویژه XGBoost و Random Forest، با AUC بالا و تعادل مناسب بین حساسیت و اختصاصیت، بهترین عملکرد را داشتند. این وضعیت بازتابی

فیزیکی» نیز عمل کنند و سازوکارهای حاکم بر طوفان‌های گردوغبار را از دل مدل‌های یادگیری ماشین بیرون بکشند. به‌طور خلاصه، در حضور جت‌استریم، تکیه بر شاخص‌های دینامیکی تراز بالا و به‌کارگیری مدل‌های درختی و در غیاب جریان جت‌استریم، تأکید بر متغیرهای ترمودینامیکی و استفاده از SVM، بهترین راهبرد برای پیش‌بینی کاهش دید ناشی از گردوغبار در غرب و جنوب‌غرب ایران به‌نظر می‌رسد و می‌تواند مبنایی برای توسعه سامانه‌های هشدار زودهنگام در این منطقه باشد.

در راستای توسعه پژوهش‌های آینده، پیشنهاد می‌شود اطلاعات زمان وقوع رخدادهای (به‌صورت ماهانه یا فصلی) نیز به‌عنوان یک ویژگی به مجموعه داده‌ها افزوده شود. افزودن این مؤلفه می‌تواند به مدل‌ها در بازنمایی چرخه‌های فصلی گردوغبار، تفاوت‌های دینامیکی بین فصول سرد و گرم و نقش گرمایش سطحی و پایداری لایه مرزی کمک کرده و دقت و پایداری پیش‌بینی‌ها را به‌ویژه در رژیم بدون جت‌استریم افزایش دهد. این رویکرد می‌تواند گامی مؤثر در جهت بهبود سامانه‌های هشدار زودهنگام گردوغبار در غرب و جنوب‌غرب ایران باشد.

مراجع

- Abdi Vishkaee, F., Flamant, C., Cuesta, J., Oolman, L., Flamant, P., & Khaledifard, H. R. (2012). Dust transport over Iraq and northwest Iran associated with winter Shamal: A case study. *Journal of Geophysical Research: Atmospheres*, 117(D3).
- Aghababaeian, H., Ostadtaghizadeh, A., Ardalan, A., Asgary, A., Akbary, M., Yekaninejad, M. S., Sharafkhani, R., & Stephens, C. (2021). Effect of dust storms on non-accidental, cardiovascular, and respiratory mortality: A case of Dezful City in Iran. *Environmental Health Insights*, 15:11786302211060152. doi: HYPERLINK "https://doi.org/10.1177/11786302211060152" 10.1177/11786302211060152
- Alshammari, R. K., Alrwais, O., & Aksoy, M. S. (2024). Machine learning forecast of dust storm frequency in Saudi Arabia using multiple features. *Atmosphere*, 15(5), 520.
- Archer, C. L., & Caldeira, K. (2008). Historical trends in the jet streams. *Geophysical Research Letters*, 35(8), L08803.

از ساختار منظم و نسبتاً سازمان‌یافته جریان در حضور جت است که باعث می‌شود روابط بین شاخص‌های همدیدی و کاهش دید، برای مدل‌های درختی قابل یادگیری و پایدار باشد.

در رژیم بدون حضور جت‌استریم که طبقه‌بندی چهارکلاسی و توزیع نامتوازن داده‌ها مسئله را پیچیده‌تر می‌کند، خروجی Boruta و تحلیل SHAP نشان داد که نقش بادهای سطحی و تراز بالا نسبت به رژیم جتی کم‌رنگ‌تر شده و وزن اصلی به سمت متغیرهای فشاری و دمایی-از جمله دمای هوا (۲۰۰-۱۰ cm)، دمای بیشینه و دمای سطح زمین-جابه‌جا می‌شود. در چنین شرایطی، مدل‌های درختی دچار بیش‌برازش شده و بخش بزرگی از رخدادهای کم‌فراوانی را در کلاس غالب ادغام می‌کنند، در حالی که SVM با کرنل RBF به دلیل تکیه بر ساختار ترمودینامیکی پایدارتر و بهره‌گیری از اصل کمینه‌سازی زیان ساختاری، دقت و تعادل بهتری در تشخیص هر چهار کلاس گردوغبار نشان می‌دهد.

ترکیب انتخاب ویژگی Boruta، تحلیل SHAP و شاخص‌های کارایی (Accuracy، AUC، F1 و رادارپلات) نشان داد که این ابزارها، علاوه بر نقش کاهش ابعاد و ارزیابی آماری، می‌توانند به‌عنوان «آشکارساز

- Beyranvand, A., Azizi, G., Alizadeh, O., & Darvishi Boloorani, A. (2023). Dust in Western Iran: The emergence of new sources in response to shrinking water bodies. *Scientific Reports*, 13(1), 16158.
- Boloorani, A. D., Nabavi, S. O., Bahrami, H. A., Mirzapour, F., Kavosi, M., Abasi, E., & Azizi, R. (2014). Investigation of dust storms entering Western. *Journal of Environmental Health Science & Engineering*, 12, 124.
- Bommert, A., Sun, X., Bischl, B., Rahnenführer, J., & Lang, M. (2020). Benchmark for filter methods for feature selection in high-dimensional classification data. *Computational Statistics & Data Analysis*, 143, 106839.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Broomandi, P., Dabir, B., Bonakdarpour, B., & Rashidi, Y. (2017). Identification of dust storm origin in South-West of Iran. *Journal of Environmental Health Science & Engineering*, 15(1), 16.
- Broomandi, P., Mohammadpour, K., Kaskaoutis,

- D.G., Fathian, A., Abdullaev, S.F., Maslov, V.A., Nikfal, A., Jahanbakhshi, A., Aubakirova, B., Kim, J.R., Satyanaga, A., Rashki, A., & Middleton, N. (2023). A Synoptic- and Remote Sensing-based Analysis of a Severe Dust Storm Event over Central Asia. *Aerosol Air Qual. Res.* 23 (2), 220309, <https://doi.org/10.4209/aaqr.220309>
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Association for Computing Machinery, San Francisco, 13-17 August 2016, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Feng, X., Li, Q., Zhu, Y., Hou, J., Jin, L., & Wang, J. (2015). Artificial neural networks forecasting of PM2.5 pollution using air mass trajectory based geographic model and wavelet transformation. *Atmospheric Environment*, 107, 118-128.
- Francis, D., Fonseca, R., Nelli, N., Bozkurt, D., Picard, G., & Guan, B. (2022). Atmospheric rivers drive exceptional Saharan dust transport towards Europe. *Atmospheric Research*, 266, 105959. <https://doi.org/10.1016/j.atmosres.2021.105959>
- Hamidi, M., Kavianpour, M. R., & Shao, Y. (2013). Synoptic analysis of dust storms in the Middle East. *Asia-Pacific Journal of Atmospheric Sciences*, 49(3), 279-286.
- He, Q., & Huang, B. (2018). Satellite-based mapping of daily high-resolution ground PM2.5 in China via space-time regression modeling. *Remote Sensing of Environment*, 206, 72-83.
- Jalali, A., & Goudarzi, G. (2024). A review of introduction to Khuzestan dust storm: Immunotoxicity and its effects on human health. *Journal of Advanced Immunopharmacology*, 4(4).
- Kanamitsu, M., Ebisuzaki, W., Woollen, J., Yang, S. K., Hnilo, J. J., Fiorino, M., & Potter, G. L. (2002). NCEP-DOE AMIP-II reanalysis (R-2). *Bulletin of the American Meteorological Society*, 83(11), 1631-1644.
- Knippertz, P., & Todd, M. C. (2012). Mineral dust aerosols over the Sahara: Meteorological controls on emission and transport and implications for modeling. *Reviews of Geophysics*, 50(1).
- Koch, P., Wernli, H., & Davies, H. C. (2006). An event-based jet-stream climatology and typology. *International Journal of Climatology*, 26(3), 283-301.
- Kursa, M. B., & Rudnicki, W. R. (2010). Feature selection with the Boruta package. *Journal of Statistical Software*, 36, 1-13.
- Li, T., Shen, H., Yuan, Q., Zhang, X., & Zhang, L. (2017). Estimating ground-level PM2.5 by fusing satellite and station observations: A geo-intelligent deep learning approach. *Geophysical Research Letters*, 44(23), 11985-11993.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 12 (2). <https://doi.org/10.48550/arXiv.1705.07874>.
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., & Lee, S. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2(1), 56-67. <https://doi.org/10.1038/s42256-019-0138-9>
- Mahmoudi, L., & Ikegaya, N. (2023). Identifying the distribution and frequency of dust storms in Iran based on long-term observations from over 400 weather stations. *Sustainability*, 15(16), 12294.
- McGovern, A., Lagerquist, R., Gagne, D. J., Jergensen, G. E., Elmore, K. L., Homeyer, C. R., & Smith, T. (2019). Making the black box more transparent: Understanding the physical implications of machine learning. *Bulletin of the American Meteorological Society*, 100(11), 2175-2199.
- Mobarak Hassan, E., Fatahi, E., Karim Khan, M., & Noori, F. (2019). The effect of wind direction on dust transfer toward the Persian Gulf. *Journal of Air Pollution and Health*, 4(1), 33-52. [HYPERLINK "https://doi.org/10.18502/japh.v4i1.602"](https://doi.org/10.18502/japh.v4i1.602)
- Notaro, M., Alkolibi, F., Fadda, E., & Bakhrijy, F. (2013). Trajectory analysis of Saudi Arabian dust storms. *Journal of Geophysical Research: Atmospheres*, 118(12), 6028-6043.
- Park, J., & Sandberg, I. W. (1991). Universal approximation using radial-basis-function networks. *Neural Computation*, 3(2), 246-257.
- Parno, R., Meshkatee, A.-H., Mobarak Hassan, E., Hamzeh, N. H., Ooi, M. C., & Habibi, M. (2024). Investigating the role of the low-level jet in two winters' severe dust rising in southwest Iran. *Atmosphere*, 15(4), 400.
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Ranjbar Saadat Abadi, A., Hamzeh, N. H., Kaskaoutis, D. G., Opp, C., & Fazl Kazemi, A. (2025). Long term spatio temporal analysis, distribution, and trends of dust events over Iran. *Atmosphere*, 16(3), 334.

- 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.
- Schultz, M. G., Betancourt, C., Gong, B., Kleinert, F., Langguth, M., Leufen, L. H., Mozaffari, A., & Stadler, S. (2021). Can deep learning beat numerical weather prediction? Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 379(2194), 20200097.
- Shao, Y., & Dong, C. H. (2006). A review on East Asian dust storm climate, modelling and monitoring. *Global and Planetary Change*, 52(1–4), 1–22.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222.
- Talaie, A., Kamyab, H., Chelliapan, S., & Khalili, E. (2024). Sources and impacts of dust pollution in Iran: A comprehensive overview. *Journal of Environmental Treatment Techniques*, 12(2), 1–15.
- Uccellini, L. W., & Johnson, D. R. (1979). The coupling of upper and lower tropospheric jet streaks and implications for the development of severe convective storms. *Monthly Weather Review*, 107(6), 682–703.
- Woollings, T., Hannachi, A., Hoskins, B., & Turner, A. (2010). A regime view of the North Atlantic Oscillation and its response to anthropogenic forcing. *Journal of Climate*, 23(6), 1291–1307.
- Zaghir, A. I., Kamran, K. V., & Karimzadeh, S. (2025). Evaluation of the origin and synoptic analysis of dust storm phenomena using satellite image processing in Western Iran. *International Journal of Engineering and Geosciences*, 10(3), 419–427.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. New York: Springer.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). New York: Springer.
- Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). India: Pearson Education.
- Holton, J. R., & Hakim, G. J. (2013). *An Introduction to Dynamic Meteorology* (5th ed.). Academic Press.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression* (3rd ed.). John Wiley & Sons.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning: With Applications in R*. New York: Springer.
- Jolliffe, I. T., & Stephenson, D. B. (Eds.). (2012). *Forecast Verification: A Practitioner's Guide in Atmospheric Science* (2nd ed.). Wiley-Blackwell.
- Molnar, C. (2020). *Interpretable Machine Learning*. Lulu.com.
- Stull, R. B. (1988). *An Introduction to Boundary Layer Meteorology*. Dordrecht: Kluwer Academic Publishers.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer.
- Wilks, D. S. (2011). *Statistical Methods in the Atmospheric Sciences* (Vol. 100). Academic Press.
- Shaw, R., Luo, Y., Cheong, T.S., Abdul Halim, S., Chaturvedi, S., Hashizume, M., Insarov, G.E., Ishikawa, Y., Jafari, M., Kitoh, A., Pulhin, J., Singh, C., Vasant, K., & Zhang, Z. (2022). Asia Supplementary Material. In: *Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegria, M. Craig, S. Langsdorf, S. Löschke, V. Möller, A. Okem, B. Rama (eds.)]. Available from <https://www.ipcc.ch/report/ar6/wg2/>
- Broomhead, D. S., & Lowe, D. (1988). Radial basis functions, multi-variable functional interpolation and adaptive networks (RSRE Memo 4148).