



Scientific Journal of

Sustainable Development of Geographical Environment



Vol. 8, No. 17, Summer 2026

Prioritizing Human-Demographic and Environmental Factors in Modeling the Increasing Trend of PM_{2.5} using Machine Learning Models (Case Study: Isfahan)

Ali Bagheri¹, Ali Shamsoddini^{2*}, Ali Sistanipour¹

1. Department of Geography, YI. C., Islamic Azad University, Tehran, Iran

2. Department of Geography, Shi.C., Islamic Azad University, Shiraz, Iran

Abstract

Introduction: Suspended particles with a diameter of less than 2.5 microns have a remarkable contribution to air pollution and human health. These particulate matter types are among the most critical air pollutants, with severe impacts on human health. Given the importance of these particles, this study aimed to model the increasing trend in PM_{2.5} concentrations in Isfahan, one of Iran's metropolises, using machine learning models, and to determine the contributions of environmental and human-demographic factors influencing it over 24 years (2001-2024).

Materials and Methods: Initially, using ground-based PM_{2.5} data from 12 air pollution monitoring stations and satellite-derived Aerosol Optical Depth (AOD) images (MCD19A2 product from MODIS), monthly PM_{2.5} images were estimated for the entire city of Isfahan via linear regression. The Mann-Kendall trend test was then applied in TerrSet software to determine the monthly trend of PM_{2.5} changes over the 24 years. Based on the results, six months, including April, May, June, August, October, and March, which showed the highest percentage of area with an increasing trend, were selected as the study months. For modeling the increasing trend in PM_{2.5} using machine learning models, including Random Forest (RF), Support Vector Machine (SVM), and Boosted Regression Trees (BRT), in RStudio. Validation was performed using the Receiver Operating Characteristic (ROC) curve and Area Under the Curve (AUC), while factor prioritization was conducted using Jackknife sensitivity analysis.

Results and Discussion: Trend analysis revealed that June (81.16% of the area), April (78.07%), August (71.41%), May (52.91%), October (45.72%), and March (40.68%) exhibited the largest spatial extent of increasing PM_{2.5} trends, respectively. This indicates that while air pollution has increased across all seasons, the intensity is more pronounced during the warm months and early spring, potentially due to higher temperatures, intensified photochemical reactions, and dust phenomena. The highest modeling accuracy, with an AUC of 0.9, was achieved by the SVM model in August, indicating its strong ability to identify complex, nonlinear patterns governing air pollution that month. Also, according to the Jackknife sensitivity analysis, temperature emerged as the most dominant variable in five out of six months (except October). This confirms temperature's critical role in shaping air pollution through its influence on atmospheric stability, photochemical reactions, and secondary particle formation.

Conclusion: This study, integrating ground-based PM_{2.5} data with satellite AOD imagery and employing machine learning models coupled with Jackknife sensitivity analysis, successfully identified spatial-temporal pollution patterns and their driving factors in Isfahan. The results demonstrate that while environmental variables, particularly temperature, are fundamental in driving the PM_{2.5} trend, human demographic factors such as industry, traffic, agriculture, and population concentration constitute the primary source of emissions and play a decisive, sometimes dominant, role in increasing PM_{2.5} concentrations. Based on these findings, it is recommended that new industries be established with appropriate buffer zones, preferably downwind of the prevailing wind. Strict monitoring of existing industrial stacks and the mandatory adoption of emission-reduction technologies are essential. Given the significant role of roads, especially in June and October, developing clean public transportation, expanding low-traffic zones, and enforcing stringent vehicle emission inspections should be prioritized. Prohibiting agricultural residue burning and promoting conservation agriculture are crucial measures. Increasing green spaces with native, drought-resistant species in high-population-density areas and near industrial zones is suggested as a strategy for particulate matter absorption. Finally, any urban development policies must incorporate environmental considerations to reduce population concentration in critical, high-pollution areas.

Keywords: Air Pollution, Isfahan, Machine Learning, Support Vector Machine.

Citation : Bagheri, A., Shamsoddini, A., & Sistanipour, A. (2026). Prioritizing Human-Demographic and Environmental Factors in Modeling the Increasing Trend of PM_{2.5} using Machine Learning Models (Case Study: Isfahan). *Sustainable Development of Geographical Environment*, Vol. 8, No. 17, (90-109). <https://doi.org/10.48308/sdge.2026.243936.1306>

Received: 14/04/2026

Revised: 21/05/2026

Accepted: 21/05/2026

* Corresponding Author's Email: Ali_shamsoddini@iau.ac.ir



Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

اهمیت عوامل انسانی-جمعیتی و محیطی مؤثر در مدل‌سازی روند افزایشی PM_{2.5} با استفاده

از مدل‌های یادگیری ماشین (مطالعه موردی: اصفهان)

علی باقری^۱، علی شمس‌الدینی^{۲*}، علی سیستانی‌پور^۱

۱. گروه جغرافیا، واحد یادگار امام خمینی (ره) شهری، دانشگاه آزاد اسلامی، تهران، ایران

۲. گروه جغرافیا، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

چکیده

مقدمه: ذرات معلق با قطری کمتر از ۲/۵ میکرون سهم قابل توجهی در آلودگی هوا و سلامت انسان دارند. این ذرات معلق از مهم‌ترین آلاینده‌های هوا با پیامدهای شدید برای سلامت انسان به شمار می‌روند. با توجه به اهمیت این ذرات، این مطالعه با هدف مدل‌سازی روند افزایشی غلظت PM_{2.5} در شهر اصفهان، به عنوان یکی از کلان‌شهرهای ایران، با استفاده از مدل‌های یادگیری ماشین و تعیین سهم عوامل محیطی و انسانی - جمعیتی مؤثر بر آن در بازه زمانی ۲۴ ساله (۲۰۰۱ تا ۲۰۲۴) انجام شد.

مواد و روش‌ها: در ابتدا، با استفاده از داده‌های زمینی PM_{2.5} از ۱۲ ایستگاه پایش آلودگی هوا و تصاویر عمق نوری آئروسول (AOD) استخراج‌شده از ماهواره (محصول MCD19A2 از MODIS)، تصاویر ماهانه PM_{2.5} برای کل شهر اصفهان از طریق مدل‌سازی رگرسیون خطی برآورد شد. سپس آزمون روند من-کندال در نرم‌افزار TerrSet برای تعیین روند ماهانه تغییرات PM_{2.5} طی ۲۴ سال به کار گرفته شد. بر اساس نتایج، شش ماه شامل آوریل، مه، ژوئن، اوت، اکتبر و مارس که بیشترین درصد مساحت با روند افزایشی را نشان دادند، به عنوان ماه‌های مطالعه انتخاب شدند. برای مدل‌سازی روند افزایشی PM_{2.5} از مدل‌های یادگیری ماشین شامل جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و درختان رگرسیون تقویت‌شده (BRT) در نرم‌افزار RStudio استفاده شد. اعتبارسنجی با استفاده از منحنی مشخصه عملکرد گیرنده (ROC) و مساحت زیر منحنی (AUC) انجام گرفت، در حالی که اولویت‌بندی عوامل با استفاده از تحلیل حساسیت Jackknife صورت پذیرفت.

نتایج و بحث: تحلیل روند نشان داد که به ترتیب ماه‌های ژوئن (۸۱/۱۶٪ از مساحت)، آوریل (۷۸/۰۷٪)، اوت (۷۱/۴۱٪)، مه (۵۲/۹۱٪)، اکتبر (۴۵/۷۲٪) و مارس (۴۰/۶۸٪) بیشترین گستره مکانی روند افزایشی PM_{2.5} را نشان داده‌اند. این موضوع بیانگر آن است که اگرچه آلودگی هوا در تمام فصول افزایش یافته است، شدت آن در ماه‌های گرم و اوایل بهار بیشتر است که احتمالاً به دلیل دماهای بالاتر، تشدید واکنش‌های فتوشیمیایی و پدیده‌های گردوغبار است. بیشترین دقت مدل‌سازی با مقدار AUC برابر با ۰/۹ مربوط به مدل SVM در ماه اوت بود که نشان‌دهنده توانایی بالای این مدل در شناسایی الگوهای پیچیده و غیرخطی حاکم بر آلودگی هوا در این ماه است. همچنین بر اساس تحلیل حساسیت Jackknife دما به عنوان غالب‌ترین متغیر در پنج ماه از شش ماه (به جز اکتبر) شناخته شد. این امر نقش حیاتی دما را در شکل‌گیری آلودگی هوا از طریق تأثیر آن بر پایداری جو، واکنش‌های فتوشیمیایی و تشکیل ذرات ثانویه تأیید می‌کند.

نتیجه‌گیری: این مطالعه با تلفیق داده‌های زمینی PM_{2.5} با تصاویر ماهواره‌ای AOD و به‌کارگیری مدل‌های یادگیری ماشین همراه با تحلیل حساسیت Jackknife، الگوهای زمانی - مکانی آلودگی و عوامل محرک آن‌ها را در شهر اصفهان با موفقیت شناسایی کرد. نتایج نشان می‌دهد که اگرچه متغیرهای محیطی، به‌ویژه دما، نقش بنیادی در افزایش روند PM_{2.5} دارند، اما عوامل انسانی - جمعیتی مانند صنعت، ترافیک، کشاورزی و تمرکز جمعیت به عنوان منابع اصلی انتشار عمل کرده و نقشی تعیین‌کننده و گاهی غالب در افزایش غلظت PM_{2.5} ایفا می‌کنند. بر اساس این یافته‌ها، توصیه می‌شود استقرار صنایع جدید با رعایت حریم مناسب و در اولویت پایین‌دست جریان باد غالب انجام شود. همچنین نظارت بر خروجی دودکش‌های صنایع موجود و الزام به استفاده از فناوری‌های کاهش آلاینده‌ها به صورت الزامی صورت گیرد. با عنایت به نقش تراکم و فاصله از جاده‌ها به‌ویژه در ماه‌های خرداد و مهر، توسعه حمل‌ونقل عمومی پاک، گسترش مناطق کم‌ترافیک و تشدید معاینه فنی خودروها باید در اولویت قرار گیرد. با توجه به اهمیت فاصله از اراضی کشاورزی، ممنوعیت سوزاندن بقایای گیاهی و ترویج کشاورزی حفاظتی می‌تواند مؤثر باشد. همچنین افزایش فضای سبز با گونه‌های بومی و مقاوم به خشکی در نواحی با تراکم جمعیت بالا و نزدیک به مراکز صنعتی، به عنوان راهکاری برای جذب ذرات معلق پیشنهاد می‌شود. در نهایت، با توجه به نقش تراکم جمعیت، هرگونه سیاست‌گذاری در زمینه توسعه شهری باید با ملاحظات زیست‌محیطی و با هدف کاهش تمرکز جمعیت در مناطق بحرانی همراه باشد.

واژه‌های کلیدی: آلودگی هوا، اصفهان، یادگیری ماشین، ماشین بردار پشتیبان

استناد: باقری، ع.، شمس‌الدینی، ع. و سیستانی‌پور، ع. (۱۴۰۵). اولویت‌بندی عوامل انسانی-جمعیتی-شناختی و محیطی در مدل‌سازی روند افزایشی PM_{2.5} با استفاده از مدل‌های یادگیری ماشین (مطالعه موردی: اصفهان). توسعه پایدار محیط جغرافیایی، دوره ۸، شماره ۱۷، تابستان ۱۴۰۵، (۹۰-۱۰۹).

<https://doi.org/10.48308/sdge.2026.243936.1306>

پذیرش: ۱۴۰۵/۰۲/۳۱

بازنگری: ۱۴۰۵/۰۲/۳۱

دریافت: ۱۴۰۵/۰۱/۲۵

* رایانامه نویسنده مسئول: Ali_shamsoddini@iau.ac.ir

مقدمه

آلودگی هوا که به عنوان تغییر ترکیب طبیعی جو توسط هر عامل شیمیایی، فیزیکی یا بیولوژیکی در محیط داخلی یا خارجی تعریف می شود (Fatima et al., 2023)، به عنوان یکی از چالش های جدی جهانی در عصر حاضر شناخته شده است (sha et al. 2025). در مجموع ۹۲ درصد از جمعیت آسیا و اقیانوسیه، یا حدود ۴ میلیارد نفر، در معرض سطوحی از آلودگی هوا هستند که برای سلامتی خطرناک است (Iram et al. 2025). در سال های اخیر آلودگی هوای کلان شهرها به ویژه در کشورهای در حال توسعه به عنوان مهم ترین نگرانی زیست محیطی مطرح بوده است (Falahati et al., 2013). آلودگی هوا علاوه بر اینکه خطر قابل توجهی برای سلامتی دارد، بر رشد اقتصادی، محیط زیست، سلامت انسان و تولید محصولات کشاورزی نیز تأثیر می گذارد. مضرترین آلاینده های هوا ذرات معلق ریز ($PM_{2.5}$) هستند که در واقع ذرات با قطر کمتر از 2.5 میکرون می باشند. این ذرات به دلیل نفوذ به دستگاه تنفسی انسان، نشر آلودگی^۲ و تأثیر در تغییرات آب و هوای جهانی اهمیت زیادی دارند (Nisi et al., 2021) و از فاکتورهای مهم آلودگی هوا در مناطق شهری محسوب می شوند (Davtalab et al., 2023). عموماً منابعی مانند خودروهای دیزلی، نیروگاه های زغال سنگی، گردوغبار، فعالیت های ساختمانی و راه سازی و غیره غلظت بالایی از ذرات $PM_{2.5}$ را منتشر می کنند. این ذرات، به عنوان ماده ای مضر شناخته می شوند که پتانسیل افزایش میزان ابتلا به سرطان و مرگ و میر انسان ها را دارند (Liu et al., 2019; Tiwary and Williams., 2019). مطابق با بررسی های انجام شده، سهم عمده ذرات معلق ریز مربوط به فعالیت های انسانی از جمله احتراق ناقص در وسایل نقلیه موتوری، فعالیت های صنعتی و استفاده از سوخت های فسیلی است


(Oroji, 2025). علاوه بر آن، شرایط خاص اقلیمی کشور ایران به ویژه در استان های مرکزی با اقلیم خشک و نیمه خشک و وقوع طوفان هایی با منشأ محلی یا منطقه ای منجر به افزایش غلظت ذرات معلق در جو می گردد (Heger & Sarraf, 2018). شهر اصفهان به دلیل رشد جمعیت، توسعه شهری، روند صنعتی شدن، خشکسالی و وقوع طوفان های گردوغبار با چالش جدی آلودگی هوا مواجه است. انتشار ذرات معلق ناشی از فعالیت های انسانی و پدیده های اقلیمی منجر به افزایش غلظت آلاینده ها در سطح شهر می شود و به طور مستقیم بر سلامت انسان، کیفیت زندگی انسان و سلامت سایر زیست مندان اثر می گذارد. بنابراین مطالعات جامعی جهت تعیین روند تغییرات آلودگی هوا، مناطق مستعد آلودگی، بررسی تغییرات آلودگی در طول سال و شناخت عوامل مؤثر در افزایش آلودگی به منظور مقابله با این پدیده لازم و ضروری است. مدل سازی که معمولاً به صورت روابط ریاضی و یا مفهومی بیان می شود، یکی از ابزارهای مناسب جهت تصمیم گیری و پیش بینی پدیده های مختلف و شناخت عوامل مؤثر بر آن ها به شمار می رود (Darvand et al., 2021). یادگیری ماشین^۱ که به مفهوم برنامه نویسی برای بهینه سازی یک عملکرد با استفاده از داده ها و تجربیات گذشته می باشد، یک ابزار مدل سازی است که می تواند برای پیش بینی و یا به منظور استخراج دانش از داده ها استفاده شود.

مطالعات متعددی در سراسر جهان به بررسی آلودگی هوا و تعیین مناطق حساس به این پدیده با استفاده از مدل های یادگیری ماشین صورت گرفته است. در پژوهشی که با استفاده از مدل های آماری و مدل های یادگیری ماشین به پیش بینی غلظت $PM_{2.5}$ با استفاده از آلاینده های هوا و پارامترهای هواشناسی به عنوان متغیرهای پیش بینی کننده در هند پرداخته شد، مدل XGboost در بین مدل های مورد استفاده بهترین کارایی را جهت پیش بینی غلظت $PM_{2.5}$ داشت (Mondal et al., 2024). همچنین در مطالعه ای با استفاده از چهار مدل یادگیری ماشین، غلظت $PM_{2.5}$ پژوهشگران پیش بینی کردند و بیان داشتند که مدل های یادگیری ماشین در پیش بینی غلظت این پارامتر عملکرد بسیار خوبی داشتند (Makhdoumi et al., 2025). با توجه به اهمیت موضوع آلودگی هوا در شهر اصفهان، در پژوهش حاضر با در نظر گرفتن مدل های مختلف یادگیری ماشین به مدل سازی روند افزایشی $PM_{2.5}$ در این شهر پرداخته شد تا ضمن تعیین مناطق مستعد آلودگی هوا، اهمیت عوامل انسانی و محیطی مؤثر در آن نیز تعیین گردد.

مواد و روش‌ها

محدوده مورد مطالعه

شهر اصفهان در موقعیت جغرافیایی $32^{\circ}38'41''$ عرض شمالی و $51^{\circ}40'33''$ طول شرقی واقع شده است. ارتفاع متوسط شهر اصفهان حدود ۱۵۷۰ متر از سطح دریا است و پس از تهران و مشهد، سومین شهر پرجمعیت ایران است. شهر اصفهان که بر روی بستر رودخانه زاینده‌رود شکل گرفته و توسعه یافته است، به دلیل موقعیت جغرافیایی خود، دارای اقلیم خشک و نیمه‌خشک است. به دلیل وجود نواحی صنعتی زیاد در نزدیکی شهر اصفهان، تراکم جمعیت، خودروها و وقوع ریزگردها، این شهر با مسئله آلودگی هوا مواجه می‌باشد. درواقع شهر اصفهان به‌عنوان یکی از شهرهای بزرگ و صنعتی ایران به دلیل موقعیت جغرافیایی، افزایش جمعیت و توسعه صنایع، با افزایش روزافزون آلاینده‌های هوا مواجه است. موقعیت جغرافیایی شهر اصفهان در کشور و استان اصفهان در شکل (۱) ارائه شده است.



شکل ۱. موقعیت جغرافیایی شهر اصفهان

روش پژوهش

به‌منظور مدل‌سازی روند تغییرات افزایشی PM_{2.5} در شهر اصفهان و تعیین اهمیت عوامل انسانی-جمعیتی و عوامل محیطی مؤثر در آن، ابتدا به تعیین روند تغییرات PM_{2.5} به صورت ماهانه، طی سال‌های ۲۰۰۱ تا ۲۰۲۴ پرداخته شد. سپس با استفاده از مدل‌های یادگیری ماشین، مدل‌سازی روند تغییرات افزایشی PM_{2.5} در ماه‌هایی که بیشترین روند افزایشی را داشتند، صورت گرفت. در نهایت اولویت عوامل اثرگذار در افزایش PM_{2.5} اعم از عوامل انسانی-جمعیتی و عوامل محیطی با استفاده از آنالیز حساسیت جک‌نایف تعیین شد. مراحل انجام پژوهش به تفکیک در ادامه شرح داده شده است. جدول (۱) به صورت خلاصه داده‌های مورد استفاده در پژوهش را نشان می‌دهد.

جدول ۱. خلاصه داده‌های مورد استفاده در پژوهش

داده	منبع	قدرت تفکیک مکانی	قدرت تفکیک زمانی
PM _{2.5}	ایستگاه‌های سنجش زمینی (شهرداری اصفهان)	-	یک ساعته
AOD	سنجنده مودیس	یک کیلومتر	یک روزه
دما و بارش	سازمان هواشناسی	-	سه ساعته
EVI	ماهواره Landsat	۳۰ متر	۱۶ روزه
تراکم جمعیت	شهرداری اصفهان	Resample شده بر اساس تصاویر Landsat	-
اراضی صنعتی	شهرداری اصفهان	Resample شده بر اساس تصاویر Landsat	-
اراضی زراعی	نقشه پایه سازمان جنگل‌ها و مراتع ایران	Resample شده بر اساس تصاویر Landsat	-
جاده (تراکم و فاصله)	Open Street Map (OSM)	Resample شده بر اساس تصاویر Landsat	-
تراکم آبادی	OSM	Resample شده بر اساس تصاویر Landsat	-

ارزیابی روند تغییرات آلودگی هوا در شهر اصفهان

به منظور ارزیابی روند تغییرات آلودگی هوا در شهر اصفهان از مقادیر PM_{2.5} ایستگاه‌های زمینی سنجش آلودگی هوا و تصاویر ماهواره‌ای مربوط به شاخص AOD استفاده شد. در مرحله اول، داده‌های زمینی PM_{2.5} حاصل از ۱۲ ایستگاه سنجش آلودگی هوا، با در نظر گرفتن فاصله حداقل ۱/۵ کیلومتری از هم، که شامل ایستگاه‌های ۲۵ آبان، انقلاب، پارک زمزم، پروین، دانشگاه صنعتی اصفهان، رهنان، زینبیه، سپاهان شهر، فیض، کردآباد، میرزا طاهر و ولدان می‌باشد، جمع‌آوری شد. سپس مقادیر میانگین ماهانه PM_{2.5} برای ایستگاه‌های مورد نظر محاسبه گردید.

در مرحله بعد، داده‌های میانگین ماهانه AOD با طول موج سبز (۵۵۰ نانومتر) محصول MCD19A2 سنجنده مودیس با قدرت تفکیک مکانی یک کیلومتر و تفکیک زمانی یک روزه، از سامانه گوگل ارث انجین دانلود شد. با مدل‌سازی رابطه بین مقادیر میانگین ماهانه PM_{2.5} و مقادیر میانگین ماهانه AOD با استفاده از آنالیز رگرسیون خطی، تصاویر PM_{2.5} به صورت ماهانه برای ۲۴ سال (۲۰۰۱-۲۰۲۴) برآورد شد.

در نهایت به منظور ارزیابی روند تغییرات PM_{2.5} در شهر اصفهان، پس از برآورد تصاویر میانگین ماهانه PM_{2.5} طی سال‌های ۲۰۰۱ تا ۲۰۲۴، از آزمون روند من‌کندال در مدل‌سازی روند زمین (ETM) نرم‌افزار TerrSet استفاده شد. آزمون روند من‌کندال که ابتدا توسط من (۱۹۴۵) ارائه و سپس توسط کندال (۱۹۷۰) تکامل یافت، بر اساس معادلات زیر محاسبه می‌شود.

$$S = \sum_{i=2}^n \sum_{j=1}^{i-1} (\text{sign}(x_i - x_j)) \quad \text{رابطه (۱)}$$

که در آن مقادیر x_i و x_j داده‌های متوالی است، n طول سری زمانی است و تابع علامت نیز به ترتیب زیر قابل محاسبه است.

$$\text{sign}(x_i - x_j) = \begin{cases} +1 & \text{اگر } (x_i - x_j) > 0 \\ 0 & \text{اگر } (x_i - x_j) = 0 \\ -1 & \text{اگر } (x_i - x_j) < 0 \end{cases} \quad \text{رابطه (۲)}$$

میانگین $E(S)$ و واریانس $\text{Var}(S)$ پارامتر S به ترتیب زیر به دست می آید.


$$E(S) = 0 \quad \text{رابطه (۳)}$$

$$\text{VAR}(S) = \frac{1}{18} \left[n(n-1)(2\alpha + 5) - \sum_{p=1}^q tp(tp-1)(2\alpha + 5) \right] \quad \text{رابطه (۴)}$$

که tp تعداد دنباله ها برای p امین مقدار و p تعداد مقادیر دنباله ها است. جزء دوم در فرمول فوق یک تعدیل برای دنباله یا داده های حساس است. پارامتر استاندارد شده آزمون ZM از رابطه زیر به دست می آید.

$$Z_M = \begin{cases} \frac{S-1}{\sqrt{\text{VAR}(S)}} & \text{اگر } S > 0 \\ 0 & \text{اگر } S = 0 \\ \frac{S+1}{\sqrt{\text{VAR}(S)}} & \text{اگر } S < 0 \end{cases} \quad \text{رابطه (۵)}$$

مقدار مثبت ZM روند افزایشی و مقدار منفی ZM روند کاهشی سری زمانی را نشان می دهد. آستانه سطح معنی داری پنج درصد معادل $|ZM| > 1.9$ می باشد و اگر ZM بیشتر از این آستانه ها باشد، فرض صفر رد شده و سری زمانی پارامتر مورد مطالعه دارای روند معنی دار و در غیر این صورت فاقد روند، برآورد می شود (Zhou et al, 2018). آزمون من-کنندال می تواند برای جواب دادن به این سؤال که آیا مقادیر مرکزی یا میانه یک سری زمانی به مرور تغییر می کنند یا نه، استفاده شود. موقعیت جغرافیایی ایستگاه های سنجش آلودگی هوا در شهر اصفهان در شکل (۲) ارائه شده است.



شکل ۲. موقعیت جغرافیایی ایستگاه‌های سنجش آلودگی

مدل‌سازی روند افزایشی $PM_{2.5}$ در شهر اصفهان

جهت مدل‌سازی روند افزایشی $PM_{2.5}$ در شهر اصفهان، از نتایج ارزیابی روند تغییرات $PM_{2.5}$ استفاده شد. بدین منظور شش ماه از سال که بیشترین روند افزایشی مقادیر $PM_{2.5}$ را در طول ۲۴ سال مطالعاتی دارا بودند، مدنظر قرار گرفتند و مدل‌سازی روند افزایشی $PM_{2.5}$ برای ماه‌های منتخب مطابق با مراحل زیر صورت گرفت.

تعیین نقاط وقوع و عدم وقوع روند افزایشی $PM_{2.5}$: گام نخست در مدل‌سازی روند افزایشی $PM_{2.5}$ در شهر اصفهان؛ تعیین نقاط وقوع (نقاط یک) و نقاط عدم وقوع (نقاط صفر) بود. بدین منظور بر اساس نتایج ارزیابی روند تغییرات $PM_{2.5}$ در طول ۲۴ سال مطالعاتی، مناطقی از شهر که دارای روند افزایشی $PM_{2.5}$ بودند به عنوان مناطق وقوع افزایش آلودگی در نظر گرفته شدند و نواحی با روند کاهشی یا بدون روند به عنوان مناطق عدم وقوع افزایش آلودگی هوا، مدنظر قرار گرفتند. سپس نقاط وقوع و عدم وقوع در هر یک از مناطق، به صورت کاملاً تصادفی با استفاده از نرم‌افزار ArcGIS تعیین شد. در ادامه مجموعه نقاط به صورت تصادفی به دودسته گروه آموزشی یا واسنجی جهت آموزش به مدل و نیز گروه اعتبارسنجی جهت تعیین دقت و کارایی مدل، تقسیم گردید. مجموعه داده‌های آموزشی شامل ۷۰٪ نقاط و مجموعه داده‌های اعتبارسنجی شامل ۳۰٪ نقاط بود.

تعیین عوامل اثرگذار در افزایش $PM_{2.5}$ (متغیرهای پیش‌بینی کننده): با بررسی مطالعات پیشین و قابلیت دسترسی به آمار، عوامل مؤثر در افزایش $PM_{2.5}$ ، انتخاب و داده‌های مربوط به هر یک تهیه شد. متغیرهای مورد استفاده در این مرحله شامل متغیرهای محیطی از جمله دما، بارش، پوشش گیاهی (EVI) و متغیرهای انسانی-جمعیتی شامل فاصله از جاده، تراکم جاده، فاصله از اراضی کشاورزی، فاصله از مراکز صنعتی، تراکم جمعیت و تراکم آبادی می‌باشد. مقادیر میانگین ۳۰ ساله دما و بارش با استفاده از داده‌های سازمان هواشناسی ایران محاسبه شد. شاخص میانگین پوشش گیاهی به

صورت ماهانه با استفاده از تصاویر ماهواره‌ای Landsat تهیه شد. داده‌های مربوط به تراکم جمعیت و فاصله از اراضی صنعتی از شهرداری اصفهان دریافت شد. جهت تعیین اراضی زراعی و فاصله از آن، از نقشه پایه سازمان جنگل‌ها و مراتع ایران استفاده شد. همچنین به منظور تهیه نقشه سایر عوامل شامل تراکم جاده، فاصله از جاده و تراکم آبادی، فایل‌های Open Street Map مورد استفاده قرار گرفت. در نهایت نقشه‌های مربوط به عوامل اثرگذار بر PM_{2.5}، در نرم‌افزار ArcGIS با پیسکل‌سایزهای یکسان به منظور مدل‌سازی تهیه شد.

تعیین همبستگی عوامل پیش‌بینی کننده: همبستگی زیاد بین عوامل اثرگذار بر آلودگی هوا یا متغیرهای پیش‌بینی کننده باعث کاهش دقت مدل می‌شود. جهت بررسی همبستگی خطی بین این عوامل، قبل از اعمال مدل‌های یادگیری ماشین از عامل تورم واریانس (VIF) استفاده شد. عامل تورم واریانس نشان می‌دهد که واریانس ضرایب تخمینی تا چه حد نسبت به حالتی که متغیرها، همبستگی خطی ندارند، متورم شده است. درواقع، VIF نشان می‌دهد که یک عامل تا چه اندازه تحت تأثیر سایر عوامل پیش‌بینی کننده قرار گرفته و تغییر رفتار می‌دهد (معادله ۶). در این پژوهش، مقدار شاخص تورم واریانس بالای ۱۰ به عنوان وضعیت هم‌خطی بحرانی و مقدار نزدیک به یک به عنوان وضعیت مطلوب در نظر گرفته شد (Gareth et al. 2013).

$$VIF_i = \frac{1}{1 - R_i^2} \quad \text{رابطه (۶)}$$

در این رابطه، شاخص R^2 که بیانگر ضریب تعیین عوامل است، استفاده شد. **مدل‌سازی روند افزایشی PM_{2.5} در شهر اصفهان:** به منظور مدل‌سازی افزایش PM_{2.5} در ماه‌های منتخب، از سه الگوریتم یادگیری ماشین از جمله جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و درخت تقویت شده رگرسیون و طبقه‌بندی (BRT) در نرم‌افزار RStudio استفاده شد. بدین منظور مجموعه نقاط آموزشی که ۷۰٪ نقاط وقوع و عدم وقوع افزایش آلودگی هوا را شامل می‌شد، به همراه لایه‌های اطلاعاتی عوامل اثرگذار بر آلودگی هوا در نرم‌افزار RStudio به مدل‌های یادگیری ماشین معرفی شد و سپس با اجرای مدل‌ها، مدل‌سازی صورت گرفت.

اعتبارسنجی نتایج حاصل از مدل‌سازی: به منظور اعتبارسنجی نتایج حاصل از مدل، از منحنی راک و ۳۰٪ نقاط وقوع و عدم وقوع آلودگی هوا که به عنوان مجموعه داده‌های اعتبارسنجی در نظر گرفته شده‌اند، استفاده شد. در نظر گرفتن سطح زیر این منحنی (AUC) یکی از روش‌های رایج اعتبارسنجی است که در مدل‌سازی برای ارزیابی مدل‌های پیش‌بینی مورد استفاده قرار می‌گیرد (Robinson, 2014; Rezaei & JavanNezhad, ۲۰۲۰). AUC بین صفر تا ۱ متغیر است. هرچه مقدار مقادیر به ۱ نزدیک‌تر باشد، کارایی مدل بهتر محسوب است (جدول ۲).

جدول ۲. توصیف مقادیر AUC (Robinson, ۲۰۱۴)

مقدار AUC	کیفیت آزمون
۰/۶ - ۰/۵	ضعیف
۰/۷ - ۰/۶	متوسط
۰/۸ - ۰/۷	خوب
۰/۹ - ۰/۸	خیلی خوب
۱ - ۰/۹	عالی

*Variance Inflation Factor

*Random Forest

*Support Vector Machine

*Boosted Regression Tree


*Area Under the ROC Curve

اولویت‌بندی اثر عوامل انسانی-جمعیتی و عوامل محیطی مؤثر: به‌منظور تعیین اولویت عوامل پیش‌بینی‌کننده در هر مدل، آنالیز حساسیت جک‌نایف موردبررسی قرار گرفت (Abolhasani et al., 2022; Choubin et al., 2020) در پژوهش حاضر، آزمون جک‌نایف پس از پهنه‌بندی مناطق مستعد افزایش آلودگی هوا توسط هر مدل در محیط RStudio اجرا شد.

نتایج و بحث

ارزیابی روند تغییرات $PM_{2.5}$

نتایج مدل‌سازی رابطه بین مقادیر میانگین ماهانه $PM_{2.5}$ و مقادیر میانگین ماهانه AOD حاکی از همبستگی خوب بین این دو پارامتر بود (شکل ۳). بر اساس نتایج آنالیز رگرسیون خطی، شاخص AOD می‌تواند بیانگر وضعیت آلودگی هوا بر اساس ذرات معلق $PM_{2.5}$ در شهر اصفهان باشد. بنابراین با ضرب تصاویر ماهانه مربوط به شاخص AOD با طول موج سبز در ۲۴ سال مطالعاتی در رابطه حاصل از رگرسیون به دست آمده، تصاویر $PM_{2.5}$ به صورت ماهانه برای ۲۴ سال برآورد شد.





شکل ۳. همبستگی ذرات آلاینده $PM_{2.5}$ و AOD با طول موج سبز

نتایج روند تغییرات ماهانه $PM_{2.5}$ طی سال‌های ۲۰۰۱-۲۰۲۴ که توسط نرم‌افزار TerrSet صورت گرفت، نشان داد که ماه‌های خرداد، فروردین، مرداد، اردیبهشت، مهر و اسفند به ترتیب بیشترین روند افزایشی $PM_{2.5}$ در طول ۲۴ سال را دارا بودند. بنابراین این شش ماه، با بیشترین درصد مساحت مربوط به روند افزایشی $PM_{2.5}$ در شهر اصفهان به‌منظور مدل‌سازی در نظر گرفته شد. در ماه فروردین ۷۸/۰۷ درصد از مساحت شهر اصفهان با افزایش مقدار این آلاینده در طول ۲۴ سال مطالعاتی روبرو بوده است. در ماه اردیبهشت و خرداد، تغییرات $PM_{2.5}$ و آلودگی هوا در نواحی شمالی و غرب شهر اصفهان تا بخش‌هایی از مرکز شهر در طول ۲۴ سال مطالعاتی بدون روند بوده و در سایر نواحی، روند افزایشی مشاهده شد. در ماه اردیبهشت ۵۲/۹۱ درصد و در خردادماه ۸۱/۱۶ درصد از مساحت شهر با روند افزایشی $PM_{2.5}$ در طول ۲۴ سال مواجه بوده است. در ماه مرداد نیز ۷۱/۴۱ درصد از مساحت شهر با روند افزایشی $PM_{2.5}$ روبرو بوده است. به‌طوری‌که در عمده قسمت‌های شمال، شمال غرب، شمال شرق، غرب، شرق و مرکز شهر این روند افزایشی قابل مشاهده است. در ماه مهر، ۴۵/۷۲ درصد از مساحت شهر دارای روند افزایشی $PM_{2.5}$ و آلودگی هوا بوده است که عمدتاً در قسمت‌های شمال تا شمال شرق، شرق اصفهان، نواحی مرکزی، جنوب تا جنوب غربی و جنوب شرقی شهر اصفهان قابل مشاهده است. همچنین ۴۰/۶۸ درصد از مساحت شهر اصفهان در ماه اسفند با روند افزایشی شاخص

PM_{2.5} مواجهه بوده است که عمدتاً به نواحی شرقی، مرکز تا بخش‌هایی از غرب و شمال شهر اصفهان اختصاص دارد (شکل ۴).

این یافته حاکی از آن است که اگرچه آلودگی هوا در تمام فصول روند افزایشی داشته، اما شدت و وسعت این روند در ماه‌های گرم سال (خرداد، مرداد) و نیز ابتدای بهار (فروردین) چشمگیرتر بوده است. در پژوهش در سال ۱۴۰۲ نیز بیان شد که روند تغییرات شاخص AOD، که درواقع بیانگر وجود ذرات معلق در جو می‌باشد، از سال ۱۳۸۰ تا ۱۴۰۱ در نیمه شرقی و مرکزی ایران از جمله استان اصفهان با احتمال ۷۰٪ به صورت افزایشی بوده است (Nasabpour et al. 2023). گستردگی روند افزایشی در ماه‌های گرم می‌تواند ناشی از افزایش دما، تشدید واکنش‌های فتوشیمیایی و پایداری بیشتر جو در برخی روزها باشد. گراوندی و همکاران (۱۳۹۴) و نوروزی و همکاران (۲۰۱۷) نیز بیان داشتند که آلودگی هوا در شهر اصفهان در فصول گرم سال بیشتر از فصل‌های سرد بوده است. در مقابل، روند افزایشی در فروردین ماه احتمالاً تحت تأثیر پدیده‌های گردوغباری و نیز افزایش فعالیت‌های انسانی و ترافیک جاده‌ای پس از تعطیلات نوروزی قرار دارد. بر اساس مطالعات خسروشاهی و همکاران (۱۴۰۲)، در دو دهه گذشته، به‌ویژه در فصل‌های بهار و تابستان، فرکانس و شدت رخدادهای گردوغبار با منشأ منطقه‌ای و فرامرزی، در غرب و مرکز ایران افزایش یافته است و ماه‌های فروردین و خرداد اوج فصل گردوغبار در فلات مرکزی ایران هستند.







شکل ۴. روند تغییرات آلودگی هوا در ماه‌های منتخب در طول سال‌های ۲۰۰۱-۲۰۲۴

مدل‌سازی روند افزایشی $PM_{2.5}$

تعیین نقاط وقوع و عدم وقوع: با توجه به درصد مساحت دربرگیرنده روند افزایشی $PM_{2.5}$ در ماه‌های فروردین، اردیبهشت، خرداد، مرداد، مهر و اسفند، به ترتیب تعداد ۱۴۰، ۱۳۸، ۱۳۸، ۱۳۴ و ۱۳۴ نقطه وقوع و عدم وقوع در همراه در نظر گرفته شد (شکل ۵). نیمی از مجموعه نقاط در همراه به نقاط وقوع و نیم دیگر به نقاط عدم وقوع تعلق دارد. ۷۰٪ مجموعه نقاط جهت آموزش و مدل‌سازی به مدل معرفی شد و ۳۰٪ نقاط برای اعتبارسنجی در نظر گرفته شد.






شکل ۵. نقاط وقوع و عدم وقوع افزایش آلودگی هوا در ماه‌های منتخب

عوامل اثرگذار بر افزایش PM_{2.5}: متغیرهای اثرگذار بر افزایش PM_{2.5} و آلودگی هوا شامل عوامل محیطی از جمله دما، بارش و پوشش گیاهی و نیز عوامل انسانی- جمعیتی از جمله تراکم جاده، فاصله از جاده، فاصله از اراضی کشاورزی، فاصله از مراکز صنعتی، تراکم جمعیت و تراکم آبادی بود. نقشه تمامی عوامل با پیکسل سائزهای یکسان جهت مدل‌سازی در نرم‌افزار ArcGIS تهیه شد (شکل ۶). لازم به ذکر است که مقادیر دما، بارش و پوشش گیاهی برای هرماه به‌طور جداگانه برآورد و در مدل‌سازی اعمال شد که در شکل (۶) به‌عنوان نمونه مقادیر دما، بارش و EVI ماه خرداد ارائه شده است و برای تمامی ماه‌ها در جدول (۳) مقادیر پارامترهای مذکور نشان داده شده است. مقادیر میانگین دما، بارش و پوشش گیاهی برای شش ماه منتخب، در جدول زیر ارائه شده است. شاخص EVI مقادیری بین -۱ تا +۱ ارائه می‌دهد که -۱ شرایط نامساعد پوشش گیاهی یا مناطق فاقد پوشش می‌باشد. مقدار +۱ نیز شرایط مساعد پوشش گیاهی را نشان می‌دهد.

جدول ۳. مقادیر میانگین دما، بارش و شاخص پوشش گیاهی EVI برای ماه‌های منتخب

ماه	دما (°C)	بارش (mm)	EVI
فروردین	۳/۴۵	۰/۷۶	۰/۰۶
اردیبهشت	۶/۸۱	۸/۱۴	۰/۰۷
خرداد	۱۱/۹۵	۱۷/۷	۰/۰۷
مرداد	۲۲/۵	۱۰/۶۶	۰/۰۶
مهر	۳۰/۶۹	۱۵/۷۵	۰/۰۸
اسفند	۴/۸۹	۱۶/۱۸	۰/۰۶



شکل ۶. نقشه عوامل انسانی-جمعیتی و عوامل محیطی مؤثر بر افزایش $PM_{2.5}$

همبستگی بین عوامل اثرگذار: مطابق با نتایج آزمون عامل تورم واریانس که در جدول‌های ۴ تا ۹ ارائه شده است، مقادیر VIF برای عوامل پیش‌بینی کننده زیر ۱۰ می‌باشد. بنابراین از نظر همبستگی و هم‌خط بودن عوامل، مشکلی جهت مدل‌سازی ایجاد نمی‌شود. به‌منظور مدل‌سازی آلودگی هوا در ماه‌های مختلف، میانگین بلندمدت دما، بارش و پوشش گیاهی مختص همان ماه در مدل‌سازی در نظر گرفته شده است. بنابراین مقادیر VIF در هر بار مدل‌سازی به‌طور جداگانه برآورد شده است.

جدول ۴. مقدار عامل تورم واریانس جهت مدل‌سازی آلودگی هوا در ماه فروردین

مقدار VIF	عوامل پیش‌بینی کننده
۱/۴۶	فاصله از اراضی کشاورزی
۱/۶۱	پوشش گیاهی
۱/۴۵	فاصله از اراضی صنعتی
۳/۶۹	بارش
۴/۳۳	تراکم جمعیت
۱/۰۸	تراکم آبادی
۳/۳۶	دما
۱/۶۷	فاصله از جاده
۳/۶۸	تراکم جاده

جدول ۵. مقدار عامل تورم واریانس جهت مدل سازی آلودگی هوا در ماه اردیبهشت

عوامل پیش بینی کننده	مقدار VIF
فاصله از اراضی کشاورزی	۱/۷۵
پوشش گیاهی	۱/۷۱
فاصله از اراضی صنعتی	۱/۴۹
بارش	۳/۵۴
تراکم جمعیت	۴/۲۹
تراکم آبادی	۱/۰۹
دما	۳/۵
فاصله از جاده	۲/۱۲
تراکم جاده	۳/۶۳

جدول ۶. مقدار عامل تورم واریانس جهت مدل سازی آلودگی هوا در ماه خرداد

عوامل پیش بینی کننده	مقدار VIF
فاصله از اراضی کشاورزی	۳/۷۴
پوشش گیاهی	۱/۹
فاصله از اراضی صنعتی	۱/۱۸
بارش	۱/۶
تراکم جمعیت	۴/۱۵
تراکم آبادی	۱/۰۲
دما	۱/۰۲
فاصله از جاده	۶/۸۳
تراکم جاده	۷/۳

جدول ۷. مقدار عامل تورم واریانس جهت مدل سازی آلودگی هوا در ماه مرداد

عوامل پیش بینی کننده	مقدار VIF
فاصله از اراضی کشاورزی	۱/۷۶
پوشش گیاهی	۱/۵۳
فاصله از اراضی صنعتی	۱/۵
بارش	۳/۴۶
تراکم جمعیت	۶/۰۹
تراکم آبادی	۱/۱۶
دما	۳/۲۳
فاصله از جاده	۲/۱۵
تراکم جاده	۵/۲


جدول ۸. مقدار عامل تورم واریانس جهت مدل سازی آلودگی هوا در ماه مهر

عوامل پیش بینی کننده	مقدار VIF
فاصله از اراضی کشاورزی	۱/۵
پوشش گیاهی	۱/۵۵
فاصله از اراضی صنعتی	۱/۵
بارش	۲/۹
تراکم جمعیت	۴
تراکم آبادی	۱/۰۴
دما	۲/۶۷
فاصله از جاده	۱/۹
تراکم جاده	۳/۲۱


جدول ۹. مقدار عامل تورم واریانس جهت مدل سازی آلودگی هوا در ماه اسفند

عوامل پیش بینی کننده	مقدار VIF
فاصله از اراضی کشاورزی	۱/۵۵
پوشش گیاهی	۱/۷۳
فاصله از اراضی صنعتی	۱/۳۳
بارش	۳/۸۱
تراکم جمعیت	۴/۰۴
تراکم آبادی	۱/۰۶
دما	۳/۳۶
فاصله از جاده	۱/۹۸
تراکم جاده	۳/۶۷


مدل سازی روند افزایشی $PM_{2.5}$: نتایج مدل سازی روند افزایشی $PM_{2.5}$ شهر اصفهان در ماه های منتخب بر اساس سه مدل جنگل تصادفی، درخت رگرسیون تقویت شده و مدل ماشین بردار پشتیبان در شکل های ۷ الی ۱۲ ارائه شده است. بر اساس نتایج به دست آمده، بیشترین روند افزایشی $PM_{2.5}$ ساله ۲۴ در ماه فروردین به قسمت های شمال، شمال شرق، شمال غرب تا شرق و مرکز شهر اصفهان اختصاص داشته است. در ماه اردیبهشت، نواحی جنوبی تا جنوب شرق و جنوب غربی شهر اصفهان با بیشترین روند افزایشی $PM_{2.5}$ در طول ۲۴ سال مواجه بوده است. در خردادماه، قسمت های شرقی شهر اصفهان، جنوب شرق، جنوب تا جنوب غرب و بخش هایی از غرب و مرکز شهر استان با روند افزایشی آلودگی هوا در طول ۲۴ سال مطالعاتی مواجه بوده است. در ماه مرداد، بیشترین روند افزایشی $PM_{2.5}$ در قسمت های شمال، شمال شرق، شمال غرب، مرکز و غرب تا جنوب غرب شهر اصفهان مشاهده شد. همچنین، بیشترین روند افزایشی $PM_{2.5}$ در ماه مهر به قسمت هایی از شمال، شمال غرب، مرکز تا جنوب شرق شهر اصفهان تعلق داشته و در ماه اسفند در نواحی شمال غرب، غرب، جنوب غرب و جنوب شهر اصفهان بیشترین روند افزایشی $PM_{2.5}$ قابل مشاهده است.




شکل ۷. مدل سازی مکانی آلودگی هوا در ماه فروردین




شکل ۸. مدل سازی مکانی آلودگی هوا در ماه اردیبهشت




شکل ۹. مدل سازی مکانی آلودگی هوا در ماه خرداد



شکل ۱۰. مدل‌سازی مکانی آلودگی هوا در ماه مرداد



شکل ۱۱. مدل‌سازی مکانی آلودگی هوا در ماه مهر



شکل ۱۲. مدل‌سازی مکانی آلودگی هوا در ماه اسفند

صحت‌سنجی نتایج مدل‌سازی افزایش PM_{2.5}: مطابق با مقادیر AUC در منحنی ROC که به منظور صحت‌سنجی نتایج مدل‌های اعمال شده برآورد شد، در ماه فروردین به ترتیب مدل‌های RF، SVM و BRT بیشترین قابلیت را در مدل‌سازی افزایش آلودگی هوا در شهر اصفهان دارا بودند. در ماه اردیبهشت مدل BRT با مقدار AUC برابر با ۰/۸۶ بیشترین کارایی را جهت مدل‌سازی دارا بود و پس‌از آن به ترتیب مدل RF و SVM قرار داشتند. در ماه‌های خرداد و مرداد مدل SVM به ترتیب با مقادیر AUC برابر با ۰/۸۱ و ۰/۹ بیشترین کارایی جهت مدل‌سازی آلودگی هوا در شهر اصفهان را داشت. همچنین در ماه‌های مهر و اسفند به ترتیب مدل BRT با AUC برابر با ۰/۸۲ و مدل RF با AUC برابر با ۰/۸۶ بهترین کارایی جهت مدل‌سازی آلودگی هوا را داشتند (جدول ۱۰). از سه مدل اعمال شده جهت مدل‌سازی افزایش آلودگی هوا در بین تمامی ماه‌های مطالعاتی، مدل SVM در ماه مرداد با AUC برابر با ۰/۹ که نشان‌دهنده کارایی خیلی خوب مدل است، بیشترین قابلیت جهت مدل‌سازی را نشان داد. بررسی کارایی سه مدل جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و درخت تقویت‌شده رگرسیون و طبقه‌بندی (BRT) نشان داد که عملکرد مدل‌ها در ماه‌های مختلف، متفاوت بوده است. در مجموع، مدل RF در ماه فروردین و اسفند، مدل SVM در دو ماه خرداد و مرداد و مدل BRT در دو ماه اردیبهشت و مهر بهترین عملکرد را داشتند. این تنوع در عملکرد مدل‌ها نشان می‌دهد که انتخاب الگوریتم مناسب باید با توجه به ویژگی‌های هرماه و نوع رابطه بین متغیرها صورت گیرد. بیشترین دقت مدل‌سازی با مقدار AUC برابر ۰/۹ مربوط به مدل SVM در ماه مرداد بود که بیانگر توانایی بالای این مدل در شناسایی الگوهای پیچیده و غیرخطی حاکم بر آلودگی هوا در این ماه است. مرادی و همکاران (۲۰۲۳)، دقت بالای مدل SVM را در مدل‌سازی مرتبط با پوشش گیاهی، به دلیل توانایی SVM در مدیریت داده‌هایی با ابعاد بالا و شناسایی مرزهای تصمیم‌گیری بهینه در فضاهای ویژگی پیچیده، گزارش کردند. معظمی و همکاران (۱۳۹۶) نیز عملکرد مناسب مدل SVM در پیش‌بینی غلظت روزانه CO در شهر تهران را برآورد کردند.

جدول ۱۰. مقادیر AUC در منحنی ROC

ماه	مقادیر AUC در مدل‌های یادگیری ماشین		
	SVM	BRT	RF
فروردین	۰/۷۴	۰/۷۲	۰/۷۹
اردیبهشت	۰/۸۲	۰/۸۶	۰/۸۴
خرداد	۰/۸۱	۰/۷۴	۰/۷۷
مرداد	۰/۹	۰/۸	۰/۸۳
مهر	۰/۷۵	۰/۸۲	۰/۸۱
اسفند	۰/۷۶	۰/۷۷	۰/۸۶

اولویت‌بندی عوامل مؤثر در مدل‌سازی روند افزایشی $PM_{2.5}$: نتایج آنالیز حساسیت جک‌نایف بر اساس مقادیر AUC برای هرماه به‌طور جداگانه ارائه شده است. لازم به ذکر است که درصد‌های ارائه شده برای هر عامل بر اساس درصدی از مقادیر AUC می‌باشد که نشان‌دهنده کاهش مقدار AUC با حذف آن عامل است. جمع این درصد‌ها لزوماً ۱۰۰ نمی‌شود، چراکه ممکن است بخشی از قدرت مدل به اثرات تعاملی یا مشترک چند متغیر وابسته باشد که با حذف یکی هر متغیر قابل تشخیص نیست. بر اساس نتایج به دست آمده از مدل جنگل تصادفی، در ماه فروردین به ترتیب عوامل دما، فاصله از اراضی صنعتی، فاصله از اراضی کشاورزی، بارش، پوشش گیاهی، تراکم جمعیت و تراکم جاده بیشترین اثرگذاری را در افزایش آلودگی هوا داشتند. بر اساس نتایج مدل BRT، به ترتیب عوامل فاصله از اراضی کشاورزی، پوشش گیاهی و دما، تراکم جاده و فاصله از جاده بیشترین اهمیت را در مدل‌سازی افزایش آلودگی هوا در شهر اصفهان داشتند. همچنین بر اساس مدل SVM، فاصله از اراضی زراعی، پوشش گیاهی، فاصله از اراضی صنعتی، فاصله از جاده و تراکم جمعیت به ترتیب مهم‌ترین عوامل اثرگذار در مدل‌سازی افزایش آلودگی هوا بودند (جدول ۱۱). در ماه اردیبهشت عامل درجه حرارت در هر سه مدل بیشترین اثرگذاری را در افزایش $PM_{2.5}$ در شهر اصفهان داشت. در مدل جنگل تصادفی پس از درجه حرارت، عوامل فاصله از اراضی صنعتی و بارش به ترتیب بیشترین تأثیرگذاری را در داشتند. همچنین در مدل‌های BRT و SVM به ترتیب فاصله از اراضی صنعتی، پوشش گیاهی و بارش بیشترین اثرگذاری را دارا بودند (جدول ۱۲). در ماه خرداد، مطابق با نتایج آنالیز حساسیت جک‌نایف، عوامل فاصله از جاده، دما و تراکم جاده به ترتیب در مدل‌سازی افزایش $PM_{2.5}$ توسط الگوریتم‌های RF، BRT و SVM بیشترین اثرگذاری را دارا بودند (جدول ۱۳). در مردادماه، مطابق با نتایج مدل جنگل تصادفی، عامل درجه حرارت، فاصله از اراضی کشاورزی، تراکم جمعیت و تراکم جاده بیشترین تأثیر را در افزایش $PM_{2.5}$ داشتند. همچنین مطابق با نتایج آنالیز حساسیت جک‌نایف در مدل‌های BRT و SVM عامل درجه حرارت بیشترین اثرگذاری را در نتایج مدل و افزایش آلودگی هوا دارا بود (جدول ۱۴). در ماه مهر مطابق با نتایج مدل‌های RF و BRT، بارش و فاصله از اراضی کشاورزی بیشترین تأثیر را در نتایج مدل داشتند. در حالی که در مدل SVM تراکم جمعیت با مقدار $20/9$ درصد و پس‌از آن فاصله از اراضی کشاورزی با $14/6$ درصد، بیشترین اثر را در نتایج مدل جهت مدل‌سازی افزایش $PM_{2.5}$ در شهر اصفهان داشتند (جدول ۱۵). همچنین بر اساس نتایج مدل‌سازی افزایش $PM_{2.5}$ در ماه اسفند، در هر سه مدل عامل درجه حرارت بیشترین اثرگذاری را داشته است. در مدل RF پس از دما، به ترتیب عوامل انسانی تراکم جاده و فاصله از اراضی صنعتی دارای بیشترین اثر بودند. در مدل BRT، فاصله از اراضی صنعتی با مقدار $8/6$ درصد و تراکم جمعیت با درصد $5/8$ ، پس از دما بیشترین تأثیر را داشتند. در نهایت در مدل SVM، بعد از دما به ترتیب عوامل انسانی فاصله از اراضی صنعتی، فاصله از جاده، تراکم جاده و تراکم جمعیت بیشترین تأثیر را دارا بودند (جدول ۱۶).

جدول ۱۱. درصد میزان اهمیت عوامل اثرگذار در مدل‌سازی افزایش PM_{2.5} در ماه فروردین بر اساس مقادیر AUC

عوامل اثرگذار	RF	BRT	SVM
فاصله از اراضی کشاورزی	۱/۲	۱۷/۱	۱۵/۹
پوشش گیاهی	۰/۴	۶/۹	۸/۶
فاصله از اراضی صنعتی	۱/۴	۲/۴	۷/۸
بارش	۰/۵	۲/۳	۴/۵
تراکم جمعیت	۰/۲	۲/۱	۵/۳
تراکم جاده	۰/۲	۳/۴	۳/۵
فاصله از جاده	۰/۱	۲/۷	۶/۸
دما	۶/۳	۶/۹	۴/۸
تراکم آبادی	۰	۰	۱/۹

جدول ۱۲. درصد میزان اهمیت عوامل اثرگذار در مدل‌سازی افزایش PM_{2.5} در ماه اردیبهشت بر اساس مقادیر AUC

عوامل اثرگذار	RF	BRT	SVM
فاصله از اراضی کشاورزی	۱/۲	۰/۳	۲/۴
پوشش گیاهی	۱/۳	۲/۸	۶/۴
فاصله از اراضی صنعتی	۲/۷	۲/۸	۱۲/۱
بارش	۲/۲	۲/۵	۴/۵
تراکم جمعیت	۰/۷	۲/۱	۳
تراکم جاده	۰/۸	۱/۲	۲/۲
فاصله از جاده	۰/۹	۰/۵	۲/۶
دما	۵/۷	۴۵	۲۵
تراکم آبادی	۰	۰	۱/۴

جدول ۱۳. درصد میزان اهمیت عوامل اثرگذار در مدل‌سازی افزایش PM_{2.5} در ماه خرداد بر اساس مقادیر AUC

عوامل اثرگذار	RF	BRT	SVM
فاصله از اراضی کشاورزی	۰/۶	۳/۶	۸/۹
پوشش گیاهی	۰	۴	۴/۹
فاصله از اراضی صنعتی	۰/۱	۲/۲	۱۱/۹
بارش	۰	۱/۴	۵/۹
تراکم جمعیت	۰/۴	۶/۸	۱۶/۹
تراکم جاده	۰/۷	۱۱/۴	۱۹/۷
فاصله از جاده	۳/۸	۱۱/۳	۹/۷
دما	۰/۴	۱۸/۴	۹/۳
تراکم آبادی	۰	۰/۲	۶/۱

جدول ۱۴. درصد میزان اهمیت عوامل اثرگذار در مدل‌سازی افزایش PM_{2.5} در ماه مرداد بر اساس مقادیر AUC

عوامل اثرگذار	RF	BRT	SVM
فاصله از اراضی کشاورزی	۲/۶	۳/۴	۷/۹
پوشش گیاهی	۰/۲	۰/۶	۵/۱
فاصله از اراضی صنعتی	۱/۱	۸/۱	۷/۷
بارش	۰/۳	۰/۹	۶/۷
تراکم جمعیت	۱/۶	۴/۴	۳
تراکم جاده	۱/۵	۳/۵	۵/۹
فاصله از جاده	۰	۰/۵	۱/۹
دما	۱۲/۱	۳۶	۲۳/۱
تراکم آبادی	۰	۰	۱/۹

جدول ۱۵. درصد میزان اهمیت عوامل اثرگذار در مدل سازی افزایش $PM_{2.5}$ در ماه مهر بر اساس مقادیر AUC

عوامل اثرگذار	RF	BRT	SVM
فاصله از اراضی کشاورزی	۳/۲	۱۳/۳	۱۴/۶
پوشش گیاهی	۰	۳/۸	۶/۶
فاصله از اراضی صنعتی	۱/۳	۵/۲	۸
بارش	۳/۲	۲۶/۳	۱۴/۲
تراکم جمعیت	۱/۲	۵/۲	۲۰/۹
تراکم جاده	۰	۱۰/۳	۱۱/۴
فاصله از جاده	۰	۰/۳	۱۱
دما	۰	۲/۲	۱۱/۶
تراکم آبادی	۰	۰	۶/۳

جدول ۱۶. درصد میزان اهمیت عوامل اثرگذار در مدل سازی افزایش $PM_{2.5}$ در ماه اسفند بر اساس مقادیر AUC

عوامل اثرگذار	RF	BRT	SVM
فاصله از اراضی کشاورزی	۰	۱/۴	۴
پوشش گیاهی	۰/۱	۲/۱	۱۱
فاصله از اراضی صنعتی	۱/۵	۸/۶	۱۰/۶
بارش	۰/۷	۱	۸/۲
تراکم جمعیت	۰	۵/۸	۶/۴
تراکم جاده	۳/۹	۱	۸/۸
فاصله از جاده	۰/۳	۲/۳	۸/۹
دما	۳۶	۵۶	۳۴
تراکم آبادی	۰	۰	۲/۹

بر اساس نتایج آنالیز حساسیت جک‌نایف که تصویری روشن از سهم نسبی عوامل مختلف در افزایش آلودگی هوای اصفهان به دست داد، عامل دما در پنج ماه از شش ماه مورد مطالعه (به جز ماه مهر) به عنوان یکی از مهم ترین متغیرها ظاهر شد. این عامل در ماه اردیبهشت، با ۴۵٪ سهم در مدل BRT و ۲۵٪ در مدل SVM، در ماه مرداد ۳۶٪ در BRT و ۲۳/۱٪ در SVM و در ماه اسفند ۵۶٪ در BRT و ۳۶٪ در مدل RF، بالاترین درصد اهمیت را به خود اختصاص داد. این یافته مؤید نقش کلیدی دما در شکل گیری و تشدید آلودگی هوا از طریق تأثیر بر پایداری جو، واکنش های فتوشیمیایی و تشکیل ذرات ثانویه است. ابراهیمی خوسفی و درگاهیان (۱۳۷) نیز همبستگی بالا بین مقادیر میانگین درجه حرارت و غلظت $PM_{2.5}$ را تأیید کردند. اگرچه عوامل محیطی به ویژه دما سهم بالایی در روند افزایشی $PM_{2.5}$ داشتند، اما مجموع عوامل انسانی-جمعیتی در تمامی ماه ها سهم قابل توجهی را به خود اختصاص داد. فاصله از اراضی صنعتی به عنوان یک عامل کلیدی در اغلب ماه های مطالعاتی، اهمیت خود را نشان داد. این نتیجه بیانگر تأثیر مستقیم انتشار آلاینده های صنعتی بر کیفیت هوای مناطق مجاور است. فاصله از اراضی کشاورزی نیز در ماه های فروردین، مهر و خرداد به عنوان عاملی مهم ظاهر شد. این مسئله می تواند ناشی از سوزاندن بقایای گیاهی پس از برداشت محصول و یا انتشار گردوغبار از اراضی کشاورزی به ویژه در فصول خاص باشد. تراکم جاده و فاصله از جاده به عنوان شاخص های ترافیک و حمل و نقل، در ماه های خرداد با ۱۹/۷٪ و ۹/۷٪ در مدل SVM و مهر با ۱۱/۴٪ و ۱۱٪ در مدل SVM، اهمیت بالایی داشتند. این نشان می دهد که منابع متحرک آلودگی در برخی ماه ها (احتمالاً هم زمان با اوج سفرها و فعالیت های شهری) سهم عمده ای در افزایش $PM_{2.5}$ دارند. همچنین مطابق با نتایج مدل SVM، تراکم جمعیت، به عنوان نماینده فعالیت های شهری و مصرف انرژی، در ماه های مهر و خرداد با ۲۰/۹٪ و ۱۶/۹٪ بیشترین تأثیر را در افزایش $PM_{2.5}$ نشان داد. مطالعات متعددی، فعالیت های انسانی را به عنوان عاملی مؤثر در افزایش $PM_{2.5}$ معرفی کردند (Peng et al. 2022؛ Oroji, 2025). شاخص پوشش گیاهی (EVI) در ماه های فروردین، اردیبهشت و اسفند، اهمیت نسبی در افزایش $PM_{2.5}$ در شهر اصفهان داشت. از یک سو پوشش گیاهی با تثبیت خاک و جذب آلاینده ها می تواند به کاهش آلودگی هوا کمک کند، اما از سوی

دیگر در برخی فصول (مانند اوایل بهار) ممکن است با انتشار گرده‌ها یا تغییر در رطوبت سطحی، اثرات غیرمستقیم بر غلظت ذرات PM_{2.5} داشته باشد که در مقایسه با سایر منابع آلاینده قابل توجه نمی‌باشد. نتایج پژوهش کیانی و همکاران (۱۴۰۴) نشان داد که کاهش ۶۰٪ پوشش درختی باغ‌نگارستان از سال ۱۳۲۱ تا ۱۳۷۸ و بهبود نسبی به ۱/۴۱ هکتار در سال ۱۴۰۴، به افزایش غلظت ذرات معلق کوچکتر از ۲/۵ میکرون و ذرات معلق کوچکتر از ۱۰ میکرون منجر شده است. سناریوهای افزایش ۳۵٪ و ۷۰٪ پوشش سبز به ترتیب کاهش ۲۴٪ و ۳۸٪ در غلظت ذرات معلق کوچکتر از ۲/۵ میکرون و کاهش ۱۸ و ۲۷ درصد در نرخ مرگ‌ومیر را نشان داد.

نتیجه‌گیری

پژوهش حاضر با هدف تعیین اولویت عوامل انسانی-جمعیتی و محیطی در مدل‌سازی روند تغییرات آلودگی هوای شهر اصفهان طی سال‌های ۲۰۰۱ تا ۲۰۲۴ انجام شد. تلفیق داده‌های زمینی PM_{2.5} و تصاویر ماهواره‌ای AOD، همراه با بهره‌گیری از مدل‌های یادگیری ماشین و آنالیز حساسیت جک‌نایف، امکان شناسایی دقیق‌تر الگوهای مکانی-زمانی آلودگی و عوامل مؤثر بر آن را فراهم آورد. نتایج پژوهش حاضر نشان داد که روند افزایشی آلودگی هوا در شهر اصفهان محدود به فصل خاصی نیست، اما شدت آن در ماه‌های گرم سال و ابتدای بهار بیشتر است. از منظر اولویت‌بندی عوامل مؤثر، اگرچه متغیرهای محیطی به‌ویژه دما نقش اساسی در تشدید شرایط آلودگی ایفا می‌کنند، اما عوامل انسانی-جمعیتی به‌صورت ترکیبی و در تعامل با شرایط محیطی، سهمی تعیین‌کننده و بعضاً غالب در افزایش غلظت آلاینده‌ها دارند. به‌بیان دیگر، شرایط محیطی (مانند دما) زمینه‌ساز پایداری یا واکنش‌های شیمیایی هستند، اما منشأ اصلی آلاینده‌ها به فعالیت‌های انسانی (صنعت، ترافیک، کشاورزی و تمرکز جمعیت) بازمی‌گردد.

بر اساس یافته‌های این پژوهش، پیشنهاد می‌شود با توجه به اهمیت فاصله از اراضی صنعتی، استقرار صنایع جدید با رعایت حریم مناسب و در اولویت پایین دست جریان باد غالب انجام شود. همچنین نظارت بر خروجی دودکش‌های صنایع موجود و الزام به استفاده از فناوری‌های کاهش آلاینده‌ها به صورت الزامی صورت گیرد. با عنایت به نقش تراکم و فاصله از جاده‌ها به‌ویژه در ماه‌های خرداد و مهر، توسعه حمل‌ونقل عمومی پاک، گسترش مناطق کم‌ترافیک و تشدید معاینه فنی خودروها باید در اولویت قرار گیرد. با توجه به اهمیت فاصله از اراضی کشاورزی، ممنوعیت سوزاندن بقایای گیاهی و ترویج کشاورزی حفاظتی می‌تواند مؤثر باشد. همچنین افزایش فضای سبز با گونه‌های بومی و مقاوم به خشکی در نواحی با تراکم جمعیت بالا و نزدیک به مراکز صنعتی، به عنوان راهکاری برای جذب ذرات معلق پیشنهاد می‌شود. در نهایت، با توجه به نقش تراکم جمعیت، هرگونه سیاست‌گذاری در زمینه توسعه شهری باید با ملاحظات زیست‌محیطی و با هدف کاهش تمرکز جمعیت در مناطق بحرانی همراه باشد.

سپاسگزاری: مقاله حاضر برگرفته از رساله دکتری می‌باشد. بدین‌وسیله از همکاری مشارکت‌کنندگان در این مقاله که سهم مؤثری در جمع‌آوری داده‌ها داشته‌اند، تشکر و قدردانی می‌شود.

حامی مالی: بنا به اظهار نویسنده مسئول، این مقاله حامی مالی نداشته است.

سهم نویسندگان در پژوهش: همه نویسندگان، در نگارش و تنظیم مقاله حاضر نقش و سهم برابر دارند.

تضاد منافع: نویسندگان اعلام می‌دارند هیچ تضاد منافی در رابطه با نویسندگی و یا انتشار این مقاله ندارند.

References

- Abolhasani, A., Zehtabian, G., Khosravi, H., Rahmati, O., Alamdarloo, E. H., & D'Odorico, P., 2022. A new conceptual framework for spatial predictive modelling of land degradation in a semiarid area. *Land Degradation & Development*, 33(17), 3358–3374. <https://doi.org/10.1002/ldr.4402>
- Darvand, S., Khosravi, H., Keshtkar, H. R., Zehtabian, G., & Rahmati, O., 2021. Comparison of machine learning models for prioritizing dust-prone areas. *Journal of Rangeland and Watershed Management*, 74(1), 58–63. <https://doi.org/10.22059/jrwm.2021.312937> (In Persian)

- Davtalab, M., Byčenkienė, S., & Bimbaitė, V., 2023. Long-term spatial and temporal evaluation of the PM2.5 and PM10 mass concentrations in Lithuania. *Atmospheric Pollution Research*, 14(12), 101951. <https://doi.org/10.1016/j.apr.2023.101951>
- Ebrahimi Khouf, Z., & Dargahian, F., 2018. Investigating the effects of climatic parameters on variations in PM10 concentration and its relationship with wind erosion events in arid regions. *Journal of Arid Region Geographical Studies*, 9(34), 76–92. https://arsg.hsu.ac.ir/article_89634.html (In Persian)
- Fatima, M., Butt, I., Nasar-u-Minallah, M., Atta, A., & Cheng, G., 2023. Assessment of air pollution and its association with population health: geo-statistical evidence from Pakistan. *Geography, Environment, Sustainability*, 16(2), 93–101. <https://doi.org/10.24057/2071-9388-2022-076>
- Geravandi, S., Zalaghi, E., Goudarzi, G., Mohammadi, M. J., Babaei, A. A., Yari, A. R., et al., 2016. Exposure to particulate matter of less than 10 microns and its effect on respiratory and cardiovascular diseases in Isfahan, Iran in 2013. *Journal of Health System Research*, 11(4), 725–730. <https://hsr.mui.ac.ir/article-1-840-fa.html> (In Persian)
- Heger, M., & Sarraf, M., 2018. Air pollution in Tehran: health costs, sources, and policies. World Bank Report. <https://openknowledge.worldbank.org/handle/10986/29961>
- Iram, S., Qaisar, I., Shabbir, R., Pomee, M. S., Schmidt, M., & Hertig, E., 2025. Impact of air pollution and smog on human health in Pakistan: a systematic review. *Environments*, 12(2), 46. <https://doi.org/10.3390/environments12020046>
- James, G., Witten, D., Hastie, T., & Tibshirani, R., 2013. An introduction to statistical learning: with applications in R. Springer.
- Khosroshahi, M., Saeedifar, Z., Shahbazi, K., Zandifar, S., Lotfinasabasl, S., Gohardoust, A., Dargahian, F., Naeemi, M., Ensafi Moghadam, T., Kashi Zenouzi, L., Ebrahimi Khosefi, Z., & Khodaghali, M., 2024. Investigating the trend of temporal and spatial changes of dusty days and determining the contribution of climatic elements on its spread in Iran. *Iranian Journal of Range and Desert Research*, 30(4), 521–541. <https://doi.org/10.22092/ijdr.2024.130966> (In Persian)
- Kiani, K., Zandieh, M., Medi, H., Zarrabi, M. M., & Azmoodeh, M., 2025. Analysis of the impact of vegetation on reducing air pollution and health with an emphasis on quality of life in the Baharestan Square area. *Urban Design Discourse*, 6(3), 17–29. <https://doi.org/10.48311/udd.2025.27565> (In Persian)
- Liu, X., Nie, D., Zhang, K., Wang, Z., Li, X., Shi, Z., Wang, Y., Huang, L., Chen, M., Ge, X., & Ying, Q., 2019. Evaluation of particulate matter deposition in the human respiratory tract during winter in Nanjing using size and chemically resolved ambient measurements. *Air Quality, Atmosphere & Health*, 12(5), 529–538. <https://doi.org/10.1007/s11869-019-00681-3>
- Makhdoomi, A., Sarkhosh, M., & Ziaei, S., 2025. PM2.5 concentration prediction using machine learning algorithms: an approach to virtual monitoring stations. *Scientific Reports*, 15(1), 8076. <https://doi.org/10.1038/s41598-025-08076-1>
- Moazami, S., Nouri, R., Solimani, M., Momeni, M. R., & Salehi, N., 2017. Evaluating the capability of support vector machine in predicting carbon monoxide. *Modares Civil Engineering Journal*, 17(3), 195–202. <https://mcej.modares.ac.ir/article-16-10531-fa.html> (In Persian)
- Mondal, S., Adhikary, A. S., Dutta, A., Bhardwaj, R., & Dey, S., 2024. Utilizing machine learning for air pollution prediction, comprehensive impact assessment, and effective solutions in Kolkata, India. *Results in Earth Sciences*, 2, 100030. <https://doi.org/10.1016/j.resenv.2024.100030>
- Moradi, E., Darabi, H., Alamdarloo, E. H., Karimi, M., & Kløve, B., 2023. Vegetation vulnerability to hydrometeorological stresses in water-scarce areas using machine learning and remote sensing techniques. *Ecological Informatics*, 73, 101838. <https://doi.org/10.1016/j.ecoinf.2022.101838>
- Nasabpour, S., Salajegheh, A., Khosravi, H., Nasiri, A., & Ranjbar Sa'adatabadi, A., 2023. Investigating dust storm trends in the eastern half of Iran. *Desert Management*, 11(2), 1–16. <https://doi.org/10.22034/jdmal.2023.1990426.1345> (In Persian)
- Nisi, A., Goodarzi, G., Ahmadi Angali, K., & Nejat, S. H., 2021. Assessment of PM2.5 and PM10 concentrations and their association with cardiovascular and respiratory mortality in Susangerd during 2014–2016. *Environmental Health Engineering Journal*, 9(2), 145–156. <https://jehe.abzums.ac.ir/article-1-840-fa.html> (In Persian)
- Norouzi, S., Khademi, H., Ayoubi, S., Cano, A. F., & Acosta, J. A., 2017. Seasonal and spatial variations in dust deposition rate and concentrations of dust-borne heavy metals, a case study from Isfahan, central Iran. *Atmospheric Pollution Research*, 8(4), 686–699. <https://doi.org/10.1016/j.apr.2017.01.003>
- Oroji, B., 2025. The role of environmental factors and sources of ultrafine particulate matter emissions in enclosed spaces. *Journal of Environmental Health Science and Engineering*, 3(10). (In Persian)

- Peng, J., Han, H., Yi, Y., Huang, H., & Xie, L., 2022. Machine learning and deep learning modeling and simulation for predicting PM_{2.5} concentrations. *Chemosphere*, 308, 136353. <https://doi.org/10.1016/j.chemosphere.2022.136353>
- Rezaei, M., & JavanNezhad, R., 2020. Modeling the role of climate in the distribution of two-spotted spider mite: case study of Tehran province. *Journal of Environmental Science Studies*, 5(2), 2554–2559. http://www.jess.ir/article_111776.html (In Persian)
- Robinson, S., 2014. *Simulation: the practice of model development and use*. 2nd edition. Palgrave Macmillan.
- Sha, T., Li, L. Q., Yan, S. Q., Yang, S. Y., Li, Y., Dong, Z. P., & Chen, Q. C., 2025. Review of machine learning in air pollution research. *Huan Jing Ke Xue*, 46(6), 3315–3328. <https://doi.org/10.13227/j.hjxx.202403164>
- Tiwary, A., & Williams, I., 2018. *Air pollution: measurement, modelling and mitigation*. CRC Press.