

Review Article

DOI: 10.22067/geoeh.2024.88696.1497



A Meta-Analysis and Systematic Review of Integrating Satellite-

Derived Aerosol Optical Depth Data with Machine Learning for

Estimating Fine Particulate Matter (PM_{2.5}) Concentrations

Rasool Taherian Esfahani^a, Mehdi Ghanbarzadeh Lak^{a*}

^a Civil Engineering Department, School of Engineering, Urmia University, Urmia, Iran

Article Info

Abstract

Article history	Exposure to fine particulate matter (PM _{2.5}) significantly impacts public
Received :13 July 2024	health, particularly in regions where annual average levels of PM2.5 exceed
Received in revised form:	the World Health Organization (WHO) guidelines. According to the
4 December 2024	literature, in Iran, elevated fine particulate matter levels contribute
Accepted: 25 December	substantially to mortality among adults. The spatial coverage limitations and
2024	intermittent data gaps of ground $PM_{2.5}$ monitoring stations nose challenges
Available online:	for effective air quality management
21 March 2025	The products of remote sensing technologies, such as Aerosol Optical Depth
	(AOD) from the Moderate Desolution Imaging Spectroradiometer (MODIS)
Keywords:	(AOD) noin the Moderate Resolution imaging Spectrolationeter (MODIS)
	sensors, otter a promising alternative for time particulate matter estimation.
PM2.5, AEROSOL	This study reviews previous research on using machine learning algorithms to
OPTICAL DEPTH (AOD),	predict PM _{2.5} ground concentrations based on AOD data. A structured
MACHINE LEARNING,	analysis of 127 selected studies reveals varying correlations between AOD
MODIS, ENSEMBLE	and $PM_{2.5}$ (with the resultant coefficient of determination, R^2 , between
LEARNING, HYBRID	ground PM _{2.5} concentrations and AOD data ranging from 48 to 99%),
MODELS, SYSTEMATIC	influenced by auxiliary variables like meteorological conditions and
REVIEW, PUBLIC	environmental factors.
HEALTH IMPACT	Integrating these variables enhances prediction accuracy, though it may
	increase complexity and potential errors in machine learning models. The
	hybrid machine learning models demonstrate superior performance compared
	to individual algorithms, leveraging their adaptability, parallel processing
	capabilities, and ability to handle missing data. Despite advancements,
	challenges persist due to data uncertainty and meteorological dynamics.
	In conclusion, while machine learning offers robust tools for PM _{2.5} forecasting
	using AOD data ongoing research is essential to address existing limitations
	and ontimize model performance amidst environmental variability
	and optimize model performance annast environmental variability.
* Como an aline o costlo an	Charles and the Equal address in should and the Quanties of in

*.Corresponding author: Ghanbarzadeh Lak E-mail address: m.ghanbarzadehlak@urmia.ac.ir

How to cite this article: Taherian Esfahani, R., & Ghanbarzadeh Lak, M. (2025). A Meta-Analysis and Systematic Review of Integrating Satellite-Derived Aerosol Optical Depth Data with Machine Learning for Estimating Fine Particulate Matter (PM_{2.5}) Concentrations. *Journal of Geography and Environmental Hazards*, *14*(1), pp.157-192, https://doi.org/10.22067/geoeh.2024.88696.1497

©2025 The author(s). This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0)

Extended Abstract Introduction

Air pollution, an inevitable consequence of industrialization, climate change, and increased fossil fuel usage, has emerged as a critical environmental concern, especially in urban areas. Globally, air pollution is recognized as one of the leading environmental health risks, contributing significantly to premature mortality and morbidity, with Iran ranking particularly high in terms of annual deaths linked to air pollution. Recent data place air pollution as the eighth leading global risk factor for mortality and the seventh in Iran, underlining its severe public health implications. The health effects range from respiratory and cardiovascular diseases to heightened risks of cancer. Emerging evidence also highlights the psychological and cognitive effects of air pollution, linking it to anxiety, depression, reduced cognitive performance, and even increased criminal tendencies.

Among air pollutants, fine particulate matter (PM_{2.5}) is especially concerning due to its ability to penetrate deep into the respiratory system and bloodstream, causing widespread systemic harm. PM_{2.5} particles, with diameters of 2.5 microns or less, are associated with increased risks of heart attacks, strokes, and chronic lung diseases. In Iran, approximately 75,000 deaths annually are attributed to PM_{2.5} exposure. The average population-weighted PM_{2.5} concentration in the country stands at 48 μ g/m³— substantially higher than the World Health Organization's recommended maximum of 10 μ g/m³. Such alarming figures underscore the critical need for effective air quality management strategies, including accurate and consistent monitoring of PM_{2.5} concentrations.

Conventional ground-based air quality monitoring stations are valuable for tracking PM_{2.5} levels but are limited by their sparse spatial coverage, especially in smaller cities and rural regions. To complement ground-based monitoring, remote sensing technologies have gained prominence as a means of providing broader spatial coverage. Aerosol Optical Depth (AOD), derived from satellite observations, is a key parameter for assessing atmospheric aerosols and estimating PM_{2.5} concentrations. Sensors such as the Moderate Resolution Imaging Spectroradiometer (MODIS) have been instrumental in providing AOD data through retrieval algorithms like Dark Target (DT) and Deep Blue (DB). However, traditional approaches for converting AOD data into PM_{2.5} concentrations often fall short in accuracy and adaptability, necessitating the exploration of advanced methodologies like machine learning.

The Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) method was employed in the present paper to evaluate relevant studies and summarize the findings of previous research. The main advantage of this method compared to others lies in its high accuracy in extracting information, reducing bias, and providing a comprehensive and well-documented perspective on previous research findings. This approach, particularly in studies based on quantitative data, yields stronger and more reliable results. The focus of the analysis was centered on three main axes:

- 1. Identifying factors that significantly influence the establishment of a statistically meaningful correlation between AOD data obtained from satellite imagery and PM_{2.5} data derived from ground-based monitoring;
- 2. Assessing the success rate of previous research in establishing such correlations using statistical indicators; and
- 3. Examining the machine learning algorithms employed in these studies.

Material and Methods

This study systematically reviews machine learning algorithms used for estimating $PM_{2.5}$ concentrations based on AOD data, focusing on their performance, scalability, and adaptability across diverse environmental settings. The primary objectives are to identify the strengths and limitations of existing methodologies, highlight gaps in current research, and propose avenues for improvement.

To ensure a comprehensive analysis, the study employed a systematic review and metaanalytical approach based on the PRISMA guidelines. Reputable scientific databases, including PubMed, Google Scholar, and Science Direct, were queried using keywords (Fig. 1) such as "PM_{2.5} estimation," "Aerosol Optical Depth," and "machine learning." An initial pool of 977 documents was narrowed down to 127 highly relevant articles through a rigorous screening process (Fig. 2). Key extraction parameters included the correlation between AOD and PM_{2.5}, machine learning models employed, and performance metrics such as R² values, root mean square error (RMSE), and mean absolute error (MAE).

Results and Discussion

Correlation between AOD and PM_{2.5}

Numerous studies demonstrate a strong correlation between AOD values and groundlevel PM_{2.5} concentrations, although the strength of this relationship varies based on geographical, meteorological, and land-use factors (Fig. 3 and Table 1). Meteorological conditions such as temperature, relative humidity, and wind speed significantly influence the correlation by affecting aerosol properties and atmospheric dispersion. Additionally, land-use characteristics—such as urban density, vegetation cover, and proximity to industrial zones—modulate local PM_{2.5} levels.

Incorporating these auxiliary variables (see Fig. 4) into predictive models has proven effective in enhancing the accuracy of PM_{2.5} estimations. For example, regression models integrating meteorological and traffic data achieved significantly improved performance compared to models relying solely on AOD data. However, the inclusion of too many auxiliary variables can lead to overfitting, reducing the model's generalizability. Balancing model complexity with predictive accuracy remains a key challenge in this domain.

Machine Learning Algorithms for PM2.5 Estimation

Machine learning (ML) methods have revolutionized the estimation of PM_{2.5} concentrations from AOD data by effectively capturing the complex, non-linear relationships between variables. Among these, ensemble learning models such as Random Forest (RF) and XGBoost have consistently outperformed traditional linear regression models due to their ability to handle high-dimensional data and mitigate biases. Deep learning techniques, including Convolutional Neural Networks (CNNs) and Long Short-Term Memory (LSTM) networks, have also shown promise, particularly in time-series predictions of PM_{2.5} levels. Studies comparing ML algorithms highlight the superior performance of ensemble models, especially when combined with feature selection techniques to reduce input data redundancy. For instance, hybrid approaches that integrate RF and XGBoost have achieved R² values exceeding 0.9 in several case studies, indicating exceptional predictive power. Furthermore, the use of advanced optimization techniques, such as Bayesian

optimization, has enhanced the performance of these models by fine-tuning hyperparameters.

Limitations and Challenges

Despite the advancements in ML-based PM_{2.5} estimation, several challenges persist. The accuracy of these models is highly dependent on the quality of input data, which can be compromised by factors such as cloud cover, sensor limitations, and temporal mismatches between satellite observations and ground measurements. Additionally, the variability in meteorological conditions introduces uncertainties that are difficult to account for, particularly in regions with complex topography. Another limitation is the reliance on high-resolution satellite imagery, which is often expensive and not readily available for all regions. Addressing these challenges requires integrating data from multiple sources, including ground-based sensors, satellite datasets, and meteorological models. The development of robust data fusion techniques is essential for improving the scalability and reliability of PM_{2.5} estimation models.

Potential Applications and Future Directions

Future research should focus on developing hybrid algorithms that combine the strengths of multiple ML techniques, such as deep learning and ensemble learning. These algorithms should be capable of handling diverse datasets, enhancing temporal and spatial resolution, and addressing data uncertainty. Additionally, integrating long-term climate change scenarios into these models could provide more comprehensive insights into the dynamics of air pollution.

Conclusion

This study underscores the utility of AOD as a proxy for estimating PM_{2.5} concentrations and highlights the transformative potential of machine learning in enhancing the accuracy and scalability of air quality monitoring (please refer to Figs. 5 and 6). Ensemble learning models, particularly hybrid approaches, offer significant advantages in capturing the complex interactions between AOD and PM_{2.5}. However, addressing challenges related to data quality, meteorological variability, and scalability is crucial for realizing the full potential of these methods.



یادگیری ماشین در بر آورد غلظت ذرات معلق ریز (PM_{2.5}) السول طاهریان اصفهانی^۱، مهدی قنبرزاده لک^{۱*}

اً گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه ارومیه، ارومیه، ایران

چکیدہ	اطلاعات مقاله
قرار گرفتن در معرض ذرات ریز (PM _{2.5}) آلاینده هوا، به ویژه در مناطقی که میانگین	
سالانه آن از دستورالعملهای سازمان بهداشت جهانی فراتر است، به طور قابل توجهی بر	تاريخچه مقاله
سلامت عمومی تأثیر میگذارد. در ایران، افزایش سطح مواجهه با PM _{2.5} ، به میزان قابل	تا, بخ د, یافت: ۱۴۰۳/۴/۲۳
توجهی بر مرگ و میر درمیان بزرگسالان نقش داشته است. محدودیتهای پوشش مکانی	
و شکاف مقطعی دادههای ایستگاههای پایش زمینی، چالشهایی را در مدیریت مؤثر	تاریخ بازنگری: ۱۴۰۳/۹/۱۱
کیفیت هوا ایجاد نموده است. محصولات فناوریهای سنجش از دور، مانند	
عمقنوری آئروسل (AOD) بر گرفته از حسگرهای MODIS، جایگزین امیدوار کنندهای	تاریخ پذیرش: ۱۴۰۳/۱۰/۵
در برآورد PM _{2.5} به شمار میروند. در مقاله حاضر، تحقیقات پیشین درزمینه استفاده از	کلمات کلیدی:
الگوریتمهای یادگیری ماشین در برآورد غلظت PM _{2.5} بر اساس دادههای AOD، مرور	
شدهاست. تجزیه و تحلیل ساختاری ۱۲۷ مطالعه انتخاب شده، همبستگیهای متفاوتی را	ذرات PM2.5 ، عمق نوری
بین AOD و PM _{2.5} نشان داد (R ² در محدوده ۴۸ تا ۹۹٪)، که می تواند با بهره گیری از	آئروسل(AOD) ، يادگيري
متغیرهای کمکی نظیر شرایط هواشناسی و عوامل محیطی، بهبود یابد. اگرچه ادغام این	ماشین، سنجنده MODIS ،
متغیرها، دقت برآورد را افزایش میدهد، ولی در عین حال، پیچیدگی و خطاهای بالقوه را	يادگيرى گروهى، مدلهاى
در مدلهای یادگیریماشین افزایش خواهد داد. مدلهای یادگیری ماشین ترکیبی	تركيبى، مرور سيستماتيك، تأثير
عملکرد بهتری را در مقایسه با الگوریتمهای فردی نشان میدهند، چراکه قابلیت انطباق،	بر سلامت عمومی
پردازش موازی و مدیریت دادههای ازدست رفته را دارند. علی رغم پیشرفتهای اخیر، هنوز	
چالشهایی به دلیل عدم قطعیت دادهها و دینامیک بودن پدیدههای هواشناسی، باقی	
ماندهاند. الگوریتمهای یادگیری ماشین، اگرچه ابزاری قوی در برآورد $\mathrm{PM}_{2.5}$ بر اساس	
شاخص AOD ارائه میدهد، لیکن تحقیقات آتی در راستای رفع محدودیتها و	
بهینهسازی عملکرد مدل متناسب با تغییرات محیطی، ضروری است.	

* نویسنده مسئول: مهدی قنبرزاده لک

E-mail: m.ghanbarzadehlak@urmia.ac.ir

چکیدہ تصویری



مقدمه

امروزه بحث آلودگی هوا به عنوان پیامدی از توسعه فرآیندهای صنعتی، تغییرات اقلیمی و افزایش استفاده ار سوختهای فسیلی، به یکی از معضلات جدی زیستمحیطی خصوصاً در شهرهای بزرگ تبدیل شده **Bai, Wang, Ma & Lu, 2018; Bono & Fenitra, 2023 Abbas, Ekowati, Suhariadi ; Bai, Wang, Ma & Lu, 2018; Bono & Fenitra, 2023 Abbas, Ekowati, Suhariadi ; et al., 2015; Jzah, Iyiola, Yarkwan & Richard, 2023; Jia, Li, Chen & Yang, 2023; et al., 2015; Jzah, Iyiola, Yarkwan & Richard, 2023; Jia, Li, Chen & Yang, 2023; et al., 2015; Jah, Iyiola, Yarkwan & Richard, 2023; Jia, Li, Chen & Yang, 2023; a** شتمین عامل خطر و در کشور ایران به عنوان هفتمین عامل خطر با بالاترین تعداد مرگ و میر سالانه، شناخته میشود (**Institute for Environmental Research, 2019**). طرح ریزی و اجرای اقدامات حفاظتی کیفیت هوای آزاد، با پیشگیری از به مخاطره افتادن سلامتی افراد در معرض (به عنوان نیروی محرکه توسعه صنعتی) و در نتیجه کاهش غیبت افراد در محیط کاری و جلوگیری از کاهش بهرهوری فردی کارکنان، منجر به رشد و شکوفایی اقتصادی جوامع خواهد شد. از دیدگاه روانشناختی، آلودگی هوا یکی از روانی همچون اسکیزوفرنی و اوتیسم میباشد. در عین حال، به لحاظ شناختی، آلودگی هوا میتواند عملکرد روانی همچون اسکیزوفرنی و اوتیسم میباشد. در عین حال، به لحاظ شناختی، آلودگی هوا میتواند عملکرد اخلاقی گردد(**Lu, 2020)**). به بیان دیگر، آلودگی هوا نه تنها سلامت افراد، بلکه سلامت جامعه را نیز به مخاطره می_اادازد. دستهبندی آلایندههای هوا (قابل شناسایی در هوای آزاد یا در گاز خروجی از منابع ساکن و متحرک) براساس دیدگاههای مختلفی همچون ترکیب شیمیایی گونهها، ویژگیهای واکنش پذیری، خصوصیات پراکنش در هوا، پایداری در محیط، توانایی انتقال در مسافتهای کوتاه یا طولانی و اثرات تدریجی بر سلامتی انسان و/یا حیوانات، انجام می شود. با این وجود و با در نظر گرفتن برخی خصوصیات مشابه، آلایندههای هوا را می توان در چهار طبقه کلی (۱) آلاینده های گازی (مانند دی اکسید گوگرد، منوکسید کربن، اکسیدهای نیتروژن، اُزُن و ترکیبات آلی فرار)؛ (۲) آلایندههای آلی دیرپا (همچون دایاکسینها و فیورنها) ۲؛ (۳) فلزات سنگین (نظیر سرب و جیوه)؛ و (۴) ذرات جامد معلق (که در ادبیات فنی در دو دسته کلی PM_{2.5} و PM^{10°} و PM طبقهبندی می شوند)؛ دستهبندی نمود(<u>Kampa & Castanas, 2008</u>). در این بین، آلایندههای معیار کیفیت هوای آزاد، ترکیباتی را شامل میشوند که اولاً حضور آنها در هوای آزاد شهری متداول بوده و ثانیاً سطوح قابل قبولی از قرار گرفتن در معرض آنها توسط استانداردهای کیفیت هوای آزاد، تعیین شده است. براساس استانداردهای سازمان حفاظت از محیطزیست ایالات متحده امریکا، این آلایندهها شامل اُزُن، منوکسید کربن، سرب، دیاکسید گوگرد، دیاکسید نیتروژن و ذرات معلق، میباشند(<u>U.S. EPA, 2024</u>). ذرات معلق با قطر آئرودینامیکی مساوی یا کمتر از PM_{2.5}) ۲/۵ μm) ، از آلایندههای مهم کیفیت هوای آزاد محسوب می گردند و قادرند از طریق دستگاه تنفسی انسان، وارد جریان خون شوند. اثرات استنشاق PM_{2.5} از سادهترین حالات آلرژی تا بیماریهای قلبی-عروقی و همچنین افزایش خطر مبتلا شدن به بیماریهای ; Chen et al., 2021; Bell, Dominici, Ebisu, Zeger & Samet, 2007) سرطانی، متغیر است Chudnovsky et al., 2013; Feng, Li, Wang & Du, 2020; Li, Yu, Huang, Sun & Jia, 2023; Moryani, Kong, Du & Bao, 2020; Nabavi, Haimberger & Abbasi, 2019; Osimobi, Yorkor & Nwankwo, 2019; Perrone et al., 2013; Pope III & Dockery, 2006; Saeed, Hussain, Awan & Idris, 2017; Xiao et al., 2017; Xue et al., 2022; Yan, Zang, Luo, Jiang & Li, 2020; Kelly & Fussell, 2012; Institute for Environmental Research, 2019; He & Huang, 2018).

مطالعات اخیر نشان دادند که در ایران، سالانه حدود ۲۵ هزار مرگ و میر (بین ۶۲ تا ۸۶ هزار) به دلیل قرار گرفتن افراد در معرض ذرات معلق محیطی PM_{2.5} است (یعنی چیزی حدود ۲۴ درصد از کل مرگ و میر سالانه افراد بالای ۲۵ سال در ایران). بر اساس میانگین وزنی-جمعیتی سالانه، در ایران غلظت آلاینده PM_{2.5} در هوای آزاد (که افراد در معرض آن میباشند)، حدود ³⁻ mg ۲۸ برآورد میشود که نسبت به میانگین جهانی آن (یعنی ³⁻ mg m⁻¹) کمی پایین است؛ اما با این وجود، همچنان قریب به ۴/۸ برابر بیشتر از از سطح توصیه شده توسط سازمان بهداشت جهانی (WHO)^۵ یعنی ³⁻ mg m⁻¹ و تقریباً چهار برابر بیشتر از استاندارد ملی است (Institute for Environmental Research, 2019). بنابراین ضروری است که

¹ Persistent organic pollutants

² Dioxins and Furans

³ Particulate Matter less than 2.5 micrometers in aerodynamic diameter (PM_{2.5})

⁴ Particulate Matter less than 10 micrometers in aerodynamic diameter (PM₁₀)

⁵ World Health Organization (WHO)

میزان این ذرات به طور مستمر اندازه *گ*یری و در خصوص کنترل غلظت آن، مراقبت شود(<u>Xu, Chen,</u>). Yang, Tang & Dong, 2021).

اندازه گیری ساعتی و روزانه غلظت ذرات معلق PM_{2.5} در هوای آزاد شهری توسط ایستگاههای زمینی پایش کیفیت هوا و پیش بینی شرایط آتی آن، از اهمیت قابل توجهی برخوردار است. با این حال، پوشش مکانی ایستگاههای پایش زمینی محدود بوده و در مواقعی از سال، ممکن است بدلیل نیاز به واسنجی تجهیزات یا مسائل نگهداری، از مدار خارج شوند. علاوه بر آن، تعداد اندک ایستگاههای زمینی پایش کیفیت هوای نصب شده در شهرهای کوچک، امکان پاسخگویی مناسب قبل از وقوع رخداد آلودگی هوا را تا حد زیادی محدود نموده است. در سالیان اخیر تلاشهایی در راستای بهره گیری از تکنولوژیهای سنجش از دور به عنوان ابزاری جایگزین، صورت گرفته و بدین ترتیب میتوان پوشش گستردهتر فضایی و زمانی از غلظت آلایندههای هوا جهت اقدامات پیشگیرانه در دسترس داشت(<u>Rao, 2013</u>).

یکی از پارامترهای اصلی برآورد غلظت آلایندههای PM در هوای آزاد براساس تکنولوژیهای سنجش از دور، عمق نوری آئروسل (AOD)^۱ است که از طریق تصاویر ماهوارهای بدست میآید و در مطالعات پیشین به طور گستردهای از آن بهرهبرداری شده است(AOD)^۹ است که از طریق تصاویر ماهوارهای بدست میآید و در مطالعات پیشین به مطور گستردهای از آن بهرهبرداری شده است(AOD) معیار مناسبی در برآورد میزان ذرات معلق موجود در جو است که بر اساس نسبت امواج شاخص AOD معیار مناسبی در برآورد میزان ذرات معلق موجود در جو است که بر اساس نسبت امواج میگردد. AOD معیار مناسبی در برآورد میزان ذرات معلق موجود در جو است که بر اساس نسبت امواج میگردد. AOD معیار مناسبی در برآورد میزان ذرات معلق موجود در جو است که بر اساس نسبت امواج میگردد. AOD بطور معمول در یک ستون عمودی از هوا تعیین شده و دادههای تولیدی توسط سنجنده **Taheri Shahraiyni پر شاه است(** گرفته است(**Sodod)** به طور گستردهای، بدین منظور مورد استفاده قرار گرفته است(**Sodod)** و الگوریتم آبی AOD⁷ و الگوریتم آبی معلور معرول در بازیابی ویژگیهای آئروسل از محصول تصحیح اتمسفری سنجنده عمیق (DT)³ ، دو الگوریتم متداول در بازیابی ویژگیهای آئروسل از محصول تصحیح اتمسفری سنجنده میقور (DT)³ ، دو الگوریتم متداول در بازیابی ویژگیهای آئروسل از محصول تصحیح اتمسفری سنجنده می (DT)³ ، دو الگوریتم متداول در بازیابی ویژگیهای آئروسل از محصول تصحیح اتمسفری سنجنده می (DT)³ ، دو الگوریتم متداول در بازیابی ویژگیهای آئروسل از محصول تصحیح اتمسفری سنجنده (OT)

الگوریتم DT توسط کافمن و همکاران(Kaufman et al., 1997) معرفی شد. DT از این مفهوم فیزیکی الهام گرفته است که ذرات معلق در هوا از سطوح تاریکتر زمین مانند جنگلها و سطح اقیانوسها، روشنتر هستند. به دلیل محدودیت این الگوریتم در شناسایی ذرات معلق خصوصاً در مناطق شهری و بیابانی که دارای سطوح روشن میباشند، بازیابی دقیق ذرات معلق، یک چالش بزرگ بوده است. همین موضوع سبب شد تا هسو و همکاران (Hsu, Tsay, King & Herman, 2004)، الگوریتم دیگری به نام DB را بر روی تصاویر ماهوارهای MODIS با تفکیکپذیری ۱۰ کیلومتری پیادهسازی کنند. در الگوریتم اخیر از باند طول

¹ Aerosol Optical Depth (AOD)

² Moderate Resolution Imaging Spectroradiometer (MODIS)

³ Dark Target (DT)

⁴ Deep Blue (DB)

موجی ۴۱۲ نانومتر استفاده شد که آبی عمیق نام دارد و در آن آئروسلها از هر نوع سطح زمینی، روشنتر هستند (Nabavi et al., 2019).

هدف اصلی در مقاله مروری حاضر، بررسی الگوریتمهای مختلف یادگیری ماشین بکار رفته در برآورد غلظت ذرات معلق ریز با استفاده از دادههای AOD و میزان تطابق آنها با نتایج پایشهای زمینی است. با توجه به نوپا بودن کاربرد الگوریتمهای یادگیری ماشین در این شاخه از علوم و با عنایت به این موضوع که برخی روشهای سنتی نیز در برآورد غلظت PM_{2.5} از دادههای AOD تاکنون مورد استفاده قرار گرفته اند، دامنه مطالعه مروری حاضر قدری گستردهتر انتخاب شد و مقالات و مستنداتی که به بررسی همبستگی ما بین غلظت غلظت PM_{2.5} زمینی و دادههای AOD با یا بدون بهره گیری از یادگیری ماشین پرداخته بودند، مورد توجه قرار گرفتند.

لازم بذکر است در مطالعات مروری، روش های مختلفی جهت گردآوری و تحلیل اطلاعات وجود دارد. مرور سنتی^۱ به مرور کلی مطالعات می پردازد و معمولاً فاقد ساختار دقیق و روش شناسی مشخص است؛ این روش بیشتر برای مطالعات مقدماتی مناسب بوده و ممکن است شامل سوگیری شود. مرور سیستماتیک^۲ با استفاده از رویکردی ساختاریافته و منظم، به شناسایی و ارزیابی مطالعات مرتبط با یک سؤال پژوهشی خاص می پردازد و بای ارائه نتایج دقیقتر و جامع، طراحی شده است. مرور دامنهای^۳ نیز برای شناسای شناسای مختار کار مرور معمولاً فاقد ساختار مطالعات مرور سیستماتیک^۲ با استفاده از رویکردی ساختاریافته و منظم، به شناسایی و ارزیابی مطالعات مرتبط با یک سؤال پژوهشی خاص می پردازد و برای ارائه نتایج دقیقتر و جامع، طراحی شده است. مرور دامنه ای^۳ نیز برای شناسایی شکافهای تحقیقاتی و ارزیابی گستردگی موضوعی پژوهش ها به کار می رود، اما برخلاف مرور سیستماتیک، بر کیفیت مطالعات تأکید کمتری دارد. علاوه بر این، متا-آنالیز⁴ یا فراکاوی یک روش کمی است که دادههای آماری

بدین منظور و در مطالعه مروری حاضر، از روش مرور ساختاریافته و فراکاوی (PRISMA)^۵ بهره گیری گردید. این رویکرد به دلیل ساختار دقیق و منظم خود، امکان شناسایی و ارزیابی مطالعات مرتبط را فراهم می کند و با بهره گیری از تکنیکهای آماری، نتایج مطالعات پیشین را تحلیل و خلاصهسازی می نماید. مزیت اصلی این روش نسبت به روشهای دیگر، دقت بالا در استخراج اطلاعات، کاهش سوگیری و ارائه یک دیدگاه جامع و مستند از یافتههای پژوهشهای پیشین است. این ترکیب، به ویژه در پژوهشهای مبتنی بر دادههای کمی، نتایجی قوی تر و قابل اعتمادتر فراهم می آورد. کانون توجه در استخراج نتایج از مقالات و مستندات بر سه محور (۱) تعیین عوامل مؤثر بر ایجاد همبستگی معنیدار از نقطه نظر آماری بین دادههای AOD، که از طریق تصاویر ماهواره ای بدست می آید و دادههای EM2.5 حاصل از پایش زمینی؛ (۲) میزان موفقیت تحقیقات پیشین در ایجاد همبستگی فوق براساس شاخصهای آماری؛ و نهایتاً (۳) الگوریتمهای یادگیری

¹ Traditional Review

² Systematic Review

³ Scoping Review

⁴ Meta-Analysis

⁵ Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA)

روش تحقيق

مقالات مبتنی بر روش مرور ساختاریافته و فراکاوی، از این جهت که متخصصان با بهرهگیری از آنها قادر خواهند بود تا در زمینه تخصصی خود بهروز باشند، دارای اهمیت قابل توجهی است. اساس کار در این روش، بررسی سؤال یا مسألهای مشخص و معین بوده و بدین منظور از الگوریتمهای ساختار یافته و صریح در شناسایی، انتخاب و ارزیابی منصفانه مطالعات مرتبط استفاده می نماید. در نهایت، با گردآوری و تجزیه و تحلیل نتایج مطالعات پیشین طی جداول و اشکال (فراکاوی)، خلاصهای از پیشرفتهای پیشین حاصل شده در شاخه مورد تحقیق، به خوانندگان ارائه خواهد شد. به بیان دیگر، فراکاوی با استفاده تکنیکهای آماری به تجزیه و تحلیل و خلاصه سازی نتایج مطالعات پیشین می پردازد (<u>Moher, Liberati, Tetzlaff, Altman</u> PRISMA Group, 2009 ک. در این مطالعه، از رویکرد PRISMA برای شناسایی، غربالگری و انتخاب مقالات مرتبط استفاده شده است. برای جستجوی مطالعات پیشین، مستندات منتشر شده در پایگاههای اطلاعاتی Google Scholar ، PubMed و Science Direct مورد بررسی قرار گرفت. جستجوی مدارک با ترکیب دو گروه از کلمات کلیدی مرتبط با موضوع، پی گیری گردید. بگونهای که گروه اول شامل کلید واژههای توصیف کننده برآورد آلودگی هوا بوده و گروه دوم، کلید واژههای مربوط به یادگیری ماشین و سنجش از دور را شامل می شدند. جستجوی مدارک با استفاده از کلید واژههای انگلیسی و با ترکیب احتمالی کلمات مهم، اصلی و حساس، انجام شد. بدین منظور، کلید واژههای منتخب به همراه عملگرهای AND و OR، در بخشهای عنوان، کلمات کلیدی و چکیده مدارک، جستجو شدند. واژگان کلیدی که در جستجوی مقالات مورد استفاده قرار گرفتند، در شکل (۱) آورده شده است.

Machine learning algorithms Machine learning approach AOD AOD data Aerosol optical depth Remote sensing Satellite remote sensing data

(گروه ۲) (Group 2)

Forecasting air quality Predict atmospheric pollution Predicting air pollutant Forecast air pollution PM_{2.5} concentrations prediction PM_{2.5} concentrations estimation

> (گروه ۱) (Group 1)

شکل 1- واژگان کلیدی مورد استفاده در جستجوی مقالات Fig.1. Keywords Used in Article Searches

در مرحله اول عملیات جستجو، مقالاتی انتخاب شدند که در آنها وجود همبستگی و شدت آن بین دادههای AOD ماهوارهای و مقادیر پایش شده زمینی PM_{2.5}، با/بدون استفاده از الگوریتمهای یادگیری ماشین، مورد مطالعه قرار گرفته بود. در بررسی اولیه سه پایگاه داده فوق الذکر، در کل ۹۷۷ مقاله حائز شرایط این تحقیق تا تاریخ ۱۹ آوریل ۲۰۲۴ (۳۱ فروردین ۱۴۰۳)، به دست آمد. سپس عنوان و چکیده تمامی

مقالات، مستندات و گزارشهای منتخب در مرحله اول، استخراج و با بررسی محتوای آنها، موارد تکراری حذف شدند. بر اساس بررسی عناوین و چکیدهها، تعداد زیادی از منابع حذف گردیدند. محتوای مقالات باقیمانده به طور دقیق مورد مطالعه قرار گرفت و منابع کاملاً مرتبط، انتخاب شدند. در نهایت بر اساس عنوان، نویسنده اصلی، سال انتشار، نوع الگوریتم انتخابی و مشخصات دیگر، مستندات به صورت خلاصه در جدولی طبقهبندی گردیدند. بدین ترتیب فرآیند جمعآوری و بررسی منابع پژوهشی به طور سیستماتیک انجام پذیرفت تا اطلاعات مفید برای پاسخ به سؤال پژوهش به دست آید. فرآیند جستجو، ورود و خروج مقالات، در شکل (۲) آورده شده است.



Fig.2. The Process of Searching, Entering and Exiting Articles

نتايج و بحث

توسعه مدلهای پیشبینی/ برآورد غلظت آلایندههای هوا در یک مکان خاص، ابزاری قدرتمند در طرحریزی اقدامات پیشگیرانه همچون کنترل منابع پراکنش و هشداردهی به شهروندان در شرایط اضطراری را در اختیار مدیران شهری قرار میدهد(<u>–Cortina–Januchs, Quintanilla–Dominguez, Vega</u>). به طور کلی، راهکارهای پیشبینی/ برآورد غلظت یک آلاینده در یک محیط براساس دادههای پایش پیشین همان آلاینده یا سایر آلایندههای معیار و اطلاعات محیطی، در دو دسته راهکارهای قطعی و آماری، تقسیم بندی می شوند (<u>Bai et al., 2018</u>).

مدلهای کیفیت هوای چند مقیاسی جامعه (CMAQ)^۱ و پیش بینی عددی وضع هوای جفت شده با مباحث شیمی (WRF-Chem)^۲، از جمله پُرکاربردترین مدلهای قطعی پیش بینی غلظت آلایندههای هوا به شمار میروند (Li et al., 2018bKong, Xin, Zhang & Wang, 2016) : این مدلها با در نظر گرفتن عملکردهای فیزیکی شامل گسیل، پراکنش، انتقال و پخش آلاینده؛ درهم کنشهای شیمیایی به وقوع پیوسته در جو را نیز شبیه سازی می نمایند (<u>Seng et al., 2010</u>) : این مدلهای واکنش این وجود، از آنجا که بیشتر این مدلها به دانش پیچیده ای درباره حالت پخش آلاینده و مسیرهای واکنش شیمیایی نیاز دارند، برآورد غلظت آلاینده یا PM_{2.5}

در راستای رفع محدودیتهای راهکارهای قطعی، از مدلهای آماری در پیشبینی/ برآورد آلودگی هوا بهرهگیری شده است. این مدلها خود در دو طبقه مدلهای فضایی (مکانی) و مدلهای دنباله زمانی، دستهبندی میشوند. در مدلهای فضایی (مکانی) راهکارهایی که بر مبنای درونیابی عمل میکنند، تحت عنوان راهکارهای زمین آماری در مدلسازی آلودگی هوا شناخته شده و نمونههایی از آنها شامل روشهای رگرسیون خطی ساده (MLR <u>Kilaru, Jacob & Koutrakis, 2005</u>) روشامل روشهای درگرسیون خطی چندگانه (MLR)^{*} (MLR)، رگرسیون وزندار جغرافیایی (GWR)^{*} (GWR)^{*} (GWR)^{*} (GWR)^{*} (GWR)^{*} (GWR)^{*} (GWR)^{*} (GWR)^{*} (GWR)^{*} (IDW)^{*} (GWR) وارونه (MDR)^{*} (Lue et al., 2015)^{*} (LUR)، روش کریجینگ (Hu et al., 2015)^{*} روش وزندا روش وان وارونه (MAR)^{*} (IDW)^{*} (MLR)^{*} (Masroor et al., 2020)^{*} (IDW)^{*} (Surger)^{*} (IDW)^{*} (MLR)^{*} (IDW)^{*} (Surger)^{*} (IDW)^{*} (Surger)^{*} (IDW)^{*} (MLR)^{*} (IDW)^{*} (Surger)^{*} (IDW)^{*} (IDW)^{*} (Surger)^{*} (IDW)^{*} (Surger)^{*}

¹ the Community Multiscale Air Quality (CMAQ)

² Weather Research and Forecasting model coupled to Chemistry (WRF-Chem)

³ Multi Linear Regression (MLR)

⁴ Geographically Weighted Regression (GWR)

⁵ Inverse Distance Weighted (IDW)

⁶ Land Use Regression (LUR)

⁷ Mixed Effect Model (MEM)

Koutrakis, 2012) میباشند که در تحقیقات گذشته در برآورد مکانی آلودگی در یک زمان مشخص در سطح شهر، به کار رفتهاند.

بخش دوم یعنی راهکارهای دنباله زمانی محور با هدف پیشبینی/ برآورد آلودگی هوا، شامل روشهای سنتی و روشهای نوین میباشند. متداول ترین روش سنتی، مدل رگرسیونی میانگین متحرک یکپارچه خود همبسته (ARIMA)^۲ است که در برآورد غلظت PM_{2.5} PM_{2.5} مورد استفاده قرار گرفته است (ARIMA)^۲ است که در برآورد غلظت PM_{2.5} مورد استفاده قرار گرفته است (ARIMA)^۲ است که در برآورد غلظت PM_{2.5} مورد استفاده قرار گرفته است (ARIMA)^۲ است که در برآورد غلظت PM_{2.5} مورد استفاده قرار گرفته است (ARIMA)^۲ است که در برآورد غلظت PM_{2.5} مورد استفاده قرار گرفته است (ARIMA)^۲ است که در برآورد غلظت PM_{2.5} مورد استفاده قرار گرفته است (ARIMA)^۲ است که در برآورد غلظت روشهای سنتی میتوان به عدم عملکرد مؤثر این مدلها در تجزیه و تحلیل و ادغام دادههای چند منبعی مانند دادههای هواشناسی، کاربری زمین و ترافیک، اشاره داشت که منجر به دقت اندک آنها در برآوردها شده است. علاوه بر آن، روشهای سنتی مدلسازی مبتنی بر دنباله زمانی نیازمند پیشفرضهایی همچون انتخاب یک توزیع خاص آماری و پذیرش خطی بودن مدل هستند که Song, Qin, این پیشفرضها، نتایج مدل با خطای قابل توجهی همراه خواهد بود (خواهند گرفت. در صورت عدم برقراری این پیشفرضها، نتایج مدل با خطای قابل توجهی همراه خواه دوار خواهند گرفت. در محرک (۳) فراوانی مقالات وارد شده در مطالعه مروری حاضر براساس سال انتشار آنها آورده شده است. همانطور که از این شکل برمیآید، روند انتشار تحقیقات مرتبط با برآورد غلظتهای زمینی زمینی 2.5M



Fig.3. Frequency of Articles Included in the Current Review by Publication Year

¹ AutoRegressive Integrated Moving Average (ARIMA)

در تعدادی از مطالعات بررسی شده در تحقیق حاضر، مقادیر بالای همبستگی بین غلظت PM_{2.5} و PM_{2.5} دادههای AOD به عنوان برآوردگر دادههای AOD مشاهده شده است. این امر قابلیت بالای استفاده از دادههای AOD به عنوان برآوردگر مناسبی در تخمین غلظت PM_{2.5} PM_{2.5} و PM_{2.5} با این وجود، برخی مطالعات نیز وجود مناسبی معنی دار بین PM_{2.5} PM_{2.5} و PM_{2.5} با این وجود، برخی مطالعات نیز وجود همبستگی معنی دار بین PM_{2.5} و PM_{2.5} را دشان می دهد (Xue, Zhang, Zhong, Ji & Huang, 2020 . همبستگی معنی دار بین PM_{2.5} و PM_{2.5} را د کرده یا شدت پایینی از همبستگی میان آنها را نشان دادهاند. این مستندات، حصول همبستگی قوی تر بین PM_{2.5} و AOD را منوط به استفاده از متغیرهای دیگری همچون پارامترهای هواشناسی، دانستهاند. به بیان دیگر، از نظر تعدادی از محققان، برقراری ارتباط مطمئن میان PM_{2.5} PM_{2.5} و PM_{2.5} را دادههای کمکی بیشتری است (PM_{2.5} ار PM_{2.5}). در شکل (۴) میان PM_{2.5} و PM_{2.5} مستلزم بهره گیری از دادههای کمکی بیشتری است (PM_{2.5} از PM_{2.5}). در شکل (۴) میان ADD و PM_{2.5} و PM_{2.5} بین دادهای کمکی بیشتری است (PM_{2.5}). در شکل (۴) میان ADD آورده شده است. در تقویت همبستگی بین دادههای غلظت PM_{2.5} پایش شده زمینی و



AOD شکل ۴– پارامترهای کمکی در تقویت همبستگی بین دادههای غلظت PM_{2.5} و Fig.4. Auxiliary Parameters Enhancing the Correlation Between PM_{2.5} Concentration and

AOD Data

هو و همکاران (<u>Hu et al., 2013</u>)، بر این باور بودند که استفاده صرف از محصولات ماهوارهای ممکن است منجر به خطاهای برآورد در نتایج شود. ایشان در جهت رفع این خطاها پیشنهاد نمودند که علاوه بر AOD، از پارامترهای محلی نظیر متغیرهای پوشش زمین و پارامترهای هواشناسی، به عنوان ورودیهای کمکی در مدل رگرسیون استفاده شود. آنها به این نتیجه رسیدند که ورود این پارامترهای کمکی میتواند عملکرد مدل رگرسیون خطی در برآورد غلظت PM_{2.5} را بهبود بخشد. یانگ و همکاران (<u>Yang et al.</u> 2019)، مشاهده کردند که در مناطق خشک مانند شمال چین، همبستگی بین PM_{2.5} و AOD بیشتر است؛ در حالی که در مناطق ساحلی، این همبستگی ضعیفتر بدست آمد. آنها عواملی همچون تویوگرافی سطحی و پارامترهای هواشناسی را بر تغییرات زمانی و مکانی رابطه بین PM_{2.5} و AOD مؤثر دانستند. در مطالعهای دیگر، وایی و همکاران(<u>Yi et al., 2019</u>)، به برآورد غلظت PM_{2.5} در استانهای شمالی چین پرداختند. آنها دریافتند که شرایط آب و هوایی گوناگون در منطقه مورد مطالعه، تغییرات مختلفی در شدت همبستگی غلظت PM_{2.5} و AOD ایجاد نموده است و نتایج با مدلهای بدست آمده از مناطق دیگر، تفاوت دارد. هوانگ و همکاران (Huang et al., 2019)، با استفاده از پارامترهای هواشناسی و ارتفاع از سطح دریاهای آزاد، ابتدا مقادیر گمشده AOD با تفکیکپذیری' یک کیلومتر در شهر نیویورک را برآورد نموده و سپس با بهرهگیری از دادههای کمکی پوشش سطح، غلظت PM_{2.5} را تخمین زدند. میری و همکاران (<u>Miri, Ghassoun,</u>) Dovlatabadi, Ebrahimnejad & Löwner, 2019)، در برآورد غلظت PM_{2.5} در شهر سبزوار، از پارامترهای کمکی پوشش زمین، فاصله از خیابان و مناطق صنعتی و همچنین ارتفاع، استفاده کردند. برخلاف مطالعات قبلی، در این تحقیق از مقادیر AOD در برآورد غلظت PM_{2.5} استفاده نشد. چن و همکاران (Chen, Wu, Tu & Cao, 2020)، از یک مدل رگرسیون خطی شامل پارامترهای هواشناسی، دادههای مربوط به ترافیک، انواع پوشش زمین، جمعیت و دادههای ارتفاعی در بازه زمانی زمستان ۲۰۱۲ تا ۲۰۱۵ در کشور چین، به منظور برآورد غلظت PM_{2.5} استفاده کردند. فنگ و همکاران (Feng et al., 2020)، در دو شهر پکن و چانگدو جهت برآورد غلظت PM_{2.5} از مقادیر AOD ماهوارهای، از پارامترهای کمکی هواشناسی و متغیرهای پوشش سطح استفاده نمودند. آنها در این مطالعه موفق به دستیابی به ضریب تعیین ${
m R}^2$ برابر با ۰/۷۱ شدند. ژانگ و همکاران (<u>Zhang et al., 2021</u>)، عدم اطمینان موجود در برآورد PM_{2.5} از نتایج مبتنی بر AOD را یک چالش جدی دانسته و با استفاده از پارامترهای هواشناسی و متغیرهای پوشش زمین، سعی نمودند این مشکل را حل کنند. در پژوهشی دیگر، جیانگ و همکاران (<mark>Jiang et al., 2021</mark>)، بیان داشتند وقتی غلظت آئروسل در هوای آزاد بالا است، برآورد PM_{2.5} صرفاً براساس AOD دچار خطا میشود. آنها برای حل این مشکل از پارامترهای هواشناسی علاوه بر دادههای AOD استفاده نمودند. استفاده از دادههای کمکی در تحقیقات دیگر محققان نیز مورد اشاره قرار گرفته است (<u>Guo, Tang, Gong &</u>) Liu, Franklin, Kahn & bLi et al., 2018a Gulliver et al., 2018 Zhang, 2017 ; Liu, Paciorek & Koutrakis, 2009 ; Meng et al., 2016 ; Moore, Koutrakis, 2007

¹ Resolution

Jerrett, Mack & Künzli, 2007 ; Qi, Li, Karimian & Liu, 2019 ; Ross, Jerrett, Ito, Tempalski & Thurston, 2007; Shi, Ho, Xu & Ng, 2018; Su et al., 2009 ; Wu et al., 2021 [Superior and the second seco

جدول ۱- پارامترهای کمکی مورد استفاده در بر آورد غلظت PM_{2.5} براساس دادههای AOD بهمراه

دقت نتايج

 Table 1- Auxiliary Parameters Used in Estimating PM2.5 Concentrations from AOD Data with Accuracy Results

				بارامترهای هواشناسی یارامترهای هواشناسی Meteorological parameters																	
مرجع Reference	% R ²	AOD	شاخص کیفیت هوا Air quality index	فاصله دید افقی Horizontal visible distance	أب قابل بارش Precipitable water	دید Visibility	سرعت و جهت باد Wind speed and direction	رطویت نسبی Relative humidity	بارش Precipitation	فشار Pressure	دما Temperature	PM25	PM ₁₀	نوع پوشش زمین Land cover type	نوع کاربری زمین Land use type	ترافیک شہری Urban traffic	فاصله از مراکز صنعتی Distance from industrial centers	شاخص گیاهی Plant index	ارتفاع از سطح دریاهای آزاد Height above sea level	تراکم جمعیت Population density	منطقه مورد مطالعه Study area
Ayus et al., 2023	99	1	1									1	1	.71-							جين (China)
Reddy et al., 2018	٩۶	1					1	1		1	4										جين (China)
Shogrkhodaei et al., 2021	٩۵	1					1	1	4		4							1		1	تهران (Tehran)
Ren et al., 2024	٩۵	1					1	1	1	1			1								چين (China)
Miri et al., 2019	٩٣											1		1		1	1		1	1	سبزوار (Sabzevar)
Yang et al., 2024	٩٣	1					1	1		1	⊀										چین (China)
Feng et al., 2020	41	1					1	1			1	1		1				1			چین (China)
Qi et al., 2019	۹۱	1	1				1	1			1	1	1								چين (China)
Mohammadi et al., 2024	٩٠	1					1	1		1	4	1									تهران (Tehran)
Chen et al., 2021	٨٩	1			1		1	1		1	4	1									چین (China)
Liu et al., 2019	٨۶	1					1	1		1	4	1									چين (China)
Huang et al., 2019	۸۵	1					1	1			1					1		1		1	نيويورک (New York)
Jiang et al., 2021	۸۵	1		1		1	1	1		1	. ✓	1		1	1	1		1	1		چين (China)
Obodoeze et al., 2021	۸۵	1					1	1			✓	1									چين (China)
Enebish et al., 2021	٨٢	1					1	1		1	1	1	1						1	1	مغولستان (Mongolia)
Li et al., 2018b	A1													1		1	1	1	4	1	پکن (Beijing)
Zhang et al., 2021	A1	1	1				1	1		1	4	1	4	1				1	4	1	چين (China)
Ghaemi et al., 2016	A1	1			1		1			1	4	1									تهران (Tehran)
Zamani Joharestani et al., 2019	A1	1		1		1	1	1	1	1	4	1									تهران (Tehran)
Karimian et al., 2019	٨.	1					1	1	1		✓										تهران (Tehran)
Aguilera et al., 2023	۷۸	1									1	1							1		أمريكا (USA)
Chen et al., 2024	٧٨	1					1	1			1	1						1	1		چين (China)
Yang et al., 2019	**	1					1	1								1					منطقه ساحلی چین (Coastal region of China)
Cortina-Januchs et al., 2015	**	1					4	1	4	1	1	4		1	1			1	4		ر (Mexico) مکز تک
Yi et al., 2019	٧۶	1					1	1		1	4										شمال حين (North China)
Li et al., 2018a	Y۵	1					1	1			4			1		1	4	1			شاندونگ (Shandong)
Chen et al 2020	YI						1	1			4			1		1	1		1	1	جنوب جين (South China)
Zhang et al., 2018	59	1		1			1	1			1	1	1	1		1		1	1		تگزانی (Texas)
Nabavi et al., 2019	۶٨	1		1		1	1	1			1	1				1			1		تهران (Tehran)
Yan et al., 2020	۶۳	1					1	1	1	1	1	1							1		جين (China)
Hu et al., 2013	۶١	1					1	1			1							1			آمریکا (USA)
Kong et al., 2016	۵۸	1						1													یک (Beijing)
Xu et al., 2018	۴A	1					4	1	1	1	4	1						1	4		کانادا (Canada)

نکته دیگری که در اینجا حائز اهمیت است، احتمال بروز خطای بیش برازش^۱ درصورت استفاده از تعداد زیادی از پارامترهای کمکی در یک مدل است. هرچه تعداد پارامترهای قابل تنظیم در یک مدل بیشتر باشد، مدل پیچیدهتر می شود و توانایی بیشتری برای یادگیری الگوهای بسیار خاص و جزئی در دادههای آموزشی پیدا می کند. این امر باعث می شود مدل به شدت به دادههای آموزشی وابسته شده و در مواجهه با دادههای جدید که ممکن است اندکی متفاوت باشند، عملکرد ضعیفی از خود نشان دهد. به عبارت دیگر، یک مدل با پارامترهای کمکی زیاد، می تواند به راحتی دادههای آموزشی را حفظ کند، اما این حفظ کردن به معنای یادگیری واقعی نیست. در واقع، مدل به جای یادگیری قوانین کلی حاکم بر دادهها، صرفاً جزئیات تصادفی و نویزهای موجود در دادههای آموزشی را یاد می گیرد. این پدیده شبیه به این است که یک دانش آموز به جای درک مفاهیم اصلی یک درس، فقط به حفظ کردن متن کتاب بسنده کند. در نتیجه، زمانی که با سؤالی روبرو پارامترهای کمکی بدون کنترل، می تواند به طور مستقیم به افزایش خطر بیش برازش موزایش تعداد می شود که کمی متفاوت از متن کتاب باشد، قادر به پاسخگویی نخواهد بود. بنابراین، افزایش تعداد و استفاده از تکنیکهای روش های مختولی می تفاد منظمسازی^۲، کاهش ابعاد دادها و انتخاب ویژگیهای مهم و استفاده از تکنیکهای توقف زودهنگام، به کار می روند (و**101**

همانطور که قبلاً گفته شد، در سالیان اخیر از روشهای نوین مبتنی بر دنباله زمانی در برآورد غلظت PM_{2.5} PM_{2.5} از دادههای AOD بهرهبرداری شده است. این روشها شامل شبکههای عصبی مصنوعی (ANN³, PM_{2.5} Lai, Li و دادههای AOD بهرهبرداری شده است. این روشها شامل شبکههای عصبی مصنوعی (ANN³, الگوریتمهای مختلف یادگیری ماشین همچون رگرسیون بردار پشتیبان (SVR³) و یادگیری عمیق (Peng, Vang, Xia & Gao, 2022 با یادگیری عمیی PM_{2.5} Pen, 2021 و PM_{2.5} Peng, Vang, Xia & Gao, 2022 با et al., 2023 و ورشهای یادگیری جمعی نظیر جنگل تصادفی (RF³) و تقویت گرادیان، میشوند. با توجه به وجود رابطه غیرخطی بین _{2.5} PM و متغیرهای پیشبینی کننده، روشهای مذکور به دلیل توانایی قابل توجه در انتخاب و مدیریت تعداد زیادی متغیرهای پیشبینی کننده، روشهای مذکور به دلیل توانایی قابل توجه در انتخاب و مدیریت تعداد زیادی متغیر مستقل و امکان تحلیل مسائل پیچیدهتر، بسیار مورد توجه محققان بوده اند. در شکل (۵) نمودار فراوانی استفاده از روشهای یادگیری ماشین در برآورد غلظت _{2.5} PM براساس دادههای AOD، آورده شده است. لازم بذکر است مبنای استخراج شکل (۵)، کلیه الگوریتمهای بهره گیری شده توسط محقق در مستند است. لازم بذکر است مبنای استخراج شکل (۵)، کلیه الگوریتمهای بهره گیری شده توسط محقق در مستند انتشار یافته بوده؛ لیکن از نقطه نظر معرفی بهترین الگوریتم جهت انجام برآوردها، روشهای ترکیبی یا است. لازم بذکر است مبنای استخراج شکل (۵)، کلیه الگوریتمهای بهره گیری شده توسط محقق در مستند مانتشار یافته بوده؛ لیکن از نقطه نظر معرفی بهترین الگوریتمهای یهره گیری ماشی انجام پیشبینیهای دقیق در جایگاههای اول تا سوم قرار می گیرند. استفاده از الگوریتمههای یادگیری ماشین، انجام پیشبینیهای دقیق در مسائل تحلیل پیشرفته دادهها را امکان پذیر نموده است ((۷<mark>۵ستره</mark>های یادگیری ماشین ای روشها می بر کرنل³ بوده

- 1 Overfitting
- 2 Regularization
- 3 Artificial Neural network (ANN)
- 4 Support Vector Regression (SVR)
- 5 Random Forest (RF)

⁶ Kernel

و در تحقیقات با هدف پیش بینی دنباله زمانی (<u>Quan, Liu & Liu, 2010</u>; <u>Sapankevych & Sankar, 2009</u>; <u>Tay & Cao, 20012011</u>) و در تحقیقات با موفقیت به کار گرفته (<u>Ghaemi, Farnaghi & Alimohammadi, 2016</u>)، با موفقیت به کار گرفته شدهاند.

همانطور که از شکل ۵ برمی آید، الگوریتمهای متنوعی در زمینه ایجاد همبستگی بین دادههای زمینی پایش PM_{2.5} و اطلاعات برگرفته از ماهواره (AOD) به کار گرفته شده است، اما میزان استفاده از هر الگوریتم به شدت متغیر است. الگوریتمهایی مانند (RF) Random Forest و SGBoost با بیشترین فراوانی در صدر جدول قرار دارند. این امر نشان میدهد که این الگوریتمها به دلیل دقت و کارایی بالای خود در برآورد پارامترهای پیچیده و محیطی مانند غلظت PM_{2.5}، بیشتر مورد توجه قرار گرفتهاند. در مقابل، برخی الگوریتمها با فراوانی کمتر استفاده شدهاند که ممکن است به دلیل محدودیتهای این الگوریتمها در مدل سازی دادههای غیرخطی و پیچیده باشد. به طور کلی، نمودار حاکی از روند رو به رشد استفاده از روشهای پیشرفته رو ترکیبی در مدل سازی پدیدههای محیطی است که به مرور جایگزین روشهای ساده تر شدهاند. این توزیع همچنین نشان دهنده علاقه پژوهشگران به استفاده از الگوریتمهای انعطاف پذیر و توانمند در پردازش دادههای حجیم و پیچیده می باشد.



شکل ۵- فراوانی کاربرد الگوریتمهای یادگیری ماشین در برآورد غلظت PM_{2.5} Fig.5. Frequency of Machine Learning Algorithm Applications in Estimating PM_{2.5} Concentrations

مدل ماشین بردار پشتیبان نه تنها به صورت مستقل در پیشبینیهای مبتنی بر دنباله زمانی استفاده شده است، بلکه در ترکیب با روشهای دیگر نیز میتواند سریهای زمانی پیچیده و نامانا را مدلسازی نماید. ژو و همکاران (Zhou et al., 2019)، این مدل را در ترکیب با روشهای دیگر بکار برده و با استفاده از متغیرهای غلظت آلایندههای هوا، پارامترهای هواشناسی و دادههای ترافیکی، به پیشبینی مکانی-زمانی آلودگی در چند ساعت آینده، پرداختند. با این حال، شبکههای ماشین بردار پشتیبان با وجود توانایی بالا در حل مسائل پیچیده، با محدودیتهایی نیز روبرو میباشند. به طوری که با افزایش حجم دادههای ورودی، زمان پردازش نیز افزایش یافته و همچنین قادر به حفظ اطلاعات در دنباله زمانی نیستند و در پیشبینیهایی در چند گام جلوتر، شبکه با کاهش دقت مواجه میشود (<u>Han, Zhao, Leung, Ma & Wang, 2019</u>). اوبودوئز و همکاران (Obodoeze, Nwabueze & Akaneme, 2021)، جهت برآورد غلظت PM_{2.5} در فاصله زمانی سالهای ۲۰۰۸ تا ۲۰۱۳، از نُه روش رگرسیون خطی چندگانه شامل رگرسیون بردار پشتیبان، رگرسیون خطی چندگانه، شبکه عصبی مصنوعی پرسپترون چند لایه، درخت تصمیم، درخت تصمیم تقویت شده با AdaBoost، جنگل تصادفی، XGBoost^۲، در شهر پکن، چین، استفاده کردند. نتایج نشان دهنده عملکرد بهتر مدل XGBoost نسبت به سایر مدلها بود.

شبکههای عصبی یکی دیگر از مدلهای متداول در پیشبینیهای مبتنی بر دنباله زمانی هستند. این شبکههای عصبی یکی دیگر از مدلهای متداول در پیشبینیهای مبتنی بر دنباله زمانی هستند. این شبکهها با پیشینه حدود ۲۰ ساله، با موفقیت در حل مسائل مربوط به رگرسیون، طبقهبندی و استخراج ویژگیها استفاده شدهاند. وانگ و همکاران (<u>Wang, Zeng & Chen, 2015</u>)، لچترمچر و فوللر (<u>Wang, Zeng & Chen, 2015</u>)، لچترمچر و میشرا و <u>گویال (<u>Mellit & Pavan, 2010</u>)، مللیت و پاوان (<u>Mellit & Pavan, 2010</u>) و میشرا و میشرا و گردند. در مطالعه ییگر، هان و همکاران (<u>Hellit & Pavan, 2010</u>)، متوجه ضعف عملکرد شبکه عصبی در برابر کردند. در مطالعه ییگر، هان و همکاران (<u>Han et al., 2019</u>)، متوجه ضعف عملکرد شبکه عصبی در برابر مسائل پیچیده با حجم انبوه ورودی شدند که میتواند منجر به کاهش عملکرد شبکه و عدم توانایی در تقریب مسائل پیچیده شود.</u>

یادگیری عمیق، روشی جدید در حوزه یادگیری ماشین است که در سالیان اخیر در بخش هوش مصنوعی معرفی شده و قادر است الگوهای مرتبط با خصوصیات بسیار پیچیده را با استفاده از حجم بزرگی از دادههای ورودی تشخیص دهد (<u>Yamins & DiCarlo, 2016</u>؛ <u>Deng & Yu, 2014</u>). در مقایسه با روشهای سنتی، یادگیری عمیق میتواند به طور کارآمد، مدلی را از دادههای آموزشی استخراج کرده و پیشبینی دقیقتری را ارائه دهد (<u>Zhang, Zheng & 2016 Meyer, Kühnlein, Appelhans & Nauss</u>). در مقایسه با روشهای دقیقتری را ارائه دهد (<u>Oi, 2017</u>). با گسترش استفاده از یادگیری عمیق در موضوعات متنوع، بررسی پیشبینی غلظت آلایندههای هوای شهری با استفاده از یادگیری عمیق در موضوعات متنوع، بررسی پیشبینی غلظت آلایندههای (<u>Zuo, Guo, Shi & Zhang, 2020</u>). با گسترش استفاده از یادگیری عمیق در سالهای اخیر مورد توجه ویژه محققان بوده است (<u>Zuo, Guo, Shi & Zhang, 2020</u>). استفاده از یادگیری عمیق در سالهای اخیر مورد توجه ویژه محققان بوده است (<u>Schmidhuber, 2015</u>).

راهکارهای یادگیری عمیق در حوزه پیشبینی، مبتنی بر دنباله زمانی، شامل سه دسته اصلی (۱) بدون نظارت (مانند شبکه خود رمزنگار)؛ (۲) نظارت شده یا تمایزی (مانند شبکههای کانولوشنی و بازگشتی)؛ و (۳) یادگیری ترکیبی است (<u>Sarker, 2021</u>). لو و همکاران (Lv, Duan, Kang, Li & Wang, 2014) و لی و همکاران (<u>Li, Peng, Hu, Shao & Chi, 2016</u>)، از شبکههای خود رمزنگار جهت پیشبینی دنباله زمانی مانند پیشبینی جریان ترافیک و پیشبینی مصرف انرژی در ساختمان، استفاده کردند. در یک پژوهش در کشور ژاپن با هدف پیشبینی غلظت PM_{2.5} با استفاده از شبکههای خود رمزنگار عمیق، یک روش نوین

¹ Adaptive Boosting (AdaBoost)

² Extreme Gradient Boosting (XGBoost)

³ Least Absolute Shrinkage and Selection Operation (LASSO)

پیش آموزش شبکه پویا برای دادههای سری زمانی توسعه یافت. در این تحقیق، از دادههای آلودگی هوا با دقت بالا در ۵۲ شهر کشور ژاپن و دادههای هواشناسی استفاده شده است. مقایسه مدل پیشنهادی با دادههای سازمان مطالعات محیطزیست کشور ژاپن نشاندهنده عملکرد مناسب مدل پیشنهادی بوده است(<u>Ong, Ong</u> سازمان مطالعات محیطزیست کشور ژاپن نشاندهنده عملکرد مناسب مدل پیشنهادی بوده است(<u>Sugiura & Zettsu</u>, 2016 ایستگاهها به طور همزمان برای چهار فصل آینده سال، توسط الگوریتمهای ARMA^۱، ARMA^۲، ISTME^۲، ISTME^۲، STDL منجش آلودگی هوا در شهر پکن، برای در نظر گرفت. در این مطالعه با استفاده از دادههای ۱۲ ایستگاه سنجش آلودگی هوا در شهر پکن، برای در نظر گرفتن ارتباطات ذاتی مکانی-زمانی، از ترکیب دو مدل خود رمزنگار عمیق و رگرسیون منطقی استفاده شد. در این روش، خروجی آخرین لایه پنهان خود رمزنگار به عنوان ورودی برای لایه رگرسیون منطقی استفاده شده است. مدل ارائه شده در این تحقیق، براساس درصد میانگین مطلق خطای (MAPE)³ معادل ۲۵ درصد، در مقایسه با سایر روشهای شبکه عصبی مصنوعی ارائه شده، دقت بالاتری داشته است (Li et al., 2017)

هوچریتر و اسچمیدبر (LSTM ار ارائه کردند که یکی از روش های پُر کاربرد در زمینه پیشبینی شبکههای بازگشتی تحت عنوان LSTM را ارائه کردند که یکی از روش های پُر کاربرد در زمینه پیشبینی آلودگی هوا به شمار میآید (<u>Athira, Stenge, Charters</u> & Schmidhuber,) در طازه سال های <u>Reddy, Yedavalli, Mohanty & Reddrik (Charters</u>). به عنوان مثال در کشور چین، Reddy و همکاران (<u>Kakhat, 2018</u>). به عنوان مثال در کشور چین، Reddy و همکاران (<u>Kakhat, 2018</u>). در بازه سال های ۲۰۱۵ تا ۲۰۱۵ (<u>Nakhat, 2018</u>)، با استفاده از روش حافظه طولانی کوتاه مدت (LSTM) در بازه سال های ۲۰۱۵ تا <u>Yenders</u>)، با استفاده از روش حافظه طولانی کوتاه مدت (<u>Kakhat, 2018</u>). در بازه سال های ۲۰۱۵ تا <u>Yenders</u>)، با استفاده از دادههای نُه ایستگاه سنجش آلودگی هوا در شهر تهران در بازه سال های ۲۰۱۳ تا <u>Yenders</u>)، با استفاده از دادههای نُه ایستگاه سنجش آلودگی هوا در شهر تهران در بازه سال های ۲۰۱۳ تا <u>Yenders</u>)، با استفاده از دادههای نُه ایستگاه سنجش آلودگی هوا در شهر تهران در بازه سال های ۲۰۱۳ تا <u>Yenders</u>)، با استفاده از دادههای نُه ایستگاه سنجش آلودگی هوا در شهر تهران در بازه سال های ۲۰۱۳ تا <u>Yenders</u>)، با استفاده از دادههای نُه ایستگاه سنجش آلودگی هوا در شهر تهران در بازه سال های ۲۰۱۳ تا ۲۰۱۷ <u>Yenders</u>)، با استفاده از دادههای نُه ایستگاه سنجش آلودگی هوا در شهر تهران در بازه سال های ۲۰۱۳ تا ۲۰۱۷ <u>Yenders</u>)، با استفاده از دادههای نُه ایستگاه سنجش آلودگی هوا در شهر تهران در بازه سال های ۲۰۱۳ تا ۲۰۱۷

یادگیری عمیق شامل شبکه عصبی بازگشتی، شبکه LSTM و شبکه GRU جهت پیشبینی غلظت PM_{2.5} از دادههای ۱۴۹۸ سنجنده آلودگی استفاده شد. نتایج حاصله عملکرد بهتر شبکه GRU را اثبات میکند. در پژوهشی که ژو و همکاران(Xu et al., 2018) در استان بریتیش کلمبیا در غرب کانادا انجام دادند، جهت برآورد غلظت ذرات PM_{2.5} از روشهای یادگیری ماشین استفاده گردید. براساس نتایج این مطالعه،

روشهای XGBoost ،Cubist و جنگل تصادفی، عملکرد بهتری نسبت به سایر روشها داشتند. در مطالعهای

¹ Auto Regression Moving Average (ARMA)

² Long Short-Term Memory (LSTM)

³ Long Short-Term Memory Extended (LSTME)

⁴ SpatioTemporal Deep Learning (STDL)

⁵ Time Delay Neural Network (TDNN)

⁶ Mean Absolute Percentage Error (MAPE)

دیگر، لیو و همکاران (PM_{2.5} با استفاده روش Liu, Weng, Li & Cribb, 2019)، در برآورد غلظت PM_{2.5} با استفاده روش جنگل تصادفی (RF)، به مقدار ۰/۸۶ برای R² رسیدند. آهنی و همکاران (Ahani, Salari & Shadman, پندلایه (2019) در برآورد غلظت PM_{2.5} هوای آزاد شهر مشهد، از دو روش یادگیری ماشین شبکه عصبی چندلایه (MLP)^{۵۱} و میانگین متحرک خود همبسته یکپارچه (ARIMA)، استفاده نمودند. پارامترهای هواشناسی و کیفیت هوا بعنوان ورودی کمکی مدلها استفاده شده و نتایج نشان داد که روش ARIMA بهترین عملکرد را در برآورد غلظت PM_{2.5} داشت.

زمانی و همکاران (PM_{2.5} و Addition و PM_{2.5} در شهر تهران، از سه روش یادگیری ماشین یعنی جنگل تصادفی، برای پیشبینی غلظت آلاینده PM_{2.5} در شهر تهران، از سه روش یادگیری ماشین یعنی جنگل تصادفی، XGBoost و یادگیری عمیق استفاده کردند. در مقایسه با روشهای جنگل تصادفی و یادگیری عمیق، روش XGBoost با داشتن مقدار R² برابر با ۸۱/۰ و RMSE¹ برابر با 30 مالارد بهتری را از خود XGBoost با داشتن مقدار R² برابر با ۸۱/۰ و RMSE¹ برابر با 30 مالارد بهتری را از خود نشان داد. پنگ و همکاران (Peng et al., 2022)، در استان هونان چین در مجموع ۱۷۵۲۰ داده را با بهره گیری از دو الگوریتم یادگیری ماشین (تقویت گرادیان XGBoost و یادگیری عمیق)، شش پارامتر هواشناسی (فشار اتمسفر، رطوبت نسبی، سرعت باد، جهت باد، بارندگی و دما) و غلظت MS2.5 که به طور مستقل از دو سایت پایش در طول سال ۲۰۲۱ اندازه گیری شده بود، مورد بررسی قرار دادند. نتایج حاکی از عملکرد بهتر شبکه XGBoost بوده است.

در پژوهش انجامشده توسط انبیش و همکاران (Enebish, Chau, Jadamba & Franklin, 2021) در شهر اولان باتور در کشور مغولستان، محققان در بازه زمانی سالهای ۲۰۱۰ تا ۲۰۱۸ از شش الگوریتم یادگیری ماشین استفاده کردند. نتایج این مطالعه نشان داد که الگوریتمهای جنگل تصادفی و XGBoost عملکرد بهتری در مقایسه با سایر الگوریتمها داشتند. در مطالعه شکرخدایی و همکاران(Shogrkhodaei, از سه روش یادگیری عملکرد ایت در مقایسه با سایر الگوریتمها داشتند. در مطالعه شکرخدایی و همکاران AdaBoost از سه روش یادگیری ماشین استفاده شده است: AdaBoost، جنگل تصادفی و گرادیان کاهشی تصادفی(SGD)^۲. نتایج این پژوهش نشان داد که در میان این سه روش، روش جنگل تصادفی عملکرد بهتری داشته است.

در مطالعهای دیگر، آیوس و همکاران (Ayus, Natarajan & Gupta, 2023)، در بازه زمانی هفت ساله از سال ۲۰۱۳ تا ۲۰۲۱ برای ده شهر بزرگ در سراسر چین با استفاده از شش تکنیک مختلف یادگیری عمیق شامل شبکه عصبی مکرر (RNN)^۳، واحد برگشتی دروازهای دو جهته (Bi-GRU)^۴، حافظه طولانی کوتاه مدت دو جهته کوتاه مدت دو جهته (Bi-STM)

¹ Root Mean Squared Error (RMSE)

² Stochastic Gradient Descent (SGD)

³ Recurrent Neural Network (RNN)

⁴ Bidirectional Gated Recurrent Unit (Bi-GRU)

⁵ Bidirectional Long Short-Term Memory (BiLSTM)

(CNN-BiLSTM)^۱، شبکه کانولوشنالی حافظه طولانی کوتاه مدت دو جهته (CNN-BiLSTM)^۲ و مدل تقویت گرادیان (XGBoost)، استفاده کردند. نتایج نشان داد Conv1D-BiLSTM و CNN-BiLSTM در بین مدلهای یادگیری عمیق در برآورد شاخص کیفیت هوا (AQI)^۲، عملکرد خوبی دارند؛ در حالی که مدل یادگیری ماشین (XGBoost)، بهتر از مدلهای یادگیری عمیق است. لی و همکاران (<u>Li</u>, LSTM) در شهر شینبی کشور تایوان با استفاده روش پیشبینی ترکیبی -LSTM XGBoost-SVR بر اساس ویژگیهای زمانی-مکانی، توانستند دقت پیشبینی را بهبود بخشند.

Mohammadi, Teiri, Hajizadeh, Abdolahnejad & Ebrahimi,) محمدی و همکاران (PM_{2.5} PM_{2.5})، از دادههای هواشناسی نُه سال گذشته در شهر اصفهان، برای پیش بینی غلظت PM_{2.5} با استفاده از چهار الگوریتم یادگیری ماشین شامل شبکههای عصبی مصنوعی (ANN)، K-همسایگان نزدیک (KNN)³, ماشینهای بردار پشتیبان (SVM)⁶ و جنگل تصادفی (RF)، استفاده کردند. نتایج نشان داد که بر اساس درصد دقت، مدل ANN و RF در مقایسه با سایر مدلها برای پیش بینی غلظت PM_{2.5} عملکرد بهتری در شد.

در مطالعهای دیگر یانگ و همکاران (Xang et al., 2024) برای برآورد غلظت $PM_{2.5}$ ، یک مدل شبکه عصبی حافظه بلندمدت و کوتاهمدت (LSTM) و رگرسیون جنگل تصادفی (RF)، استفاده کردند. در نهایت، RMSE = $4.59 \ \mu g \ m^{-} R^{2} = 0.93$ تصادفی (Ren, Ren, Ren, Ren, 2024) به عنوان مدل بهینه انتخاب شد. رن و همکاران (Ren, Zhang & Fan, 2024)، جهت برآورد غلظت 5)، به عنوان مدل بهینه انتخاب شد. رن و همکاران (Ren, Zhang & Fan, 2024)، جهت برآورد غلظت نزرات معلق $PM_{2.5}$ از الگوریتمهای جنگل تصادفی، RDSD و مدل تلفیقی² این الگوریتمها نزرات معلق در الهوریتم های جنگل تصادفی، RDSOSt، Ren و مدل تلفیقی² این الگوریتمها نیزات معلق در معالیان دهنده دقت بالای برآورد مدل تلفیقی نسبت به سایر مدلها بود. در مطالعهای دیگر چن و همکاران (Chen et al., 2024)، برای برآورد غلظت $PM_{2.5}$ از مدل تلفیقی توسعه یافته استفاده کردند؛ این الگوریتم براساس برآورد انباشتگی با ساختار دو لایه و تلفیق چندین مدل یادگیری ماشین، ساخته شده است. مدل تلفیقی توسعه یافته در این مطالعه در مقایسه با سایر مدلهای مستقل (جنگل تصادفی، LightGBM⁴

در پژوهش انجام شده توسط آگیلرا و همکاران (Aguilera et al., 2023)، سه الگوریتم یادگیری ماشین (یعنی یادگیری عمیق، جنگل تصادفی (RF) و گرادیان تقویتی) در برآورد غلظت PM_{2.5} مورد استفاده قرار گرفت. نتایج نشان داد که تلفیق بهینه این سه الگوریتم، بهترین عملکرد را با ضریب همبستگی R² = 0.78 بهدست خواهد داد. این یافته نشان میدهد که استفاده از یک ترکیب چند الگوریتمی (در مقایسه با استفاده

¹ Convolutional Neural Network BiLSTM (CNN-BiLSTM)

² Convolutional BiLSTM (Conv1D-BiLSTM)

³ Air Quality Index (AQI)

⁴ K-Nearest-Neighbors (KNN)

⁵ Support Vector Machine (SVM)

⁶ Ensemble Model

⁷ Light Gradient Boosting Model (LightGBM)

از هر الگوریتم به تنهایی) میتواند به طور مؤثرتری غلظت PM_{2.5} را برآورد نماید. رویکرد ترکیبی فوق مزایایی همچون بهبود دقت، پوشش وسیعتر ویژگیها و مقاومت در برابر نقاط ضعف هر الگوریتم را به همراه خواهد داشت.

همانطور که در متن اشاره گردید، الگوریتمهای یادگیری ماشین بخش نوینی از روشهای آماری مبتنی بر دنباله زمانی بوده (شکل ⁹) و روند استفاده از آنها در برآورد غلظت PM_{2.5} زمینی براساس AOD، افزایشی است.



شکل ۶– روشهای مختلف پیشبینی/ بر آورد غلظت PM_{2.5} براساس دادههای زمینی و ماهوارهای Fig.6. Various Methods for Predicting/Estimating PM_{2.5} Concentrations Based on Ground and Satellite Data

نتيجهگيرى

در برآورد غلظت PM_{2.5} ومینی، شاخص AOD معیار مناسبی ارائه میدهد. مطالعات بیانگر آن است که استفاده از دادههای کمکی نظیر شرایط اتمسفری (رطوبت نسبی هوا، دمای سطحی، فاصله دید افقی و سرعت و جهت باد)، بر تقویت همبستگی PM_{2.5} و AOD تأثیرگذار خواهد بود. با این وجود، افزایش تعداد پارامترهای مورد استفاده، منجر به پیچیدگی روابط و افزایش خطای الگوریتمهای یادگیری ماشین خواهد شد. استفاده از الگوریتمهای تلفیقی یادگیری در چنین حالاتی، به دلیل توانایی در انتخاب و مدیریت تعداد PM_{2.5} پارامترهای زیاد، توصیه شده است. مجموعه دادههای بکار رفته در برقراری همبستگی قوی بین غلظت PM_{2.5} زمینی و شاخص AOD توسط محققان عبارتند از:

(الف) دادههای ماهوارهای: شامل عمق نوری آئروسل (AOD) که از سنسورهای MODIS و OMI استخراج شدهاند.

(ب) دادههای ایستگاههای هواشناسی: شامل متغیرهای دما، رطوبت نسبی، سرعت باد، جهت باد و بارش.

(ج) دادههای زمینی: شامل شاخص پوشش گیاهی (NDVI)' ، تراکم جمعیت، تراکم شبکه جادهای، ارتفاع و تعداد ساختمانها.

(د) دادههای آلودگی هوا: شامل غلظت PM_{2.5} و سایر آلایندهها مانند O₃ ،CO، NO و SO₂.

مطابق با تحقیقات انجام گرفته، با توجه به حجم بالای دادهها و استفاده همزمان از چند پارامتر و همچنین به دلیل وجود رابطه غیرخطی بین PM_{2.5} و متغیرهای پیشبینی کننده، الگوریتمهای یادگیری ماشین بواسطه توانایی برتر در انتخاب و مدیریت تعداد زیادی متغیر مستقل، که قادر به پیشبینی متغیر وابسته در مسائل تحلیل پیشرفته دادهها و حل کردن مسائل پیچیده هستند، در سالیان اخیر در کانون توجه محققان قرار گرفته اند.

در بین الگوریتمهای یادگیری ماشین، مدلهای ترکیبی به دلیل برآوردهای دقیقتر، انعطاف پذیر بودن، پردازش موازی و سرعت بالا، توجه به دادههای گمشده و صرف زمان کمتر برای آموزش و برآورد، در برآورد غلظت PM_{2.5} زمینی عملکرد مناسبتری نسبت به عملکرد هریک از الگوریتمها به تنهایی، داشته اند. الگوریتمهای ترکیبی که چندین مدل (همچون RF، XGboost و CNN³) را ترکیب میکنند، سوگیری⁷ را کاهش داده، استحکام پیشبینیها را افزایش میدهند و در بهبود دقت پیشبینی موثر هستند. با وجود پیشرفتهای اخیر، هنوز چالشها و محدودیتهای ذاتی به دلیل عدم قطعیت در دادههای ورودی و تغییرات جوی و هواشناسی، در این زمینه وجود داشته و اثربخشی مدلها برای افقهای پیشبینی طولانیتر (بیش از ۱۲ ساعت در برخی موارد)، کاهش مییابد.

از جمله این چالشها که تحقیقات آتی باید به آنها بپردازد میتوان به عدم اطمینان در دادههای ورودی، پیچیدگیهای ناشی از تغییرات زمانی و مکانی و نیاز به ترکیب دادههای چندمنبعی، اشاره کرد. برای رفع این چالشها، تحقیقات آینده باید بر توسعه الگوریتمهای ترکیبی پیشرفتهتر متمرکز شوند که قابلیت مدیریت دادههای گمشده، پردازش حجم بالای دادهها و تطبیق با تغییرات محیطی را داشته باشند. همچنین، استفاده از دادههای ماهوارهای با وضوح مکانی و زمانی بالاتر، بهبود کیفیت متغیرهای کمکی (مانند دادههای هواشناسی) و تلفیق دادههای ایستگاههای زمینی و سنجش از دور میتواند دقت پیشبینیها را افزایش دهد.

3 Bias

¹ Normalized Difference Vegetation Index (NDVI)

² Convolutional Neural Network

علاوه بر این، طراحی مدلهایی که توانایی پیشبینی تأثیرات بلندمدت تغییرات آبوهوایی را داشته باشند، میتواند مسیر جدیدی برای پژوهشهای آینده ایجاد کند.

References

- Abbas, A., Ekowati, D., Suhariadi, F., & Fenitra, R. M. (2023). Health implications, leaders societies, and climate change: a global review. *Ecological footprints of climate change: Adaptive approaches and sustainability*, 653-675. <u>https://doi.org/10.1007/978-3-031-15501-7_26</u>
- Aguilera, R., Luo, N., Basu, R., Wu, J., Clemesha, R., Gershunov, A., & Benmarhnia, T. (2023). A novel ensemble-based statistical approach to estimate daily wildfire-specific PM_{2.5} in California (2006–2020). *Environment International*, 171, 107719. https://doi.org/10.1016/j.envint.2022.107719
- Ahani, I. K., Salari, M., & Shadman, A. (2019). Statistical models for multi-step-ahead forecasting of fine particulate matter in urban areas. *Atmospheric Pollution Research*, 10(3), 689-700. <u>https://doi.org/10.1016/j.apr.2018.11.006</u>
- Athira, V., Geetha, P., Vinayakumar, R., & Soman, K. P. (2018). DeepAirNet: Applying recurrent networks for air quality prediction. *Proceedia Computer Science*, 132, 1394-1403. <u>https://doi.org/10.1016/j.procs.2018.05.068</u>
- Ayus, I., Natarajan, N., & Gupta, D. (2023). Comparison of machine learning and deep learning techniques for the prediction of air pollution: a case study from China. *Asian Journal of Atmospheric Environment*, 17(1), 4. <u>https://doi.org/10.1007/s44273-023-00005-w</u>
- Bai, L., Wang, J., Ma, X., & Lu, H. (2018). Air pollution forecasts: An overview. International Journal of Environmental Research and Public Health, 15(4), 780. https://doi.org/10.3390/ijerph15040780
- Beckerman, B. S., Jerrett, M., Serre, M., Martin, R. V., Lee, S. J., Van Donkelaar, A., ... & Burnett, R. T. (2013). A hybrid approach to estimating national scale spatiotemporal variability of PM2. 5 in the contiguous United States. *Environmental Science & Technology*, 47(13), 7233-7241. <u>https://doi.org/10.1021/es400039u</u>
- Bell, M. L., Dominici, F., Ebisu, K., Zeger, S. L., & Samet, J. M. (2007). Spatial and temporal variation in PM_{2.5} chemical composition in the United States for health effects studies. *Environmental Health Perspectives*, 115(7), 989-995. https://doi.org/10.1289/ehp.962
- Bono, R., Tassinari, R., Bellisario, V., Gilli, G., Pazzi, M., Pirro, V., ... & Piccioni, P. (2015). Urban air and tobacco smoke as conditions that increase the risk of oxidative stress and respiratory response in youth. *Environmental Research*, 137, 141-146. https://doi.org/10.1016/j.envres.2014.12.008
- Chen, B., You, S., Ye, Y., Fu, Y., Ye, Z., Deng, J., ... & Hong, Y. (2021). An interpretable selfadaptive deep neural network for estimating daily spatially-continuous PM_{2.5}

concentrations across China. *Science of The Total Environment*, 768, 144724. https://doi.org/10.1016/j.scitotenv.2020.144724

- Chen, L., Wu, Z., Tu, W., & Cao, Z. (2020). Applying LUR model to estimate spatial variation of PM_{2.5} in the Greater Bay Area, China. *In Spatiotemporal Analysis of Air Pollution and Its Application in Public Health*, 207-215. <u>https://doi.org/10.1016/B978-0-12-815822-7.00010-8</u>
- Chen, X., Zhang, W., He, J., Zhang, L., Guo, H., Li, J., & Gu, X. (2024). Mapping PM_{2.5} concentration from the top-of-atmosphere reflectance of Himawari-8 via an ensemble stacking model. *Atmospheric Environment*, 120560. https://doi.org/10.1016/j.atmosenv.2024.120560
- Chudnovsky, A., Tang, C., Lyapustin, A., Wang, Y., Schwartz, J., & Koutrakis, P. J. A. C. (2013). A critical assessment of high-resolution aerosol optical depth retrievals for fine particulate matter predictions. *Atmospheric Chemistry and Physics*, 13(21), 10907-10917. https://doi.org/10.5194/acp-13-10907-2013
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv preprint arXiv:1412.3555. https://doi.org/10.48550/arXiv.1412.3555
- Cortina–Januchs, M. G., Quintanilla–Dominguez, J., Vega–Corona, A., & Andina, D. (2015). Development of a model for forecasting of PM₁₀ concentrations in Salamanca, Mexico. *Atmospheric Pollution Research*, 6(4), 626-634. https://doi.org/10.5094/APR.2015.071
- Das Chagas Moura, M., Zio, E., Lins, I. D., & Droguett, E. (2011). Failure and reliability prediction by support vector machines regression of time series data. *Reliability Engineering* & *System Safety*, 96(11), 1527-1534. https://doi.org/10.1016/j.ress.2011.06.006
- De Hoogh, K., Gulliver, J., van Donkelaar, A., Martin, R. V., Marshall, J. D., Bechle, M. J., ... & Hoek, G. (2016). Development of West-European PM_{2.5} and NO₂ land use regression models incorporating satellite-derived and chemical transport modelling data. *Environmental Research*, 151, 1-10. https://doi.org/10.1016/j.envres.2016.07.005
- Deng, L., & Yu, D. (2014). Deep learning: methods and applications. Foundations and Trends® in signal processing, 7(3–4), 197-387. <u>http://dx.doi.org/10.1561/2000000039</u>
- Enebish, T., Chau, K., Jadamba, B., & Franklin, M. (2021). Predicting ambient PM_{2.5} concentrations in Ulaanbaatar, Mongolia with machine learning approaches. *Journal of Exposure Science & Environmental Epidemiology*, 31(4), 699-708. https://doi.org/10.1038/s41370-020-0257-8
- Feng, L., Li, Y., Wang, Y., & Du, Q. (2020). Estimating hourly and continuous ground-level PM_{2.5} concentrations using an ensemble learning algorithm: The ST-stacking model. *Atmospheric Environment*, 223, 117242. https://doi.org/10.1016/j.atmosenv.2019.117242

- Fotheringham, A. S., Charlton, M. E., & Brunsdon, C. (1998). Geographically weighted regression: a natural evolution of the expansion method for spatial data analysis. *Environment and planning A*, 30(11), 1905-1927. <u>https://doi.org/10.1068/a301905</u>
- Geng, G., Zhang, Q., Martin, R. V., Van Donkelaar, A., Hong, H., Che, H., ... & He, K. (2015). Estimating long-term PM_{2.5} concentrations in China using satellite-based aerosol optical depth and a chemical transport model. *Remote Sensing of Environment*, 166, 262–270. https://doi.org/10.1016/j.rse.2015.05.016
- Ghaemi, Z., Farnaghi, M., & Alimohammadi, A. (2016). An Online Approach for Spatio-Temporal Prediction of Air Pollution in Tehran using Support Vector Machine. *Engineering Journal of Geospatial Information Technology*, 3(4), 43-63.[In Persian] http://jgit.kntu.ac.ir/article-1-305-en.html
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222-2232. https://doi.org/10.1109/TNNLS.2016.2582924
- Gulliver, J., Morley, D., Dunster, C., McCrea, A., van Nunen, E., Tsai, M. Y., ... & Kelly, F. J. (2018). Land use regression models for the oxidative potential of fine particles (PM_{2.5}) in five European areas. *Environmental Research*, 160, 247-255. https://doi.org/10.1016/j.envres.2017.10.002
- Guo, Y., Tang, Q., Gong, D. Y., & Zhang, Z. (2017). Estimating ground-level PM_{2.5} concentrations in Beijing using a satellite-based geographically and temporally weighted regression model. *Remote Sensing of Environment*, 198, 140-149. https://doi.org/10.1016/j.rse.2017.06.001
- Han, W., & Tong, L. (2019). Satellite-based estimation of daily ground-level PM_{2.5} concentrations over urban agglomeration of Chengdu Plain. *Atmosphere*, 10(5), 245. <u>https://doi.org/10.3390/atmos10050245</u>
- Han, Z., Zhao, J., Leung, H., Ma, K. F., & Wang, W. (2019). A review of deep learning models for time series prediction. *IEEE Sensors Journal*, 21(6), 7833-7848. <u>https://doi.org/10.1109/JSEN.2019.2923982</u>
- He, Q., & Huang, B. (2018). Satellite-based high-resolution PM_{2.5} estimation over the Beijing-Tianjin-Hebei region of China using an improved geographically and temporally weighted regression model. *Environmental Pollution*, 236, 1027-1037. https://doi.org/10.1016/j.envpol.2018.01.053
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <u>https://doi.org/10.1162/neco.1997.9.8.1735</u>
- Hosseini, V., & Shahbazi, H. (2016). Urban air pollution in Iran. *Iranian Studies*, 49(6), 1029-1046. <u>https://doi.org/10.1080/00210862.2016.1241587</u>
- Hsu, N. C., Tsay, S. C., King, M. D., & Herman, J. R. (2004). Aerosol properties over brightreflecting source regions. *IEEE Transactions on Geoscience and Remote Sensing*, 42(3), 557-569. <u>https://doi.org/10.1109/tgrs.2004.824067</u>
- Hu, X., Waller, L. A., Al-Hamdan, M. Z., Crosson, W. L., Estes Jr, M. G., Estes, S. M., ... & Liu, Y. (2013). Estimating ground-level PM_{2.5} concentrations in the southeastern U.S.

using geographically weighted regression. *Environmental Research*, 121, 1–10. https://doi.org/10.1016/j.envres.2012.11.003

- Hu, Z., Liebens, J., & Rao, K. R. (2011). Merging satellite measurement with ground-based air quality monitoring data to assess health effects of fine particulate matter pollution. *In Geospatial Analysis of Environmental Health* (pp. 395-409). Dordrecht: Springer Netherlands. <u>https://doi.org/10.1007/978-94-007-0329-2_20</u>
- Huang, K., Bi, J., Meng, X., Geng, G., Lyapustin, A., Lane, K. J., ... & Liu, Y. (2019). Estimating daily PM_{2.5} concentrations in New York City at the neighborhood-scale: Implications for integrating non-regulatory measurements. *Science of the Total Environment*, 697, 134094. https://doi.org/10.1016/j.scitotenv.2019.134094
- Institute for Environmental Research, Tehran University of Medical Sciences and National Institute of Health Research, (I.R. Iran). (2019). Air quality in Iran and its effects on health in 2017. Available at (accessed: May 2024): https://enier.tums.ac.ir/Centerfor-Air-Pollution-Research-News/Air-quality-in-Iran-its-effects-on-health-in-2017
- Izah, S. C., Iyiola, A. O., Yarkwan, B., & Richard, G. (2023). Impact of air quality as a component of climate change on biodiversity-based ecosystem services. In *Visualization techniques for climate change with machine learning and artificial intelligence*, 123-148. https://doi.org/10.1016/B978-0-323-99714-0.00005-4
- Jia, N., Li, Y., Chen, R., & Yang, H. (2023). A review of global PM_{2.5} exposure research trends from 1992 to 2022. *Sustainability*, 15(13), 10509. https://doi.org/10.3390/su151310509
- Jiang, T., Chen, B., Nie, Z., Ren, Z., Xu, B., & Tang, S. (2021). Estimation of hourly fullcoverage PM_{2.5} concentrations at 1-km resolution in China using a two-stage random forest model. *Atmospheric Research*, 248, 105146. https://doi.org/10.1016/j.atmosres.2020.105146
- Kampa, M., & Castanas, E. (2008). Human health effects of air pollution. *Environmental Pollution*, 151(2), 362-367. <u>https://doi.org/10.1016/j.envpol.2007.06.012</u>
- Karimian, H., Li, Q., Wu, C., Qi, Y., Mo, Y., Chen, G., ... & Sachdeva, S. (2019). Evaluation of different machine learning approaches to forecasting PM_{2.5} mass concentrations. *Aerosol* and Air Quality Research, 19(6), 1400-1410. https://doi.org/10.4209/aaqr.2018.12.0450
- Kaufman, Y. J., Wald, A. E., Remer, L. A., Gao, B. C., Li, R. R., & Flynn, L. (1997). The MODIS 2.1-/spl mu/m channel-correlation with visible reflectance for use in remote sensing of aerosol. *IEEE transactions on Geoscience and Remote Sensing*, 35(5), 1286-1298. https://doi.org/10.1109/36.628795
- Kelly, F. J., & Fussell, J. C. (2012). Size, source and chemical composition as determinants of toxicity attributable to ambient particulate matter. *Atmospheric Environment*, 60, 504-526. <u>https://doi.org/10.1016/j.atmosenv.2012.06.039</u>
- Koelemeijer, R. B. A., Homan, C. D., & Matthijsen, J. (2006). Comparison of spatial and temporal variations of aerosol optical thickness and particulate matter over Europe.

Atmospheric Environment, 40(27), 5304-5315. https://doi.org/10.1016/j.atmosenv.2006.04.044

- Kong, L., Xin, J., Zhang, W., & Wang, Y. (2016). The empirical correlations between PM_{2.5}, PM₁₀ and AOD in the Beijing metropolitan region and the PM_{2.5}, PM₁₀ distributions retrieved by MODIS. *Environmental Pollution*, 216, 350-360. https://doi.org/10.1016/j.envpol.2016.05.085
- Kuremoto, T., Kimura, S., Kobayashi, K., & Obayashi, M. (2014). Time series forecasting using a deep belief network with restricted Boltzmann machines. *Neurocomputing*, 137, 47-56. https://doi.org/10.1016/j.neucom.2013.03.047
- Lachtermacher, G., & Fuller, J. D. (1995). Back propagation in time-series forecasting. *Journal of Forecasting*, 14(4), 381-393. <u>https://doi.org/10.1002/for.3980140405</u>
- Lai, X., Li, H., & Pan, Y. (2021). A combined model based on feature selection and support vector machine for PM2. 5 prediction. *Journal of Intelligent & Fuzzy Systems*, 40(5), 10099-10113. https://doi.org/10.3233/JIFS-202812
- Lee, H. J., Coull, B. A., Bell, M. L., & Koutrakis, P. (2012). Use of satellite-based aerosol optical depth and spatial clustering to predict ambient PM_{2.5} concentrations. *Environmental Research*, 118, 8-15. https://doi.org/10.1016/j.envres.2012.06.011
- Lee, H. J., Liu, Y., Coull, B. A., Schwartz, J., & Koutrakis, P. (2011). A novel calibration approach of MODIS AOD data to predict PM_{2.5} concentrations. *Atmospheric Chemistry* and Physics, 11(15), 7991-8002. <u>https://doi.org/10.5194/acp-11-7991-2011</u>
- Lee, J. H., Wu, C. F., Hoek, G., de Hoogh, K., Beelen, R., Brunekreef, B., & Chan, C. C. (2015). LUR models for particulate matters in the Taipei metropolis with high densities of roads and strong activities of industry, commerce and construction. *Science of the Total Environment*, 514, 178-184. https://doi.org/10.1016/j.scitotenv.2015.01.091
- Li, H., Yu, Y., Huang, Z., Sun, S., & Jia, X. (2023). A multi-step ahead point-interval forecasting system for hourly PM_{2.5} concentrations based on multivariate decomposition and kernel density estimation. *Expert Systems with Applications*, 226, 120140. <u>https://doi.org/10.1016/j.eswa.2023.120140</u>
- Li, L., Zhang, J., Meng, X., Fang, Y., Ge, Y., Wang, J., ... & Kan, H. (2018a). Estimation of PM_{2.5} concentrations at a high spatiotemporal resolution using constrained mixed-effect bagging models with MAIAC aerosol optical depth. *Remote Sensing of Environment*, 217, 573-586. https://doi.org/10.1016/j.rse.2018.09.001
- Li, R., Ma, T., Xu, Q., & Song, X. (2018b). Using MAIAC AOD to verify the PM_{2.5} spatial patterns of a land use regression model. *Environmental Pollution*, 243, 501-509. https://doi.org/10.1016/j.envpol.2018.09.026
- Li, X., Huo, H., & Liu, Z. (2022). Analysis and prediction of PM_{2.5} concentration based on LSTM-XGBoost-SVR model. <u>https://doi.org/10.21203/rs.3.rs-2158285/v1</u>
- Li, X., Peng, L., Hu, Y., Shao, J., & Chi, T. (2016). Deep learning architecture for air quality predictions. *Environmental Science and Pollution Research*, 23, 22408-22417. <u>https://doi.org/10.1007/s11356-016-7812-9</u>

- Li, X., Peng, L., Yao, X., Cui, S., Hu, Y., You, C., & Chi, T. (2017). Long short-term memory neural network for air pollutant concentration predictions: Method development and evaluation. *Environmental Pollution*, 231, 997-1004. https://doi.org/10.1016/j.envpol.2017.08.114
- Liu, J., Weng, F., Li, Z., & Cribb, M. C. (2019). Hourly PM_{2.5} estimates from a geostationary satellite based on an ensemble learning algorithm and their spatiotemporal patterns over central east China. *Remote Sensing*, 11(18), 2120. https://doi.org/10.3390/rs11182120
- Liu, Y., Franklin, M., Kahn, R., & Koutrakis, P. (2007). Using aerosol optical thickness to predict ground-level PM_{2.5} concentrations in the St. Louis area: A comparison between MISR and MODIS. *Remote Sensing of Environment*, 107(1-2), 33-44. https://doi.org/10.1016/j.rse.2006.05.022
- Liu, Y., Paciorek, C. J., & Koutrakis, P. (2009). Estimating regional spatial and temporal variability of PM_{2.5} concentrations using satellite data, meteorology, and land use information. *Environmental Health Perspectives*, 117(6), 886-892. https://doi.org/10.1289/ehp.0800123
- Liu, Y., Sarnat, J. A., Kilaru, V., Jacob, D. J., & Koutrakis, P. (2005). Estimating ground-level PM2. 5 in the eastern United States using satellite remote sensing. *Environmental Science* & *Technology*, 39(9), 3269-3278. <u>https://doi.org/10.1021/es049352m</u>
- Lu, J. G. (2020). Air pollution: A systematic review of its psychological, economic, and social effects. *Current Opinion in Psychology*, 32, 52-65. <u>https://doi.org/10.1016/j.copsyc.2019.06.024</u>
- Lu, J., Li, B., Li, H., & Al-Barakani, A. (2021). Expansion of city scale, traffic modes, traffic congestion, and air pollution. *Cities*, 108, 102974. <u>https://doi.org/10.1016/j.cities.2020.102974</u>
- Lv, Y., Duan, Y., Kang, W., Li, Z., & Wang, F. Y. (2014). Traffic flow prediction with big data: A deep learning approach. *IEEE Transactions on Intelligent Transportation Systems*, 16(2), 865-873. <u>https://doi.org/10.1109/TITS.2014.2345663</u>
- Mao, L., Qiu, Y., Kusano, C., & Xu, X. (2012). Predicting regional space-time variation of PM_{2.5} with land-use regression model and MODIS data. *Environmental Science and Pollution Research*, 19, 128-138. <u>https://doi.org/10.1007/s11356-011-0546-9</u>
- Masroor, K., Fanaei, F., Yousefi, S., Raeesi, M., Abbaslou, H., Shahsavani, A., & Hadei, M. (2020). Spatial modelling of PM_{2.5} concentrations in Tehran using Kriging and inverse distance weighting (IDW) methods. *Journal of Air Pollution and Health*, 5(2), 89-96. https://doi.org/10.18502/japh.v5i2.4237
- Mellit, A., & Pavan, A. M. (2010). A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar Energy*, 84(5), 807-821. <u>https://doi.org/10.1016/j.solener.2010.02.006</u>
- Meng, X., Fu, Q., Ma, Z., Chen, L., Zou, B., Zhang, Y., ... & Liu, Y. (2016). Estimating ground-level PM10 in a Chinese city by combining satellite data, meteorological

information and a land use regression model. *Environmental Pollution*, 208, 177-184. https://doi.org/10.1016/j.envpol.2015.09.042

- Meyer, H., Kühnlein, M., Appelhans, T., & Nauss, T. (2016). Comparison of four machine learning algorithms for their applicability in satellite-based optical rainfall retrievals. *Atmospheric Research, 169, 424-433.* https://doi.org/10.1016/j.atmosres.2015.09.021
- Miri, M., Ghassoun, Y., Dovlatabadi, A., Ebrahimnejad, A., & Löwner, M. O. (2019). Estimate annual and seasonal PM₁, PM_{2.5} and PM₁₀ concentrations using land use regression model. *Ecotoxicology and Environmental Safety*, 174, 137-145. https://doi.org/10.1016/j.ecoenv.2019.02.070
- Mishra, D., & Goyal, P. (2015). Development of artificial intelligence based NO₂ forecasting models at Taj Mahal, Agra. *Atmospheric Pollution Research*, 6(1), 99-106. <u>https://doi.org/10.5094/APR.2015.012</u>
- Mohammadi, F., Teiri, H., Hajizadeh, Y., Abdolahnejad, A., & Ebrahimi, A. (2024). Prediction of atmospheric PM_{2.5} level by machine learning techniques in Isfahan, Iran. *Scientific Reports*, 14(1), 2109. <u>https://doi.org/10.1038/s41598-024-52617-z</u>
- Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & PRISMA Group, T. (2009). Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *Annals* of Internal Medicine, 151(4), 264-269. <u>https://doi.org/10.7326/0003-4819-151-4-</u> 200908180-00135
- Moore, D. K., Jerrett, M., Mack, W. J., & Künzli, N. (2007). A land use regression model for predicting ambient fine particulate matter across Los Angeles, CA. *Journal of Environmental Monitoring*, 9(3), 246-252. <u>https://doi.org/10.1039/B615795E</u>
- Moryani, H. T., Kong, S., Du, J., & Bao, J. (2020). Health risk assessment of heavy metals accumulated on PM_{2.5} fractioned road dust from two cities of Pakistan. *International Journal of Environmental Research and Public Health*, 17(19), 7124. <u>https://doi.org/10.3390/ijerph17197124</u>
- Nabavi, S. O., Haimberger, L., & Abbasi, E. (2019). Assessing PM_{2.5} concentrations in Tehran, Iran, from space using MAIAC, deep blue, and dark target AOD and machine learning algorithms. *Atmospheric Pollution Research*, 10(3), 889-903. <u>https://doi.org/10.1016/j.apr.2018.12.017</u>
- Obodoeze, F. C., Nwabueze, C. A., & Akaneme, S. A. (2021). Comparative Evaluation of Machine Learning Regression Algorithms for PM_{2.5} Monitoring. *American Journal of Engineering Research*, 10(12), 19-33.
- Ong, B. T., Sugiura, K., & Zettsu, K. (2016). Dynamically pre-trained deep recurrent neural networks using environmental monitoring data for predicting PM_{2.5}. *Neural Computing* and Applications, 27, 1553-1566. <u>https://doi.org/10.1007/s00521-015-1955-3</u>
- Osimobi, O. J., Yorkor, B., & Nwankwo, C. A. (2019). Evaluation of daily pollutant standard index and air quality index in a university campus in Nigeria using PM₁₀ and PM_{2.5} particulate matter. Journal of Science, *Technology and Environment Informatics*, 7(2), 517-532. <u>https://doi.org/10.18801/jstei.070219.54</u>

- Paciorek, C. J., Liu, Y., Moreno-Macias, H., & Kondragunta, S. (2008). Spatiotemporal associations between GOES aerosol optical depth retrievals and ground-level PM_{2.5}. *Environmental science & technology*, 42(15), 5800-5806. <u>https://doi.org/10.1021/es703181j</u>
- Peng, L., Wang, L., Xia, D., & Gao, Q. (2022). Effective energy consumption forecasting using empirical wavelet transform and long short-term memory. *Energy*, 238, 121756. https://doi.org/10.1016/j.energy.2021.121756
- Perrone, M. G., Gualtieri, M., Consonni, V., Ferrero, L., Sangiorgi, G., Longhin, E., ... & Camatini, M. (2013). Particle size, chemical composition, seasons of the year and urban, rural or remote site origins as determinants of biological effects of particulate matter on pulmonary cells. *Environmental Pollution*, 176, 215-227. https://doi.org/10.1016/j.envpol.2013.01.012
- Pope III, C. A., & Dockery, D. W. (2006). Health effects of fine particulate air pollution: lines that connect. *Journal of the Air & Waste Management Association*, 56(6), 709-742. https://doi.org/10.1080/10473289.2006.10464485
- Qi, Y., Li, Q., Karimian, H., & Liu, D. (2019). A hybrid model for spatiotemporal forecasting of PM_{2.5} based on graph convolutional neural network and long short-term memory. Science of the Total Environment, 664, 1-10. https://doi.org/10.1016/j.scitotenv.2019.01.333
- Quan, T., Liu, X., & Liu, Q. (2010). Weighted least squares support vector machine local region method for nonlinear time series prediction. *Applied Soft Computing*, 10(2), 562-566. <u>https://doi.org/10.1016/j.asoc.2009.08.025</u>
- Reddy, V., Yedavalli, P., Mohanty, S., & Nakhat, U. (2018). Deep air: forecasting air pollution in Beijing, China. *Environmental Science*, 1564.
- Ren, Y., Zhang, Y., & Fan, S. (2024). PM_{2.5} Inversion Based on XGBoost And LightGBM Integrated Models. Proceedings of the 4th International Conference on Environment Resources and Energy Engineering (ICEREE 2024). https://doi.org/10.1051/e3sconf/202452002023
- Ross, Z., Jerrett, M., Ito, K., Tempalski, B., & Thurston, G. D. (2007). A land use regression for predicting fine particulate matter concentrations in the New York City region. *Atmospheric Environment*, 41(11), 2255-2269. https://doi.org/10.1016/j.atmosenv.2006.11.012
- Saeed, S., Hussain, L., Awan, I. A., & Idris, A. (2017). Comparative analysis of different statistical methods for prediction of PM_{2.5} and PM₁₀ concentrations in advance for several hours. IJCSNS International *Journal of Computer Science and Network Security*, 17(11), 45-52. <u>http://ijcsns.org/07_book/html/201711/201711006.html</u>
- Sapankevych, N. I., & Sankar, R. (2009). Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, 4(2), 24-38. https://doi.org/10.1109/MICI.2009.932254

- Sarker, I. H. (2021). Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, 2(6), 420. https://doi.org/10.1007/s42979-021-00815-1
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. Neural Networks, 61, 85-117. <u>https://doi.org/10.1016/j.neunet.2014.09.003</u>
- Shi, Y., Ho, H. C., Xu, Y., & Ng, E. (2018). Improving satellite aerosol optical depth-PM_{2.5} correlations using land use regression with microscale geographic predictors in a highdensity urban context. *Atmospheric Environment*, 190, 23-34. <u>https://doi.org/10.1016/j.atmosenv.2018.07.021</u>
- Shogrkhodaei, S. Z., Razavi-Termeh, S. V., & Fathnia, A. (2021). Spatio-temporal modeling of PM_{2.5} risk mapping using three machine learning algorithms. *Environmental Pollution*, 289, 117859. https://doi.org/10.1016/j.envpol.2021.117859
- Song, Y., Qin, S., Qu, J., & Liu, F. (2015). The forecasting research of early warning systems for atmospheric pollutants: A case in Yangtze River Delta region. *Atmospheric Environment*, 118, 58-69. <u>https://doi.org/10.1016/j.atmosenv.2015.06.032</u>
- Stern, R., Builtjes, P. J. H., Schaap, M., Timmermans, R., Vautard, R., Hodzic, A., ... & Kerschbaumer, A. (2008). A model inter-comparison study focussing on episodes with elevated PM10 concentrations. *Atmospheric Environment*, 42(19), 4567–4588. <u>https://doi.org/10.1016/j.atmosenv.2008.01.068</u>
- Su, J. G., Jerrett, M., Beckerman, B., Wilhelm, M., Ghosh, J. K., & Ritz, B. (2009). Predicting traffic-related air pollution in Los Angeles using a distance decay regression selection strategy. *Environmental Research*, 109(6), 657-670. <u>https://doi.org/10.1016/j.envres.2009.06.001</u>
- Taheri Shahraiyni, H., & Sodoudi, S. (2016). Statistical modeling approaches for PM10 prediction in urban areas; A review of 21st-century studies. *Atmosphere*, 7(2), 15. <u>https://doi.org/10.3390/atmos7020015</u>
- Tay, F. E., & Cao, L. (2001). Application of support vector machines in financial time series forecasting. Omega, 29(4), 309-317. <u>https://doi.org/10.1016/S0305-0483(01)00026-3</u>
- U.S. EPA. (2024). Criteria air pollutants, the National Ambient Air Quality Standards (NAAQS) Table. Available at (accessed: May 2024): <u>https://www.epa.gov/criteria-air-pollutants/naaqs-table</u>
- Van Donkelaar, A., Martin, R. V., Brauer, M., Kahn, R., Levy, R., Verduzco, C., & Villeneuve, P. J. (2010). Global estimates of ambient fine particulate matter concentrations from satellite-based aerosol optical depth: development and application. *Environmental Health Perspectives*, 118(6), 847-855. <u>https://doi.org/10.1289/ehp.0901623</u>
- Vapnik, V. (2013). The nature of statistical learning theory. Springer science & business media. New York: Springer.
- Vicedo-Cabrera, A. M., Biggeri, A., Grisotto, L., Barbone, F., & Catelan, D. (2013). A Bayesian kriging model for estimating residential exposure to air pollution of children living in a high-risk area in Italy. *Geospatial Health*, 8(1), 87-95. https://doi.org/10.4081/gh.2013.57

- Wang, J., & Christopher, S. A. (2003). Intercomparison between satellite-derived aerosol optical thickness and PM_{2.5} mass: Implications for air quality studies. *Geophysical Research Letters*, 30(21). https://doi.org/10.1029/2003GL018174
- Wang, L., Zeng, Y., & Chen, T. (2015). Back propagation neural network with adaptive differential evolution algorithm for time series forecasting. *Expert Systems with Applications*, 42(2), 855-863. <u>https://doi.org/10.1016/j.eswa.2014.08.018</u>
- West, J. J., Cohen, A., Dentener, F., Brunekreef, B., Zhu, T., Armstrong, B., ... & Wiedinmyer, C. (2016). What we breathe impacts our health: improving understanding of the link between air pollution and health. *Environmental Science & Technology*, 50(10), 4895– 4904. https://doi.org/10.1021/acs.est.5b03827
- World Health Organization. (2016). Ambient air pollution: A global assessment of exposure and burden of disease. *Clean Air J*, 26(2). https://iris.who.int/handle/10665/250141
- Wu, C. D., Chen, Y. C., Pan, W. C., Zeng, Y. T., Chen, M. J., Guo, Y. L., & Lung, S. C. C. (2017). Land-use regression with long-term satellite-based greenness index and culturespecific sources to model PM_{2.5} spatial-temporal variability. *Environmental Pollution*, 224, 148-157. <u>https://doi.org/10.1016/j.envpol.2017.01.074</u>
- Xiao, Q., Wang, Y., Chang, H. H., Meng, X., Geng, G., Lyapustin, A., & Liu, Y. (2017). Fullcoverage high-resolution daily PM2. 5 estimation using MAIAC AOD in the Yangtze River Delta of China. *Remote Sensing of Environment*, 199, 437-446. <u>https://doi.org/10.1016/j.rse.2017.07.023</u>
- Xu, Q., Chen, X., Yang, S., Tang, L., & Dong, J. (2021). Spatiotemporal relationship between Himawari-8 hourly columnar aerosol optical depth (AOD) and ground-level PM_{2.5} mass concentration in mainland China. *Science of the Total Environment*, 765, 144241. <u>https://doi.org/10.1016/j.scitotenv.2020.144241</u>
- Xu, X., & Zhang, C. (2020). Estimation of ground-level PM_{2.5} concentration using MODIS AOD and corrected regression model over Beijing, China. *PLoS One*, 15(10), e0240430. <u>https://doi.org/10.1371/journal.pone.0240430</u>
- Xu, Y., Ho, H. C., Wong, M. S., Deng, C., Shi, Y., Chan, T. C., & Knudby, A. (2018). Evaluation of machine learning techniques with multiple remote sensing datasets in estimating monthly concentrations of ground-level PM_{2.5}. *Environmental Pollution*, 242, 1417-1426. <u>https://doi.org/10.1016/j.envpol.2018.08.029</u>
- Xue, Q., Tian, Y., Liu, X., Wang, X., Huang, B., Zhu, H., & Feng, Y. (2022). Potential risks of PM_{2.5}-bound polycyclic aromatic hydrocarbons and heavy metals from inland and marine directions for a marine background site in North China. *Toxics*, 10(1), 32. https://doi.org/10.3390/toxics10010032
- Xue, W., Zhang, J., Zhong, C., Ji, D., & Huang, W. (2020). Satellite-derived spatiotemporal PM_{2.5} concentrations and variations from 2006 to 2017 in China. *Science of the Total Environment*, 712, 134577. https://doi.org/10.1016/j.scitotenv.2019.134577
- Yamins, D. L., & DiCarlo, J. J. (2016). Using goal-driven deep learning models to understand sensory cortex. *Nature Neuroscience*, 19(3), 356-365. https://doi.org/10.1038/nn.4244

- Yan, X., Zang, Z., Luo, N., Jiang, Y., & Li, Z. (2020). New interpretable deep learning model to monitor real-time PM_{2.5} concentrations from satellite data. *Environment International*, 144, 106060. <u>https://doi.org/10.1016/j.envint.2020.106060</u>
- Yang, Q., Yuan, Q., Yue, L., Li, T., Shen, H., & Zhang, L. (2019). The relationships between PM_{2.5} and aerosol optical depth (AOD) in mainland China: About and behind the spatiotemporal variations. *Environmental Pollution*, 248, 526-535. https://doi.org/10.1016/j.envpol.2019.02.071
- Yang, Y., Wang, Z., Cao, C., Xu, M., Yang, X., Wang, K., ... & Shi, Z. (2024). Estimation of PM_{2.5} Concentration across China Based on Multi-Source Remote Sensing Data and Machine Learning Methods. *Remote Sensing*, 16(3), 467. <u>https://doi.org/10.3390/rs16030467</u>
- Yi, L., Mengfan, T., Kun, Y., Yu, Z., Xiaolu, Z., Miao, Z., & Yan, S. (2019). Research on PM_{2.5} estimation and prediction method and changing characteristics analysis under long temporal and large spatial scale-A case study in China typical regions. *Science of the Total Environment*, 696, 133983. <u>https://doi.org/10.1016/j.scitotenv.2019.133983</u>
- Zamani Joharestani, M., Cao, C., Ni, X., Bashir, B., & Talebiesfandarani, S. (2019). PM_{2.5} prediction based on random forest, XGBoost, and deep learning using multisource remote sensing data. *Atmosphere*, 10(7), 373. <u>https://doi.org/10.3390/atmos10070373</u>
- Zhang, J., Zheng, Y., & Qi, D. (2017). Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction. Proceedings of the AAAI Conference on Artificial Intelligence, 31(1). https://doi.org/10.1609/aaai.v31i1.10735
- Zhang, T., He, W., Zheng, H., Cui, Y., Song, H., & Fu, S. (2021). Satellite-based ground PM_{2.5} estimation using a gradient boosting decision tree. *Chemosphere*, 268, 128801. <u>https://doi.org/10.1016/j.chemosphere.2020.128801</u>
- Zhang, X., Chu, Y., Wang, Y., & Zhang, K. (2018). Predicting daily PM_{2.5} concentrations in Texas using high-resolution satellite aerosol optical depth. *Science of the Total Environment*, 631, 904-911. https://doi.org/10.1016/j.scitotenv.2018.02.255
- Zhou, Y., Chang, F. J., Chang, L. C., Kao, I. F., Wang, Y. S., & Kang, C. C. (2019). Multioutput support vector machine for regional multi-step-ahead PM_{2.5} forecasting. *Science of the Total Environment*, 651, 230-240. <u>https://doi.org/10.1016/j.scitotenv.2018.09.111</u>
- Zou, B., Fang, X., Feng, H., & Zhou, X. (2021). Simplicity versus accuracy for estimation of the PM_{2.5} concentration: A comparison between LUR and GWR methods across time scales. *Journal of Spatial Science*, 66(2), 279-297. https://doi.org/10.1080/14498596.2019.1624203
- Zuo, X., Guo, H., Shi, S., & Zhang, X. (2020). Comparison of six machine learning methods for estimating PM_{2.5} concentration using the Himawari-8 aerosol optical depth. *Journal of the Indian Society of Remote Sensing*, 48(9), 1277-1287. <u>https://doi.org/10.1007/s12524-020-01154-z</u>