



## Improvement of Downscaling of Aerosol Optical Depth Using a Hybrid Approach of Machine Learning and Deep Learning: A Case Study in Zanzan County

Ali Sadeghnezhad<sup>1</sup>, Ali Shamsoddini<sup>2</sup>

1. Department of Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran. E-mail: [alisadeghnezhad@modares.ac.ir](mailto:alisadeghnezhad@modares.ac.ir)
2. Corresponding Author, Department of Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran. E-mail: [ali.shamsoddini@modares.ac.ir](mailto:ali.shamsoddini@modares.ac.ir)

### Article Info

#### Article type:

Research Article

#### Article history:

Received: 22 March 2025

Revised: 30 July 2025

Accepted: 29 April 2026

Published: 29 April 2026

#### Keywords:

Downscaling,  
Machine learning,  
Deep learning,  
Aerosol Optical Depth,  
MODIS,  
Landsat-8.

### ABSTRACT

**Objective:** “Atmospheric Optical Depth (AOD) product effectiveness is limited for local-scale applications, particularly in urban air pollution monitoring, due to its coarse spatial resolution. This study aims to improve the accuracy of AOD estimation by leveraging Landsat remote sensing data and integrating advanced machine learning and deep learning techniques.”

**Methods:** To evaluate the accuracy of AOD estimation, six algorithms were tested: Multiple Linear Regression, Support Vector Regression (SVR), Random Forest Regression, Extra Trees Regression, Deep Multilayer Perceptron, and Deep Forest Regression. A decision-level fusion approach based on averaging was employed to integrate the results. The study utilized albedo data, 1 km resolution AOD products from the MODIS sensor, and top-of-atmosphere reflectance data from the OLI sensor (with 7 bands). Additionally, 180 AOD measurements from the AERONET (Aerosol Robotic Network) were used for training and validation. The study period covered the years 2014 to 2022.

**Results:** All algorithms demonstrated relatively strong performance, with  $R^2$  values ranging from 0.73 to 0.86 and Root Mean Square Error (RMSE) values between 0.185 and 0.414. The Deep Multilayer Perceptron algorithm achieved the best performance, although the differences among the algorithms were minor. The decision-level fusion approach improved estimation accuracy, achieving an  $R^2$  of 0.86 and reducing RMSE to 0.202.

**Conclusions:** The proposed method, which combines machine learning and deep learning techniques with Landsat-8 imagery, shows significant potential for generating high-resolution AOD datasets. This approach can enhance the accuracy of AOD estimation, making it more suitable for local-scale applications such as urban air quality monitoring.


**Cite this article:** Sadeghnezhad, A., & Shamsoddini, A. (2026). Improvement of Downscaling of Aerosol Optical Depth Using a Hybrid Approach of Machine Learning and Deep Learning: A Case Study in Zanzan County. *Journal of Remote Sensing and GIS Applications in Environmental Sciences*, 6 (19), 19-30. <http://doi.org/10.22034/rsgi.2026.66463.1128>



© The Author(s).

DOI: <http://doi.org/10.22034/rsgi.2026.66463.1128>

Publisher: University of Tabriz.



## Introduction

Monitoring Atmospheric Optical Depth (AOD) is of significant importance due to the critical role of atmospheric aerosols in influencing the radiation reaching the Earth's surface (Liang et al., 2022; Rendana et al., 2022; Tao et al., 2017a; X. Zhu et al., 2022a). AOD is a key parameter in studies related to global climatology, atmospheric pollutants, forest fires, and atmospheric corrections for remote sensing imagery to derive surface reflectance (Aube et al., 2000). However, the low spatial resolution of current AOD datasets, coupled with their significant deviation from ground-based measurements, poses a major challenge in accurately estimating surface energy. Additionally, each downscaling method has its own strengths and weaknesses depending on the computational algorithms employed. In statistical downscaling, it is assumed that there is a meaningful spatial and temporal relationship between AOD concentration and high-resolution satellite imagery. Consequently, linear and non-linear methods are used to model the relationship between these datasets (H. H. Chang et al., 2014).

Torres et al. were among the first to propose an AOD downscaling method by combining Support Vector Regression (SVR) and kriging. Their study utilized MACC datasets, ground-based meteorological data from 213 stations, and AERONET data from Spain. The SVR method demonstrated promising results, with the estimated error from the modeled data being lower than that of the MACC data based on AERONET measurements. The validation metric, Root Mean Absolute Error (RMSE), indicated that the predicted data had an error of 10.2%, outperforming the MACC data, which had an error of 18.5% (Antonanzas-Torres et al., 2014a). However, this study had limitations, such as the lack of correlation metrics between predicted and validation data, and the exclusive use of MACC data with a spatial resolution of 20 km, despite the availability of MODIS data with a 10 km resolution.

High-resolution AOD data are essential for identifying local pollution caused by human activities, particularly in the context of rapid urbanization and associated air pollution. Previous studies have explored the feasibility of using various remote sensing data sources for high-resolution AOD estimation in urban areas. For example, Sun et al. estimated Landsat-8 AOD at a 500-meter resolution using relationships between AOD, surface reflectance, and top-of-atmosphere (TOA) reflectance based on radiative transfer simulations (Sun et al., 2016). However, a limitation of this approach is that atmospheric corrections are applied uniformly across the entire satellite image, which may not account for spatial variations in AOD concentration, thus limiting the reliability of the results.

To address these limitations, two primary methods for MODIS AOD retrieval were developed by 2018: the Deep Blue (DB) method, which produces 10 km resolution AOD products, and the Dark Target (DT) method, which generates 3 km resolution AOD products. However, these methods have their own drawbacks, such as the low spatial resolution of DB and the reduced accuracy of AOD estimation over densely vegetated areas in DT. Bilal et al. attempted to overcome these limitations by integrating data at the decision level. They resampled 10 km DB data to 3 km using the nearest-neighbor method and then applied the SDS method for data fusion. Validation using AERONET data from 2008 to 2012 showed that the RMSE for the 3 km DT method was 0.54, while the fused method achieved an RMSE of 0.26, indicating significant improvement (Bilal et al., 2018). However, the reliance on data redundancy for resampling and the limited effectiveness of the SDS method highlight the need for more robust decision-level fusion techniques.

In 2019, NASA introduced a 1 km resolution AOD product based on multi-angle imaging (MAIAC), which provides daily global AOD estimates. However, cloud cover and unfavorable surface reflectance conditions often lead to significant data gaps. To address this, Li et al. used an artificial neural network to fill missing data by converting daily data into weekly composites, thereby creating cloud-free images. The model was trained using auxiliary data, including hourly PM<sub>2.5</sub>, PM<sub>10</sub>, NO<sub>2</sub>, and SO<sub>2</sub> measurements, which, despite their lower spatial resolution, provided high temporal accuracy. The results showed a correlation of 0.85 with the original AOD data, with fewer missing values (C. Li et al., 2020). However, most of these studies were limited to small regions, raising concerns about the generalizability of the algorithms to other latitudes.

NASA also developed the Land Surface Reflectance Code (LaSRC) for global atmospheric correction of Landsat-8 imagery, based on the 6SV radiative transfer model. LaSRC uses reflectance ratios derived from MODIS and MISR data at a 5 km resolution to retrieve AOD at 550 nm for each 30-meter Landsat-8 pixel. However, several factors, such as aerosol type, land cover variability, and human activities, introduce



uncertainties in AOD retrieval. These factors are often oversimplified, for example, by assuming a Lambertian surface and constant aerosol type, leading to significant uncertainties in AOD estimation.

One potential solution to these challenges is the incorporation of prior knowledge and the use of advanced machine learning and deep learning algorithms to improve AOD estimation. Several studies have demonstrated the effectiveness of neural networks and machine learning in modeling the relationship between satellite observations and ground-based AOD measurements, yielding satisfactory results. However, these methods also have their limitations, which can reduce their overall effectiveness. Therefore, a more efficient approach is to integrate results at the decision level, leveraging the strengths of each model to enhance AOD estimation accuracy. By combining data and algorithms, the precision of results can be improved at the decision level. Thus, the objective of this study is to compare various machine learning and deep learning methods and propose an efficient approach for integrating their results to downscale AOD values effectively.

### Materials and Methods

In this study, we used satellite observations from Landsat 8 and MODIS, in combination with AERONET ground station data, to estimate and downscale Aerosol Optical Depth (AOD) over Zanjan County during 2014–2022. All data preprocessing was performed on the Google Earth Engine platform. Atmospheric correction was applied to Landsat imagery, and MODIS AOD data were resampled to match Landsat's spatial resolution. Ground-based AOD measurements from AERONET and hourly air pollution data (PM<sub>2.5</sub>, PM<sub>10</sub>, NO<sub>2</sub>, SO<sub>2</sub>) were used for model training and validation. To ensure spatial and temporal consistency, appropriate resampling and filtering techniques were employed. Cloud-contaminated pixels were masked out using Landsat quality bands. The final dataset was used to train both machine learning and deep learning models for improving AOD downscaling performance in the study area.

### Results

In this study, the performance of six machine learning and deep learning algorithms for estimating Atmospheric Optical Depth (AOD) was evaluated. The algorithms examined include: Multiple Linear Regression (MLR), Support Vector Regression (SVR), Random Forest Regression (RF), Extra Trees Regression (ET), Deep Multilayer Perceptron (MLP), and Deep Forest Regression (DFR). The evaluation was conducted using the coefficient of determination ( $R^2$ ) and Root Mean Square Error (RMSE) metrics. Table 1 summarizes the performance of each algorithm. The  $R^2$  values ranged from 0.73 to 0.86, indicating the models' capability to explain and predict AOD values. The RMSE values varied between 0.185 and 0.414, reflecting differences in prediction accuracy among the algorithms. Specifically, the MLP algorithm demonstrated the best performance, with an  $R^2$  of 0.889 and an RMSE of 0.279.

To further enhance AOD estimation accuracy, a decision-level fusion approach based on averaging was employed. This method increased the  $R^2$  to 0.86 and reduced the RMSE to 0.202, highlighting the potential of fusion techniques for generating high-resolution AOD datasets.

**Superior Performance of Deep Multilayer Perceptron (MLP):** The MLP algorithm achieved the lowest Mean Squared Error (MSE) of 0.078 and RMSE of 0.279, outperforming the other algorithms. It also exhibited a high correlation coefficient ( $R^2 = 0.88$ ) between predicted and observed AOD values.

**Competitive Performance of Other Machine Learning Algorithms:** The other machine learning algorithms, including SVR, RF, ET, MLR, and DFR, also demonstrated acceptable performance. Their RMSE values ranged from 0.185 (for MLR) to 0.414 (for RF).

**Improved Accuracy with Decision Fusion:** The decision-level fusion approach significantly improved AOD estimation accuracy, achieving an RMSE of 0.202 and an  $R^2$  of 0.86. This underscores the effectiveness of fusion methods in enhancing prediction precision.

**Greater Stability of Decision Fusion:** The lower standard deviation (0.06) for decision fusion indicates greater stability compared to individual algorithms, making it more robust to input data variability.

**Strengths and Weaknesses of Algorithms:** While MLP showed the best average performance, its error occasionally increased to 0.43. In contrast, MLR, despite its higher average RMSE, exhibited a lower minimum error (0.16) compared to MLP.



In summary, machine learning and deep learning methods generally provided higher accuracy, while linear regression also demonstrated reasonable performance. By integrating results at the decision level, the accuracy and reliability of AOD estimation were significantly improved.

### Conclusion

This study aimed to improve the downscaling of AOD by integrating machine learning and deep learning methods. The results revealed that both linear and nonlinear factors significantly influence AOD modeling, with different models capturing these effects in varying ways. The MLP model demonstrated superior performance in AOD downscaling, although other methods also exhibited notable strengths. Key findings include:

The MLP model is highly effective for AOD downscaling.

Integrating results from linear and nonlinear models significantly enhances AOD downscaling accuracy.


These findings underscore the importance of combining diverse modeling approaches to achieve more accurate and reliable AOD estimates. Future work should focus on refining these methods and exploring their applicability across different regions and datasets.

### References

- Andreae, M. O., & Rosenfeld, D. (2008). Aerosol–cloud–precipitation interactions. Part 1. The nature and sources of cloud-active aerosols. *Earth-Science Reviews*, 89(1), 13–41. <https://doi.org/10.1016/j.earscirev.2008.03.001>
- Antonanzas-Torres, F., Sanz-Garcia, A., Martínez-de-Pisón, F. J., Antonanzas, J., Perpiñán-Lamigueiro, O., & Polo, J. (2014). Towards downscaling of aerosol gridded dataset for improving solar resource assessment, an application to Spain. *Renewable Energy*, 71, 534–544. <https://doi.org/10.1016/j.renene.2014.06.010>
- Aube, M., O'Neill, N. T., & Royer, A. (2000). Modelling of aerosol optical depth variability at regional scale. IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium. Taking the Pulse of the Planet: The Role of Remote Sensing in Managing the Environment. Proceedings (Cat. No.00CH37120), 1, 199–201 vol.1. <https://doi.org/10.1109/IGARSS.2000.860467>
- Bilal, M., Qiu, Z., Campbell, J. R., Spak, S. N., Shen, X., & Nazeer, M. (2018). A New MODIS C6 Dark Target and Deep Blue Merged Aerosol Product on a 3 km Spatial Grid. *Remote Sensing*, 10(3), Article 3. <https://doi.org/10.3390/rs10030463>
- Chang, H. H., Hu, X., & Liu, Y. (2014). Calibrating MODIS aerosol optical depth for predicting daily PM<sub>2.5</sub> concentrations via statistical downscaling. *Journal of Exposure Science & Environmental Epidemiology*, 24(4), Article 4. <https://doi.org/10.1038/jes.2013.90>
- Charlson, R. J., Schwartz, S. E., Hales, J. M., Cess, R. D., Coakley, J. A., Hansen, J. E., & Hofmann, D. J. (1992). Climate forcing by anthropogenic aerosols. *Science (New York, N.Y.)*, 255(5043), 423–430. <https://doi.org/10.1126/science.255.5043.423>
- Gunaseelan, I., Bhaskar, B. V., & Muthuchelian, K. (2014). The effect of aerosol optical depth on rainfall with reference to meteorology over metro cities in India. *Environmental Science and Pollution Research*, 21(13), 8188–8197. <https://doi.org/10.1007/s11356-014-2711-4>
- Holben, B. N., Eck, T. F., Slutsker, I., Tanré, D., Buis, J. P., Setzer, A., Vermote, E., Reagan, J. A., Kaufman, Y. J., Nakajima, T., Lavenu, F., Jankowiak, I., & Smirnov, A. (1998). AERONET—A Federated Instrument Network and Data Archive for Aerosol Characterization. *Remote Sensing of Environment*, 66(1), 1–16. [https://doi.org/10.1016/S0034-4257\(98\)00031-5](https://doi.org/10.1016/S0034-4257(98)00031-5)
- Li, K., Bai, K., Li, Z., Guo, J., & Chang, N.-B. (2022). Synergistic data fusion of multimodal AOD and air quality data for near real-time full coverage air pollution assessment. *Journal of Environmental Management*, 302, 114121. <https://doi.org/10.1016/j.jenvman.2021.114121>
- Li, L., Franklin, M., Girguis, M., Lurmann, F., Wu, J., Pavlovic, N., Breton, C., Gilliland, F., & Habre, R. (2020). Spatiotemporal imputation of MAIAC AOD using deep learning with downscaling. *Remote Sensing of Environment*, 237, 111584. <https://doi.org/10.1016/j.rse.2019.111584>



- Liang, T., Liang, S., Zou, L., Sun, L., Li, B., Lin, H., He, T., & Tian, F. (2022). Estimation of Aerosol Optical Depth at 30 m Resolution Using Landsat Imagery and Machine Learning. *Remote Sensing*, 14(5), Article 5. <https://doi.org/10.3390/rs14051053>
- Pöschl, U. (2005). Atmospheric Aerosols: Composition, Transformation, Climate and Health Effects. *Angewandte Chemie International Edition*, 44(46), 7520–7540. <https://doi.org/10.1002/anie.200501122>
- Shao, L., Li, G., Zhao, Q., Li, Y., Sun, Y., Wang, W., Cai, C., Chen, W., Liu, R., Luo, W., Yin, X., & Lee, X. (2020). The fertilization effect of global dimming on crop yields is not attributed to an improved light interception. *Global Change Biology*, 26(3), 1697–1713. <https://doi.org/10.1111/gcb.14822>
- Sokolik, I. N., & Toon, O. B. (1996). Direct radiative forcing by anthropogenic airborne mineral aerosols. *Nature*, 381(6584), Article 6584. <https://doi.org/10.1038/381681a0>
- Wang, X., Wu, J., Chen, M., Xu, X., Wang, Z., Wang, B., Wang, C., Piao, S., Lin, W., Miao, G., Deng, M., Qiao, C., Wang, J., Xu, S., & Liu, L. (2018). Field evidences for the positive effects of aerosols on tree growth. *Global Change Biology*, 24(10), 4983–4992. <https://doi.org/10.1111/gcb.14339>
- Zhou, H., Yue, X., Lei, Y., Tian, C., Ma, Y., & Cao, Y. (2021). Aerosol radiative and climatic effects on ecosystem productivity and evapotranspiration. *Current Opinion in Environmental Science & Health*, 19, 100218. <https://doi.org/10.1016/j.coesh.2020.10.006>



## بهبود ریزمقیاس‌نمایی پارامتر عمق نوری آئروسول با تلفیق روش‌های یادگیری ماشین و یادگیری عمیق: مطالعه موردی شهرستان زنجان

علی صادق‌نژاد<sup>۱</sup>، علی شمس‌الدینی<sup>۲\*</sup>

۱. دانشجوی دکتری، گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم انسانی، دانشگاه تربیت مدرس، تهران، ایران. رایانامه: [alisadeghnezhad@modares.ac.ir](mailto:alisadeghnezhad@modares.ac.ir)

۲. نویسنده مسئول، دانشیار، گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم انسانی، دانشگاه تربیت مدرس، تهران، ایران. رایانامه: [ali.shamsoddini@modares.ac.ir](mailto:ali.shamsoddini@modares.ac.ir)

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	<b>هدف:</b> کارایی محصولات عمق نوری آئروسول <sup>۱</sup> برای کاربردهای محلی، به‌ویژه در زمینه پایش آلودگی هوای شهری، به‌دلیل قدرت تفکیک مکانی پایین محدود است. این مطالعه با هدف بهبود صحت تخمین عمق نوری آئروسول با استفاده از داده‌های سنجش از دور لندست و تلفیق روش‌های پیشرفته یادگیری ماشین و یادگیری عمیق انجام شده است.
تاریخ دریافت: ۱۴۰۴/۰۱/۰۲	<b>روش‌ها:</b> شش الگوریتم شامل رگرسیون خطی چند متغیره <sup>۲</sup> ، رگرسیون ماشین بردار پشتیبان <sup>۳</sup> ، رگرسیون جنگل تصادفی <sup>۴</sup> ، درخت تصمیم رگرسیون <sup>۵</sup> ، پرسپترون چندلایه عمیق <sup>۶</sup> و رگرسیون جنگل عمیق <sup>۷</sup> و برای ادغام نتایج، از روش تلفیق در سطح تصمیم‌گیری مبتنی بر میانگین‌گیری استفاده شد. داده‌های مورد استفاده شامل داده‌های آلبدو، محصولات عمق نوری آئروسول با وضوح ۱ کیلومتر از سنجنده مادیس و داده‌های بازتاب بالایی اتمسفر از ماهواره لندست-۸ (با ۷ باند) بودند.
تاریخ بازنگری: ۱۴۰۴/۰۵/۰۸	<b>نتایج:</b> تمامی الگوریتم‌ها عملکرد نسبتاً خوبی داشتند، به‌طوری که مقادیر $R^2$ بین ۰/۷۳ تا ۰/۸۶ و مقادیر ریشه میانگین مربعات خطا بین ۰/۱۸۵ تا ۰/۴۱۴ متغیر بود. روش تلفیق در سطح تصمیم‌گیری صحت تخمین را بهبود بخشید و مقادیر $R^2$ برابر با ۰/۸۶ و ریشه میانگین مربعات خطا برابر با ۰/۲۰۲ حاصل گردید.
تاریخ پذیرش: ۱۴۰۵/۰۲/۰۹	<b>نتیجه‌گیری:</b> روش پیشنهادی که ترکیبی از تکنیک‌های یادگیری ماشین و یادگیری عمیق با تصاویر لندست-۸ است، پتانسیل بالایی برای تولید مجموعه داده‌های عمق نوری آئروسول با وضوح بالا نشان می‌دهد. این رویکرد می‌تواند دقت تخمین عمق نوری آئروسول را افزایش دهد و آن را برای کاربردهای محلی مانند پایش کیفیت هوای شهری مناسب‌تر کند.
تاریخ انتشار: ۱۴۰۵/۰۲/۰۹	کلیدواژه‌ها: ریزمقیاس‌نمایی، یادگیری ماشین، یادگیری عمیق، عمق نوری آئروسول، سنجنده مادیس، لندست-۸.

**استناد:** صادق‌نژاد، علی و شمس‌الدینی، علی (۱۴۰۵). بهبود ریزمقیاس‌نمایی پارامتر عمق نوری آئروسول با تلفیق روش‌های یادگیری ماشین و یادگیری عمیق: مطالعه موردی شهرستان زنجان. کاربرد سنجش از دور و سیستم اطلاعات جغرافیایی در علوم محیطی، ۶ (۱۹)، ۳۰-۱۹.

<http://doi.org/10.22034/rsgi.2026.66463.1128>



© نویسندگان.

ناشر: دانشگاه تبریز.

1. Aerosol Optical Depth
2. Multiple Linear Regression
3. Support Vector Regression
4. Random Forest regression
5. Decision Tree Regression
6. Deep Neural Multilayer Perceptron
7. Deep Forest regression

## مقدمه

پایش عمق نوری آئروسول<sup>۱</sup> به دلیل نقش مهم ذرات معلق در تغییر تابش رسیده به سطح زمین، یکی از پارامترهای کلیدی در مطالعات اقلیم‌شناسی، کیفیت هوا، مدل‌سازی آتش‌سوزی جنگل‌ها و همچنین در روشهای تصحیح اتمسفری تصاویر سنجش از دور محسوب می‌شود (Aube et al., 2000; Liang et al., 2022; Rendana et al., 2022; Tao et al., 2017; Zhu et al., 2022). با این حال، قدرت تفکیک مکانی پایین داده‌های عمق نوری آئروسول ماهواره‌ای و اختلافات آن‌ها با اندازه‌گیری‌های زمینی، چالش‌های جدی در ارزیابی دقیق توزیع آلاینده‌ها و انرژی رسیده به سطح زمین ایجاد می‌کند. در دهه‌های اخیر، روش‌های ریزمقیاس‌نمایی<sup>۲</sup> به عنوان راهکاری برای ارتقای قدرت تفکیک مکانی محصولات عمق نوری آئروسول مطرح شده‌اند. این روش‌ها بر فرض وجود ارتباط آماری معنادار میان داده‌های عمق نوری آئروسول با قدرت تفکیک مکانی پایین و ویژگی‌های استخراج‌شده از تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالاتر استوارند (Chang et al., 2014). در این راستا، ترکیب الگوریتم‌های یادگیری ماشین و میان‌یابی مکانی، نظیر ماشین بردار پشتیبان و کریجینگ، توانسته‌اند عملکرد قابل قبولی در برآورد عمق نوری آئروسول ارائه دهند (Antonanzas-Torres et al., 2014). با این حال، محدودیت‌هایی چون نبود اطلاعات همبستگی، استفاده صرف از داده‌های با قدرت تفکیک مکانی پایین (مانند MACC با قدرت تفکیک مکانی ۲۰ کیلومتر) و نادیده‌گیری داده‌های موجود با قدرت تفکیک مکانی بالاتر (مانند مادیس با قدرت تفکیک مکانی یک کیلومتر تا ۱۰ کیلومتر) از نقاط ضعف این دسته مطالعات است. داده‌های عمق نوری آئروسول با وضوح بالا برای شناسایی آلودگی‌های محلی، به‌ویژه در مناطق شهری با رشد سریع و فعالیت‌های انسانی گسترده، ضروری هستند. تحقیقات متعددی مانند (Sun et al., 2016)، تلاش کرده‌اند تا با استفاده از روابط بین بازتاب سطحی، بازتاب سطحی در بالای اتمسفر و عمق نوری آئروسول، داده‌های لندست-۸ (Landsat-8) را برای تخمین عمق نوری آئروسول با قدرت تفکیک مکانی ۵۰۰ متری به کار گیرند. هرچند این روش‌ها با چالش‌هایی مانند تصحیح اتمسفری یکنواخت و فرض غلظت ثابت آئروسول در سطح تصویر مواجه‌اند. با هدف بهبود عملکرد این روش‌ها، محصولات مختلفی از مادیس توسعه یافته‌اند، از جمله محصول Deep Blue با قدرت تفکیک مکانی ۱۰ کیلومتر و محصول Dark Target با قدرت تفکیک مکانی ۳ کیلومتر که هر یک مزایا و محدودیت‌های خاص خود را دارند. برای مثال، (Bilal et al., 2018) با استفاده از روش‌های تلفیق در سطح تصمیم‌گیری و بازنمونه‌برداری، موفق به کاهش RMSE از ۰/۵۴ به ۰/۲۶ شدند، اما همچنان از الگوریتم‌های ساده مانند SMS استفاده شده بود که در کنار عدم لحاظ نمودن فیزیک آئروسول‌ها، صحت تخمین را محدود می‌کردند. در ادامه، الگوریتم MAIAC با ارائه داده‌های عمق نوری آئروسول با قدرت تفکیک مکانی ۱ کیلومتری و به‌روزرسانی روزانه توسط ناسا، گام بزرگی در این حوزه محسوب شد. هرچند وجود ابر و بازتاب نامطلوب سطحی، کیفیت داده‌ها را کاهش داده و نیاز به روش‌های مکمل را بیشتر کرده است. برای رفع این مشکل، (Li et al., 2020) از شبکه‌های عصبی مصنوعی برای برطرف نمودن مشکل داده‌های ناقص و ایجاد نقشه‌های یک‌دست عمق نوری آئروسول استفاده کردند و به همبستگی ۰/۸۵ با داده‌های آئرونِت<sup>۳</sup> دست یافتند.

یکی از منابع معتبر و گسترده برای اندازه‌گیری‌های زمینی عمق نوری آئروسول، شبکه جهانی سنجش آئروسول موسوم به آئرونِت است که توسط NASA و مؤسسه علوم فضایی فرانسه راه‌اندازی شده است. این شبکه شامل مجموعه‌ای از فوتومترهای خورشیدی با دقت بالا در سراسر جهان است که داده‌های عمق نوری آئروسول را در طول موج‌های مختلف با دقت زمانی بالا ثبت می‌کنند (Holben et al., 1998). داده‌های آئرونِت به دلیل صحت بالا، معمولاً به عنوان مرجع برای اعتبارسنجی محصولات ماهواره‌ای و مدل‌های پیش‌بینی ضخامت نوری آئروسول استفاده می‌شوند. با این حال، یکی از چالش‌های عمده در استفاده از داده‌های آئرونِت در ایران، کمبود شدید ایستگاه‌های فعال در کشور است. در حال حاضر، تنها تعداد محدودی ایستگاه آئرونِت در

1. Aerosol Optical Depth – AOD

2. downscaling

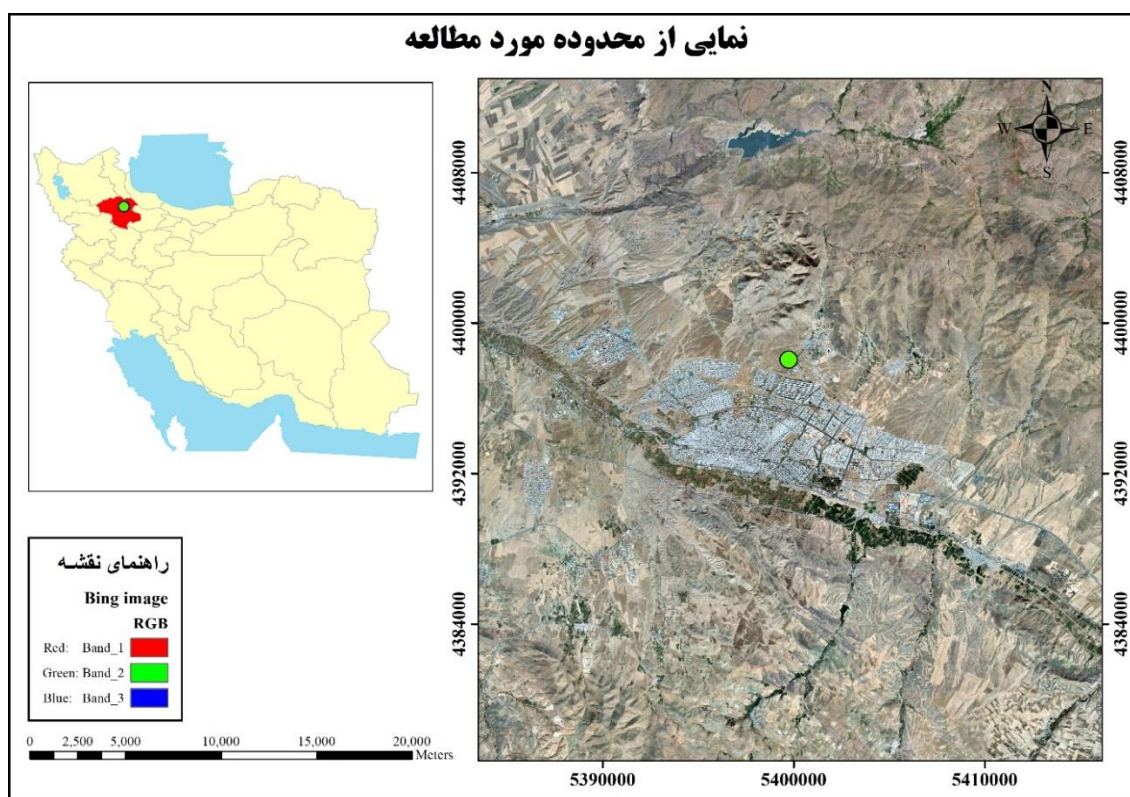
3. AERONET (AErosol RObotic NETwork)

ایران ثبت شده که برخی از آن‌ها نیز فعال نبوده یا داده‌های آن‌ها ناقص است. در این مطالعه، داده‌های ایستگاه آئروسول مستقر در نزدیکی زنجان به‌عنوان تنها ایستگاه در دسترس و دارای داده‌های تاریخی کافی مورد استفاده قرار گرفت. هرچند اتکاء به یک ایستگاه زمینی ممکن است از نظر پوشش مکانی محدودیت‌هایی ایجاد کند، اما وجود داده‌های پیوسته و بلندمدت این ایستگاه از سال‌های گذشته، امکان آموزش مناسب الگوریتم‌های یادگیری ماشین و یادگیری عمیق را فراهم کرده و تا حد زیادی کمبود سایر داده‌های زمینی را جبران نموده است. این موضوع ضرورت توسعه شبکه‌های سنجش زمینی در ایران را نیز برجسته می‌سازد.

الگوریتم‌های مختلف یادگیری ماشین و یادگیری عمیق نظیر جنگل تصادفی، *Gradient Boosting* و شبکه‌های عصبی کانولوشنی، در مطالعات مختلف نتایج رضایت‌بخشی در تخمین عمق نوری آئروسول ارائه داده‌اند. با این حال، هر کدام از این الگوریتم‌ها محدودیت‌هایی در زمینه تعمیم‌پذیری، نیاز به تنظیمات دقیق پارامترها و حساسیت به نویز دارند. از این رو، تلفیق نتایج این مدل‌ها در سطح تصمیم‌گیری می‌تواند رویکرد مؤثرتری برای بهره‌گیری از نقاط قوت هر الگوریتم و کاهش ضعف‌های آن باشد که در این پژوهش به‌عنوان هدف اصلی مورد بررسی قرار گرفته است.

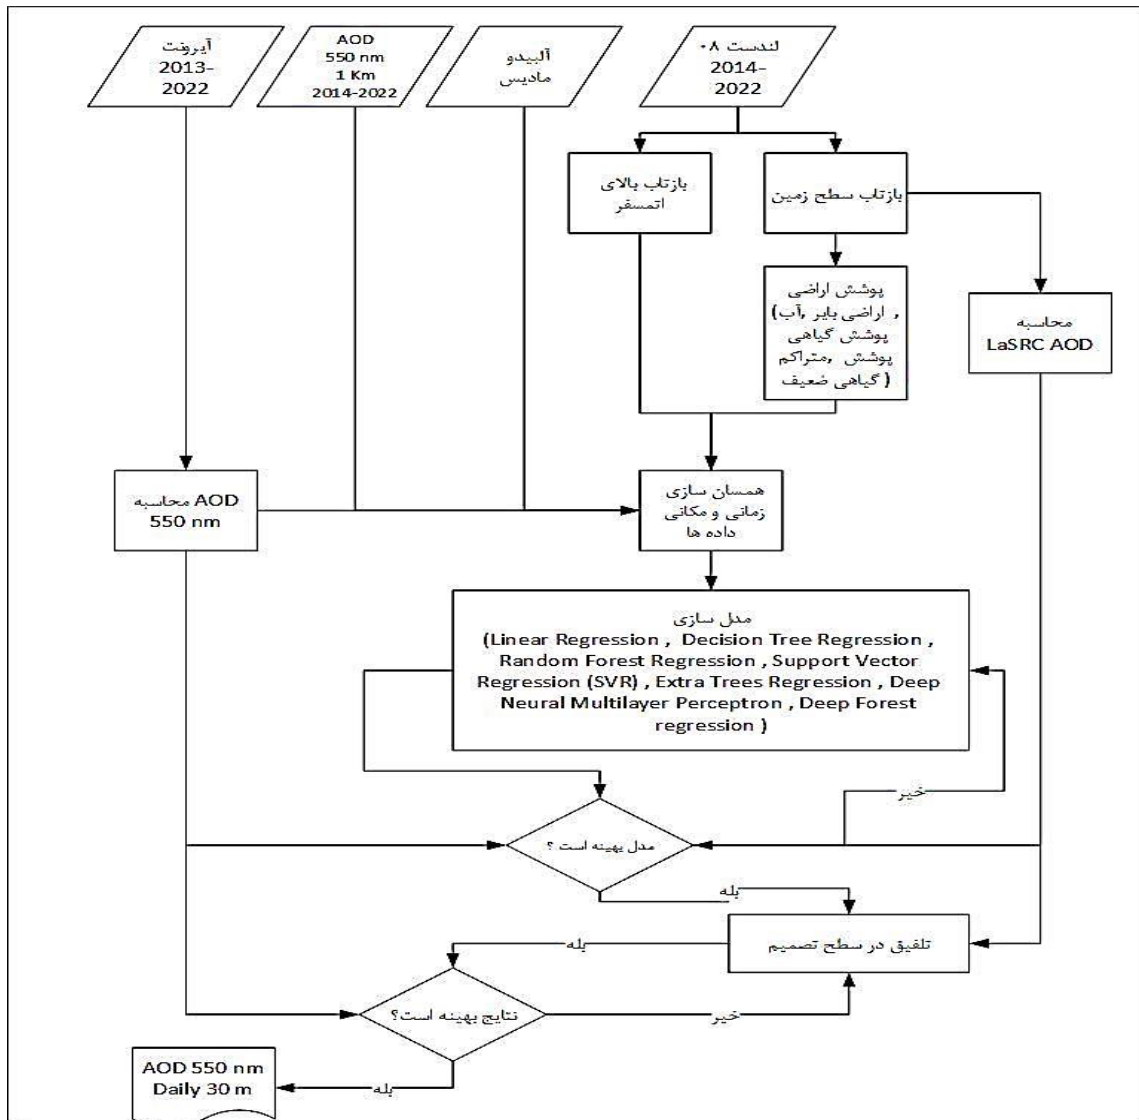
## روش پژوهش

با توجه به این موضوع که برای اعتبار سنجی نتایج نیاز به داده‌های زمینی می‌باشد، محدوده مورد مطالعه در اطراف شهر زنجان در نظر گرفته شد زیرا یک ایستگاه آئروسول در این منطقه وجود دارد که داده‌های ضخامت نوری آئروسول را در طول موج‌های مختلف اندازه‌گیری و از سال ۲۰۰۹ تاکنون بصورت رایگان در اختیار عموم قرار می‌دهد. شکل ۱ منطقه مورد مطالعه در این پژوهش را نشان می‌دهد.



شکل ۱. منطقه مورد مطالعه در نزدیکی شهرستان زنجان و ایستگاه زمینی Aeronet  
 Fig. 1. The study area, near Zanjan County and the Aeronet ground station.

نمودار جریانی روند انجام کار در شکل ۲ آورده شده است. در این پژوهش، از داده‌های ماهواره‌ای لندست-۸، مادیس و داده‌های ایستگاه‌های زمینی آئرونوت برای بازه زمانی ۲۰۱۴ تا ۲۰۲۲ استفاده شد. تمام مراحل پیش‌پردازش و پردازش داده‌ها در پلتفرم گوگل ارث انجین (Google Earth Engine) انجام شد. داده‌های بازتاب سطحی در بالای اتمسفر لندست-۸ (TOA Reflectance) و بازتاب سطحی تصحیح شده از اثرات اتمسفر برای باندهای آبی، سبز، قرمز، مادون قرمز نزدیک، SWIR 1 و SWIR 2 مورد استفاده قرار گرفت. تصحیح اتمسفری با استفاده از الگوریتم LaSRC (ارائه شده در سامانه گوگل ارث انجین) انجام شد. دلیل استفاده از هر دو نوع داده، تشخیص آلودگی هوا با کمک داده‌های تصحیح اتمسفری شده و نشده بود. داده‌های آلبیدو سطحی از باندهای ۱، ۳، و ۴ استخراج گردید و داده‌های عمق نوری آئروسول با قدرت تفکیک مکانی ۱ کیلومتر از محصول Deep Blue در طول موج ۵۵۰ نانومتر بدست آمد. داده‌های آئرونوت شامل داده‌های عمق نوری آئروسول در طول موج ۵۵۰ نانومتر از ایستگاه آئرونوت موجود در شهر زنجان جمع‌آوری شد. برای تطبیق مکانی داده‌های آئرونوت با داده‌های ماهواره‌ای، از روش میانگین‌گیری داده‌های پیکسل‌های اطراف ایستگاه استفاده شد. تطبیق زمانی با انتخاب داده‌های آئرونوت همزمان با زمان تصویربرداری لندست-۸ انجام شد. داده‌های آلودگی هوا شامل داده‌های ساعتی PM2.5، PM10، NO2 و SO2 از ایستگاه زمینی دریافت شد. این داده‌ها با استفاده از روش درون‌یابی به قدرت تفکیک مکانی یک کیلومتر و منطبق بر شبکه‌بندی دیگر داده‌ها تبدیل شدند. مدل رقومی ارتفاع با قدرت تفکیک مکانی ۹۰ متر از داده‌های SRTM بدست آمد. برای همسان‌سازی داده‌ها از نظر زمانی، یک فیلتر زمانی بر روی داده‌ها اعمال شد تا فقط داده‌های همزمان با تصاویر لندست-۸ باقی بمانند. برای همسان‌سازی مکانی، داده‌های مادیس با استفاده از روش نزدیکترین همسایه به قدرت تفکیک مکانی ۳۰ متر تبدیل شدند. پیکسل‌های ابری با استفاده از باندهای طیفی لندست ۸ شناسایی و با مقدار صفر جایگزین شدند تا از فرایند آموزش الگوریتم‌های یادگیری ماشینی و یادگیری عمیق کنار گذاشته شوند.



شکل ۲. نمودار جریانی از مراحل انجام تحقیق  
Fig. 2. flowchart of research steps

در این پژوهش، برای تخمین دقیق‌تر پارامتر عمق نوری آئروسول از ترکیبی از روش‌های یادگیری ماشین و یادگیری عمیق استفاده شده است. یادگیری ماشین شامل الگوریتم‌هایی است که با استفاده از ویژگی‌های استخراج‌شده از داده‌ها، روابط آماری میان متغیرها را مدل‌سازی می‌کنند. این روش‌ها معمولاً نیاز به حجم نمونه کمتر دارند و فرآیند آموزش آن‌ها سریع‌تر و ساده‌تر است. در مقابل، یادگیری عمیق زیرمجموعه‌ای از یادگیری ماشین است که از شبکه‌های عصبی عمیق با چندین لایه پنهان استفاده می‌کند و توانایی بالایی در استخراج خودکار ویژگی‌ها از داده‌های بزرگ و پیچیده دارد، اما نیاز به منابع محاسباتی بیشتر و نمونه‌های آموزشی فراوان‌تری دارد (L. Li, 2020; She et al., 2020; Su et al., 2020). در این مطالعه، الگوریتم‌ها به دو دسته کلی تقسیم می‌شوند. روش‌های یادگیری ماشین که شامل رگرسیون خطی چند متغیره (Multiple Linear Regression)، درخت تصمیم رگرسیون (Decision Tree Regression)، جنگل تصادفی (Random Forest Regression)، رگرسیون بردار پشتیبان (Support Vector Regression) می‌باشند. دسته دوم، روش‌های یادگیری عمیق که شامل شبکه عصبی چندلایه پرسپترون عمیق (Deep Neural Multilayer Perceptron - MLP) و جنگل عمیق (Deep Forest Regression) می‌باشند.

الگوی انتخاب این مدل‌ها با توجه به مطالعات پیشین صورت گرفته است که در آن‌ها کاربرد موفق این روش‌ها در برآورد عمق نوری آتروسول و سایر شاخص‌های آلودگی هوا با استفاده از تصاویر ماهواره‌ای و داده‌های زمینی به اثبات رسیده است (Hilker et al., 2009; Salehi et al., 2021; Tao et al., 2017b; X. Zhu et al., 2022b). همچنین، استفاده تلفیقی از این الگوریتم‌ها با هدف بهره‌گیری از نقاط قوت و پوشش نقاط ضعف آن‌ها انجام شده است (Azarang & Kehtarnavaz, 2019; Lin et al., 2021; Shopovska et al., 2020). در ادامه توضیحاتی در رابطه با روش‌های استفاده شده در این پژوهش ارائه می‌گردد.

### ۱. رگرسیون خطی چند متغیره

رگرسیون خطی چند متغیره یکی از ساده‌ترین و پایه‌ای‌ترین روش‌های یادگیری ماشین است که برای مدل‌سازی روابط خطی بین متغیرهای مستقل و وابسته به کار می‌رود. این روش به دلیل سادگی، سرعت محاسباتی بالا و درک آسان، اغلب به‌عنوان مدل پایه در مطالعات یادگیری ماشین مورد استفاده قرار می‌گیرد. با این حال، عملکرد آن در شرایطی که داده‌ها روابط غیرخطی دارند، محدود است (Yang et al., 2020).

### ۲. درخت تصمیم رگرسیون

درخت تصمیم رگرسیون یک الگوریتم غیرپارامتریک و تفسیری است که با تقسیم داده‌ها به‌صورت سلسله‌مراتبی، توانایی شناسایی روابط غیرخطی و پیچیده را دارد (Ghassemian, 2016). از مزایای این روش، امکان تفسیر آسان مدل و اجرای سریع آن است. با این وجود، این الگوریتم در مجموعه داده‌های کوچک یا دارای نویز مستعد بیش‌برازش است (Zhang et al., 2021).

### ۳. جنگل تصادفی

جنگل تصادفی یک الگوریتم یادگیری همادی (Ensemble Learning) است که از ترکیب چندین درخت تصمیم برای افزایش صحت و پایداری مدل استفاده می‌کند (You et al., 2015). این روش در برابر بیش‌برازش مقاوم‌تر است و می‌تواند روابط پیچیده میان متغیرها را مدل کند، اما زمان محاسباتی بیشتری نسبت به مدل‌های ساده‌تر نیاز دارد (Antonanzas-Torres et al., 2014b).

### ۴. رگرسیون بردار پشتیبان

این روش یک الگوریتم قدرتمند برای مدل‌سازی روابط غیرخطی است که با استفاده از توابع کرنل، داده‌ها را به فضای ویژگی با ابعاد بالاتر نگاشت می‌کند (N.-B. Chang et al., 2018; Nirala, 2008). این روش در شرایطی که داده‌ها به‌خوبی تفکیک‌پذیر هستند عملکرد مطلوبی دارد، ولی در مجموعه داده‌های بزرگ و با تعداد ویژگی‌های بالا، نیاز به منابع محاسباتی بیشتری دارد (Guan et al., 2023).

### ۵. شبکه عصبی چندلایه پرسپترون عمیق

این روش از لایه‌های متعدد شامل نرون‌های مصنوعی تشکیل شده است و توانایی شناسایی و مدل‌سازی روابط بسیار پیچیده و غیرخطی را دارد (H. Zhu et al., 2023). با این حال، نیاز به داده‌های آموزشی فراوان، تنظیم دقیق ابرپارامترها و زمان محاسباتی بالا از چالش‌های اصلی این روش به شمار می‌رود (Song et al., 2022).

### ۶. جنگل عمیق

جنگل عمیق یک روش مبتنی بر یادگیری مجموعه‌ای است که از مزایای مدل‌های جنگل تصادفی و یادگیری عمیق بهره می‌برد. این الگوریتم با استفاده از معماری لایه‌ای بدون نیاز به تنظیم ابرپارامترهای پیچیده، عملکردی قابل رقابت با شبکه‌های عصبی ارائه می‌دهد و به داده‌های آموزشی کمتری نیاز دارد (Mirzaei et al., 2023).

## ۷. تلفیق مدل‌ها و الگوریتم‌های ترکیبی

با توجه به اینکه هر الگوریتم دارای مزایا و معایب خاص خود است، استفاده ترکیبی از آن‌ها می‌تواند به نتایج صحیح‌تری منجر شود. در این پژوهش از روش میانگین‌گیری ساده برای تلفیق خروجی الگوریتم‌ها استفاده شد. هدف از این کار، افزایش پایداری مدل نهایی و کاهش حساسیت آن نسبت به نویز یا عدم قطعیت‌های موجود در داده‌ها بود (N.-B. Chang et al., 2018; Nirala, 2008).

### ارزیابی مدل

در این پژوهش، ارزیابی عملکرد مدل‌های تخمین عمق نوری آتروسول با استفاده از معیارهای آماری رایج، شامل میانگین، حداکثر، حداقل، انحراف معیار<sup>۱</sup>، میانگین مربعات خطا<sup>۲</sup>، ریشه میانگین مربعات خطا<sup>۳</sup> و ضریب تعیین ( $R^2$ ) انجام شد. میانگین به عنوان یک معیار مرکزی، برای بررسی مقدار متوسط پیش‌بینی‌ها یا مشاهدات واقعی استفاده می‌شود. این شاخص می‌تواند نشان دهد که آیا مدل به طور کلی به سمت مقادیر بالا یا پایین گرایش دارد. اگر میانگین پیش‌بینی‌ها با میانگین داده‌های واقعی تفاوت زیادی داشته باشد، احتمالاً مدل دارای سوگیری<sup>۴</sup> است. حداکثر و حداقل مقدار پیش‌بینی شده یا مشاهده شده نشان می‌دهد که مدل یا داده‌ها تا چه حد به مقادیر بالا یا پایین رسیده‌اند. این شاخص‌ها به شناسایی نقاط دورافتاده<sup>۵</sup> و بررسی عملکرد مدل در پیش‌بینی مقادیر بسیار زیاد کمک می‌کند. اگر مقدار پیش‌بینی شده بسیار دورتر از داده‌های واقعی باشد، ممکن است مدل در شرایط خاص دچار بیش‌برازش<sup>۶</sup> شده باشد. این شاخص نشان‌دهنده میزان پراکندگی داده‌ها یا پیش‌بینی‌ها نسبت به میانگین است. انحراف معیار بیشتر به معنای پراکندگی بالاتر و داده‌های متغیرتر است. مقایسه انحراف معیار پیش‌بینی‌ها با داده‌های واقعی می‌تواند نشان دهد که آیا مدل توانسته تغییرات داده را به درستی درک کند. اگر انحراف معیار پیش‌بینی‌ها بسیار کمتر از داده‌های واقعی باشد، مدل ممکن است بیش از حد ساده‌سازی شده باشد. ریشه میانگین مربعات خطا<sup>۷</sup>، به‌عنوان یک معیار اندازه‌گیری خطا، نشان‌دهنده میانگین فاصله بین مقادیر پیش‌بینی شده و مقادیر واقعی است. ریشه میانگین مربعات خطا ریشه دوم میانگین مربعات خطا است و به‌عنوان یک معیار استاندارد برای ارزیابی خطای مدل استفاده می‌شود. در این مطالعه، ریشه میانگین مربعات خطا برای ارزیابی میزان انحراف پیش‌بینی‌ها از مقادیر واقعی عمق نوری آتروسول محاسبه شد. ضریب تعیین، معیاری است که درصد واریانس متغیر وابسته (عمق نوری آتروسول) را که توسط متغیرهای مستقل توضیح داده می‌شود، نشان می‌دهد. مقدار  $R^2$  بین ۰ و ۱ متغیر است؛ به‌طوری‌که مقدار نزدیک‌تر به ۱ نشان‌دهنده توانایی بالای مدل در توضیح واریانس داده‌ها و عملکرد خوب مدل در تطابق پیش‌بینی‌ها با مقادیر واقعی است.

### نتایج و بحث

در این پژوهش، عملکرد شش الگوریتم یادگیری ماشین و یادگیری عمیق برای تخمین عمق نوری آتروسول مورد ارزیابی قرار گرفت. ارزیابی عملکرد این الگوریتم‌ها با استفاده از معیارهای ضریب تعیین و ریشه میانگین مربعات خطا انجام شد. جدول ۱، عملکرد هر یک از الگوریتم‌ها را نشان می‌دهد. مقادیر  $R^2$  حاصل از این الگوریتم‌ها بین ۰/۷۳ تا ۰/۸۶ متغیر بود که نشان‌دهنده توانایی مناسب این مدل‌ها در تبیین و پیش‌بینی تغییرات مقادیر عمق نوری آتروسول است. همچنین، مقادیر ریشه میانگین مربعات خطا بین ۰/۱۸۵ تا ۰/۴۱۴ متغیر بود که نشان‌دهنده تفاوت در صحت پیش‌بینی الگوریتم‌ها است. به طور خاص، الگوریتم شبکه عصبی پرسپترون عمیق با  $R^2$  برابر با ۰/۸۸۹ و ریشه میانگین مربعات خطا برابر با ۰/۲۷۹، بهترین عملکرد را از خود نشان داد.

1. Standard Deviation
2. Mean Squared Error - MSE
3. Root Mean Squared Error - RMSE
4. Bias
5. Outliers
6. Overfitting
7. RMSE

برای بهبود بیشتر صحت تخمین عمق نوری آثروسل، از روش تلفیق نتایج در سطح تصمیم‌گیری با استفاده از میانگین‌گیری استفاده شد. این روش منجر به افزایش  $R^2$  به  $0/86$  و کاهش مقدار ریشه میانگین مربعات خطا به  $0/202$  شد. این نتایج نشان‌دهنده پتانسیل بالای روش تلفیق برای ایجاد عمق نوری آثروسل با قدرت تفکیک مکانی بالا است. در رابطه با عملکرد روش‌های مختلف با توجه به جدول ۱ می‌توان موارد زیر را بیان نمود:

(۱) عملکرد برتر شبکه عصبی چندلایه پرسپترون عمیق: این الگوریتم با کمترین میانگین مربعات خطا معادل  $0/078$  و ریشه میانگین مربعات خطا معادل  $0/279$ ، بهترین عملکرد را در بین الگوریتم‌های مورد بررسی برای تخمین عمق نوری آثروسل از خود نشان داده است. همچنین، این الگوریتم با ضریب همبستگی  $0/88$ ، همبستگی بالایی بین مقادیر پیش‌بینی شده و مشاهده شده عمق نوری آثروسل نشان می‌دهد.

(۲) عملکرد قابل قبول سایر الگوریتم‌های یادگیری ماشین: سایر الگوریتم‌های یادگیری ماشین، شامل رگرسیون بردار پشتیبان، رگرسیون جنگل تصادفی، درخت تصمیم رگرسیون، رگرسیون خطی چند متغیره و رگرسیون جنگل عمیق، نیز عملکرد قابل قبولی در تخمین عمق نوری آثروسل داشته‌اند. مقادیر ریشه میانگین مربعات خطا برای این الگوریتم‌ها بین  $0/188$  (برای رگرسیون خطی چند متغیره) تا  $0/414$  (برای رگرسیون جنگل تصادفی) متغیر است.

(۳) بهبود عملکرد با استفاده از تلفیق در سطح تصمیم‌گیری (*Decision Fusion*): استفاده از روش تلفیق در سطح تصمیم‌گیری منجر به بهبود قابل توجه در صحت تخمین عمق نوری آثروسل شده است. با تلفیق نتایج الگوریتم‌های مختلف، ریشه میانگین مربعات خطا به  $0/202$  کاهش و ضریب همبستگی به  $0/86$  افزایش یافته است، که نشان‌دهنده کارایی بالای این روش در بهبود صحت پیش‌بینی است.

(۴) پایداری بیشتر نتایج حاصل از تلفیق در سطح تصمیم‌گیری: انحراف معیار کمتر نتایج حاصل از این روش ( $0/06$ ) نشان‌دهنده پایداری بیشتر این روش در مقایسه با سایر الگوریتم‌ها است. به عبارت دیگر، تلفیق در سطح تصمیم‌گیری نسبت به نوسانات داده‌های ورودی مقاوم‌تر است.

(۵) نقاط قوت و ضعف الگوریتم‌ها: با توجه به مقادیر حداقل و حداکثر خطا، می‌توان نقاط قوت و ضعف هر الگوریتم را در شرایط مختلف بررسی کرد. برای مثال، اگرچه روش شبکه عصبی چندلایه پرسپترون عمیق به‌طور متوسط بهترین عملکرد را دارد، اما در برخی موارد، خطای آن تا  $0/43$  نیز افزایش یافته است. در مقابل، رگرسیون خطی چند متغیره با وجود ریشه میانگین مربعات خطا بالاتر، حداقل خطای کمتری ( $0/16$ ) نسبت به روش شبکه عصبی چندلایه پرسپترون عمیق داشته است.

به‌طور کلی، روش‌های یادگیری ماشین و یادگیری عمیق در برخی موارد عملکرد بهتری را از نظر صحت ارائه دادند، در حالی که رگرسیون خطی چند متغیره نیز صحت قابل قبولی را نشان داد. از این‌رو، با تلفیق داده‌ها در سطح تصمیم‌گیری، دقت و صحت نتایج به‌طور معناداری افزایش یافت (جدول ۱).

جدول ۱. مقایسه آماری نتایج روش‌های یادگیری ماشین و یادگیری عمیق در ریزمقیاس‌نمایی داده‌های عمق نوری آثروسل

Decision Fusion	Deep Forest regression	Linear Regression	Extra Trees Regression	Random forest regression	SVR	Deep Neural Multilayer Perceptron	ردیف
0.25	0.25	0.27	0.24	0.25	0.29	0.19	میانگین
0.35	0.49	0.45	0.45	0.46	0.60	0.43	حداکثر
0.14	0.01	0.16	0.00	0.03	0.07	0.04	حداقل
0.06	0.14	0.07	0.13	0.13	0.13	0.12	انحراف معیار
0.86	0.81	0.73	0.84	0.78	0.74	0.889	همبستگی
0.041	0.136	0.034	0.168	0.171	0.099	0.078	میانگین مربعات خطا
0.202	0.369	0.185	0.410	0.414	0.314	0.279	میانگین مربعات ریشه خطا

در این پژوهش، کارایی الگوریتم‌های مختلف یادگیری ماشین و رویکرد تلفیق تصمیم‌گیری برای تخمین عمق نوری آئروسول مورد بررسی قرار گرفت. یافته‌ها نشان می‌دهد که پرسپترون چندلایه عمیق در بین الگوریتم‌های منفرد، بهترین عملکرد را با کمترین مقدار ریشه میانگین مربعات خطا معادل  $0.279$  و ضریب تعیین  $0.88$  از خود نشان داد. این نتایج نشان‌دهنده توانایی این روش در مدل‌سازی روابط پیچیده غیرخطی بین ویژگی‌های ورودی و عمق نوری آئروسول است. این نتایج همسو با نتایج تحقیقی دیگری است که در آن عملکرد شبکه عصبی چندلایه پرسپترون عمیق را در یک مسئله مشابه (تشخیص ابر) بررسی نموده و نشان داده که این مدل در یادگیری روابط پیچیده و غیرخطی بین داده‌های ورودی و خروجی موفق است (Taravat et al., 2015). اگرچه الگوریتم‌های دیگری مانند رگرسیون بردار پشتیبان، جنگل تصادفی، درخت تصمیم رگرسیون، رگرسیون خطی چند متغیره و جنگل عمیق نیز تخمین‌های قابل قبولی ارائه دادند، اما عملکرد آن‌ها نسبت به شبکه عصبی چندلایه پرسپترون عمیق ضعیف‌تر بود. نکته قابل توجه این است که رگرسیون خطی چند متغیره، با وجود ریشه میانگین مربعات خطا بالاتر، حداقل خطای کمتری را ارائه نمود، که نشان‌دهنده عملکرد مناسب این مدل برای سناریوهای خاص با تغییرپذیری کمتر است. در مسائل پیش‌بینی و مدل‌سازی، انتخاب روش مناسب بسیار مهم است. انتخاب روش مناسب برای مدل‌سازی، تاثیر زیادی بر دقت و عملکرد مدل خواهد داشت و روش‌های خطی و یادگیری ماشین معمولاً دقت پایین‌تری نسبت به روش‌های یادگیری عمیق دارند (Wang et al., 2022). با این حال، این روش‌ها به دلیل سادگی و سرعت پردازش بیشتری که دارند، در برخی موارد می‌توانند بهترین گزینه باشند. به علاوه، این روش‌ها در مواردی که داده‌ها کم و ناکافی هستند، می‌توانند نتایج بهتری ارائه دهند. از سوی دیگر، روش‌های یادگیری عمیق مانند شبکه عصبی چندلایه پرسپترون عمیق، به دلیل توانایی بیشتر در استخراج ویژگی‌های پیچیده، قادر به مدل‌سازی با صحت بالاتر هستند. با این حال، هزینه محاسباتی این روش‌ها بسیار بالاست و به دلیل پیچیدگی بیشتر، نیاز به تعداد بیشتری داده‌های آموزشی دارند. انتخاب روش مناسب باید با توجه به ویژگی‌های داده‌ها، محیط مورد استفاده و هدف مدل‌سازی باشد (Taskinen et al., 2022). باید از تجربیات گذشته و نتایج به دست آمده در مدل‌های مشابه استفاده شود تا بتوان روش مناسبی برای مدل‌سازی انتخاب کرد. از این جهت نمی‌توان به راحتی فرایندی را در مورد استفاده از روش‌های مختلف ارائه نمود. بنابراین، برای مدل‌سازی عمق نوری آئروسول، بهتر است از ترکیب روش‌های مختلف استفاده شود (Stebel et al., 2021). به عنوان مثال، از روش‌های یادگیری ماشین و خطی برای شبیه‌سازی سریع و با دقت بالا در شرایطی که داده کمتری در دسترس است، استفاده می‌شود. اما در شرایطی که داده بیشتر در دسترس است، می‌توان از روش‌های یادگیری عمیق برای مدل‌سازی استفاده کرد. با ترکیب این روش‌ها، می‌توان صحت مدل‌سازی را بهبود بخشید و همچنین پیچیدگی و هزینه را کاهش داد (Li et al., 2022).

با توجه به این که هر روش مزایا و معایب خود را دارد، در این بخش به صورت مجزا در رابطه با هر یک از روش‌ها بحث می‌شود. روش رگرسیون خطی چند متغیره یک روش خطی است که برای پیش‌بینی یک متغیر به عنوان وابسته از چندین متغیر مستقل استفاده می‌شود. مزیت این روش این است که آن را می‌توان به سادگی توضیح داد و نتایج به دست آمده از آن قابل تفسیر هستند. از طرف دیگر، معایب آن شامل نیاز به فرضیات خاص برای داده‌ها و حساسیت به داده‌های پرت می‌باشد. روش رگرسیون بردار پشتیبان، یک روش غیر خطی است که برای پیش‌بینی داده‌ها استفاده می‌شود (Stebel et al., 2020). این روش مزایایی مانند قابلیت پردازش داده‌های پیچیده و قابلیت تعمیم به داده‌های جدید را داراست. اما معایب آن شامل حساسیت به انتخاب پارامترهای مناسب و حساس به داده‌های پرت می‌باشد. روش جنگل تصادفی، یک روش غیر خطی است که برای پیش‌بینی داده‌ها استفاده می‌شود (Sun et al., 2016). مزایای این روش شامل قابلیت پردازش داده‌های پیچیده و مقاومت بالا در برابر داده‌های پرت است. از طرف دیگر، معایب آن شامل مصرف بالای حافظه و زمان محاسبات بیشتر می‌باشد. درخت تصمیم رگرسیون یک روش یادگیری ماشین برای مدل‌سازی پیش‌بینی است. از جمله مزایای این روش آن است که این روش برای مسائل پیش‌بینی پیچیده با داده‌های غیرخطی می‌تواند کاربرد داشته باشد. همچنین این الگوریتم باعث کاهش اهمیت وزن داده‌های نویزی و خطا می‌شود و از آنها در مدل‌سازی صرف‌نظر می‌نماید. علاوه بر این، این روش پویا است، یعنی با بروزسانی

داده‌های جدید، می‌توانند به سرعت تطبیق پیدا کند و از صحت بالایی برخوردار باشد. در ضمن، این روش در مقایسه با روش‌های دیگری که از درخت‌های تصادفی استفاده می‌کنند، اغلب سریع‌تر است (Aziz et al., 2023; Hameed et al., 2021; Sudhamathi & Perumal, 2024). معایب این روش می‌تواند شامل نیاز به تنظیم پارامترهای مختلف و همچنین نیازمند بودن به تعداد بیشتری از داده‌ها نسبت به روش‌های خطی بوده و در مواردی که داده‌ها دارای ابهام بوده و یا فرضیات نامناسبی در طراحی مدل اتخاذ شود، این روش ممکن است عملکرد نامطلوبی داشته باشد.

با توجه به موارد ذکر شده در رابطه با مزایا و معایب هر یک از روش‌ها، و نیز تفاوت ناچیز در عملکرد هر یک از روش‌ها در این تحقیق، اهمیت این مزایا و معایب می‌تواند به منظور انتخاب روش بهینه تاثیرگذار باشد. برای مثال، در صورتی که داده‌ها به صورت خطی قابل تحلیل باشند و تعداد متغیرها کم باشد، الگوریتم رگرسیون خطی چند متغیره می‌تواند گزینه مناسبی باشد. اما در صورتی که داده‌ها به صورت پیچیده و غیرخطی باشند و تعداد متغیرها زیاد باشد، روش‌هایی مانند شبکه عصبی چندلایه پرسپترون عمیق و جنگل عمیق می‌توانند گزینه‌های بهتری باشند. در کل، برای رسیدن به نتایج بهتر، نیاز به انتخاب درست الگوریتم‌ها و تلفیق مناسب آنها می‌باشد. با تلفیق روش‌های مختلف می‌توان دقت و صحت نتایج را در حد قابل قبولی افزایش داد. یکی از مشارکت‌های کلیدی این کار، پیاده‌سازی موفقیت‌آمیز رویکرد تلفیق در سطح تصمیم‌گیری است که صحت تخمین عمق نوری آتروسل را به‌طور قابل توجهی افزایش داد. با ترکیب پیش‌بینی‌های الگوریتم‌های منفرد، مقدار ریشه میانگین مربعات خطا به  $0/۲۰۲$  کاهش یافت و همبستگی به  $0/۸۶$  بهبود یافت. این امر قدرت ترکیب مدل‌های متنوع را برای بهره‌برداری از نقاط قوت فردی آن‌ها و کاهش نقاط ضعفشان نشان می‌دهد. پایداری بهبود یافته رویکرد تلفیق در سطح تصمیم‌گیری، که با انحراف معیار کمتر آن مشهود است، مقاومت و قابلیت اطمینان آن را بیشتر تقویت می‌کند.

اختلاف عملکرد مشاهده شده بین الگوریتم‌ها را می‌توان به ویژگی‌های ذاتی آن‌ها و ماهیت مسأله تخمین عمق نوری آتروسل نسبت داد (Liang et al., 2022). عملکرد برتر شبکه عصبی چندلایه پرسپترون عمیق احتمالاً ناشی از توانایی آن در مدل‌سازی روابط پیچیده غیرخطی است، در حالی که مدل رگرسیون خطی چند متغیره ساده‌تر ممکن است برای سناریوهایی با روابط ساده‌تر بین پیش‌بینی‌کننده‌ها و عمق نوری آتروسل مناسب‌تر باشد. اثربخشی رویکرد تلفیق در سطح تصمیم‌گیری، مزایای ترکیب مدل‌های متنوع را برای به تصویر کشیدن جنبه‌های مختلف پدیده مورد بررسی برجسته می‌کند. تحقیقات آینده می‌تواند معماری‌های یادگیری عمیق جایگزین، مانند شبکه‌های عصبی کانولوشنی (CNN) یا شبکه‌های عصبی بازگشتی (RNN) را برای بهبود بیشتر دقت تخمین عمق نوری آتروسل مورد بررسی قرار دهد. بررسی تأثیر ویژگی‌های ورودی مختلف و کاوش تکنیک‌های پیشرفته مهندسی ویژگی نیز می‌تواند عملکرد مدل را افزایش دهد. علاوه بر این، تجزیه و تحلیل عدم قطعیت مرتبط با تخمین‌های عمق نوری آتروسل و توسعه روش‌هایی برای کمی‌سازی و کاهش این عدم قطعیت برای بهبود قابلیت اطمینان پیش‌بینی‌های عمق نوری آتروسل بسیار مهم است. در نهایت، اعمال این تکنیک‌ها در مناطق جغرافیایی و مجموعه داده‌های مختلف، بینش ارزشمندی در مورد قابلیت تعمیم و استحکام روش‌های پیشنهادی ارائه می‌دهد.

## نتیجه‌گیری

در این پژوهش، از مجموعه‌ای از الگوریتم‌های یادگیری ماشین و یادگیری عمیق برای ریزمقیاس‌نمایی عمق نوری آتروسل استفاده شد. بررسی‌های انجام شده نشان داد که اگرچه هر یک از الگوریتم‌ها مزایا و معایب خاص خود را دارند، اما در مجموع می‌توان از تلفیق آن‌ها برای دستیابی به پیش‌بینی با صحت و دقت بیشتر بهره گرفت. در میان مدل‌های بررسی شده، الگوریتم شبکه عصبی چندلایه پرسپترون عمیق بهترین عملکرد را در پیش‌بینی مقادیر عمق نوری آتروسل نشان داد. با این حال، سایر الگوریتم‌ها نیز عملکرد نسبتاً قابل قبولی داشتند. برای نمونه، مدل‌های رگرسیون بردار پشتیبان و جنگل تصادفی در برخی سناریوها دقت مناسبی ارائه دادند و الگوریتم رگرسیون خطی چند متغیره، علی‌رغم سادگی، در مواردی با حداقل خطای کمتر از مدل‌های پیچیده‌تر همراه بود. این نتایج نشان می‌دهد که انتخاب بهترین الگوریتم به ساختار داده‌ها، میزان غیرخطی بودن روابط

و هدف مدل‌سازی بستگی دارد. یکی از مهم‌ترین دستاوردهای این تحقیق، استفاده موفق از رویکرد تلفیق در سطح تصمیم‌گیری بود که با ترکیب خروجی‌های چند مدل، باعث بهبود چشمگیر عملکرد نهایی شد. به‌کارگیری این رویکرد منجر به افزایش ضریب همبستگی به ۰/۸۶ و کاهش مقدار ریشه میانگین مربعات خطا به ۰/۲۰۲ شد. همچنین، انحراف معیار پایین‌تر مدل تلفیقی (۰/۰۶) نشان‌دهنده پایداری بیشتر و مقاومت بهتر آن در برابر نوسانات داده‌های ورودی بود.

این مطالعه همچنین نشان داد که رویکردهای یادگیری عمیق، علی‌رغم نیاز به داده‌های آموزشی بیشتر و پیچیدگی بالاتر، قابلیت مدل‌سازی دقیق‌تری نسبت به روش‌های کلاسیک دارند. از سوی دیگر، روش‌های ساده‌تر مانند رگرسیون خطی چند متغیره می‌توانند در شرایط خاصی (مانند محدودیت داده یا روابط خطی ساده) عملکرد قابل قبولی داشته باشند. بنابراین، ترکیب این رویکردها می‌تواند یک راهکار متوازن برای بهینه‌سازی دقت و کارایی مدل‌سازی عمق نوری آئروسول فراهم آورد. در نهایت، یکی از مشارکت‌های کلیدی این پژوهش، ارائه یک چارچوب کاربردی برای تلفیق مدل‌های مختلف در زمینه تخمین عمق نوری آئروسول با دقت بالا است. استفاده از این چارچوب می‌تواند در مطالعات آینده نیز برای بهبود مدل‌سازی پدیده‌های جوی، به‌ویژه در مناطق با داده‌های محدود، مورد استفاده قرار گیرد. پیشنهاد می‌شود در ادامه، مدل‌های پیشرفته‌تری نظیر شبکه‌های عصبی کانولوشنی (CNN) و بازگشتی (RNN) نیز مورد بررسی قرار گرفته و اثر متغیرهای ورودی جدید و تکنیک‌های مهندسی ویژگی بر عملکرد مدل‌ها ارزیابی شود. همچنین تحلیل عدم قطعیت در پیش‌بینی‌ها و آزمون‌پذیری مدل‌ها در مناطق و دوره‌های زمانی مختلف، می‌تواند گام مؤثری در افزایش قابلیت تعمیم و اعتمادپذیری نتایج باشد.

## References

- Andreae, M. O., & Rosenfeld, D. (2008). Aerosol–cloud–precipitation interactions. Part 1. The nature and sources of cloud-active aerosols. *Earth-Science Reviews*, 89(1), 13–41. <https://doi.org/10.1016/j.earscirev.2008.03.001>
- Antonanzas-Torres, F., Sanz-Garcia, A., Martínez-de-Pisón, F. J., Antonanzas, J., Perpiñán-Lamigueiro, O., & Polo, J. (2014). Towards downscaling of aerosol gridded dataset for improving solar resource assessment, an application to Spain. *Renewable Energy*, 71, 534–544. <https://doi.org/10.1016/j.renene.2014.06.010>
- Aube, M., O'Neill, N. T., & Royer, A. (2000). Modelling of aerosol optical depth variability at regional scale. *IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium. Taking the Pulse of the Planet: The Role of Remote Sensing in Managing the Environment. Proceedings (Cat. No.00CH37120)*, 1, 199–201 vol.1. <https://doi.org/10.1109/IGARSS.2000.860467>
- Bilal, M., Qiu, Z., Campbell, J. R., Spak, S. N., Shen, X., & Nazeer, M. (2018). A New MODIS C6 Dark Target and Deep Blue Merged Aerosol Product on a 3 km Spatial Grid. *Remote Sensing*, 10(3), Article 3. <https://doi.org/10.3390/rs10030463>
- Chang, H. H., Hu, X., & Liu, Y. (2014). Calibrating MODIS aerosol optical depth for predicting daily PM<sub>2.5</sub> concentrations via statistical downscaling. *Journal of Exposure Science & Environmental Epidemiology*, 24(4), Article 4. <https://doi.org/10.1038/jes.2013.90>
- Charlson, R. J., Schwartz, S. E., Hales, J. M., Cess, R. D., Coakley, J. A., Hansen, J. E., & Hofmann, D. J. (1992). Climate forcing by anthropogenic aerosols. *Science (New York, N.Y.)*, 255(5043), 423–430. <https://doi.org/10.1126/science.255.5043.423>
- Gunaseelan, I., Bhaskar, B. V., & Muthuchelian, K. (2014). The effect of aerosol optical depth on rainfall with reference to meteorology over metro cities in India. *Environmental Science and Pollution Research*, 21(13), 8188–8197. <https://doi.org/10.1007/s11356-014-2711-4>
- Holben, B. N., Eck, T. F., Slutsker, I., Tanré, D., Buis, J. P., Setzer, A., Vermote, E., Reagan, J. A., Kaufman, Y. J., Nakajima, T., Lavenu, F., Jankowiak, I., & Smirnov, A. (1998). AERONET—A Federated Instrument Network and Data Archive for Aerosol Characterization. *Remote Sensing of Environment*, 66(1), 1–16. [https://doi.org/10.1016/S0034-4257\(98\)00031-5](https://doi.org/10.1016/S0034-4257(98)00031-5)

- Li, K., Bai, K., Li, Z., Guo, J., & Chang, N.-B. (2022). Synergistic data fusion of multimodal AOD and air quality data for near real-time full coverage air pollution assessment. *Journal of Environmental Management*, 302, 114121. <https://doi.org/10.1016/j.jenvman.2021.114121>
- Li, L., Franklin, M., Girguis, M., Lurmann, F., Wu, J., Pavlovic, N., Breton, C., Gilliland, F., & Habre, R. (2020). Spatiotemporal imputation of MAIAC AOD using deep learning with downscaling. *Remote Sensing of Environment*, 237, 111584. <https://doi.org/10.1016/j.rse.2019.111584>
- Liang, T., Liang, S., Zou, L., Sun, L., Li, B., Lin, H., He, T., & Tian, F. (2022). Estimation of Aerosol Optical Depth at 30 m Resolution Using Landsat Imagery and Machine Learning. *Remote Sensing*, 14(5), Article 5. <https://doi.org/10.3390/rs14051053>
- Pöschl, U. (2005). Atmospheric Aerosols: Composition, Transformation, Climate and Health Effects. *Angewandte Chemie International Edition*, 44(46), 7520–7540. <https://doi.org/10.1002/anie.200501122>
- Shao, L., Li, G., Zhao, Q., Li, Y., Sun, Y., Wang, W., Cai, C., Chen, W., Liu, R., Luo, W., Yin, X., & Lee, X. (2020). The fertilization effect of global dimming on crop yields is not attributed to an improved light interception. *Global Change Biology*, 26(3), 1697–1713. <https://doi.org/10.1111/gcb.14822>
- Sokolik, I. N., & Toon, O. B. (1996). Direct radiative forcing by anthropogenic airborne mineral aerosols. *Nature*, 381(6584), Article 6584. <https://doi.org/10.1038/381681a0>
- Wang, X., Wu, J., Chen, M., Xu, X., Wang, Z., Wang, B., Wang, C., Piao, S., Lin, W., Miao, G., Deng, M., Qiao, C., Wang, J., Xu, S., & Liu, L. (2018). Field evidences for the positive effects of aerosols on tree growth. *Global Change Biology*, 24(10), 4983–4992. <https://doi.org/10.1111/gcb.14339>
- Zhou, H., Yue, X., Lei, Y., Tian, C., Ma, Y., & Cao, Y. (2021). Aerosol radiative and climatic effects on ecosystem productivity and evapotranspiration. *Current Opinion in Environmental Science & Health*, 19, 100218. <https://doi.org/10.1016/j.coesh.2020.10.006>