



## Estimation of PM<sub>2.5</sub> as a Harmful Environmental Hazard in Tehran by Fusion of MODIS Aerosol Products through a Machine Learning Approach

Ali Mirzaei<sup>a</sup>, Hossein Bagheri<sup>b\*</sup>, Mehran Sattari<sup>b</sup>

<sup>a</sup> MA in Remote Sensing, University of Isfahan, Isfahan, Iran

<sup>b</sup> Assistant Professor in Geomatics, University of Isfahan, Isfahan, Iran

Received: 14 November 2022

Revised: 12 December 2022

Accepted: 15 January 2023

### Abstract

Air pollution is one of the most harmful natural hazards in Tehran metropolitan. Particles with a diameter of less than 2.5 micrometers (PM<sub>2.5</sub>) as one of the most harmful pollutants have endangered the health of people living in Tehran. One of the PM<sub>2.5</sub> estimation techniques is the use of Aerosol Optical Depth (AOD) products derived from satellite observations. Various AOD products are retrieved with different algorithms that do not have the same accuracy and spatial resolution. Due to the differences in many assumptions and approximations adopted in the AOD retrieval process, the generated AOD products involve uncertainties. This issue reduces the accuracy of PM<sub>2.5</sub> concentration estimation. The purpose of this study was to investigate the possibility of fusing AOD products obtained from MODIS sensor observations (retrieved by Deep Blue and Dark Target algorithms) to estimate PM<sub>2.5</sub> more accurately. First, the performance of different machine learning algorithms in estimating PM<sub>2.5</sub> from AOD data was evaluated. As a result, the XGBoost algorithm with the highest performance was selected as the base model for PM<sub>2.5</sub> estimation. Then, the AOD products were fused using a weighted averaging based on the retrieval quality of the primary products. Finally, the fused AOD product along with meteorological data were employed to estimate PM<sub>2.5</sub> using XGboost. The results demonstrated that the accuracy of PM<sub>2.5</sub> estimation from the fused AOD product is better than when the AOD products are used individually ( $R^2 = 0.77$ ,  $MAE = 7.00 \frac{\mu g}{m^3}$ ,  $RMSE = 9.59 \frac{\mu g}{m^3}$ ). Thus, the retrieval quality of AOD products will lead to more accurate estimation of PM<sub>2.5</sub> in the end.

**Keywords:** Aerosol Optical Depth, Data Fusion, MODIS, PM<sub>2.5</sub>, XGBoost

\*. Corresponding author: Hossein Bagheri Email: h.bagheri@cet.ui.ac.ir Tel:+989127567529

**How to cite this Article:** Mirzaei, A., Bagheri, H., & Sattari, M. (2023). Estimation of PM<sub>2.5</sub> as a harmful environmental hazard in Tehran by fusion of MODIS aerosol products through a machine learning approach. *Journal of Geography and Environmental Hazards*, 12(3), 101-122

DOI: 10.22067/geoeh.2023.79402.1296



Journal of Geography and Environmental Hazards are fully compliant With open access mandates, by publishing its articles under Creative Commons Attribution 4.0 International License (CC BY 4.0).



Creative Commons Attribution 4.0 International License (CC BY 4.0)

## Geography and Environmental Hazards

Volume 12, Issue 3 - Number 47, Fall 2023

<https://geoeh.um.ac.ir>

<https://doi.org/10.22067/geoeh.2023.79402.1296>

جغرافیا و مخاطرات محیطی، سال دوازدهم، شماره چهارم و هفتم، پاییز ۱۴۰۲، صص ۱۲۲-۱۰۱

مقاله پژوهشی

### ارائه یک روش مبتنی بر یادگیری ماشین برای تلفیق محصولات آئروسول سنجنده مادیس جهت بهبود تخمین PM<sub>2.5</sub>، به عنوان یکی از مهم ترین مخاطرات زیست محیطی در شهر تهران

علی میرزایی - کارشناسی ارشد دانشکده مهندسی عمران و حمل و نقل، دانشگاه اصفهان، اصفهان، ایران

حسین باقری<sup>۱</sup> - استادیار گروه مهندسی نقشه برداری، دانشکده مهندسی عمران و حمل و نقل، دانشگاه اصفهان، ایران

مهران ستاری - استادیار گروه مهندسی نقشه برداری، دانشکده مهندسی عمران و حمل و نقل، دانشگاه اصفهان، ایران

تاریخ دریافت: ۱۴۰۱/۸/۲۳ تاریخ بازنگری: ۱۴۰۱/۹/۲۱ تاریخ تصویب: ۱۴۰۱/۱۰/۲۵

#### چکیده

افزایش بحران های محیط زیست در جهان باعث شده است تا در دهه های اخیر اهمیت مطالعه در مورد مسائل زیست محیطی افزایش یابد. آلودگی هوا در ردیف یکی از زیان بارترین مخاطرات طبیعی قرار گرفته است. ذرات معلق در هوا با قطر کمتر از ۲.۵ میکرومتر (PM<sub>2.5</sub>) یکی از خطرناک ترین و مضرترین نوع ذرات در میان آلاینده های مختلف هوا برای سلامتی انسان هستند. یکی از تکنیک های تخمین PM<sub>2.5</sub> استفاده از محصولات عمق نوری آئروسول (AOD) است. محصولات مختلف AOD با الگوریتم های متفاوتی بازیابی می شوند که دارای دقت و قدرت تفکیک مکانی یکسانی نمی باشند. به دلیل تفاوت در فرضیات و تقریبات زیادی که در مراحل بازیابی AOD ها اتخاذ می شود، محصولات AOD تولید شده دارای عدم قطعیت هستند. این موضوع، باعث کاهش دقت تخمین غلظت PM<sub>2.5</sub> می گردد. هدف این مقاله بررسی امکان تلفیق محصولات AOD حاصل از مشاهدات سنجنده MODIS (بازیابی شده توسط

Email: [h.bagheri@cet.ui.ac.ir](mailto:h.bagheri@cet.ui.ac.ir)

۱ نویسنده مسئول: ۰۹۱۲۷۵۶۷۵۲۹

نحوه ارجاع به این مقاله:

میرزایی، علی، باقری، حسین، ستاری، مهران. (۱۴۰۲). ارائه یک روش مبتنی بر یادگیری ماشین برای تلفیق محصولات آئروسول سنجنده مادیس جهت بهبود تخمین PM<sub>2.5</sub>، به عنوان یکی از مهمترین مخاطرات زیست محیطی در شهر تهران. جغرافیا و

مخاطرات محیطی، ۱۲(۳)، صص ۱۲۲-۱۰۱

<https://doi.org/10.22067/geoeh.2023.79402.1296>

الگوریتم‌های Deep Blue و Dark Target) به منظور تخمین دقیق‌تر PM2.5 است. در این مطالعه، نخست با انجام آزمایش بر روی الگوریتم‌های مختلف یادگیری ماشین و بررسی عملکرد آن‌ها در تخمین PM2.5 از روی داده‌های AOD، الگوریتم XGBoost به‌عنوان الگوریتم پایه در روش تلفیق پیشنهادی انتخاب شد. سپس محصول AOD تلفیقی با استفاده از یک روش وزن‌دهی مبتنی بر کیفیت بازیابی محصولات اولیه، تولید شد. محصول تلفیقی به همراه داده‌های هواشناسی و الگوریتم XGBoost برای تخمین PM2.5 مورد استفاده قرار گرفت. نتایج حاصل از تلفیق نشان داد که دقت تخمین PM2.5 محصول تلفیقی در هر سه شاخص RMSE، MAE و  $R^2$  نسبت به حالت‌هایی که محصولات به‌صورت منفرد استفاده شدند، بهتر است ( $R^2 = 0.77$ ،  $MAE = 7.00 \frac{\mu g}{m^3}$ ،  $RMSE = 9.09 \frac{\mu g}{m^3}$ ). علاوه بر افزایش دقت، روش پیشنهادی ساده و از نظر محاسباتی کم‌هزینه است. علاوه بر این در این تحقیق مشخص گردید، توجه به نشانگر کیفی بازیابی محصولات AOD، زمینه دستیابی به یک محصول تلفیقی دقیق‌تر را فراهم خواهد کرد.

کلیدواژه‌ها: عمق نوری آئروسول، تلفیق داده، سنجنده MODIS، PM2.5، الگوریتم XGBoost.

#### ۱- مقدمه

امروزه آلودگی هوا به یکی از مهم‌ترین مخاطرات زیست‌محیطی تبدیل شده است (Huang & Kuo, 2018). رشد جمعیت شهرنشین، توسعه صنعت، افزایش ترافیک و عدم برنامه‌ریزی مناسب در زمینه کنترل منابع آلودگی هوا از جمله عواملی هستند که منجر به افزایش انتشار آلاینده‌ها و تشدید این مشکل شده‌اند. از مهم‌ترین آلاینده‌ها، ذرات معلق<sup>۱</sup> (PM) هستند (Luo et al., 2020). در دهه‌های اخیر علاوه بر منابع طبیعی (مثل آتشفشان‌ها، آتش‌سوزی و طوفان‌های گردوخاک)، افزایش منابع غیرطبیعی مانند استفاده زیاد از سوخت‌های فسیلی در بخش‌های صنعتی و حمل‌ونقل نیز انتشار ذرات معلق را تشدید کرده است. این ذرات به دلیل متفاوت بودن خصوصیات هم‌چون اندازه و ترکیبات شیمیایی تشکیل دهنده، تأثیرات یکسانی بر محیط‌زیست و سلامتی انسان ندارند. ذرات با قطر آئرو دینامیکی کوچک‌تر از ۱۰ میکرومتر را به‌اختصار PM10 و ذرات با قطر آئرو دینامیکی کوچک‌تر از ۲/۵ میکرومتر را به‌اختصار PM2.5 می‌نامند. افزایش غلظت ذرات PM2.5 علاوه بر تهدید سلامت انسان باعث بروز هزینه‌های اقتصادی و تأثیر منفی بر حاصلخیزی خاک، چرخه غذایی، فتوسنتز گیاهان و منابع آبی می‌شود (Liao et al., 2020; Singer, Zobeck, Poberezsky, & Argaman, 2003). بنابراین اندازه‌گیری و پایش میزان غلظت این ذرات امری ضروری است.

یکی از روش‌های معمول در پایش ذرات PM2.5 اندازه‌گیری میزان غلظت آن‌ها با استفاده از ایستگاه‌های زمینی کنترل کیفیت هوا است؛ اما ایستگاه‌های زمینی هزینه احداث و نگهداری بالایی دارند. همچنین، به دلیل کم بودن تعداد این ایستگاه‌ها، امکان تخمین دقیق و پایش تغییرات فضایی غلظت این ذرات خصوصاً در نواحی با تغییرات بالا نظیر شهرها میسر نیست. به‌عنوان یک راه‌حل، از محصولات AOD<sup>1</sup> حاصل از مشاهدات ماهواره‌ای برای تخمین این آلاینده‌ها استفاده می‌شود. مشاهدات ماهواره‌ای علاوه بر پوشش مکانی خوب و پیوستگی زمانی، بسیار مقرون‌به‌صرفه هستند (Anderson et al., 2010). شاخص AOD با تعیین میزان عمق نوری اتمسفر، به‌عنوان یک شاخص مهم در مطالعه میزان کیفیت هوا و غلظت ذرات PM2.5 مورد استفاده قرار می‌گیرد. AOD شاخصی است که میزان جلوگیری از انتشار نور در یک ستون از جو بر اثر حضور ذرات معلق در هوا را اندازه‌گیری می‌کند. بنابراین این شاخص به‌طور مستقیم با میزان غلظت ذرات معلق در جو ارتباط دارد و به‌عنوان یک شاخص کلیدی در مطالعه PM2.5 استفاده می‌شود ((Wei, Chang, Bai, & Gao, 2020) مطالعات زیادی جهت تخمین میزان غلظت ذرات PM2.5 از روی محصولات AOD صورت پذیرفته است (Bagheri, 2022; Hu et al., 2014; Li, 2020; Ni, Cao, ) Zhou, Cui, & P Singh, 2018; Qi, Li, Karimian, & Liu, 2019). با این حال استفاده از محصولات AOD نیز با چالش‌ها و نواقصی همراه است.

کیفیت داده‌های ورودی خصوصاً داده‌های AOD تأثیر بسیاری در دقت تخمین غلظت PM2.5 دارد. در سال‌های اخیر الگوریتم‌های متنوع بازتابی AOD (همچون الگوریتم‌های Dark Target, Deep Blue, MAIAC<sup>2</sup>, SARA<sup>3</sup> و ...) توسط تیم‌های تحقیقاتی مختلف گسترش یافته‌اند (Hui Xu et al., 2012). الگوریتم‌های مختلف بازتابی AOD همیشه خروجی یکسانی از نظر دقت و قدرت تفکیک مکانی نمی‌دهند و در مناطق مختلف عملکردهای متفاوتی دارند (Tang, Bo, & Zhu, 2016). به‌عنوان مثال، محصول Dark Target (DT) برای مناطقی که بازتاب سطح در محدوده مرئی کم است (مانند مناطق دارای پوشش گیاهی) عملکرد بهتری نشان می‌دهد؛ در حالی که محصول Deep Blue (DB) در مناطق با سطوح روشن مانند مناطق شهری نتایج دقیق‌تری به دست می‌دهد (Hsu et al., 2013; Remer, Mattoo, Levy, & Munchak, 2013). با این وجود، عدم قطعیت‌های زیادی در محصولات فوق وجود دارد و این عدم قطعیت‌ها از فرضیات و تقریب‌های زیادی که در مراحل بازتابی AOD از جمله بخش‌های غربالگری ابر، انتخاب مدل بازتابی و تعیین بازتاب سطح اتخاذ می‌شود، ناشی می‌گردند. بدیهی است که عدم قطعیت در محصولات AOD باعث کاهش کیفیت این محصولات و به تبع آن کاهش دقت تخمین PM2.5 می‌شود.

1 Aerosol Optical Depth

2 Multi Angle Implementation of Atmospheric Correction

3 Simplified high resolution MODIS Aerosol Retrieval Algorithm

یکی از روش‌های افزایش کیفیت محصولات مختلف AOD، تلفیق آن‌ها است. به‌طور کلی مدل‌های تلفیق داده، اطلاعات چندین سنجنده را جهت بهبود دقت و دستیابی به اطلاعات جامع‌تر، ترکیب می‌کنند (Castanedo, 2013; Hall & Llinas, 1997; Khaleghi, Khamis, Karray, & Razavi, 2013; Meng, Jing, Yan, & Pedrycz, 2020; Mirzaei, Bagheri, & Sattari, 2023). تلفیق این محصولات منجر به رفع عیوب هر یک و همچنین افزایش توانایی‌های بالقوه آن‌ها می‌شود

(Bagheri, Schmitt, d'Angelo, & Zhu, 2018; Bagheri, Schmitt, & Zhu, 2018; H Xu et al., 2015). در

مطالعات گذشته نیز تلاش‌هایی برای بهبود عملکرد محصولات AOD صورت پذیرفته است. به‌عنوان مثال، **هان و همکاران<sup>۱</sup> (۲۰۱۷)** محصولات AOD سنجنده‌های MODIS2 و CALIOP3 را در یک فرآیند دو مرحله‌ای با هم تلفیق کردند. در مرحله اول شرایطی که هرکدام از محصولات این دو سنجنده با کیفیت بهتر عمل می‌کرد، تعیین شد. در مرحله بعد، تلفیق دو محصول براساس نقاط ضعف و قوت آن‌ها انجام شد و دقت به‌طور قابل‌توجهی از ۰.۶۵ و ۰.۵۲ به ترتیب برای محصول MODIS و CALIOP به ۰.۸۰ برای محصول تلفیق شده براساس  $R^2$  افزایش یافت (Han, Ding, Ma, & Gong, 2017). همچنین وانگ و همکاران<sup>۲</sup> (۲۰۱۹) محصول عمق نوری آتروسول سنجنده MODIS از سکوه‌های Terra و Aqua که با الگوریتم DB تولید شده بودند را برای بهبود پوشش مکانی تلفیق کردند. دقت محصول نهایی برابر با دقت محصول MODIS بود و تعداد پیکسل‌های دارای مقدار در محصول تلفیقی ۱۲۳ درصد نسبت به محصولات منفرد افزایش یافت. اخیراً در یک مطالعه دیگر به تلفیق محصولات AOD به دست آمده از یک سنسور فعال (CALIPSO) و یک سنسور غیر فعال (MODIS) پرداخته شد. برای تلفیق این محصولات از روش بیزین ماکزیمم آنتروپی استفاده شد. نتایج بهبود قابل‌توجه پوشش مکانی را نشان داد (پوشش مکانی، برای محصولات منفرد در بازه ۰.۳ درصد تا ۷۵.۴ درصد و برای محصول تلفیقی در بازه ۵۶.۷ درصد تا ۱۰۰ درصد قرار داشت). این در حالی است که دقت محصول تلفیق شده براساس شاخص RMSE برابر با ۵۰.۲۰ و دقت محصولات اولیه به ترتیب ۰.۱۹ و ۰.۱۸ برای محصولات CALIOP و MODIS بود (Xia et al., 2021). همچنین در مطالعه‌ای در سال ۲۰۲۲، با بهره‌گیری از مزایای شبکه‌های بیزین و رویکرد تلفیق محصولات AOD حاصل از سنجنده‌های CALIOP و MODIS، سعی در بهبود قدرت تفکیک زمانی محصول عمودی AOD شده است. در این تحقیق با بکارگرفتن محصول MAIAC، مشاهدات MODIS و محصول عمودی AOD حاصل از CALIOP،

1 Han, Ding, Ma, & Gong, 2017

2 Moderate Resolution Imaging Spectroradiometer

3 Cloud-Aerosol Lidar with Orthogonal Polarization

4 Y. Wang et al., 2019

مقادیر AOD در دو لایه ارتفاعی مجزا با قدرت تفکیک مکانی-زمانی MAIAC (به ترتیب یک کیلومتری و روزانه) ارائه شد (Pashayi & Satari, 2022).

علاوه بر کیفیت محصولات AOD، الگوریتم مورد استفاده برای تخمین رابطه AOD با داده‌های هواشناسی و PM2.5 نیز بر دقت تخمین PM2.5 مؤثر است (باقری، ۲۰۲۲). مطالعات زیادی، با استفاده از روش‌های متنوع، جهت تخمین میزان غلظت ذرات PM2.5 از روی محصولات AOD صورت پذیرفته است (Bagheri, 2022; Hu et al., 2019; Ni et al., 2018; Qi et al., 2019; Li, 2020). دسته‌ای از این روش‌ها مبتنی بر یادگیری ماشین می‌باشند که در مطالعات متعددی قابلیت آن‌ها به اثبات رسیده است

(Bagheri, 2022, 2023; Chen, Yang, Du, & Huang, 2021; Gogikar, Tripathy, Rajagopal, Paul, & Tyagi, 2021; Hu et al., 2014; Jung, Chen, & Nakayama, 2021; Kianian, Liu, & Chang, 2021; Li, 2020; Zhang, 2017; You et al., 2016; Zhao et al., 2018; Stafoggia et al., 2019; Yang, Yuan, Li, Shen et al., 2020). نی و همکاران (۲۰۱۸) از یک شبکه Fully Connected با یک لایه میانی استفاده کردند و رابطه میان PM2.5، محصول DT سنجنده MODIS و داده‌های هواشناسی را تخمین زدند. این شبکه هفت نورون در لایه ورودی، هفت نورون در لایه میانی و یک نورون در لایه خروجی داشت. نتایج، PM2.5 را با دقت ۶۸ درصد براساس شاخص R<sup>2</sup> ارائه کردند. همچنین نبوی و همکاران (۲۰۱۹) از AOD و پارامترهای هواشناسی شامل شش پارامتر بیشینه، کمینه و میانگین دما، زاویه تابش خورشید، میزان دید و سرعت باد برای برآورد غلظت PM2.5 در تهران استفاده کردند. آن‌ها AOD را به کمک ارتفاع لایه تداخل مرزی استاندارد کردند و از الگوریتم درخت تصمیم‌گیری برای برآورد غلظت PM2.5 استفاده کردند. در بهترین حالت، دقت نهایی براساس شاخص R<sup>2</sup> به ۰.۶۸ رسید (نبوی و همکاران، ۲۰۱۹). در یک مطالعه دیگر (۲۰۱۹)، برای پیش‌بینی PM2.5، به مقایسه عملکرد سه الگوریتم RF، Fully Connected و XGBoost براساس داده‌های هواشناسی (شامل بیشینه، کمینه و میانگین دمای هوا، رطوبت نسبی، بارش روزانه، میزان دید، سرعت باد، پایداری سرعت باد، فشار هوا و دمای نقطه شبنم) و داده‌های عمق نوری آتروسل پرداخته شد که الگوریتم XGBoost با RMSE برابر  $13.58 \frac{\mu g}{m^3}$  بهترین عملکرد را از خود نشان داد (Zamani Joharestani, Cao, Ni, Bashir, & Talebiesfandarani, 2019). یان و همکاران<sup>۲</sup> (۲۰۲۰) با سه روش RF، شبکه عصبی و روش XGBoost به تخمین PM2.5 پرداختند. در این تحقیق، روش XGBoost عملکرد بهتری (R<sup>2</sup> برابر ۶۴ درصد) نسبت به دو روش دیگر داشت. باقری (۲۰۲۲) با روش Gradient Boosting و به کمک محصول MAIAC و داده‌های هواشناسی به تهیه نقشه PM2.5 با وضوح بالا در شهر تهران پرداخت. در حین این

1 Nabavi et al.

2 Yan et al.

تحقیق، به تأثیر چندین متغیر بر تخمین  $PM_{2.5}$  پرداخته شد. همچنین نشان داده شد که الگوریتم یادگیری ماشین Gradient Boosting بهترین عملکرد را در میان سایر الگوریتم‌های یادگیری ماشین دارد ( $R^2$  برابر با ۷۴ درصد). بررسی مطالعات گذشته نشان می‌دهد که یادگیری ماشین به یک موضوع پرطرفدار تحقیقاتی در حوزه تخمین غلظت ذرات  $PM_{2.5}$  از روی داده‌های آئروسول تبدیل شده است. تنوع الگوریتم‌های استفاده شده در مطالعات قبل، اهمیت انتخاب الگوریتم پایه برای تلفیق را دو چندان می‌کند. این مقلله به بررسی تولنایی و دقت الگوریتم‌های مختلف در تخمین غلظت ذرات  $PM_{2.5}$  از داده‌های آئروسول ماهواره‌ای و اطلاعات هواشناسی نیز می‌پردازد. در نتیجه، یک مدل یادگیری ماشین با بهترین عملکرد، به‌عنوان مدل پایه در تلفیق محصولات مختلف AOD حاصل از تصاویر مادیس انتخاب می‌گردد. سپس، تلفیق با استفاده از مدل پایه و شاخص کیفیت بازیابی محصولات AOD به روش میانگین وزن‌دار انجام خواهد شد. این ایده با کم کردن اثر داده‌های بی‌کیفیت و مشارکت بیشتر داده‌های AOD بازیابی شده با دقت بالا در فرآیند تلفیق، منجر به تخمین دقیق‌تر  $PM_{2.5}$  خواهد گردید. به‌طور مشخص هدف اصلی این مطالعه بهبود دقت تخمین  $PM_{2.5}$  از طریق حذف یا کاهش منابع عدم قطعیت موجود در محصولات AOD با استفاده از تلفیق آن‌ها است.

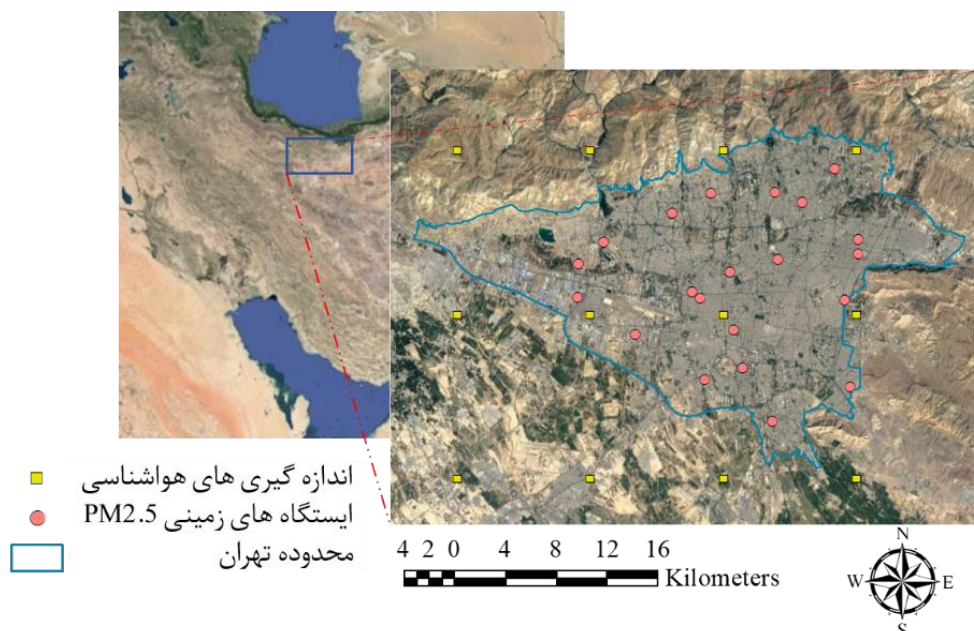
## ۲- مواد و روش

### ۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه، شهر تهران، پایتخت ایران است که دارای ۱۳.۳ میلیون جمعیت (Habibi, Alesheikh, & Mohammadinia, & Sharif, 2017). شکل ۱ موقعیت این منطقه را نشان می‌دهد. این شهر از ۳۵.۳۵ تا ۳۵.۴۸ درجه شمالی و از ۵۱.۱۷ تا ۵۱.۳۳ درجه شرقی گسترش یافته و ۷۵۱ کیلومتر مربع مساحت دارد.

### ۲-۲ داده‌های مورد استفاده

در این مطالعه از محصولات AOD سنجنده MODIS (Deep Blue و Dark Target)، اندازه‌گیری‌های زمینی  $PM_{2.5}$  و داده‌های یک مدل جهانی هواشناسی (European Centre for Medium-Range Weather Forecasts) استفاده گردید. نوع و مشخصات داده‌های مورد استفاده برای تخمین  $PM_{2.5}$  به‌طور خلاصه در جدول ۱ نمایش داده شده‌اند. داده‌ها برای یک بازه زمانی هفت ساله، از ژانویه ۲۰۱۳ تا دسامبر ۲۰۱۹ جمع‌آوری شدند. در ادامه به جزئیات هرکدام از داده‌ها اشاره شده است.



شکل ۱- منطقه مورد مطالعه، شهر تهران

جدول ۱- داده های استفاده شده برای تخمین غلظت PM<sub>2.5</sub>

داده	توضیح	منبع داده	قدرت تفکیک مکانی	قدرت تفکیک زمانی
AOD	محصولات Dark و Deep Blue Target	سنجنده MODIS	۱۰ و ۳ km	روزانه
Latitude	عرض جغرافیایی ایستگاه های اندازه گیری PM <sub>2.5</sub>	AQCC	۱۰ km	روزانه
Longitude	طول جغرافیایی ایستگاه های اندازه گیری PM <sub>2.5</sub>	AQCC	۱۰ km	روزانه
Dewpoint temperature (DPT)	دمای نقطه شبنم	ECMWF	۱۰ km	روزانه
Temperature (T)	دما	ECMWF	۱۰ km	روزانه
Boundary layer height (BLH)	ارتفاع لایه مرزی	ECMWF	۱۰ km	روزانه
Surface pressure (SP)	فشار سطحی	ECMWF	۱۰ km	روزانه
Leaf area index, high vegetation (Lai hv)	شاخص پوشش برگ، برای مناطق با پوشش متراکم گیاهی	ECMWF	۱۰ km	روزانه
Leaf area index, low vegetation (Lai lv)	شاخص پوشش برگ، برای مناطق با پوشش کم گیاهی	ECMWF	۱۰ km	روزانه
Wind speed (WS)	سرعت باد	ECMWF	۱۰ km	روزانه



داده	توضیح	منبع داده	قدرت تفکیک مکانی	قدرت تفکیک زمانی
<b>Wind direction (WD)</b>	جهت باد	ECMWF	۱۰ km	روزانه
<b>Clear sky direct solar radiation at surface (Cdir)</b>	مقدار تابش رسیده به سطح در شرایط آسمان صاف	ECMWF	۱۰km	روزانه
<b>Downward UV radiation at the surface (Uvb)</b>	مقدار اشعه فرابنفش رسیده به سطح زمین	ECMWF	۱۰km	روزانه
<b>Relative humidity (RH)</b>	رطوبت نسبی	ECMWF	۱۰km	روزانه
<b>Day of year (DOY)</b>	شماره روز سال	-	-	-

### ۲-۲-۱- محصولات AOD

در این تحقیق از محصولات AOD سنجنده MODIS استفاده شد. این سنجنده AOD را با الگوریتم‌های DT و DB در طول موج ۵۵ نانومتر بازیابی می‌کند. سنجنده MODIS بر روی دو سکوی Terra و Aqua قرار دارد. محصولات با قدرت تفکیک زمانی روزانه، به صورت رایگان در دسترس هستند (<https://earthexplorer.usgs.gov>). در کنار تمام محصولات AOD مورد استفاده، یک نشانگر کیفیت بازیابی (Q) نیز ارائه می‌شود. مقادیر Q از ۰ (پایین‌ترین کیفیت) تا ۳ (بالترین کیفیت) متغیر است. این مقادیر براساس تعداد پیکسل‌های ورودی برای بازیابی AOD، نزدیکی به مناطقی با سطح روشن و مقدار خطای بازیابی، اختصاص داده می‌شوند ("Dark Target aerosol", 2020, product user's guid).

### ۲-۲-۲- اندازه‌گیری زمینی PM2.5

همان‌طور که در شکل ۱ نمایش داده شده است، مقدار متوسط روزانه PM2.5 در سطح شهر تهران توسط شرکت کنترل کیفیت هوای تهران<sup>۱</sup> (AQCC) در ۲۱ ایستگاه اندازه‌گیری ارائه می‌شود (<https://www.iqair.com>).

### ۲-۲-۳- داده‌های هواشناسی

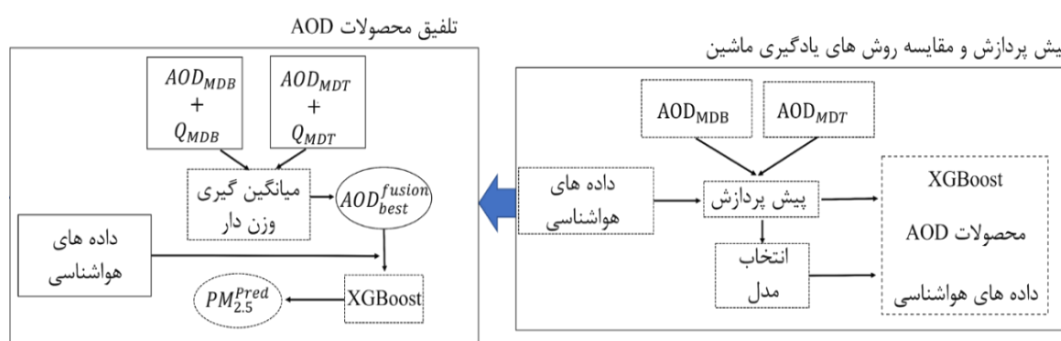
مطالعات مختلفی لزوم استفاده از داده‌های هواشناسی در کنار داده AOD برای تخمین غلظت PM2.5 را روشن ساخته‌اند (Gupta & Christopher, 2009; Ni et al., 2018). برای تهیه داده‌های هواشناسی روزانه از خروجی مدل جهانی ECMWF<sup>۲</sup> استفاده شد. این داده‌ها نسبت به داده‌های هواشناسی زمینی در منطقه مورد مطالعه، توزیع بهتری دارند. همان‌طور که در جدول ۱ و شکل ۱ مشخص است این داده‌ها با قدرت تفکیک مکانی ۱۰ کیلومتر و قدرت تفکیک زمانی روزانه فراهم شده‌اند.

1 Air Quality Control Company

2 European Centre for Medium-Range Weather Forecasts

## ۲-۳- روش تحقیق

شکل ۲ روند کلی تحقیق را نشان می‌دهد. نخست، پیش پردازش‌ها بر روی داده‌های خام انجام می‌شود. سپس عملکرد چندین الگوریتم یادگیری ماشین در تخمین  $PM_{2.5}$  با استفاده از محصولات مختلف، بررسی و الگوریتم برتر به‌عنوان الگوریتم پایه در تلفیق محصولات AOD استفاده می‌شود و در نهایت، روش پیشنهادی جهت تلفیق محصولات AOD ارائه می‌شود. از این ساختار کلی می‌توان برای تلفیق دیگر محصولات AOD و نیز در موقعیت‌های مکانی دیگر بهره برد.



شکل ۲- چارچوب پیاده‌سازی شده برای تلفیق محصولات AOD برای تخمین  $PM_{2.5}$

## ۲-۳-۱- پیش پردازش محصولات AOD

مطالعات گذشته نشان داده‌اند برای تعیین صحت AOD اندازه‌گیری شده می‌توان از مقادیر پیکسل‌های اطراف استفاده کرد (باقری، ۲۰۲۲). به بیان دیگر اختلاف زیاد بین مقادیر اندازه‌گیری شده در یک همسایگی، نشان دهنده حضور ابر، برف و یا دیگر عوارض مخرب است. در این مطالعه نیز به‌منظور استخراج AOD در موقعیت هر ایستگاه زمینی، از یک پنجره  $3 \times 3$  استفاده می‌شود و در هر پنجره، میانگین مقادیر AOD به‌همراه انحراف معیار آن‌ها محاسبه می‌گردد. چنانچه در هر پنجره انحراف معیار از  $0.02$  بیشتر باشد، اندازه‌گیری مذکور غیر قابل اطمینان بوده و حذف می‌گردد. مقدار نهایی AOD در یک پنجره بر اساس میانگین مقادیر قابل اطمینان (پس از بررسی در شرط مذکور) تعیین می‌گردد.

نکته مهم دیگر این است که AOD در یک ستون از جو اندازه‌گیری می‌شود. در حالی که ذرات  $PM_{2.5}$  در نزدیکی سطح حضور دارند. در این خصوص مقادیر AOD قبل از هر پردازشی باید تصحیح شوند. تسای و همکاران<sup>۱</sup> (۲۰۱۱) نشان دادند که این تصحیح را می‌توان با تقسیم AOD بر ارتفاع لایه تداخل (Mixing layer)

1 Tsai et al.

(height) همانند رابطه ۱ بدست آورد (Tsai, Jeng, Chu, Chen, & Chang, 2011; Z. Wang, Chen, Tao, Zhang, & Su, 2010). که در آن nAOD مقدار نرمال شده AOD است و  $L_{mix}$  نیز ارتفاع لایه تداخل را نشان می دهد.

$$nAOD = \frac{AOD}{L_{mix}} \quad (1)$$

در این مطالعه فرض شد که ذرات آئروسول به صورت همگن مخلوط شده و از ارتفاع لایه صرف نظر شد. علاوه بر این نبوی و همکاران (۲۰۱۹) نشان دادند که ارتفاع لایه آئروسول و ارتفاع لایه مرزی (Blh) دارای ارتفاع یکسانی بالاتر از لایه های مملو از آئروسول هستند در نتیجه،  $L_{mix}$  را می توان با Blh جایگزین کرد (نبوی و همکاران، ۲۰۱۹). بن؛راین، معادله ۱ را می توان به صورت زیر بازنویسی کرد که آن nAOD مقدار نرمال شده AOD و Blh نیز ارتفاع لایه مرزی است.

$$nAOD = \frac{AOD}{Blh} \quad (2)$$

### ۲-۳-۲- پیش پردازش PM2.5

در ایستگاه های کنترل کیفیت هوای شهر تهران از دستگاه TEOM<sup>1</sup> برای تعیین غلظت ذرات PM2.5 استفاده می شود. این دستگاه قبل از اندازه گیری غلظت PM2.5، دمای محیط را تا ۵۰ درجه سانتیگراد بالا می برد. این امر باعث می شود جرم خشک PM2.5 به عنوان غلظت PM2.5 گزارش شود (باقری، ۲۰۲۲). مطالعات قبلی نشان داده اند رابطه میان AOD و PM2.5 تحت تأثیر رطوبت هوا است (ژلنگ و همکاران<sup>۲</sup>، ۲۰۱۶). در این تحقیق به کمک فرمول ۳ اثر رطوبت بر PM2.5 اعمال می گردد که در آن  $PM_c$ ، PM تصحیح شده و RH رطوبت نسبی است که بر حسب درصد بیان می شود.

$$PM_c = PM \left(1 - \frac{RH}{100}\right)^{-1} \quad (3)$$

### ۲-۳-۳- پیش پردازش داده های هواشناسی

علاوه بر AOD، داده های هواشناسی نیز در تخمین PM2.5 نقش مهمی را ایفا می کنند. در این مطالعه از داده های هواشناسی ECMWF استفاده شد. برای تعیین داده های هواشناسی در موقعیت ایستگاه های PM2.5، از روش درون یابی کریجینگ استفاده شد. هایپر پارامترهای این روش نیز از طریق اعتبار سنجی متقابل<sup>۳</sup> تعیین شد (Bagheri, Sadeghian, & Sadjadi, 2014). جدول ۲ دقت درون یابی و یکسری اطلاعات آماری برای هر پارامتر هواشناسی را نشان می دهد.

1 Tapered Element Oscillating Microbalance

2 Zhang et al.

3 K-Fold Cross Validation

جدول ۲- اطلاعات آماری و دقت درونیابی پارامترهای هواشناسی

دقت درونیابی (MAE)	کمینه مقدار	بیشینه مقدار	میانگین	داده هواشناسی
۳۶.۵۲	۲۲.۹	۱۹۷۱.۲	۶۲۲.۱	Blh (m)
۶۷۸.۷۴	۳۳۶۶۴۷.۸	۱۰۳۶۴۲۶.۸	۷۲۱۴۲۸.۲	Cdir ( $\frac{J}{m^2}$ )
۱.۳۰	۲۵۲.۵	۲۸۶.۹	۲۷۱.۹	DPT (K)
۱.۱۷	۲۶۲.۴	۳۰۷.۹	۲۸۷.۴	T (K)
۰.۲۲	۱.۳۶	۲.۱۹	۱.۸۰	Lai_hv
۰.۰۱	۰.۴۸	۰.۵۳	۰.۵۰	Lai_lv
۲۴۲۸.۲۴	۷۹۷۲۲.۲	۸۶۹۲۱.۳	۸۳۳۰۸.۰	Sp (Pa)
۱۹۴۶۸۱	۹۲۳۰۶.۵	۱۳۸۶۳۷.۱	۱۲۰۲۶.۴	Uvb ( $\frac{J}{m^2}$ )
۰.۴۶	-۲.۴۲	۲.۰۹	-۰.۵۲	WD (R)
۰.۰۷	۰.۵۴	۴.۷۸	۱.۷۴	WS ( $\frac{m}{s}$ )
۱	۶۴	۷۹	۷۱	RH (%)

### ۲-۳-۴- مقایسه عملکرد روش‌های یادگیری ماشین و انتخاب مدل پایه برای تلفیق

همانگونه که در فصل مقدمه ذکر گردید، الگوریتم‌های یادگیری ماشینی مختلفی برای تخمین PM2.5 از داده‌های AOD مورد استفاده قرار گرفته‌اند که هر کدام عملکرد متفاوتی را در تحقیقات مختلف بر اساس منطقه مورد مطالعه و داده‌های ورودی نشان داده‌اند؛ بنابراین، در ابتدا لازم است عملکرد چند الگوریتم یادگیری ماشین پرکاربرد، در تخمین PM2.5 با استفاده از محصولات AOD مختلف بررسی گردد. هدف از این کار، یافتن دقیق‌ترین الگوریتم برای استفاده در تلفیق محصولات AOD می‌باشد. در ادامه شرح مختصری از الگوریتم‌های به کاررفته بیان می‌گردد. یکی از الگوریتم‌های پایه در تخمین PM2.5، مدل رگرسیون خطی چند متغیره می‌باشد که در مطالعات متعددی مورد استفاده قرار گرفته است (Gogikar et al., 2021; Hu et al., 2014; You et al., 2016). باین حال الگوریتم‌های خطی قادر به حل مسائل غیرخطی پیچیده با ابعاد بالا نیستند. در نتیجه الگوریتم‌های پیشرفته‌تری نظیر الگوریتم رگرسیون بردار پشتیبان<sup>۱</sup> (SVR) در حل این مسائل مورد استفاده قرار می‌گیرند (Chen et al., 2021). این الگوریتم مسائل تفکیک ناپذیر در فضایی با ابعاد کم را از طریق یک نگاشت و با بردن به یک فضای جدید با ابعاد بیشتر، با استفاده از یک ابرصفحه تفکیک می‌کند (Chang & Lin, 2011). علاوه بر الگوریتم ماشین بردار پشتیبان، درخت‌های تصمیم، قابلیت بالایی را در حل مسائل رگرسیون غیرخطی نشان داده‌اند. نسخه پیشرفته‌ای از این الگوریتم‌ها نظیر جنگل تصادفی<sup>۲</sup> (RF) در مطالعات بسیاری برای تخمین غلظت PM2.5 از داده‌های AOD مورد استفاده قرار

1 Support Vector Regression

2 Random Forest

گرفته‌اند (Jung et al., 2021; Kianian et al., 2021; Stafoggia et al., 2019). RF با تجمیع<sup>۱</sup> کردن درختان تصمیم در برابر بیش برآزش مقاوم بوده و ضمن شناسایی داده‌های پرت، می‌تواند اهمیت متغیرهای ورودی را ارزیابی کند (Xiao, Chang, Geng, & Liu, 2018). باین حال، با افزایش درختان و پیچیدگی هر درخت، زمان آموزش و پیش بینی مدل افزایش می‌یابد. الگوریتم XGBoost بر مبنای تقویت<sup>۲</sup> درختان تصمیم شکل می‌گیرد. این الگوریتم در برابر بیش از حد یادگیری، مقاوم است و از پردازش موازی در حین آموزش استفاده می‌کند که باعث بالا رفتن سرعت پردازش و دستیابی به دقت بالاتر می‌گردد (Zamani Joharestani et al., 2019). همچنین اخیراً، الگوریتم‌های یادگیری عمیق، عملکرد بسیار موفقی در حوزه‌های گوناگون نظیر رگرسیون و طبقه بندی نشان داده‌اند (Zhu et al., 2020). متداول‌ترین ساختار در حل مسائل رگرسیون با استفاده از داده‌های جدولی، شبکه‌های FC<sup>۳</sup> می‌باشند (Bharath Ramsundar & Reza Bosagh Zadeh, 2018). با این وجود به‌طور کلی الگوریتم‌های یادگیری عمیق بر مواجهه با داده‌های جدولی ناهمگون از سایر الگوریتم‌های یادگیری ماشینی کلاسیک به ویژه روش‌های مبتنی بر درختان تصمیم، ضعیف‌تر عمل می‌کنند (میرزایی و همکاران، ۲۰۲۳). NODE<sup>۵</sup> یک معماری یادگیری عمیق پیشرفته است که برای کار با هر نوع داده جدولی و پوشش این ضعف، طراحی شده است (Popov, Morozov, & Babenko, 2019).

لازم به ذکر است در این تحقیق و در هر آزمایش، ۷۵ درصد داده‌ها به‌عنوان داده آموزشی<sup>۶</sup> و ۲۵ درصد داده‌ها به‌عنوان داده آزمایشی<sup>۷</sup>، به شکل تصادفی، انتخاب شدند. هاپرپارامترها در تمام الگوریتم‌ها (بجز روش رگرسیون خطی<sup>۸</sup> و Fully connected) از طریق روش اعتبار سنجی متقابل، با استفاده از داده‌های آموزشی با انتخاب  $K=5$  تعیین شدند. همچنین سه شاخص  $R^2$ <sup>۹</sup>، RMSE<sup>۱۰</sup> و MAE<sup>۱۱</sup> به‌عنوان شاخص دقت، در ارزیابی نتایج، مورد استفاده قرار گرفتند.

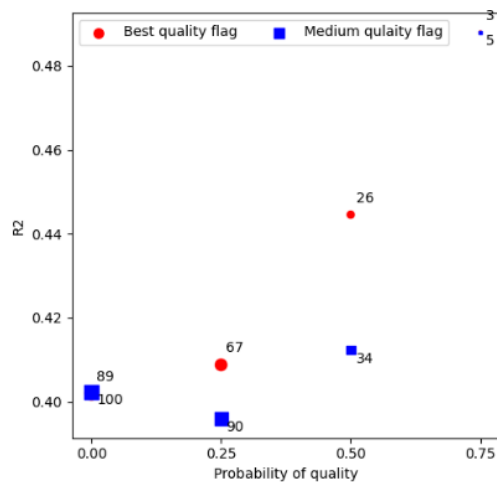
### ۲-۳-۵- تلفیق محصولات AOD

همان‌طور که قبلاً بیان گردید هدف این پژوهش بهبود تخمین PM2.5 از روی تلفیق داده‌های AOD می‌باشد. باین حال، مطالعات قبلی نیز حاکی از عملکرد متفاوت محصولات AOD در مناطق مختلف‌اند (Liu et al., 2019; )

- 
- 1 Aggregate et al.
  - 2 Boosting
  - 3 Fully connected
  - 4 Mirzaei et al.
  - 5 Neural Oblivious Decision Ensemble
  - 6 Train
  - 7 Test
  - 8 Linear
  - 9 R-squared
  - 10 Root Mean Squared Error
  - 11 Mean Absolute Error

استفاده شده برای بازیابی محصولات AOD جستجو کرد (Tang et al., 2016). تلفیق محصولات مختلف AOD منجر به تولید یک محصول خواهد شد که تمام مناطق عملکرد قابل قبولی در تخمین PM2.5 دارد.

در این بخش محصولات AOD به صورت مستقیم و بدون پیش پردازش با یکدیگر تلفیق می شوند. روش پیشنهادی، ساده بوده و بار محاسباتی کمی دارد. چالش اساسی در این نوع تلفیق کاهش نسبت سیگنال به نویز به دلیل استفاده از داده های مختلف و متعدد بودن منابع خطا در آنهاست (Bagheri, Schmitt, & Zhu, 2017). مطالعات قبلی نشان داده اند که فیلتر محصولات AOD با استفاده از نشانگر کیفیت بازیابی (Q)، باعث بهبود عملکرد آنها در تخمین PM2.5 می شوند (Bagheri, 2022; Nabavi, Haimberger, & Abbasi, 2019). شکل ۳ نتایج مطالعه باقری (۲۰۲۲) در خصوص تأثیر اعمال شاخص کیفیت بازیابی AOD محصول MAIAC در تخمین PM2.5 را نشان می دهد (Bagheri, 2022). در این مطالعه داده های AOD بر اساس دو شرط مربوط به کیفیت بازیابی آنها فیلتر گشتند. حالت یک، فقط شامل شرط ابری نبودن پیکسل مورد نظر و حالت دوم علاوه بر حالت یک، شامل ابری و برفی نبودن پیکسل های مجاور است. همان طور که در شکل ۳ مشخص است افزایش احتمال حضور پیکسل های باکیفیت، باعث افزایش دقت از نظر شاخص  $R^2$  می گردد، با این حال فیلتر داده ها بر اساس این شاخص، باعث کاهش تعداد نمونه ها می شود. در این تحقیق نیز برای جلوگیری از کاهش نسبت سیگنال به نویز و نیز بهبود دقت محصول نهایی، از شاخص Q برای تلفیق در سطح داده استفاده شد. برای این منظور، از میانگین وزن دار AOD ها برای تلفیق آنها استفاده گردید. در ابتدای فرآیند تلفیق، شاخص احتمال حضور مقادیر AOD با کیفیت بالا، در میانگین گیری AOD (جزئیات در بخش ۲-۳-۱)، به عنوان وزن تعیین می گردد. این شاخص، نسبت تعداد پیکسل ها با بهترین کیفیت ( $Q=3$ ) به تعداد کل پیکسل ها در یک پنجره سه در سه اطراف هر ایستگاه را به صورت معادله ۴، نشان می دهد:



شکل ۳- تأثیر افزایش احتمال حضور AOD های با کیفیت بر اساس شرایط حالت یک و شرایط حالت دو بر تخمین PM2.5 (برای جزئیات بیشتر مراجعه کنید به (Bagheri, 2022))

$$P(AOD_{best}) = \frac{\sum_{i=1}^9 n}{9} \quad n = \begin{cases} 1 & \text{if } Q_i == 3 \\ 0 & \text{else} \end{cases} \quad (4)$$

که در آن نشان دهنده شاخص کیفیت بازیابی برای پیکسل  $i$  ام در یک پنجره  $3 \times 3$  است و  $P(AOD_{best})$  بیانگر احتمال حضور پیکسل با کیفیت، در پنجره مذکور می باشد که به عنوان وزن پیکسل مربوطه، در تلفیق AOD ها، مورد استفاده قرار می گیرد.

پس از تعیین وزن ها، AOD تلفیق شده، از میانگین وزن دار AOD های ورودی بر اساس احتمال بدست آمده در رابطه ۴، محاسبه می گردد (رابطه ۵):

$$AOD_{best}^{fusion} = \frac{P(AOD_{Terra}^{DT}) \times AOD_{Terra}^{DT} + \dots + P(AOD_{Aqua}^{DB}) \times AOD_{Aqua}^{DB}}{P(AOD_{Terra}^{DT}) + \dots + P(AOD_{Aqua}^{DB})} \quad (5)$$

که در آن اندیس های Terra و Aqua، به نام سکوهاى هر محصول اشاره دارد. اندیس DT و DB نیز بیانگر الگوریتم بازیابی AOD محصول مورد نظر است. به عنوان مثال  $P(AOD_{Terra}^{DT})$  وزن بدست آمده برای محصول DT سنجنده Terra است یا  $AOD_{Terra}^{DT}$  نیز میانگین AOD های بدست آمده در پنجره  $3 \times 3$  برای محصول DT سنجنده Terra را نشان می دهد.  $AOD_{best}^{fusion}$  نیز محصول تلفیق شده با بهترین شرایط کیفی (حاصل از رابطه ۴) می باشد. در نهایت AOD تلفیق شده به همراه داده های هواشناسی، برای تخمین PM2.5 مورد استفاده قرار می گیرد.

## ۳- نتایج

در این بخش، نتایج مقایسه روش‌های یادگیری ماشین و تلفیق محصولات AOD در تخمین PM2.5 ارائه و مورد بررسی قرار می‌گیرد.

## ۳-۱- نتایج مقایسه روش‌های یادگیری ماشین

در ابتدا توانایی الگوریتم‌های یادگیری ماشین معرفی شده برای تخمین غلظت PM2.5 با استفاده از محصولات DB و DT، مورد ارزیابی قرار گرفتند. دقت الگوریتم‌ها در تخمین غلظت PM2.5، در جدول ۳ بیان گردیده است. همان‌طور که مشخص است الگوریتم XGBoost در دو شاخص RMSE و  $R^2$  بهترین عملکرد را داشته است. عملکرد الگوریتم XGBoost در تخمین PM2.5 با استفاده از محصول MDT، در شاخص  $R^2$  دو درصد، در شاخص RMSE  $\frac{\mu g}{m^3}$  ۰.۱۷ و در شاخص MAE  $\frac{\mu g}{m^3}$  ۰.۳۳ بهتر از الگوریتم RF (به‌عنوان بهترین الگوریتم پس از XGBoost) بود. البته XGBoost هنگام استفاده از این محصول، در شاخص MAE و در رقابت با الگوریتم FC اختلاف ناچیزی در حدود  $\frac{\mu g}{m^3}$  ۰.۰۳ داشت. از منظر شاخص‌های دقت دیگر و همچنین پارامترهایی مثل زمان آموزش و سهولت در تعیین ابرپارامترها، اولویت با انتخاب الگوریتم XGBoost است. زمانی که از محصول MDB برای تخمین PM2.5 استفاده شد، XGBoost در شاخص  $R^2$  دو درصد و در شاخص RMSE  $\frac{\mu g}{m^3}$  ۰.۰۷ نسبت به الگوریتم RF بهتر عمل نمود. درحالی‌که از نظر شاخص MAE، نتایج لندکی ( $\frac{\mu g}{m^3}$  ۰.۰۴) بدتر از الگوریتم RF بود. نکته قابل توجه دیگر برتری محسوس XGBoost نسبت به روش‌های یادگیری عمیق آزمایش شده بود. با وجود موفقیت‌های چشم‌گیر این الگوریتم‌ها در زمینه‌های مختلف، این الگوریتم‌ها در مواجهه با داده‌های جدولی ناهمگون<sup>۱</sup>، عملکرد ضعیف‌تری نسبت به الگوریتم‌های کلاسیک مانند درختان

تصمیم تقویت شده با گرادیان<sup>۲</sup>، دارند. همچنین تنظیم ابرپارامترها و زمان آموزش در روش XGBoost بسیار سریع‌تر از روش‌های یادگیری عمیق است (Shwartz-Ziv & Armon, 2022).

جدول ۳- عملکرد روش‌های یادگیری ماشین در تخمین PM2.5

شاخص دقت	$R^2$		MAE ( $\frac{\mu g}{m^3}$ )		RMSE ( $\frac{\mu g}{m^3}$ )	
	DT	DB	DT	DB	DT	DB
محصولات						
XGBoost	۰.۷۰	۰.۷۶	۸.۴۱	۸.۴۸	۱۱.۰۶	۱۰.۹۱
RF	۰.۶۸	۰.۷۴	۸.۷۴	۸.۴۴	۱۱.۱۳	۱۱.۰۸
FC	۰.۶۴	۰.۷۰	۸.۳۸	۸.۷۰	۱۲.۲۸	۱۰.۹۲

1 heterogeneous tabular data

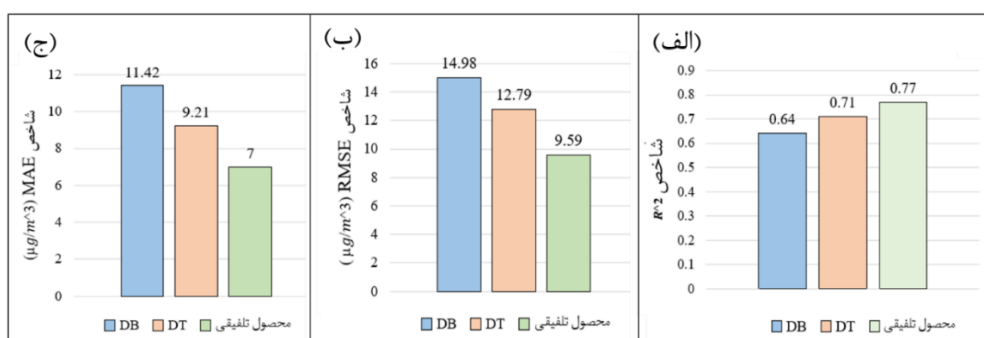
2 gradient boosted decision trees



شاخص دقت	$R^2$		MAE ( $\frac{\mu g}{m^3}$ )		RMSE ( $\frac{\mu g}{m^3}$ )	
	DT	DB	DT	DB	DT	DB
محصولات						
NODE	۰.۵۰	۰.۶۵	۱۱.۶۱	۱۰.۲۸	۱۴.۲۹	۱۴.۳۱
SVR	۰.۵۴	۰.۵۸	۱۷.۵۴	۱۴.۶۰	۱۸.۱۷	۲۰.۸۶
Linear	۰.۵۰	۰.۴۹	۱۱.۳۶	۱۱.۸۲	۲۴.۶۸	۱۴.۳۶

### ۳-۲- نتایج تلفیق

محصولات AOD بر اساس روش توضیح داده شده در بخش ۲-۳-۵ با هم تلفیق گردیدند. شکل ۴ دقت محصول AOD تلفیق شده را نسبت به هر یک از محصولات در تخمین PM2.5، نشان می‌دهد. از نظر شاخص  $R^2$ ، روش پیشنهادی تلفیق و تخمین غلظت PM2.5، شش درصد نسبت به محصول MDT و سیزده درصد نسبت به محصول MDB دقیق‌تر عمل نمود. همچنین نتایج حاصل از تلفیق از نظر شاخص RMSE،  $۳.۲ \frac{\mu g}{m^3}$  نسبت به محصول MDT و  $۵.۳۹ \frac{\mu g}{m^3}$  نسبت به محصول MDB بهبود یافت. عملکرد محصول تلفیقی، از نظر شاخص MAE نیز روش پیشنهادی  $۲.۲۱ \frac{\mu g}{m^3}$  بهتر از MDT و  $۴.۴۲ \frac{\mu g}{m^3}$  بهتر از MDB بود. به‌طور کلی می‌توان چنین نتیجه‌گیری کرد که تلفیق به روش پیشنهادی از نظر دقت، نسبت به هر کدام از محصولات بکار رفته به‌صورت منفرد در تخمین PM2.5 عملکرد بسیار بهتری دارد. اما به ؛ یل شرط استفاده شده برای حذف داده‌های بی‌کیفیت در این روش، برخی اطلاعات که ممکن است در تخمین PM2.5 مفید واقع شوند از دست می‌روند.



شکل ۴- الف) نتایج تلفیق محصولات بر اساس شاخص  $R^2$ ، ب) نتایج تلفیق محصولات بر اساس شاخص MAE و ج) نتایج تلفیق محصولات بر اساس شاخص RMSE

## ۴- بحث و جمع‌بندی

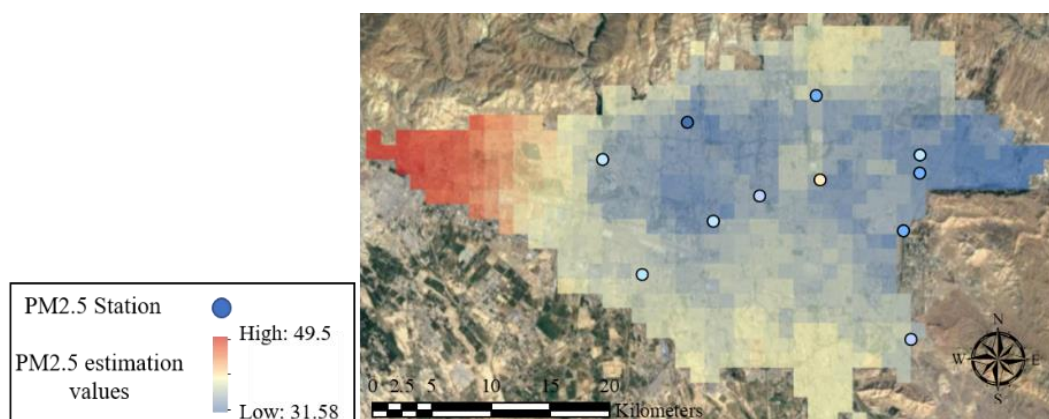
در این مطالعه به بررسی تأثیر تلفیق محصولات AOD بر بهبود دقت تخمین PM2.5، به‌عنوان یکی از مهم‌ترین مخاطرات زیست‌محیطی مخصوصاً در مناطق شهری پرداخته شد. نخست عملکرد الگوریتم‌های مختلف یادگیری ماشین در تخمین PM2.5 ارزیابی شد. نتایج، نشان دهنده برتری الگوریتم XGBoost بر روی داده‌های مورد استفاده در مقایسه با روش‌های یادگیری عمیق، بود. سپس الگوریتم XGBoost، به‌عنوان الگوریتم پایه در روش تلفیق پیشنهادی استفاده گردید. روش پیشنهادی بر اساس میانگین وزن‌دار مبتنی بر وزن‌های حاصل از شاخص کیفیت بازیابی ارائه شده در محصولات AOD، صورت گرفت. روش مذکور با کم کردن تأثیر مشارکت AOD های کم کیفیت و نیز افزایش تأثیر AOD های باکیفیت، باعث بهبود قابل توجه از نظر دقت نسبت به محصولات اولیه برای تخمین PM2.5، شد که در قسمت نتایج ارائه گردید.

همچنین جهت نشان دادن عملکرد مدل پیشنهادی، نقشه PM2.5 حاصل تلفیق داده‌های مختلف AOD در سطح منطقه مورد مطالعه برای یک روز ترسیم گردید. برای ترسیم این نقشه، از اندازه‌گیری‌های زمینی PM2.5 و تخمین‌های بدست آمده از روش پیشنهادی و روش درون‌یابی وزندهی معکوس<sup>۱</sup> بر اساس فاصله، استفاده شد. شکل ۵ نقشه PM2.5 روز چهارم تیر ماه سال ۱۳۹۵ را نشان می‌دهد. بر اساس PM2.5 اندازه‌گیری شده توسط ایستگاه‌های زمینی در این روز، شاخص کیفیت هوا<sup>۲</sup> در دسته متوسط<sup>۳</sup> قرار گرفته است. در این روز تنها ۱۱ ایستگاه از ۲۱ ایستگاه زمینی به دلیل مشکلات فنی، غلظت PM2.5 را ثبت کرده بودند. بر اساس شکل ۵، غلظت PM2.5 با استفاده از روش پیشنهادی در مناطق مرکزی مناطق تحت پوشش ایستگاه‌های زمینی، بین  $\frac{31 \mu g}{m^3}$  تا  $\frac{49 \mu g}{m^3}$  تخمین زده شده است که با AQI اعلام شده از سوی شرکت کنترل کیفیت هوای تهران (بین  $\frac{16 \mu g}{m^3}$  تا  $\frac{41 \mu g}{m^3}$ ) مطابقت دارد. علت این اختلاف اندک را نیز می‌توان در توزیع نامناسب ایستگاه‌های زمینی اندازه‌گیری PM2.5 جستجو کرد. همان‌طور که در شکل مشخص است، در منطقه غرب تهران، به دلیل حضور کارخانه‌ها و منابع آلودگی و نیز وزش باد از سمت غرب به شرق، غلظت ذرات PM2.5 بالاست. این در حالی است که هیچ ایستگاه اندازه‌گیری زمینی در این منطقه وجود ندارد.

1 Inverse Distance Weighting

2 Air Quality Control

3 Moderate



شکل ۵- نقشه روزانه PM2.5 تهیه شده به کمک تلفیق محصولات مختلف AOD

### تقدیر و تشکر

نویسندگان از سازمان‌هایی که داده‌های خام را به صورت رایگان به اشتراک می‌گذارند از جمله ناسا، برای داده‌های AOD سنجنده MODIS، شرکت کنترل کیفیت هوای تهران برای داده‌های زمینی PM2.5 و مرکز پیش‌بینی هواشناسی متوسط مقیاس اروپا برای داده‌های هواشناسی نهایت تشکر و قدردانی را دارند.

### کتابنامه

- Anderson, L. O., Malhi, Y., Aragão, L. E., Ladle, R., Arai, E., Barbier, N., & Phillips, O. (2010). Remote sensing detection of droughts in Amazonian forest canopies. *New Phytologist*, 187(3), 733-750. doi:<https://doi.org/10.1111/j.1469-8137.2010.03355.x>
- Bagheri, H. (2022). A machine learning-based framework for high resolution mapping of PM2.5 in Tehran, Iran, using MAIAC AOD data. *Advances in Space Research*, 69(9), 3333-3349. doi:<https://doi.org/10.1016/j.asr.2022.02.032>
- Bagheri, H. (2023). Using deep ensemble forest for high-resolution mapping of PM2. 5 from MODIS MAIAC AOD in Tehran, Iran. *Environmental Monitoring and Assessment*, 195(3), 377. doi:<https://doi.org/10.1007/s10661-023-10951-1>
- Bagheri, H., Sadeghian, S., & Sadjadi, S. Y. (2014). The Assessment of using an Intelligent Algorithm for the Interpolation of Elevation in the DTM Generation. *Photogrammetrie-Fernerkundung-Geoinformation*, 197-208. doi:<https://doi.org/0.1127/1432-8364/2014/0220>
- Bagheri, H., Schmitt, M., d'Angelo, P., & Zhu, X. X. (2018). A framework for SAR-optical stereogrammetry over urban areas. *ISPRS journal of photogrammetry and remote sensing*, 146, 389-408. doi:<https://doi.org/10.1016/j.isprsjprs.2018.10.003>
- Bagheri, H., Schmitt, M., & Zhu, X. X. (2017). Uncertainty assessment and weight map generation for efficient fusion of TanDEM-X and Cartosat-1 DEMs. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(1/W1), 433-439. doi:<https://doi.org/10.5194/isprs-archives-XLII-1-W1-433-2017>
- Bagheri, H., Schmitt, M., & Zhu, X. X. (2018). Fusion of TanDEM-X and Cartosat-1 elevation data supported by neural network-predicted weight maps. *ISPRS journal of photogrammetry and remote sensing*, 144, 285-297. doi:<https://doi.org/10.1016/j.isprsjprs.2018.07.007>

- Bharath Ramsundar & Reza Bosagh Zadeh. (2018). *TensorFlow for Deep Learning* (Rachel Rouneliotis & Alicia Young Ed. first ed. Vol. 16802 KB).
- Castanedo, F. (2013). A review of data fusion techniques. *The Scientific World Journal*, 2013, 704504. doi:<https://doi.org/10.1155/2013/704504>
- Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: a library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2(3), 1-27. doi:<https://dl.acm.org/doi/10.1145/1961189.1961199>
- Chen, N., Yang, M., Du, W., & Huang, M. (2021). PM2.5 estimation and spatial-temporal pattern analysis based on the modified support vector regression model and the 1 km resolution MAIAC AOD in Hubei, China. *ISPRS International Journal of Geo-Information*, 10(1), 31. doi:<https://doi.org/10.3390/ijgi10010031>
- Dark Target aerosol product user's guide (2020). In: NASA.
- Gogikar, P., Tripathy, M. R., Rajagopal, M., Paul, K. K., & Tyagi, B. (2021). PM2.5 estimation using multiple linear regression approach over industrial and non-industrial stations of India. *Journal of Ambient Intelligence and Humanized Computing*, 12(2), 2975-2991. doi:<https://doi.org/10.1007/s12652-020-02457-2>
- Gupta, P., & Christopher, S. A. (2009). Particulate matter air quality assessment using integrated surface, satellite, and meteorological products: Multiple regression approach. *Journal of Geophysical Research: Atmospheres*, 114(D14). doi:<https://doi.org/10.1029/2008JD011496>
- Habibi, R., Alesheikh, A. A., Mohammadinia, A., & Sharif, M. (2017). An assessment of spatial pattern characterization of air pollution: A case study of CO and PM2.5 in Tehran, Iran. *ISPRS International Journal of Geo-Information*, 6(9), 270. doi: <https://doi.org/10.3390/ijgi6090270>
- Hall, D. L., & Llinas, J. (1997). An introduction to multisensor data fusion. *Proceedings of the IEEE*, 85(1), 6-23. doi:<https://doi.org/10.1109/5.554205>
- Han, B., Ding, H., Ma, Y., & Gong, W. (2017). Improving retrieval accuracy for aerosol optical depth by fusion of MODIS and CALIOP data. *Tehnicki vjesnik/Technical Gazette*, 24(3). doi:<https://doi.org/10.17559/TV-20160429044233>
- Hsu, N., Jeong, M. J., Bettenhausen, C., Sayer, A., Hansell, R., Seftor, C., . . . Tsay, S. C. (2013). Enhanced Deep Blue aerosol retrieval algorithm: The second generation. *Journal of Geophysical Research: Atmospheres*, 118(16), 9296. doi:<https://doi.org/10.1002/jgrd.50712>
- Hu, X., Waller, L. A., Lyapustin, A., Wang, Y., Al-Hamdan, M. Z., Crosson, W. L., . . . Puttaswamy, S. J. (2014). Estimating ground-level PM2.5 concentrations in the Southeastern United States using MAIAC AOD retrievals and a two-stage model. *Remote Sensing of Environment*, 140, 220-232. doi:<https://doi.org/10.1016/j.rse.2013.08.032>
- Huang, C.-J., & Kuo, P.-H. (2018). A deep CNN-LSTM model for particulate matter (PM2.5) forecasting in smart cities. *Sensors*, 18(7), 2220. doi:<https://doi.org/10.3390/s18072220>
- Jung, C.-R., Chen, W.-T., & Nakayama, S. F. (2021). A national-scale 1-km resolution PM2.5 estimation model over Japan using MAIAC AOD and a two-stage random forest model. *Remote Sensing*, 13(18), 3657. doi:<https://doi.org/10.3390/rs13183657>
- Khaleghi, B., Khamis, A., Karray, F. O., & Razavi, S. N. (2013). Multisensor data fusion: A review of the state-of-the-art. *Information Fusion*, 14(1), 28-44. doi:<https://doi.org/10.1016/j.inffus.2011.08.001>
- Kianian, B., Liu, Y., & Chang, H. H. (2021). Imputing satellite-derived aerosol optical depth using a multi-resolution spatial model and random forest for PM2.5 prediction. *Remote Sensing*, 13(1), 126. doi:<https://doi.org/10.3390/rs13010126>
- Li, L. (2020). A robust deep learning approach for spatiotemporal estimation of satellite AOD and PM2.5. *Remote Sensing*, 12(2), 264. doi:<https://doi.org/10.3390/rs12020264>

- Liao, Q., Jin, W., Tao, Y., Qu, J., Li, Y., & Niu, Y. (2020). Health and Economic Loss Assessment of PM<sub>2.5</sub> Pollution during 2015–2017 in Gansu Province, China. *International Journal of Environmental Research and Public Health*, 17(9), 3253. doi:<https://doi.org/10.3390/ijerph17093253>
- Liu, N., Zou, B., Feng, H., Wang, W., Tang, Y., & Liang, Y. (2019). Evaluation and comparison of multiangle implementation of the atmospheric correction algorithm, Dark Target, and Deep Blue aerosol products over China. *Atmospheric Chemistry and Physics*, 19(12), 8243–8268. doi:<https://doi.org/10.5194/acp-19-8243-2019>
- Luo, H., Guan, Q., Lin, J., Wang, Q., Yang, L., Tan, Z., & Wang, N. (2020). Air pollution characteristics and human health risks in key cities of northwest China. *Journal of Environmental Management*, 269, 110791. doi:<https://doi.org/10.1016/j.jenvman.2020.110791>
- Meng, T., Jing, X., Yan, Z., & Pedrycz, W. (2020). A survey on machine learning for data fusion. *Information Fusion*, 57, 115–129. doi:<https://doi.org/10.1016/j.inffus.2019.12.001>
- Mirzaei, A., Bagheri, H., & Sattari, M. (2023). Data level and decision level fusion of satellite multi-sensor AOD retrievals for improving PM<sub>2.5</sub> estimations, a study on Tehran. *Earth Science Informatics*, 16(1), 753–771. doi:<http://dx.doi.org/10.48550/arXiv.2302.10278>
- Nabavi, S. O., Haimberger, L., & Abbasi, E. (2019). Assessing PM<sub>2.5</sub> 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. doi:<https://doi.org/10.1016/j.apr.2018.12.017>
- Ni, X., Cao, C., Zhou, Y., Cui, X., & P Singh, R. (2018). Spatio-temporal pattern estimation of PM<sub>2.5</sub> in Beijing-Tianjin-Hebei Region based on MODIS AOD and meteorological data using the back propagation neural network. *Atmosphere*, 9(3), 105. doi:<https://doi.org/10.3390/atmos9030105>
- Pashayi, M., & Satari, M. (2022). Improvement of spatial-temporal resolution of aerosol profile by using multi-source satellite data over the Persian Gulf. *Atmospheric Environment*, 119410. doi:<https://doi.org/10.1016/j.atmosenv.2022.119410>
- Popov, S., Morozov, S., & Babenko, A. (2019). Neural oblivious decision ensembles for deep learning on tabular data. *arXiv preprint arXiv:1909.06312*. doi:<https://doi.org/10.48550/arXiv.1909.06312>
- Qi, Y., Li, Q., Karimian, H., & Liu, D. (2019). A hybrid model for spatiotemporal forecasting of PM<sub>2.5</sub> based on graph convolutional neural network and long short-term memory. *Science of the Total Environment*, 664, 1–10. doi:<https://doi.org/10.1016/j.scitotenv.2019.01.333>
- Remer, L., Mattoo, S., Levy, R., & Munchak, L. (2013). MODIS 3 km aerosol product: algorithm and global perspective. *Atmospheric Measurement Techniques*, 6(7), 1829–1844. doi:<https://doi.org/10.5194/amt-6-1829-2013>
- Sayer, A., Munchak, L., Hsu, N., Levy, R., Bettenhausen, C., & Jeong, M. J. (2014). MODIS Collection 6 aerosol products: Comparison between Aqua's Deep Blue, Dark Target, and “merged” data sets, and usage recommendations. *Journal of Geophysical Research: Atmospheres*, 119(24), 13,965–13,989. doi:<https://doi.org/10.1002/2014JD022453>
- Shwartz-Ziv, R., & Armon, A. (2022). Tabular data: Deep learning is not all you need. *Information Fusion*, 81, 84–90. doi:<https://doi.org/10.1016/j.inffus.2021.11.011>
- Singer, A., Zobeck, T., Poberezsky, L., & Argaman, E. (2003). The PM<sub>10</sub> and PM<sub>2.5</sub> dust generation potential of soils/sediments in the Southern Aral Sea Basin, Uzbekistan. *Journal of Arid Environments*, 54(4), 705–728. doi:<https://doi.org/10.1006/jare.2002.1084>
- Stafoggia, M., Bellander, T., Bucci, S., Davoli, M., De Hoogh, K., De'Donato, F., . . . Renzi, M. (2019). Estimation of daily PM<sub>10</sub> and PM<sub>2.5</sub> concentrations in Italy, 2013–2015, using a

- spatiotemporal land-use random-forest model. *Environment International*, 124, 170-179. doi:<https://doi.org/10.1016/j.envint.2019.01.016>
- Tang, Q., Bo, Y., & Zhu, Y. (2016). Spatiotemporal fusion of multiple-satellite aerosol optical depth (AOD) products using Bayesian maximum entropy method. *Journal of Geophysical Research: Atmospheres*, 121(8), 4034-4048. doi:<https://doi.org/10.1002/2015JD024571>
- Tsai, T.-C., Jeng, Y.-J., Chu, D. A., Chen, J.-P., & Chang, S.-C. (2011). Analysis of the relationship between MODIS aerosol optical depth and particulate matter from 2006 to 2008. *Atmospheric Environment*, 45(27), 4777-4788. doi:<https://doi.org/10.1016/j.atmosenv.2009.10.006>
- Wang, Y., Yuan, Q., Shen, H., Zheng, L., & Zhang, L. (2020). Investigating multiple aerosol optical depth products from MODIS and VIIRS over Asia: Evaluation, comparison, and merging. *Atmospheric Environment*, 230, 117548. doi:<https://doi.org/10.1016/j.atmosenv.2020.117548>
- Wang, Z., Chen, L., Tao, J., Zhang, Y., & Su, L. (2010). Satellite-based estimation of regional particulate matter (PM) in Beijing using vertical-and-RH correcting method. *Remote Sensing of Environment*, 114(1), 50-63. doi:<https://doi.org/10.1016/j.rse.2009.08.009>
- Wei, X., Chang, N.-B., Bai, K., & Gao, W. (2020). Satellite remote sensing of aerosol optical depth: Advances, challenges, and perspectives. *Critical Reviews in Environmental Science and Technology*, 50(16), 1640-1725. doi:<https://doi.org/10.1080/10643389.2019.1665944>
- Xia, X., Zhao, B., Zhang, T., Wang, L., Gu, Y., Liou, K.-N., . . . Huang, Y. (2021). Satellite-Derived Aerosol Optical Depth Fusion Combining Active and Passive Remote Sensing Based on Bayesian Maximum Entropy. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-13. doi:<https://doi.org/10.1109/TGRS.2021.3051799>
- Xiao, Q., Chang, H. H., Geng, G., & Liu, Y. (2018). An ensemble machine-learning model to predict historical PM2.5 concentrations in China from satellite data. *Environmental science & technology*, 52(22), 13260-13269. doi:<https://doi.org/10.1021/acs.est.8b02917>
- Xu, H., Guang, J., Xue, Y., De Leeuw, G., Che, Y., Guo, J., . . . Wang, T. (2015). A consistent aerosol optical depth (AOD) dataset over mainland China by integration of several AOD products. *Atmospheric Environment*, 114, 48-56. doi:<https://doi.org/10.1016/j.atmosenv.2015.05.023>
- Xu, H., Xue, Y., Guang, J., Li, Y., Yang, L., Hou, T., . . . Chen, Z. (2012). A semi-empirical optical data fusion technique for merging aerosol optical depth over China. Paper presented at the 2012 IEEE International Geoscience and Remote Sensing Symposium.
- Yang, Q., Yuan, Q., Li, T., Shen, H., & Zhang, L. (2017). The relationships between PM2.5 and meteorological factors in China: seasonal and regional variations. *International Journal of Environmental Research and Public Health*, 14(12), 1510. doi:<https://doi.org/10.3390/ijerph14121510>
- You, W., Zang, Z., Zhang, L., Li, Y., Pan, X., & Wang, W. (2016). National-scale estimates of ground-level PM2.5 concentration in China using geographically weighted regression based on 3 km resolution MODIS AOD. *Remote Sensing*, 8(3), 184. doi:<https://doi.org/10.3390/rs8030184>
- Zamani Joharestani, M., Cao, C., Ni, X., Bashir, B., & Talebiesfandarani, S. (2019). PM2.5 prediction based on random forest, XGBoost, and deep learning using multisource remote sensing data. *Atmosphere*, 10(7), 373. doi:<https://doi.org/10.3390/atmos10070373>
- Zhao, C., Wang, Q., Ban, J., Liu, Z., Zhang, Y., Ma, R., . . . Li, T. (2020). Estimating the daily PM2.5 concentration in the Beijing-Tianjin-Hebei region using a random forest model with a 0.01° × 0.01° spatial resolution. *Environment International*, 134, 105297. doi:<https://doi.org/10.1016/j.envint.2019.105297>

Zhu, X. X., Hu, J., Qiu, C., Shi, Y., Kang, J., Mou, L., . . . Huang, R. (2020). So2Sat LCZ42: A benchmark data set for the classification of global local climate zones [Software and Data Sets]. *IEEE Geoscience and Remote Sensing Magazine*, 8(3), 76-89. doi:<https://doi.org/10.1109/MGRS.2020.2964708>