

Investigating the effects of criteria air pollutants and meteorological parameters on the change of black carbon concentration in Tehran and Tabriz

Parisa Kahrari¹, Shahriar Khaledi², Ghasem Keikhosravi^{3*} , Seyed Jalil Alavi⁴

1. PhD Student of Climatology, Department of Natural Geography, University of Shahid Beheshti, Tehran, Iran
2. Professor of Climatology, Department of Natural Geography, University of Shahid Beheshti, Tehran, Iran
3. *Corresponding Author*, Assistant Professor of Climatology, Department of Natural Geography, University of Shahid Beheshti, Tehran, Iran
4. Associate Professor of Forestry, Department of Forestry, University of Tarbiat Modarres, Mazandaran, Iran

Article Info	ABSTRACT
Article type: Research Article Article history: Received: 09 February 2024 Revised: 15 July 2024 Accepted: 05 August 2024 Keywords: Air pollution, Particulate matter, Machine learning, Nonparametric algorithms, R software, Spearman's correlation.	Black carbon (BC) is a primary component of fine particulate matter which has a significant effect on climate and human health, and anthropogenic activity along with weather conditions affects its long-term variability. This study aimed to investigate the statistical relationships between meteorological elements (temperature, rainfall, wind speed, relative humidity, air pressure, sunshine hours, solar radiation, and cloudiness), criteria air pollutants (CO, NO₂, SO₂, O₃, PM₁₀, and PM_{2.5}) and black carbon particles (BC), as well as assess and compare the efficacy of five different machine learning algorithms (multiple linear regression (MLR), generalized additive model (GAM), classification and regression trees (CART), random forest (RF) and gradient boosting machine (GBM)) in modeling pollutants and climatic factors responsible for variations in black carbon concentration levels in Tabriz and Tehran from 2004 to 2021 using R 4.3.2 software. The results of the present study showed a significant variation in the influence of meteorological parameters and criteria air pollutants on the level of black carbon pollutant concentration in Tabriz and Tehran depending on the different geographical locations, weather conditions, and regional structure. Black carbon particles have experienced a significant upward trend with a relatively equal speed during the statistical period studied in the cities of Tabriz and Tehran. Based on the results of Spearman's correlation analysis, black carbon particles have a positive correlation with PM_{2.5}, NO₂, CO, and SO₂ and a negative correlation with O₃. Black carbon was highly correlated with parameters of wind speed (negatively) and relative humidity (positively) in Tabriz and temperature (negatively) and air pressure (positively) in Tehran. Based on the performance evaluation of predictive models and concerning the parsimony principle, the GAM model in Tabriz and the MLR model in Tehran had better performance in predicting black carbon values than other models.
Cite this article: Kahrari, P., Khaledi, S., Keikhosravi, G., & Alavi, S. J. (2025). Investigating the effects of criteria air pollutants and meteorological parameters on the change of black carbon concentration in Tehran and Tabriz. <i>Journal of Natural Environmental Hazards</i>, 14(43), 35-58. DOI: 10.22111/jneh.2024.47935.2028  © Ghasem Keikhosravi. DOI: 10.22111/jneh.2024.47935.2028 Publisher: University of Sistan and Baluchestan	

* Corresponding Author Email: gh_keikhosravi@sbu.ac.ir

مجله علمی پژوهشی مخاطرات محیط طبیعی، دوره ۱۴، شماره ۴۳، پیاپی ۱، بهار ۱۴۰۴

بررسی اثرات آلاینده‌های جوی معیار و پارامترهای هواشناسی بر تغییر غلظت

کربن سیاه در تهران و تبریز

پریسا کهراری^۱، شهریار خالدي^۲، قاسم کیخسروی^{۳*}، سید جلیل علوی^۴

۱. دانشجوی دکتری آب و هواشناسی، گروه جغرافیای طبیعی، دانشگاه شهید بهشتی

۲. استاد آب و هواشناسی، گروه جغرافیای طبیعی، دانشگاه شهید بهشتی

۳. استادیار آب و هواشناسی، گروه جغرافیای طبیعی، دانشگاه شهید بهشتی (نویسنده مسئول)

۴. دانشیار جنگلداری، گروه جنگلداری، دانشگاه تربیت مدرس

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۲/۱۱/۲۰ تاریخ ویرایش: ۱۴۰۳/۰۴/۲۵ تاریخ پذیرش: ۱۴۰۳/۰۵/۱۵ واژه‌های کلیدی: آلودگی هوا، ذرات معلق، یادگیری ماشین، الگوریتم‌های ناپارامتری، نرم افزار R، همبستگی اسپیرمن.	کربن سیاه (BC) یکی از اجزای مهم ذرات ریز معلق در هواست که تأثیر قابل‌توجهی بر آب و هوا و سلامت انسان دارد و فعالیت‌های انسانی همراه با شرایط آب‌وهوایی بر تغییرپذیری آن در طولانی مدت تأثیر می‌گذارد. از این‌رو، این مطالعه به بررسی روابط آماری بین پارامترهای هواشناسی (دما، بارش، سرعت باد، رطوبت نسبی، فشار هوا، ساعات آفتابی، تابش خورشیدی و ابرناکی)، آلاینده‌های معیار هوا (CO، NO₂، SO₂، O₃، PM₁₀ و PM_{2.5}) و آلاینده کربن سیاه و همچنین ارزیابی و مقایسه کارایی پنج الگوریتم یادگیری ماشین (رگرسیون خطی چندگانه (MLR)، مدل جمعی تعمیم‌یافته (GAM)، درخت طبقه‌بندی و رگرسیون (CART)، جنگل تصادفی (RF) و تقویت گرادیان (GBM)) در مدل‌سازی آلاینده‌ها و عوامل آب‌وهوایی مؤثر در تغییرات سطح غلظت آلاینده کربن سیاه در تهران و تبریز و استفاده از نرم‌افزار R 4.3.2 پرداخته است. نتایج این مطالعه بیانگر تفاوت آشکار تأثیر پارامترهای هواشناسی و آلاینده‌های جوی معیار بر سطح غلظت آلاینده کربن سیاه در تبریز و تهران به دلیل موقعیت جغرافیایی، شرایط آب‌وهوایی و ساختار منطقه‌ای متفاوت این شهرها است. ذرات کربن سیاه روند صعودی معناداری را با سرعت نسبتاً برابر در طول دوره آماری مورد مطالعه در شهرهای تبریز و تهران تجربه کرده‌اند. بر اساس یافته‌های حاصل از تحلیل همبستگی اسپیرمن، ذرات کربن سیاه دارای همبستگی مثبت با آلاینده‌های PM_{2.5}، NO₂، CO و SO₂ و همبستگی منفی با O₃ است. آلاینده کربن سیاه دارای بیشترین همبستگی با پارامترهای سرعت باد (منفی) و رطوبت نسبی (مثبت) در تبریز و پارامترهای دما (منفی) و فشار هوا (مثبت) در تهران است. بر اساس ارزیابی عملکرد مدل‌های پیشگو و با توجه به اصل صرفه‌جویی، در تبریز مدل GAM و در تهران مدل مبنای MLR از عملکرد بهتری در پیش‌بینی مقادیر کربن سیاه نسبت به سایر مدل‌ها برخوردار بودند.

استناد: کهراری، پریسا، خالدي، شهریار، کیخسروی، قاسم، علوی، سید جلیل. (۱۴۰۴). بررسی اثرات آلاینده‌های جوی معیار و پارامترهای هواشناسی

بر تغییر غلظت کربن سیاه در تهران و تبریز. مخاطرات محیط طبیعی، ۱۴(۴۳)، ۳۵-۵۸. DOI: 10.22111/jneh.2024.47935.2028



© پریسا کهراری، شهریار خالدي، قاسم کیخسروی*، سید جلیل علوی.

ناشر: دانشگاه سیستان و بلوچستان

مقدمه

رشد شتابان شهرنشینی، افزایش تقاضا و مصرف انرژی، صنعتی شدن و توسعه اقتصادی در سال‌های اخیر، خطرات بهداشتی و زیست‌محیطی ناشی از آلودگی هوا به‌عنوان بزرگ‌ترین بحران بهداشت محیط در قرن حاضر را تشدید کرده است و بسیاری از شهرهای جهان به‌دلیل برنامه‌ریزی و طراحی ضعیف و ترافیک سنگین از کیفیت نامطلوب هوا رنج می‌برند. ذرات معلق با قطر کمتر از $2.5/\mu m$ (PM_{2.5})^۱، که یکی از مهم‌ترین آلاینده‌ها در ارزیابی کیفیت هوای شهری محسوب می‌شوند، ارتباط بسیار نزدیکی با اثرات نامطلوب بر سلامت انسان از جمله مرگ‌ومیر زودرس دارند (نوینیا^۲ و همکاران، ۲۰۲۰). بر اساس گزارش جدید سازمان جهانی بهداشت، سالانه حدود ۷ میلیون نفر بر اثر قرار گرفتن طولانی مدت در معرض ذرات ریز (PM_{2.5}) موجود در هوای آلوده که منجر به بیماری‌های قلبی، سرطان ریه، سکته، بیماری‌های مزمن انسدادی ریه و عفونت‌های تنفسی از جمله ذات‌الریه می‌شود، جان خود را از دست می‌دهند (سازمان بهداشت جهانی، ۲۰۲۱). کربن سیاه (BC)^۳ که اغلب به‌عنوان دوده شناخته می‌شود، یکی از اجزای مهم ذرات ریز معلق در هوا است و بیشتر از احتراق ناقص سوخت‌های فسیلی، سوخت‌های زیستی و زیست توده در جو انتشار می‌یابد (احمد^۴ و همکاران، ۲۰۱۴؛ کواسی^۵ و همکاران، ۲۰۲۱). ذرات کربن سیاه سیستم آب‌وهوایی زمین را به شیوه‌های مختلف از جمله جذب مستقیم انرژی خورشیدی (باند^۶ و همکاران، ۲۰۱۳)، تغییر ویژگی‌های ابر و پایداری حرارتی، تأثیر بر بارش و گردش عمومی جو (لوند^۷ و همکاران، ۲۰۱۷) و کاهش سپیدایی برف و پوشش یخی یخی تحت تأثیر قرار می‌دهد (ژانگ^۸ و همکاران، ۲۰۱۹). کاهش انتشار کربن سیاه ممکن است به بهبود کیفیت هوا در کشورهای در حال توسعه کمک کند (دینگ^۹ و همکاران، ۲۰۱۶). علاوه بر این، می‌تواند گرمایش جهانی را به میزان قابل‌توجهی کاهش دهد (گریشاپ^{۱۰} و همکاران، ۲۰۰۹؛ سامست^{۱۱} و همکاران، ۲۰۱۳). قرارگیری در معرض ذرات کربن سیاه می‌تواند در مقایسه با سایر اجزای ذرات ریز معلق در هوا با اثرات و پیامدهای بهداشتی بیشتری همراه باشد. به همین دلیل مطالعات گسترده‌ای در حوزه آلودگی ذرات کربن سیاه توسط پژوهشگران در نقاط مختلف جهان صورت گرفته است. بسیاری از این مطالعات، ترافیک را منبع اصلی انتشار کربن سیاه در مناطق شهری معرفی کرده‌اند (کیم^{۱۲} و همکاران، ۲۰۱۷؛ وینیگر^{۱۳} و همکاران، ۲۰۱۷؛ جینگ^{۱۴} و همکاران، ۲۰۱۹). در مراکز شهرها که تراکم بالایی از ترافیک وجود دارد، مقادیر بالاتر غلظت کربن سیاه معمولاً در طول روز مشاهده می‌شود (سینگ^{۱۵} و همکاران، ۲۰۱۸). بنابراین سازمان بهداشت جهانی بر اهمیت BC به‌عنوان یکی از عوامل مؤثر در اثرات بهداشتی مرتبط با ترافیک تأکید کرده است (یانسن^{۱۶} و همکاران، ۲۰۱۲). نتایج مطالعات نشان داده‌اند که میانگین

1 Particulate matter with an aerodynamic diameter less than 2.5 microns

2 Navinya

3 Black Carbon

4 Ahmed

5 Kouassi

6 Bond

7 Lund

8 Zhang

9 Ding

10 Grieshop

11 Samset

12 Kim

13 Winiger

14 Jing

15 Singh

16 Janssen

غلظت کربن سیاه در مناطق مختلف جهان متفاوت است، به‌طوری‌که میانگین غلظت بالای این آلاینده در طول زمستان در ایستگاه شهری گوراخپور، ۱۹ میکروگرم بر متر مکعب و در ایستگاه ترافیکی پکن، ۱۷/۹ میکروگرم بر متر مکعب مشاهده شده است (وایشیا^۱ و همکاران، ۲۰۱۷؛ سونگ^۲ و همکاران، ۲۰۱۳). در مقابل، سطوح پایین غلظت کربن سیاه در منطقه روستایی هارول در بریتانیا و حومه انتاریا، کانادا به‌طور میانگین تقریباً ۰/۵ میکروگرم بر متر مکعب برآورد شده است (سینگ و همکاران، ۲۰۱۸؛ هیلی^۳ و همکاران، ۲۰۱۷). مطالعات متعددی تأثیر آلاینده کربن سیاه را بر تغییرات آب‌وهوایی و سلامت انسان در خاورمیانه و مناطق اطراف آن بررسی کرده است (آلاس^۴ و همکاران، ۲۰۱۸؛ چن^۵ و همکاران، ۲۰۲۲). محققان زیادی اذعان کرده‌اند که شرایط ترافیکی و عوامل هواشناسی مانند سرعت باد، دما، رطوبت نسبی و دید بر غلظت کربن سیاه در مناطق شهری مؤثر است و میزان این تأثیر در مقیاس‌های زمانی روزانه و فصلی تغییر می‌یابد (بهاث^۶ و همکاران، ۲۰۱۷؛ بی بی^۷ و همکاران، ۲۰۱۷؛ سینگ و همکاران، ۲۰۱۸؛ وانگ^۸ و همکاران، ۲۰۱۸؛ کوتزنر^۹ و همکاران، ۲۰۱۸؛ چن^{۱۰} و همکاران، ۲۰۱۹؛ موسوی^{۱۱} و همکاران، ۲۰۱۹؛ لیاکاکو^{۱۲} و همکاران، ۲۰۲۰). نتایج حاصل از اندازه‌گیری غلظت کربن سیاه در پایتخت ایران نیز حاکی از آن است که بیشترین میزان غلظت این ذرات تحت تأثیر منابع انتشار و عوامل جوی چون ارتفاع لایه مرزی در ساعات شب و کمترین غلظت آن در طول روز مشاهده می‌شود و ناوگان سنگین دیزلی دارای بیشترین سهم در انتشار آلاینده کربن سیاه در سطح شهر تهران است (طاهری^{۱۳} و همکاران، ۲۰۱۹). یافته‌های پژوهش جامع انجام‌گرفته در زمینه بررسی منابع انتشار آلاینده کربن سیاه در شهر تهران و همچنین دامنه تأثیر این ذرات بیانگر تفاوت چشمگیر غلظت BC در مقیاس‌های مکانی گوناگون (محلی، متوسط و بزرگ) و همچنین تأثیر مستقیم حضور وسایل نقلیه دیزلی از جمله کامیون‌های سنگین بر انتشار این آلاینده است (یگانه^{۱۴} و همکاران، ۲۰۲۱). پایش بلند مدت غلظت آلاینده کربن سیاه در گستره جغرافیایی کشور ایران با استفاده از داده‌های MERRA-2^{۱۵} نیز نشان‌دهنده روند افزایشی غلظت این ذرات طی دوره آماری ۴۰ ساله و تأثیرپذیری آن از پارامترهای هواشناسی فشار هوا و سرعت باد است (رئیس‌پور و خسروی، ۱۴۰۰).

مرور ادبیات پژوهش نشان می‌دهد که بیشتر مطالعات انجام‌شده در حوزه‌ی کربن سیاه بیشتر بر بررسی تغییرات زمانی و مکانی، منشأیابی و شناخت اثرات پارامترهای هواشناسی محدود بر تغییرات غلظت ذرات کربن سیاه متمرکز بوده و تاکنون مطالعه جامع داخلی که به تحلیل ارتباط میان پارامترهای مختلف هواشناسی، تغییرات غلظت آلاینده‌های جوی معیار و آلاینده کربن سیاه پرداخته باشد صورت نگرفته است. ازاین‌رو این پژوهش بر آن است تا ضمن

1 Vaishya

2 Song

3 Healy

4 Alas

5 Chen

6 Bhat

7 Bibi

8 Wang

9 Kutzner

10 Chen

11 Mousavi

12 Liakakou

13 Taheri

14 Yeganeh

15 Modern-Era Retrospective analysis for Research and Applications, version 2

واکوی روند سری زمانی بلند مدت (۲۰۲۱-۲۰۰۴) عناصر آب‌وهوایی (دما، بارش، سرعت باد، رطوبت نسبی، فشار هوا، ساعات آفتابی، تابش خورشیدی و ابرناکی) و آلاینده‌های هوا (کربن سیاه (BC)، کربن منوکسید (CO)^۱، نیتروژن دی اکسید (NO₂)^۲، گوگرد دی اکسید (SO₂)^۳، ازن (O₃)^۴، ذرات معلق با قطر کمتر از ۱۰ میکرون (PM₁₀)^۵ و ذرات معلق با قطر کمتر از ۲/۵ میکرون (PM_{2.5}) در تبریز و تهران، به بررسی ارتباط بین پارامترهای هواشناسی، آلاینده‌های جوی معیار و آلاینده کربن سیاه از منظر آماری در مقیاس‌های زمانی ماهانه و فصلی پردازد. هدف اصلی این پژوهش ارزیابی عملکرد الگوریتم‌های یادگیری ماشین ناپارامتری (مدل جمعی تعمیم‌یافته (GAM)^۶، درخت طبقه‌بندی و رگرسیون (CART)^۷، جنگل تصادفی (RF)^۸ و تقویت گرادیان (GBM)^۹) در مدلسازی آلاینده‌ها و عوامل هواشناسی مسئول تغییرات سطوح آلودگی ذرات کربن سیاه در تبریز و تهران و متعاقباً مقایسه کارایی روش‌های بالا با رگرسیون خطی چندگانه (MLR)^{۱۰} به‌عنوان مدل مبنا در نرم‌افزار R 4.3.2 (R Core Team، ۲۰۲۳) است که زمینه‌ای علمی برای پیشگیری و کنترل آلودگی هوا در کلان‌شهرها فراهم می‌کند.

داده‌ها و روش‌ها

منطقه مورد مطالعه:

این پژوهش از نظر قلمروی مکانی محدود به شهرهای تبریز و تهران است. تبریز با مساحتی حدود ۳۲۴ کیلومتر مربع و جمعیتی بالغ بر ۱/۵ میلیون نفر، چهارمین شهر بزرگ ایران، پر جمعیت‌ترین کلان‌شهر در شمال غرب ایران و مرکز استان آذربایجان شرقی است که با متوسط ارتفاع ۱۳۶۶ متر از سطح دریا در گستره جغرافیایی ۴۶° ۰۷' تا ۴۶° ۲۷' طول شرقی و ۳۸° ۰۱' تا ۳۸° ۱۰' عرض شمالی واقع شده است (سرور و همکاران، ۱۳۹۹). اقلیم تبریز نیمه‌خشک و زمستان‌های آن سرد و تابستان‌های آن مطبوع اما بسیار خشک است. توسعه صنعتی، تردد خودروهای فرسوده و افزایش منابع آلاینده، تبریز را با مشکلات جدی ناشی از آلودگی هوا به‌ویژه در فصول سرد سال مواجه ساخته و این شهر را به یکی از کانون‌های آلودگی هوا در کشور مبدل کرده است.

تهران با وسعت ۶۱۵ کیلومتر مربع و جمعیتی حدود ۹ میلیون نفر، بزرگ‌ترین و پر جمعیت‌ترین شهر، پایتخت ایران و مرکز استان تهران است که با ارتفاع متوسط ۱۲۰۰ متر از سطح دریا در محدوده جغرافیایی ۵۱° ۰۶' تا ۵۱° ۳۸' طول شرقی و ۳۴° ۳۵' تا ۳۵° ۵۱' عرض شمالی واقع شده است (راد^{۱۱} و همکاران، ۲۰۲۲). بر اساس طبقه‌بندی اقلیمی کوپن^{۱۲}، تهران دارای آب‌وهوای نیمه‌خشک با زمستان‌های سرد و نسبتاً بارانی و تابستان‌های گرم، آفتابی و خشک است (بک^{۱۳} و همکاران، ۲۰۱۸). اقلیم تهران بیشتر تحت تأثیر جغرافیای آن یعنی کوه‌های البرز در شمال و

1 Carbon Monoxide

2 Nitrogen Dioxide

3 Sulphur Dioxide

4 Ozone

5 Particulate matter with an aerodynamic diameter less than 10 microns

6 Generalized Additive Model

7 Classification and Regression Trees

8 Random Forest

9 Gradient Boosting Machine


10 Multiple Linear Regression

11 Rad

12 Köppen

13 Beck

کویر مرکزی کشور در جنوب شهر قرار دارد. در نتیجه تفاوت‌های عمیق ارتفاعی بین مناطق مختلف، شمال شهر سردتر از بخش‌های مرکزی و جنوبی آن است. نام شهر تهران به دلیل انتشار آلاینده‌های هوا از وسایل نقلیه، پالایشگاه‌ها، نیروگاه‌ها و کارخانه‌ها همواره در فهرست آلوده‌ترین شهرهای جهان به چشم می‌خورد و وارونگی دما در فصل سرد سال، موقعیت خاص جغرافیایی و همچنین شرایط جوی به تشدید آلودگی هوای تهران انجامیده است. موقعیت جغرافیایی مناطق مورد مطالعه و ایستگاه‌های همدیدی و پایش کیفیت هوا آنها در شکل ۱ نشان داده شده است.



شکل ۱: موقعیت منطقه مورد مطالعه و توزیع مکانی ایستگاه‌های همدیدی و پایش کیفیت هوا. منبع: نویسندگان

داده‌ها:

داده‌های سری زمانی مورد استفاده در این مطالعه شامل داده‌های ماهانه ایستگاه‌های هواشناسی، داده‌های روزانه ایستگاه‌های پایش کیفیت هوا و داده‌های ساعتی مدل مبنای MERRA-2 (M2T1NXAER)^۱ در بازه زمانی ۱ مارس ۲۰۰۴ تا ۳۰ ژوئن ۲۰۲۱ است. میانگین ماهانه داده‌های هواشناسی شامل دما (T , $^{\circ}\text{C}$), بارش (R , mm), سرعت باد (WS , m/s), رطوبت نسبی (RH , %), فشار هوا (AP , hPa), ساعات آفتابی (SH , h), تابش خورشیدی (SR , $\text{j/cm}^2/\text{day}$) و ابرناکی ($Okata$, C) در چهار ایستگاه همدیدی تهران و دو ایستگاه همدیدی تبریز از سازمان

¹ MERRA-2 M2T1NXAER: Aerosol Diagnostics V5.12.4

هواشناسی کشور دریافت گردید (<https://data.irimo.ir/>). به همین ترتیب، داده‌های مربوط به میانگین روزانه غلظت آلاینده‌های جوی معیار، یعنی کربن منوکسید (CO ، mg/m^3)، نیتروژن دی اکسید (NO_2 ، $\mu\text{g/m}^3$)، گوگرد دی اکسید (SO_2 ، $\mu\text{g/m}^3$)، ازن (O_3 ، $\mu\text{g/m}^3$) و ذرات معلق (PM_{10} و $\text{PM}_{2.5}$ ، $\mu\text{g/m}^3$) در ۲۱ ایستگاه پایش کیفیت هوای تهران و ۸ ایستگاه سنجش کیفیت هوای تبریز به ترتیب از شرکت کنترل کیفیت هوای تهران (<https://air.tehran.ir/>) و مرکز پایش و کنترل آلودگی هوای شهر تبریز اخذ گردید (<https://as.doe.ir/>). غلظت‌های ساعتی آلاینده‌ی کربن سیاه نیز از باند غلظت جرمی کربن سیاه (BCSMAS)^۱ داده‌های مدل MERRA-2 ارائه شده توسط مرکز مدلسازی و داده‌گواهی سازمان فضایی و هوانوردی ملی آمریکا (ناسا) در سامانه گوگل ارث انجین (GGE) با قدرت تفکیک مکانی ۶۹۳۷۵ متر برای دوره آماری مورد مطالعه استخراج گردید (<https://gmao.gsfc.nasa.gov/reanalysis/MERRA-2/>). اگرچه داده‌های مدل MERRA-2 از کیفیت، دقت و قابلیت اعتماد بالایی برخوردارند و مطالعات متعددی موفقیت این مدل در شبیه‌سازی غلظت ذرات کربن سیاه را تأیید کرده‌اند (کولارکو^۲ و همکاران، ۲۰۱۰؛ رینکر^۳ و همکاران، ۲۰۱۱؛ بیان^۴ و همکاران، ۲۰۱۳؛ بوچارد^۵ و همکاران، ۲۰۱۶)، با این حال این مطالعه با استفاده از میانگین ماهانه غلظت کربن سیاه در چهار ایستگاه سنجش کیفیت هوای تهران (ستاد بحران، شهرری، شریف و صدر) در دو سال اخیر (۱۴۰۱ - ۱۴۰۰) نسبت به اعتبارسنجی داده‌های کربن سیاه دریافتی از مدل MERRA-2 از طریق بسته hydroGOF اقدام کرده است که به نوبه‌ی خود ارزش ویژه‌ای به این مطالعه می‌بخشد (زامبرانو-بیگیارینی^۶، ۲۰۲۴).

به منظور جلوگیری از تأثیر مقادیر مفقود (گمشده)^۷ بر شکل توزیع داده‌ها، همبستگی میان متغیرها، عملکرد الگوریتم‌های مدلسازی و تجزیه و تحلیل‌ها، یک روش انتساب^۸ ناپارامتری مبتنی بر الگوریتم جنگل تصادفی (بسته missForest) برای مدیریت مقادیر مفقود موجود در مجموعه داده‌ها استفاده شد (استخون^۹، ۲۰۲۲). در این مطالعه، مقادیر پرت (دورافتاده)^{۱۰} بالا و پایین با استفاده از رویکرد انتساب capping به ترتیب با مقادیر نماینده صدک‌های ۹۵ و ۵ جایگزین گردید و کیفیت داده‌های آلودگی هوا مورد بررسی قرار گرفت (ریو^{۱۱}، ۲۰۲۲). جهت سازگاری زمانی با داده‌های هواشناسی، مقادیر ماهانه غلظت آلاینده‌های جوی معیار و ذرات کربن سیاه استخراج گردید.

تجزیه و تحلیل آماری:

نرم‌افزار R نسخه ۴.۳.۲ برای انجام تجزیه و تحلیل آماری داده‌ها مورد استفاده قرار گرفت. بررسی نرمال بودن توزیع متغیرها و محاسبه آمار توصیفی داده‌ها توسط توابع ارائه‌شده در بسته MVN^{۱۲} انجام شد (کورکماز^{۱۳} و همکاران،

1 Black Carbon Surface Mass Concentration

2 Colarco

3 Rienecker

4 Bian

5 Buchard

6 Zambrano-Bigiarini

7 Missing value

8 imputation

9 Stekhoven

10 outliers

11 Ryu

12 Multivariate Normality

13 Korkmaz

۲۰۱۴). روش STL^۱ برای تجزیه سری زمانی داده‌ها به مؤلفه‌های روند (T_t)، فصلی (S_t) و باقیمانده (R_t) جهت استخراج روندها و الگوهای فصلی در سری زمانی عناصر آب‌وهوایی و آلاینده‌های هوا و همچنین اندازه‌گیری قدرت روند (F_T) و فصلی (F_S) به‌ترتیب زیر استفاده شد (وانگ^۲ و همکاران، ۲۰۰۶):

$$F_t = \max \left(0.1 - \frac{\text{Var}(R_t)}{\text{Var}(T_t + R_t)} \right) \quad (۱)$$

$$F_s = \max \left(0.1 - \frac{\text{Var}(R_t)}{\text{Var}(S_t + R_t)} \right) \quad (۲)$$

مقدار F_T و F_S می‌تواند بین صفر تا یک متغیر باشد، به‌طوری‌که داده‌های سری زمانی با F_T و F_S نزدیک به ۰ تقریباً هیچ اثر فصلی و هیچ روندی را نشان نمی‌دهند، درحالی‌که "۱" به این معنی است که روند بسیار قوی در سری داده‌ها وجود دارد و فصلی بودن رخ داده است. آزمون ناپارامتری من-کندال^۳ برای بررسی معناداری آماری روند (کاهش/افزایش) عناصر هواشناسی و آلاینده‌های هوا در طول زمان و آزمون شیب سن^۴ جهت برآورد شیب واقعی روند در سری زمانی داده‌ها با استفاده از بسته trend به‌کار گرفته شد (من^۵، ۱۹۴۵؛ پولرت^۶، ۲۰۲۳). ارتباط میان پارامترهای هواشناسی، غلظت آلاینده‌های جوی معیار و غلظت ذرات کربن سیاه در مقیاس‌های زمانی ماهانه و فصلی با انتخاب روش تحلیل همبستگی مناسب بر اساس توزیع داده‌ها (نرمال و غیر نرمال) مورد تجزیه و تحلیل قرار گرفت و بصری سازی نتایج حاصل از ماتریس همبستگی شامل ضرایب همبستگی و معناداری آماری ضرایب در سطح اطمینان ۹۹/۹٪ با به‌کارگیری بسته corplot فراهم گردید (وی^۷ و سیمکو^۸، ۲۰۲۱). با توجه به ویژگی‌های آب‌وهوایی در شهرهای تبریز و تهران، چهار فصل بهار (مارس، آوریل، مه)، تابستان (ژوئن، ژوئیه، اوت)، پاییز (سپتامبر، اکتبر و نوامبر) و زمستان (دسامبر، ژانویه، فوریه) انتخاب شد و تفسیر ضرایب همبستگی بر اساس معیارهای ارائه‌شده توسط موکاکا^۹ (۲۰۱۲) یعنی $< ۰/۳$: همبستگی بسیار ضعیف، $۰/۳ - ۰/۴۹$: همبستگی ضعیف، $۰/۴۹ - ۰/۵$: همبستگی متوسط، $۰/۵ - ۰/۷$: همبستگی قوی و $۰/۷ - ۱$: همبستگی بسیار قوی صورت گرفت.

رویکردهای مدل‌سازی:

به منظور تعیین اثرات احتمالی عناصر هواشناسی و آلاینده‌های جوی معیار بر سطح غلظت ذرات کربن سیاه در تبریز و تهران، الگوریتم‌های یادگیری ماشین شامل رگرسیون خطی چندگانه (MLR)، مدل جمعی تعمیم‌یافته (GAM)، درخت طبقه‌بندی و رگرسیون (CART)، جنگل تصادفی (RF) و تقویت گرادیان (GBM) در بسته tidymodels پیاده‌سازی شد (کوهن^{۱۰} و ویکهام^{۱۱}، ۲۰۲۰). مدل‌ها با در نظر گرفتن غلظت ذرات کربن سیاه به‌عنوان متغیر وابسته و عناصر هواشناسی و آلاینده‌های جوی معیار به‌عنوان متغیرهای مستقل، برای پاسخ کربن سیاه به مجموعه‌ای از

1 Seasonal-Trend decomposition using Loess

2 Wang

3 Mann-Kendall

4 Sen's slope

5 Mann

6 Pohlert

7 Wei

8 Simko

9 Mukaka


10 Kuhn

11 Wickham

متغیرهای مهم توضیحی برآزش یافتند. هم‌خطی متغیرهای مستقل از طریق خوشه‌بندی سلسله‌مراتبی ضرایب همبستگی اسپیرمن در بسته Hmisc مورد بررسی قرار گرفت (سارل^۱، ۱۹۹۰؛ هارل^۲، ۲۰۲۳). از آنجایی که متغیر وابسته دارای ماهیت کمی (عددی) است، بر روی رویکردهای رگرسیون در الگوریتم‌های یادگیری ماشین تمرکز گردید. روش اعتبارسنجی متقابل^۳ شامل تقسیم داده‌ها به مجموعه‌های آموزشی (۷۰٪) و اعتبارسنجی یا آزمایش (۳۰٪) جهت اطمینان از قابلیت تعمیم مدل‌های پیش‌بینی و استقلال از داده‌های آموزشی، کاربرد موفقیت‌آمیز آنها در یک مجموعه داده جداگانه و تنظیم فرآپارامترهای^۴ مورد نیاز برای هر یک از مدل‌ها استفاده شد. مدل‌ها بر روی مجموعه آموزشی برآزش شدند و در مجموعه آزمایش مورد اعتبارسنجی قرار گرفتند و ارزیابی عملکرد مدل‌های پیشگو بر اساس ضریب تعیین R^2 ^۵ و ریشه میانگین مربعات خطای (RMSE) اعتبارسنجی (آزمایش) صورت گرفت. اهمیت نسبی متغیرهای مستقل در تبیین تغییرپذیری متغیر پاسخ با استفاده از روش جایگشت در بسته vip بر اساس مقدار R^2 به‌عنوان معیار عملکرد مدل محاسبه شد (گرین ول^۶ و همکاران، ۲۰۲۰). در نهایت، انتخاب مدل نهایی به‌صورت تعادلی بین دقت پیشگویی و کوتاه و مختصر بودن مدل (اصل صرفه‌جویی^۷) انجام شد (فالك^۸ و موتوکریشنا^۹، ۲۰۲۳). در فرآیند مقایسه مدل‌ها باید دقت و سادگی درنظر گرفته شود و میان دو مدل با دقت پیشگویی نسبتاً برابر، بهتر است مدل ساده‌تر انتخاب شود، حتی اگر با افزایش تعداد پارامترها، خطای پیش‌بینی کاهش یابد. برای کسب اطلاعات بیشتر در خصوص الگوریتم‌های یادگیری ماشین استفاده‌شده در این مطالعه به کتاب Hands-on machine learning with R نوشته بوهمکه^{۱۰} و گرینول^{۱۱} (۲۰۱۹) مراجعه شود. چکیده تصویری پژوهش در شکل ۲ نمایش داده شده است.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

-
- 1 Sarle
 - 2 Harrell
 - 3 K-fold cross-validation
 - 4 hyperparameters
 - 5 R-Squared
 - 6 Greenwell
 - 7 parsimony principle
 - 8 Falk
 - 9 Muthukrishna
 - 10 Boehmke
 - 11 Greenwell



شکل ۲: چکیده تصویری پژوهش. منبع: نویسندگان

نتایج و بحث

آمار توصیفی:

اطلاعات مربوط به پارامترهای هواشناسی و همچنین آلاینده‌های هوا (آلاینده‌های معیار و کربن سیاه) در تبریز و تهران شامل مقادیر میانگین، حداقل، حداکثر و وضعیت توزیع داده‌ها از ۲۰۰۴-۰۳-۰۱ تا ۲۰۲۱-۰۶-۳۰، در جدول ۱ ارائه شده است. مقایسه وضعیت جوی دو شهر نشان می‌دهد که میانگین مقادیر بارش، سرعت باد، رطوبت نسبی، ساعات آفتابی و ابرناکی در تبریز بیشتر از تهران است و درعین حال، دما، فشار هوا و تابش خورشیدی در تهران در مقایسه با تبریز بیشتر است. میانگین سطح غلظت آلاینده‌های BC ، NO_2 ، SO_2 ، PM_{10} و $PM_{2.5}$ در تهران به میزان قابل توجهی بیشتر از شهر تبریز است و تنها مقادیر میانگین غلظت‌های CO و O_3 در تبریز اندکی بالاتر از تهران است. ستون آخر جدول ۱ وضعیت توزیع متغیرها را بر اساس آزمون تک متغیره کولموگروف - اسمیرنوف (KS)^۱ نشان می‌دهد. همان‌طور که ملاحظه می‌شود در تبریز تنها متغیرهای سرعت باد، O_3 و PM_{10} در مجموعه داده‌ها، دارای توزیع نرمال تک متغیره در سطح معنی‌داری ۰/۰۵ هستند. این در حالی است که در تهران، تمامی متغیرها جز دما، بارش، رطوبت نسبی، ساعات آفتابی، NO_2 و SO_2 دارای توزیع نرمال هستند.

¹ Kolmogorov-Smirnov

جدول ۱: مروری بر وضعیت پارامترهای هواشناسی و آلاینده‌های هوا بر اساس میانگین ماهانه در تبریز و تهران (۲۰۲۱-۲۰۰۴)

نرمالیت (p-value)		شاخص آماری						متغیر
		پیشینه		کمینه		میانگین		
تهران	تبریز	تهران	تبریز	تهران	تبریز	تهران	تبریز	
< ۰/۰۰۱	۰/۰۰۴	۳۲/۶۸	۲۹/۴۲	۳/۲۰	-۵/۷۵	۱۷/۴۶	۱۳/۳۰	T (°C)
< ۰/۰۰۱	< ۰/۰۰۱	۸۲/۰۲	۱۸۹/۷۶	۰	۰	۲۲/۶۳	۲۴/۵۹	R (mm)
۰/۲۵	۰/۱۴	۳/۰۵	۶/۷۴	۱/۰۷	۲/۱۲	۲	۳/۸۵	WS (m/s)
< ۰/۰۰۱	۰/۰۰۱	۷۲/۰۵	۷۹/۸۵	۱۴/۳۷	۲۲/۷۸	۳۷/۳۶	۵۱/۴۲	RH (%)
۰/۴۰	۰/۰۰۴	۸۶۹/۴۵	۸۷۰/۷۳	۸۵۶/۸۱	۸۵۰/۸۱	۸۶۳/۷۲	۸۵۹/۱۶	AP (hPa)
۰/۰۰۴	۰/۰۳	۳۶۸/۳۷	۳۷۸/۹۰	۹۹/۳۰	۸۳	۲۳۷/۵۳	۲۳۸/۵۶	SH (h)
۰/۴۶	۰/۰۱	۱۰۷۰۶۴/۶۷	۱۴۶۶۷۴	۱۶۲۴۷	۱۱۸۸۸/۵۰	۵۷۲۹۴/۹۳	۵۷۱۹۵/۸۶	SR(j/cm ² /day)
۰/۱۴	۶e-۰۴	۵/۳۱	۵/۷۶	۰/۱۷	۰/۶۱	۲/۴۲	۳/۰۸	C (Okta)
۰/۱۳	۰/۰۰۲	۰/۹۸	۰/۷۵	۰/۵۰	۰/۳۴	۰/۶۸	۰/۵۳	BC (µg/m ³)
۰/۱	۰/۰۲	۵/۴۶	۵/۹۸	۱/۱۸	۱/۱۳	۲/۷۰	۲/۸۰	CO (mg/m ³)
۰/۰۲	۰/۰۳	۱۳۶/۷۰	۶۶/۸۹	۵۳/۶۰	۲/۸۸	۸۹/۴۳	۳۷/۴۳	NO ₂ (µg/m ³)
< ۰/۰۰۱	< ۰/۰۰۱	۸۳/۶۱	۵۰/۶۰	۸/۲۸	۳/۶۳	۳۴/۱۵	۱۷/۵۰	SO ₂ (µg/m ³)
۰/۰۷	۰/۱۷	۷۱/۹۴	۷۲/۵۱	۱۳/۲۳	۱۳	۳۸/۹۶	۳۹/۳۶	O ₃ (µg/m ³)
۰/۷	۰/۱۱	۱۲۵/۵۵	۷۴/۳۵	۴۴/۲۸	۲۳/۲۰	۸۱/۱۷	۴۷/۴۳	PM ₁₀ (µg/m ³)
۰/۱۱	۵e-۰۴	۵۲/۵۳	۳۸/۰۹	۱۶/۴۴	۱۰/۴۸	۳۱/۸۰	۱۹/۸۱	PM _{2.5} (µg/m ³)

برناکی را نشان می‌دهند. C به ترتیب مقادیر میانگین ماهانه دما، بارش، سرعت باد، رطوبت نسبی، فشار هوا، ساعات آفتابی، تابش خورشیدی و SR, SH, AP, RH, WS, R, T.

تحلیل سری‌های زمانی:

نتایج محاسبات مربوط به قدرت فصلی (F_s) و روند متغیرها (F_T) و همچنین یافته‌های نهایی آزمون‌های ناپارامتری من-کندال و شیب سن، شامل مقادیر Z ، شیب روند و p -value که به ترتیب بیانگر جهت روند پارامترهای هواشناسی و آلاینده‌ها (افزایش یا کاهش)، سرعت افزایش یا کاهش آنها و معناداری آماری روندهاست، در جدول ۲ ارائه شده است. بر اساس نتایج روش تجزیه STL، اثرات فصلی و روند در سری زمانی تمامی متغیرها (عناصر آب‌وهوایی و آلاینده‌ها) وجود دارد. قدرت فصلی تمام پارامترهای هواشناسی در تبریز، به جز فشار هوا و تابش خورشیدی، بیشتر از قدرت روند بود. در تهران نیز قدرت فصلی پارامترهای هواشناسی، به جز تابش خورشیدی، بیشتر از قدرت روند بود. قدرت فصلی بین عناصر آب‌وهوایی متفاوت و بالاترین میانگین قدرت فصلی در هر دو شهر، متعلق به دمای هوا ($F_{ST} = 1$) بود. به جز O_3 ، $PM_{2.5}$ و BC، قدرت روند سایر آلاینده‌ها در تبریز و تهران بیشتر از قدرت فصلی آنها محاسبه گردید. بر اساس STL، بیشترین قدرت روند آلاینده در تبریز برای PM_{10} و در تهران برای CO و SO_2 با میانگین روند $F_{TPM10} = 0/7$ ، $F_{TCO} = 0/8$ و $F_{TSO2} = 0/8$ بود.

فرضیه صفر ($p\text{-value} > 0/05$) مبنی بر عدم وجود روند در سری زمانی پارامترهای هواشناسی به جز پارامترهای سرعت باد (افزایش)، فشار هوا (کاهش) و تابش خورشیدی (افزایش) در تبریز پذیرفته می‌شود. در تهران نیز تنها پارامتر ابرناکی روند کاهشی معناداری را در طول دوره آماری تجربه کرده است. در تبریز CO ، SO_2 ، PM_{10} و $PM_{2.5}$ و

در تهران آلاینده‌های CO ، SO_2 و $PM_{2.5}$ روند کاهشی معناداری را در سطح اطمینان ۹۵٪ نشان داده‌اند. سرعت کاهش CO در تبریز تندتر از سرعت کاهش $PM_{2.5}$ ، PM_{10} و SO_2 است و در تهران نیز آلاینده CO با سرعت بیشتری نسبت به $PM_{2.5}$ و SO_2 کاهش یافته است. این درحالی است که ذرات کربن سیاه در هر دو شهر تبریز و تهران روند صعودی معناداری را با سرعت نسبتاً برابر تجربه کرده‌اند.

جدول ۲: تحلیل فصلی و روند پارامترهای هواشناسی و آلاینده‌های هوا بر اساس میانگین ماهانه در تبریز و تهران (۲۰۲۱-۲۰۰۴)


متغیر	قدرت روند (F_T)		قدرت فصلی (F_S)		آماره Z		شیب روند		p-value
	تهران	تبریز	تهران	تبریز	تهران	تبریز	تهران	تبریز	تهران
T (°C)	۰/۳	۰/۲	۱	۱	-۰/۳۳	-۰/۲۷	-۰/۰۰۳	-۰/۰۰۳	۰/۷۴
R (mm)	۰/۱	۰/۲	۰/۳	۰/۵	-۰/۷۹	۱/۴۰	-۰/۰۰۳	۰/۰۲	۰/۴۳
WS (m/s)	۰/۴	۰/۴	۰/۹	۰/۸	-۰/۲۴	۲/۴۸	-۰/۰۰۰۱	۰/۰۰۳	۰/۸۱
RH (%)	۰/۲	۰/۲	۰/۹	۰/۸	-۱/۱۹	۰/۵۳	-۰/۰۲	۰/۰۱	۰/۲۴
AP (hPa)	۰/۹	۰/۲	۰/۸	۰/۸	۱/۶۸	-۸/۳۶	۰/۰۱	-۰/۰۵	۰/۰۹
SH (h)	۰/۱	۰/۳	۰/۹	۰/۹	-۰/۳۷	۰/۰۶	۰/۰۱	-۰/۰۴	۰/۹۵
SR(j/cm ² /day)	۰/۷	۰/۸	۰/۸	۰/۵	-۰/۸۳	۲	-۳۱/۵۰	۵۹/۰۲	۰/۴۱
C (Okta)	۰/۲	۰/۲	۰/۷	۰/۷	-۲/۳۷	۰/۰۱	-۰/۰۰۴	۲/۹۳e-۰۵	۰/۰۲
BC (µg/m ³)	۰/۳	۰/۲	۰/۹	۰/۷	۲/۷۱	۱/۹۰	۰/۰۰۰۳	۰/۰۰۰۳	۰/۰۱
CO (mg/m ³)	۰/۶	۰/۸	۰/۲	۰/۴	-۱۲/۹۹	-۶/۳۰	-۰/۰۲	-۰/۰۱	۰/۱۶e-۲۲
NO ₂ (µg/m ³)	۰/۶	۰/۷	۰/۴	۰/۵	-۰/۶۳	۱/۴۹	-۰/۰۱	۰/۰۲	۰/۵۳
SO ₂ (µg/m ³)	۰/۶	۰/۸	۰/۴	۰/۲	-۱۰/۴۹	-۵/۸۳	-۰/۰۷	-۰/۰۴	۰/۱۶e-۲۲
O ₃ (µg/m ³)	۰/۳	۰/۵	۰/۹	۰/۸	-۱/۹۰	-۰/۵۵	-۰/۰۴	-۰/۰۱	۰/۰۶
PM ₁₀ (µg/m ³)	۰/۷	۰/۵	۰/۱	۰/۴	۱/۷۷	-۹/۵۷	۰/۰۴	-۰/۰۲	۰/۰۸
PM _{2.5} (µg/m ³)	۰/۴	۰/۴	۰/۷	۰/۷	-۵/۵۰	-۱/۹۱	-۰/۰۱	-۰/۰۴	۰/۰۵

T, R, WS, RH, AP, SH و C به ترتیب مقادیر میانگین ماهانه دما، بارش، سرعت باد، رطوبت نسبی، فشار هوا، ساعات آفتابی، تابش خورشیدی و ابری را نشان می‌دهند.

اعتبارسنجی داده‌های کربن سیاه:

برای ارزیابی داده‌های کربن سیاه مدل MERRA-2، میانگین ماهانه غلظت این آلاینده در چهار ایستگاه ستاد بحران، شهر ری، شریف و صدر برای دوره آماری دو ساله (۱۴۰۰-۰۱-۰۱ تا ۱۴۰۲-۰۱-۰۱) از شرکت کنترل کیفیت هوا دریافت گردید. سری زمانی غلظت‌های ساعتی کربن سیاه از مدل MERRA-2 در مختصات ایستگاه‌های یادشده نیز برای این دوره دو ساله دریافت و مقادیر ماهانه استخراج گردید. در نهایت، مقایسه مقادیر ایستگاهی غلظت‌ها و مقادیر شبیه‌سازی‌شده توسط مدل از طریق محاسبه شاخص‌های میانگین خطای مطلق (MAE)، ریشه میانگین مربعات خطا (RMSE)، ضریب همبستگی اسپیرمن (r) و ضریب تبیین (R^2) با استفاده از تابع ggof در بسته hydroGOF انجام گرفت که نتایج آن در شکل ۳ ارائه شده است. همان‌طور که ملاحظه می‌گردد غلظت‌های شبیه‌سازی‌شده برای ذرات کربن سیاه در شهر تهران همبستگی معنادار بالایی ($r = ۰/۷۲$) با میانگین ماهانه غلظت این

آلاینده در ایستگاه‌های اندازه‌گیری غلظت BC در سطح اطمینان ۹۵٪ دارد ($p\text{-value} < 0.001$). اگرچه داده‌های مدل MERRA-2 روندهای فصلی را با دقت نسبتاً خوبی نشان می‌دهد، با این حال این مدل می‌تواند نیمی از تغییرات کربن سیاه را تبیین کند ($R^2 = 0.53$) و خطای تقریباً ۵۰ درصدی آن نیز می‌تواند ناشی از خطای سوگیری در مدل به دلیل لحاظ نکردن ویژگی‌های منطقه‌ای و همچنین قدرت تفکیک مکانی کم مدل باشد (۶۹۳۷۵ متر). بنابراین می‌توان گفت مدل MERRA-2 غلظت‌های کربن سیاه در شهر تهران را به صورت کیفی و نه کمی بازتولید می‌کند.



شکل ۳: مقایسه مقادیر شبیه‌سازی‌شده غلظت ذرات کربن سیاه توسط مدل MERRA-2 و مقادیر ایستگاهی در تهران. منبع: نویسندگان
* معناداری آماری همبستگی در سطح اطمینان ۹۵٪ را نشان می‌دهد.

تحلیل روابط بین آلاینده کربن سیاه، آلاینده‌های جوی معیار و پارامترهای هواشناسی:

همان‌طور که در بخش آمار توصیفی داده‌ها مشاهده گردید (جدول ۱)، برخی از آلاینده‌های هوا و پارامترهای هواشناسی از توزیع نرمال تبعیت نمی‌کنند و به همین دلیل از آزمون ناپارامتری اسپیرمن برای بررسی ارتباط ذرات کربن سیاه با آلاینده‌های معیار هوا و متغیرهای هواشناسی در تبریز و تهران استفاده گردید (اسپیرمن، ۱۹۶۱). گفتنی است که تحلیل روابط بر اساس معناداری آماری صورت گرفته است و متغیرهایی که ارتباط معناداری در سطح اطمینان ۹۹/۹٪ نداشتند، مورد بحث قرار نگرفته‌اند (شکل ۴). تحلیل ضرایب همبستگی اسپیرمن در مقیاس زمانی ماهانه در تبریز حاکی از همبستگی مثبت آلاینده کربن سیاه با آلاینده‌های CO ، NO_2 ، SO_2 و $PM_{2.5}$ و همبستگی منفی این ذرات با آلاینده O_3 است. همبستگی مثبت BC با CO ، NO_2 ، SO_2 و $PM_{2.5}$ بازتابنده‌ی منابع انتشار مشترک و نقش بسیار مهم منابع احتراق در انتشار ذرات کربن سیاه و همبستگی منفی قوی BC با O_3 ($r = -0.88$) بیانگر تأثیر ذرات کربن سیاه در جذب تابش خورشیدی و کاهش میزان تجزیه شیمیایی بر اثر نیروی

تابشی و در پی آن کاهش غلظت ازن در سطح زمین است. روابط مشابهی میان BC و آلاینده‌های جوی معیار در چین مشاهده شده است (لیو^۱ و همکاران، ۲۰۲۲). بر اساس شکل ۴-الف، کربن سیاه به‌ترتیب دارای بیشترین همبستگی مثبت با PM_{2.5} و NO₂ با ضرایب همبستگی ۰/۷۶ و ۰/۴۸ است. همبستگی بالای ذرات BC با آلاینده‌های CO و NO_x در استانبول و همبستگی بالای BC با PM_{2.5} در پکن در مطالعات دیگر گزارش شده است (ژائو^۲ و همکاران، ۲۰۱۳؛ یو^۳ و همکاران، ۲۰۱۵؛ شاهین^۴ و همکاران، ۲۰۲۰). در مقیاس فصلی، BC در تبریز دارای همبستگی مثبت متوسط با ذرات PM_{2.5} در تابستان و همبستگی منفی ضعیف با O₃ در زمستان است. همبستگی ضعیف BC با SO₂ توسط محققان دیگر نیز تأیید شده است (شاهین و همکاران، ۲۰۲۰؛ لیو و همکاران، ۲۰۲۲). به‌طور مشابه، BC در تهران دارای همبستگی مثبت بسیار ضعیف با آلاینده‌های SO₂ و PM_{2.5} و درعین‌حال همبستگی منفی متوسط با O₃ است. BC در تهران دارای یک رابطه منفی بسیار ضعیف با آلاینده CO در فصول بهار و زمستان است و رابطه‌ی آن با آلاینده ازن در فصل زمستان به رابطه‌ی مثبت بسیار ضعیفی تبدیل می‌شود.

کربن سیاه با میانگین ماهانه عناصر هواشناسی دما، سرعت باد، ساعات آفتابی و تابش خورشیدی در تبریز همبستگی منفی و با پارامترهای رطوبت نسبی، فشار هوا و ابرناکی همبستگی مثبت نشان داد. همبستگی منفی قوی بین BC، دما، ساعات آفتابی و تابش خورشیدی به معنای کاهش غلظت ذرات کربن سیاه با افزایش این پارامترها و بالعکس است. رابطه معکوس بین دما و کربن سیاه می‌تواند به‌دلیل شرایط مطلوب برای تراکم گازهای خروجی از آگزوز، گونه‌های نیمه فرار در طول زمستان و ترکیبات آلی ثانویه تولیدشده توسط واکنش‌های فتوشیمیایی در تابستان باشد (بارمان^۵ و گوخاله^۶، ۲۰۱۹). کاهش غلظت آلاینده کربن سیاه با افزایش دما در مطالعات دیگر نیز گزارش شده است (چنگ^۷ و یانگ^۸، ۲۰۱۶؛ بوتسا^۹ و همکاران، ۲۰۲۱؛ سانکار^{۱۰} و همکاران، ۲۰۲۳). رابطه BC با دما در تبریز در فصل تابستان به رابطه‌ی مستقیم متوسطی تبدیل شده است ($r = 0/53$). همبستگی مثبت کربن سیاه با دما در یک ایستگاه ترافیکی در استانبول نیز مشاهده شده است (شاهین و همکاران، ۲۰۲۰). BC بیشترین همبستگی منفی را با پارامتر سرعت باد در تبریز دارد ($r = -0/89$). باد یکی از مهم‌ترین عوامل هواشناسی است که بر حرکت و انتقال توده‌های هوا و همچنین پراکندگی آلاینده‌ها در جو تأثیر می‌گذارد. افزایش سرعت باد به تسهیل پراکندگی ذرات کربن سیاه و در نتیجه کاهش غلظت آنها در سطح زمین می‌انجامد. رابطه BC و WS در زمستان به رابطه‌ای مثبت و بسیار ضعیف تغییر یافته است. همبستگی منفی قوی ذرات کربن سیاه با سرعت باد در مطالعات دیگر نیز تأیید شده است (شاهین و همکاران، ۲۰۲۰؛ لیو و همکاران، ۲۰۲۲). همان‌طور که در شکل ۴-الف مشاهده می‌شود، BC دارای یک رابطه همبستگی مثبت قوی با رطوبت نسبی در تبریز است ($r = 0/83$). اگرچه ذرات BC آب‌گریز هستند، اما می‌توانند با ذرات آب دوست (سولفات، نیتрат، کربن آلی و ...) ترکیب و به هسته‌های میعان ابر (CCN)^{۱۱} تبدیل

1 Liu

2 Zhao

3 Yu

4 Şahin

5 Barman

6 Gokhale

7 Cheng

8 Yang

9 Botsa

10 Sankar

11 Cloud Condensation Nuclei

شوند و یا به‌طور مستقیم به‌عنوان هسته‌های یخ عمل کنند و با تغییر ویژگی‌های میکروفیزیکی و تشعشعی و طول عمر ابر به‌طور غیر مستقیم بر اقلیم منطقه تأثیر بگذارند. بنابراین کربن سیاه می‌تواند با جذب تابش خورشیدی و کاهش مقدار تابش رسیده به سطح زمین، فرآیند تشکیل ابر و بارش را تحت تأثیر قرار دهد که به موجب آن ممکن است با مهار همرفت و افزایش طول عمر ابر و در نتیجه افزایش پایداری، بر گردش جوی و بخار آب موجود در جو تأثیر بگذارد. در واقع، ذرات کربن سیاه منجر به گرم شدن هوا و در نتیجه افزایش احتمال حضور بخار آب در جو و به عبارت دیگر افزایش رطوبت نسبی می‌شود. همبستگی مثبت و معنادار میانگین ماهانه غلظت کربن سیاه با رطوبت نسبی در طول دوره مورد مطالعه در تبریز نشان می‌دهد که BC ممکن است به‌عنوان یکی از CCNهای اصلی مؤثر بر آب قابل بارش و شدت بارش در این منطقه باشد. غلظت بالای کربن سیاه در روزهایی که میزان رطوبت هوا در یک ایستگاه شهری در ووهان بیشتر است و همچنین همبستگی مثبت کربن سیاه با رطوبت نسبی در دوره‌های سرد و گرم سال در چین توسط محققان دیگر گزارش شده است (لیو و همکاران، ۲۰۱۹؛ لیو و همکاران، ۲۰۲۲). رابطه غلظت کربن سیاه با RH در تبریز در فصل تابستان به رابطه‌ی معکوس متوسطی تبدیل می‌شود. همبستگی کربن سیاه و فشار هوا در تبریز در مقیاس زمانی ماهانه مثبت و ضعیف دیده شد که به معنای افزایش غلظت ذرات BC با افزایش فشار هوا در منطقه است. همبستگی میان BC و پارامتر ابرناکی در تبریز مثبت و متوسط مشاهده شد ($r = 0.63$). ذرات کربن سیاه با جذب تابش خورشیدی ورودی به زمین و ایجاد اختلال در ساختار دمایی جو، بر پوشش ابر تأثیر می‌گذارد. این اثر که اثر نیمه‌مستقیم ذرات BC نامیده می‌شود، با کاهش یا افزایش پوشش ابر در شرایط مختلف بسته به ارتفاع ذرات نسبت به ابر و نوع ابر همراه است (کخ^۱ و دل جینیو^۲، ۲۰۱۰). اگر ذرات در لایه ابر جاسازی شوند، پوشش ابر کاهش می‌یابد و حضور ذرات زیر ابر ممکن است به افزایش همرفت و پوشش ابر منجر شود.


در تهران نیز آلاینده کربن سیاه دارای همبستگی منفی قوی با پارامترهای دما ($r = -0.81$) و ساعات آفتابی ($r = -0.73$)، همبستگی منفی متوسط با تابش خورشیدی ($r = -0.60$)، همبستگی منفی ضعیف با سرعت باد ($r = -0.47$)، همبستگی مثبت قوی با رطوبت نسبی ($r = 0.76$) و فشار هوا ($r = 0.71$) و همچنین همبستگی مثبت متوسط با بارش ($r = 0.56$) و ابرناکی ($r = 0.52$) در مقیاس زمانی ماهانه است. ذرات کربن سیاه در تهران دارای رابطه همبستگی منفی و متوسط ($r = -0.54$) با پارامتر بارش در فصل زمستان است. ذرات BC می‌توانند با جذب تابش خورشیدی و تغییر نرخ گرمایش جو بر بارش تأثیر بگذارند. در واقع، جو با تغییر ابرها، رطوبت نسبی و بارش به سرعت با گرمای افزوده توسط کربن سیاه سازگار می‌شود. در بازه‌های زمانی بلند مدت، کربن سیاه ممکن است با گرم کردن سطح، بارش را افزایش دهد (سند^۳ و همکاران، ۲۰۲۰). همبستگی مثبت کربن سیاه با بارش در عراق مشاهده شده است (وهاب^۴ و همکاران، ۲۰۲۳). نقش مؤثر پارامتر بارش در کاهش ذرات کربن سیاه از جو از طریق نهشت تر^۵ نیز در مطالعات بسیاری گزارش شده است (بابو^۶ و مورثی^۷، ۲۰۰۲؛ شاهین و همکاران، ۲۰۲۰). رابطه BC

1 Koch
2 Del Genio
3 Sand
4 Wahab
5 Wet deposition
6 Babu
7 Moorthy

با ساعات آفتابی در تهران به رابطه‌ای مثبت و بسیار ضعیف در زمستان تغییر یافته است. رابطه غلظت BC با RH در تهران در فصل تابستان همانند تبریز به رابطه‌ای معکوس و متوسط و در فصل زمستان به رابطه‌ای منفی بسیار ضعیفی تبدیل می‌شود.

نتایج حاصل از مقایسه ضرایب همبستگی بین غلظت آلاینده کربن سیاه و پارامترهای هواشناسی در تبریز و تهران حاکی از یکسان بودن جهت ارتباط (مستقیم و معکوس) کربن سیاه با دما، سرعت باد، رطوبت نسبی، فشار هوا، ساعات آفتابی، تابش خورشیدی و ابرناکی در هر دو شهر و تفاوت در شدت روابط است. شدت روابط معکوس بین BC و دما، BC و سرعت باد، BC و ساعات آفتابی و BC و تابش خورشیدی و همچنین شدت روابط مستقیم بین BC و رطوبت نسبی و BC و ابرناکی در تبریز بیشتر از تهران است. این در حالی است که همبستگی غلظت ذرات کربن سیاه با پارامتر فشار هوا در تهران شدیدتر از تبریز است. به‌طور کلی می‌توان گفت آلاینده کربن سیاه دارای بیشترین همبستگی منفی با سرعت باد و بیشترین همبستگی مثبت با رطوبت نسبی در تبریز و بیشترین همبستگی منفی با دما و بالاترین همبستگی مثبت با فشار هوا در تهران است.


تحلیل ضرایب همبستگی بین آلاینده‌های هوا (CO ، NO_2 ، SO_2 ، O_3 ، PM_{10} ، $PM_{2.5}$ و BC) و عناصر هواشناسی نشان می‌دهد که از میان آلاینده‌های جوی، آلاینده کربن سیاه در مقایسه با سایر آلاینده‌ها بیشتر تحت تأثیر شرایط آب-وهوایی در شهرهای تبریز و تهران قرار دارد و به‌طور کلی تغییر در غلظت این ذرات ارتباط معنادارتری با پارامترهای جوی به‌ویژه دما، سرعت باد، رطوبت نسبی و فشار هوا دارد.



شکل ۴: ضرایب همبستگی اسپیرمن بین آلاینده کربن سیاه، آلاینده‌های معیار هوا و عناصر هواشناسی در (الف) تبریز و (ب) تهران. T، R، WS، RH، AP، SH، SR و C به ترتیب میانگین ماهانه دما، بارش، سرعت باد، رطوبت نسبی، فشار هوا، ساعات آفتابی، تابش خورشیدی و ابرناکی و * معناداری آماری در سطح اطمینان ۹۹/۹٪ را نشان می‌دهد. منبع: نویسندگان

تأثیر پارامترهای هواشناسی و آلاینده‌های جوی معیار بر سطح غلظت آلاینده کربن سیاه در تبریز و تهران:

در مجموع ۱۰ مدل (پنج مدل برای تبریز و پنج مدل برای تهران) با استفاده از الگوریتم‌های یادگیری ماشین (MLR، GAM، CART، RF و GBM) برای آگاهی بهتر از تأثیرات احتمالی عوامل هواشناسی (T، R، WS، RH، AP، SH، SR و C) و آلاینده‌های معیار هوا (CO، NO₂، SO₂، PM₁₀ و PM_{2.5}) بر سطح غلظت آلاینده کربن سیاه در تبریز و تهران از مارس ۲۰۰۴ تا ژوئیه ۲۰۲۱ ساخته شد. تمامی مدل‌ها برای تحقق مفروضات اساسی، هم خطی بین متغیرهای توضیحی و تنظیم فرامترهای مورد نیاز مورد بررسی قرار گرفتند. نمودار درختی ارائه‌شده در شکل ۵ تحلیل خوشه‌ای سلسله‌مراتبی متغیرهای مستقل را در توضیح تغییرپذیری غلظت ذرات کربن سیاه بر اساس روش مؤلفه اصلی در شهرهای تبریز و تهران نشان می‌دهد. بر اساس نمودار، پارامترهای هواشناسی دما، رطوبت نسبی و ساعات آفتابی در تبریز و تهران همبستگی بسیار بالایی با یکدیگر دارند ($r > 0/8$). به منظور جلوگیری از بروز عدم اطمینان و بی‌ثباتی در عملکرد مدل‌ها ناشی از وجود چند خطی میان متغیرهای بیان‌شده، رطوبت نسبی و ساعات آفتابی از مدلسازی حذف شدند. پس از حذف متغیرهای رطوبت نسبی و ساعات آفتابی از فرآیند مدلسازی، تعداد متغیرهای پیشگوی واردشده به مدل‌ها از ۱ تا ۱۲ تغییر یافت و متغیرهای ورودی مورد استفاده در هر الگوریتم متفاوت بود. شکل ۶ رتبه‌بندی متغیرهای پیشگو را در توضیح تغییرپذیری متغیر پاسخ کربن سیاه در تبریز و تهران بر اساس اهمیت نسبی مبتنی بر جایگشت آنها در داده‌های آموزشی با استفاده از ضریب تبیین (R^2) به‌عنوان معیار ارزیابی مدل نشان می‌دهد. شاخص‌های ارزیابی عملکرد تمامی فن‌های مدل‌سازی در جدول ۳ خلاصه شده است.



شکل ۵: خوشه‌بندی سلسله‌مراتبی متغیرهای پیشگو (پارامترهای هواشناسی و آلاینده‌های جوی معیار) با استفاده از همبستگی اسپیرمن در الف) تبریز و ب) تهران. T، R، WS، RH، AP، SH، SR و C به ترتیب میانگین ماهانه دما، بارش، سرعت باد، رطوبت نسبی، فشار هوا، ساعات آفتابی، تابش خورشیدی و ابرناکی را نشان می‌دهد. منبع: نویسندگان

نمودارهای اهمیت نسبی متغیرهای هواشناسی و آلاینده‌های معیار هوا در توضیح تغییرپذیری سطح آلاینده کربن سیاه در شهر تبریز نشان می‌دهد که آلاینده O_3 به‌عنوان عامل اصلی مؤثر در تغییرات غلظت ذرات BC در کلیه الگوریتم‌های مدلسازی MLR، GAM، CART، RF و GBM شناخته شده است. بر اساس برون‌داد مدل‌های MLR و GAM، متغیرهای O_3 ، SR، WS، $PM_{2.5}$ ، NO_2 و T از مهم‌ترین متغیرهای پیشگوی تأثیرگذار در تغییرات سطح غلظت آلاینده کربن سیاه در تبریز محسوب می‌شوند که از میان آنها O_3 و SR دارای بیشترین اهمیت و پارامتر دما دارای کمترین اهمیت است. در مدل‌های درخت مبنا (CART، RF و GBM)، به‌ترتیب اهمیت O_3 ، سرعت باد، دما، $PM_{2.5}$ و تابش خورشیدی در تبیین تغییرپذیری غلظت ذرات BC در تبریز بیش از سایر متغیرها تخمین زده شده است. CART، RF و GBM، آلاینده SO_2 را به‌عنوان کم تأثیرترین متغیر در تغییرات BC نشان داده‌اند. به‌طور کلی، با در نظر گرفتن رتبه‌بندی متغیرها در تمامی مدل‌ها می‌توان گفت که از میان آلاینده‌های جوی معیار، آلاینده‌های O_3 ، $PM_{2.5}$ و NO_2 و از میان پارامترهای هواشناسی، عناصر تابش خورشیدی، سرعت باد و دما از اهمیت بیشتری در توضیح تغییرات BC در تبریز برخوردارند. از سوی دیگر، در نگاه اول عملکرد تمامی مدل‌ها در پیش‌بینی BC در تبریز خوب به نظر می‌رسد. مقایسه عملکرد مدل‌ها در پیش‌بینی مقادیر غلظت ذرات BC در تبریز حاکی از حصول بهترین نتیجه از نظر بالاترین مقدار R^2 و پایین‌ترین مقدار RMSE اعتبارسنجی برای مدل جنگل تصادفی ($0.04 = RMSE_{RF}$ و $0.91 = R^2_{RF}$) و پس از آن مدل‌های جمعی تعمیم‌یافته ($0.04 = RMSE_{GAM}$ و $0.88 = R^2_{GAM}$) و تقویت گرادیان ($0.04 = RMSE_{GBM}$ و $0.88 = R^2_{GBM}$) است. بر اساس مقادیر معیارهای ارزیابی ارائه‌شده در جدول ۳، عملکرد پیش‌بینی مدل رگرسیون خطی چندگانه ($0.04 = RMSE_{MLR}$ و $0.87 = R^2_{MLR}$) بسیار نزدیک به مدل‌های جمعی تعمیم‌یافته، تقویت گرادیان و جنگل تصادفی است و تنها مدل درخت طبقه‌بندی و رگرسیون ($0.06 = RMSE_{CART}$ و $0.75 = R^2_{CART}$) دارای عملکرد ضعیف‌تری نسبت به مدل MLR است. عملکرد ضعیف CART می‌تواند ناشی از تمایل این مدل‌ها به محدود کردن دامنه پیش‌بینی‌ها و بیش‌برازش باشد. همان‌طور که نمودار رتبه‌بندی اهمیت متغیرهای پیشگو در توضیح تغییرپذیری ذرات کربن سیاه در تبریز نشان می‌دهد، انتخاب متغیر در مدل GAM فقط محدود به شش متغیر O_3 ، SR، WS، $PM_{2.5}$ ، NO_2 و T است و وارد کردن متغیرهای جدید در مدل جنگل تصادفی، قدرت پیش‌بینی را به میزان کمی افزایش داده است (۰.۳٪). بنابراین، می‌توان نتیجه گرفت که با توجه به دقت پیش‌بینی مدل و اصل صرفه‌جویی، مدل ساده‌تر GAM با متغیرهای کمتر نسبت به مدل پیچیده‌تر RF با متغیرهای بیشتر ترجیح داده می‌شود.

نمودارهای رتبه‌بندی اهمیت نسبی پارامترهای هواشناسی و آلاینده‌های جوی معیار مؤثر در توصیف تغییرپذیری سطح غلظت ذرات کربن سیاه در شهر تهران نیز بیانگر شناخت نقش بسیار مهم متغیر دما در پیش‌بینی مقادیر BC توسط تمامی مدل‌های برازش یافته است. فشار هوا و $PM_{2.5}$ متغیرهای پیشگوی تأثیرگذار بعدی در مدل‌های MLR و GAM هستند و آلاینده O_3 نسبت به آنها از اهمیت کمتری در توضیح تغییرات BC در تهران برخوردار است. در مدل درخت طبقه‌بندی و رگرسیون، پس از پارامتر هواشناسی دما، پارامترهای بارش، فشار هوا، آلاینده ازن و پارامتر ابرناکی به‌ترتیب به‌عنوان مؤثرترین متغیرهای توضیحی در پیش‌بینی مقادیر غلظت آلاینده BC شناخته شده و تابش خورشیدی، سرعت باد، NO_2 ، $PM_{2.5}$ و PM_{10} از اهمیت کمتری برخوردار هستند. در دو مدل درخت مبنای دیگر

(GBM و RF)، پارامتر فشار هوا و آلاینده ازن به عنوان دو متغیر مهم بعدی معرفی شده‌اند و در میان سایر متغیرها، آلاینده SO_2 دارای کمترین تأثیر در تغییرات سطح غلظت ذرات کربن سیاه در تهران است. در مجموع، از میان آلاینده‌های معیار هوا، آلاینده‌های $PM_{2.5}$ و O_3 و از میان عناصر هواشناسی، پارامترهای دما، فشار هوا و بارش نقش مؤثرتری در بیان تغییرات غلظت آلاینده کربن سیاه در تهران ایفا می‌کنند. ارزیابی نتایج عملکرد مدل‌های پیش‌بینی‌کننده بر مبنای معیارهای R^2 و RMSE نشان می‌دهد که عملکرد کلی مدل‌های MLR، GAM، RF و GBM نسبتاً خوب به نظر می‌رسد و در این میان مدل CART کمترین امتیاز را کسب می‌کند. نتایج حاصل از مقایسه عملکرد مدل‌های مختلف حاکی از آن است که روش GAM عملکرد پیش‌بینی بهتری را نسبت به مدل‌های دیگر با بالاترین مقدار ضریب تبیین اعتبارسنجی ($R^2_{GAM} = 0.68$) و کمترین مقدار ریشه میانگین مربعات خطا ($RMSE_{GAM} = 0.06$) ارائه می‌دهد. مدل رگرسیون خطی چندمتغیره ($RMSE_{MLR} = 0.06$ و $R^2_{MLR} = 0.67$)، جنگل تصادفی ($RMSE_{RF} = 0.07$ و $R^2_{RF} = 0.63$) و تقویت گرادیان ($RMSE_{GBM} = 0.07$ و $R^2_{GBM} = 0.58$) به ترتیب بهترین مدل‌های بعدی بودند. همان‌طور که ملاحظه می‌گردد مدل‌های GAM و MLR از عملکرد بهتری در پیش‌بینی مقادیر ذرات کربن سیاه در تهران نسبت به مدل‌های درخت مبنا برخوردارند. گزینش متغیر در مدل MLR به عنوان مدل مبنا، بیشتر به چهار متغیر دما، فشار هوا، O_3 و $PM_{2.5}$ محدود می‌شود و افزودن متغیرهای بارش و PM_{10} در مدل GAM، عملکرد پیش‌بینی را به میزان غیرقابل توجهی (۱٪) افزایش می‌دهد. بنابراین می‌توان با در نظر گرفتن دقت و سادگی مدل‌ها، مدل رگرسیون خطی چندمتغیره را به عنوان مدل نهایی مناسب برای تفسیر تأثیر متغیرهای هواشناسی و آلاینده‌های جوی در تغییرات غلظت BC و پیش‌بینی مقادیر انتخاب کرد.

جدول ۳: مقایسه عملکرد مدل‌های GBM، RF، GART، GAM، MLR در پیش‌بینی مقادیر غلظت کربن سیاه در تبریز و تهران

شهر	معیار	تکنیک‌های مدل‌سازی							
		GBM		RF		CART		GAM	
		آموزشی	آزمایشی	آموزشی	آزمایشی	آموزشی	آزمایشی	آموزشی	آزمایشی
تبریز	R ²	۰/۸۸	۰/۹۰	۰/۹۱	۰/۹۹	۰/۷۵	۱	۰/۸۸	۰/۹۲
	RMSE	۰/۰۴	۰/۰۲	۰/۰۴	۰/۰۲	۰/۰۶	۰	۰/۰۴	۰/۰۳
تهران	R ²	۰/۶۲	۰/۸۰	۰/۶۳	۰/۹۴	۰/۳۸	۰/۷۲	۰/۶۸	۰/۷۲
	RMSE	۰/۰۷	۰/۰۴	۰/۰۷	۰/۰۲	۰/۰۸	۰/۰۵	۰/۰۶	۰/۰۵

نتیجه‌گیری

نتایج این مطالعه حاکی از آن است که تأثیر پارامترهای هواشناسی و آلاینده‌های جوی معیار بر سطح غلظت آلاینده کربن سیاه در تبریز و تهران به‌دلیل موقعیت جغرافیایی، شرایط آب‌وهوایی و ساختار منطقه‌ای مختلف این شهرها متفاوت است. ذرات کربن سیاه روند صعودی معناداری را با سرعت نسبتاً برابر در طول دوره آماری ۱۷ ساله مورد مطالعه (۲۰۲۱-۲۰۰۴) در شهرهای تبریز و تهران تجربه کرده‌اند که با روند افزایشی غلظت کربن سیاه در گستره ایران مطابقت دارد (رئیس‌پور و خسروی، ۱۴۰۰). بر اساس یافته‌های حاصل از تحلیل همبستگی اسپیرمن در سطح اطمینان ۹۹/۹٪، ذرات کربن سیاه دارای همبستگی مثبت قوی با PM_{2.5}، همبستگی مثبت ضعیف با NO₂، همبستگی مثبت بسیار ضعیف با CO و SO₂، همبستگی منفی قوی با O₃ در تبریز، همبستگی مثبت بسیار ضعیف با آلاینده‌های SO₂ و PM_{2.5} و درعین‌حال همبستگی منفی متوسط با O₃ در تهران است. آلاینده کربن سیاه با میانگین ماهانه عناصر هواشناسی دما، سرعت باد، ساعات آفتابی و تابش خورشیدی در تبریز و تهران همبستگی منفی و با پارامترهای رطوبت نسبی، فشار هوا و ابرناکی همبستگی مثبت نشان داد و مقایسه ضرایب همبستگی بین غلظت آلاینده کربن سیاه و پارامترهای هواشناسی در تبریز و تهران بیانگر یکسان بودن جهت ارتباط کربن سیاه با این متغیرها در هر دو شهر و تفاوت در شدت روابط است. به‌طورکلی آلاینده کربن سیاه دارای بیشترین همبستگی با پارامترهای سرعت باد (منفی) و رطوبت نسبی (مثبت) در تبریز و پارامترهای دما (منفی) و فشار هوا (مثبت) در تهران است. نقش مؤثر پارامترهای هواشناسی سرعت باد و فشار هوا در تغییر غلظت آلاینده کربن سیاه در گستره جغرافیایی ایران توسط رئیس‌پور و خسروی (۱۴۰۰)، تأثیر پارامترهای سرعت باد و رطوبت نسبی بر غلظت ذرات کربن سیاه در چین توسط لیو و همکاران (۲۰۲۲) و اثر سرعت باد در پراکنش این ذرات در استانبول توسط شاهین و همکاران (۲۰۲۰) نیز گزارش شده است. یافته‌های حاصل از ارزیابی عملکرد مدل‌های مختلف برازش‌یافته بر اساس داده‌های این مطالعه حاکی از عملکرد بسیار خوب و خوب مدل‌های GBM، RF، GAM، MLR در پیش‌بینی مقادیر ذرات کربن سیاه به‌ترتیب در تبریز و تهران است. عملکرد مدل GAM در تبریز با عملکرد مدل‌های درخت مبنا (GBM و RF) قابل‌مقایسه است و در تهران بهتر از آنها عمل کرده است. در بین الگوریتم‌های یادگیری مبتنی بر درخت، مدل‌های RF و GBM در تبریز و تهران نسبت به CART بهتر عمل می‌کنند و به نظر می‌رسد RF نسبت به فن مدل‌سازی GBM، با اختلاف ناچیز، عملکرد بهتری در پیش‌بینی کربن سیاه به‌ویژه در تبریز ارائه دهد. در تبریز، تنها مدل CART عملکرد ضعیف‌تری نسبت به مدل MLR دارد. این در حالی است که در تهران، تنها مدل GAM در پیش‌بینی مقادیر BC بهتر از مدل مینای MLR عمل می‌کند. بنابراین می‌توان نتیجه گرفت که علیرغم

سادگی ظاهری مدل رگرسیون خطی چندگانه و تکیه آن بر مفروضات اصلی از قبیل نرمال بودن، همگنی واریانس، استقلال مشاهدات و خطی بودن، در صورت استفاده درست، عملکرد پیش‌بینی این مدل می‌تواند با عملکرد مدل‌های قدرتمندتر قابل‌مقایسه باشد و مدل GAM می‌تواند در مواقعی که مشاهدات به‌طور نرمال توزیع نیافته‌اند جایگزین مناسبی برای آن باشد.

کربن سیاه نقش پیچیده و درعین‌حال مهمی در اثر اقلیمی ذرات معلق در جو ایفا می‌کند. بنابراین، پژوهش‌ها بر روی تعاملات کربن سیاه با پارامترهای هواشناسی و سایر آلاینده‌های جوی بسیار مهم است و پیامدهای مثبتی در حفاظت از محیط‌زیست و سلامت انسان به‌همراه خواهد داشت. در واقع، به‌دلیل طول عمر کوتاه کربن سیاه، ممکن است بتوان با کنترل منابع انتشار این آلاینده گرمایش زمین را به سرعت کاهش داد. نتایج این مطالعه نشان می‌دهد که داده‌های باز تحلیل مدل MERRA-2 می‌تواند ابزار مناسبی برای تحلیل کیفی داده‌های کربن سیاه باشد. با این-حال، با توجه به قدرت تفکیک مکانی پایین داده‌های این مدل، طراحی سیستم‌های بهتر نظارت بر آلودگی هوا برای ثبت رویدادهای آلودگی کربن سیاه و تأثیرات محیطی آن در کلان‌شهرها ضروری است. ازسوی دیگر، شناخت تعامل پیچیده کربن سیاه با آب و هوا و آلاینده‌های جوی معیار در مناطق شهری دارای اقلیم و منابع انتشار متفاوت به‌ویژه در فصول مختلف سال نیازمند مطالعات بیشتر است. مطالعه واکنش‌های شیمیایی ناهمگن روی سطوح کربن سیاه و حالت‌های اختلاط آن با سایر هواویزها، تأثیر ذرات کربن سیاه بر ذوب یخچال‌ها و بازخوردهای آب‌وهوایی مرتبط و تأثیر غیرمستقیم ذرات کربن سیاه بر اقلیم می‌تواند از حوزه‌های کلیدی پژوهش‌های آتی در مورد ذرات کربن سیاه باشد.

تقدیر و تشکر

نویسندگان از سازمان هواشناسی کشور، شرکت کنترل کیفیت هوای تهران و اداره کل حفاظت محیط‌زیست استان آذربایجان شرقی جهت ارائه داده‌ها صمیمانه تشکر می‌کنند. قابل یادآوری است که این پژوهش بدون دریافت هیچ گونه کمک مالی از سازمان یا نهاد خاصی انجام گرفته است.

منابع

- رئیس پور، کوهزاد؛ خسروی، یونس. (۱۴۰۰). پایش بلندمدت غلظت آلاینده کربن سیاه (BC) در ایران با استفاده از داده‌های مدل مبنای NASA/MERRA-2. فصلنامه علوم محیطی، ۱۹(۳)، ۹۹-۱۲۲. <https://doi.org/10.52547/envs.2021.33941>
- سامانه درخواست داده‌های هواشناسی. سازمان هواشناسی کشور. <https://data.irimio.ir/>
- سرور، هوشنگ؛ اسمعیل پور، مرضیه؛ خیری‌زاده، منصور؛ امرایی، مهتاب. (۱۳۹۹). تحلیل فضایی مؤلفه‌های تأثیرگذار بر آلودگی هوای شهر تبریز. مجله مخاطرات محیط طبیعی، ۹(۲۴)، ۱۷۲-۱۵۱. <https://doi.org/10.22111/JNEH.2020.31469.1558>
- شرکت کنترل کیفیت هوا. شهرداری تهران. <https://air.tehran.ir/>
- مرکز پایش و کنترل آلودگی هوای شهر تبریز. اداره کل حفاظت محیط‌زیست استان آذربایجان شرقی. <https://as.doe.ir/>
- Ahmed, T., Dutkiewicz, V. A., Khan, A. J., & Husain, L. (2014). Long term trends in black carbon concentrations in the Northeastern United States. Atmospheric research, 137, pp 49-57. <https://doi.org/10.1016/j.atmosres.2013.10.003>
- Alas, H.D., Müller, T., Birmili, W., Kecorius, S., Cambaliza, M.O., Simpas, J.B.B., Cayetano, M., Weinhold, K., Vallar, E., Galvez, M.C. & Wiedensohler, A. (2018). Spatial characterization of black carbon mass concentration in the atmosphere of a

- Southeast Asian megacity: an air quality case study for Metro Manila, Philippines. *Aerosol and Air Quality Research*, 18(9), pp 2301-2317. <https://doi.org/10.4209/aaqr.2017.08.0281>
- Babu, S. S., & Moorthy, K. K. (2002). Aerosol black carbon over a tropical coastal station in India. *Geophysical Research Letters*, 29(23), pp 13-1. <https://doi.org/10.1029/2002GL015662>
- Barman, N. & Gokhale, S. (2019). Urban black carbon-source apportionment, emissions, and long-range transport over the Brahmaputra River Valley. *Science of the Total Environment*, 693, p.133577. <https://doi.org/10.1016/j.scitotenv.2019.07.383>
- Barton, K. (2023). MuMIn: multi-model inference. R package version 1.47.5. <https://CRAN.R-project.org/package=MumIn>.
- Beck, H. E., Zimmermann, N. E., McVicar, T. R., Vergopolan, N., Berg, A., & Wood, E. F. (2018). Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific data*, 5(1), pp 1-12. <https://doi.org/10.1038/sdata.2018.214>
- Bhat, M. A., Romshoo, S. A., & Beig, G. (2017). Aerosol black carbon at an urban site-Srinagar, Northwestern Himalaya, India: Seasonality, sources, meteorology and radiative forcing. *Atmospheric Environment*, 165, pp 336-348. <https://doi.org/10.1016/j.atmosenv.2017.07.004>
- Bian, H., Colarco, P. R., Chin, M., Chen, G., Rodriguez, J. M., Liang, Q., ... & Wisthaler, A. (2013). Source attributions of pollution to the Western Arctic during the NASA ARCTAS field campaign. *Atmospheric Chemistry and Physics*, 13(9), pp 4707-4721. <https://doi.org/10.5194/acp-13-4707-2013>
- Bibi, S., Alam, K., Chishtie, F., Bibi, H., & Rahman, S. (2017). Temporal variation of Black Carbon concentration using Aethalometer observations and its relationships with meteorological variables in Karachi, Pakistan. *Journal of Atmospheric and Solar-Terrestrial Physics*, 157, pp 67-77. <https://doi.org/10.1016/j.jastp.2017.03.017>
- Boehmke, B. & Greenwell, B.M. (2019). *Hands-on machine learning with R*. Chapman and Hall/CRC., 1st Eds, 514p.
- Bond, T.C., Doherty, S.J., Fahey, D.W., Forster, P.M., Bernsten, T., DeAngelo, B.J., Flanner, M.G., Ghan, S., Kärcher, B., Koch, D. & Zender, C. S. (2013). Bounding the role of black carbon in the climate system: A scientific assessment. *Journal of geophysical research: Atmospheres*, 118(11), pp 5380-5552. <https://doi.org/10.1002/jgrd.50171>
- Botsa, S. M., Tara, D. L. L. M., Magesh, N. S., & Tiwari, A. K. (2021). Characterization of black carbon aerosols over Indian Antarctic station, Maitri, and identification of potential source areas. *Environmental Science: Atmospheres*, 1(6), pp 416-422. <https://doi.org/10.1039/D1EA00024A>
- Bounakhla, Y., Benchrif, A., Costabile, F., Tahri, M., El Gouch, B., El Hassan, E.K., Zahry, F. & Bounakhla, M. (2023). Overview of PM10, PM2. 5 and BC and Their Dependent Relationships with Meteorological Variables in an Urban Area in Northwestern Morocco. *Atmosphere*, 14(1), p 162. <https://doi.org/10.3390/atmos14010162>
- Buchard, V., Da Silva, A. M., Colarco, P. R., Darmenov, A., Randles, C. A., Govindaraju, R., ... & Spurr, R. (2015). Using the OMI aerosol index and absorption aerosol optical depth to evaluate the NASA MERRA Aerosol Reanalysis. *Atmospheric Chemistry and Physics*, 15(10), pp 5743-5760. <https://doi.org/10.5194/acp-15-5743-2015>
- Chen, C., McCabe, D. C., Fleischman, L. E., & Cohan, D. S. (2022). Black carbon emissions and associated health impacts of gas flaring in the United States. *Atmosphere*, 13(3), p 385. <https://doi.org/10.3390/atmos13030385>
- Chen, W., Tian, H., & Qin, K. (2019). Black carbon aerosol in the industrial city of Xuzhou, China: Temporal characteristics and source appointment. *Aerosol and Air Quality Research*, 19(4), pp 794-811. <https://doi.org/10.4209/aaqr.2018.07.0245>
- Cheng, Y. H., & Yang, L. S. (2016). Characteristics of ambient black carbon mass and size-resolved particle number concentrations during corn straw open-field burning episode observations at a rural site in southern Taiwan. *International journal of environmental research and public health*, 13(7), p 688. <https://doi.org/10.3390/ijerph13070688>
- Colarco, P., da Silva, A., Chin, M., & Diehl, T. (2010). Online simulations of global aerosol distributions in the NASA GEOS-4 model and comparisons to satellite and ground-based aerosol optical depth. *Journal of Geophysical Research: Atmospheres*, 115(D14). <https://doi.org/10.1029/2009JD012820>
- Ding, A.J., Huang, X., Nie, W., Sun, J.N., Kerminen, V.M., Petäjä, T., Su, H., Cheng, Y.F., Yang, X.Q., Wang, M.H. & Fu, C. B. (2016). Enhanced haze pollution by black carbon in megacities in China. *Geophysical Research Letters*, 43(6), pp 2873-2879. <https://doi.org/10.1002/2016GL067745>
- Falk, C. F., & Muthukrishna, M. (2023). Parsimony in model selection: Tools for assessing fit propensity. *Psychological Methods*, 28(1), p 123. <https://doi.org/10.1037/met0000422>
- Fox, J. & Weisberg, S. (2018). *An R companion to applied regression*, third ed. Sage, Thousand Oaks CA.
- Greenwell, B. M., Boehmke, B. C., & Gray, B. (2020). Variable Importance Plots Introduction to the VIP Package. *R J.*, 12(1), p 343. <https://doi.org/10.32614/RJ-2020-013>
- Grieshop, A. P., Reynolds, C. C., Kandlikar, M., & Dowlatabadi, H. (2009). A black-carbon mitigation wedge. *Nature Geoscience*, 2(8), pp 533-534. <https://doi.org/10.1038/ngeo595>
- Harrell, F.E. & Dupont, C. (2023). Hmisc: Harrell miscellaneous. R package version 5.1-1.
- Healy, R.M., Sofowote, U., Su, Y., Deboz, J., Noble, M., Jeong, C.H., Wang, J.M., Hilker, N., Evans, G.J., Doerksen, G. & Munoz, A. (2017). Ambient measurements and source apportionment of fossil fuel and biomass burning black carbon in Ontario. *Atmospheric Environment*, 161, pp 34-47. <https://doi.org/10.1016/j.atmosenv.2017.04.034>
- <https://earthengine.google.com/>
- <https://gmao.gsfc.nasa.gov/reanalysis/MERRA-2/>
- Janssen, N.A., Gerlofs-Nijland, M.E., Lanki, T., Salonen, R.O., Cassee, F., Hoek, G., Fischer, P., Brunekreef, B. & Krzyzanowski, M. (2012). Health effects of black carbon. World Health Organization. Regional Office for Europe.

- Jing, A., Zhu, B., Wang, H., Yu, X., An, J., & Kang, H. (2019). Source apportionment of black carbon in different seasons in the northern suburb of Nanjing, China. *Atmospheric Environment*, 201, pp 190-200. <https://doi.org/10.1016/j.atmosenv.2018.12.060>
- Kim, S., Yu, S., & Yun, D. (2017). Spatiotemporal association of real-time concentrations of black carbon (BC) with fine particulate matters (PM_{2.5}) in urban hotspots of South Korea. *International Journal of Environmental Research and Public Health*, 14(11), p 1350. <https://doi.org/10.3390/ijerph14111350>
- Koch, D., & Del Genio, A. D. (2010). Black carbon semi-direct effects on cloud cover: review and synthesis. *Atmospheric Chemistry and Physics*, 10(16), pp 7685-7696. <https://doi.org/10.5194/acp-10-7685-2010>
- Korkmaz, S., Göksülük, D., & Zararsiz, G. Ö. K. M. E. N. (2014). MVN: An R package for assessing multivariate normality. *R JOURNAL*, 6(2).
- Kouassi, A., Doumbia, M., Silue, S., Yao, E.M., Dajuma, A., Adon, M., Touré, T. & Yoboue, V. (2021). Measurement of atmospheric black carbon concentration in rural and urban environments: cases of Lamto and Abidjan. *Journal of Environmental Protection*, 12, pp 855-872. <https://doi.org/10.4236/jep.2021.1211050>
- Kuhn, M. & Wickham, H. (2020). Tidymodels: A Collection of Packages for Modeling and Machine Learning using Tidyverse Principles. <https://www.tidymodels.org>
- Kutzner, R. D., von Schneidmesser, E., Kuik, F., Quedenau, J., Weatherhead, E. C., & Schmale, J. (2018). Long-term monitoring of black carbon across Germany. *Atmospheric Environment*, 185, pp 41-52. <https://doi.org/10.1016/j.atmosenv.2018.04.039>
- Liakakou, E., Stavroulas, I., Kaskaoutis, D.G., Grivas, G., Paraskevopoulou, D., Dumka, U.C., Tsagkaraki, M., Bougiatioti, A., Oikonomou, K., Sciare, J. & Mihalopoulos, N. (2020). Long-term variability, source apportionment and spectral properties of black carbon at an urban background site in Athens, Greece. *Atmospheric Environment*, 222, p 117137. <https://doi.org/10.1016/j.atmosenv.2019.117137>
- Liu, B., Ma, Y., Gong, W., Zhang, M., & Shi, Y. (2019). The relationship between black carbon and atmospheric boundary layer height. *Atmospheric Pollution Research*, 10(1), pp 65-72. <https://doi.org/10.1016/j.apr.2018.06.007>
- Liu, X., Wei, Y., Liu, X., Zu, L., Wang, B., Wang, S., Zhang, R. & Zhu, R. (2022). Effects of Winter Heating on Urban Black Carbon: Characteristics, Sources and Its Correlation with Meteorological Factors. *Atmosphere*, 13(7), p 1071. <https://doi.org/10.3390/atmos13071071>
- Lund, M. T., Berntsen, T. K., & Samset, B. H. (2017). Sensitivity of black carbon concentrations and climate impact to aging and scavenging in OsloCTM2-M7. *Atmospheric Chemistry and Physics*, 17(9), pp 6003-6022. <https://doi.org/10.5194/acp-17-6003-2017>
- Mann, H. B. (1945). Nonparametric tests against trend. *Econometrica: Journal of the econometric society*, pp 245-259.
- Miller, A. (2020). leaps: regression subset selection. R package version 3.1. <https://CRAN.R-project.org/package=leaps>.
- Mousavi, A., Sowlat, M.H., Lovett, C., Rauber, M., Szidat, S., Boffi, R., Borgini, A., De Marco, C., Ruprecht, A.A. & Sioutas, C. (2019). Source apportionment of black carbon (BC) from fossil fuel and biomass burning in metropolitan Milan, Italy. *Atmospheric environment*, 203, pp 252-261. <https://doi.org/10.1016/j.atmosenv.2019.02.009>
- Mukaka, M. M. (2012). A guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal*, 24(3), pp 69-71. PMID: 23638278; PMCID: PMC3576830.
- Navinya, C. D., Vinoj, V., & Pandey, S. K. (2020). Evaluation of PM_{2.5} surface concentrations simulated by NASA's MERRA version 2 aerosol reanalysis over India and its relation to the air quality index. *Aerosol and Air Quality Research*, 20(6), pp 1329-1339. <https://doi.org/10.4209/aaqr.2019.12.0615>
- Pena, E.A. & Slate, E.H. (2014). gvlma: global validation of linear models assumptions. R package version 1.0. 0.3.
- Pohlert, T. (2023). Trend: non-parametric trend tests and change-point detection. R package version, 1.1.6.
- Rad, A.K., Shamshiri, R.R., Naghipour, A., Razmi, S.O., Shariati, M., Golkar, F. & Balasundram, S.K. (2022). Machine learning for determining interactions between air pollutants and environmental parameters in three cities of Iran. *Sustainability*, 14(13), p.8027. <https://doi.org/10.3390/su14138027>
- Rienecker, M. M., Suarez, M. J., Gelaro, R., Todling, R., Bacmeister, J., Liu, E., ... & Woollen, J. (2011). MERRA: NASA's modern-era retrospective analysis for research and applications. *Journal of Climate*, 24(14), pp 3624-3648. <https://doi.org/10.1175/JCLI-D-11-00015.1>
- Ryu, C. (2022). dlookr: Tools for data diagnosis, exploration, and transformation. R package version 0.6.2.9001.
- Şahin, Ü.A., Onat, B., Akın, Ö., Ayvaz, C., Uzun, B., Mangır, N., Doğan, M. & Harrison, R.M. (2020). Temporal variations of atmospheric black carbon and its relation to other pollutants and meteorological factors at an urban traffic site in Istanbul. *Atmospheric Pollution Research*, 11(7), pp 1051-1062. <https://doi.org/10.1016/j.apr.2020.03.009>
- Samset, B.H., Myhre, G., Schulz, M., Balkanski, Y., Bauer, S., Berntsen, T.K., Bian, H., Bellouin, N., Diehl, T., Easter, R.C. & Zhang, K. (2013). Black carbon vertical profiles strongly affect its radiative forcing uncertainty. *Atmospheric Chemistry and Physics*, 13(5), pp 2423-2434. <http://dx.doi.org/10.5194/acp-13-2423-2013>
- Sand, M., Samset, B. H., Tsigaridis, K., Bauer, S. E., & Myhre, G. (2020). Black carbon and precipitation: An energetics perspective. *Journal of Geophysical Research: Atmospheres*, 125(13), e2019JD032239. <https://doi.org/10.1029/2019JD032239>

- Sankar, T. K., Ambade, B., Mahato, D. K., Kumar, A., & Jangde, R. (2023). Anthropogenic fine aerosol and black carbon distribution over the urban environment. *Journal of Umm Al-Qura University for Applied Sciences*, pp 1-10. <https://doi.org/10.1007/s43994-023-00055-4>
- Sarle, WS. (1990). The VARCLUS Procedure, in SAS/STAT® 9.3 User's Guide, 4th eds. SAS Institute Inc., Cary, NC, pp. 8065-8097.
- Singh, V., Ravindra, K., Sahu, L., & Sokhi, R. (2018). Trends of atmospheric black carbon concentration over the United Kingdom. *Atmospheric environment*, 178, pp 148-157. <https://doi.org/10.1016/j.atmosenv.2018.01.030>
- Song, S., Wu, Y., Xu, J., Ohara, T., Hasegawa, S., Li, J., Yang, L. & Hao, J. (2013). Black carbon at a roadside site in Beijing: Temporal variations and relationships with carbon monoxide and particle number size distribution. *Atmospheric Environment*, 77, pp 213-221. <https://doi.org/10.1016/j.atmosenv.2013.04.055>
- Spearman, C. (1961). The proof and measurement of association between two things.
- Stekhoven, D. J., & Bühlmann, P. (2012). MissForest—non-parametric missing value imputation for mixed-type data. *Bioinformatics*, 28(1), pp 112-118. <https://doi.org/10.1093/bioinformatics/btr597>
- Swader, A. (2022). Black Carbon and Meteorological Parameters at Two Locations in Northern Mississippi. *Mississippi" (2022). Honors Theses*. 2718. https://egrove.olemiss.edu/hon_thesis/2718
- Taheri, A., Aliasghari, P., & Hosseini, V. (2019). Black carbon and PM2.5 monitoring campaign on the roadside and residential urban background sites in the city of Tehran. *Atmospheric environment*, 218, p 116928. <https://doi.org/10.1016/j.atmosenv.2019.116928>
- Vaishya, A., Singh, P., Rastogi, S., & Babu, S. S. (2017). Aerosol black carbon quantification in the central Indo-Gangetic Plain: Seasonal heterogeneity and source apportionment. *Atmospheric Research*, 185, pp 13-21. <https://doi.org/10.1016/j.atmosres.2016.10.001>
- Wahab, B. I., Hassan, B. J., Al-Timimi, Y. K., & Al-Ataby, I. K. (2023, August). Relationship Between the Concentrations of Black Carbon and some Meteorological Parameters Over Iraq using GIS Techniques. In *IOP Conference Series: Earth and Environmental Science* (Vol. 1223, No. 1, p. 012015). IOP Publishing. <https://doi.org/10.1088/17551315/1223/1/012015>
- Wang, X., Smith, K., & Hyndman, R. (2006). Characteristic-based clustering for time series data. *Data mining and knowledge Discovery*, 13, pp 335-364. <https://doi.org/10.1007/s10618-005-0039-x>
- Wang, Z., Zhong, S., Peng, Z. R., & Cai, M. (2018). Fine-scale variations in PM2.5 and black carbon concentrations and corresponding influential factors at an urban road intersection. *Building and Environment*, 141, pp 215-225. <https://doi.org/10.1016/j.buildenv.2018.04.042>
- Wei, T. & Simko, V.R. (2021). Package "Corrplot": Visualization of a Correlation Matrix (Version 0.92). Package Corrplot for R Software.
- Winiger, P., Andersson, A., Eckhardt, S., Stohl, A., Semiletov, I.P., Dudarev, O.V., Charkin, A., Shakhova, N., Klimont, Z., Heyes, C. & Gustafsson, Ö. (2017). Siberian Arctic black carbon sources are constrained by model and observation. *Proceedings of the National Academy of Sciences*, 114(7), pp E1054-E1061. <https://doi.org/10.1073/pnas.1613401114>
- Yeganeh, B., Khuzestani, R. B., Taheri, A., & Schauer, J. J. (2021). Temporal trends in the spatial-scale contributions to black carbon in a Middle Eastern megacity. *Science of the Total Environment*, 792, p 148364. <https://doi.org/10.1016/j.scitotenv.2021.148364>
- Yu, N., Zhu, Y., Xie, X., Yan, C., Zhu, T. and Zheng, M. (2015). Characterization of Ultrafine Particles and Other Traffic-Related Pollutants Near Roadways in Beijing. *Aerosol Air Qual. Res.* 15, pp 1261-1269. <https://doi.org/10.4209/aaqr.2014.11.0295>
- Zambrano-Bigiarini, M. (2024). Goodness-of-fit functions for comparison of simulated and observed hydrological time series, R package version 0.5-4.
- Zhang, Y., Li, Y., Guo, J., Wang, Y., Chen, D., & Chen, H. (2019). The climatology and trend of black carbon in China from 12-year ground observations. *Climate Dynamics*, 53, pp 5881-5892. <https://doi.org/10.1007/s00382-019-04903-0>
- Zhao, P., Dong, F., Yang, Y., He, D., Zhao, X., Zhang, W., Yao, Q. & Liu, H. (2013). Characteristics of carbonaceous aerosol in the region of Beijing, Tianjin, and Hebei, China. *Atmospheric Environment*, 71, pp 389-398. <https://doi.org/10.1016/j.atmosenv.2013.02.010>

References

References (in Persian)

- Air pollution monitoring and control center of Tabriz city. General Department of Environmental Protection of East Azerbaijan Province. <https://as.doe.ir/>. [In Persian]
- Air Quality Control Company. Municipality of Tehran. <https://air.tehran.ir/>. [In Persian]
- Meteorological data request system. Iran Meteorological Organization. <https://data.irimo.ir/>. [In Persian]
- Raispour, K., & Khosravi, Y. (2021). Long-term monitoring of the concentration of carbon black pollutants in Iran using NASA/MERRA-2 base model data. *Environmental Sciences*, 19(3), pp 99-122. <https://doi.org/10.52547/envs.2021.33941>. [In Persian]
- Sarvar, H., Esmaeilpour, M., Kirizadeh, M. & Amrai, M. (2020). Spatial analysis of factors affecting air pollution in Tabriz city. *Journal of Natural Environmental Hazards*, 9(24), pp 151-172. <https://doi.org/10.22111/JNEH.2020.31469.1558>. [In Persian]

References (in English)

- Ahmed, T., Dutkiewicz, V. A., Khan, A. J., & Husain, L. (2014). Long term trends in black carbon concentrations in the Northeastern United States. *Atmospheric research*, 137, pp 49-57. <https://doi.org/10.1016/j.atmosres.2013.10.003>
- Alas, H.D., Müller, T., Birmili, W., Kecorius, S., Cambaliza, M.O., Simpas, J.B.B., Cayetano, M., Weinhold, K., Vallar, E., Galvez, M.C. & Wiedensohler, A. (2018). Spatial characterization of black carbon mass concentration in the atmosphere of a Southeast Asian megacity: an air quality case study for Metro Manila, Philippines. *Aerosol and Air Quality Research*, 18(9), pp 2301-2317. <https://doi.org/10.4209/aaqr.2017.08.0281>
- Babu, S. S., & Moorthy, K. K. (2002). Aerosol black carbon over a tropical coastal station in India. *Geophysical Research Letters*, 29(23), pp 13-1. <https://doi.org/10.1029/2002GL015662>
- Barman, N. & Gokhale, S. (2019). Urban black carbon-source apportionment, emissions, and long-range transport over the Brahmaputra River Valley. *Science of the Total Environment*, 693, p.133577. <https://doi.org/10.1016/j.scitotenv.2019.07.383>
- Barton, K. (2023). MuMIn: multi-model inference. R package version 1.47.5. <https://CRAN.R-project.org/package=MumIn>.
- Beck, H. E., Zimmermann, N. E., McVicar, T. R., Vergopolan, N., Berg, A., & Wood, E. F. (2018). Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific data*, 5(1), pp 1-12. <https://doi.org/10.1038/sdata.2018.214>
- Bhat, M. A., Romshoo, S. A., & Beig, G. (2017). Aerosol black carbon at an urban site-Srinagar, Northwestern Himalaya, India: Seasonality, sources, meteorology and radiative forcing. *Atmospheric Environment*, 165, pp 336-348. <https://doi.org/10.1016/j.atmosenv.2017.07.004>
- Bian, H., Colarco, P. R., Chin, M., Chen, G., Rodriguez, J. M., Liang, Q., ... & Wisthaler, A. (2013). Source attributions of pollution to the Western Arctic during the NASA ARCTAS field campaign. *Atmospheric Chemistry and Physics*, 13(9), pp 4707-4721. <https://doi.org/10.5194/acp-13-4707-2013>
- Bibi, S., Alam, K., Chishtie, F., Bibi, H., & Rahman, S. (2017). Temporal variation of Black Carbon concentration using Aethalometer observations and its relationships with meteorological variables in Karachi, Pakistan. *Journal of Atmospheric and Solar-Terrestrial Physics*, 157, pp 67-77. <https://doi.org/10.1016/j.jastp.2017.03.017>
- Boehmke, B. & Greenwell, B.M. (2019). Hands-on machine learning with R. Chapman and Hall/CRC., 1st Eds, 514p.
- Bond, T.C., Doherty, S.J., Fahey, D.W., Forster, P.M., Bernsten, T., DeAngelo, B.J., Flanner, M.G., Ghan, S., Kärcher, B., Koch, D. & Zender, C. S. (2013). Bounding the role of black carbon in the climate system: A scientific assessment. *Journal of geophysical research: Atmospheres*, 118(11), pp 5380-5552. <https://doi.org/10.1002/jgrd.50171>
- Botsa, S. M., Tara, D. L. L. M., Magesh, N. S., & Tiwari, A. K. (2021). Characterization of black carbon aerosols over Indian Antarctic station, Maitri, and identification of potential source areas. *Environmental Science: Atmospheres*, 1(6), pp 416-422. <https://doi.org/10.1039/D1EA00024A>
- Bounakhla, Y., Benchrif, A., Costabile, F., Tahri, M., El Gouch, B., El Hassan, E.K., Zahry, F. & Bounakhla, M. (2023). Overview of PM10, PM2.5 and BC and Their Dependent Relationships with Meteorological Variables in an Urban Area in Northwestern Morocco. *Atmosphere*, 14(1), p 162. <https://doi.org/10.3390/atmos14010162>
- Buchard, V., Da Silva, A. M., Colarco, P. R., Darmenov, A., Randles, C. A., Govindaraju, R., ... & Spurr, R. (2015). Using the OMI aerosol index and absorption aerosol optical depth to evaluate the NASA MERRA Aerosol Reanalysis. *Atmospheric Chemistry and Physics*, 15(10), pp 5743-5760. <https://doi.org/10.5194/acp-15-5743-2015>
- Chen, C., McCabe, D. C., Fleischman, L. E., & Cohan, D. S. (2022). Black carbon emissions and associated health impacts of gas flaring in the United States. *Atmosphere*, 13(3), p 385. <https://doi.org/10.3390/atmos13030385>
- Chen, W., Tian, H., & Qin, K. (2019). Black carbon aerosol in the industrial city of Xuzhou, China: Temporal characteristics and source appointment. *Aerosol and Air Quality Research*, 19(4), pp 794-811. <https://doi.org/10.4209/aaqr.2018.07.0245>
- Cheng, Y. H., & Yang, L. S. (2016). Characteristics of ambient black carbon mass and size-resolved particle number concentrations during corn straw open-field burning episode observations at a rural site in southern Taiwan. *International journal of environmental research and public health*, 13(7), p 688. <https://doi.org/10.3390/ijerph13070688>

- Colarco, P., da Silva, A., Chin, M., & Diehl, T. (2010). Online simulations of global aerosol distributions in the NASA GEOS-4 model and comparisons to satellite and ground-based aerosol optical depth. *Journal of Geophysical Research: Atmospheres*, 115(D14). <https://doi.org/10.1029/2009JD012820>
- Ding, A.J., Huang, X., Nie, W., Sun, J.N., Kerminen, V.M., Petäjä, T., Su, H., Cheng, Y.F., Yang, X.Q., Wang, M.H. & Fu, C. B. (2016). Enhanced haze pollution by black carbon in megacities in China. *Geophysical Research Letters*, 43(6), pp 2873-2879. <https://doi.org/10.1002/2016GL067745>
- Falk, C. F., & Muthukrishna, M. (2023). Parsimony in model selection: Tools for assessing fit propensity. *Psychological Methods*, 28(1), p 123. <https://doi.org/10.1037/met0000422>
- Fox, J. & Weisberg, S. (2018). *An R companion to applied regression*, third ed. Sage, Thousand Oaks CA.
- Greenwell, B. M., Boehmke, B. C., & Gray, B. (2020). Variable Importance Plots Introduction to the VIP Package. *R J.*, 12(1), p 343. <https://doi.org/10.32614/RJ-2020-013>
- Grieshop, A. P., Reynolds, C. C., Kandlikar, M., & Dowlatabadi, H. (2009). A black-carbon mitigation wedge. *Nature Geoscience*, 2(8), pp 533-534. <https://doi.org/10.1038/ngeo595>
- Harrell, F.E. & Dupont, C. (2023). *Hmisc: Harrell miscellaneous*. R package version 5.1-1.
- Healy, R.M., Sofowote, U., Su, Y., Deboz, J., Noble, M., Jeong, C.H., Wang, J.M., Hilker, N., Evans, G.J., Doerksen, G. & Munoz, A. (2017). Ambient measurements and source apportionment of fossil fuel and biomass burning black carbon in Ontario. *Atmospheric Environment*, 161, pp 34-47. <https://doi.org/10.1016/j.atmosenv.2017.04.034>
- <https://earthengine.google.com/>
- <https://gmao.gsfc.nasa.gov/reanalysis/MERRA-2/>
- Janssen, N.A., Gerlofs-Nijland, M.E., Lanki, T., Salonen, R.O., Cassee, F., Hoek, G., Fischer, P., Brunekreef, B. & Krzyzanowski, M. (2012). Health effects of black carbon. World Health Organization. Regional Office for Europe.
- Jing, A., Zhu, B., Wang, H., Yu, X., An, J., & Kang, H. (2019). Source apportionment of black carbon in different seasons in the northern suburb of Nanjing, China. *Atmospheric Environment*, 201, pp 190-200. <https://doi.org/10.1016/j.atmosenv.2018.12.060>
- Kim, S., Yu, S., & Yun, D. (2017). Spatiotemporal association of real-time concentrations of black carbon (BC) with fine particulate matters (PM_{2.5}) in urban hotspots of South Korea. *International Journal of Environmental Research and Public Health*, 14(11), p 1350. <https://doi.org/10.3390/ijerph14111350>
- Koch, D., & Del Genio, A. D. (2010). Black carbon semi-direct effects on cloud cover: review and synthesis. *Atmospheric Chemistry and Physics*, 10(16), pp 7685-7696. <https://doi.org/10.5194/acp-10-7685-2010>
- Korkmaz, S., Gökşülük, D., & Zararsız, G. Ö. K. M. E. N. (2014). MVN: An R package for assessing multivariate normality. *R JOURNAL*, 6(2).
- Kouassi, A., Doumbia, M., Silue, S., Yao, E.M., Dajuma, A., Adon, M., Touré, T. & Yoboue, V. (2021). Measurement of atmospheric black carbon concentration in rural and urban environments: cases of Lamto and Abidjan. *Journal of Environmental Protection*, 12, pp 855-872. <https://doi.org/10.4236/jep.2021.1211050>
- Kuhn, M. & Wickham, H. (2020). *Tidymodels: A Collection of Packages for Modeling and Machine Learning using Tidyverse Principles*. <https://www.tidymodels.org>
- Kutzner, R. D., von Schneidmesser, E., Kuik, F., Quedenau, J., Weatherhead, E. C., & Schmale, J. (2018). Long-term monitoring of black carbon across Germany. *Atmospheric Environment*, 185, pp 41-52. <https://doi.org/10.1016/j.atmosenv.2018.04.039>
- Liakakou, E., Stavroulas, I., Kaskaoutis, D.G., Grivas, G., Paraskevopoulou, D., Dumka, U.C., Tsagkaraki, M., Bougiatioti, A., Oikonomou, K., Sciare, J. & Mihalopoulos, N. (2020). Long-term variability, source apportionment and spectral properties of black carbon at an urban background site in Athens, Greece. *Atmospheric Environment*, 222, p 117137. <https://doi.org/10.1016/j.atmosenv.2019.117137>
- Liu, B., Ma, Y., Gong, W., Zhang, M., & Shi, Y. (2019). The relationship between black carbon and atmospheric boundary layer height. *Atmospheric Pollution Research*, 10(1), pp 65-72. <https://doi.org/10.1016/j.apr.2018.06.007>
- Liu, X., Wei, Y., Liu, X., Zu, L., Wang, B., Wang, S., Zhang, R. & Zhu, R. (2022). Effects of Winter Heating on Urban Black Carbon: Characteristics, Sources and Its Correlation with Meteorological Factors. *Atmosphere*, 13(7), p 1071. <https://doi.org/10.3390/atmos13071071>
- Lund, M. T., Berntsen, T. K., & Samset, B. H. (2017). Sensitivity of black carbon concentrations and climate impact to aging and scavenging in OsloCTM2-M7. *Atmospheric Chemistry and Physics*, 17(9), pp 6003-6022. <https://doi.org/10.5194/acp-17-6003-2017>
- Mann, H. B. (1945). Nonparametric tests against trend. *Econometrica: Journal of the econometric society*, pp 245-259.
- Miller, A. (2020). *leaps: regression subset selection*. R package version 3.1. <https://CRAN.R-project.org/package=leaps>.
- Mousavi, A., Sowlat, M.H., Lovett, C., Rauber, M., Szidat, S., Boffi, R., Borgini, A., De Marco, C., Ruprecht, A.A. & Sioutas, C. (2019). Source apportionment of black carbon (BC) from fossil fuel and biomass burning in metropolitan Milan, Italy. *Atmospheric environment*, 203, pp 252-261. <https://doi.org/10.1016/j.atmosenv.2019.02.009>
- Mukaka, M. M. (2012). A guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal*, 24(3), pp 69-71. PMID: 23638278; PMCID: PMC3576830.
- Navinya, C. D., Vinoy, V., & Pandey, S. K. (2020). Evaluation of PM_{2.5} surface concentrations simulated by NASA's MERRA version 2 aerosol reanalysis over India and its relation to the air quality index. *Aerosol and Air Quality Research*, 20(6), pp 1329-1339. <https://doi.org/10.4209/aaqr.2019.12.0615>
- Pena, E.A. & Slate, E.H. (2014). *gvlma: global validation of linear models assumptions*. R package version 1.0. 0.3.
- Pohlert, T. (2023). *Trend: non-parametric trend tests and change-point detection*. R package version, 1.1.6.

- Rad, A.K., Shamshiri, R.R., Naghipour, A., Razmi, S.O., Shariati, M., Golkar, F. & Balasundram, S.K. (2022). Machine learning for determining interactions between air pollutants and environmental parameters in three cities of Iran. *Sustainability*, 14(13), p.8027. <https://doi.org/10.3390/su14138027>
- Rienecker, M. M., Suarez, M. J., Gelaro, R., Todling, R., Bacmeister, J., Liu, E., ... & Woollen, J. (2011). MERRA: NASA's modern-era retrospective analysis for research and applications. *Journal of Climate*, 24(14), pp 3624-3648. <https://doi.org/10.1175/JCLI-D-11-00015.1>
- Ryu, C. (2022). dlookr: Tools for data diagnosis, exploration, and transformation. R package version 0.6.2.9001.
- Şahin, Ü.A., Onat, B., Akın, Ö., Ayvaz, C., Uzun, B., Mangır, N., Doğan, M. & Harrison, R.M. (2020). Temporal variations of atmospheric black carbon and its relation to other pollutants and meteorological factors at an urban traffic site in Istanbul. *Atmospheric Pollution Research*, 11(7), pp 1051-1062. <https://doi.org/10.1016/j.apr.2020.03.009>
- Samset, B.H., Myhre, G., Schulz, M., Balkanski, Y., Bauer, S., Bernsten, T.K., Bian, H., Bellouin, N., Diehl, T., Easter, R.C. & Zhang, K. (2013). Black carbon vertical profiles strongly affect its radiative forcing uncertainty. *Atmospheric Chemistry and Physics*, 13(5), pp 2423-2434. <http://dx.doi.org/10.5194/acp-13-2423-2013>
- Sand, M., Samset, B. H., Tsigaridis, K., Bauer, S. E., & Myhre, G. (2020). Black carbon and precipitation: An energetics perspective. *Journal of Geophysical Research: Atmospheres*, 125(13), e2019JD032239. <https://doi.org/10.1029/2019JD032239>
- Sankar, T. K., Ambade, B., Mahato, D. K., Kumar, A., & Jangde, R. (2023). Anthropogenic fine aerosol and black carbon distribution over the urban environment. *Journal of Umm Al-Qura University for Applied Sciences*, pp 1-10. <https://doi.org/10.1007/s43994-023-00055-4>
- Sarle, W.S. (1990). The VARCLUS Procedure, in SAS/STAT® 9.3 User's Guide, 4th eds. SAS Institute Inc., Cary, NC, pp. 8065-8097.
- Singh, V., Ravindra, K., Sahu, L., & Sokhi, R. (2018). Trends of atmospheric black carbon concentration over the United Kingdom. *Atmospheric environment*, 178, pp 148-157. <https://doi.org/10.1016/j.atmosenv.2018.01.030>
- Song, S., Wu, Y., Xu, J., Ohara, T., Hasegawa, S., Li, J., Yang, L. & Hao, J. (2013). Black carbon at a roadside site in Beijing: Temporal variations and relationships with carbon monoxide and particle number size distribution. *Atmospheric Environment*, 77, pp 213-221. <https://doi.org/10.1016/j.atmosenv.2013.04.055>
- Spearman, C. (1961). The proof and measurement of association between two things.
- Stekhoven, D. J., & Bühlmann, P. (2012). MissForest—non-parametric missing value imputation for mixed-type data. *Bioinformatics*, 28(1), pp 112-118. <https://doi.org/10.1093/bioinformatics/btr597>
- Swader, A. (2022). Black Carbon and Meteorological Parameters at Two Locations in Northern Mississippi. *Mississippi" (2022). Honors Theses*. 2718. https://egrove.olemiss.edu/hon_thesis/2718
- Taheri, A., Aliasghari, P., & Hosseini, V. (2019). Black carbon and PM2.5 monitoring campaign on the roadside and residential urban background sites in the city of Tehran. *Atmospheric environment*, 218, p 116928. <https://doi.org/10.1016/j.atmosenv.2019.116928>
- Vaishya, A., Singh, P., Rastogi, S., & Babu, S. S. (2017). Aerosol black carbon quantification in the central Indo-Gangetic Plain: Seasonal heterogeneity and source apportionment. *Atmospheric Research*, 185, pp 13-21. <https://doi.org/10.1016/j.atmosres.2016.10.001>
- Wahab, B. I., Hassan, B. J., Al-Timimi, Y. K., & Al-Ataby, I. K. (2023, August). Relationship Between the Concentrations of Black Carbon and some Meteorological Parameters Over Iraq using GIS Techniques. In *IOP Conference Series: Earth and Environmental Science* (Vol. 1223, No. 1, p. 012015). IOP Publishing. <https://doi.org/10.1088/17551315/1223/1/012015>
- Wang, X., Smith, K., & Hyndman, R. (2006). Characteristic-based clustering for time series data. *Data mining and knowledge Discovery*, 13, pp 335-364. <https://doi.org/10.1007/s10618-005-0039-x>
- Wang, Z., Zhong, S., Peng, Z. R., & Cai, M. (2018). Fine-scale variations in PM2.5 and black carbon concentrations and corresponding influential factors at an urban road intersection. *Building and Environment*, 141, pp 215-225. <https://doi.org/10.1016/j.buildenv.2018.04.042>
- Wei, T. & Simko, V.R. (2021). Package "Corrplot": Visualization of a Correlation Matrix (Version 0.92). Package Corrplot for R Software.
- Winiger, P., Andersson, A., Eckhardt, S., Stohl, A., Semiletov, I.P., Dudarev, O.V., Charkin, A., Shakhova, N., Klimont, Z., Heyes, C. & Gustafsson, Ö. (2017). Siberian Arctic black carbon sources are constrained by model and observation. *Proceedings of the National Academy of Sciences*, 114(7), pp E1054-E1061. <https://doi.org/10.1073/pnas.1613401114>
- Yeganeh, B., Khuzestani, R. B., Taheri, A., & Schauer, J. J. (2021). Temporal trends in the spatial-scale contributions to black carbon in a Middle Eastern megacity. *Science of the Total Environment*, 792, p 148364. <https://doi.org/10.1016/j.scitotenv.2021.148364>
- Yu, N., Zhu, Y., Xie, X., Yan, C., Zhu, T. and Zheng, M. (2015). Characterization of Ultrafine Particles and Other Traffic-Related Pollutants Near Roadways in Beijing. *Aerosol Air Qual. Res.* 15, pp 1261-1269. <https://doi.org/10.4209/aaqr.2014.11.0295>
- Zambrano-Bigiarini, M. (2024). Goodness-of-fit functions for comparison of simulated and observed hydrological time series, R package version 0.5-4.
- Zhang, Y., Li, Y., Guo, J., Wang, Y., Chen, D., & Chen, H. (2019). The climatology and trend of black carbon in China from 12-year ground observations. *Climate Dynamics*, 53, pp 5881-5892. <https://doi.org/10.1007/s00382-019-04903-0>

Zhao, P., Dong, F., Yang, Y., He, D., Zhao, X., Zhang, W., Yao, Q. & Liu, H. (2013). Characteristics of carbonaceous aerosol in the region of Beijing, Tianjin, and Hebei, China. Atmospheric Environment, 71, pp 389-398. <https://doi.org/10.1016/j.atmosenv.2013.02.010>.

