

Predicting and Comparing PM₁₀ Concentrations in Mashhad Using the LSTM Model Under Traffic Restrictions During the COVID-19 Era

Narges Atarodi

Master's Graduate of
Department of Environmental
Science, Kheradgarayn
Motahar Institute of Higher
Education, Mashhad, Iran.

Mitra Mohammadi

Assistant Professor in
Environmental Biotechnology
of Department of
Environmental Science,
Kheradgarayn Motahar Institute
of Higher Education, Mashhad,
Iran. (**Corresponding Author**)
m.mohammadi@motahar.ac.ir

Zahra Hajalioghli

PhD Graduate in Biosystem
Mechanics, Faculty of
Agriculture, University of
Tehran, Tehran, Iran.

Abstract

Background and Purpose: This study investigates and predicts the concentration of PM₁₀ pollutant in Mashhad using simple statistical techniques and also the LSTM model with a focus on traffic restrictions before and during the COVID-19 pandemic.

Materials and Methods: First, data related to the concentration of PM₁₀ pollutant were collected from air pollution monitoring stations in Mashhad. Then, using a paired t-test, the statistical changes in PM₁₀ concentration before and during the quarantine period were investigated. Also, the LSTM machine learning model was used to predict the effect of quarantine on PM₁₀ levels during this period, which included data processing, model training, and evaluation of prediction accuracy using various criteria.

Results: The results of the paired t-test showed a 16% decrease in the average concentration of PM₁₀ during the quarantine period, which is specified by a mean difference of 4.397 µg/m³. Although this decrease was not statistically significant, the relative improvement in air quality during this time period is remarkable. Also, in the study of the 210-day period before and after COVID-19, the results showed the significant impact of quarantine measures on air quality, and these changes did not occur randomly. In the next step, the LSTM machine learning model was used to predict the effect of quarantine on PM₁₀ levels. The value of the coefficient of determination (0.8) indicates a strong correlation between the predictions and the actual concentration of PM₁₀.

Conclusion: The values of mean square error (3.01) and mean absolute error (2.56) also indicate the high accuracy of the LSTM model predictions and their proximity to the actual values. These results demonstrate that the LSTM model has been able to predict the concentration of PM₁₀ pollutant with high accuracy and confirms its high efficiency in analyzing time series data.

Keywords: Air Pollution, Air Quality Prediction, PM₁₀ Concentrations, Paired T-Test, Deep Learning, LSTM Network

Open Access Policy: This is an open access article under the terms of the Creative Commons Attribution License, which permits use, distribution and reproduction in any medium, provided the original work is properly cited. To view a copy of this licence, visit <https://creativecommons.org/licenses/by/4.0/>

Received: 2025/03/30

Accepted: 2025/05/21

Doi:10.22038/jreh.2025.26632

► **Citation:** Atarodi N, Mohammadi M, Hajalioghli Z. Predicting and Comparing PM₁₀ Concentrations in Mashhad Using the LSTM Model Under Traffic Restrictions During the COVID-19 Era. *Iranian Journal of Research in Environmental Health*. Summer 2025; 11(2):55-68.

پیش‌بینی و مقایسه‌ی غلظت ذرات معلق PM_{10} شهر مشهد با استفاده از مدل LSTM در شرایط محدودیت‌های ترافیکی دوران COVID-19

نرگس عطاردی

دانش‌آموخته کارشناسی‌ارشد رشته علوم و مهندسی محیط زیست، دانشکده منابع طبیعی و محیط زیست، موسسه خردگرایان مطهر، مشهد، ایران.

میترا محمدی

*استادیار، گروه آموزشی علوم و مهندسی محیط زیست، دانشکده منابع طبیعی و محیط زیست، موسسه خردگرایان مطهر، مشهد، ایران. (نویسنده مسئول)
m.mohammadi@motahar.ac.ir

زهره حاج‌علی‌اوغلی

دانش‌آموخته دکترای رشته مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه تهران، تهران، ایران.

چکیده

زمینه و هدف: افزایش جمعیت و فعالیت‌های صنعتی در شهر مشهد، کاهش کیفیت هوا و عواقب جدی برای سلامت عمومی به همراه داشته است. همچنین، ظهور بیماری کووید-۱۹ و ارتباط آن با آلودگی هوا، ضرورت بررسی تأثیرات قرنطینه و محدودیت‌های ترافیکی بر غلظت آلاینده‌ها را در این کلان‌شهر افزایش داده است.

مواد و روش‌ها: در این مطالعه داده‌های مربوط به غلظت آلاینده PM_{10} از ایستگاه‌های سنجش آلودگی مشهد جمع‌آوری شد. سپس با استفاده از آزمون زوجی (Paired T-Test)، تغییرات آماری غلظت PM_{10} در دوران قبل و حین قرنطینه بررسی گردید. همچنین مدل یادگیری ماشین LSTM برای پیش‌بینی تأثیر قرنطینه بر سطوح PM_{10} به‌کار گرفته شد که شامل پردازش داده‌ها، آموزش مدل و ارزیابی دقت پیش‌بینی‌ها بود.

یافته‌ها: نتایج آزمون t زوجی نشان‌دهنده‌ی کاهش ۱۶٪ در میانگین غلظت PM_{10} در دوره‌ی قرنطینه بود، که با تفاوت میانگین ۴/۳۹۷ میکروگرم بر مترمکعب مشخص می‌شود. در مرحله‌ی بعدی، مدل یادگیری ماشین LSTM برای پیش‌بینی تأثیر قرنطینه بر سطوح PM_{10} استفاده شد. مقدار ضریب تعیین (R^2) نشان‌دهنده‌ی همبستگی قوی بین پیش‌بینی‌ها و غلظت واقعی PM_{10} است. مقادیر میانگین مربعات خطا ($3/01$) و میانگین خطای مطلق ($2/56$) بیانگر دقت بالای پیش‌بینی مدل LSTM و نزدیکی آن به مقادیر واقعی هستند.

نتیجه‌گیری: نتایج نشان می‌دهد که مدل LSTM توانسته است با دقت بالایی غلظت آلاینده PM_{10} را پیش‌بینی کند و کارایی بالای آن را در تحلیل داده‌های زمانی تأیید می‌کند. نتایج نه‌تنها کاهش قابل توجه در غلظت PM_{10} را نشان می‌دهد، بلکه ضرورت استفاده از مدل‌های پیشرفته برای تحلیل دقیق‌تر داده‌های محیطی را نیز تأکید می‌نماید.

کلیدواژه‌ها: آلودگی هوا، پیش‌بینی کیفیت هوا، آلاینده‌ی PM_{10} ، آزمون t زوجی، یادگیری عمیق، شبکه LSTM

◀ **استناد:** عطاردی ن، محمدی م، حاج‌علی‌اوغلی ز. پیش‌بینی و مقایسه‌ی

غلظت ذرات معلق PM_{10} شهر مشهد با استفاده از مدل LSTM در شرایط محدودیت‌های ترافیکی دوران COVID-19. فصلنامه‌ی پژوهش در بهداشت محیط. تابستان ۱۴۰۴؛ ۱۱(۲): ۵۵-۶۸.

تاریخ دریافت: ۱۴۰۴/۰۱/۱۰

تاریخ پذیرش: ۱۴۰۴/۰۵/۳۰

نوع مقاله: پژوهشی

آمار جهانی افزایش چهار برابری جمعیت جهان در طول قرن گذشته را نشان می‌دهد (۱). افزایش آلودگی هوا منجر به خسارات اقتصادی، کاهش دید و تصادفات جاده‌ای، تغییرات آب‌وهوایی و میلیون‌ها مرگ زودرس سالانه می‌شود (۲). عامل اصلی آلودگی هوا ذرات معلق هوا است. ذرات معلق شامل ذرات $PM_{2.5}$ و PM_{10} به‌عنوان آلاینده‌های معیار در نظر گرفته شده و توسط ایستگاه‌های سنجش آلودگی ثبت و اندازه‌گیری می‌شوند (گزارش کیفیت هوای تهران، ۱۳۹۶). یکی از کلان‌شهرهای آلوده ایران، شهر مشهد است که بخشی از آلودگی هوای آن به دلیل کاهش نزولات جوی و بخشی استفاده از سوخت‌های فسیلی مانند گازوئیل، بنزین و نفت است. بر طبق داده‌ها، مرگ‌ومیر ناشی از بیماری‌های تنفسی و قلبی-عروقی در سال‌های ۱۳۹۰-۱۳۸۷، ۴۵/۴۱٪ کل میزان مرگ‌ومیرها را به‌خود اختصاص داده است.

در دسامبر ۲۰۱۹، بیماری کووید-۱۹ از ووهان، چین گزارش شد و به‌سرعت در سایر نقاط جهان گسترش یافت (۳). برای محدود کردن شیوع این بیماری، قرنطینه در سراسر جهان اعلام شد و کووید-۱۹ به‌طور رسمی توسط سازمان بهداشت جهانی WHO به‌عنوان یک بیماری همه‌گیر اعلام شد. در آوریل ۲۰۲۲، سازمان جهانی بهداشت بیش از ۵۰۰ میلیون قربانی ناشی از کووید-۱۹ را تأیید کرد که بیش از ۶/۲ میلیون مرگ‌ومیر داشتند. اولین تأیید حضور ویروس کووید-۱۹ در ایران، با گزارش مثبت نتایج آزمایش اولیه ۲ مورد مشکوک ابتلا به این ویروس در قم در تاریخ ۲۹ بهمن ۱۳۹۸ اعلام شد و این موضوع مقدمه‌ای برای اندیشیدن تدابیری در سطح ملی و استانی شد. در سال ۲۰۲۰، در طول همه‌گیری کووید-۱۹، این فرضیه مطرح شد که قرارگرفتن در معرض ذرات معلق در هوا ($PM_{2.5}$ و PM_{10}) و آلاینده‌های گازی مانند ازن^۱ و دی‌اکسیدنیترژن^۲ خطر عوارض جدی سلامتی مانند تصلب شرایین، دیابت و سایر بیماری‌های همراه را افزایش می‌دهد که با مرگ‌ومیر بالاتر در بیماران مبتلا به کووید-۱۹ مرتبط است. این دانش بسیاری از محققان را بر آن داشته است تا فرضیه ارتباط بین آلودگی

هوا و بدتر شدن علائم و پیش‌آگهی کووید-۱۹ را مطرح کنند (۴).

در مرحله‌ی اول همه‌گیری، چندین کشور، اقدامات محدودکننده سختی مانند اجرای قرنطینه ملی را اجرا کردند. تأثیر چنین مداخلات استثنایی در مهار اپیدمی کووید-۱۹ هنوز باید به‌طور کامل ارزیابی شود. با این حال، یک بررسی سریع حاکی از تأثیر مثبت اقدامات مهار بر گسترش ویروس کووید-۱۹ بوده است. محدودیت تحرک فردی و تعطیلی مشاغل غیرضروری باعث شد که جریان ترافیک به‌طور چشمگیری کاهش یابد. بنابراین اقدامات قرنطینه را می‌توان به‌عنوان یک آزمایش ناخواسته اما مؤثر برای ارزیابی تأثیر سیاست‌های محدودیت ترافیک بر آلودگی هوا دید (۱).

از این‌رو، توسعه مدل‌های پیش‌بینی قوی، که حتی در دوران قرنطینه و در طول همه‌گیری کووید-۱۹ قابل اجرا هستند، اهمیت دارد و مدل‌سازی و پیش‌بینی کیفیت هوا در کوتاه‌مدت و بلندمدت مهم است. روش‌های یادگیری ماشین برای پیش‌بینی توالی‌های زمانی ترویج داده شده‌اند و کاربرد آن‌ها برای پیش‌بینی کیفیت هوا اخیراً مورد توجه قرار گرفته است (۵،۶). مدل‌های پیش‌بینی را می‌توان برای توسعه استراتژی‌های ارزیابی شاخص کیفیت هوا در آینده مورد استفاده قرار داد. به‌طور کلی مدل‌های پیش‌بینی غلظت آلودگی هوا به دو دسته رویکردهای مبتنی بر شبیه‌سازی و داده‌محور به روش‌های آماری یا یادگیری ماشینی طبقه‌بندی می‌شوند. روش مبتنی بر شبیه‌سازی، مدل‌های فیزیکی و شیمیایی را برای تولید پارامترهای هواشناسی و پس‌زمینه برای شبیه‌سازی انتشار، انتقال و تبدیل شیمیایی آلودگی هوا ترکیب می‌کند (۷). با این حال، آن‌ها از عدم قطعیت‌های مدل عددی رنج می‌برند و به‌دلیل کمبود داده، پارامترسازی انتشار گازهای گلخانه‌ای محدود شده است. رویکردهای داده‌محور از تکنیک‌های آماری و یادگیری ماشینی برای تشخیص الگوهای بین پیش‌بینی‌کننده‌ها و متغیرهای وابسته در توالی‌های زمانی بهره می‌برند (۸). روش‌های یادگیری ماشینی را می‌توان برای شناسایی مواجهه‌های مرتبط با پیامدهای سلامتی در داده‌های با ابعاد بالا مورد استفاده قرار داد (۹). پیشرفت‌ها در روش‌های یادگیری عمیق انگیزه‌های بیشتری را برای کاربردهای حوزه

^۱ O₃
^۲ NO₂

روش کار

خصوصیات منطقه مورد مطالعه

مشهد به عنوان دومین شهر بزرگ ایران بیش از ۳/۵ میلیون نفر جمعیت دارد و سالانه میزبان بیش از ۳۰ میلیون گردشگر است. مشهد دارای آب و هوای گرم و خشک است و طول جغرافیایی آن از ۵۹ درجه و ۳۵ دقیقه تا ۵۹ درجه و ۱۴ دقیقه و عرض جغرافیایی آن از ۳۶ درجه و ۱۴ دقیقه تا ۳۶ درجه و ۴۸ دقیقه شمالی است. مشهد به دلیل وجود واحدهای صنعتی متعدد و ترافیک شهری قابل توجه در بیشتر محله‌های یکی از آلوده‌ترین شهرهای ایران است. کیفیت هوای مشهد بسیار دور از استاندارد است و خطرات قابل توجهی برای ساکنان آن به همراه دارد (۱۲).

جمع‌آوری و توصیف داده‌ها


این مطالعه به بررسی تغییرات غلظت PM_{10} در زمان‌های مختلف پرداخته است که شامل دوره‌های قبل، حین و پس از قرنطینه‌های ناشی از کووید-۱۹ می‌شود. مجموعه داده‌ای که در این تحقیق مورد استفاده قرار گرفته، شامل غلظت PM_{10} به صورت روزانه است که از تاریخ اول فروردین ۱۳۹۸ تا پایان اسفند ۱۳۹۹ از ایستگاه‌های سرافرازان، خاقانی، چمن، مفتاح، سمزقند، آوینی، خیام شمالی، کریمی، امامیه، الهیه در مشهد اندازه‌گیری شده است (جدول ۱). این داده‌ها برای پیاده‌سازی در مدل LSTM پیش‌پردازش شده‌اند. موقعیت ایستگاه‌های سنجش آلودگی هوا در شهر مشهد در شکل ۱ نمایش داده شده است.

پیش‌بینی کیفیت هوا ایجاد می‌کند. شبکه‌های عصبی مکرر (RNN) مدل‌های یادگیری عمیق برجسته هستند که برای مدل‌سازی توالی‌های زمانی مناسب هستند، به‌ویژه آن‌هایی که شامل وابستگی‌های بلندمدت هستند (۱۰).

شبکه Long Short Term Memory (LSTM) نوع ویژه‌ای از شبکه‌های عصبی بازگشتی است که قدرت آموزش وابستگی بلندمدت دارد. در واقع هدف از طراحی شبکه LSTM، راهکارهایی برای برطرف کردن مشکلات وابستگی بلندمدت است. با توجه به این‌که LSTM‌ها پتانسیل استفاده برای پیش‌بینی سری‌های زمانی آلودگی هوا را دارند (۱۱)، در این مطالعه از مدل LSTM برای پیش‌بینی کیفیت هوا در طول دوره‌ی کووید-۱۹ استفاده شد. لذا هدف این پژوهش، پیش‌بینی و مقایسه غلظت ذرات معلق PM_{10} در شهر مشهد طی دوران قرنطینه ناشی از کووید-۱۹ با استفاده از مدل یادگیری عمیق LSTM است. در این مطالعه، علاوه بر به‌کارگیری مدل LSTM به منظور پیش‌بینی روند تغییرات، داده‌های مربوط به سال‌های قبل و حین قرنطینه مقایسه گردید تا اثر محدودیت‌های ترافیکی بر سطوح PM_{10} به‌طور دقیق‌تر ارزیابی شود. نوآوری مطالعه‌ی حاضر، بررسی اثر قرنطینه بر کیفیت هوا و ارائه یک روش بهبود یافته برای ارزیابی تأثیر مداخلات در کلان شهر مشهد و ارائه‌ی ابزاری علمی برای سیاست‌گذاری‌های مدیریت آلودگی هوا است.

جدول ۱. نام و موقعیت ایستگاه‌های سنجش آلودگی هوا در شهر مشهد

ردیف	نام ایستگاه	عرض جغرافیایی	طول جغرافیایی	نوع ایستگاه
۱	سمزقند	۴۰.۲۲۶۸۵	۷۲.۴۹۱۲	شهری
۲	خیام شمالی	۴۰.۲۴۵۶۱	۷۳.۲۰۲۹	ترافیکی
۳	چمن	۴۰.۱۴۷۵۱	۷۲.۷۵۲۶	ترافیکی
۴	الهیه	۴۰.۲۸۷۰۷	۷۲.۱۹۹۱	حومه شهری
۵	کریمی	۴۰.۲۲۰۲۲	۷۳.۲۹۶۰	ترافیکی
۶	مفتح	۴۰.۲۰۵۱۲	۷۳.۷۳۶۸	شهری
۷	آوینی	۴۰.۲۰۲۲۸	۷۳.۹۱۴۹	ترافیکی
۸	خاقانی	۴۰.۱۹۳۷۱	۷۲.۷۸۹۸	شهری
۹	سرافرازان	۴۰.۲۰۰۸۵	۷۲.۴۹۴۰	شهری
۱۰	امامیه	۴۰.۲۱۹۵۶	۷۲.۶۱۳۵	ترافیکی



شکل ۱. ایستگاه‌های سنجش آلودگی هوا در شهر مشهد

سپس مجموعه داده‌ها برای آموزش مدل LSTM به‌طور جداگانه تقسیم‌بندی شد، به‌طوری‌که ۹۰٪ از داده‌ها به‌عنوان مجموعه آموزشی و ۱۰٪ باقی‌مانده به‌عنوان مجموعه آزمایشی در نظر گرفته شده است. این تقسیم‌بندی به پژوهشگران این امکان را می‌دهد که مدل‌های خود را به‌طور مؤثری آموزش دهند و عملکرد آن‌ها را ارزیابی کنند.

تحلیل و آنالیز آماری آمار توصیفی

در مرحله نخست تحلیل داده‌ها، آمار توصیفی اطلاعات اولیه‌ای درباره غلظت‌های PM_{10} ارائه می‌دهد. این آمار شامل میانگین، میانه، انحراف معیار و سایر شاخص‌های مرکزی و پراکندگی است که به پژوهشگران کمک می‌کند تا تحلیل‌های دقیق‌تری انجام دهند. با بهره‌گیری از آمار توصیفی غلظت‌های PM_{10} روزانه، امکان شناسایی

داده‌های مربوط به غلظت PM_{10} در دو دوره زمانی متفاوت جمع‌آوری شده است. این داده‌ها شامل ۱۳ روز قبل از اعمال قرنطینه در فروردین ماه ۱۳۹۸ و ۱۳ روز متناظر در طول قرنطینه در فروردین ماه ۱۳۹۹ می‌باشد. هدف از این جمع‌آوری داده‌ها، بررسی تأثیر قرنطینه بر غلظت PM_{10} است.

علاوه بر این، مقایسه غلظت روزانه PM_{10} در ایستگاه‌های سنجش کیفیت هوا مختلف مشهد از اول شهریور تا پایان اسفند ۱۳۹۸ با دوره مشابه در سال ۱۳۹۹ نیز انجام شده است تا تغییرات غلظت PM_{10} قبل و بعد از قرنطینه مورد بررسی قرار گیرد. اطلاعات مورد استفاده از ده ایستگاه اندازه‌گیری کیفیت هوا که در نقاط مختلف مشهد واقع شده‌اند، جمع‌آوری شده است. داده‌های دریافتی از این ایستگاه‌ها توسط مرکز پایش آلودگی محیط زیست مشهد برای سال‌های ۱۳۹۸ و ۱۳۹۹ ثبت گردیده است.

به ترتیب حداقل و حداکثر مقادیر در مجموعه داده هستند و X_{Sc} نشان دهنده داده مقیاس شده برای هر نقطه مربوطه است.

$$X_{Sc} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad \text{معادله ۲: مقیاس گذاری داده}$$

داده های نرمال سازی شده پس از پیش پردازش به مدل وارد شدند و با استفاده از تکنیک های یادگیری عمیق، مدل به شناسایی الگوها و روابط موجود در داده ها پرداخت. برای این منظور، از مجموعه ای از داده های آموزشی و اعتبارسنجی استفاده شد تا عملکرد مدل در پیش بینی غلظت آلاینده PM_{10} ارزیابی گردد.

مؤلفه کلیدی LSTM، وضعیت سلول (C_t) است که اطلاعات را در طول مراحل زمانی مختلف در داده های توالی بدون تغییر حمل می کند. سه دروازه، که با دروازه فراموشی آغاز می شود، کنترل می کند که آیا عناصر خاصی از بردار وضعیت سلول قبلی (C_{t-1}) باید حفظ یا فراموش شوند. این فرآیند در معادله ۳ نشان داده شده است:

$$F_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad \text{معادله ۳}$$

تابع سیگموئید ($\sigma(\cdot)$) که خروجی آن بین ۰ و ۱ قرار دارد، مشخص می کند که کدام اجزای وضعیت سلول C_t باید حفظ شوند. پس از آن، دروازه ورودی تصمیم می گیرد که چه اطلاعات جدیدی از زمان $t-1$ به وضعیت سلول اضافه شود. این مرحله نیز در معادله ۴ با استفاده از تابع سیگموئید تعریف می شود:

$$I_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad \text{معادله ۴}$$

سپس، یک بردار وضعیت سلول بالقوه با استفاده از ورودی کنونی (x_t) و آخرین وضعیت پنهان (h_{t-1}) محاسبه می شود. در اینجا، $\tilde{C}$ نمایانگر وضعیت سلول کاندید در زمان t است و تابع تانژانت هایپربولیک (TanH) در شبکه های عصبی برای فشرده سازی مقادیر ورودی به دامنه ای بین -۱ و ۱ به کار می رود. این کار به شناسایی روابط غیرخطی کمک می کند. وضعیت سلول کاندید بر اساس معادله ۵ به دست می آید.

$$\tilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad \text{معادله ۵}$$

تغییرات در طول زمان فراهم می شود و پژوهشگران می توانند روندهای موجود را مورد بررسی قرار دهند. این اطلاعات به درک بهتر تأثیرات قرنطینه بر کیفیت هوا کمک خواهد کرد.

آمار استنباطی به کمک آزمون t با نمونه های

زوجی

پس از اطمینان از نرمال بودن داده ها با استفاده از آزمون کلموگروف-اسمیرنوف (نتایج نشان داده نشده است)، آزمون t با نمونه های زوجی به کار گرفته شد که احتمالاً رایج ترین آزمون در آمار برای مقایسه میانگین مقادیر بین دو نمونه است (۱۳). این آزمون به صورت معادله ۱ تعریف می شود.

معادله ۱: آزمون t برای مقایسه میانگین بین دو نمونه

$$T_2 = \frac{X_d}{\sqrt{\frac{1}{n(n-1)} \sum_{j=1}^n (X_j - \bar{X}_d)^2}}$$

واضح است که آزمون t زوجی در واقع یک آزمون t با یک نمونه است که بر اساس تفاوت در هر جفت انجام می شود. تحت فرض صفر، T_2 همیشه توزیع t با درجه آزادی df = $n - 1$ را دنبال می کند (۱۴). این آزمون در این مطالعه برای مقایسه دقیق مقادیر PM_{10} روزانه در چندین محل سنجش کیفیت هوا در مشهد استفاده شد. این مقایسه در دو مرحله انجام گردید. ابتدا مقایسه سطح PM_{10} قبل از دوره قرنطینه (۱۴ روز ابتدای فروردین ۱۳۹۸) با دوره مشابه آن در زمان قرنطینه (۱۴ روز ابتدای فروردین ۱۳۹۹) و سپس مقایسه نتایج از اول شهریور تا آخر اسفند ۱۳۹۸ (پیش از قرنطینه) با دوره مشابه آن در سال ۱۳۹۹ (پس از قرنطینه) صورت گرفت. سطح معناداری برای این مطالعه در ۵٪ تعیین شد تا بررسی دقیقی از تغییرات مشاهده شده انجام گیرد.

مدل LSTM

اجرای مدل LSTM

پیش پردازش داده ها با حذف داده های پرت (اعداد بزرگتر از ۱۰۰ و مقادیر خالی)، و نرمال سازی داده ها با استفاده از تابع MinMaxScaler در بازه ی [۰، ۱] صورت گرفت. معادله ۲ روند مقیاس گذاری هر داده را از طریق استفاده از مقیاس گذار MinMax نشان می دهد. در این معادله، X نمایانگر هر نقطه داده خام، X_{min} و X_{max}

$$R^2 = 1 - \frac{SS_{residual}}{SS_{total}}$$

$$SS_{residual} = \sum_i (y_i - f_i)^2, SS_{total} = \sum_i (y_i - \bar{y})^2$$

معادله ۹

$$MAE = \frac{1}{n} \left(\sum_i |y_i - f_i| \right)$$

معادله ۱۰

$$RMSE = \sqrt{\frac{1}{n} \left(\sum_i (y_i - f_i)^2 \right)}$$

معادله ۱۱

R^2 یا ضریب تعیین، نشان‌دهنده نسبت واریانس در داده‌های مشاهده‌شده (y) است که می‌تواند توسط داده‌های (f) توضیح داده شود. در اینجا، y به داده‌های واقعی، f به داده‌های پیش‌بینی‌شده بر اساس مدل‌ها، n به تعداد نقاط داده برای اعتبارسنجی و $\bar{y}$ به میانگین کلی داده‌های مشاهده‌شده اشاره دارد. R^2 یک معیار آماری مهم در تجزیه و تحلیل رگرسیون است که برای ارزیابی کیفیت برازش یک مدل استفاده می‌شود. این معیار نشان می‌دهد که پیش‌بینی‌های مدل چقدر با نتایج واقعی هم‌خوانی دارند.

MAE یا میانگین اختلاف مطلق، اختلاف بین مقادیر پیش‌بینی‌شده و مشاهده‌شده را چه در جهت مثبت و چه منفی محاسبه می‌کند. RMSE یا ریشه میانگین مربعات خطا، تفاوت بین مقدار پیش‌بینی‌شده و مقدار واقعی را کمی‌سازی می‌کند.

یافته‌ها

آمار توصیفی

در این تحقیق، تغییرات در غلظت‌های PM_{10} در بازه‌های زمانی مختلف، شامل دوره‌های قبل، در طول و پس از قرنطینه‌های کووید-۱۹، مورد بررسی قرار گرفته است. این مطالعه به منظور تحلیل تأثیرات ناشی از اقدامات قرنطینه بر کیفیت هوا و به‌ویژه غلظت آلاینده‌های PM_{10} انجام شده است. جدول ۲ آمار توصیفی مربوط به غلظت PM_{10} در سایت‌های مختلف سنجش کیفیت هوا را در شهر مشهد برای دو دوره ۱۳ روزه قبل و در حین قرنطینه نشان می‌دهد.

در مرحله بعد، وضعیت سلول قبلی C_{t-1} با استفاده از ضرب عنصر به عنصر به وضعیت سلول جدید (C_t) برزورسانی می‌شود که این عملیات در معادله ۶ بیان شده است:

$$C_t = F_t * C_{t-1} + I_t * \tilde{C}_t$$

معادله ۶

مرحله نهایی شامل دروازه خروجی است که خروجی شبکه را با استفاده از تابع سیگموید (σ) تعیین می‌کند. این گام در معادله ۷ نشان داده شده است:

$$O_t = \sigma(W_o * [h_{t-1}, x_t] + b_o)$$

معادله ۷

O_t یک بردار با مقادیر بین ۰ و ۱ است. پس از آن، داده‌های حاصل از معادلات (۶) و (۷) ترکیب می‌شوند تا وضعیت پنهان جدید (h_t) بر اساس معادله (۸)، محاسبه شود.

$$h_t = O_t * \tanh(C_t)$$

معادله ۸

این معادلات شامل پارامترهای قابل آموزش هستند که با ماتریس‌های وزنی W_o, W_c, W_i, W_f و هم‌چنین عبارات بایاس b_o, b_c, b_i, b_f نمایش داده می‌شوند. برای اینکه LSTM بتواند به صورت انتخابی داده‌ها را در طول توالی داده‌ها پردازش و حفظ کند، این پارامترها رفتار دروازه‌های داخلی را کنترل می‌کنند (۱۵).

سپس هاپرپارامترهای مدل LSTM به دقت تنظیم شدند تا توانایی مدل در شناسایی الگوها در مجموعه داده افزایش یابد. برای کاهش احتمال بیش‌برازش، تکنیک تنظیم $L2^3$ مدنظر قرار گرفت.

ارزیابی مدل LSTM

در فرایند ارزیابی معیارهایی هم‌چون میانگین خطای مطلق (MAE)، ریشه میانگین مربع خطا (RMSE) و ضریب تعیین (R^2) به کار گرفته شد تا توانایی مدل در پیش‌بینی غلظت آلاینده PM_{10} به طور دقیق ارزیابی شود (معادلات ۹ تا ۱۱). این معیارها اندازه‌گیری کمی از نحوه-ی هم‌راستایی مقادیر پیش‌بینی‌شده با مقادیر واقعی مشاهده شده ارائه می‌دهند. هر معیار بینش‌های متفاوتی درباره عملکرد مدل ارائه می‌کند.

³ L2 regularization

جدول ۲. آمار توصیفی مربوط به غلظت PM_{10} در سایت‌های مختلف سنجش کیفیت هوا را در شهر مشهد برای دو دوره ۱۳ روزه قبل و در حین قرنطینه

انحراف معیار	میانگین	بیشترین مقدار	کمترین مقدار	دوره زمانی
۱۲,۰۵۳۵۹۵	۲۶,۹۴۶۱۵۳	۵۰,۲۸	۱۱,۶۰	۱ تا ۱۳ فروردین ۱۳۹۸
۱۰,۹۲۰۶۴۶	۲۲,۵۴۸۵۳ ۴	۴۵,۹۴	۵,۷۶	۱ تا ۱۳ فروردین ۱۳۹۹

آزمون t نمونه‌های جفت شده جهت ارزیابی

داده‌های PM_{10} قبل و بعد از دوره کووید-۱۹

برای ارزیابی تأثیرات قرنطینه بر غلظت‌های PM_{10} ، آزمون t نمونه جفت شده به کار گرفته شده است (جدول ۳). داده‌های مربوط به غلظت PM_{10} در ۱۳ روز قبل از قرنطینه (فروردین ماه ۱۳۹۸) و دوره متناظر آن یعنی ۱۳ روز در طول قرنطینه (فروردین ماه ۱۳۹۹) جمع‌آوری شده است. از بررسی جداول ۲ و ۳ مشاهده می‌شود که میانگین غلظت PM_{10} در دوره ۱۳ روزه قبل از قرنطینه برابر با ۲۶/۹۴۶ میکروگرم بر متر مکعب و در ۱۳ روز در طول قرنطینه برابر با ۲۲/۵۴۸ میکروگرم بر متر مکعب به‌دست آمده است. این کاهش قابل توجه در میانگین

غلظت PM_{10} نشان‌دهنده بهبود نسبی کیفیت هوا در دوره قرنطینه است. تفاوت میانگین غلظت PM_{10} در این دو دوره برابر با ۴/۳۹۷ میکروگرم بر متر مکعب است. این مقدار نشان می‌دهد که میانگین غلظت PM_{10} به میزان ۱۶٪ در طول قرنطینه کاهش یافته است (جدول ۲ و ۳). اگرچه این کاهش با توجه به سطح معنی‌داری ۰/۴ به‌دست آمده از نظر آماری معنادار نیست، اما نشان‌دهنده بهبود نسبی کیفیت هوا در این دوره است (جدول ۴). این موضوع می‌تواند به‌عنوان یک فرصت برای بررسی سیاست‌های زیست‌محیطی در آینده مورد توجه قرار گیرد. به این معنا که ممکن است عوامل دیگری نیز در این تغییرات دخیل باشند.

جدول ۳. آمار نمونه‌های زوجی غلظت روزانه PM_{10} در ایستگاه‌های مختلف پایش در مشهد در ۱۳ روز قبل از قرنطینه با دوره مشابه در طول دوره قرنطینه

Paired Samples Statistics				
	Mean	N	Std.Ddeviation	Std.Error Mean
Pair 1				
قبل از قرنطینه	۲۶/۹۴۶۱۵۳۸۵	۱۳	۱۲/۰۵۳۵۹۵۳۴	۳/۳۴۳۰۶۵۸۵۰
در طول دوره قرنطینه	۲۲/۵۴۸۵۳۴۸۰	۱۳	۱۰/۹۲۰۶۴۶۴۵	۳/۰۲۸۸۴۲۳۶۵

جدول ۴. همبستگی‌های نمونه زوجی بین پیش آزمون و پس آزمون

Paired Samples Test				Paired differences			
				95% Confidence interval of difference			
	Mean	Std.Ddeviation	Std Error Mean	Lower	Upper	t	df Sig.(2-tailed)
Pair 1							
قبل از قرنطینه - در طول دوره قرنطینه	۴/۳۹۷۶۱۹۰۵	۱۹/۱۷۵۵۸۲۵	۵/۳۱۸۳۴۹۵۹	-۱/۵۹۸۵۳۰۷	۷/۱۹۰۰۶۹۴	-۰/۸۲۷	۱۲ ۰/۴۲۴


پیش‌بینی غلظت PM_{10} با استفاده از مدل

LSTM

در این مطالعه، داده‌های جمع‌آوری‌شده پس از پیش‌پردازش برای آموزش مدل LSTM مورد استفاده قرار گرفتند. مدل LSTM با ۹۰٪ از داده‌های اولیه آموزش دیده و سپس برای پیش‌بینی داده‌های آزمون (۱۰٪ دیگر داده‌ها) به کار گرفته شد. نمره R^2 محاسبه‌شده برای مدل LSTM برابر با ۰/۸۰ بود که

نشان‌دهنده توانایی این مدل در پیش‌بینی دقیق داده‌های ناشناخته است. هم‌چنین، مقادیر RMSE و MAE به ترتیب ۳/۰۱ و ۲/۵۶ محاسبه شدند. نمودار ۲ تابع هزینه مدل LSTM را به نمایش گذاشته است. همان‌طور که در نمودار مشاهده می‌شود با افزایش تعداد دوره‌های آموزش،

مدل توانسته به خوبی الگوها را از داده‌ها یاد بگیرد و خطا به نزدیک صفر رسیده است.



نمودار ۲. نمودار تابع هزینه مدل LSTM


رویکرد دوم برای ارزیابی دقت مدل شامل اعتبارسنجی بر روی کل مجموعه داده است. در این روش، مدل LSTM بر روی مجموعه داده کامل آموزش داده شد و سپس برای پیش‌بینی تمامی داده‌های موجود استفاده گردید. نمره R^2 برای این ارزیابی نیز 0.72 محاسبه شد و مقادیر RMSE و MAE به ترتیب 6.05 و 8.76 به دست آمد. نمودار ۵ مقایسه‌ای از مقادیر پیش‌بینی شده غلظت با غلظت‌های واقعی را نشان می‌دهد و این نمایش گرافیکی بر توانایی مدل در پیش‌بینی داده‌ها تأکید دارد.

نمودار ۳ تفاوت بین پیش‌بینی غلظت PM_{10} توسط مدل LSTM را با داده‌های واقعی موجود در مجموعه آزمون، نشان می‌دهد. در این نمودار، خط آبی نمایانگر داده‌های واقعی و خط نارنجی نمایانگر داده‌های پیش‌بینی شده است. زمان بر روی محور X و غلظت آلاینده PM_{10} بر روی محور Y نشان داده شده‌اند. لازم به ذکر است که این مجموعه آزمون شامل ۱۰ درصد نهایی داده‌های سری زمانی است. مشاهده می‌شود که، مدل یادگیری عمیق LSTM توانسته این نقاط داده را با دقت بالایی پیش‌بینی کند.


نمودار ۴ نیز مقادیر پیش‌بینی غلظت PM_{10} توسط مدل LSTM و مقادیر داده‌های واقعی موجود در مجموعه آزمون را نشان می‌دهد.



نمودار ۳. سطح غلظت واقعی و غلظت پیش‌بینی شده PM_{10} توسط مدل LSTM بر روی مجموعه آزمایش




نمودار ۴. سطح غلظت واقعی و غلظت پیش بینی شده PM_{10} توسط مدل LSTM بر روی مجموعه آموزش



نمودار ۵. نتایج مدل LSTM بر روی مجموعه داده آموزش و آزمایش

۲۲/۸۹۷ میکروگرم بر مترمکعب بود، در حالی که غلظت پیش‌بینی‌شده برای این دوره با استفاده از مدل LSTM به میزان ۱۷/۰۶۵ میکروگرم بر مترمکعب تخمین زده شد (نمودار ۶).

در این مطالعه با توجه به توانایی مدل در پیش‌بینی، از آن برای پیش‌بینی غلظت PM_{10} در ۱۳ روز اول قرنطینه کووید-۱۹ نیز استفاده شد. نمودار ۵ غلظت PM_{10} پیش‌بینی‌شده با مدل LSTM را نمایش می‌دهد. میانگین غلظت PM_{10} در این ۱۳ روز برابر با



نمودار ۶. نتایج پیش‌بینی غلظت PM_{10} برای ۱۳ روز اول قرنطینه با استفاده از مدل LSTM در مقایسه با داده‌های واقعی

به مقادیر واقعی نزدیک‌تر هستند، که این امر LSTM را برای تخمین‌های دقیق‌تر مناسب‌تر می‌سازد. مقایسه نتایج به‌دست‌آمده با بخش قبلی نشان می‌دهد که غلظت‌های اندازه‌گیری‌شده در سال ۱۳۹۹ نسبت به غلظت‌های پیش‌بینی‌شده توسط تکنیک‌های مختلف

نمره بالای R^2 (۰/۸۰) مدل LSTM نشان‌دهنده همبستگی قوی بین پیش‌بینی‌ها و غلظت واقعی PM_{10} است. همچنین، مقادیر $RMSE$ (۳/۰۱) و MAE (۲/۵۶) نشان می‌دهد که پیش‌بینی‌های این مدل به طور متوسط

تغییرات کمتری را نشان می‌دهد. مدل‌های LSTM هر نقطه داده را با مشاهدات قبلی پیش‌بینی می‌کنند و در صورتی که به درستی تنظیم شوند، می‌توانند داده‌های آلودگی هوا را با دقت قابل توجهی پیش‌بینی کنند. بنابراین، علاوه بر نتایج اعتبارسنجی، دلایل ذکر شده نشان‌دهنده قابلیت اطمینان مدل‌ها در پیش‌بینی صحیح میزان آلودگی هوا هستند. جدول ۵ نتایج اعتبارسنجی مطالعات مشابه شامل مدل‌های یادگیری ماشین برای پیش‌بینی غلظت PM_{10} را گردآوری کرده است. همان‌طور که در جدول ۵ نشان داده شده است، محدوده R^2 ، RMSE و MAE مدل‌های مختلف به $0/13-0/96$ ،

جدول ۵. مروری بر مطالعات مشابه و نتایج اعتبارسنجی مربوطه در پیش‌بینی غلظت PM_{10}

کشور	شهر	مدل	R^2	RSME	MAE	منبع
پاکستان	لاهور	Decision Tree	۰/۴۳۴	۴۲/۱۹	۳۵/۴۰	زکیب و همکاران (۲۰۲۳)
پاکستان	لاهور	Support Vector Machines (SVM)	۰/۹۶	۸۳/۳۲	۳۷/۸۲	زکیب و همکاران (۲۰۲۳)
پاکستان	لاهور	Random Forest (RF)	۰/۱۳	۵۳/۳۳	۳۸/۴۴	زکیب و همکاران (۲۰۲۳)
پاکستان	لاهور	Long short-term memory (LSTM)	۰/۷۵	۱۲/۸۴	۸/۵۸	زکیب و همکاران (۲۰۲۳)
آلمان	برلین	RF	۰/۳۵	۰/۴۱	-	شاتکه و همکاران (۲۰۲۲)
چین	ماکائو	RF	۰/۹۰	۸/۱۵	۶/۶۴	لی و همکاران (۲۰۲۲)
چین	ماکائو	Support Vector Regression (SVR)	۰/۶۸	۱۶/۱۳	۱۳/۰۱	لی و همکاران (۲۰۲۲)
کرواسی	زاگرب	RF	۰/۷۷	۱۰/۴۷	-	لوریک و همکاران (۲۰۲۲)
ایران	مشهد	LSTM	۰/۸	۳/۰۱	۲/۵۶	مطالعه حاضر

گذاشته است. علاوه بر این، کاهش فعالیت‌های تجاری نیز در این کاهش نقش داشته است.

در مطالعه‌ای به بررسی ترکیب شیمیایی و شناسایی منابع PM_{10} در پنج شهر شمال غرب اروپا پرداخته و نتایج نشان‌دهنده تنوع فصلی و فضایی قابل توجهی در غلظت این ذرات است. سطح PM_{10} در فصل زمستان افزایش می‌یابد و اجزای اصلی آن شامل آئروسول‌های غیرآلی ثانویه، مواد آلی و گردوغبار معدنی هستند. از ۱۹۴۲ نمونه جمع‌آوری‌شده، آئروسول‌های غیرآلی ثانویه به‌عنوان غالب‌ترین مؤلفه شناسایی شدند. تحلیل مؤلفه‌های اصلی نیز نشان داد که مهم‌ترین منابع آلودگی شامل آئروسول‌های ثانویه، سوختن زیست‌توده هستند (۱۶). این

منابع می‌توانند به‌طور مستقل از فعالیت‌های حمل‌ونقل، بر کیفیت هوا تأثیرگذار باشند. بنابراین، برای بهبود کیفیت

بحث

در اسفند ماه ۱۳۹۸ و فروردین ۱۳۹۹، تمامی کسب‌وکارهای غیرضروری در مشهد به‌دلیل قرنطینه تعطیل شدند. هم‌چنین، ورود مسافران به شهر ممنوع و تمام اقامتگاه‌ها و مراکز تفریحی و فرهنگی در خراسان رضوی، از جمله حرم مقدس رضوی، بسته شدند. علاوه بر این، از تاریخ ۱۲ فروردین، ورود وسایل نقلیه به استان از ساعت ۵ صبح تا ۲۴ بعد از ظهر ممنوع گردید. به همین دلیل، مدت زمان کوتاه قرنطینه در مشهد ممکن است تأثیر قابل توجهی بر وضعیت کیفیت هوا داشته باشد. یکی دیگر از دلایل کاهش غلظت PM_{10} در مشهد، کاهش قابل توجه فعالیت‌های اقتصادی و ترافیک خودروها در طول دوران قرنطینه است. کاهش استفاده از وسایل نقلیه عمومی و خصوصی، به‌ویژه کامیون‌های دیزل سنگین، به‌طور مستقیم بر کاهش آلودگی هوا تأثیر

هوا، نیاز به رویکردی جامع و چندجانبه داریم که تمامی منابع آلاینده را در نظر بگیرد. بنابراین ترکیبات پیچیده PM₁₀ و عوامل منطقه‌ای خاص، نظیر شرایط آب‌وهوایی و معیارهای قرنطینه که در محاسبات لحاظ نشده‌اند، می‌توانند بر تغییرات غلظت PM₁₀ تأثیر بگذارند.

در تحقیقی به بررسی تأثیر عوامل جوی مانند دما، رطوبت و سرعت باد بر غلظت PM₁₀ پرداخته شد. داده‌های مورد استفاده شامل غلظت PM₁₀ به مدت ۲۴ ساعت، دما، رطوبت و سرعت باد در سال ۲۰۱۸ از سه ایستگاه پایش کیفیت هوا است. نتایج نشان می‌دهد که غلظت PM₁₀ در فصل زمستان بیشتر و در فصل تابستان کمتر است. همچنین، ارتباط معکوس بین غلظت PM₁₀ و عوامل جوی مشاهده شده است، به طوری که با افزایش دما، رطوبت و سرعت باد، غلظت PM₁₀ کاهش می‌یابد. این مطالعه تأکید می‌کند که عوامل جوی نقش مهمی در آلودگی هوا دارند و تغییرات فصلی و جغرافیایی قابل توجهی در غلظت PM₁₀ وجود دارد. به علاوه، نتایج نشان می‌دهد که در فصل خشک، غلظت PM₁₀ به طور معناداری بیشتر از فصل مرطوب است (۱۷). این موضوع نشان می‌دهد که درک دقیق نقش هواشناسی در طراحی استراتژی‌های کنترل انتشار بسیار مهم است. به ویژه در شرایطی که تغییرات آب و هوایی می‌تواند به طور مستقیم بر کیفیت هوا تأثیر بگذارد.

در مطالعه‌ای که در ترکیه به بررسی تأثیر اقدامات محدودیت ناشی از کووید-۱۹ بر کیفیت هوا در ۸۱ شهر ترکیه پرداخته شده بود، داده‌های تحرک انسانی برای بررسی ارتباط با کیفیت هوای محلی مورد استفاده قرار گرفته است. نتایج نشان داد که غلظت‌های میانگین PM₁₀ و SO₂ به ترتیب ۶۷٪ و ۵۹٪ نسبت به پنج سال گذشته کاهش یافته است. همچنین تأثیر محدودیت‌ها بر آلودگی هوای محیط و ارتباط آن با تحرک انسانی بررسی شد. نتایج همبستگی نشان می‌دهد که تحرک در رستوران‌ها، کافه‌ها، وسایل نقلیه عمومی و محل‌های کار به طور معناداری با غلظت‌های PM₁₀ و SO₂ در ترکیه ارتباط دارد (۱۸). بنابراین، تغییرات غلظت PM₁₀ می‌تواند به عواملی فراتر از محدودیت‌های ناشی از کووید-۱۹ وابسته باشد و نیاز به بررسی دقیق‌تر و در نظر گرفتن جوانب مختلف برای تحلیل دقیق‌تر این تغییرات وجود دارد.

این نتایج نشان‌دهنده ارتباط مستقیم بین فعالیت‌های انسانی و کیفیت هوا هستند و اهمیت اتخاذ تدابیر مناسب برای کاهش آلودگی را نمایان می‌سازند. در نهایت، به نظر می‌رسد که اقدامات قرنطینه به طور موقت به بهبود کیفیت هوا کمک کرده‌اند، اما برای دستیابی به نتایج پایدار در این زمینه، نیاز به برنامه‌ریزی و اقدام مداوم در کنترل آلودگی هوا وجود دارد. این اقدامات باید شامل کاهش فعالیت‌های آلاینده، بهبود حمل‌ونقل عمومی و استفاده از انرژی‌های تجدیدپذیر باشد. با توجه به چالش‌های موجود، همکاری بین نهادهای دولتی، محققان و جامعه مدنی برای بهبود کیفیت هوا و حفظ سلامت عمومی ضروری است.

محدودیت‌های مطالعه: اگرچه نتایج این مطالعه نشان‌دهنده کاهش قابل توجه غلظت PM₁₀ در دوران قرنطینه کووید-۱۹ است، باید توجه داشت که شرایط محیطی و سایر عوامل مؤثر نیز می‌توانند بر تغییرات غلظت ذرات معلق نقش داشته باشند. پارامترهای هواشناسی مانند دما، رطوبت نسبی، سرعت باد و بارش از مهم‌ترین عوامل طبیعی هستند که می‌توانند بر پراکندگی یا تجمع ذرات معلق تأثیرگذار باشند. بررسی داده‌های هواشناسی دوره مطالعه نشان داد که تغییرات این عوامل در دوران قرنطینه نسبت به دوره مشابه سال قبل تفاوت چشمگیری نداشت و بنابراین کاهش مشاهده شده در PM₁₀ را می‌توان عمدتاً به محدودیت‌های ترافیکی و کاهش فعالیت‌های انسانی نسبت داد. با این وجود، نمی‌توان نقش کامل سایر منابع آلاینده یا شرایط جوی را نادیده گرفت و همین امر یکی از محدودیت‌های پژوهش حاضر محسوب می‌شود. بدین ترتیب، پیشنهاد می‌شود در مطالعات آتی با بهره‌گیری از مجموعه داده‌های گسترده‌تر و در نظر گرفتن هم‌زمان عوامل هواشناسی و منابع آلاینده متنوع، سهم هر یک از این متغیرها در تغییرات غلظت PM₁₀ به طور دقیق‌تر شناسایی و کمی‌سازی گردد.

نتیجه‌گیری

مطالعه حاضر نشان داد که قرنطینه کووید-۱۹ در مشهد تأثیر قابل توجهی بر کاهش غلظت PM₁₀ داشت. مقایسه داده‌های سال‌های ۱۳۹۸ و ۱۳۹۹ نشان داد که میانگین سطح PM₁₀ در دو رویکرد تحلیلی به ترتیب ۱۶٪ و

۳۷٪ کاهش یافته است که این اختلاف بر اهمیت انتخاب روش تحلیلی مناسب تأکید می‌کند. مدل LSTM نیز به‌طور موفق توانست روند تغییرات PM₁₀ را پیش‌بینی کرده و به‌عنوان ابزاری مؤثر در مدیریت کیفیت هوا مطرح شود. یافته‌ها نشان می‌دهد که استفاده از یادگیری ماشین می‌تواند برای تحلیل تغییرات سریع آلودگی هوا در شرایط خاص مانند قرنطینه بسیار کاربردی باشد. این نتایج علاوه بر ارائه شواهد علمی، می‌تواند به سیاست‌گذاران در طراحی اقدامات کنترلی کارآمدتر و تنظیم برنامه‌های بهداشت عمومی کمک کند. به‌طور خاص، تدوین سیاست‌هایی برای مدیریت ترافیک شهری و کاهش انتشار آلاینده‌ها می‌تواند در بهبود کیفیت هوا نقش مهمی ایفا کند. همچنین توصیه‌های بهداشتی نظیر استفاده از ماسک یا محدودیت فعالیت‌های بیرونی در دوره‌های پرخطر می‌تواند بر اساس پیش‌بینی‌های مدل اعمال شود. در کنار این دستاوردها، پژوهش بر لزوم توسعه مطالعات آتی با پوشش جغرافیایی گسترده‌تر و بررسی عوامل تأثیرگذار دیگر تأکید می‌کند. در نهایت، نتایج بیانگر اهمیت اتخاذ رویکردهای پایدار برای کاهش بلندمدت آلودگی هوا و مقابله با پیامدهای ناشی از تغییرات اقلیمی است.

تشکر و قدردانی: این مقاله حاصل پایان‌نامه کارشناسی‌ارشد با عنوان "پیش‌بینی کیفیت هوای شهر مشهد با استفاده از مدل LSTM با تمرکز بر محدودیت‌های ترافیکی دوران COVID-19" رشته

- 4) Cole, M. A., Elliott, R., & Liu, B. (2020). The Impact of the Wuhan Covid-19 Lockdown on Air Pollution and Health: A Machine Learning and Augmented Synthetic Control Approach. *Environmental & resource economics*, 1-28. Advance online publication. <https://doi.org/10.1007/s10640-020-00483-4> MID: 32703584.
- 5) Bui, T.-C., Le, V.-D., & Cha, S.-K. (2018). A Deep Learning Approach for Forecasting Air Pollution in South Korea Using LSTM. <https://arxiv.org/abs/1804.07891v3>
- 6) Li, L., Li, Q., Huang, L., Wang, Q., Zhu, A., Xu, J., Liu, Z., Li, H., Shi, L., Li, R., Azari, M., Wang, Y., Zhang, X., Liu, Z., Zhu, Y., Zhang, K., Xue, S., Ooi, M. C. G., Zhang, D., & Chan, A. (2020). Air quality changes during the

COVID-19 lockdown over the Yangtze River Delta Region: An insight into the impact of human activity pattern changes on air pollution

علوم و محیط زیست گرایش آلودگی‌های محیط زیست موسسه خردگرایان مطهر مشهد می‌باشد. بدین‌وسیله از تمامی افرادی که ما را در انجام این مطالعه یاری نموده‌اند، تشکر و قدردانی می‌شود.

تعارض منافع: نویسندگان هیچ‌گونه تعارض منافع با یکدیگر ندارند.

حمایت مالی: نویسندگان مقاله اعلام می‌نمایند که این تحقیق پشتیبان مالی نداشته است.

ملاحظات اخلاقی: نویسندگان تمام نکات اخلاقی شامل عدم سرقت ادبی، انتشار دوگانه، تحریف داده‌ها و داده‌سازی را در این مقاله رعایت کرده‌اند. همچنین هرگونه تضاد منافع حقیقی یا مادی که ممکن است بر نتایج یا تفسیر مقاله تأثیر بگذارد را رد می‌کنند.

سهم نویسندگان: تمام نویسندگان در ایده‌پردازی و طراحی مطالعه مشارکت داشتند. مفهوم‌سازی، روش‌شناسی، نرم‌افزار، نظارت و نگارش توسط نرگس عطاردی انجام شد. پیش‌نویس اولیه مقاله توسط میترا محمدی و نرگس عطاردی نگارش یافت و سایر نویسندگان نیز بر نسخه‌های قبلی مقاله نظر دادند. تمامی نویسندگان نسخه نهایی مقاله را مطالعه کرده و تأیید نمودند. علاوه بر این، مفهوم‌سازی، روش‌شناسی و نگارش توسط میترا محمدی به انجام رسید. نگارش، بازبینی و ویرایش نیز توسط زهرا حاج‌علی‌اوغلی صورت گرفت.

References

- 1) Xu, M., Wang, Y., & Tu, Y. (2021). Uncovering the invisible effect of air pollution on stock returns: A moderation and mediation analysis. *Finance Research Letters*, 39, 101646. <https://doi.org/10.1016/j.frl.2020.101646>
- 2) Huang, Y., Wu, Y., & Zhang, W. (2020). Comprehensive identification and isolation policies have effectively suppressed the spread of COVID-19. *Chaos, Solitons & Fractals*, 139, 110041. <https://doi.org/10.1016/j.chaos.2020.110041> PMID:32834599 PMCID:PMC7305880
- 3) Lai, C.-C.; Shih, T.-P.; Ko, W.-C.; Tang, H.-J.; Hsueh, P.-R. Severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) and coronavirus disease-2019 (COVID-19): The epidemic and the challenges. *Int. J. Antimicrob. Agents* 2020, 55, 105924. <https://doi.org/10.1016/j.ijantimicag.2020.105924> PMID:32081636 PMCID:PMC7127800

- variation. *The Science of the Total Environment*, 732, 139282. <https://doi.org/10.1016/j.scitotenv.2020.139282> PMID:32413621 PMCID:PMC7211667
- 7) Emmons, L. K., Walters, S., Hess, P. G., Lamarque, J. F., Pfister, G. G., Fillmore, D., Granier, C., Guenther, A., Kinnison, D., Laepple, T., Orlando, J., Tie, X., Tyndall, G., Wiedinmyer, C., Baughcum, S. L., & Kloster, S. (2010). Description and evaluation of the Model for Ozone and Related chemical Tracers, version 4 (MOZART-4). *Geoscientific Model Development*, 3(1), 43-67. <https://doi.org/10.5194/gmd-3-43-2010>
- 8) Karimian, H., Li, Q., Li, C., Jin, L., Fan, J., & Li, Y. (2016). An Improved Method for Monitoring Fine Particulate Matter Mass Concentrations via Satellite Remote Sensing. *Aerosol and Air Quality Research*, 16(4), 1081-1092. <https://doi.org/10.4209/aaqr.2015.06.0424>
- 9) Patel, C. J. (2017). Analytic Complexity and Challenges in Identifying Mixtures of Exposures Associated with Phenotypes in the Exposome Era. *Current Epidemiology Reports*, 4(1), 22-30. <https://doi.org/10.1007/s40471-017-0100-5> PMID:28251040 PMCID:PMC5306298
- 10) Werbos, P. J. (2002). Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE*, 78(10), 1550-1560 <https://doi.org/10.1109/5.58337>
- 11) Xiao, D., Fang, F., Zheng, J., Pain, C. C., & Navon, I. M. (2019). Machine learning-based rapid response tools for regional air pollution modelling. *Atmospheric Environment*, 199, 463-473. <https://doi.org/10.1016/j.atmosenv.2018.11.051>
- 12) Seqatoleslami, N., Mousavi, M, A'lam, M. (2006). Modeling and prediction of ozone formation in the atmosphere of Mashhad city using a neural-fuzzy network based on fuzzy-adaptive inference systems. *Iran Chemical Engineering. (Persian)*
- 13) Ma, Y., Zhao, Y., Liu, J., He, X., Wang, B., Fu, S., ... & Luo, B. (2020). Effects of temperature variation and humidity on the death of COVID-19 in Wuhan, China. *Science of the total environment*, 724, 138226. <https://doi.org/10.1016/j.scitotenv.2020.138226> PMID:32408453 PMCID:PMC7142681
- 14) Freeman, B. S., Taylor, G., Gharabaghi, B., & Thé, J. (2018). Forecasting air quality time series using deep learning. 68(8), 866-886. <https://doi.org/10.1080/10962247.2018.1459956> PMID:29652217
- 15) Xayasouk, T., Lee, H., & Lee, G. (2020). Air pollution prediction using long short-term memory (LSTM) and deep autoencoder (DAE) models. *Sustainability*, 12(6), 2570. <https://doi.org/10.3390/su12062570>
- 16) Hama, S. M., Cordell, R. L., Staelens, J., Mooibroek, D., & Monks, P. S. (2018). Chemical composition and source identification of PM10 in five North Western European cities. *Atmospheric Research*, 214, 135-149. <https://doi.org/10.1016/j.atmosres.2018.07.014>
- 17) Dung, N. A., Son, D. H., & Tri, D. Q. (2019). Effect of Meteorological Factors on PM 10 Concentration in Hanoi, Vietnam. *Journal of Geoscience and Environment Protection*, 7(11), 138. <https://doi.org/10.4236/gep.2019.711010>
- 18) Orak, N. H., & Ozdemir, O. (2021). The impacts of COVID-19 lockdown on PM10 and SO2 concentrations and association with human mobility across Turkey. *Environmental research*, 197, 111018. <https://doi.org/10.1016/j.envres.2021.111018> PMID:33745929 PMCID:PMC8542992
- 19) Lei, T. M., Siu, S. W., Monjardino, J., Mendes, L., & Ferreira, F. (2022). Using machine learning methods to forecast air quality: A case study in Macao. *Atmosphere*, 13(9), 1412. <https://doi.org/10.3390/atmos13091412>
- 20) Lovrić, M., Antunović, M., Šunić, I., Vuković, M., Kecorius, S., Kröll, M., ... & Šimić, I. (2022). Machine learning and meteorological normalization for assessment of particulate matter changes during the COVID-19 lockdown in Zagreb, Croatia. *International journal of environmental research and public health*, 19(11), 6937. <https://doi.org/10.3390/ijerph19116937> PMID:35682517 PMCID:PMC9180289
- 21) Schatke, M., Meier, F., Schröder, B., & Weber, S. (2022). Impact of the 2020 COVID-19 lockdown on NO2 and PM10 concentrations in Berlin, Germany. *Atmospheric Environment*, 290, 119372. <https://doi.org/10.1016/j.atmosenv.2022.119372> PMID:36092472 PMCID:PMC9450488
- 22) WHO, 2021. WHO global air quality guidelines: particulate matter (PM2.5 and PM10), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. World Health Organization. Available at: [https:// apps. who. int/ iris/ handle/10665/ 345329](https://apps.who.int/iris/handle/10665/345329). Last access: October 2021.
- 23) Zukaib, U., Maray, M., Mustafa, S., Haq, N. U., & Rehman, F. (2023). Impact of COVID-19 lockdown on air quality analyzed through machine learning techniques. *PeerJ Computer Science*, 9, e1270. <https://doi.org/10.7717/peerj-cs.1270> PMID:37346587 PMCID:PMC10280446