



Analysis and Prediction of PM₁₀ Concentrations Based on Meteorological Parameters Using a Multilayer Perceptron (MLP) Neural Network in Ahvaz, Iran

Atefeh Bosak¹ | Zahra Hejazizadeh² Akbar Heydari Tashekaboud³

1. Corresponding author, ph.d student of Climatology, Department of Natural Geography, Faculty of Geographical Sciences, Khorazmi University, Tehran, Iran. E-mail: std_bosak.a.97@khu.ac.ir
2. Professor of Climatology, Department of Natural Geography, Faculty of Geographical Sciences, Khorazmi University, Tehran, Iran. E-mail: hejazizadeh@khu.ac.ir
3. Institute of Artificial Intelligence, Shaoxing University, Shaoxing, China & Department of Geography & Urban Planning; Ferdowsi University of Mashhad, Iran. E-mail: Heydariakbar@gmail.com

Article Info	ABSTRACT
Article type: Research Article	This study aimed to investigate the relationships between meteorological parameters and particulate matter (PM₁₀) concentrations and to predict PM₁₀ concentrations in Ahvaz, Iran. Daily meteorological data, including temperature, wind speed, wind direction, horizontal visibility, precipitation, and relative humidity, along with PM₁₀ concentration data, were collected for the period 2011–2023 from the Iran Meteorological Organization and the Khuzestan Department of Environmental Protection. Following data preprocessing, the Kolmogorov–Smirnov test was applied to assess the normality of the data distributions. Given the non-normal distribution of the data, Spearman’s rank correlation coefficient and Kendall’s Tau-b correlation coefficient were employed to examine the relationships between PM₁₀ concentrations and meteorological parameters. Statistical analyses and modeling were performed using SPSS and the Python programming language in the Spyder environment. The correlation analysis revealed significant associations between PM₁₀ concentrations and the meteorological parameters. Specifically, PM₁₀ exhibited significant positive correlations with temperature (0.284 and 0.187) and wind speed (0.094 and 0.061), while significant negative correlations were observed with horizontal visibility (-0.408 and -0.300), wind direction (-0.048 and -0.034), precipitation (-0.159 and -0.125), and relative humidity (-0.259 and -0.173). Subsequently, a Multilayer Perceptron (MLP) artificial neural network was employed to predict PM₁₀ concentrations. The network architecture consisted of an input layer with six neurons corresponding to the meteorological parameters, three hidden layers with 16, 32, and 64 neurons, and an output layer. The model evaluation results indicated that the MLP neural network achieved acceptable performance in predicting PM₁₀ concentrations in Ahvaz, with prediction errors remaining within an acceptable range across the training, validation, and testing stages.
Article history:	
Received	
2024/07/18	
Received in revised	
2024/09/20	
Accepted	
2024/09/26	
Published	
2024/09/27	
Published online	
2026/06/22	
Keywords: Air Pollution, Artificial Neural Network, Multilayer Perceptron (MLP), Particulate Matter (PM ₁₀), Ahvaz.	

Cite this article: Bosak, Atefeh., Hejazizadeh, Zahra., & Heydari Tashekaboud, Akbar. (2026). Analysis and Prediction of PM₁₀ Concentrations Based on Meteorological Parameters Using a Multilayer Perceptron (MLP) Neural Network in Ahvaz, Iran. *Applied Researches in Geographical Sciences*, 26 (81), 1-27. DOI: <http://dx.doi.org/10.66224/jgs.26.81.12>





Extended Abstract

Introduction

Air pollution, due to its detrimental impacts on the environment and human health, is considered a serious threat to the Earth and living organisms (Shams et al., 2023). Aerosol particles are a major component of air pollution. These fine particles, ranging from 1 to 100 nanometers, can carry toxic gaseous compounds, infectious diseases, minerals, and more. Their small size allows them to penetrate the bloodstream and lung tissues, posing significant health risks to humans and other living beings (Asaei-Moamam et al., 2023). PM₁₀ particles are one type of air pollutant aerosol that are considered hazardous due to their association with carcinogenic elements such as dioxins, furans, benzo(a)pyrenes, and heavy metals (Shams et al., 2023). The increase in pollutant concentrations is due to natural sources, human activities, and chemical reactions (Yukago et al., 2020). According to statistics from the World Health Organization, air pollution levels increased by approximately eight percent between 2008 and 2013 (Shams et al., 2023).

Materials and Methods

This study aimed to assess the status of PM₁₀ atmospheric pollutants using various meteorological parameters and to predict future time steps of this pollutant using the multilayer perceptron (MLP) neural network model. The meteorological data were obtained from the National Meteorological Organization, and the PM₁₀ data were received from the Khuzestan Department of Environment. After processing and refining the data, meteorological parameters including visibility, wind speed, wind direction, relative humidity, temperature, precipitation, and PM₁₀ pollutants were selected for a 12-year period (2011 to 2023). The hourly data were converted to daily data and preprocessed. The normality of the data distribution was assessed using the Kolmogorov-Smirnov test with SPSS software, which indicated that the data were non-normally distributed. Therefore, non-parametric methods were chosen for the statistical analysis. The Spearman and Kendall Tau-b correlation coefficients were used to examine the correlation between the variables. Additionally, Python was used to plot the time series graphs of the pollutants. To predict future PM₁₀ levels, an MLP neural network model was used, implemented in Python with the Spyder environment. The general steps to create the MLP neural network model were as follows:

1. Importing necessary libraries.
2. Reading the data file.
3. Preprocessing the data.
4. Converting the data to the required format using the supervised function.
5. Splitting the data into training and testing sets.

6. Normalizing the data.
7. Constructing the MLP neural network model.
8. Predicting and evaluating the model.
9. Rescaling the predictions back to the original data format.
10. Plotting graphs to compare actual and predicted results.
11. Forecasting future values.

For the MLP neural network, after splitting the input data into training and testing sets in an 80:20 ratio, the designed model included three hidden Dense layers with ReLU activation functions, containing 16, 32, and 64 neurons hierarchically. The output layer used a linear activation function. The model was compiled using the MSE loss function and the Adam optimizer, with EarlyStopping to prevent overfitting. The model was trained for a maximum of 3000 epochs with batch sizes of 64, and evaluated using the loss function, Mean Squared Error (MSE), Average Mean Error (AME), and Root Mean Squared Error (RMSE). Finally, the predicted values were rescaled and presented as a forecast of PM₁₀ levels for the next 31 days in graphical format.

Results and Discussion

Using Python, the statistical information of the data was extracted and presented in tables for analysis. The Spearman correlation coefficient results showed a positive and significant correlation between PM₁₀ and meteorological data such as wind speed and temperature, with correlation coefficients of 0.094 and 0.284, respectively, at a 99% confidence level. Negative and significant correlations were found between PM₁₀ and other meteorological variables, including visibility (-0.408), wind direction (-0.048), precipitation (-0.159), and relative humidity (-0.259). The Kendall Tau-b correlation coefficient results were like those of Spearman, with PM₁₀ having negative correlations with visibility (-0.300), wind direction (-0.034), precipitation (-0.125), and relative humidity (-0.173), and positive correlations with wind speed and temperature at 0.061 and 0.187, respectively, at a 99% confidence level. The performance of the MLP neural network showed that the MSE for the training set was 0.0034 and for the validation data was 0.0012. For the test set, the validation accuracy was mse_mlp=0.0048 and val_loss=0.0012, indicating a suitable performance of the neural network model. The error function values and mean squared error for the next 31 future time steps demonstrated the MLP neural network model's acceptable performance in predicting PM₁₀ levels in Ahvaz.

Conclusion

The results of this study indicate a significant direct or inverse correlation between meteorological data and PM₁₀. There are negative and significant correlations between PM₁₀



Journal of Applied Researches in Geographical Sciences

Print ISSN: 2228-7736

Online ISSN: 2588-5138

<https://jgs.khu.ac.ir/>



and parameters such as precipitation, relative humidity, visibility, and wind direction at a 99% confidence level, and positive and significant correlations with temperature and wind speed at a 99% confidence level. The MLP neural network results showed that the network provided satisfactory performance and acceptable predictions for future PM_{10} levels in Ahvaz.



تحلیل و پیش‌بینی غلظت PM₁₀ بر پایه پارامترهای هواشناسی با استفاده از شبکه عصبی پرسپترون چندلایه (MLP) در شهر اهواز^۱

عاطفه بساک^۱، زهرا حجازی زاده^۲، اکبر حیدری تاشه کبود^۳

۱. نویسنده مسئول، دانشجو دکتری آب‌وهواشناسی، گروه جغرافیا طبیعی، دانشکده علوم جغرافیایی، دانشگاه خوارزمی تهران، تهران،

ایران. رایانامه: std_bosak.a.97@khu.ac.ir

۲. استاد آب‌وهواشناسی، گروه جغرافیا طبیعی، دانشکده علوم جغرافیایی، دانشگاه خوارزمی تهران، تهران، ایران. رایانامه:

hejazizadeh@khu.ac.ir

۳. گروه هوش مصنوعی و شهرهای هوشمند دانشگاه ژائو ژنگ، چین و گروه جغرافیا و برنامه‌ریزی شهری، دانشگاه فردوسی مشهد،

ایران. رایانامه: Heydariakbar@gmail.com

چکیده	اطلاعات مقاله
این پژوهش با هدف ارزیابی ارتباط میان پارامترهای هواشناسی و غلظت ذرات معلق PM ₁₀ و پیش‌بینی غلظت این آلاینده در شهر اهواز انجام شد. داده‌های روزانه پارامترهای هواشناسی شامل دما، سرعت باد، جهت باد، دید افقی، بارش و رطوبت نسبی و همچنین غلظت PM ₁₀ در بازه زمانی ۱۳۹۰ تا ۱۴۰۲، از سازمان هواشناسی کشور و اداره کل حفاظت محیط‌زیست خوزستان گردآوری شد. پس از پیش‌پردازش داده‌ها، به‌منظور بررسی نرمال بودن توزیع آن‌ها از آزمون کولموگروف اسمیرنوف استفاده شد. با توجه به غیرنرمال بودن داده‌ها، ضرایب همبستگی اسپیرمن و تاوی بی کندال برای بررسی ارتباط میان غلظت PM ₁₀ و پارامترهای هواشناسی به‌کار گرفته شدند. تحلیل‌های آماری و مدل‌سازی با استفاده از نرم‌افزار SPSS و زبان برنامه‌نویسی پایتون در محیط Spyder انجام شد. نتایج تحلیل همبستگی نشان داد که بین غلظت PM ₁₀ و پارامترهای هواشناسی ارتباط معناداری وجود دارد. به‌طور مشخص، همبستگی مثبت و معناداری بین PM ₁₀ و دما (۰/۲۸۴ و ۰/۱۸۷) و سرعت باد (۰/۰۹۴ و ۰/۰۶۱) و همبستگی منفی و معناداری بین PM ₁₀ و دید افقی (۰/۴۰۸ و ۰/۳۰۰)، جهت باد (۰/۰۴۸ و ۰/۰۳۴)، بارش (۰/۱۵۹ و ۰/۱۲۵) و رطوبت نسبی (۰/۲۵۹ و ۰/۱۷۳) مشاهده شد. در ادامه، به‌منظور پیش‌بینی غلظت PM ₁₀ ، از شبکه عصبی مصنوعی چندلایه پرسپترون (MLP) استفاده شد. ساختار شبکه شامل یک لایه ورودی با شش نورون متناظر با پارامترهای هواشناسی، سه لایه پنهان با ۱۶، ۳۲ و ۶۴ نورون و یک لایه خروجی بود. نتایج ارزیابی مدل نشان داد که شبکه عصبی MLP عملکرد قابل قبولی در پیش‌بینی غلظت PM ₁₀ در شهر اهواز دارد و خطای پیش‌بینی در مراحل آموزش، اعتبارسنجی و آزمون در سطح قابل قبولی قرار گرفت.	نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۳/۰۴/۲۸ تاریخ بازنگری: ۱۴۰۳/۰۶/۳۰ تاریخ پذیرش: ۱۴۰۳/۰۷/۰۵ تاریخ انتشار: ۱۴۰۳/۰۷/۰۶ تاریخ انتشار آنلاین: ۱۴۰۵/۰۴/۰۱ کلیدواژه‌ها: آلودگی هوا، شبکه عصبی مصنوعی، پرسپترون چندلایه (MLP)، ذرات معلق کمتر از ده میکرون (PM ₁₀)، اهواز.

استناد: بساک، عاطفه؛ حجازی‌زاده، زهرا؛ و حیدری تاشه کبود، اکبر (۱۴۰۵). تحلیل و پیش‌بینی غلظت PM₁₀ بر پایه پارامترهای هواشناسی با استفاده از شبکه عصبی پرسپترون چندلایه (MLP) در شهر اهواز. تحقیقات کاربردی علوم جغرافیایی،

۲۶ (۸۱)، ۲۷-۱. <http://dx.doi.org/10.66224/jgs.26.81.12>



© نویسندگان.

ناشر: دانشگاه خوارزمی تهران.

^۱ این مقاله برگرفته از رساله دکترای نویسنده‌ی اول با عنوان: آینده‌پژوهی آلاینده‌های جوی در شهرهای صنعتی استان خوزستان با توجه به سناریوهای تغییر اقلیم در افق ۱۴۳۰ و به راهنمایی نویسنده دوم و مشاوره‌ی نویسنده سوم است.

مقدمه

هوا یک نیاز اساسی برای حیات در سیاره‌ی زمین است (سوبرامانیام و همکاران^۲، ۲۰۲۲)؛ و کیفیت آن ارتباط مستقیم و تنگاتنگی با اکوسیستم‌های سطح زمین و آب‌وهوا دارد (کابانیروس و همکاران^۳، ۲۰۱۹). آلودگی هوا یکی از عناصر کلیدی و مهم تأثیرگذار در محیط‌زیست و جمعیت جهانی است و در طی دهه‌های گذشته به‌صورت پی‌درپی به‌عنوان نگرانی زیست‌محیطی مهم بوده و پیامدهای بسیاری برای اقتصاد و سلامت عمومی در بعد جهانی دارد (ویبها یاداو و همکاران^۴، ۲۰۲۴). اولین بار اهمیت آلودگی هوا و اثرات آن بر سلامتی انسان توسط مردم روم باستان و آتن مطرح شد (موزلی^۵، ۲۰۱۴). به‌مرور با پیشرفت تکنولوژی و حمل‌ونقل، رشد سریع شهرنشینی و افزایش جمعیت مسئله‌ی آلودگی هوا به یک مسئله‌ی جهانی تبدیل شده است؛ که نتایج آن منجر به بروز تغییرات اقلیمی شده است (سوبرامانیام و همکاران^۶، ۲۰۲۲). استفاده از سوخت‌های فسیلی، صنایع و کارخانجات، جنگل‌زدایی، انتشار گازهای گلخانه‌ای و سیستم حمل‌ونقل از عوامل انسانی ایجاد آلودگی هوا هستند و در نهایت منجر به تغییرات آب‌وهوایی می‌شوند (سوبرامانیام و همکاران^۶، ۲۰۲۲). بر اساس تعریف سازمان بهداشت جهانی آلودگی هوا عبارت است از آلودگی محیط داخلی یا خارجی توسط هر عامل شیمیایی، فیزیکی یا بیولوژیکی که ویژگی‌های طبیعی جو را تغییر می‌دهد (سازمان بهداشت جهانی^۷، ۲۰۲۴)، آلاینده‌های مهم جوی شامل گازهای مونوکسید کربن (CO)، دی‌اکسید گوگرد (SO₂)، دی‌اکسید نیتروژن (NO₂)، ازن (O₃)^۷، میانگین غلظت ذرات معلق کمتر از ۱۰ میکرون (PM₁₀)^۸ و میانگین غلظت ذرات معلق کمتر از ۲.۵ میکرون (PM_{2.5}) اشاره کرد (بساک و همکاران^۹، ۱۴۰۲ و WHO, 2024). آلودگی هوای بیرون و داخل خانه باعث بیماری‌های تنفسی و سایر بیماری‌ها می‌شود و از منابع مهم مرگ‌ومیر محسوب می‌شود (WHO, 2024). در عصر حاضر حدود ۹۹٪ از جمعیت جهان در معرض آلودگی هوا قرار دارند و این مقدار بیش از میزان مشخص شده توسط سازمان بهداشت جهانی است و منجر به مرگ بیش از ۷ میلیون مرگ زودرس در سال می‌شود (یاداو و همکاران^۹، ۲۰۲۴). شاخص کیفیت هوا (AQI)^{۱۰} نقش مهمی در ارزیابی و پیش‌بینی آلودگی هوا ایفا می‌کند (لیو^{۱۱} و همکاران^{۱۲}، ۲۰۲۴). در سنجش کیفیت هوای محیط، ذرات معلق به دلیل تأثیراتی که روی سلامتی، میزان دید و آب‌وهوا و... دارند توسط ایستگاه‌های سنجش آلودگی مقدارشان پایش، ثبت و اندازه‌گیری می‌شود (رودریگز و همکاران^{۱۳}، ۲۰۰۱). ذرات اتمسفر (PM) یکی از آلاینده‌های هوا هستند که روی سلامتی انسان تأثیرگذارند (بیانکوفیوره و همکاران^{۱۴}، ۲۰۱۷). ذرات با قطر آیرودینامیکی کمتر از ده میکرون (PM₁₀) از خطرناک‌ترین این آلاینده‌ها هستند (بیانکوفیوره و همکاران^{۱۴}، ۲۰۱۷). این ذرات به مناطق حساس سیستم تنفسی ورود می‌کنند و منجر به بیماری‌های تنفسی و آسیب به بافت گلو و ریه می‌شوند (بیانکوفیوره و همکاران^{۱۴}، ۲۰۱۷). جنس ذرات PM به‌صورت کلی از اسیدها مانند نیترات‌ها و سولفات‌ها، مواد شیمیایی آلی، فلزات و همچنین ذرات غبار و گردوخاک تشکیل شده است؛ و عوامل ایجاد آن از دو منبع فرایندهای طبیعی و صنعتی از قبیل توفان‌های گردوغبار، معلق شدن خاک‌های محلی، گردوغبارهای جاده‌ای، رخدادهای خشک‌سالی و کم‌آبی و به‌تبع آن افزایش سطوح بایر و کاهش پوشش گیاهی، کارخانجات و صنایع (هدایت زاده و همکاران^{۱۵}، ۱۳۹۸) و... نشئت می‌گیرند. شرایط هواشناسی میزان PM₁₀ جو را کنترل می‌کنند (رودریگز و همکاران^{۱۴}، ۲۰۰۱)؛ و افزایش غلظت آن ناشی از شرایط نامناسب هواشناسی و سایر عوامل مؤثر بر آن است (گریواس و چالولاکو، ۲۰۰۶، کارنوال

² Subramaniam et al³ Cabaneros et al⁴ Yadav et al⁵ Mosley⁶ World Health Organization (WHO)⁷ Ozone⁸ Particulate matter⁹ Vibha Yadav et al¹⁰ Air Quality Index¹¹ Liu¹² Rodriguez et al¹³ Biancofiore et al¹⁴ Rodriguez et al

[و همکاران، ۲۰۱۰](#)). حداکثر میزان PM₁₀ مجاز موجود در جو در دستورالعمل اتحادیه اروپا برابر با میانگین روزانه ۵۰ میکروگرم بر مترمکعب تعیین شده است و همچنین بیش از ۳۵ روز در سال نباید از این میزان تجاوز کرد و حداکثر میزان سالانه آن نیز ۴۰ میکروگرم بر مترمکعب است ([بیانکوفیوره و همکاران، ۲۰۱۷](#)). از این روی ذرات آلاینده‌ی کمتر از ده میکرون از مهم‌ترین عوامل آلودگی جوی است که موجب کاهش کیفیت هوا و بروز آلودگی هوا در جهان علی‌الخصوص در شهرهای صنعتی ([بساک و همکاران، ۱۴۰۲](#)) و مستعد خیزش گردوخاک شده است. استان خوزستان نیز با توجه به موقعیت جغرافیایی آن و همچنین با توجه به اینکه یکی از قطب‌های صنعتی کشور است سالیان طولانی است که با پدیده‌ی آلودگی هوا مواجه است. شهر اهواز به‌عنوان مرکز استان استراتژیک خوزستان به علت قرارگیری صنایع آلاینده از قبیل نفت و پتروشیمی و کشت و صنعت‌ها و همچنین وجود منشأهای گردوغبار داخلی و در مسیر توفان‌های گردوغبار با کانون‌های خارجی از بهره‌مندی از هوای با کیفیت مطلوب محروم بوده است. به‌گونه‌ای که مطابق گزارش سازمان بهداشت جهانی از نظر میزان آلودگی هوا، به مدت یک سال (اوت ۲۰۰۹ تا اوت ۲۰۱۰) شهر اهواز در بین ۱۱۰۰ شهر جهان با میانگین سالیانه ذرات آلاینده‌ی PM₁₀ برابر با ۳۷۲ میکروگرم بر مترمکعب دارای رتبه‌ی اول بوده است ([صادقی و خاکسار آستانه، ۱۳۹۳](#)) ([ملکی و همکاران، ۲۰۱۹](#))؛ با توجه به مطالعات پیشین ([دونگ و همکاران، ۲۰۲۳](#)؛ [کابانروس و همکاران، ۲۰۱۹](#))، مدل‌های پیش‌بینی می‌توانند به‌عنوان ابزاری قدرتمند برای درک و پیش‌بینی وضعیت کیفیت هوا مورد استفاده قرار گیرند. تحقیقات مختلف ([وی و همکاران، ۲۰۱۹](#)؛ [ژانگ و همکاران، ۲۰۲۱](#)؛ [طاهری و رازبان، ۲۰۲۱](#)) نشان داده‌اند که شبکه‌های عصبی مصنوعی، مدل‌های رگرسیونی و مدل‌های مبتنی بر درخت تصمیم از جمله رایج‌ترین الگوریتم‌های یادگیری ماشین برای پیش‌بینی آلودگی هوا هستند. در میان این الگوریتم‌ها، شبکه‌های عصبی به دلیل توانایی در مدل‌سازی روابط پیچیده و غیرخطی، اغلب برای پیش‌بینی آلودگی هوا عملکرد بهتری از خود نشان می‌دهند. مطالعات نشان داده‌اند که شبکه‌های عصبی مصنوعی ابزاری قدرتمند برای پیش‌بینی و مدل‌سازی میزان آلودگی هوا هستند ([کیخسروی و همکاران، ۱۳۹۸](#)). این روش‌ها به دلیل قابلیت یادگیری الگوهای پیچیده در داده‌ها و انعطاف‌پذیری در برخورد با داده‌های نویزدار، نسبت به روش‌های سنتی دقت بالاتری دارند ([پاداو و همکاران، ۲۰۲۴](#)). به علاوه، امکان استفاده از طیف گسترده‌ای از پارامترهای ورودی در شبکه‌های عصبی، مدل‌های پیش‌بینی را دقیق‌تر و قابل‌اعتمادتر می‌سازد.

بنابراین با توجه به اهمیت مسئله‌ی حیاتی آلودگی هوا، در این پژوهش به مطالعه‌ی سنجش و ارزیابی آلاینده جوی PM₁₀ در شهر اهواز با استفاده از روش‌های آماری و شبکه عصبی پرسپترون چندلایه^{۱۶} (MLP) به‌وسیله‌ی زبان پایتون و در فضای Spyder در بازه زمانی ۲۰۱۱-۲۰۲۳ پرداخته و همچنین پیش‌بینی این آلاینده برای گام زمانی یک ماه آینده (۳۱ روز) را انجام خواهیم داد.

روش‌شناسی


موقعیت منطقه مورد مطالعه

شهر اهواز به‌عنوان مرکز سیاسی و اداری استان خوزستان در جنوب غربی ایران واقع شده است. این شهر از نظر موقعیت جغرافیایی در طول جغرافیایی ۴۸ درجه و ۶۶ دقیقه و ۹۲ ثانیه شرقی و عرض جغرافیایی ۳۱ درجه و ۳۲ دقیقه شمالی قرار گرفته است. اهواز با ۱۲ شهر استان خوزستان هم‌جوار بوده و با مساحتی بالغ بر ۴۸۶۸ کیلومتر مربع، بزرگ‌ترین شهر استان و بخش جنوبی کشور محسوب می‌شود. ارتفاع این شهر از سطح دریا ۲۲.۵ متر بوده و در جلگه‌ی خوزستان واقع شده است. اهواز دارای ۳ بخش، ۲ شهر و ۶ دهستان است ([سالنامه آماری استان خوزستان، ۱۳۹۸](#)). بر اساس آخرین سرشماری نفوس و مسکن در سال ۱۳۹۵، جمعیت اهواز به ۱۳۰۲۵۹۱ نفر می‌رسد. این شهر از جاذبه‌های گردشگری فرهنگی متعددی برخوردار است که مهم‌ترین آن‌ها رودخانه کارون است که از میان شهر عبور کرده و جلوه‌ای زیبا به آن بخشیده است از نظر

^{۱۵} Biancofiore et al

^{۱۶} Multi Layer Perceptron

آبوهوایی دارای آبوهوایی گرم و خشک بوده و دارای میانگین دمای سالانه ۲۶.۳ درجه سانتی‌گراد و میانگین بارش ۲۰۲.۵ میلی‌متر می‌باشد (ویژگی‌های جغرافیایی و اقلیمی استان خوزستان)؛ و از نظر سنجش کیفیت هوا نیز با ثبت تعداد بسیار زیاد روزهای دارای هوای آلوده جزء آلوده‌ترین شهرهای جهان در سال ۲۰۱۱ بوده است. وجود صنایع آلاینده و نفتی و قرار گرفتن در مسیر رخدادهای گردوغبارهای متعدد از عوامل کاهش کیفیت هوای این شهر به شمار می‌روند؛ همچنین سرانه فضای سبز اهواز در مقایسه با میانگین جهانی که برابر با ۲۵ متر برای هر نفر است، برای شهر اهواز فقط ۶ متر می‌باشد. در شکل (۱) موقعیت جغرافیایی شهر اهواز در کشور و استان خوزستان ارائه شده است. شهرستان کارون در ضلع جنوبی شهر اهواز قرار دارد که مرکز آن شهر کوت عبدالله می‌باشد. این شهر که در گذشته جزئی از شهر اهواز بوده در بهمن ماه ۱۳۹۱ از بخش مرکزی اهواز جدا شده و به‌عنوان شهرستان کارون شناخته می‌شود. همچنین شهرستان باوی نیز در ناحیه‌ی شمال شرقی اهواز و بین شهرهای اهواز و شوشتر قرار گرفته است. نمایی از وضعیت هوای شهر اهواز ناشی از آلاینده‌های صنعتی و توفان‌های گردوغبار در شکل (۲) ارائه شده است.



شکل (۱). موقعیت جغرافیایی شهر اهواز در استان خوزستان و ایران



شکل (۲). نمایی کلی از منابع و وضعیت آلودگی شهر اهواز (منبع: عکاس: علی محمدی و سایت ایرنا)

داده‌های مورد استفاده

شاخص‌های سنجش کیفیت هوا و اثرات آن‌ها بر سلامتی که در شکل (۳) ارائه شده حاکی از میزان اهمیت و اثرگذاری این پارامترها بر روی سلامتی و زندگی انسان‌ها و سایر موجودات زنده می‌باشد. از این‌رو به‌منظور بررسی، مطالعه و پیش‌بینی وضعیت آلاینده‌های هوای شهر اهواز از پارامترهای مختلف، شکل (۴)، برای سنجش آلاینده‌های استفاده می‌شود، داده‌های سه‌ساعته هواشناسی از سازمان هواشناسی کشور و داده‌های ساعتی ایستگاه زمینی سنجش و کنترل کیفیت هوا در سطح شهرستان اهواز، باوی و کارون دریافتی از اداره کل محیط‌زیست استان خوزستان استفاده می‌گردد. در این مقاله برای

آزمون کلموگروف اسمیرنوف^{۱۹} (KS)

قبل از انجام هر آزمون آماری ابتدا میزان نرمال بودن داده‌ها بررسی می‌شود تا براساس آن نوع آزمون آماری مشخص شود. در این پژوهش جهت بررسی توزیع داده‌ها و نرمالیتی آن‌ها از آزمون آماری کلموگروف اسمیرنوف در نرم‌افزار SPSS استفاده شد. باتوجه به جدول (۱) سطح معنی‌داری (Sig) برای تمامی متغیرها برابر با ۰.۰۰۰ است که باتوجه به کمتر از ۰.۰۵ بودن آن بیانگر غیرنرمال بودن داده‌های موردبررسی می‌باشد.

جدول (۱). آزمون کلموگروف اسمیرنوف برای بررسی نرمال بودن پارامترهای مورد مطالعه

متغیر	تعداد نمونه	میانگین	انحراف معیار	آماره آزمون (D)	سطح معناداری (Sig)
PM ₁₀	۴۴۸۵	۱۷۴.۳۸	۱۹۸.۳۱۱	۰.۲۵۵	۰.۰۰۰C
رطوبت نسبی	۴۴۸۵	۴۱.۴۶۴	۲۰.۳۲۱۵	۰.۰۹۷	۰.۰۰۰C
بارش	۴۴۸۵	۰.۴۷	۳.۰۹۱	۰.۴۹۸	۰.۰۰۰C
دید افقی	۴۴۸۵	۸۱۳۰.۸۲	۲۰۲۶.۱۴۷	۰.۱۷۶	۰.۰۰۰C
دما	۴۴۸۵	۲۷.۰۰	۹.۷۱۰	۰.۱۱۷	۰.۰۰۰C
سرعت باد	۴۴۸۵	۲.۲۴۵	۱.۰۸۰۸	۰.۱۰۵	۰.۰۰۰C
جهت باد	۴۴۸۵	۲۰۴.۴	۷۲.۰۳۲	۰.۰۷۳	۰.۰۰۰C

همان‌طور که نتایج آزمون کلموگروف اسمیرنوف نشان داد داده‌های ما دارای توزیع غیرنرمال می‌باشند. با توجه به نتایج آزمون فوق جهت انجام پژوهش موردنظر از روش‌های آماری ناپارامتریک (ضریب همبستگی اسپیرمن، تاوی-بی کندال) بهره گرفته می‌شود؛ و از شبکه عصبی پرسپترون چندلایه (MLP) برای انجام رگرسیون و پیش‌بینی گام‌های زمانی آینده‌ی مقادیر ذرات معلق کمتر از ده میکرون استفاده خواهد شد.

ضریب همبستگی تاوی-بی کندال^{۲۰}

همبستگی بیانگر ارتباط بین دو یا چند متغیر است و ضریب همبستگی میزان عددی این ارتباط را بیان می‌کند. برای بررسی همبستگی بین داده‌های هواشناسی ناپارامتری با توجه به نوع داده‌ها و هدف ما از آن مطالعه روش‌های مختلفی برای محاسبه‌ی ضریب همبستگی وجود دارد. یکی از این روش‌ها ضریب همبستگی تاوی-بی کندال است. این ضریب یکی از ضرایب قدرتمند برای محاسبه‌ی میزان همبستگی میان متغیرهای ناپارامتری محسوب می‌شود. برای محاسبه‌ی این نوع همبستگی از مقادیر نسبی داده‌ها استفاده می‌شود (عساکره، ۱۳۹۰، ۱۷۹) ضرایب همبستگی اعدادی بین +۱ تا -۱ هستند به‌طوری‌که +۱ نمایانگر ارتباط قوی و مستقیم بین دو متغیر است و افزایش یک متغیر منجر به افزایش دیگری خواهد شد؛ همبستگی -۱ نشان‌دهنده وجود ارتباط قوی و معکوسی هست و افزایش یک متغیر بیانگر کاهش دیگری است. همچنین اگر اندازه عددی صفر باشد نشان می‌دهد رابطه خطی مستقیمی بین متغیرها وجود ندارد و بیانگر مستقل بودن متغیرها از همدیگر است؛ در ادامه فرمول آن در رابطه (۱) ارائه می‌گردد:

$$\tau_2 = \frac{\sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{Sgn}(a_i - a_j)}{\frac{1}{2}n(n-1)} = \frac{P}{\sqrt{\frac{1}{18}[n(n-1)(2n+5) - \sum b_1(b_1-1)(2b_1+5)]}} \quad \text{رابطه (۱)}$$

در رابطه‌ی (۱) b_1 : تعداد داده‌های همسان (تکرارها) و n بیانگر طول دوره‌ی آماری است. همچنین Sgn علامت جبری همه‌ی زوج‌های محتمل رتبه‌ها $(a_i - a_j)$ است که در آن $j > i$ که به معنی تفاضل رتبه‌ی i م و j م است به‌صورتی که رابطه (۲):

¹⁹ Kolmogorov-Smirnov²⁰Kendall's Tau-b correlation coefficient

$$\text{sgn}(a_i - a_j) = \begin{cases} +1 & a_i > a_j \\ 0 & a_i = a_j \\ -1 & a_i < a_j \end{cases} \quad \text{رابطه (۲)}$$

و همچنین آماره‌ی P را به روش محاسبه‌ی تعداد مقادیر پایین‌تر و بالاتر از هر جمله در سری به دست می‌آوریم رابطه (۳) (عساکره، ۱۳۹۰، ۱۷۹ و ۱۸۰).

$$P = \sum_{i=1}^{n-1} n_i \quad \text{رابطه (۳)}$$

در این پژوهش جهت سنجش میزان همبستگی بین ذرات معلق آلاینده‌ی هوا (pm₁₀) با پارامترهای هواشناسی (دید افقی، بارش، دما، سرعت و جهت باد و رطوبت نسبی) از ضریب همبستگی اسپیرمن و همچنین ضریب همبستگی تاوی-بی کندال با استفاده از نرم‌افزار IBM SPSS Statistics 26 استفاده شد؛ که نتایجشان در ادامه ارائه می‌شود.

شبکه عصبی^{۲۱} (ANN)

تاریخچه‌ی شبکه‌ی عصبی مصنوعی به دهه‌ی ۱۹۴۰ میلادی بازمی‌گردد؛ هنگامی که محققان در تلاش بودند تا مدل ریاضی ایجاد کنند که توانایی یادگیری و تجزیه و تحلیل را داشته باشد. شبکه عصبی مصنوعی که از مهم‌ترین موضوعات هوش مصنوعی محسوب می‌شود (منبع: [اسلاملوئیان و خادمی: ۲۰۰۹](#)). سیستم‌های پردازش داده هستند که از سیستم‌های عصبی مغز الهام می‌گیرند ([هونگ و همکاران، ۲۰۲۱](#)) و می‌توانند به عنوان یک مدل پیش‌بینی از یک برنامه خاص زمانی که آموزش دیده‌اند استفاده کنند ([مؤیدی و همکاران، ۲۰۲۰](#)). تعداد لایه‌ها در شبکه عصبی می‌تواند از یک لایه تا چندین لایه متفاوت باشد ([پاوین و السریجی، ۲۰۱۴](#)). به صورت کلی شبکه‌های عصبی دارای سه لایه‌ی ورودی، پنهان و خروجی هستند که هر لایه از تعدادی نورون تشکیل شده است. لایه‌ی ورودی که داده‌های ورودی به شبکه را در برمی‌گیرد و تعداد نورون‌های این لایه به تعداد داده‌های ورودی آن بستگی دارد. دومین لایه که به عنوان لایه‌ی مخفی یا میانی از آن یاد می‌شود با توجه به میزان پیچیدگی شبکه و برخورداری از کمترین میزان خطا از یک تا چندین لایه را داراست و از تعداد نورون‌های متفاوتی برخوردار است که تعداد آن‌ها به میزان خطای شبکه بستگی دارد ([جی و همکاران، ۲۰۱۸](#) و [وانگ و همکاران، ۱۹۹۲](#)). همچنین لایه‌ی آخر که لایه‌ی خروجی شبکه محسوب می‌شود ([Adil. Et al, 2020](#))؛ اگر شبکه برای طبقه‌بندی باشد از چندین خروجی و اگر برای رگرسیون باشد تنها یک خروجی دارد. به صورت کلی یک شبکه‌ی عصبی دارای یک لایه‌ی ورودی، یک یا چند لایه‌ی میانی و یک لایه‌ی خروجی می‌باشد.

آناکوندا یک توزیع آزاد و متن‌باز از زبان برنامه‌نویسی پایتون است که بسته‌های گوناگونی برای محاسبات علمی، یادگیری ماشین، داده‌کاوی و... را شامل می‌شود. یکی از برنامه‌هایی که به همراه توزیع پایتون آناکوندا منتشر می‌شود اسپایدر است؛ که این IDE از بهترین‌ها برای برنامه‌نویسی پایتون محسوب می‌شود (سایت: فرادرس). در این مطالعه با استفاده از زبان برنامه‌نویسی پایتون در IDE اسپایدر به انجام شبکه عصبی پرسپترون چندلایه پرداخته می‌شود.

شبکه عصبی پرسپترون چندلایه (MLP)

شبکه عصبی پرسپترون چندلایه پرکاربردترین مدل شبکه عصبی است ([لوکش کومار و گوراو کومار، ۲۰۲۴](#)) با توجه به اینکه توزیع داده‌های ما از نوع غیرنرمال و ناپارامتری بودند برای پیش‌بینی مقدار PM₁₀ از شبکه عصبی مصنوعی (mlp) استفاده شد که به عنوان یک مدل رگرسیون عمل می‌کند. شبکه‌های عصبی پرسپترون چندلایه الگوها و وابستگی‌های پیچیده را در

²¹ Artificial Neural Networks

²² Hoang et al

²³ Baawain & Al-Serhi

²⁴ Ge et al

²⁵ Wang et al

داده‌های متفاوت ثبت می‌کنند و نتایج قابل اتکایی ارائه می‌دهند (لوپز گنزالس و همکاران^{۲۶}، ۲۰۲۳). شبکه‌های عصبی مصنوعی می‌توانند با پردازش داده‌های تجربی قوانین نهفته در آن‌ها را آشکار نمایند از این‌رو به سیستم‌های هوشمند نیز معروفاند (صادقی و خاکسار آستانه، ۱۳۹۳). به‌صورت کلی مراحل ایجاد مدل شبکه عصبی پرسپترون چندلایه ما شامل این گام‌هاست: گام ۱: وارد کردن کتابخانه‌های موردنظر، گام ۲: خواندن فایل داده، گام ۳: پیش‌پردازش داده، گام ۴: تبدیل داده‌ها به فرمت موردنظر (تبدیل داده‌ها به فرمت نظارت شده با استفاده از تابع supervised to)، گام ۵: تقسیم داده‌ها به مجموعه آموزش و آزمایش، گام ۶: نرمال‌سازی داده‌ها، گام ۷: ساخت مدل شبکه عصبی پرسپترون چندلایه، گام ۸: پیش‌بینی و ارزیابی مدل، گام ۹: بازگرداندن مقیاس پیش‌بینی‌ها به حالت داده‌های واقعی، گام ۱۰: ترسیم نمودارها برای مقایسه نتایج واقعی و پیش‌بینی شده، گام ۱۱: پیش‌بینی آینده که در شکل (۵) به‌صورت شماتیک نمایش داده شده‌اند و در ادامه این مراحل شرح داده می‌شود.



شکل (۵). گام‌های مختلف پیشبرد شبکه عصبی پرسپترون چندلایه

پس از ورود داده‌ها به مدل ابتدا فرایند پیش‌پردازش داده‌ها انجام و سپس ویژگی‌ها و هدف مدل انتخاب شد. به‌صورتی که داده‌ها به دو بخش داده‌های ورودی که شامل متغیرهای هواشناسی مورد مطالعه بودند و داده خروجی که پارامتر ذرات معلق کمتر از ده میکرون بود؛ تقسیم شدند.


داده‌های مورد استفاده در این پژوهش شامل مشاهدات روزانه از تاریخ ۱ فروردین ۱۳۹۰ تا ۹ تیرماه ۱۴۰۲ (به مدت ۴۴۸۵ روز) است. پس از پیش‌پردازش داده‌ها و تبدیل آن‌ها به فرمت مناسب، داده‌ها به دو مجموعه آموزش (۸۰ درصد داده‌ها) و آزمایش (۲۰ درصد داده‌ها) تقسیم شدند. با توجه به ماهیت سری زمانی داده‌ها و به‌منظور بهبود عملکرد مدل، داده‌ها نرمال‌سازی شدند. سپس، یک شبکه عصبی پرسپترون چندلایه با ساختار بهینه طراحی گردید. این شبکه شامل یک لایه ورودی با ۶ نورون (مربوط به ۶ ویژگی ورودی)، سه لایه پنهان متوالی با ۱۶، ۳۲ و ۶۴ نورون به ترتیب و یک لایه خروجی با تابع فعال‌سازی خطی است. در لایه‌های پنهان از تابع فعال‌سازی $ReLU^{27}$ استفاده شده است.

²⁶ López-Gonzales et al

²⁷ Rectified Linear Unit

برای آموزش مدل از الگوریتم بهینه‌ساز Adam و تابع هزینه میانگین مربعات خطا (MSE) استفاده شد. همچنین، از روش توقف زودهنگام (EarlyStopping) برای جلوگیری از بیش‌برازش‌سازی مدل بهره گرفته شد. مدل به مدت حداکثر ۳۰۰۰ دوره و با اندازه دسته‌های ۶۴ نمونه آموزش داده شد.

پس از آموزش مدل، از معیارهای ارزیابی توابع زیان^{۲۸}، میانگین خطای مطلق^{۲۹}، میانگین مربعات خطا^{۳۰}، ریشه میانگین مربعات خطا^{۳۱} برای ارزیابی عملکرد مدل در مجموعه آزمایش استفاده شد. در نهایت، مقادیر پیش‌بینی شده به مقیاس اصلی بازگردانده شدند و نتایج پیش‌بینی غلظت ذرات معلق کمتر از ۱۰ میکرون برای ۳۱ روز آینده به صورت نموداری ارائه گردید. ساختار کلی شبکه عصبی در شکل (۶) نشان داده شده است.



شکل (۶). ساختار کلی شبکه عصبی مورد استفاده

اعتبار سنجی مدل

برای اعتبار سنجی مدل از توابع هزینه‌ای که برای برآورد مدل‌های رگرسیونی هستند استفاده شده است. این توابع شامل: Loss Function, Mean Squared Error (MSE), Root Mean Squared Error (RMSE) می‌باشد که در ادامه به توضیح هر کدام از این توابع زبانی رگرسیونی می‌پردازیم.

معیار Loss Function

یکی از معیارهای اساسی در آموزش مدل‌های یادگیری ماشین تابع هزینه می‌باشد. این تابع برای ارزیابی عملکرد مدل‌های شبکه‌ای عصبی مورد استفاده قرار می‌گیرد. تابع هزینه مقادیر خطا یا مقدار زیان را در هر بار اجرای شبکه‌ای عصبی برای داده‌های آموزش ارائه می‌کند. در این مطالعه برای بخش تابع هزینه‌ی مدل شبکه‌ای عصبی MLP از تابع هزینه‌ی MSE استفاده شد.

²⁸ Loss Function

²⁹ Mean Absolute Error (MAE)

³⁰ Mean Squared Error (MSE)

³¹ Root Mean Squared Error (RMSE)

معیار (Mean Squared Error) (MSE)

تابع زیان میانگین مربعات که به صورت مختصر (MSE) گفته می شود یکی از توابع هزینه مدل های رگرسیونی می باشد. این تابع به گونه ای عمل می کند که میانگین مربعات فاصله بین مقادیر واقعی و پیش بینی شده را محاسبه که به صورت رابطه (۴) می باشد.

$$MSE = \sum_{i=1}^n \frac{1}{n} (y_i - \hat{y}_i)^2 \quad \text{رابطه (۴)}$$

که در آن: n تعداد داده ها، y_i مقدار واقعی و $\hat{y}_i$ مقدار پیش بینی شده می باشد.

معیار (Root Mean Squared Error) (RMSE)

یکی از معیارهایی که برای ارزیابی عملکرد مدل های شبکه عصبی استفاده می شود معیار ریشه میانگین مربعات خطا یا (RMSE) می باشد. RMSE به دلیل محاسبه ی مربع خطاها به خطاهای بزرگ حساس می باشد. این معیار تفاوت بین مقادیر پیش بینی شده با مقادیر واقعی را بیان می کند و هر قدر مقدار آن کمتر باشد نشان دهنده ی عملکرد بهتر مدل می باشد که به صورت رابطه (۵) محاسبه می شود.

$$RMSE = \sqrt{MSE} \quad \text{رابطه (۵)}$$

نتایج و بحث**بررسی اطلاعات آماری متغیرهای مورد مطالعه**

اطلاعات و ویژگی های آماری پارامترهای مورد مطالعه ی هواشناسی و ذرات معلق کمتر از ده میکرون شهر اهواز در بازه ی زمانی ۱۳۹۰ تا ۱۴۰۲ و شامل تعداد، میانگین، حداقل، حداکثر، میانه، مد، دامنه، انحراف معیار، کشیدگی و چولگی برای هر متغیر و در فضای اسپایدر با استفاده از زبان برنامه نویسی پایتون به دست آمدند که نتایج آن در جداول (۲ و ۳) ارائه شده است. با استفاده از این اطلاعات دید بهتر و واضح تری نسبت به شرایط اقلیمی شهر اهواز وجود دارد تا بر این اساس بتوان آلودگی هوای آن را با درک بهتری بررسی کرد. همان طور که در جدول (۲) ارائه شده است اطلاعات آماری پارامترهای مورد بررسی باتوجه به بازه ی زمانی ۱۲ ساله ی مورد بررسی برای تمامی متغیرها تعداد ۴۴۸۵ روز مورد مطالعه قرار گرفت.

اطلاعات آماری دید افقی نشان می دهد که میانگین دید افقی در دوره مطالعه برابر با ۸۲۱۹ متر بوده است. این مقدار حاکی از وجود شرایط دید مناسب در اکثر روزها می باشد. باین حال، حداقل دید افقی ثبت شده ۵۵۰ متر بوده که نشان دهنده وجود روزهایی با شرایط گردوغبار شدید است. حداکثر دید افقی نیز ۱۰۰۰۰ متر ثبت شده که بیانگر شرایط جوی کاملاً صاف و شفاف در برخی روزها است. میانه داده ها با مقدار ۸۸۷۵ متر نشان می دهد که ۵۰ درصد روزها دارای دید افقی کمتر از این مقدار بوده اند. همچنین، بیشترین فراوانی یا مد داده ها بر روی مقدار ۱۰۰۰۰ متر متمرکز شده است که نشان دهنده ی تکرار بالای شرایط دید بسیار خوب است. دامنه تغییرات دید افقی با مقدار ۹۴۵۰ متر، گستردگی قابل توجهی از شرایط جوی را در طول دوره مطالعه نشان می دهد. انحراف استاندارد با مقدار ۱۸۸۷.۴۱ متر نیز بیانگر پراکندگی زیاد داده ها حول میانگین است و حاکی از نوسانات قابل توجه در دید افقی است. ضریب کشیدگی با مقدار ۱.۶۳، نشان دهنده توزیع دم دار داده ها به سمت مقادیر بزرگ تر از میانگین است. به عبارت دیگر، تعداد کمی روز با دید افقی بسیار زیاد، بر روی میانگین کلی تأثیر گذار بوده اند. همچنین، ضریب چولگی با مقدار ۱.۳۷-، نشان دهنده چولگی توزیع به سمت چپ است. این بدان معناست که تعداد بیشتری روز با دید افقی کمتر از میانگین وجود داشته است.

باتوجه به اطلاعات آماری به دست آمده از داده های روزانه ی جهت باد شهر اهواز در بازه ی زمانی مورد مطالعه چنین در می یابیم که میانگین آن ها برابر با ۲۰۳.۹۲ درجه بوده است. حداقل باد صفر درجه است که همان باد شمالی محسوب می شود و همچنین حداکثر جهت باد ثبت شده نیز با مقدار ۳۴۱ درجه به باد شمال غرب مربوط می شود. بررسی میانه ی داده های مربوط به جهت باد اهواز نشان می دهد که نیمی از بادها کمتر از ۲۰۶ درجه بوده اند. همچنین مد یا بیشترین فراوانی، وقوع

بادهای با جهت ۲۹۰ درجه بوده است که بادهای در محدوده‌ی غربی را شامل می‌شوند بر این اساس جهت باد غالب به صورت غربی بوده است استقرار تالاب هورالعظیم و زمین‌های بایر در سمت غربی اهواز منجر به ورود آلاینده‌های ناشی از آن‌ها و آلودگی هوای شهر اهواز می‌شود. دامنه‌ای که از بررسی داده‌های جهت باد به دست آمد برابر با ۳۴۱ درجه بود که بیانگر تغییرات زیاد جهت باد بوده است. همچنین انحراف معیار جهت باد در شهر اهواز ۷۲ بوده است. باتوجه به جدول (۲) داده‌های مربوط به کشیدگی و چولگی هر دو منفی بوده و به ترتیب برابر با ۰.۷۳- و ۰.۳۰- بوده است که نشان‌دهنده‌ی پراکندگی داده‌ها و دور بودن آن‌ها از میانگین است و همین‌طور با توجه به چوله به چپ بودن آن‌ها مشخص می‌کند که داده‌ها به سمت کمتر از میانگین مایل بوده‌اند.

بررسی داده‌ها و اطلاعات آماری مربوط به سرعت باد در شهر اهواز مشخص می‌کند که: میانگین سرعت باد در این شهر برابر با ۲.۲۳ متر بر ثانیه بوده است که حاکی از سرعت باد کم و ملایم در این شهر است و وجود باد ملایم از دلایل پایداری آلودگی هوا در این شهر محسوب می‌شود. همچنین حداقل سرعت باد برابر با صفر متر بر ثانیه بوده است که هوای پایدار و آرامی را برای این شهر رقم می‌زند. توجه به داده‌های باد مشخص می‌کند که حداکثر سرعت باد روزانه‌ی ثبت شده برابر با ۸.۱۲ متر بر ثانیه بوده است که این میزان بیانگر وجود روزهایی با سرعت باد شدید در شهر اهواز بوده است. توجه به میانه‌ی با سرعت ۲ متر بر ثانیه مشخص می‌کند که نیمی از بادهای ثبت شده در شهر اهواز در بازه‌ی زمانی ۱۲ ساله کمتر از ۲ متر بر ثانیه بوده‌اند. همچنین مد ثبت شده‌ی سرعت باد اهواز نیز برابر است با ۱.۰۸ متر بر ثانیه که بیانگر این است که فراوانی باد با سرعت ۱.۰۸ متر بر ثانیه بیشتر از سایر مقادیر بوده است. همان‌طور که در جدول (۲) نیز ارائه شده است دامنه‌ی سرعت باد شهر اهواز ۸.۱۲ متر بر ثانیه است که تغییرات زیاد سرعت باد را نشان می‌دهد. انحراف معیار داده‌های سرعت باد برابر با ۱.۰۸ متر بر ثانیه می‌باشد که پراکندگی داده‌های سرعت باد را نشان می‌دهد. همین‌طور کشیدگی مثبت آن‌ها که به مقدار ۱.۱۱ بوده است نشان‌دهنده‌ی توزیع غیرنرمال داده‌های سرعت باد می‌باشد. چولگی داده‌های سرعت باد که باتوجه به مقدار آن چوله به راست و برابر با ۰.۸۸ بوده است نشان می‌دهد که داده‌ها به مقادیر بیشتر از میانگین مایل بوده‌اند.

از مطالعه‌ی اطلاعات آماری میانگین دمای روزانه‌ی شهر اهواز چنین برداشت می‌شود که متوسط میانگین دمای آن برابر با ۲۶.۹۸ بوده است و حداقل دما برابر با ۳.۶۵ درجه سانتی‌گراد بوده و همین‌طور حداکثر دمای روزانه برابر با ۴۴.۰۲ درجه‌ی سانتی‌گراد می‌باشد که نشان می‌دهد این شهر از روزهای بسیار گرم زیادی برخوردار می‌باشد (بررسی داده‌های سه‌ساعته‌ی شهر اهواز در بازه‌ی زمانی ۱۲ سال اخیر نشان می‌دهد که دماهای ۵۴ درجه نیز در این شهر ثبت شده است منبع: بررسی داده‌های دمای شهر اهواز توسط نگارندگان). میانه‌ی داده‌های دمای روزانه ۲۷.۵۲ درجه سانتی‌گراد بوده است که نصف داده‌ها دمای کمتر و نصف داده‌ها دمای بیش از این مقدار را ثبت کرده‌اند. فراوان‌ترین میزان دمایی که ثبت شده برابر با مد ۳۹.۴۲ درجه سانتی‌گراد بوده است و همچنین دامنه‌ی داده‌ها با ۴۰.۳۷ درجه سانتی‌گراد ثبت شد. انحراف معیار به دست آمده برای دمای اهواز مطابق با ۹.۷۰ بوده است که بیان‌کننده‌ی پراکندگی داده‌های دمای شهر اهواز می‌باشد. برای پارامتر دمای اهواز با چولگی و کشیدگی منفی مواجه هستیم به گونه‌ای که کشیدگی داده‌ها ۱.۳۷- بوده و چولگی‌شان نیز برابر با ۰.۱۳- هست.

اطلاعات آماری مربوط به میانگین بارش روزانه‌ی شهر اهواز در بازه‌ی زمانی ۱۳۹۰ تا ۱۴۰۲ در جدول (۲) ارائه شده است. همان‌طور که از جدول (۲) نیز دریافت می‌شود میانگین بارش روزانه‌ی شهر اهواز برابر با ۰.۴۷ میلی‌متر بوده است که نشان می‌دهد میزان بارندگی در این شهر وضعیت مطلوبی نداشته و شهر اهواز در ردیف شهرهای کم باران می‌باشد. حداقل بارش این شهر به میزان صفر میلی‌متر بوده است که نشان می‌دهد بسیاری از روزها فاقد بارندگی بوده است. باتوجه به مقدار حداکثر بارندگی روزانه که برابر با ۷۳.۷ میلی‌متر بوده است مشخص می‌شود که این شهر از بارش‌های سنگینی برخوردار می‌شود. مد و میانه‌ی داده‌های بارش اهواز برابر با صفر هست و دامنه‌ی داده‌های بارش رقمی برابر با ۷۳.۷ میلی‌متر را نشان می‌دهد که بیان‌کننده‌ی تغییرات بسیار زیاد بارش در بازه‌ی زمانی مورد مطالعه می‌باشد. همچنین داده‌های بارش دارای انحراف معیاری به میزان ۳.۰۹ می‌باشد که نشانگر پراکندگی داده‌ها می‌باشد. از آنجایی که میزان کشیدگی بیانگر توزیع داده‌ها

می باشد در اینجا مقدار کشیدگی برابر با ۱۶۶.۱۱ بوده است که بیانگر توزیع بسیار غیرممتقارن و غیرنرمال داده ها می باشد و نشان می دهد که بیشتر داده ها در سمت چپ میانگین قرار دارند و تعداد اندکی از داده ها را مقادیر بزرگ در بر می گیرند و وقوع بارش های بسیار شدید را نشان می دهد. باتوجه به مقدار چولگی بارش که ۱۱.۱۸ می باشد نشان دهنده ی چوله به راست بودن داده های بارش می باشد و غیرنرمال بودن داده های بارش را نشان می دهد.

اطلاعات آماری مربوط به میزان رطوبت نسبی روزانه ی شهر اهواز برای بازه ی زمانی ۱۲ ساله چنین نشان می دهد که میانگین رطوبت نسبی روزانه برابر با ۴۱.۴۵ درصد می باشد که نشان دهنده ی مرطوب بودن هوای شهر اهواز می باشد. ثبت حداقل و حداکثر رطوبت نسبی به میزان ۶.۶۲ درصد و ۹۹.۵ درصد بیانگر برخورداری شهر اهواز از هوای مرطوب می باشد به میزانی که در بعضی روزها شاهد بروز هوای شرجی و تقریباً اشباع در این شهر می باشیم. میانه ی داده های رطوبت نسبی عددی مطابق با ۳۷.۲۵ درصد را نشان می دهد که باتوجه به تعریف میانه نیمی از داده ها بالای این مقدار و نیمی دیگر کمتر از ۳۷.۲۵ درصد می باشد. فراوان ترین مقدار رطوبت نسبی نیز به میزان ۲۳.۸۷ درصد می باشد باتوجه به اینکه مقدار مد از میزان میانگین رطوبت نسبی و همچنین میانه ی آن کمتر می باشد لذا بیانگر این است که تعداد روزهای خشک بیشتری در این شهر ثبت شده است. دامنه ی رطوبت نسبی این شهر برابر با ۹۲.۸۷ درصد می باشد. میزان انحراف معیار برای رطوبت نسبی برابر با ۲۰.۳۲ درصد می باشد که نشان دهنده ی مقادیر زیاد نوسان برای این پارامتر می باشد. کشیدگی منفی رطوبت نسبی که برابر با ۰.۵۳- هست نشان می دهد که مقادیر بالا کمتر رخ داده و مقادیر کمتر فراوانی وقوع بیشتری داشته اند. همچنین میزان مثبت چولگی که ۰.۶۱ می باشد نشان دهنده ی چوله به راست بودن داده های رطوبت نسبی می باشد و توزیع غیرنرمال داده ها را نشان می دهد.

جدول (۲). بررسی ویژگی های کلی داده های روزانه ی هواشناسی موردبررسی ایستگاه اهواز (۱۳۹۰ - ۱۴۰۲)

پارامترهای هواشناسی						
تعداد	دید افقی	جهت باد	سرعت باد	دما	بارش	رطوبت نسبی
۴۴۸۵	۴۴۸۵	۴۴۸۵	۴۴۸۵	۴۴۸۵	۴۴۸۵	۴۴۸۵
میانگین	۸۲۱۹.۴	۲۰۳.۹۲	۲.۲۳	۲۶.۹۸	۰.۴۷	۴۱.۴۵
حداقل	۵۵۰	۰۰	۰۰	۳.۶۵	۰۰	۶.۶۲
حداکثر	۱۰۰۰۰	۳۴۱.۲۵	۸.۱۲	۴۴.۰۲	۷۳.۷	۹۹.۵
میانه	۸۸۷۵	۲۰۶.۲۵	۲	۲۷.۵۲	۰۰	۳۷.۲۵
مد	۱۰۰۰۰	۲۹۰	۱.۶۲	۳۹.۴۲	۰۰	۲۳.۸۷
دامنه	۹۴۵۰	۳۴۱.۲۵	۸.۱۲	۴۰.۳۷	۷۳.۷	۹۲.۸۷
انحراف معیار	۱۸۸۷.۴۱	۷۲.۰۲	۱.۰۸	۹.۷۰	۳.۰۹	۲۰.۳۲
کشیدگی	۱.۶۳	- ۰.۷۳	۱.۱۱	- ۱.۳۷	۱۶۶.۱۱	- ۰.۵۳
چولگی	- ۱.۳۷	- ۰.۳۰	۰.۸۸	- ۰.۱۳	۱۱.۱۸	۰.۶۱

در جدول (۳) اطلاعات آماری پارامتر ذرات معلق کمتر از ده میکرون ارائه شده است. همان طور که در جدول (۳) نیز مشخص است میانگین ذرات معلق کمتر از ده میکرون برای بازه ی زمانی ۱۲ ساله ی شهر اهواز برابر با ۱۷۴.۶۶ میکروگرم بر مترمکعب بوده است که این رقم نسبت به میزان استاندارد سازمان حفاظت محیط زیست ایران برابر با ۱۵۰ میکروگرم بر مترمکعب و به صورت سالانه ۴۰ میکروگرم بر مترمکعب است فراتر می باشد. حداقل میزان آلاینده ذرات معلق کمتر از ده میکرون برای این شهر برابر با ۱۶.۷ $[\mu\text{g}/\text{m}^3]$ می باشد و همچنین حداکثر میزان ذرات معلق روزانه ی اهواز برابر با ۲۸۹۴ میکروگرم بر مترمکعب می باشد که نشان دهنده ی وقوع رخدادهای آلودگی هوای بسیار شدید و بسیار فراتر از میزان استاندارد جهانی می باشد. میانه و مد ذرات معلق کمتر از ده میکرون برابر با ۱۲۹.۱ و ۹۵.۸ میکروگرم بر مترمکعب می باشد که مد نشان دهنده ی فراوانی بیشتر مقدار ۹۵.۸ $[\mu\text{g}/\text{m}^3]$ در میان داده های ثبت شده ی این آلاینده می باشد. همچنین دامنه ی

این پارامتر برابر با ۲۷۸۷ میکروگرم بر مترمکعب است که نشان‌دهنده تغییرات بسیار زیادی در رخداد این پارامتر بوده است. میزان انحراف معیار آن‌ها که ۱۹۸.۷۹ میکروگرم بر مترمکعب می‌باشد که بیانگر تغییرات زیاد در داده‌های آلاینده می‌باشد. همچنین کشیدگی پارامتر PM_{10} برابر با ۶۶.۰۲ [$\mu g/m^3$] هست که این مقدار نشان می‌دهد که تعداد بسیار زیادی از داده‌ها از میانگین دور بوده و مقادیر شدید آلودگی هوا را شامل می‌شوند. همچنین از مقدار چولگی که ۶.۹۵ میکروگرم بر مترمکعب می‌باشد مشخص می‌شود که باتوجه به مثبت بودن مقدار آن چوله به سمت راست بوده و بیشتر داده‌های آلاینده PM_{10} در سمت چپ چوله قرار گرفته‌اند و حاکی از داشتن داده‌های با مقدار زیاد در بین داده‌هایش می‌باشد که نشان‌دهنده وقوع رخدادهای گردوغباری شدید می‌باشد.

جدول (۳). بررسی ویژگی‌های کلی داده‌های روزانه آلاینده‌ای ایستگاه‌های سنجش کیفیت هوای شهرهای اهواز (۱۳۹۰-۱۴۰۲)

پارامتر ذرات معلق کمتر از ۱۰ میکرون (PM_{10})			
تعداد	۴۴۸۵	مد	۹۵.۸
میانگین	۱۷۴.۶۶	دامنه	۲۸۷۸
حداقل	۱۶.۷	انحراف معیار	۱۹۸.۷۹
حداکثر	۲۸۹۴	کشیدگی	۶۶.۰۲
میانه	۱۲۹.۱	چولگی	۶.۹۵

ضریب همبستگی تاوی بی کندال

برای بررسی ارتباط میان داده‌های جوی و غلظت ذرات معلق کمتر از ده میکرومتر (PM_{10})، از ضریب همبستگی تاوی بی کندال استفاده شد. نتایج حاصل از این تحلیل در جدول (۴) آورده شده است. بر اساس نتایج این جدول، همبستگی آماری معناداری بین تمامی پارامترهای جوی و غلظت PM_{10} مشاهده می‌شود. در ادامه، به بررسی دقیق‌تر ارتباط هر یک از متغیرهای هواشناسی با غلظت PM_{10} پرداخته می‌شود.


همان‌طور که جدول (۴) نشان می‌دهد، بین غلظت ذرات معلق کمتر از ۱۰ میکرومتر (PM_{10}) و دید افقی همبستگی منفی و معناداری به میزان ۰.۳۰۰ - وجود دارد (سطح معناداری $Sig = 0.000$) این بدان معناست که با افزایش غلظت PM_{10} ، دید افقی کاهش می‌یابد. در واقع، دید افقی بیشترین همبستگی منفی را با PM_{10} در میان تمامی متغیرهای بررسی شده نشان داده است. تحلیل همبستگی بین میانگین روزانه PM_{10} برای ایستگاه‌های اهواز، کارون و باوی و میانگین روزانه جهت باد نیز همبستگی منفی و معناداری به میزان ۰.۰۳۴ - را نشان می‌دهد. اگرچه این همبستگی معنادار است، اما شدت آن بسیار ضعیف است. از سوی دیگر، بین غلظت PM_{10} و سرعت باد شهر اهواز، همبستگی مثبت و معناداری به میزان ۰.۰۶۱ با سطح اطمینان ۹۹٪ مشاهده شده است. این نتیجه نشان می‌دهد که افزایش سرعت باد با افزایش غلظت PM_{10} همراه است. یافته‌های این پژوهش با نتایج مطالعه [گارسا و همکاران \(۲۰۲۳\)](#) نیز همخوانی دارد. با توجه به موقعیت جغرافیایی شهر اهواز در مجاورت کانون‌های گردوغبار، این ارتباط قابل انتظار است. بررسی ضریب همبستگی نشان می‌دهد که بین میانگین دمای روزانه و ذرات معلق کمتر از ۱۰ میکرومتر، همبستگی مثبت ضعیفی به میزان ۰.۱۸۷ وجود دارد. این همبستگی در سطح معناداری ۰.۰۰۰ (با سطح اطمینان ۹۹.۹٪) قرار دارد. این یافته حاکی از آن است که به‌طورکلی، با افزایش دما، غلظت ذرات معلق نیز تمایل به افزایش دارد. این نتیجه با یافته‌های مطالعه [ملکی و همکاران \(۲۰۲۲\)](#) نیز همسو است. در این پژوهش، ارتباط میان ذرات معلق کمتر از ۱۰ میکرون (PM_{10}) با پارامترهای جوی، از جمله مجموع بارش روزانه و رطوبت نسبی، نیز بررسی شد. نتایج نشان داد که هر دو پارامتر بارش و رطوبت نسبی، ارتباط منفی و ضعیفی با غلظت PM_{10} دارند (به ترتیب با ضرایب همبستگی ۰.۱۲۵ - و ۰.۱۷۳ - و سطح معناداری بسیار بالا). این بدان معناست که با افزایش میزان بارش و رطوبت، غلظت آلاینده‌های PM_{10} معمولاً کاهش می‌یابد.

جدول (۴). بررسی همبستگی تاوی بی کنдал بین پارامتر (PM₁₀) و پارامترهای جوی

متغیرهای جوی	ضریب همبستگی اسپیرمن		ضریب همبستگی تاوی بی کنдал	
	ضریب همبستگی	سطح معناداری (Sig)	ضریب همبستگی	سطح معناداری (Sig)
بررسی همبستگی	۰.۴۰۸**	۰.۰۰۰	۰.۳۰۰**	۰.۰۰۰
ذرات معلق کمتر از ۱۰ میکرون (PM ₁₀)	۰.۰۴۸**	۰.۰۰۱	۰.۰۳۴**	۰.۰۰۱
با متغیرهای هواشناسی	۰.۰۹۴**	۰.۰۰۰	۰.۰۶۱**	۰.۰۰۰
دما	۰.۲۸۴**	۰.۰۰۰	۰.۱۸۷**	۰.۰۰۰
بارش	۰.۱۵۹**	۰.۰۰۰	۰.۱۲۵**	۰.۰۰۰
رطوبت نسبی	۰.۲۵۹**	۰.۱۶۹	۰.۱۷۳**	۰.۰۰۰

بررسی خروجی ضریب همبستگی اسپیرمن و تاوی-بی کنдал

در این مطالعه، برای بررسی همبستگی بین پارامترهای مختلف و ذرات معلق کمتر از ده میکرون، از دو ضریب همبستگی ناپارامتری اسپیرمن و تاوی-بی کنдал استفاده شد. هر دو ضریب، جهت و قدرت ارتباط بین متغیرها را نشان می‌دهند و نتایج حاصل از هر دو به‌طور کلی همسو هستند. باین حال، به‌طور معمول، مقادیر ضریب همبستگی اسپیرمن اندکی بزرگ‌تر از تاوی-بی کنдал است. نتایج نشان می‌دهد که بین پارامترهای سرعت باد و دما با ذرات معلق کمتر از ده میکرون همبستگی مثبت و معناداری وجود دارد، به این معنی که با افزایش سرعت باد و دما، غلظت ذرات معلق نیز افزایش می‌یابد. از سوی دیگر، بین پارامترهای دید افقی، جهت باد، بارش و رطوبت نسبی با ذرات کمتر از ده میکرون، همبستگی منفی و معناداری مشاهده شده است. این بدان معناست که با افزایش دید افقی، بارش و رطوبت نسبی و تغییر در جهت باد، غلظت ذرات معلق کاهش می‌یابد. به‌منظور نمایش بصری این روابط از نقشه حرارتی^{۳۲} ضرایب همبستگی اسپیرمن و تاوی بی کنдал استفاده شده است. نقشه‌های حرارتی توسط زبان برنامه‌نویسی پایتون و در فضای اسپایدر ترسیم گردیدند. این نقشه‌ها در اشکال (۷ و ۸) نشان داده شده‌اند. نقشه‌های حرارتی تهیه شده به‌وضوح الگوهای همبستگی را بین پارامترهای مورد مطالعه نمایش می‌دهند. بررسی نقشه‌های حرارتی با نتایج حاصل از جدول (۴) هماهنگی و مطابقت دارند. با نگاهی به نقشه‌های حرارتی در می‌یابیم که پارامتر ذرات معلق با متغیرهای هواشناسی بیشترین همبستگی را با دید افقی (۰.۴۲-) دارد که با رنگ آبی در نقشه نمایش داده شده است؛ نتایج این مطالعه با نتایج [باسکار و مهتا^{۳۳} \(۲۰۱۰\)](#) و [کایس و همکاران^{۳۴} \(۲۰۱۹\)](#)، [لیو و همکاران^{۳۵} \(۲۰۲۰\)](#) مطابقت دارد.

شکل (۷). نقشه حرارتی ضریب همبستگی اسپیرمن بین متغیرهای هواشناسی و PM₁₀³² Heat Map³³ Bhaskar et al³⁴ Kayes et al³⁵ Liu et al



شکل (۸). نقشه حرارتی ضریب همبستگی ناوی بی کندانال بین متغیرهای هواشناسی و PM_{10}


نمودار گلباد شهر اهواز با استفاده از داده‌های سرعت و جهت باد دوره مورد مطالعه به وسیله نرم‌افزار WRPLOT View ترسیم و خروجی نهایی آن با نرم‌افزار Google Earth pro ترسیم و ارائه شد تا الگوهای باد شهر اهواز را با توجه به موقعیت جغرافیایی به صورت دقیق‌تر نشان دهد. نمودار ۱۳ ساله گلباد شهر اهواز در شکل (۹) آورده شده است. همان‌طور که در شکل (۹) مشاهده می‌شود از جریانات ورودی به اهواز حدود ۱۳.۷ درصد آن‌ها دارای سرعت باد آرام و کمتر از ۰.۵ متر بر ثانیه و ۸۶.۳ درصد از جریانات دارای سمت و سرعت می‌باشند. از نظر فراوانی توزیع باد، بادهای دارای سرعت ۰.۵ تا ۲.۱ متر بر ثانیه دارای بیشترین فراوانی رخداد به میزان ۷۱.۵ درصد می‌باشد. باد غالب شهر اهواز در دوره مورد مطالعه با میزان ۲۲.۵ درصد از کل بادهای غربی می‌باشد. به‌طوری‌که ۱۸ درصد الگوی باد غالب با سرعت ۰.۵ تا ۲.۱ متر بر ثانیه، ۴ درصد باد غالب با سرعت ۲.۱ تا ۳.۶ متر بر ثانیه و ۰.۵ درصد از آن‌ها دارای سرعت ۳.۶ تا ۵.۷ متر بر ثانیه از طرف غرب می‌وزند. باد نایب غالب بادهای شمال غربی بوده و ۲۱ درصد از کل بادهای شامل می‌شود. از این جهت ۱۴ درصد بادهای با سرعت ۰.۵ تا ۲.۱ متر بر ثانیه و ۶ درصد از بادهای با سرعت ۲.۱ تا ۳.۶ متر بر ثانیه و حدود ۱ درصد از آن‌ها با سرعت ۳.۶ تا ۵.۷ متر بر ثانیه می‌وزند. از سایر جهتها نیز بادهای جنوبی و جنوب شرقی به میزان مساوی هرکدام مقدار ۱۰ درصد از بادهای شامل می‌شوند. در این جهت ۸ درصد از بادهای با سرعت ۰.۵ تا ۲.۱ متر بر ثانیه از طرف جنوب و جنوب شرقی اهواز می‌وزند. ۱.۵ درصد از جریانات ورودی از این جهات با سرعت ۲.۱ تا ۳.۶ متر بر ثانیه و ۰.۵ درصد از بادهای وزیده شده از دو جهت جنوبی و جنوب شرقی به اهواز نیز دارای سرعتی برابر با ۳.۶ تا ۵ متر بر ثانیه می‌باشند. به صورت کلی نیز از نظر فراوانی توزیع سرعت باد، بادهای دارای سرعت ۰.۵ تا ۲.۱ متر بر ثانیه با مقدار ۷۱.۵ درصد از کل بادهای ثبت شده در این شهر بیشترین فراوانی وقوع را داشته‌اند.




شکل (۹). نمودار گلباد شهر اهواز، کارون، باوی در دوره مورد مطالعه

سری زمانی پارامترهای مورد بررسی

سری زمانی پارامترهای مورد مطالعه هواشناسی (دید افقی، دما، بارش، سرعت باد، جهت باد، رطوبت نسبی) و آلاینده‌ی هوای ذرات معلق کمتر از ده میکرون برای بازه زمانی (۱۳۹۰-۱۴۰۲) با استفاده از زبان برنامه‌نویسی پایتون ترسیم شد که در اشکال (۱۰ و ۱۱) ارائه شده است.



شکل (۱۰). نمودار سری زمانی پارامترهای هواشناسی منطقه مورد مطالعه (۲۰۱۱-۲۰۲۳)




شکل (۱۱). نمودار سری زمانی ذرات معلق کمتر از ده میکرون و دید افقی منطقه مورد مطالعه (۲۰۱۱-۲۰۲۳)


شبکه عصبی پرسپترون چندلایه^{۳۶} (MLP) برای پارامتر pm_{10} شهر اهواز دوره‌ی ۱۲ ساله (2011/03/21 – 2023/06/30) هدف ما از انجام مدل شبکه عصبی پرسپترون چندلایه (MLP) پیش‌بینی گام‌های زمانی آینده برای پارامتر ذرات معلق کمتر از ده میکرون (PM_{10}) شهر اهواز بوده است. به منظور ترسیم شبکه عصبی مصنوعی بر اساس مدل MLP برای پارامترهای ذرات معلق کمتر از ده میکرون شهر اهواز در بازه زمانی ۱۲ ساله (۱۳۹۰ – ۱۴۰۲) از زبان برنامه‌نویسی پایتون و فضای برنامه‌نویسی اسپایدر استفاده شد. ابتدا کتابخانه‌های کاربرد و مورد نیاز برای انجام روش شبکه عصبی MLP فراخوانی

³⁶ Multi Layer Perceptron


شدند. سپس از داده‌های هواشناسی که شامل دید افقی، سرعت باد، جهت باد، بارش، دما و رطوبت نسبی و همچنین داده‌های ذرات معلق کمتر از ده میکرون به‌عنوان داده‌های ورودی مدل استفاده شد. در ابتدای امر پس از ورود داده‌ها به مدل با توجه به هدف پژوهش که پیش‌بینی ذرات معلق کمتر از ده میکرون (PM_{10}) برای بازه زمانی موردنظر بود، داده‌های ورودی به دو بخش ورودی و خروجی تقسیم شدند؛ به‌گونه‌ای که داده‌های هواشناسی به‌عنوان ورودی (features) و داده‌های ذرات معلق کمتر از ده میکرون نیز به‌عنوان داده‌های خروجی (target) تعریف شدند. سپس داده‌ها را به دو بخش آموزش و آزمون به نسبت ۸۰ درصد برای آزمون شبکه و ۲۰ درصد جهت آموزش مدل تقسیم کردیم. مدل با استفاده از این داده‌ها و با بررسی لایه‌های مختلف آموزش داده شد و بهترین خروجی برای آزمون انتخاب گردید. ۲۰ درصد داده‌های باقی‌مانده نیز به‌منظور ارزیابی و آزمون مدل استفاده گردید. نتایج آموزش و ارزیابی و آزمون مدل در اشکال (۱۲) تا (۱۴) ارائه شده است. عملکرد بخش آموزش شبکه عصبی بدین‌صورت بوده که میزان میانگین مربعات خطای (MSE) آن برابر با ۰.۰۰۳۴ بوده است و همچنین مقدار خطای روی داده‌های اعتبارسنجی آن نیز برابر با val_loss: 0.0012 بوده است که نمودار داده‌های بخش آموزش مدل در شکل (۱۲) ارائه شده است. همچنین برای بخش آزمون نیز اعتبارسنجی به‌دست‌آمده برابر با mse_mlp=0.0051 و val_loss: 0.0012 بوده است؛ که مقدار کم آن‌ها بیانگر عملکرد مناسب مدل شبکه عصبی است. برای بخش پیش‌بینی نیز مقادیر تابع خطا، میانگین مربعات خطا محاسبه شدند که در شکل (۱۸) قابل‌دسترسی هستند.



شکل (۱۲). آموزش مدل شبکه عصبی MLP برای PM_{10} شهر اهواز، کارون، باوی (۲۰۱۱-۲۰۲۳)




شکل (۱۳). آزمون مدل شبکه عصبی MLP برای PM_{10} شهر اهواز، کارون، باوی (۲۰۱۱-۲۰۲۳)



شکل (۱۴). معیارهای ارزیابی عملکرد پیش‌بینی ۳۱ گام آینده‌ی مدل شبکه عصبی پرسپترون چند لایه


در روند شبکه‌ی عصبی MLP پس از طی مراحل آموزش و آزمایش مدل به مرحله‌ی اصلی که هدف ما از انجام این تحقیق بوده می‌پردازیم. در این مرحله با توجه به گام‌های زمانی موردنظر جهت انجام فرایند پیش‌بینی، به پیش‌بینی میزان ذرات معلق کمتر از ده میکرون برای گام‌های پیش رو می‌پردازیم. در این شبکه، با ۳۱ گام به پیش‌بینی یک ماه آینده پرداختیم که در شکل (۱۵) خروجی آن نشان داده شده است. همچنین مقایسه‌ی مقادیر واقعی و پیش‌بینی شده‌ی شبکه نیز در شکل (۱۶) ارائه شده است در این نمودار محور افقی (X) زمان و محور عمودی (Y) نیز مقادیر داده‌های واقعی و پیش‌بینی شده را نشان می‌دهد. داده‌های واقعی با رنگ آبی و داده‌های پیش‌بینی شده با رنگ قرمز مشخص شده‌اند که هر قدر این دو به هم نزدیک‌تر باشند بیانگر عملکرد بهتر مدل می‌باشد که در اینجا تا حد مطلوبی به هم نزدیک می‌باشند. بررسی نمودار موجود در شکل (۱۶) بیانگر تطابق حدودی و نزدیک به هم داده‌های واقعی و داده‌های پیش‌بینی شده PM₁₀ می‌باشد. نمودار پراکنش آن‌ها نیز در شکل (۱۷) مشخص کننده‌ی این است که مقادیر واقعی و پیش‌بینی شده نسبت به هم به چه صورتی عمل می‌کنند. در این نمودار هر نقطه بیانگر یک داده‌ی واقعی و پیش‌بینی می‌باشد که هر قدر این نقاط به خط نزدیک‌تر باشند، بیانگر عملکرد بهتر مدل می‌باشد و فاصله‌ی زیاد آن‌ها از خط نشان‌دهنده‌ی عملکرد نامناسب شبکه عصبی موردنظر می‌باشد. در اینجا با توجه به نمودار شکل (۱۷)، برخی از نقاط ما روی خط و سایر نقاط نیز به فاصله‌های حدوداً نزدیکی از خط قرار گرفته‌اند که به صورت کلی حاکی از عملکرد قابل قبول مدل پرسپترون چندلایه‌ی طراحی شده می‌باشد. همچنین مقادیر معیارهای ارزیابی عملکرد مقایسه‌ی داده‌های پیش‌بینی و واقعی مدل شبکه عصبی مقادیر معیار ریشه میانگین مربعات خطا (RMSE) و میانگین مطلق خطای (MAE) داده‌های پیش‌بینی مدل در شکل (۱۸) ارائه شده است. معیارهای ارائه شده نشان دهنده‌ی عملکرد مطلوب مدل شبکه عصبی پرسپترون چندلایه‌ی طراحی شده برای پیش‌بینی ذرات معلق کمتر از ده میکرون است.



شکل (۱۵). پیش‌بینی ۳۱ گام آینده توسط شبکه عصبی مصنوعی MLP برای (PM₁₀) شهر اهواز، کارون، باوی (۲۰۱۱-۲۰۲۳)



شکل (۱۶). نمودار مقادیر پیش‌بینی PM₁₀ توسط شبکه عصبی مصنوعی MLP و مقایسه با داده‌های واقعی شهر اهواز



شکل (۱۷). نمودار پراکنش داده‌های واقعی و پیش‌بینی شده توسط مدل MLP



شکل (۱۸). معیارهای ارزیابی عملکرد مقایسه‌ی داده‌های پیش‌بینی و واقعی مدل شبکه عصبی پرسپترون چند لایه

نتیجه‌گیری و پیشنهادها

در زمینه‌ی پیش‌بینی آلودگی هوا، پیچیدگی و عدم قطعیت‌های مربوط به داده‌های محیطی و اتمسفری از مهم‌ترین چالش‌های موجود محسوب می‌شوند. روش‌های شبکه عصبی و یادگیری ماشین در این زمینه عملکرد مناسبی داشته‌اند. در این مطالعه نیز شبکه‌های عصبی پرسپترون چند لایه جهت پیش‌بینی ذرات معلق کمتر از ده میکرون (PM_{10}) استفاده شد. در این پژوهش با استفاده از روش‌های آماری و شبکه‌ی عصبی پرسپترون چند لایه (MLP) به بررسی و سنجش رابطه‌ی بین پارامترهای هواشناسی (دیدافقی، جهت باد، دما، رطوبت نسبی، بارش، سرعت باد) با ذرات معلق کمتر از ده میکرون در شهر اهواز پرداخته شد. داده‌های مورد استفاده شامل داده‌های روزانه‌ی ۱۲ ساله (۱۳۹۰-۱۴۰۲) بودند و به پیش‌بینی گام‌های زمانی آینده‌ی PM_{10} نیز پرداخته شد.

نتایج این بررسی‌ها نمایانگر ارتباط پایایی بین ذرات معلق کمتر از ده میکرون و داده‌های هواشناسی بود. به‌طور خاص نتایج نشان‌دهنده‌ی این بودند که: بین دیدافقی و ذرات معلق کمتر از ده میکرون ارتباط معکوسی وجود دارد و افزایش ذرات آلاینده موجب کاهش افق دید می‌شود؛ و همچنین پارامتر بارش و رطوبت نسبی نیز ارتباط معکوسی با PM_{10} دارند به‌نحوی که افزایش بارش موجب کاهش ذرات آلاینده در جو می‌شود. بین دما و سرعت باد با PM_{10} ارتباط مستقیمی وجود دارد به‌طوری که در فصول گرم سال احتمال رخداد و افزایش این آلاینده‌ها در جو بیشتر می‌باشد که خشکی مناطق مستعد خیزش آلاینده در این امر مؤثر می‌باشد. سرعت باد نیز با توجه به موقعیت جغرافیایی کم ارتفاع شهر اهواز و قرارگیری در مناطق مستعد خیزش ذرات معلق و وجود صنایع و پالایشگاه‌های آلاینده موجب کاهش کیفیت هوای شهر می‌شود. باتوجه به نتایج نمودار گلباد و جهت بادهای غالب و همچنین ضرایب همبستگی، میزان کم همبستگی که بین سرعت باد و آلاینده PM_{10} نشان می‌دهد که بین میزان وقوع آلودگی و سرعت باد ارتباط کمی وجود دارد و نقش سایر عوامل از جمله کانون‌های محلی صنایع و کارخانجات، پتروشیمی و نفت و گاز و... در ایجاد آلودگی هوای شهر اهواز پررنگ‌تر می‌باشد. نقشه‌های حرارتی ضرایب همبستگی اسپیرمن و تاوی بی کندال به‌وضوح الگوهای همبستگی بین متغیرهای هواشناسی

مورد مطالعه و با ذرات آلاینده‌ی PM_{10} را به تصویر کشیدند که هماهنگ بودن خروجی آن‌ها با جدول ضرایب همبستگی، جدول (۴)، تأییدی بر نتایج آماری و عددی به‌دست‌آمده می‌باشد.

نتایج شبکه‌ی عصبی پرسپترون چند لایه نشان داد که شبکه توانسته عملکرد و خروجی مطلوبی را ارائه دهد و برای گام‌های زمانی آینده پیش‌بینی قابل قبولی را داشته باشد. این نتایج به‌صورت نمودارهای مختلف ارائه شدند.

مقایسه‌ی نتایج دریافتی با سایر تحقیقات نشان‌دهنده‌ی نتایج مشابه با آن‌ها می‌باشد اما با توجه به منطقه‌ی مورد مطالعه شدت آن‌ها می‌تواند متفاوت باشد. از جمله تحقیقات مرتبط می‌توان به تحقیقات [باسکار و مهتا \(۲۰۱۰\)](#) و [کایس و همکاران \(۲۰۱۹\)](#)، [لیو و همکاران \(۲۰۲۰\)](#)، [ملکی و همکاران \(۲۰۲۲\)](#)، [گارسا و همکاران \(۲۰۲۳\)](#)، [عالی محمودی سراب و همکاران \(۱۳۹۷\)](#)، [زنگویی و اسداله فردی \(۱۳۹۶\)](#) و... اشاره کرد.

از محدودیت‌های این پژوهش می‌توان به دسترسی سخت به داده‌های مورد نیاز و نامرتب بودن آن‌ها اشاره کرد.

برای مطالعات آینده پیشنهاد می‌شود از داده‌های متنوع اقلیمی و سایر آلاینده‌های جوی مانند تابش خورشید، فشار هوا، رطوبت خاک، پوشش گیاهی، ذرات معلق کمتر از 2.5 میکرون، مونوکسید کربن، دی‌اکسید گوگرد و... استفاده شود.

تأثیر عواملی از قبیل ترافیک، تغییرات کاربری زمین و... سنجیده شود. در همچنین پیشنهاد می‌شود از پایگاه داده‌های ماهواره‌ای و از داده‌ها و تصاویر ماهواره‌های سنجنده‌ی مودیس و سنتینل ۵ پی نیز استفاده شود. از روش‌های متنوع‌تر شبکه عصبی مصنوعی از جمله روش‌های LSTM, GRU و روش‌های تلفیقی نیز بهره گرفته شود تا نتایج نهایی با دقت بالاتری ارائه شوند و به درک کامل‌تر و مناسب‌تری از عوامل تأثیرگذار بر آلودگی هوا و پیش‌بینی آن دست‌یافت. در زمینه‌ی آگاهی بخشی جمعی در خصوص آلودگی هوا و تأثیر آن بر سلامتی جامعه تلاش شود تا در شرایط آلودگی هوا شهروندان کمتر در معرض هوای آلوده قرار گیرند. توجه به منابع انتشار آلاینده‌ها و ارائه‌ی راهکارهای مناسب نیز در مدیریت آن‌ها می‌تواند نقش مؤثری داشته باشد. با توجه به هدف مطالعه‌ی ما در نهایت برای پیش‌بینی گام‌های آینده‌ی مدل اقدام شد که با در نظر گرفتن پیش‌بینی یک ماه آینده برای مدل مورد نظر ۳۱ گام آینده برای پیش‌بینی منظور شد که خروجی آن در شکل (۱۵) ارائه شده است. با توجه به اشکال (۱۴ و ۱۸) که میزان اعتبار سنجی پیش‌بینی مدل و اعتبارسنجی مقایسه پیش‌بینی با داده‌های واقعی ارائه شده است مشخص می‌کند که مدل ما از اعتبار مناسبی برخوردار بوده و می‌توان بیان داشت که گام‌های آینده را به‌خوبی پیش‌بینی کرده است که از قوت‌های استفاده از روش‌های شبکه عصبی برای پیش‌بینی می‌توان به دقت بالا در ارزیابی و پیش‌بینی گام‌های زمانی مورد نظر اشاره کرد. خصوصاً در زمینه‌ی مباحث مربوط به آلودگی هوا که از موضوعات بسیار حائز اهمیت و چالشی محسوب می‌شود.

به‌صورت کلی می‌توان دریافت که عوامل متعددی در رخداد و بروز آلاینده‌های جوی خصوصاً ذرات معلق کمتر از ده میکرون نقش دارند که با مدیریت بهینه می‌توان میزان رخداد و بروز آن‌ها را ساماندهی کرد و کیفیت هوای محیط را افزایش داد.

منابع

بساک، عاطفه؛ حجازی زاده، زهرا؛ حیدری تاشه کبود، اکبر (۱۴۰۲). واکاوی سری زمانی آلاینده جوی PM_{10} در شهر جهانی شوشتر با استفاده از روش‌های آماری (۲۰۲۳-۲۰۱۴). دومین کنفرانس ملی و اولین کنفرانس بین‌المللی روز آینده، شهر آینده، تهران.

حسینی، سید اسعد، مسگری، ابراهیم، سالاری فنودی، محمدرضا. (۱۳۹۵). شبکه‌های عصبی مصنوعی در آب‌وهواشناسی. زنجان: آذرکک.

زنگویی، حسین؛ اسداله فردی، غلامرضا (۱۳۹۶). پیش‌بینی آلودگی PM_{10} هوای شهر مشهد با استفاده از شبکه‌های عصبی مصنوعی MLP و مدل زنجیره مارکوف. تحقیقات کاربردی علوم جغرافیایی، ۱۷(۴۷)، ۳۹-۵۹.

سالنامه آماری استان خوزستان، ۱۳۹۸

- صادقی، حسین؛ خاکسار آستانه، سمانه (۱۳۹۳). پیش‌بینی کوتاه‌مدت آلودگی ذرات معلق شهر اهواز با کمک شبکه‌های عصبی. *پژوهش‌های محیط‌زیست*، ۵(۹)، ۱۷۷-۱۸۶.
- عالی محمودی سراب، سجاده؛ معیری، محمدهادی؛ شتایی جویباری، شعبان؛ راشکی، علیرضا (۱۳۹۷). برآورد میزان آلودگی هوا (PM_{10}) با استفاده از داده‌های آب و هوایی (مطالعه موردی: شهرستان اهواز). *محیط‌زیست طبیعی، منابع طبیعی/ایران*، ۷۱(۳)، ۳۸۵-۳۹۷. doi: 10.22059/JNE.2018.221268.1280
- عساکره، حسین. (۱۳۹۰). *میانی اقلیم‌شناسی آماری*. زنجان، چاپ اول: دانشگاه زنجان.
- قربانی سالخورد، رضوان؛ مباحثی، محمدرضا؛ رحیم زادگان، مجید (۱۳۹۱). روشی سریع در برآورد غلظت ذرات معلق با استفاده از سنجنده مودیس: یک مطالعه موردی در تهران، *مجله پژوهشی حکیم*، ۱۵(۲)، ۱۶۶-۱۷۷.
- کیخسروی، سعید؛ نژادکورکی، فرهاد؛ امین طوسی، محمود (۱۳۹۸). ارزیابی دقت شبکه‌های عصبی مصنوعی در پیش‌بینی گردوغبار کارخانه سیمان سبزوار، *فصلنامه پژوهش در بهداشت محیط*، ۵(۱)، ۴۳-۵۲.
- مهرجو، فرزاد؛ باغخانی پور، محمدصابر؛ علم، امیر (۲۰۲۳). بررسی آلودگی هوای ناشی از صنعت فروسیلیس (مطالعه موردی: کارخانه فروآلیاژ ایران، لرستان). *مخاطرات محیط طبیعی*، ۱۲(۳۷)، ۱۱۷-۱۳۲.
- ویژگی‌های جغرافیایی استان خوزستان <https://khzmet.ir/image/climakh.pdf>
- هدایت زاده، فریبا؛ ایلدرمی، علیرضا؛ حسن‌زاده، نسرين (۱۳۹۸). تحلیل کیفیت هوا براساس ذرات معلق $PM_{2.5}$ و PM_{10} با دو روش USEPA-AQI و IND-AQI و فاکتور EF در شهر اهواز در سال‌های ۱۳۹۵ و ۱۳۹۶. *مجله مهندسی بهداشت محیط*، ۷، ۷۵-۷۷.
- Adil, M., Ullah, R., Noor, S., & Gohar, N. (2020). Effect of number of neurons and layers in an artificial neural network for generalized concrete mix design. *Neural computing and applications*, 34(11), 8355-8363.
- Alimahmoodi Sarab, S., Shataee Jouybari, S., & Rashki, A. (2018). The Estimate of Dust Concentration Using of Weather Variable (A Case study: Ahvaz City). *Journal of Natural Environment*, 71(3), 385-397. doi: 10.22059/jne.2018.221268.1280. (in Persian)
- Asaei-Moamam, Z. S., Safi-Esfahani, F., Mirjalili, S., Mohammadpour, R., & Nadimi-Shahraki, M. H. (2023). Air quality particulate-pollution prediction applying GAN network and the Neural Turing Machine. *Applied Soft Computing*, 147, 110723.
- Baawain, M. S., & Al-Serhi, A. S. (2014). Systematic approach for the prediction of ground-level air pollution (around an industrial port) using an artificial neural network. *Aerosol and air quality research*, 14(1), 124-134.
- Bhaskar, B. V., & Mehta, V. M. (2010). Atmospheric particulate pollutants and their relationship with meteorology in Ahmedabad. *Aerosol and Air Quality Research*, 10(4), 301-315.
- Biancofiore, F., Busilacchio, M., Verdecchia, M., Tomassetti, B., Aruffo, E., Bianco, S., ... & Di Carlo, P. (2017). Recursive neural network model for analysis and forecast of PM_{10} and $PM_{2.5}$. *Atmospheric Pollution Research*, 8(4), 652-659.
- Bosak, Atefeh., hejazizadeh, Zahra., Heydari Tashekaboud, Akbar. (2024). Analyzing the time series of PM_{10} air pollution in Shushtar International City using statistical methods (2014-2023). The second national and first international conference of futures day, futures city. Tehran. (in Persian)
- Cabaneros, S. M., Calautit, J. K., & Hughes, B. R. (2019). A review of artificial neural network models for ambient air pollution prediction. *Environmental Modelling & Software*, 119, 285-304.
- Carnevale, C., Pisoni, E., & Volta, M. (2010). A non-linear analysis to detect the origin of PM_{10} concentrations in Northern Italy. *Science of the Total Environment*, 409(1), 182-191.
- Dong, J., Goodman, N., & Rajagopalan, P. (2023). A Review of Artificial Neural Network Models Applied to Predict Indoor Air Quality in Schools. *International Journal of Environmental Research and Public Health*, 20(15), 6441.
- Eslamloueyan, R., & Khademi, M. H. (2009). Estimation of thermal conductivity of pure gases by using artificial neural networks. *International Journal of Thermal Sciences*, 48(6), 1094-1101.

- Garsa, K., Khan, A. A., Jindal, P., Middey, A., Luqman, N., Mohanty, H., & Tiwari, S. (2023). Assessment of meteorological parameters on air pollution variability over Delhi. *Environmental Monitoring and Assessment*, 195(11), 1315.
- Ge, R., Kuditipudi, R., Li, Z., & Wang, X. (2018). Learning two-layer neural networks with symmetric inputs. *arXiv preprint arXiv:1810.06793*.
- Grivas, G., & Chaloulakou, A. (2006). Artificial neural network models for prediction of PM₁₀ hourly concentrations, in the Greater Area of Athens, Greece. *Atmospheric environment*, 40(7), 1216-1229.
- Hedayatzadeh F, Ildoromi A, Hassanzadeh N. Analysis of air quality based on particulate matter (PM_{2.5} and PM₁₀) by using two methods USEPA-AQI and IND-AQI and EF Factor in Ahwaz city in 2016 and 2017. *jehe* 2020; <https://doi.org/10.29252/jehe.0.57>. (in Persian)
- Heidar Maleki, Armin Sorooshian, Khan Alam, Ahmad Fathi, Tammy Weckwerth, Hadi Moazed, Arsalan Jamshidi, Ali Akbar Babaei, Vafa Hamid, Fatemeh Soltani & Gholamreza Goudarzi (2022). The impact of meteorological parameters on PM₁₀ and visibility during the Middle Eastern dust storms. *Journal of Environmental Health Science and Engineering*, 20(1), 495-507.
- Hoang, A. T., Nižetić, S., Ong, H. C., Tarelko, W., Le, T. H., Chau, M. Q., & Nguyen, X. P. (2021). A review on application of artificial neural network (ANN) for performance and emission characteristics of diesel engine fueled with biodiesel-based fuels. *Sustainable Energy Technologies and Assessments*, 47, 101416.
- <http://aliper.persiangig.com/page8.html>
- <https://almaprime.com/>
- <https://blog.faradars.org>
- <https://www.cdc.gov/>
- <https://www.eea.europa.eu/themes/air/health-impacts-of-air-pollution>
- <https://www.epa.gov/criteria-air-pollutants>
- https://www.who.int/health-topics/air-pollution#tab=tab_1
- Kayes, I., Shahriar, S. A., Hasan, K., Akhter, M., Kabir, M. M., & Salam, M. A. (2019). The relationships between meteorological parameters and air pollutants in an urban environment. *Global Journal of Environmental Science and Management*, 5(3), 265-278.
- Keykhosravi, S. S., Nejadkoorki, F., & Amintoosi, M. (2019). Estimation of Artificial Neural Networks (MLP and RBF) Accuracy in Anticipation of the Dust of the Sabzevar Cement Factory. *Journal of Research in Environmental Health*, 5(1), 43-52. doi: 10.22038/jreh.2019.38083.1277. (in Persian)
- Kumar, L. K. L., & Kumar, G. K. D. G. (2024). A Prediction Model for Air Pollution using Artificial Neural Networks.
- Liu, J. B., Zheng, Y. Q., & Lee, C. C. (2024). Statistical analysis of the regional air quality index of Yangtze River Delta based on complex network theory. *Applied Energy*, 357, 122529. <https://www.sciencedirect.com/science/article/abs/pii/S0306261923018937#preview-section-introduction>
- Liu, Y., Zhou, Y., & Lu, J. (2020). Exploring the relationship between air pollution and meteorological conditions in China under environmental governance. *Scientific reports*, 10(1), 14518.
- López-Gonzales, J. L., Gómez Lamus, A. M., Torres, R., Canas Rodrigues, P., & Salas, R. (2023). Self-Organizing Topological Multilayer Perceptron: A Hybrid Method to Improve the Forecasting of Extreme Pollution Values. *Stats*, 6(4), 1241-1259.
- Maleki, H., Sorooshian, A., Goudarzi, G., Baboli, Z., Tahmasebi Birgani, Y., & Rahmati, M. (2019). Air pollution prediction by using an artificial neural network model. *Clean technologies and environmental policy*, 21, 1341-1352.
- Mehrjo, F., Baghkhani-pour, M., & Alam, A. (2023). Investigating air pollution caused by the ferrosilicon industry (Case study: Iran Ferroalloy Factory, Lorestan). *Journal of Natural Environmental Hazards*, 12(37), 117-132. doi: 10.22111/jneh.2023.43635.1923. (in Persian)

- Mishra, P., Pandey, C. M., Singh, U., Gupta, A., Sahu, C., Keshri, A. (2019). Descriptive statistics and normality tests for statistical data. *Annals of cardiac anesthesia*, 22(1), p. 67. https://doi.org/10.4103%2Faca.ACA_157_18
- Moayedi, H., Mosallanezhad, M., Rashid, A. S. A., Jusoh, W. A. W., & Muazu, M. A. (2020). A systematic review and meta-analysis of artificial neural network application in geotechnical engineering: theory and applications. *Neural Computing and Applications*, 32, 495-518.
- Mosley, S. (2014). Environmental history of air pollution and protection. In *The basic environmental history* (pp. 143-169). Cham: Springer International Publishing.
- Qorbani Salkhord R, Mobasheri MR, Rahimzadehgan M. A Fast Method for Assessment of PM₁₀ Concentration Using MODIS Images, a Case Study in Tehran. *Hakim Research Journal* 2012;15(2):166-177. (in Persian)
- Ramalho, O., Malingre, L., Sivanantham, S., Little, J. C., & Mandin, C. (2019). Machine learning and statistical models for predicting indoor air quality. *Indoor Air*, 29(5), 704-726.
- Rodriguez, S., Querol, X., Alastuey, A., Kallos, G., & Kakaliagou, O. (2001). Saharan dust contributions to PM₁₀ and TSP levels in Southern and Eastern Spain. *Atmospheric Environment*, 35(14), 2433-2447.
- sadeghi, H., & khaksar, S. (2015). Neural Network Model for Short Term Prediction of PM₁₀ Pollution in Ahvaz City. *Environmental Researches*, 5(9), 177-186. (in Persian)
- Shams a , Seyedeh Reyhaneh. Kalantary b , Saba. Jahani c , Ali. Shams d , Seyed Mohammad Parsa. Kalantari e , Behrang. Singh a , Deveshwar. Moeinnadini f , Mazaher. Choi, Yunsoo. (2023). Assessing the effectiveness of artificial neural networks (ANN) and multiple linear regressions (MLR) in forecasting AQI and PM₁₀ and evaluating health impacts through AirQ+ (case study: Tehran). *Environmental Pollution*, 338, 122623.
- Subramaniam, S., Raju, N., Ganesan, A., Rajavel, N., Chenniappan, M., Prakash, C., ... & Dixit, S. (2022). Artificial intelligence technologies for forecasting air pollution and human health: a narrative review. *Sustainability*, 14(16), 9951.
- Taheri, S., & Razban, A. (2021). Learning-based CO₂ concentration prediction: Application to indoor air quality control using demand-controlled ventilation. *Building and Environment*, 205, 108164.
- Ukaogo, P. O., Ewuzie, U., & Onwuka, C. V. (2020). Environmental pollution: causes, effects, and the remedies. In *Microorganisms for sustainable environment and health* (pp. 419-429). Elsevier.
- Wang, Z., Tham, M. T., & JULIAN MORRIS, A. (1992). Multilayer feedforward neural networks: a canonical form approximation of nonlinearity. *International Journal of Control*, 56(3), 655-672.
- Wei, W., Ramalho, O., Malingre, L., Sivanantham, S., Little, J. C., & Mandin, C. (2019). Machine learning and statistical models for predicting indoor air quality. *Indoor Air*, 29(5), 704-726.
- Yadav, V., Yadav, A. K., Singh, V., & Singh, T. (2024). Artificial neural network an innovative approach in air pollutant prediction for environmental applications: A review. *Results in Engineering*, 102305.
- Zangooei, Hossein., asadollahfardi. (2017). PM₁₀ Air pollution in mashhad city using artificial neural network and makov chain model. *jgs* 2017; 17 (47) :39-59. (in Persian)
- Zhang, H., Srinivasan, R., & Yang, X. (2021). Simulation and analysis of indoor air quality in florida using time series regression (tsr) and artificial neural networks (ann) models. *Symmetry*, 13(6), 952.