



## Journal of Environmental Research

Vol. 13, No. 26, Autumn & Winter 2023

Journal Homepage: [www.iraneiap.ir](http://www.iraneiap.ir)  
Print ISSN: 2008-9597 Online ISSN 2008-9590

### Predicting and Modeling of Daily Concentration of Particulate Matter (PM<sub>2.5</sub> & PM<sub>10</sub>) in Hamadan Winter with Multilayer Perceptron Neural Network

Document Type  
Research Paper

Received  
2022/09/21

Accepted  
2023/04/15

Eisa Solgi<sup>1\*</sup>, Mohamad Parsi Mehr<sup>2</sup>

1 Associate Professor of Department of Environment, Faculty of Natural Resources and Environment, Malayer University, Malayer, Hamedan, Iran

2 Ph.D student of Environmental Pollution, Faculty of Natural Resources and Environment, Malayer University, Malayer, Hamedan, Iran

DOI: 10.22034/eiap.2023.169982

#### Abstract

In recent years, the number of days with high concentrations of particulate matter (PM) has been increased in Hamadan city. Since this phenomenon is more prevalent in winter, in this research, an optimal artificial neural network model has been proposed to predict the concentration of PM in winter. To investigate the concentration of winter PM in Hamedan, the winter data of air pollutants and meteorological parameters were analyzed with Pearson correlation. Then, according to the results, Multilayer Perceptron Artificial Neural Network (MLP-ANN) with an optimized structure based on the training and testing was used to predict the daily concentration of PM<sub>2.5</sub> & PM<sub>10</sub>. Among meteorological and air quality factors, air quality variables were more correlated with winter PM concentration. MLP-ANN predicted PM<sub>2.5</sub> in a model with 3 input layers, 1 hidden layer and 4 middle layer processors with R: 0.93 and also with 1 input layer, 1 hidden layer and 5 middle layer processors with R: 0.92. Predicted PM<sub>10</sub>. Alvand Mountains are located between the prevailing wind in the western parts of the Iran and Hamedan, therefore the effect of meteorological factors on PM concentration is low. Also, the increase of winter PM in the city can be due to increased fuel consumption in winter. The MLP-ANN tool with the lowest and most accessible data has the ability to predict PM early and can be used to control PM effects.

**Keywords:** Artificial Intelligence, Environmental Assessment, Environmental Pollution, Air Pollution, Hamedan

\* Corresponding author

Email: [e.solgi@malayeru.ac.ir](mailto:e.solgi@malayeru.ac.ir)

## Introduction

With the physical development of the city, the increase in population, the development of industries, and the increase in the number of cars, air pollution, especially particulate matter (PM) in Hamadan city, is rapidly expanding and has recently become a serious problem (Asl et al., 2018; Hoseinzahed et al., 2012). This city has cold winters (Zare et al., 2011). Therefore, the use of fuel for heating, in addition to industries and transportation, increases significantly in this season and causes an increase in air pollution in winter compared to other seasons. Also, in recent years, the phenomenon of temperature inversion (thermal inversion) has happened several times in the winter season in this city, and it has aggravated air pollution. Temperature inversion is one of the main reasons for increasing winter pollution in cities with cold climates (Janhäll et al., 2006). Considering the location of Hamedan city on the slopes of Alvand mountain and the way of expansion and establishment of the Zagros highlands, prevents the entry of the western air front into this area (Zare et al., 2011). The impact of the prevailing meteorological variables in western Iran, such as western winds, on the city limits, has decreased. The influence of the prevailing meteorological variables in western Iran, such as western winds, on the city limits has decreased. The effect of wind on PM in the western regions of Iran is significant from two aspects. At first glance, the ability to carry PM by the wind from the western and southern regions and cause pollution draws attention to the fact that this phenomenon in susceptible regions can be limited to a few cases per year. But in general, meteorological factors such as wind and rain have a significant impact on transporting and eliminating air pollution (Tecer et al., 2008). In cities surrounded by mountains like Hamedan, the risk of air pollution is much more serious because the potential of air pollution dispersion by these factors is less. Therefore, early modeling and forecasting of air pollution, especially winter PM values of Hamedan city is of particular importance. Early prediction of winter PM concentration can be a great help to city managers and planners to deal with the harmful effects of city air pollution.

## Methodology

Hamedan province is located in an area of 20,172 square kilometers, in the west of Iran, at the foot of Alvand Mountain and at an altitude of 1,800 meters above sea level, and Hamedan city covers 2,831 square kilometers of this province, Figure (1).

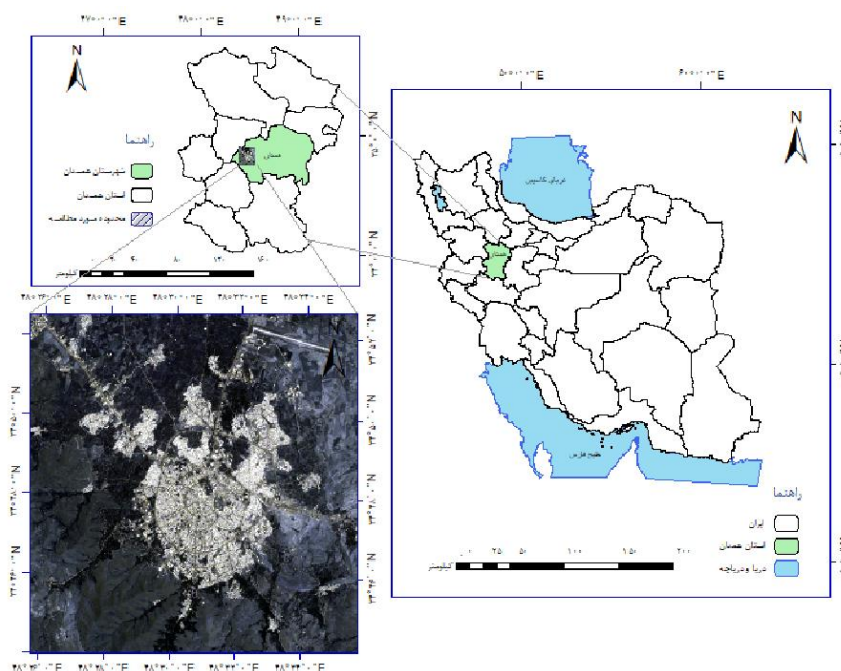


Figure (1): The study area

In this research, meteorological data and concentration of air pollutants including O<sub>3</sub> (ppb), CO (ppm), No<sub>x</sub> (ppb), and SO<sub>2</sub> (ppb) were used to investigate, model and predict the concentration of PM<sub>2.5</sub> and PM<sub>10</sub>.

Due to the fact that in cities with cold winters due to the increased consumption of fossil fuels, the risk of air pollution in winter is higher and the data for this season were used (Ilten & Selici, 2008).

The design of the network is based on the variables affecting the concentration of PM in the past, in the form of different structures of different variables in the input layer. In each of the structures, the input information after processing, from the way output of the neurons of the first layer, to the neurons of the next layers and finally, if it is acceptable, it is transferred to the network output. Otherwise, with the propagation of the calculation error, it returns to the previous layers and the calculations are repeated until an acceptable result is obtained (Parsimehr et al., 2018). In order to increase the speed of information processing and not stop the network at local minimums, normalized information was used as the input of the network. To model the artificial neural network, first a percentage of the data is used for training the network, then in the next step, the remaining percentage of the data is used for validation and testing of the network.

In this research, 70% of the data was used for training and the remaining 30% was used for validating and testing the network (Mohammadi et al., 2017). Then the predicted data is compared with the real data and the error amount is calculated.

### Results and Discussion

In this research, multi-layer Perceptron artificial neural network was used to model and predict winter PM concentration in Hamedan city, and based on the results of this research, multi-layer Perceptron artificial neural network method had good ability and accuracy to model and predict these parameters. In this model with sigmoid training function and Levenberg–Marquardt stimulus function with three inputs, four neurons in a hidden layer with correlation of model results with real data more than 90% for PM<sub>2.5</sub> and another model with training and stimulus function respectively sigmoid and Levenberg–Marquardt with one input and five neurons in a hidden layer had the best results for PM<sub>10</sub>. According to the results of the sensitivity test, the variables have been selected correctly. According to the Pearson correlation results, PM<sub>2.5</sub> parameter with coefficients of 0.684, 0.674 and 0.763 respectively had a higher correlation with the concentration of CO, NO<sub>x</sub> and SO<sub>2</sub> pollutants compared to meteorological variables, and PM<sub>10</sub> parameter with a coefficient of 0.763 had the highest correlation with the PM<sub>2.5</sub> variable, which indicates that the winter PM concentration in Hamedan city is influenced by the concentration of air pollutants. Compared to PM<sub>10</sub>, PM<sub>2.5</sub> values are more correlated with air quality variables, and PM<sub>10</sub> concentration has the highest correlation with PM<sub>2.5</sub> concentration. From this, it can be concluded that the concentration of PM<sub>10</sub> is more under the control of the concentration of PM<sub>2.5</sub>. One of the reasons for the low correlation between meteorological parameters and PM concentration is the presence of the Zagros highlands in the studied area, which reduces the penetration of western winds into this area (Zare et al., 2011).

The prediction accuracy of ANN in this research with R was 0.93 and 0.92 for Pm<sub>2.5</sub> and Pm<sub>10</sub>, respectively, which is the result of Cortina et al.,'s model (2015) with CC: 0.6, Franceschi et al.,'s (2018) with R: 0.59 and Nidzgorska et al., (2018) with R<sub>2</sub> = 0.84 had higher accuracy. The high forecasting accuracy shows the correct selection of the influencing variables and also the appropriate structure of the selected network in this research. Other air pollutants selected as inputs to the model can be the source or controller of PM concentration. In the research of Fing et al., (2015) using the data of the movement path of air masses, wind speed and direction, he was able to predict the PM concentration with an average detection rate of 90%, which in addition to confirming the capability of the integrated artificial neural network model. It shows the importance of air movement in removing suspended particles. The results obtained in this research, like previous research, emphasized the high ability of ANN in modeling and predicting parameters in very complex natural environments, such as predicting air pollutants. In the optimized network in this research, like the research of Zengoui et al., (2018) and unlike Chellali et al., (2016); Memarianfard and Hatami, (2017); Nidzgorska et al., (2018) were selected to model the PM concentration data of other air pollutants, which is the result of the special topographical conditions of this area. Similar to the study of other researchers who predicted PM concentration with MLP-ANN (Dutta & Jinsart, 2021; Taşpınar, 2015; Taşpınar & Bozkurt, 2014; Unal et al., 2016), in this study, the high ability of this model was confirmed. This tool can replace traditional deterministic models, whose inability has been proven in complex environments, and can be used as an early warning system before contamination occurs. To prevent or reduce the harmful effects of air pollution in the studied city with the necessary measures.

---

**References**

- Asl, F. B.; Leili, M.; Vaziri, Y.; Arian, S. S.; Cristaldi, A., Conti, G. O. & Ferrante, M. 2018. Health impacts quantification of ambient air pollutants using AirQ model approach in Hamadan, Iran. *Environmental research*, 161, 114–121.
- Chellali, Abderrahim, H.; Hamou, A.; Nebatti, A. & Janovec, J. 2016. Artificial neural network models for prediction of daily fine particulate matter concentrations in Algiers. *Environmental Science and Pollution Research*, 23(14), 14008–14017.
- Cortina-Januchs, M. G.; Quintanilla-Dominguez, J.; Vega-Corona, A. & Andina, D. 2015. Development of a model for forecasting of PM10 concentrations in Salamanca, Mexico. *Atmospheric Pollution Research*, 6(4), 626–634.
- Dutta, A. & Jinsart, W. 2021. Air Pollution in Indian Cities and Comparison of MLR, ANN and CART Models for Predicting PM10 Concentrations in Guwahati, India. *Asian Journal of Atmospheric Environment (AJAE)*, 15.(1)
- Feng, X.; Li, Q.; Zhu, Y.; Hou, J.; Jin, L. & Wang, J. 2015. Artificial neural networks forecasting of PM2.5 pollution using air mass trajectory based geographic model and wavelet transformation. *Atmospheric Environment*, 107, 118–128.
- Franceschi, F.; Cobo, M. & Figueredo, M. 2018. Discovering relationships and forecasting PM10 and PM2.5 concentrations in Bogotá, Colombia, using Artificial Neural Networks, Principal Component Analysis, and k-means clustering. *Atmospheric Pollution Research*, 9(5), 912–922.
- Ilten, N. & Selici, A. T. 2008. Investigating the impacts of some meteorological parameters on air pollution in Balikesir, Turkey. *Environmental monitoring and assessment*, 140(1), 267–277.
- Janhäll, S.; Olofson, K. F. G.; Andersson, P. U.; Pettersson, J. B. C. & Hallquist, M. 2006. Evolution of the urban aerosol during winter temperature inversion episodes. *Atmospheric Environment*, 40(28), 5355–5366.
- Memarianfard, M. & Hatami, A. M. 2017. Artificial neural network forecast application for fine particulate matter concentration using meteorological data. *Global Journal of Environmental Science and Management*, 3(3), 333–340.
- Mohammadi, N.; Zoroufchi, B. K.; Shakerkhatibi, M.; Fatehifar, E.; Behroozsarand, A.; Mahmoudian, A. & Sheikholeslami, F. 2017. Forecasting Concentrations of Gaseous Air Pollutants Using Artificial Neural Networks in Tabriz. *Civil and Environmental Engineering (Technical College)*.46(2): 97-104. (In Persian)
- Nidzgorska-Lencewicz, J. 2018. Application of Artificial Neural Networks in the Prediction of PM10 Levels in the Winter Months: A Case Study in the Tricity Agglomeration, Poland. *Atmosphere*, 9(6), 203.
- Parsimehr, M.; Shayesteh, K.; Godini, K. & Bayat Varkeshi, M. 2018. Using Multilayer Perceptron Artificial Neural Network for Predicting and Modeling the Chemical Oxygen Demand of the Gamasiab River. *Avicenna J Environ Health Eng*, 5(1), 15–20.
- Taşpınar, F. & Bozkurt, Z. 2014. Application of artificial neural networks and regression models in the prediction of daily maximum PM10 concentration in Düzce, Turkey. *Fresenius Environ. Bull*, 23, 2450–2459.
- Taşpınar, F. 2015. Improving artificial neural network model predictions of daily average PM10 concentrations by applying principal component analysis and implementing seasonal models. *Journal of the Air & Waste Management Association*, 65(7), 800–809.
- Tecer, L. H.; Süren, P.; Alagha, O.; Karaca, F. & Tuncel, G. 2008. Effect of meteorological parameters on fine and coarse particulate matter mass concentration in a coal-mining area in Zonguldak, Turkey. *Journal of the Air & Waste Management Association*, 58(4), 543–552.
- Unal, Y. S.; Toros, H.; Deniz, A. & Incecik, S. 2011. Influence of meteorological factors and emission sources on spatial and temporal variations of PM10 concentrations in Istanbul metropolitan area. *Atmospheric Environment*, 45(31), 5504–5513.
- Zangoi, H. & Asadolahfardi, G. 2018. PM10 air pollution in Mashhad City using artificial neural network and Markov Chain model. *Applied Research of Geographical Sciences*. 47(17),39-59 (In Persian)
- Zare, A. H.; Bayat, V. M. & Yazdani, V. 2011. Trend Analysis of Annual and Seasonal Temperature, Precipitation and Drought in Hamedan Province. (In Persian)

## پیش‌بینی و مدل‌سازی غلظت روزانه ذرات معلق (PM<sub>2.5</sub> & PM<sub>10</sub>) زمستانه شهر همدان با شبکه عصبی مصنوعی پرسپترون چند لایه

عیسی سلگی<sup>۱\*</sup>، محمد پارسی مهر<sup>۲</sup>

۱ دانشیار گروه محیط‌زیست، دانشکده منابع طبیعی و محیط‌زیست، دانشگاه ملایر، ملایر، ایران

۲ دانشجوی دکتری آلودگی محیط‌زیست، دانشکده منابع طبیعی و محیط‌زیست، دانشگاه ملایر، ملایر، ایران

تاریخ پذیرش مقاله: ۱۴۰۱/۱۰/۰۵

تاریخ وصول مقاله: ۱۴۰۱/۰۶/۳۰

### چکیده

در سال‌های اخیر تعداد روزهای با غلظت بالای ذرات معلق (PM) در شهر همدان بسیار افزایش یافته است. با توجه به شدت بیشتر این پدیده در فصل زمستان، برای مدیریت اثرات بهداشتی و محیط‌زیستی آن در این فصل کوشیده شده است تا با استفاده از شبکه عصبی مصنوعی (ANN) ابزاری بهینه برای پیش‌بینی زود هنگام آن ارائه گردد. برای بررسی عوامل تاثیرگذار بر غلظت PM زمستانه شهر همدان، داده‌های زمستانه آلاینده‌های هوا و پارامترهای هواشناسی با همبستگی پیرسون مورد تحلیل قرار گرفت. سپس بر اساس نتایج حاصل، شبکه عصبی پرسپترون چندلایه (MLP-ANN) بهینه شده بر اساس آزمون و آزمایش مدل‌سازی و مقادیر PM پیش‌بینی شد. در بین عوامل هواشناسی و کیفی هوا، متغیرهای کیفی هوا دارای همبستگی بیشتری با غلظت PM زمستانه بودند. ANN در مدلی با ۳ لایه ورودی، ۱ لایه پنهان و ۴ پردازنده لایه میانی با دقت بالای ۹۰٪ میزان PM<sub>2.5</sub> و مدلی با یک لایه ورودی، یک لایه پنهان و ۵ پردازنده لایه میانی با دقتی بالای ۹۰٪ میزان PM<sub>10</sub> را پیش‌بینی نمود. با وجود قرارگیری کوه الوند بین باد غالب نواحی غربی کشور و شهر همدان تاثیر عوامل هواشناسی بر غلظت PM کم می‌باشد. همچنین افزایش PM زمستانه شهر می‌تواند ناشی از افزایش مصرف سوخت و تولید آلاینده‌های حاصل از احتراق در زمستان باشد. ابزار MLP-ANN با کمترین و در دسترس‌ترین داده‌ها دارای قابلیت پیش‌بینی زود هنگام میزان PM می‌باشد و می‌توان از آن برای کنترل اثرات PM بهره گرفت.

**کلید واژه‌ها:** هوش مصنوعی، ارزیابی محیط‌زیست، آلودگی محیط‌زیست، آلودگی هوا، همدان

## سراغاز

(ANN)، که دارای قابلیت‌های نقشه برداری غیرخطی، خود سازگاری و نیرومند بودن است، برتری خود را ثابت کرده است و به طور گسترده‌ای در زمینه‌های پیش‌بینی استفاده می‌شود. به تازگی ساختارهای مختلفی از شبکه عصبی مصنوعی برای بهبود عملکرد پیش‌بینی غلظت آلاینده‌های هوا ایجاد شده است (Antanasijević, Ristić, Perić-Grujić, & Pocajt, 2013; Chen, Yang, Hu, Hossain, & Muhammad, 2018; Feng, Zhang, Sun, & Zhang, 2011; Li et al., 2015; Mohebbi, Jashni, Dehghani, & Hadad, 2018; Paschalidou, Karakitsios, Kleanthous, & Kassomenos, 2011; Wu Feng, Du, & Li, 2011). راستای بررسی کارایی ANN برای پیش‌بینی PM پژوهش‌هایی در داخل کشور (Rostami Fasih et al., 2015; Zangoei & Asadolahfrd, 2018) و همچنین برخی از پژوهش‌های خارجی انجام شده در ذیل آورده شده است. Chellali و همکاران، (۲۰۱۶) کارایی مدل‌های ANN را برای پیش‌بینی ذرات معلق با قطر آبرودینامیکی کمتر از ۱۰ میکرومتر (PM10) در El Hamma الجزیره مورد بررسی قرار دادند. مدل ANN با استفاده از ترکیبی از داده‌های هواشناسی در مقیاس زمانی به عنوان متغیرهای ورودی توسعه داده شد. نتایج به دست آمده با رضایت بخش بودن داده‌های مورد پیش‌بینی تأکیدی بر توانمند بودن این ابزار بود (Chellali, Abderrahim, Hamou, Nebatti, & Janovec, 2016). Hatami (۲۰۱۷) در پژوهشی ابزار ANN را برای بررسی پراکندگی PM در شهر تهران مورد ارزیابی قرار دادند. در این پژوهش از داده‌های هواشناسی مانند سرعت باد، رطوبت، دما و غلظت آلاینده‌های هوا در یک دوره زمانی استفاده شد بر اساس نتایج به دست آمده ANN بر اساس مقایسه نتایج پیش‌بینی شده با داده‌های واقعی و بررسی میزان خطا، ANN دارای توانایی بالا برای مدل‌سازی ذرات معلق در شهر تهران ارزیابی شد (Memarianfard & Hatami, 2017). Nidzgorska و همکاران، (۲۰۱۸) در پژوهشی ANN را برای مدل‌سازی پیش‌بینی غلظت ساعتی PM زمستان مورد ارزیابی قرار دادند برای این پژوهش از داده‌های هواشناسی و غلظت PM در Agglomeration لهستان استفاده شد. در زمستان به دلیل استفاده بیشتر از سوخت، میزان PM در این شهر نسبت به سایر فصل‌ها بالاتر است. بر اساس نتایج حاصل در این پژوهش توانایی ANN برای پیش‌بینی غلظت PM اثبات شده است

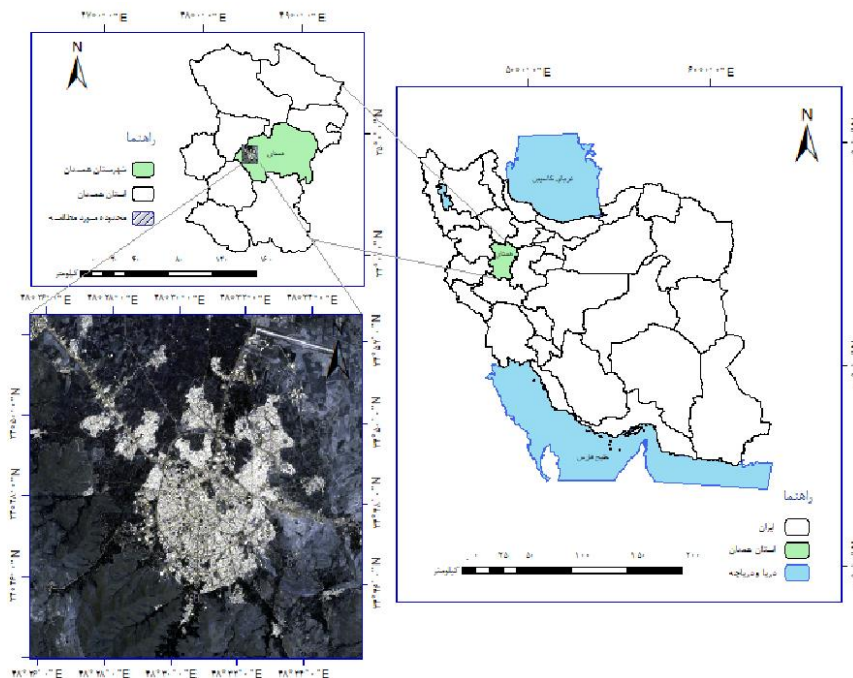
میزان ذرات معلق (PM2/5 و PM10) محیط بر کیفیت هوا تاثیر می‌گذارد و یک فاکتور ریسک محیط‌زیستی مهم به ویژه در شهرهای بزرگ است (Bhakta, Khillare, & Jyethi, 2019). آلودگی PM ۲/۵ به علت اثرات منفی آن بر سلامت به یک نگرانی مهم در سراسر جهان تبدیل شده است. PM به اندازه کافی کوچک است تا بتواند به بیشتر ارگانیسم‌های بدن نفوذ کند، هنگامی که مواجهه با ذرات معلق برای مدت زیادی انجام شود ممکن است در افراد علائم بیماری‌های قلبی عروقی، سرطان ریه، تحریک پوست و غیره ایجاد کند و به طور خاص اثرات مستقیم بر سلامت دستگاه تنفسی داشته باشد (Brook et al., 2010; Knibbs, Cole-Hunter, & Morawska, 2011; Memarianfard & Hatami, 2017; Rajagopalan et al., 2012; Ristovski et al., 2012; Brook, 2012). به طور کلی آلودگی هوا در سال‌های اخیر به دلیل تاثیرات نامطلوبی که بر سلامت بشر داشته است توجه بسیاری از پژوهشگران را به خود جلب کرده و باعث شده که مدیران شهری ایستگاه‌های نظارت و جمع‌آوری آمار آلاینده‌های هوا در اکثر شهرها ایجاد کنند (Cheng, Shen, Zhu, & Huang, 2018). اما پیش‌لحظه‌ای کیفیت هوا نمی‌تواند همه نیازهای مدیران شهری را برای کنترل و مدیریت شرایط محیطی برآورده کند. بنابراین یک مدل دقیق و قابل اعتماد برای پیش‌بینی آلودگی هوا بسیار با اهمیت است زیرا می‌توان به وسیله آن آلودگی هوا را در مراحل اولیه پیش‌بینی کرد و با کنترل آن از آثار زیان بار آلودگی هوا جلوگیری و از بهداشت عمومی حفاظت کرد (Bai, Li, Wang, Xie, & Li, 2016). به تازگی تحقیقات زیادی در زمینه پیش‌بینی غلظت آلاینده‌های هوا به شکل‌گیری و توسعه مدل‌های مختلف اختصاص یافته است، به عنوان مثال، مدل‌های آماری (Ozel & Cakmakyapan, 2015)، مدل چند مقیاسه کیفیت هوا (Djalalova, Delle Monache, & Wilczak, 2015)<sup>(۱)</sup>، مدل تحقیق و پیش‌بینی با شیمی (Saide et al., 2011)، سیستم استنتاج فازی (Domańska & Wojtylak, 2012) و سایر مدل‌های ترکیبی (Yahya, Zhang, & Vukovich, 2014). این روش‌ها عملکرد خوبی را برای پیش‌بینی آلودگی هوا به دست آورده‌اند که از طریق تابع آنها امکان شناسایی وابستگی‌های جدید بین داده‌های جمع‌آوری شده را به دست می‌دهد. در میان این مدل‌ها، شبکه عصبی مصنوعی

همدان بر اساس پارامترهای تاثیرگذار، بهینه شده و مورد ارزیابی قرار گیرد تا ابزاری کار آمد برای هشدار اولیه و پیش‌بینی قبل از وقوع آلودگی زمستانه ارایه گردد.

### روش بررسی

#### محدوده مورد مطالعه

استان همدان در گستره‌ای به مساحت ۲۰۱۷۲ کیلومترمربع، در غرب ایران در دامنه کوه الوند و در بلندای ۱۸۰۰ متری از سطح دریا واقع شده است و شهر همدان ۲۸۳۱ کیلومترمربع از این استان را شامل می‌شود، شکل (۱) (Kalvandi, Safikhani, ) (Najafi, & Babakhanlo, 2007).



شکل (۱): محدوده مورد مطالعه

و داده‌های هواشناسی از سایت سازمان هواشناسی برای فصل زمستان سال ۹۷ تهیه شد.

### تحلیل آماری

جهت بررسی رابطه بین متغیرهای تاثیرگذار با غلظت PM<sub>2.5</sub> و PM<sub>10</sub> از روش پیرسون در نرم‌افزار SPSS 25 استفاده شد. بررسی همبستگی نشان‌دهنده میزان تاثیرپذیری پارامترها از یکدیگر است. سپس به بررسی مدل‌های مختلف ANN برای پیش‌بینی و مدل‌سازی پارامترهای آلاینده هوا پرداخته خواهد

(Nidzgorska-Lencewicz, 2018).

کیفیت هوای شهر همدان در سال‌های اخیر دچار تغییرات گسترده‌ای شده است به طوری که این شهر با روزهای متوالی کیفیت ناسالم هوا بر اساس شاخص‌های مربوطه اعلام گردیده است. به این دلیل آگاهی و پیش‌بینی روزانه آلودگی هوا برای دسترسی به هشدار اولیه و مدیریت قبل از وقوع آلودگی بسیار با اهمیت است. با توجه به این که همدان دارای اقلیم سرد و خشک است (Zare, Bayat, & Yazdani, 2011)، استفاده سوخت در زمستان به بیشترین مقدار خود می‌رسد که این نیز می‌تواند یکی از دلایل افزایش غلظت PM در این فصل باشد. در این پژوهش سعی شده است که تا مدل شبکه عصبی مصنوعی برای مدل‌سازی و پیش‌بینی PM زمستانه شهری در

### داده‌های مورد استفاده

در این پژوهش برای بررسی، مدل‌سازی و پیش‌بینی غلظت PM<sub>2.5</sub> و PM<sub>10</sub> از داده‌های هواشناسی و داده‌های مربوط به غلظت آلاینده‌های هوا شامل O<sub>3</sub>(ppb)، CO (ppm)، SO<sub>2</sub>(ppb) و Nox(ppb) زمستان شهر استفاده شد. با توجه به این که در شهرهای دارای زمستان‌های سرد به دلیل افزایش مصرف سوخت‌های فسیلی ریسک آلودگی هوا در این فصل بیشتر است (Iten & Selici, 2008). در این پژوهش داده‌های ایستگاه پایش کیفیت هوای شهر همدان از سازمان محیط‌زیست

دیگر این نرم افزار، وجود توابع مختلف با الگوریتم‌های گوناگون در بانک نرم‌افزار است (Nasrabadi, 2011) (Asadpour & Nasrabadi, 2011). برای مدل‌سازی شبکه عصبی مصنوعی ابتدا درصدی از داده‌ها برای آموزش شبکه استفاده می‌شود سپس در مرحله بعدی درصد باقی مانده داده‌ها برای عمل اعتبار سنجی و آزمایش شبکه استفاده می‌شود. در این پژوهش ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد باقی مانده برای اعتبارسنجی و آزمایش شبکه استفاده شده است (Mohammadi et al., 2017). سپس داده‌های پیش‌بینی شده با داده‌های واقعی مقایسه شده و مقدار خطا محاسبه می‌گردد.

مقادیر خطا باید در کمترین مقدار خود باشد که برای این کار باید شبکه دلخواه طراحی گردد و عمل آموزش و آزمایش با حالت‌های مختلف تکرار گردد تا خطا به حداقل خود برسد. به منظور ارزیابی و مقایسه نتایج حاصل از ضریب همبستگی (R)، میانگین خطای مطلق (MAE) و خطای نرمال نسبی (NMSE) محاسبه شده است.

رابطه (۱) میانگین خطای مطلق

$$(MAE) MAE: \frac{1}{n} \sum_{i=1}^n |x_i - y_i|$$

$x_i$  عبارت است از داده‌های واقعی و  $y_i$  داده‌های برآورد شده می‌باشد و  $n$  تعداد کل داده‌ها است.

رابطه (۲) ضریب همبستگی

$$R = \frac{\sum_{i=1}^n (Y_{act} - \hat{Y}_{act})(Y_{est} - \hat{Y}_{est})}{\sqrt{\sum_{i=1}^n (Y_{act} - \hat{Y}_{act})^2 \sum_{i=1}^n (Y_{est} - \hat{Y}_{est})^2}}$$

$Y_{act}$  مقادیر واقعی،  $\hat{Y}_{act}$  میانگین مقادیر واقعی،  $Y_{est}$  مقادیر برآورد شده و  $\hat{Y}_{est}$  میانگین مقادیر برآورد شده می‌باشد. رابطه (۳) میزان خطای نرمال شده

$$NMSE = \frac{RMSE}{PM \text{ average}}$$


که در رابطه فوق RMSE میزان خطا و PM average میزان میانگین PM به دست آمده آزمایشات است (Al-Dabbous et al., 2017).

ضریب همبستگی (R) بیان‌کننده میزان همبستگی بین نتایج پیش‌بینی شده و داده‌های واقعی می‌باشد. بدیهی است که در این رابطه هر چه میزان آن به ۱ نزدیک‌تر باشد نتایج قابل قبول‌تر و مقادیر NMSAE و MAE هرچقدر به صفر نزدیک‌تر باشد نشانده خطای کمتری است.

شد. برای استفاده در مدل‌های بهینه از داده‌های دارای بیشترین همبستگی با پارامترهای مورد نظر استفاده می‌شوند.

### شبکه عصبی مصنوعی

روش‌های ANN با توان یادگیری، خلاقیت و انعطاف پذیری شبیه به مغز انسان طراحی شده است. این روش‌ها اساساً به یک سیستم آموزشی پیشرفته متکی هستند (Ostad-Ali-Askari et al., 2017). ساختار کلی ANN دارای سه لایه با وظایف مشخص است. لایه ورودی داده‌ها به ANN، لایه پردازش اطلاعات (لایه میانی) و لایه خروجی که علاوه بر پردازش به ازای هر پارامتر ورودی به شبکه، نتایج و خروجی آنرا نشان می‌دهد (Taşpınar & Bozkurt, 2014). نرون کوچکترین واحد پردازشگر ANN است. شکل (۲) ساختار کلی شبکه عصبی مصنوعی را نشان می‌دهد. در این تحقیق از شبکه پرسپترون چند لایه (MLP) با الگوریتم پس انتشار خطا<sup>(۱)</sup> استفاده شده است.



شکل (۲): ساختار شبکه عصبی مصنوعی

طراحی شبکه براساس ترکیبی از اطلاعات پارامترهای تاثیرگذار در غلظت ذرات معلق در زمان‌های قبل، در قالب ساختارهای متفاوت از تعداد داده‌ها در لایه‌ی ورودی انجام شده است. در هر یک از ساختارها، اطلاعات ورودی پس از پردازش، از راه خروجی نرون‌های لایه‌ی اول، به نرون‌های لایه‌های بعدی و درنهایت، در صورت قابل قبول بودن به خروجی شبکه منتقل می‌شود. در غیر این صورت با انتشار خطای محاسباتی به لایه‌های قبل برگشته و محاسبه‌ها دوباره تکرار می‌شود تا نتیجه‌ی قابل قبول به دست آید (Parsimehr et al., 2018). برای افزایش سرعت پردازش اطلاعات و عدم توقف شبکه در حداقل‌های محلی، از اطلاعات نرمال شده به عنوان ورودی شبکه استفاده شد. اجرای این ساختارها در نرم‌افزار تحت سیستم عامل ویندوز Neuro Solution با قابلیت نرمال سازی داده‌ها انجام گرفت. از مزایای



## یافته‌ها

## تحلیل‌های آماری

مقادیر مختلف بیشترین، کمترین، میانگین و انحراف معیار با

کمک نرم‌افزار SPSS 25 انجام گرفت که خلاصه نتایج در جدول (۱) نمایش داده شده است.

جدول (۱): شاخص‌های آماری داده‌های مورد استفاده

بیشترین	کمترین	انحراف معیار	میانگین	N	
۲۳/۵۹	۵/۹۳	۴/۵۳۶۷۳	۱۳/۴۸۴۳	۸۴	O <sub>3</sub> (ppb)
۳/۷۶	۰/۳۷	۰/۷۲۳۱۱	۱/۴۶۲۷	۸۴	CO (ppm)
۹۰/۱۸	۱۶/۹۸	۱۶/۳۰۸۸۰	۳۲/۲۰۷۰	۸۴	No <sub>x</sub> (ppb)
۱۷/۸۵	۹/۱۵	۱/۶۱۹۲۱	۱۲/۳۱۹۰	۸۴	SO <sub>2</sub> (ppb)
۱۹۷/۶۸	۱۵/۰۴	۴۳/۵۱۷۴۹	۷۸/۴۴۱۸	۸۴	PM10
۸۶/۲۱	۹/۷۵	۱۵/۰۵۷۰۲	۲۷/۳۷۵۵	۸۴	PM 2/5
۱۱/۶	-۱۷/۹	۶/۲۷۳۳	-۲/۰۶۵	۸۴	حداقل دمای روزانه
۱۹/۰	-۴/۷	۵/۳۳۱۶	۱۰/۸۳۶	۸۴	حداکثر دمای روزانه
۱۴/۴	-۱۱/۸	۵/۶۷۲۹	۳/۸۲۹	۸۴	میانگین دمای روزانه
۷/۱۰	۰/۰۰	۱/۶۹۵۱۹	۰/۶۴۵۵	۸۴	مجموع بارش روزانه
۱۱/۰	۰/۰	۲/۷۰۶۹	۶/۴۴۶	۸۴	ساعت آفتابی
۷/۲۵	۰/۰۰	۱/۹۷۹۲۳	۳/۲۰۰۲	۸۴	ساعت ابری
۲۰	۳	۳/۷۱۲	۷/۶۲	۸۴	حداکثر سرعت باد روزانه
۳۶۰	۱۰	۹۰/۸۳۳	۲۱۰/۰۰	۸۴	جهت باد (درجه)
۷/۵۰	۰/۵۰	۱/۴۷۳۸۹	۲/۶۱۰۶	۸۴	میانگین سرعت باد (m/s)
۱۰۰	۱۹	۱۴/۵۶۴	۸۲/۷۴	۸۴	رطوبت حداکثر
۹۵	۱۰	۱۶/۸۹۱	۳۸/۲۶	۸۴	رطوبت حداقل
۹۷/۷۵	۱۶/۲۵	۱۶/۳۹۱۴۱	۶۱/۳۱۴۴	۸۴	میانگین رطوبت

همبستگی با غلظت PM2.5 است از این می‌توان نتیجه گرفت که غلظت PM10 بیشتر تحت کنترل غلظت PM2.5 می‌باشد. از دلایل میزان همبستگی پایین بین پارامترهای هواشناسی با غلظت ذرات معلق می‌توان به وجود ارتفاعات زاگرس در محدوده مورد مطالعه اشاره کرد که موجب کاهش نفوذ بادهای غربی به این محدوده می‌شود (Zare et al., 2011).

با هدف جلوگیری از بیش‌آموزی ANN و همچنین صرفه‌جویی در هزینه آزمایشات برای به دست آوردن مقادیر پارامترها، در پیش‌بینی هر متغیر تنها از سه پارامتر ورودی شبکه استفاده شد. که بر اساس بیشترین ضریب همبستگی و ارتباط بین متغیرها با پارامتر مورد پیش‌بینی بود و به این صورت انتخاب گردید که برای پارامتر PM2.5 متغیرهای CO، NO<sub>x</sub>، SO<sub>2</sub> و برای پارامتر PM10 تنها از متغیر PM2.5 استفاده گردید.

برای بررسی میزان ارتباط بین مقادیر پارامترهای مورد استفاده از همبستگی پیرسون استفاده شد، ضریب همبستگی بالا نشان‌دهنده عامل کنترل‌کننده مشترک بین پارامترها می‌باشد. بر این اساس پارامترهایی با بالاترین ضریب همبستگی به عنوان تاثیرگذارترین عوامل برای قرارگیری در ساختار MLP-ANN انتخاب شدند. نتیجه بررسی همبستگی در جدول (۲) آورده شده است.

با توجه به جدول (۲) پارامتر PM2.5 با ضرایب ۰/۶۸۴، ۰/۶۷۴ و ۰/۷۶۳ دارای همبستگی بالاتری با غلظت آلاینده‌های هوا (CO، NO<sub>x</sub> و SO<sub>2</sub>) در مقایسه با متغیرهای هواشناسی بود و پارامتر PM10 با ضریب ۰/۷۶۳ بیشترین همبستگی را با متغیر PM2.5 داشت که نشان‌دهنده این است که غلظت PM زمستانه در شهر همدان تحت تاثیر غلظت آلاینده‌های دیگر هوا است. مقادیر PM2.5 در مقایسه با PM10 همبستگی بیشتری با متغیرهای کیفیت هوا دارد و غلظت PM10 دارای بیشترین

## MLP-ANN

جدول (۲): نتایج آزمون همبستگی پیرسون

PM 2/5	PM10	
-/۵۴۹**	-/۳۴۰**	ازون ( $\text{mg}/\text{m}^3$ )
/۶۸۴**	/۵۰۳**	منواکسیدکربن (ppm)
/۶۷۴**	/۴۷۹**	No <sub>x</sub> (ppb)
/۶۲۰**	/۵۳۸**	SO <sub>2</sub> (ppb)
/۷۶۳**	۱	PM10
۱	/۷۶۳**	PM 2/5
-/۴۶۶**	-/۲۵۰*	کمینه دما
-/۲۵۸*	-/۰۷۶	بیشینه دما
-/۴۰۳**	-/۱۹۰	میانگین دما
-/۱۲۴	-/۱۳۹	رطوبت
-/۰۶۸	/۰۱۰	زمان آفتابی
-/۲۹۷**	-/۲۰۲	ابرناکی
-/۳۰۴**	-/۰۸۸	سرعت باد (M/S)
-/۲۵۷*	-/۱۹۴	جهت باد
-/۴۱۹**	-/۲۶۲*	میانگین روزانه سرعت باد (M/S)
/۱۹۵	/۰۹۶	رطوبت حداکثر
/۳۱۴**	/۱۱۴	رطوبت کمینه
/۳۴۲**	/۱۵۸	میانگین رطوبت

\*\* همبستگی در سطح ۰/۰۱ معنی دار است.

\* همبستگی در سطح ۰/۰۵ معنی دار است.


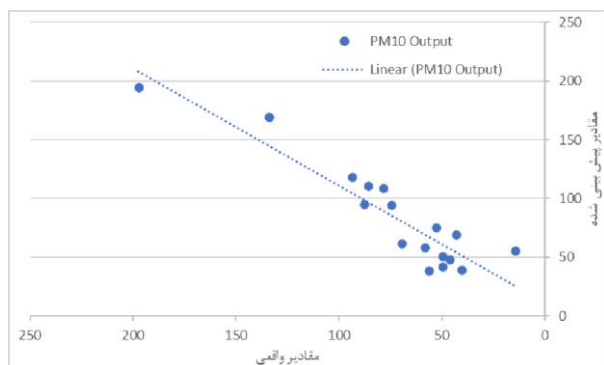
با توجه به انتخاب ورودی‌ها و خروجی چهار مدل برای مدل‌سازی و پیش‌بینی PM2.5 و PM10 بر اساس همبستگی پیرسون به صورت ذکر شده با آموزش و آزمون مختلف بهترین نتایج برای تعداد لایه‌های مخفی، قانون آموزش و تابع محرک به صورت جدول (۳) حاصل گردید. تابع آموزشی سیگموئید و تابع محرک لونیبرگ مارکوارت برای دو مدل دارای بهترین نتایج بودند.

شکل (۲) نمودارهای پراکندگی نتایج پیش‌بینی شده می‌باشد در این نمودارها محور افقی داده‌های واقعی و محور عمودی نشان‌دهنده داده‌های پیش‌بینی شده می‌باشد. در این نمودارها ارتباط بین داده‌های واقعی و داده‌های پیش‌بینی شده با یک معادله نشان داده شده است و میزان انحراف معیار از نیمساز ربع اول آورده شده. در این نمودارها هر چقدر داده‌ها به نمودار یک به یک نزدیک‌تر شوند نشان‌دهنده کارایی و دقت بالای مدل‌های ساخته شده خواهد بود.

در شکل (۳) نیز نمودار هم‌پوشانی مقادیر پیش‌بینی شده با مقادیر واقعی آورده شده است. در این نمودارها محور افقی شماره نمونه و محور عمودی نشان‌دهنده مقادیر واقعی بر حسب میکروگرم بر متر مکعب PM می‌باشد.

جدول (۳): مدل‌های مختلف شبکه عصبی مصنوعی


متغیر هدف	تعداد نرون‌های ورودی	قانون آموزشی	تابع محرک	پنهان	تعداد لایه‌های پنهان	تعداد لایه میانی	تعداد پردازنده	R	NMSE	MAE
PM2.5	۳	سیگموئید	لونیبرگ مارکوارت	۱	۴	۴	۹۳۴۶	۰/۹۳۴۶	۰/۱۷۱۹	۳/۷۲۱
PM10	۱	سیگموئید	لونیبرگ مارکوارت	۱	۵	۵	۹۲۳۵	۰/۹۲۳۵	۰/۲۴۲۰	۱۵/۶۷



شکل (۲): نمودارهای پراکندگی داده‌های پیش‌بینی شده

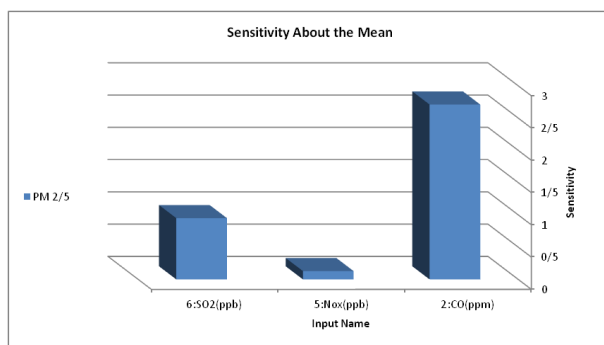
(2019)، این علاقه پژوهشگران برای مدل‌سازی و پیش‌بینی آلودگی هوا ناشی از افت شدید کیفیت هوا و بیماری‌های مرتبط با آن از جمله بیماری‌های مزمن، حاد و مرگ زودرس اعضای آسیب پذیر جامعه است. سیاست‌گذاران و برنامه‌ریزان شهری به دنبال ارائه راه‌حل‌های سریع و مقرون به صرفه برای دور زدن اثرات آلودگی هوا هستند (Moustris et al., 2010). رویکردهای قطعی به چندین عامل حساس هستند، از جمله مقیاس و کیفیت پارامترهای درگیر، از نظر محاسباتی گران هستند و وابسته به پایگاه‌های داده بزرگ از چندین پارامتر ورودی هستند، که برخی از آنها ممکن است در دسترس نباشند و این موارد نقاط ضعف این مدل‌ها در مقایسه با رویکردهای هوش مصنوعی به خصوص شبکه‌های عصبی مصنوعی است (Cabaneros et al., 2019). در نتیجه، شبکه‌های عصبی مصنوعی در بسیاری از برنامه‌های پیش‌بینی کوتاه‌مدت و بلندمدت آلاینده‌های هوا به خصوص ذرات معلق به طور موفقیت آمیزی پیاده‌سازی شده‌اند (Mohammadi et al., 2017; Moustris et al., 2010; Nidzgorska-Lencewicz, 2018; Rostami Fasih et al., 2015; Taşpınar, 2015; Taşpınar & Bozkurt, 2014).

پژوهش‌های انجام شده نشان می‌دهد که آلودگی ذرات معلق یک خطر بزرگ در کشورهای توسعه یافته و در حال توسعه است. این خطر در کشورهای آسیایی در مقایسه با اروپا و آمریکا که روند کاهشی در دو دهه اخیر در آنها ثبت شده، شدیدتر است. عوامل هواشناسی تغییرات ذرات معلق را در سطوح محلی و منطقه‌ای تغییر می‌دهند. مواد پوسته‌ای، ترافیک جاده‌ای و احتراق سوخت منابع اصلی آلودگی ذرات معلق هستند (Mukherjee & Agrawal, 2017). با توسعه کالبدی شهر، افزایش جمعیت، توسعه صنایع و افزایش تعداد خودروها آلودگی هوا به خصوص PM در شهر همدان به سرعت رو به گسترش بوده و به تازگی به مشکلی جدی تبدیل شده است (Asl et al., 2012; Hoseinzaher et al., 2018). این شهر دارای زمستان‌های سرد است (ZARE et al., 2011)، بنابراین استفاده از سوخت برای گرمایش علاوه بر صنایع، حمل و نقل در این فصل افزایش قابل ملاحظه‌ای می‌یابد و سبب افزایش میزان آلودگی هوا در فصل زمستان نسبت به سایر فصل‌ها می‌شود. همچنین در سال‌های اخیر در فصل زمستان چندین بار پدیده وارونگی دمایی در این شهر اتفاق افتاده و موجب تشدید آلودگی



شکل (۳): نمودارهای همبستگی نتایج با داده‌های واقعی

برای بررسی میزان حساسیت هر متغیر خاص در مدل انتخابی از آزمون حساسیت استفاده شد. با توجه به نمودارهای رسم شده در شکل (۴) معلوم می‌شود که میزان حساسیت متغیرهای مختلف در پیش‌بینی آلاینده‌های هوا همانند نتایج همبستگی پیرسون می‌باشد با این تفاوت که متغیر  $SO_2$  با ضریب همبستگی کمتر از  $NO_x$  در شبکه تاثیر بیشتری از آن دارد. این می‌تواند ناشی از ویژگی‌های شیمیایی و به طبع آن سهم هر کدام در آلودگی ذرات معلق باشد. به طور کلی میزان حساسیت شبکه برای متغیرها به ترتیب از بیشترین به کمترین به صورت  $CO$ ،  $SO_2$  و  $NO_x$  است.



شکل (۴): نمودار حساسیت متغیرها

### بحث و نتیجه گیری

در سال‌های اخیر پژوهش‌های مرتبط با پیش‌بینی آلاینده‌های هوا به طور چشمگیری افزایش یافته است (Cabaneros et al., )

آلودگی ذرات معلق در محدوده مورد پژوهش در این مطالعه است. با توجه به صحت نتایج، کاربردی بودن مدل و در دسترس بودن داده‌های مورد نیاز در این مدل، این ابزار برای مدیریت زود هنگام پیشنهاد می‌گردد.

دقت پیش‌بینی ANN در این پژوهش با R به ترتیب برای Pm2.5 و Pm10 مقادیر ۰/۹۳ و ۰/۹۲ بود که این نتیجه از مدل Cortina و همکاران (۲۰۱۵) با  $CC: 0/6$ ، Franceschi و همکاران (۲۰۱۸) با  $R: 0/59$  و Nidzgorska و همکاران (۲۰۱۸) با  $R^2=0/84$  دارای دقت بالا تری بود، دقت پیش‌بینی بالا نشان‌دهنده انتخاب صحیح متغیرهای تاثیرگذار و همچنین ساختار مناسب شبکه انتخاب شده در این پژوهش می‌باشد، سایر آلاینده‌های هوای انتخاب شده به عنوان ورودی مدل خود میتوانند منشا یا کنترل کننده غلظت ذرات معلق باشند. در پژوهش Fing و همکاران (۲۰۱۵) با استفاده از داده‌های مسیر حرکت توده‌های هوا، سرعت و جهت باد توانست با نرخ تشخیص میانگین ۹۰ درصد غلظت ذرات معلق را پیش‌بینی کند، که این علاوه بر تایید توانمندی مدل شبکه عصبی مصنوعی تلفیقی، اهمیت جابه‌جایی هوا در برطرف کردن ذرات معلق را نشان می‌دهد. نتایج به دست آمده در این پژوهش همانند پژوهش‌های گذشته تاکید بر توانایی بالای ANN در مدل‌سازی و پیش‌بینی پارامترها در محیط‌های بسیار پیچیده طبیعی همچون پیش‌بینی آلاینده‌های هوا بود. در شبکه بهینه شده در این پژوهش همانند پژوهش Zangoui و همکاران (۲۰۱۸) و بر خلاف Chellali و همکاران، (۲۰۱۶)؛ Memarianfard و Hatami، (۲۰۱۷)؛ Nidzgorska و همکاران، (۲۰۱۸) برای مدل‌سازی غلظت PM داده‌های سایر آلاینده‌های هوا انتخاب گردید که نتیجه شرایط تیپوگرافی ویژه این محدوده است. همانند مطالعه پژوهشگران دیگر که با MLP-ANN غلظت PM را پیش‌بینی کرده اند (Dutta & Jinsart, 2021; Taşpınar, 2015; Taşpınar & Bozkurt, 2014; Unal et al., 2011)؛ در این پژوهش نیز توانایی بالایی این مدل مورد تایید قرار گرفت. این ابزار می‌تواند جایگزین مدل‌های سنتی قطعی‌گرا که ناتوانی آنها در محیط‌های پیچیده اثبات شده است باشد و به عنوان یک سیستم هشدار زود هنگام قبل از وقوع آلودگی به کار گرفته شود تا با تمهیدات لازم اثرات مخرب آلودگی هوا در شهر مورد مطالعه جلوگیری و یا کاهش

هوا شده است. وارونگی دمایی یکی از دلایل اصلی افزایش آلودگی زمستانه در شهرهایی با اقلیم سرد است (Janhäll et al., 2006). با توجه به شکل قرارگیری شهر همدان در دامنه‌های کوه الوند و نحوه گسترش و استقرار ارتفاعات زاگرس که مانع ورود جبهه هوای غربی به این محدوده شده است (ZARE et al., 2011)، میزان تاثیر متغیرهای هواشناسی غالب غرب کشور مانند بادهای غربی بر محدوده شهر کاهش یافته است. تاثیر باد بر PM در مناطق غربی کشور از دو جنبه قابل توجه است در نگاه اول توانایی حمل PM توسط باد از نواحی غربی و جنوبی و ایجاد آلودگی جلب توجه می‌کند که این پدیده در مناطق مستعد می‌تواند محدود به موارد کمی در سال‌های خاصی باشد. اما به طور کلی عوامل هواشناسی مانند باد و بارش تاثیر به سزایی بر حمل و برطرف کردن آلودگی هوا دارند (Tecer et al., 2008). در شهرهای محصور در ارتفاعات مانند همدان خطر آلودگی هوا بسیار جدی‌تر است. زیرا، پتانسیل پراکندگی آلودگی هوا توسط این عوامل کمتر است. بنابراین مدل‌سازی و پیش‌بینی زود هنگام آلودگی هوا به خصوص مقادیر PM زمستانه شهر همدان اهمیت ویژه‌ای برخوردار است. پیش‌بینی زود هنگام غلظت PM زمستانه می‌تواند کمک بسیار بزرگی به مدیران و برنامه‌ریزان شهری برای مقابله با اثرات زیان بار آلودگی هوای شهر باشد.

در این پژوهش شبکه عصبی مصنوعی پرسپترون چند لایه جهت مدل‌سازی و پیش‌بینی غلظت PM زمستانه شهر همدان استفاده شد و بر اساس نتایج حاصل از این پژوهش روش شبکه عصبی مصنوعی پرسپترون چند لایه دارای توانایی و دقت مطلوبی جهت مدل‌سازی و پیش‌بینی این پارامترها بود. در این مدل با تابع آموزشی سیگموئید و تابع محرک لونیبرگ مارکوورت با سه ورودی، چهار نرون در یک لایه پنهان با همبستگی نتایج با داده‌های واقعی بیش از ۹۰ درصد برای PM2.5 و مدل دیگر با تابع آموزشی و محرک به ترتیب سیگموئید و لونیبرگ مارکوورت با یک ورودی و پنج نرون در یک لایه پنهان دارای بهترین نتایج برای PM10 بود. با توجه به نتایج آزمون حساسیت می‌توان نتیجه گرفت که پارامترهای انتخابی جهت ایجاد ساختار شبکه به درستی انتخاب شده است. مقایسه نتایج به دست آمده در این پژوهش با پژوهش‌های قبلی که برخی از آنها در جدول (۴) آمده است دقت بالای داده‌های پیش‌بینی شده و خطای کم شبکه ایجاد شده تاکید بر کارایی و توانمندی مدل حاصل برای

داده شود.

جدول (۴): نتایج به دست آمده از پژوهش‌های قبلی (نتایجی در بالاترین دقت و کمترین خطا)

منبع	نتایج	کشور	آلاینده هوا	مشخصات مدل
(Feng et al., 2015)	RMSE: ۱۵/۶۷	چین	PM2.5	مدل ترکیبی غلظت متوسط روزانه (ANN + مدل جغرافیایی و جابه‌جایی موجک مبتنی بر مسیر جرمی هوا)
(Bai et al., 2016)	RMSE: ۱۵/۳۹	چین	PM10	شبکه عصبی پس انتشار بر اساس تجزیه موجکی (غلظت روزانه آلاینده)
Cortina-Januchs et al., 2015)	CC: ۰/۶	مکزیک	PM10	ANN-MLP میانگین غلظت روزانه با C-means فازی و دسته بندی K-means
Franceschi et al., ) (2018)	RMSE: ۱۳/۵۰ MAE: ۱۰/۱۳ R: ۰/۵۹ RMSE: ۵/۷۷ MAE: ۴/۷۳ R: ۰/۶۴	کلمبیا	PM10  PM2.5	غلظت میانگین روزانه با ANN-MLP با آموزش RPROP. ترکیب شده با نتایج K-means
Nidzgorska-) (Lencewicz, 2018)	RMSE: ۸/۸۰ R <sup>2</sup> : ۰/۸۴۸	تریکیته لهستان	PM 10	MLP-ANN برای غلظت ساعتی آلاینده با استفاده از داده‌های هواشناسی

## 2. Backpropagation

### یادداشت‌ها

#### 1. Community multi-scale air quality model

### فهرست منابع

- Al-Dabbous, A. N.; Kumar, P. & Khan, A. R. 2017. Prediction of airborne nanoparticles at roadside location using a feed-forward artificial neural network. *Atmospheric Pollution Research*, 8(3), 446–454.
- Antanasijević, D. Z.; Ristić, M. Đ.; Perić-Grujić, A. A. & Pocajt, V. V. 2013. Forecasting human exposure to PM10 at the national level using an artificial neural network approach. *Journal of Chemometrics*, 27(6), 170–177. <https://doi.org/10.1002/cem.2505>
- Asadpour, G. & Nasrabadi, T. 2011. Municipal and medical solid waste management in different districts of Tehran, Iran. *Fresenius Environmental Bulletin*, 20(12), 3241–3245.
- Asl, F. B.; Leili, M.; Vaziri, Y.; Arian, S. S.; Cristaldi, A., Conti, G. O. & Ferrante, M. 2018. Health impacts quantification of ambient air pollutants using AirQ model approach in Hamadan, Iran. *Environmental research*, 161, 114–121.
- Bai, Y.; Li, Y., Wang, X.; Xie, J. & Li, C. 2016. Air pollutants concentrations forecasting using back propagation neural network based on wavelet decomposition with meteorological conditions. *Atmospheric Pollution Research*, 7(3), 557–566. <https://doi.org/10.1016/j.apr.2016.01.004>
- Bai, Y.; Li, Y.; Wang, X.; Xie, J. & Li, C. 2016. Air pollutants concentrations forecasting using back propagation neural network based on wavelet decomposition with meteorological conditions. *Atmospheric Pollution Research*, 7(3), 557–566.
- Bhakta, R.; Khillare, P. S. & Jyethi, D. S. 2019. Atmospheric Particulate Matter Variations and Comparison of Two Forecasting Models for Two Indian Megacities. *Aerosol Science and Engineering*, 3(2), 54–62. <https://doi.org/10.1007/s41810-019-00041-6>

- Brook, R. D.; Rajagopalan, S.; Pope III, C. A.; Brook, J. R.; Bhatnagar, A.; Diez-Roux, A. V. & Mittleman, M. A. 2010. Particulate matter air pollution and cardiovascular disease: an update to the scientific statement from the American Heart Association. *Circulation*, 121(21), 2331–2378.
- 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.
- Chellali, Abderrahim, H.; Hamou, A.; Nebatti, A. & Janovec, J. 2016. Artificial neural network models for prediction of daily fine particulate matter concentrations in Algiers. *Environmental Science and Pollution Research*, 23(14), 14008–14017.
- Chen, M.; Yang, J.; Hu, L.; Hossain, M. S. & Muhammad, G. 2018. Urban healthcare big data system based on crowdsourced and cloud-based air quality indicators. *IEEE Communications Magazine*, 56(11), 14–20.
- Cheng, W.; Shen, Y.; Zhu, Y. & Huang, L. (Eds.) 2018. A neural attention model for urban air quality inference: Learning the weights of monitoring stations.
- Cortina-Januchs, M. G.; Quintanilla-Dominguez, J.; Vega-Corona, A. & Andina, D. 2015. Development of a model for forecasting of PM10 concentrations in Salamanca, Mexico. *Atmospheric Pollution Research*, 6(4), 626–634.
- Djalalova, I.; Delle Monache, L. & Wilczak, J. 2015. PM2.5 analog forecast and Kalman filter post-processing for the Community Multiscale Air Quality (CMAQ) model. *Atmospheric Environment*, 108, 76–87. <https://doi.org/10.1016/j.atmosenv.2015.02.021>
- Domańska, D. & Wojtylak, M. 2012. Application of fuzzy time series models for forecasting pollution concentrations. *Expert Systems with Applications*, 39(9), 7673–7679. <https://doi.org/10.1016/j.eswa.2012.01.023>
- Dutta, A. & Jinsart, W. 2021. Air Pollution in Indian Cities and Comparison of MLR, ANN and CART Models for Predicting PM10 Concentrations in Guwahati, India. *Asian Journal of Atmospheric Environment (AJAE)*, 15(1).
- Feng, X.; Li, Q.; Zhu, Y.; Hou, J.; Jin, L. & Wang, J. 2015. Artificial neural networks forecasting of PM2.5 pollution using air mass trajectory based geographic model and wavelet transformation. *Atmospheric Environment*, 107, 118–128.
- Feng, Y.; Zhang, W.; Sun, D. & Zhang, L. (2011). Ozone concentration forecast method based on genetic algorithm optimized back propagation neural networks and support vector machine data classification. *Atmospheric Environment*, 45(11), 1979–1985. <https://doi.org/10.1016/j.atmosenv.2011.01.022>
- Franceschi, F.; Cobo, M. & Figueredo, M. 2018. Discovering relationships and forecasting PM10 and PM2.5 concentrations in Bogotá, Colombia, using Artificial Neural Networks, Principal Component Analysis, and k-means clustering. *Atmospheric Pollution Research*, 9(5), 912–922. <https://doi.org/10.1016/j.apr.2018.02.006>
- Hoseinzadeh, E.; Samarghandi, M. R.; Ghorbani, S. F.; Roshanai, G. & Jafari, J. 2012. Rate of suspended particulate distribution (PM2.5, PM10 and TSP) in Hamadan main intercity bus stations and its exposure rate. (In Persian)
- Ilten, N. & Selici, A. T. 2008. Investigating the impacts of some meteorological parameters on air pollution in Balikesir, Turkey. *Environmental monitoring and assessment*, 140(1), 267–277.
- Janhäll, S.; Olofson, K. F. G.; Andersson, P. U.; Pettersson, J. B. C. & Hallquist, M. 2006. Evolution of the urban aerosol during winter temperature inversion episodes. *Atmospheric Environment*, 40(28), 5355–5366.
- Knibbs, L. D.; Cole-Hunter, T. & Morawska, L. 2011. A review of commuter exposure to ultrafine particles and its health effects. *Atmospheric Environment*, 45(16), 2611–2622.

- Li, C.; Liang, M. & Wang, T. 2015. Criterion fusion for spectral segmentation and its application to optimal demodulation of bearing vibration signals. *Mechanical Systems and Signal Processing*, 64-65, 132-148. <https://doi.org/10.1016/j.ymssp.2015.04.004>
- Memarianfard, M. & Hatami, A. M. 2017. Artificial neural network forecast application for fine particulate matter concentration using meteorological data. *Global Journal of Environmental Science and Management*, 3(3), 333-340. <https://doi.org/10.22034/gjesm.2017.03.03.010>
- Mohammadi, N.; Zoroufchi, B. K.; Shakerkhatibi, M.; Fatehifar, E.; Behroozsarand, A.; Mahmoudian, A. & Sheikholeslami, F. 2017. Forecasting Concentrations of Gaseous Air Pollutants Using Artificial Neural Networks in Tabriz. *Civil and Environmental Engineering (Technical College)*.46(2): 97-104. (In Persian)
- Mohebbi, M. R.; Jashni, A. K.; Dehghani, M. & Hadad, K. 2018. Short-Term Prediction of Carbon Monoxide Concentration Using Artificial Neural Network (NARX) Without Traffic Data: Case Study: Shiraz City. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 1-8.
- Moustris, K. P.; Ziomas, I. C. & Paliatsos, A. G. 2010. 3-Day-ahead forecasting of regional pollution index for the pollutants NO<sub>2</sub>, CO, SO<sub>2</sub>, and O<sub>3</sub> using artificial neural networks in Athens, Greece. *Water, Air, & Soil Pollution*, 209(1), 29-43.
- Mukherjee, A. & Agrawal, M. 2017. World air particulate matter: sources, distribution and health effects. *Environmental Chemistry Letters*, 15(2), 283-309.
- Nidzgorska-Lencewicz, J. 2018. Application of Artificial Neural Networks in the Prediction of PM<sub>10</sub> Levels in the Winter Months: A Case Study in the Tricity Agglomeration, Poland. *Atmosphere*, 9(6), 203.
- Ostad-Ali-Askari, K.; Shayannejad, M. & Ghorbanizadeh-Kharazi, H. 2017. Artificial neural network for modeling nitrate pollution of groundwater in marginal area of Zayandeh-rood River, Isfahan, Iran. *KSCE Journal of Civil Engineering*, 21(1), 134-140.
- Ozel, G. & Cakmakyapan, S. 2015. A new approach to the prediction of PM<sub>10</sub> concentrations in Central Anatolia Region, Turkey. *Atmospheric Pollution Research*, 6(5), 735-741. <https://doi.org/10.5094/APR.2015.082>
- Parsimehr, M.; Shayesteh, K.; Godini, K. & Bayat Varkeshi, M. 2018. Using Multilayer Perceptron Artificial Neural Network for Predicting and Modeling the Chemical Oxygen Demand of the Gamasiab River. *Avicenna J Environ Health Eng*, 5(1), 15-20. <https://doi.org/10.15171/ajehe.2018.03>
- Paschalidou, A. K.; Karakitsios, S.; Kleanthous, S. & Kassomenos, P. A. 2011. Forecasting hourly PM<sub>10</sub> concentration in Cyprus through artificial neural networks and multiple regression models: implications to local environmental management. *Environmental Science and Pollution Research*, 18(2), 316-327. <https://doi.org/10.1007/s11356-010-0375-2>
- Kalvandi, R.; Safikhani, K.; Najafi, G. & Babakhanlo, P. 2007. Identification of medicinal plants of Hamedan province. *Iranian Journal of Medicinal and Aromatic Plants Research*, 2007; 23(3): 350-374. (In Persian)
- Rajagopalan, S. & Brook, R. D. (2012). Air pollution and type 2 diabetes: mechanistic insights. *Diabetes*, 61(12), 3037-3045.
- Ristovski, Z. D.; Miljevic, B.; Surawski, N. C.; Morawska, L.; Fong, K. M.; Goh, F. & Yang, I. A. 2012. Respiratory health effects of diesel particulate matter. *Respirology*, 17(2), 201-212.
- Rostami Fasih, Z.; Mesdaghinia, A.; Nadafi, K.; Nabizadeh Nodehi, R.; Mahvi, A. H. & Hadi, M. 2015. Forecasting the air quality index based on meteorological variables and autocorrelation terms using artificial neural network. *Razi Journal of Medical Sciences*, 22(137), 31-43.
- Saide, P. E.; Carmichael, G. R.; Spak, S. N.; Gallardo, L.; Osses, A. E.; Mena-Carrasco, M. A. & Pagowski, M. 2011. Forecasting urban PM<sub>10</sub> and PM<sub>2.5</sub> pollution episodes in very stable nocturnal conditions and complex terrain using WRF-Chem CO tracer model. *Atmospheric Environment*, 45(16), 2769-2780. <https://doi.org/10.1016/j.atmosenv.2011.02.001>

- Taşpınar, F. 2015. Improving artificial neural network model predictions of daily average PM10 concentrations by applying principle component analysis and implementing seasonal models. *Journal of the Air & Waste Management Association*, 65(7), 800–809.
- Taşpınar, F. & Bozkurt, Z. 2014. Application of artificial neural networks and regression models in the prediction of daily maximum PM10 concentration in Düzce, Turkey. *Fresenius Environ. Bull.*, 23, 2450–2459.
- Tecer, L. H.; Süren, P.; Alagha, O.; Karaca, F. & Tuncel, G. 2008. Effect of meteorological parameters on fine and coarse particulate matter mass concentration in a coal-mining area in Zonguldak, Turkey. *Journal of the Air & Waste Management Association*, 58(4), 543–552.
- Unal, Y. S.; Toros, H.; Deniz, A. & Incecik, S. 2011. Influence of meteorological factors and emission sources on spatial and temporal variations of PM10 concentrations in Istanbul metropolitan area. *Atmospheric Environment*, 45(31), 5504–5513.
- Voukantsis, D.; Karatzas, K.; Kukkonen, J.; Räsänen, T.; Karppinen, A. & Kolehmainen, M. 2011. Intercomparison of air quality data using principal component analysis, and forecasting of PM10 and PM2.5 concentrations using artificial neural networks, in Thessaloniki and Helsinki. *Science of the Total Environment*, 409(7), 1266–1276.
- Whalley, J. & Zandi, S. 2016. Particulate matter sampling techniques and data modelling methods. *Air Quality-Measurement and Modeling*; INTECH: Morn Hill, UK, 29–54.
- Wu, S.; Feng, Q.; Du, Y. & Li, X. 2011. Artificial Neural Network Models for Daily PM 10 Air Pollution Index Prediction in the Urban Area of Wuhan, China. *Environmental Engineering Science*, 28(5), 357–363. <https://doi.org/10.1089/ees.2010.0219>
- Yahya, K.; Zhang, Y. & Vukovich, J. M. 2014. Real-time air quality forecasting over the southeastern United States using WRF/Chem-MADRID: Multiple-year assessment and sensitivity studies. *Atmospheric Environment*, 92, 318–338. <https://doi.org/10.1016/j.atmosenv.2014.04.024>
- Zangoi, H. & Asadolahfardi, G. 2018. PM10 air pollution in Mashhad City using artificial neural network and Markov Chain model. *Applied Research of Geographical Sciences*. 47(17). (In Persian)
- Zare, A. H.; Bayat, V. M. & Yazdani, V. 2011. Trend Analysis of Annual and Seasonal Temperature, Precipitation and Drought in Hamedan Province. (In Persian)