



Developing GA-ANFIS model to predict long-term PM_{10} concentration The Case study of Tehran city

Farimah Bakhshizadeh¹, Najmeh Neysani Samany²✉, Ara Toomanian³

1. Department of Remote Sensing and Geographic Information System, Faculty of Geography, University of Tehran, Tehran, Iran

Email: f.bakhshizadeh@ut.ac.ir

2. Department of Remote Sensing and Geographic Information System, Faculty of Geography, University of Tehran, Tehran, Iran

Email: nneysani@ut.ac.ir

3. Department of Remote Sensing and Geographic Information System, Faculty of Geography, University of Tehran, Tehran, Iran

Email: a.toomanian@ut.ac.ir

Article Info

Article type:

Research Article

Article History:

Received:

1 February 2023

Received in revised form:

31 March 2023

Accepted:

5 May 2023

Keywords:

Air pollution,
Genetic algorithm,
Spatial autocorrelation,
Adaptive Neuro-Fuzzy
Inference System,
PM₁₀

ABSTRACT

Among the types of airborne particles, particles with a diameter of less than 10 microns have many adverse effects on human health. Meteorological parameters and the movement of a large volume of vehicles are considered the most important modulating factors in the distribution and concentration of atmospheric pollutants. In this study, in order to predict the concentration of PM-10 pollutant during a long-term interval in Tehran city, GA-ANFIS hybrid model was used. Wind speed, wind direction, temperature, relative humidity and traffic volume were considered as inputs and pollutant concentration PM₁₀ as the output of the model. The results of the calculation of the performance indicators showed that the combined GA-ANFIS model provides a better framework than the ANFIS model in predicting the pollutant concentration PM₁₀. In order to evaluate the spatio-temporal patterns of PM₁₀ pollutant concentration and to identify hot and cold spots in Tehran city, local Moran's statistic and Ard-J Gettys statistic were calculated. The results showed that there is a high level of clustering of PM₁₀ pollutant in Tehran (with 95% confidence level). The clusters of PM₁₀ have divided the city into two northern and southern parts so that most of the cold spots in the northern half and the hot spots in the south have spread to the center of the city.

Cite this article: Bakhshizadeh, F., Neysani Samani, N., & Toomanian, A. (2023). Developing GA-ANFIS model to predict long-term PM₁₀ concentration Case study: Tehran city. *Physical Geography Research Quarterly*, 55 (1), 57-78.

<http://doi.org/10.22059/JPHGR.2023.335120.1007663>



© The Author(s).

DOI: [10.22059/JPHGR.2023.335120.1007663](https://doi.org/10.22059/JPHGR.2023.335120.1007663)

Publisher: University of Tehran Press

Extend Abstract

Introduction

Among the types of air particles, particles with a diameter of less than 10 microns have many adverse effects on human health. The main sources of emissions of this pollutant are fuel combustion, industrial processes, agriculture, cars and diesel machines do not have the necessary standards. Meteorological parameters and high volume displacement of vehicles are the most important modulating factors in the distribution and accumulation of air pollutants. Tehran city is the capital of Iran, it is the most populous cities in Iran over 8.69 million of population. Due to the special geographical location of the city, in the northern part it has a temperate and mountainous climate and in low-lying areas it is semi-arid. The metropolis of Tehran, as the second most populous capital in the Middle East and the twenty-fourth most populous city in the world, is one of the most polluted capitals in the world. Tehran is ranked 12th among 26 metropolises in terms of ambient PM_{10} levels. The two main causes of the spread of this pollutant in Tehran are mobile sources (vehicles) and resident sources of pollution such as construction workshops and refineries around Tehran.

methods

Climatic parameters such as temperature, wind speed, wind direction and relative humidity have an important effect on the formation, transportation, accumulation and deposition of atmospheric pollutants. The role of wind speed as an important factor in the distribution of pollutants in the city of Tehran on a regional and local scale is undeniable. Due to the significant effect that high-speed winds have on the dispersion of pollutants and, consequently, on the concentration of pollutants in the atmosphere, as a result, chemical reactions are reduced. Regarding the role of temperature parameter in the process of changes in the concentration of air pollutants, it can be noted that in general, high temperature is associated with unfavorable air quality. The trend of relative humidity changes is in line with the pattern of temperature changes so that the maximum and minimum relative humidity are in accordance with the minimum and maximum

temperatures. The next very influential factor in the process of changes in the concentration of pollutants is urban road traffic. The high number of vehicles in the central streets of the city and the subsequent increase in the volume and duration of traffic has led to an increase and accumulation of concentrations of pollutants in the streets and central areas of Tehran. Recently, intelligent and data-driven methods have become increasingly well known for forecasting of air pollution. In the current investigation, an approach was presented for the training ANFIS by using GA based on a population algorithm. At first, Genetic algorithm was implemented for optimal consequent parameters of ANFS. Then, these optimal values was applied for training ANFIS model. At the next step, for spatial modeling of PM_{10} concentration level during in the studied period, hotspot analysis in GIS was used to investigate the spatial changes of PM_{10} concentration and to identify hot and cold spots. In this study, modeling of PM_{10} by GA-ANFIS was done on three dataset such as air pollution data, meteorological, traffic volume. Meteorological parameter include the hourly wind speed (m/s), wind direction (*angle*), temperature ($^{\circ}C$) and relative humidity (%) were taken the weather measurement stations in Tehran. The air quality data, which comprises the hourly concentration of PM_{10} (ppb). Concentration of pollutant (PM_{10}) were obtained from the Air Quality Control Company of Tehran. Traffic data was obtained from Tehran Traffic Control Company. The time interval of traffic data and meteorological data were considered the same. These data, covering the period from 2010 to 2020, were acquired from 21 air monitoring stations. In this study, MATLAB 2020a programming language was used to implement ANFIS and hybrid of GA-ANFIS were proposed for PM_{10} concentration prediction and four indices were used for evaluate the results of the predication by ANFIS and GA-ANFIS models. ANFIS is a combination of neuronal networks and fuzzy system that proposed by Jang and Sun. To reach the optimized output, the ANFIS can coupled with hybrid learning methods like Imperialist Competitive algorithm (ICA), PSO or GA. Genetic Algorithms (GA) is a type of evolutionary heuristic search algorithm based on

genetic science. GA provides a random search that was used to solve optimization problems. It can be noted that GA-ANFIS algorithm can successfully improve the performance of the ANFIS model. In order to assessment of the patterns of spatial changes of PM_{10} concentration in the study period at the seasons of the year, a GIS modeling was applied to produce the simulation maps at different seasons during a study period. Spatial correlation of case study overall pollution concentrations was measured using global Moran's I and Getis-Ord general G indices. In order to identify hot and cold spots on maps, G statistics was used by Getis.

Result and discussion

The results of the global spatial autocorrelation analyses found high clustering levels for PM_{10} in the case study, which are significantly different from random at the 95% confidence level. In the monthly results, the critical values for PM_{10} pollutant occurred in the June to August (due to dust storms originating outside of Tehran). In general, there was no sensible similarity in the seasonal results. As the results of spatial autocorrelation analysis showed, PM_{10} Clusters separated the city into southwest parts, as most of cold spots were situated in the north and west. With the increase in traffic volume at the beginning of the fall season due to the

reopening of universities and schools, we are witnessing polluted critical days in Tehran. Starting of rainfall in late of winter, air pollution decreases and wind speed up to 4 m / s are ineffective in reducing pollution concentrations. The highest emission of particulate matter less than 10 microns is due to natural resources and due to the prevailing wind direction in Tehran from southwest to northeast, the high concentration of this pollutant in the districts of 18, 9, 10 and 15 at the entrances of Tehran, it seems logical. The lowest PM_{10} concentration was observed in the northeastern areas of the city.

Funding

There is no funding support.

Authors' Contribution

All of the authors approved the content of the manuscript and agreed on all aspects of the work.

Conflict of Interest

Authors declared no conflict of interest.

Acknowledgments

We are grateful to all the scientific consultants of this paper.



توسعه مدل GA-ANFIS به منظور پیش‌بینی غلظت آلاینده PM_{10} در یک بازه زمانی بلندمدت مطالعه موردی: شهر تهران

فریماه بخشی‌زاده^۱، نجمه نیسانی سامانی^۲ ✉، آرا تومانیان^۳

۱- گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران. رایانامه: f.bakhshizadeh@ut.ac.ir

۲- نویسنده مسئول، گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران. رایانامه: neysani@ut.ac.ir

۳- گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران. رایانامه: a.toomanian@ut.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۱/۱۱/۱۲

تاریخ بازنگری:

۱۴۰۱/۰۱/۱۱

تاریخ پذیرش:

۱۴۰۱/۰۲/۱۵

واژگان کلیدی:

آلودگی هوا،

الگوریتم ژنتیک،

خودهمبستگی مکانی،

سیستم استنتاج فازی-عصبی

تطبیقی،

بین انواع ذرات معلق در هوا، ذراتی با قطر کمتر از ۱۰ میکرون اثرات سوء بسیاری بر سلامتی انسان‌ها دارد. پارامترهای هواشناسی و جابجایی حجم بالایی از وسایل نقلیه مهم‌ترین عوامل تعدیل‌کننده در پراکنش و غلظت آلاینده‌های جوی محسوب می‌شوند. در این مطالعه، به‌منظور به منظور پیش‌بینی غلظت آلاینده PM_{10} طی یک باز بلند مدت در شهر تهران، مدل ترکیبی GA-ANFIS بکار برده شد. سرعت باد، جهت باد، دما، رطوبت نسبی و حجم ترافیک به‌عنوان ورودی‌ها و غلظت آلاینده PM_{10} به‌عنوان خروجی مدل در نظر گرفته شد. نتایج حاصل از محاسبه شاخص‌های عملکرد نشان داد که مدل ترکیبی GA-ANFIS نسبت به مدل ANFIS قابلیت مطلوب‌تری در پیش‌بینی غلظت آلاینده PM_{10} ارائه می‌دهد. به منظور ارزیابی الگوهای مکانی-زمانی غلظت آلاینده PM_{10} و شناسایی لکه‌های داغ و سرد در شهر تهران، آماره موران محلی و آماره گتیس ارد-جی محاسبه شد. نتایج نشان داد که سطح خوشه‌بندی بالایی از آلاینده PM_{10} در تهران (با سطح اطمینان ۹۵ درصد) وجود دارد. خوشه‌های PM_{10} شهر را به دو بخش شمالی و جنوبی تقسیم کرده‌اند به‌طوری‌که بیشتر نقاط سرد در نیمه شمالی و نقاط داغ در جنوب تا مرکز شهر گسترش پیدا کرده‌اند.

استناد: بخشی‌زاده، فریماه؛ نیسانی سامانی، نجمه و تومانیان، آرا. (۱۴۰۲). توسعه مدل GA-ANFIS به‌منظور به‌منظور پیش‌بینی غلظت آلاینده

PM_{10} در یک بازه زمانی بلندمدت مطالعه موردی: شهر تهران. مجله پژوهش‌های جغرافیای طبیعی، ۵۵ (۱)، ۷۸-۵۷

<http://doi.org/10.22059/JPHGR.2023.335120.1007663>



مقدمه

چالش زیست‌محیطی آلودگی هوا، به دلایل توسعه صنعتی، افزایش جمعیت، گسترش شهرنشینی، توسعه سیستم حمل‌ونقل و افزایش میزان مصرف سوخت‌های فسیلی، به پدیده شایع اغلب کلان‌شهرها از جمله شهر تهران تبدیل شده است. کلان‌شهر تهران به‌عنوان بیست و چهارمین شهر پرجمعیت دنیا، در رده دوازدهمین شهرهای آلوده دنیا قرار دارد (سازمان بهداشت جهانی، ۲۰۱۶). ذرات معلق یکی از مهم‌ترین آلاینده‌های جوی به حساب می‌آید که در اثر احتراق سوخت خودروها و ماشین‌آلات دیزلی فاقد استانداردهای لازم، فرآیندهای صنعتی، کشاورزی و غیره به وجود می‌آیند (استویمنوا و همکاران، ۲۰۱۷؛ کوچیا و همکاران، ۲۰۱۹؛ هان و همکاران، ۲۰۲۰). در بین انواع ذرات معلق، ذراتی با قطر کوچک‌تر از ۱۰ میکرون، به دلیل نفوذ در سیستم تنفسی انسان، برای سلامتی انسان‌ها خطرناک‌تر می‌باشد (دی رویج و همکاران، ۲۰۱۷). عوامل اصلی انتشار این آلاینده در شهر تهران، منابع متحرک (وسایل نقلیه) و منابع ساکن آلودگی (کارگاه‌های عمرانی و پالایشگاه‌های اطراف شهر) می‌باشد (آذرمی و همکاران، ۲۰۱۶؛ طاهری شهرایی و سودودی، ۲۰۱۶). پارامترهای هواشناسی از قبیل سرعت و جهت باد، دما و رطوبت نسبی تأثیر مهمی در شکل‌گیری، انتقال، تجمع و رسوب آلاینده‌های جوی دارند (خان و همکاران، ۲۰۱۵؛ ژانگ و دینگ، ۲۰۱۷). علاوه بر تأثیر مهم پارامترهای هواشناسی، حجم ترافیک عبوری در کلان‌شهرها یک عامل بسیار مهم در روند تغییرات غلظت آلاینده‌های جوی می‌باشد (ژو و همکاران، ۲۰۰۲؛ بالدوف و همکاران، ۲۰۱۶؛ یانوسکی و همکاران، ۲۰۱۸).

به‌منظور پیش‌بینی غلظت انواع آلاینده‌های جوی و بررسی ارتباط بین پارامترهای هواشناسی و داده‌های ترافیکی با استفاده از تکنیک‌های یادگیری ماشین^۱، پژوهش‌های متعددی تاکنون صورت گرفته است. در پژوهشی به‌منظور پیش‌بینی شاخص کیفیت هوا در شهر ووهان چین، القانس و همکاران (۲۰۲۱) مدل ترکیبی PSOSMA-ANFIS را بکار بردند. در مدل پیشنهادی آن‌ها به‌منظور بهینه‌سازی پارامترهای مدل ANFIS از مدل SMA^۲ به‌عنوان یک مدل فرا ابتکاری جدید استفاده شد که پارامترهای این مدل با استفاده از مدل ازدحام انبوه ذرات^۳ (PSO) بهینه می‌شوند. غلظت آلاینده‌های CO_2 ، NO_2 ، $PM_{2.5}$ و SO_2 در عنوان ورودی و شاخص کیه‌عنوانبه عنوان خروجی مدل PSOSMA-ANFIS در نظر گرفته شد. نتایج حاصل از فرآیند پیش‌بینی شاخص کیفیت هوا نشان داد که مدل ترکیبی بهبودیافته در مقایسه با مدل ANFIS عملکرد بالایی در پیش‌بینی شاخص کیفیت هوا ارائه می‌دهد. هامپ و همکاران به‌منظور محاسبه شاخص کیفیت هوا در شهر مانچ آلمان کارایی سه مدل ANFIS، MLR و SVM را مورد بررسی و ارزیابی قرار دادند. بدین منظور، داده‌های هواشناسی، داده‌های مربوط به شاخص کی ثبت‌شده در ایستگاه‌های پایش آلودگی هوا و داده‌های ترافیک ساعتی و سایه‌عنوانبه عنوان پارامترهای ورودی به سه مدل در بازه زمانی ۲۰۱۴ الی ۲۰۱۸ در نظر گرفته شد. نتایج حاصل از شاخص‌های عملکرد محاسبه‌شده بیانگر آن بود که مدل ANFIS دارای بالاترین قدرت پیش‌بینی برای تمامی آلاینده‌هاست. تعیین پارامترهای ورودی مناسب و شناسایی ساختار بهینه برای مدل ANFIS جهت دستیابی به خروجی مناسب، بخش مهمی در به‌کارگیری این مدل می‌باشد؛ بدین منظور قاسمی و همکاران (۲۰۱۹) آزمون‌های خطی^۴ و تکنیک

1. Machine Learning
2. Slime Mould Algorithm
3. Particle Swarm Optimizer
4. Collinearity Tests

روبه‌جلو^۱ به منظور منظور کاهش زمان محاسبات و حذف متغیرهای ورودی اضافی بکار بردند. غلظت آلاینده‌های CO_2 ، NO_2 ، PM_{10} ، SO_2 و O_3 در روز گذشته و پارامترهای هواشناسی (دما، رطوبت نسبی، بارش، سرعت باد، نقطه شبنم، فشار) در یک‌به‌عنوانانی دوساله به عنوان ورودی‌های مدل در نظر گرفته شد. نتایج خروجی حاکی از آن بود که ترکیب‌های مختلف از داده‌های ورودی و قوانین فازی با روش سعی و خطا، استفاده از تکنیک S غیرضروری پارامترهای غیرضروری در فرآیند مدل‌سازی با استفاده از تأثیر NFIS می‌تواند تأثیر مطلوبی در نتایج خروجی داشته باشد به منظور ارزیابی عوامل موثر در انتشار دو آلاینده CO و NO_x ، در شهر کرم، سلیمان و همکاران (۲۰۱۸) با در نظر گرفتن نوع ترافیک (سنگین، نیمه سنگین و روان)، از مدل ANFIS استفاده کردند. نتایج حاصل از این بررسی بیانگر آن بود که با کاهش میزان تردد در سطح تقاطع‌ها و به دنبال آن ترافیک‌های سبک و روان، مصرف سوخت وسایل نقلیه کاهش یافته و به طبع در کاهش میزان آلاینده‌های کمک کند. به منظور پیش‌بینی غلظت ذرات معلق در یک بازه زمانی کوتاه‌مدت با سه مجموعه داده هواشناسی، غلظت ذرات معلق‌عنواناترهای مکانی به عنوان ورودی مدل در شهر رومانی، می‌هالاچه و همکاران (۲۰۱۵) از مدل ANFIS استفاده کردند. نتایج حاصل از مطالعه آن‌ها نشان داد که مدل پیش‌بینی به دست آمده قادر است برای هشدار به جمعیت در معرض آلودگی، زمانی که غلظت ذرات معلق فراتر از حد استاندارد قرار می‌گیرد، موثر و کارآمد واقع شود. در زمینه ارزیابی الگوهای مکانی-زمانی آلاینده‌های CO و $PM_{2.5}$ در سطح شهر تهران، می‌توان به مطالعه‌ی که توسط حبیبی و همکاران (۲۰۱۷) صورت گرفته است، در این پژوهش به منظور شناسایی لکه‌های داغ و سرد آلاینده‌های CO و $PM_{2.5}$ از شاخص‌های همبستگی موران^۲ و گتیس^۳ استفاده شد. نتایج نشان داد که لکه‌های داغ از نظر آلاینده $PM_{2.5}$ در قسمت‌های جنوب و جنوب غربی و لکه‌های سرد در بخش‌های شمالی شهر تهران قرار دارند. اما از نظر آلاینده CO در نواحی شمال شرق و جنوب غربی شهر لکه‌های داغ بیش‌تری مشاهده شد و لکه‌های سرد در سایر بخش‌ها پراکنده هستند. پژوهش‌های مشابه دیگری که در رابطه با روند تغییرات مکانی-زمانی ذرات معلق در سطح شهر تهران صورت گرفته است می‌توان به مطالعات نادیان و همکاران (۱۳۹۷)؛ عزیززاده و همکاران (۲۰۱۶)؛ بهاری و همکاران (۱۳۹۴)؛ شرعی‌پور و بیدختی (۱۳۹۳) اشاره نمود. نتایج حاصل از تمامی مطالعات نشان داد که از سمت شمال به جنوب و از سمت شرق به غرب غلظت ذرات معلق روند افزایشی داشته و بالاترین میزان غلظت آن در بخش‌های جنوبی و جنوب در فصول سرد سال ثبت شده است.

بررسی پژوهش‌های پیشین نشان می‌دهد که علاوه بر عامل ترافیک، یکی از مهم‌ترین مجموعه داده‌ای که به‌طور متداول در پیش‌بینی غلظت انواع آلاینده‌ها موردتوجه قرار گرفته است، پارامترهای هواشناسی و بررسی تأثیرات این پارامترها بر روند تغییرات غلظت انواع آلاینده‌ها بوده است. در دنیای واقعی، داده‌های غلظت آلاینده‌ها در بازه‌های زمانی مختلف، متغیر بوده و رفتار خطی را از خود نشان نمی‌دهند (ژانگ و دینگ، ۲۰۱۷). بنابراین روش‌های مبتنی بر یادگیری ماشین با برقراری روابط غیرخطی بین ورودی‌ها و خروجی، در حل بسیاری از مسائل پیچیده بسیار کارآمد می‌باشد (پاشالی‌دو و همکاران، ۲۰۱۱). چالش مهم در به‌کارگیری اغلب مدل‌های مبتنی بر یادگیری ماشین، تعیین بهینه پارامترها و ساختار مدل جهت دسترسی به خروجی مطلوب می‌باشد. روش رایج و متداول جهت تعیین پارامترهای تنظیم اولیه مدل‌های مبتنی بر یادگیری ماشین، روش سعی و خطا و آزمون می‌باشد. برای دستیابی به مقادیر بهینه پارامترهای اولیه این مدل‌ها، الگوریتم‌های بهینه‌سازی متعددی قادر به ارائه پاسخ‌های بهینه می‌باشند. نظر به

1. Forward Selection
2. Moran I
3. Getis

قابلیت‌های مدل‌های مبتنی بر یادگیری ماشین و کاربرد گسترده آن در انواع علوم محیطی، باین‌حال به‌کارگیری این مدل‌ها در ترکیب با مدل‌های فرا ابتکاری در زمینه پیش‌بینی غلظت آلاینده‌ها چندان موردتوجه قرار نگرفته است. لذا هدف از پژوهش حاضر پیش‌بینی غلظت آلاینده PM_{10} در ایستگاه‌های پایش آلودگی هوا در سطح شهر تهران در یک بازه زمانی ۱۰ ساله (۱۳۹۰-۱۳۹۹) با استفاده از مدل ANFIS و مدل ترکیبی GA-ANFIS می‌باشد. سپس در راستای تحلیل صحیح و دقیق روند تغییرات مکانی-زمانی این آلاینده، آنالیز خودهمبستگی مکانی (آماره موران محلی) به‌منظور شناسایی لکه‌های داغ و سرد، آماره گتیس ارد-جی محاسبه گردید.

روش پژوهش

پارامترهای موثر در روند تغییرات غلظت آلاینده PM_{10}

علی‌رغم شناسایی منابع اصلی انتشار آلاینده‌ها، شناخت پارامترهای موثر در روند تغییرات غلظت آلاینده‌ها حائز اهمیت می‌باشد (ونگاس و مازئو، ۲۰۰۶). پارامترهای هواشناسی به علت ماهیت بسیار پویا و دینامیک در طی فصول مختلف سال و تأثیرپذیری بالای فرآیندهای پخش و تراکم غلظت آلاینده‌های جوی از آن‌ها، به‌عنوان یک فاکتور مهم در ورودی اکثر مدل‌ها در نظر گرفته می‌شوند (مسعودی و همکاران، ۲۰۱۶؛ قطبی و همکاران، ۲۰۱۶؛ ارحمی و همکاران، ۲۰۱۷). پارامتر باد بسته به سرعت و جهت آن در انتقال و جابه‌جایی ذرات آلوده از سطح شهر حائز اهمیت است (اکبری و همکاران، ۲۰۱۸). با افزایش سرعت باد انجام واکنش‌های شیمیایی کاهش پیدا کرده و بدنبال باعث کاهش غلظت انواع آلاینده‌ها می‌شود (برکوویچ و همکاران، ۱۹۹۶؛ اکینیمی و همکاران، ۲۰۱۶). در رابطه با عامل باد این نکته را هم باید در نظر داشته باشیم در مواردی که وزش تندبادهای سبب وقوع پدیده گردوغبار می‌شود، غلظت ذرات معلق، بویژه PM_{10} به طرز قابل توجهی افزایش پیدا می‌کند (لی و همکاران، ۲۰۱۵؛ سیکوویچ و همکاران، ۲۰۲۰). افزایش دما و خشکی هوا، سبب تسریع واکنش‌های فتوشیمیایی شده و با کیفیت نامطلوب هوا همراه است (کاتسویانی و همکاران، ۱۹۹۳؛ روبرتز، ۲۰۰۴). لازم به ذکر است که وارونگی دمایی و پایداری جو در فصول سرد سال شهر تهران، یکی از عوامل بسیار مهم در تجمع آلودگی هوا و افزایش غلظت آلاینده‌ها در نزدیکی زمین می‌باشد (کیخسروی و لشگری، ۲۰۱۱؛ یآوری و سلیقه، ۲۰۱۴). روند تغییرات رطوبت نسبی هماهنگ با الگوی تغییرات دما اسبه‌طوریری که ماکزیمم و منیمم رطوبت نسبی مطابق با کمینه و بیشینه دما می‌باشد (خان و همکاران، ۲۰۱۵؛ ژانگ و دینگ، ۲۰۱۷).

ترافیک وسایل نقلیه به‌عنوان عاملی تأثیرگذار دیگری در تشدید غلظت آلاینده‌ها محسوب می‌شود. توسعه نامتوازن کلان‌شهرها، افزایش روزافزون وسایل نقلیه موتوری با توجه به رشد روزافزون منابع و امکانات و افزایش تقاضا، معضل تراکم ترافیک را به‌عنوان یکی از بزرگ‌ترین مشکلات حمل‌ونقل درون شهری و آلودگی ناشی از آن در شهر تهران مطرح کرده است (شهبازی و همکاران، ۲۰۱۷). از اینرو، در این مطالعه از داده‌های میانگین غلظت روزانه آلاینده PM_{10} ثبت شده توسط ایستگاه‌های سنجش آلودگی هوا، داده‌های روزانته‌شده‌دهه مربوط به پارامترهای هواشناسی (سرعت و جهت باد، دما و رطوبت نسبی) در ایستگاه‌های سینوپتیک هواشناسی (ایستگاه مهرآباد، ژئوفیزیک، شمیران و چیتگر) و داده‌های روزانه حجم ترافیک عبوری خیابان‌های سطح شهر تهران در بازه زمانی ۱۳۹۰ تا ۱۳۹۹ استفاده شد. داده‌های مربوط به حجم ترافیک عبوری از دوربین‌های نصب شده در سطح تقاطع‌ها گردآوری شد.

الگوریتم GA-ANFIS

سیستم استنتاج فازی - عصبی تطبیقی^۱ (ANFIS)

مدل ANFIS ترکیبی از شبکه‌های عصبی و سیستم استنتاج فازی است که در سال ۱۹۹۲ توسط جانگ پیشنهاد شد (جانگ، ۱۹۹۳). این مدل از ترکیب قابلیت تولید قوانین فازی مدل FIS و قابلیت آموزش در شبکه‌های عصبی مصنوعی بطور گسترده در حل مسائل با درجه پیچیدگی بالا استفاده می‌شود (جانگ، ۱۹۹۳؛ جانگ، ۱۹۹۶). اگر موارد ضعف و قوت سیستم‌های فازی و شبکه‌های عصبی مصنوعی را در نظر بگیریم، این دو ساختار می‌توانند ماهیت مکملی نسبت به یکدیگر داشته باشند (لی و وان، ۲۰۱۲؛ شهرآیینی و همکاران، ۲۰۱۵؛ پراساد و همکاران، ۲۰۱۶). در ساختار ANFIS مجموعه‌های فازی را می‌توان به عنوان وزن ارتباطات و پارامترهای ورودی و خروجی را به عنوان نرون‌ها تفسیر کرد. اگر سیستم استنتاج فازی دارای دو ورودی x و y و یک خروجی f باشد، آنگاه سیستم فازی شامل دو قانون "اگر-آنگاه" به شرح زیر است:

$$\text{Rule 1: If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1 \quad (1)$$

$$\text{Rule 2: If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = p_2x + q_2y + r_2 \quad (2)$$

در روابط بالا، A_1 ، A_2 ، B_1 و B_2 پارامترهای غیرخطی و توابع عضویت برای ورودی‌های x و y ، p_1 ، q_1 ، r_1 ، p_2 ، q_2 ، r_2 پارامترهای تابع خطی برای خروجی (f) هستند که در طول فرآیند آموزش تعیین می‌شوند. یک ساختار ANFIS شامل پنج لایه با عملکردهای مختلف است. شکل ۱ لایه‌ها، گره‌ها و اتصالات بین لایه‌ها را با فرض دو ورودی x و y و یک خروجی f نشان می‌دهد.

لایه ۱: گره‌های موجود در این لایه سری‌های فازی در ارتباط با بخش نخستین قوانین فازی را ارائه می‌دهند (فرآیند فازی‌سازی^۲). موقعیت بخش مرکزی و اصلی هر سری فازی در این لایه با پارامترهایی کنترل شده و درجات عضویت تعیین می‌گردد. در این پژوهش از تابع عضویت گوسی برای تعیین درجات عضویت استفاده شده است. فرآیند فازی‌سازی با روش تاکاگی-سوگنو^۳ درجه یک صورت گرفت (فنگ و همکاران، ۲۰۱۳؛ چن، ۲۰۱۸). که در آن تعامل بین ورودی و خروجی یک رابطه فازی نیست بلکه تابعی است از ورودی‌ها بر پایه خوشه‌بندی کاهشی^۴، که براساس شباهت‌های موجود آن‌ها را دسته‌بندی کرده و قواعد را برای هر دسته تعریف می‌کند.

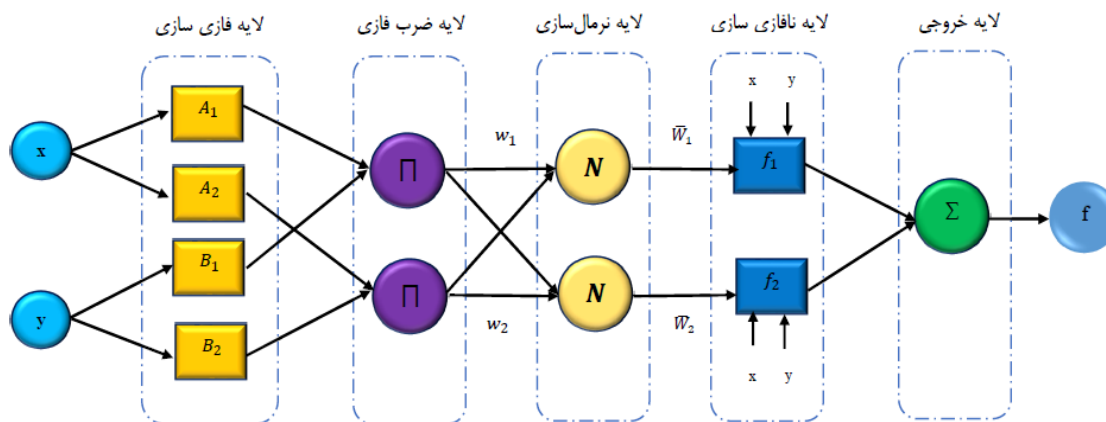
$$\mu_{A_i}(x) = \exp \left[- \left(\frac{x - c_i}{a_i} \right)^2 \right], \quad (3)$$

در رابطه (۳)، a_i و c_i پارامترهای تنظیم تابع عضویت گوسی می‌باشد. با تغییر مقادیر این پارامترها، شکل تابع گوسی متناسب با آن تغییر می‌کند. حداکثر مقدار آن ۱ و حداقل آن برابر ۰ است.

لایه ۲: هر گره در این لایه سیگنال‌های ورودی را ضرب کرده و نتایج خود را محاسبه می‌کند (لایه استلزام^۵ یا ارزیابی قواعد). در رابطه (۴)، $\mu_{A_i}(x)$ و $\mu_{B_i}(y)$ سری‌های فازی هستند که برای پارامترهای ورودی x و y تعریف شده‌اند. در این لایه میزان فعالسازی قوانین خاص فازی مشخص می‌شود.

1. Adaptive Neuro-Fuzzy Inference System
2. Fuzzification Layer
3. Takagi-Sugeno
4. Subtractive Clustering
5. Product Layer

$$W_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i = 1,2 \quad (۴)$$



شکل ۱. ساختار سیستم استنتاج فازی - عصبی تطبیقی (ANFIS)

لایه ۳: خروجی لایه دوم، W_1 و W_2 می‌باشد که در لایه سوم این وزن‌ها از طریق رابطه (۵) نرمال می‌شوند (لایه نرمال‌سازی ۱).

$$\bar{W}_i = \frac{w_i}{w_1 + w_2} \quad i = 1,2 \quad (۵)$$

لایه ۴: به ازای هر ورودی، وزن‌های نرمال شده در خروجی مربوطه ضرب خواهند شد و خروجی آن $\bar{W}_1 f_1$ و $\bar{W}_2 f_2$ می‌باشد (لایه نافازی‌سازی ۲).

$$\bar{W}_1 f_1 = \bar{W}_1 (p_1 x + q_1 y + r_1) \quad (۶)$$

$$\bar{W}_2 f_2 = \bar{W}_2 (p_2 x + q_2 y + r_2) \quad (۷)$$

لایه ۵: در لایه پایانی، خروجی کلی و نهایی (f) به ازای تمامی ورودی‌ها محاسبه می‌شود (لایه خروجی ۳).

$$O_1^5 = \text{Overall output} = \sum_i \bar{W}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (۸)$$

به‌منظور عملکرد مطلوب مدل ANFIS، لازم است پارامترهای اولیه در لایه نخست (مرکز و دامنه تابع عضویت) و پارامترهای حاصل در لایه چهارم $\{p_i, q_i, r_i\}$ که متناظر با ضریب‌های حاصل از مدل گوسی هستند، باید بهینه شوند (بودنیک و کاستلین، ۲۰۱۹). بهینه‌سازی این پارامترها می‌تواند دقت و کیفیت آموزش شبکه را به میزان قابل توجهی افزایش دهد (باسر و همکاران، ۲۰۱۵). با بکارگیری یک الگوریتم فرا ابتکاری مناسب، می‌توان پارامترهای بهینه را بدست آورد (باغبان و همکاران، ۲۰۱۵). در این مطبیه منظور منظور بهینه‌سازی پارامترهای مدل ANFIS، از الگوریتم ژنتیک استفاده شده است.

الگوریتم ژنتیک^۴ (GA)

الگوریتم ژنتیک از جمله الگوریتم‌های فراابتکاری مبتنی بر تکرار به شمار می‌رود که بطور متداول در حل مسائل بهینه‌سازی با فضای جستجوی تصادفی بکار می‌رود (گلدبرگ و هالند، ۱۹۸۸). این الگوریتم به سه مرحله اصلی تولید جمعیت اولیه، عملگرهای GA

1. Normalized Layer
2. De-Fuzzification Layer
3. Output Layer
4. Genetic Algorithm

(انتخاب^۱، جهش^۲ و ترکیب^۳) و ارزیابی نهایی از طریق تابع برازندگی^۴ تقسیم می‌شود (هاپت، ۲۰۰۴). روند حل مسئله در این الگوریتم به این صورت است که در ابتدا جمعیت^۵ اولیه (مجموعه‌ای از پاسخ‌ها برای حل مسئله بهینه‌سازی) که مقید به حد بالا و پایین متغیرهای مساله هستند، معرفی می‌شوند. در گام بعد، کروموزوم‌ها^۶ (راه‌حل‌های مسئله) جهت تعیین جواب بهینه مساله مورد ارزیابی قرار می‌گیرند (چینک، ۲۰۰۶). پس از انتخاب کروموزوم‌های بهینه، با استفاده از عملگرهای الگوریتم ژنتیک، این کروموزوم‌ها با هم ترکیب می‌شوند و جهشی در آن‌ها ایجاد می‌کنیم. در هر مرحله از تولید نسل انتظار می‌رود که جواب‌های حاصل از جمعیت جدید نسبت به جمعیت قبلی بهتر باشد (چینک، ۲۰۰۶؛ کوزا، ۲۰۰۷). انتخاب تعدادی از جواب‌ها (کروموزوم‌ها) از میان کل جواب‌ها (والدین^۷) به منظور تولید جواب‌های جدید براساس میزان مطلوبیت آن‌ها می‌باشد که این کار با استفاده از تابع برازندگی صورت می‌گیرد. مسلم است که جواب‌های مناسب‌تر شانس بیش‌تری برای تولید نسل مجدد داشته باشند. این روند تا برقراری شرطی که از پیش تعیین شده است، ادامه می‌یابد (گلدبرگ و هالند، ۱۹۸۸؛ چینک، ۲۰۰۶؛ کوزا، ۲۰۰۷).

شاخص‌های ارزیابی

جهت ارزیابی درستی و صحت نتایج حاصل از پیش‌بینی غلظت آلاینده PM_{10} با استفاده از مدل ANFIS و GA-ANFIS چهار شاخص عملکرد^۸ (PI)، $RMSE^9$ ، $MARE^{10}$ ، MBE^{11} و R^2 محاسبه گردید. شاخص‌های عملکرد، دو کمیت صحت و خطا را اندازه‌گیری می‌کنند. مقادیر صحت محاسبه شده بوسیله شاخص‌های توافق بین مقادیر ۰ و ۱ قرار می‌گیرد. مقادیر نزدیک به ۱، نشان دهنده بهترین برازش و عملکرد مدل می‌باشند در حالی که هرچه این مقادیر به ۰ نزدیک شوند، مقادیر پیش‌بینی شده با درصد بالایی از خطا همراه خواهند بود (آرجون و آنیش، ۲۰۱۵). شاخص‌های محاسبه شده در این مطالعه به صورت معادلات زیر می‌باشد:

$$RMSE = \left(\frac{1}{n} \sum_{i=1}^n [p_i - o_i]^2 \right)^{0.5} \quad (9)$$

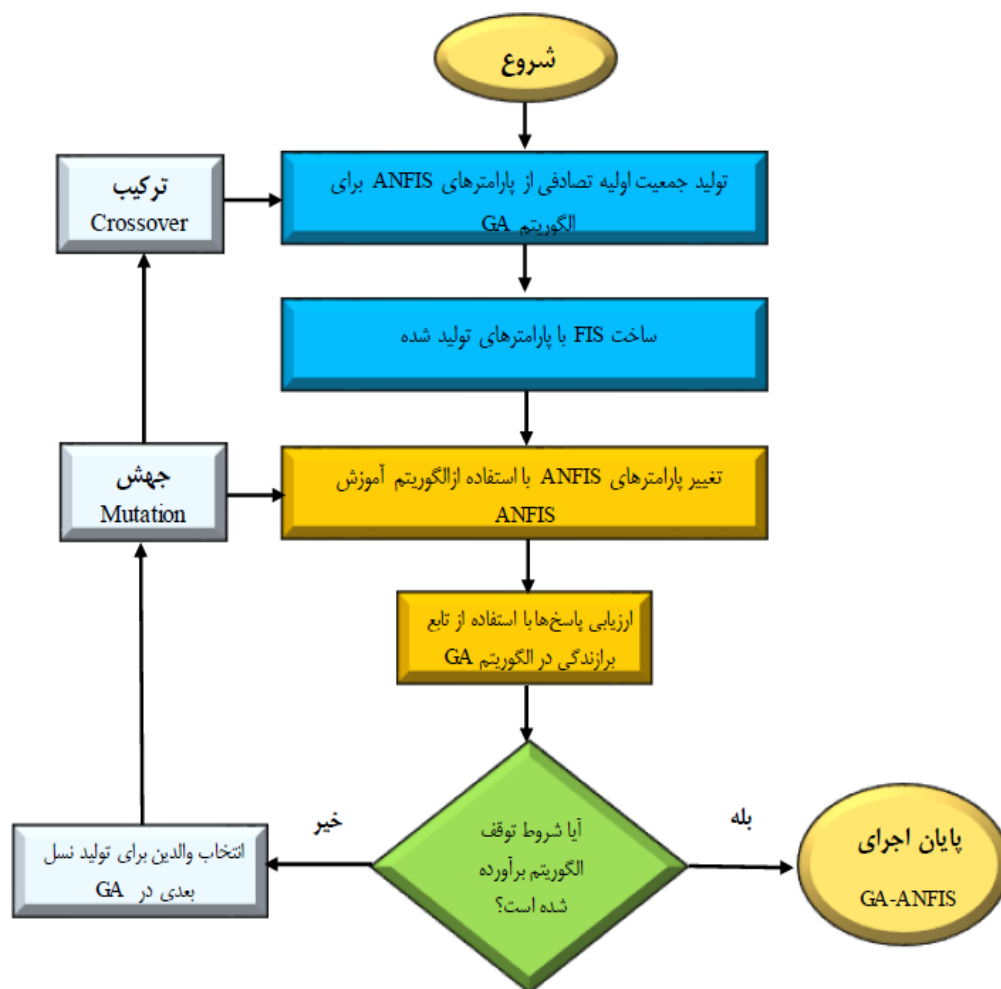
$$R^2 = \left[\left(\frac{1}{n \cdot S_{pred} \cdot S_{obs}} \right) \sum_{i=1}^n (P_i - \bar{P})(O_i - \bar{O}) \right]^2 \quad (10)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (p_i - o_i) \quad (11)$$

$$MARE = \frac{100}{n} \sum_{i=1}^n \left| \frac{p_i - o_i}{o_i} \right| \quad (12)$$

n تعداد کل داده‌ها، P_i مقادیر پیش‌بینی شده، O_i مقادیر مشاهده شده، \bar{P} متوسط مقادیر پیش‌بینی شده، \bar{O} متوسط مقادیر مشاهده شده شده، S_{pred} انحراف معیار مقادیر پیش‌بینی شده و S_{obs} انحراف معیار مقادیر مشاهده شده می‌باشد. شکل ۲ فلوچارت مراحل اجرای الگوریتم ترکیبی GA-ANFIS جهت پیش‌بینی غلظت آلاینده PM_{10} را نشان می‌دهد.

1. Selection
2. Mutation
3. Crossover
4. Fitness function
5. Population
6. Chromosome
7. Parent
8. Performance Indicators
9. Root Mean Square Error
10. Mean Absolut Relative Error
11. Mean Bias Error



شکل ۲. فلوچارت بهینه سازی ساختار ANFIS با استفاده از الگوریتم ژنتیک (GA)

آنالیز خودهمبستگی مکانی

خودهمبستگی مکانی برای شناسایی شباهت‌های پدیده‌های نزدیک بهم از طریق ارزیابی توزیع مکانی مجموعه مشخصی از ویژگی‌ها به صورت خوشه‌ای، پراکنده و تصادفی استفاده می‌شود (شرعی‌پور و بیدختی، ۲۰۱۴؛ فنگ و همکاران، ۲۰۱۶). در خوشه‌بندی مکانی اگر نقاط همسایه از نظر یک ویژگی باهم شباهت داشته باشند به این معنی است که این نقاط از نظر مکانی بهم وابسته بوده و در یک خوشه قرار می‌گیرند (جوهانسون و همکاران، ۲۰۰۷). شاخص خودهمبستگی موران^۱ به دو صورت عمومی^۲ و محلی^۳ به عنوان روشی متداول جهت اندازه‌گیری میزان همبستگی فضایی بکار برده می‌شود (انسلین، ۱۹۹۵؛ روزنلوند و همکاران، ۲۰۰۸). در آماره موران عمومی علاوه بر توجه به نحوه قرارگیری عوارض در کنار هم، ویژگی‌های عوارض هم در نظر گرفته می‌شود و میزان خودهمبستگی فضایی با توجه به موقعیت مکانی و مقادیر درونی عوارض محاسبه می‌گردد. آماره موران عمومی از رابطه زیر محاسبه می‌شود (گودچایلد، ۱۹۸۶):

1. Moran's I
2. Global
3. Local

$$I_0 = \frac{n}{S_0} \times \frac{\sum_{i=1}^n \sum_{j=1}^n W_{ij} (X_i - \bar{X})(X_j - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (13)$$

در رابطه شماره ۱۳، X_i و X_j مقادیر متغیر موردنظر در مکان‌های i و j ، \bar{X} میانگین ویژگی موردنظر، W_{ij} مقدار وزن فضایی عوارض i و j ، n تعداد کل داده‌ها، S_0 جمع کل وزن‌های فضایی را نشان می‌دهد. جمع کل وزن‌ها از رابطه (۱۰) محاسبه می‌شود:

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n W_{ij} \quad (14)$$

دامنه تغییرات آماره موران عمومی بین -۱ تا +۱ است. اگر عوارض i و j در همسایگی هم قرار گرفته باشند، مقدار W_{ij} برابر یک می‌باشد در غیر این صورت مقدار آن صفر بدست می‌آید. در دیدگاه عمومی، این آماره قادر به شناسایی خوشه‌های انفرادی نیست و فقط خوشه‌بندی کلی متغیر غلظت PM_{10} را نشان می‌دهد. بدین جهت لازم است به منظور شناسایی لکه‌های داغ^۱ (مقادیر با ارزش بالا) و لکه‌های سرد^۲ (مقادیر با ارزش پایین)، آماره موران محلی^۳ نیز محاسبه شود (انسلین، ۱۹۹۵). این آماره ارتباط فضایی بین یک نقطه و همسایگی آن را با استفاده از رابطه زیر محاسبه می‌کند:

$$I_i = n(X_i - \bar{X}) \sum_{j=1, j \neq i}^n W_{ij} (X_j - \bar{X}) \quad (15)$$

توصیف متغیرهای رابطه (۱۵) همانند رابطه (۱۳) می‌باشد. مقادیر مثبت I_i نشان‌دهنده این است که مقدار غلظت PM_{10} در یک مکان مشخص با ارزش‌های مشخص توسط موقعیت‌هایی با مقادیر مشابه همان مکان‌ها احاطه شده است (بالا-بالا^۴ یا پایین-پایین^۵). از طرفی دیگر مقادیر منفی و معنی‌دار I_i بیانگر این است که عارضه موردنظر توسط عوارضی که از نظر ارزشی هیچگونه مشابهتی با هم ندارند احاطه شده است (بالا-پایین^۶ یا پایین-بالا^۷). در به‌منظور منظور بررسی تغییرات و توزیع مکانی لکه‌های داغ (مقادیر با ارزش‌های بالا) و لکه‌های سرد (مقادیر با ارزش‌های پایین) آلاینده PM_{10} در سطح منطقه مورد مطالعه، از آماره گتیس ارد جی^۸ استفاده شد (انسلین و گتیس، ۱۹۹۲). این آماره به صورت زیر محاسبه می‌شود (ارد و گتیس، ۱۹۹۵):

$$G_i^* = \frac{\sum_{j=1}^n W_{ij} X_j - \bar{X} \sum_{j=1}^n W_{ij}}{S \sqrt{\frac{n \sum_{j=1}^n W_{ij}^2 - (\sum_{j=1}^n W_{ij})^2}{n-1}}} \quad (18)$$

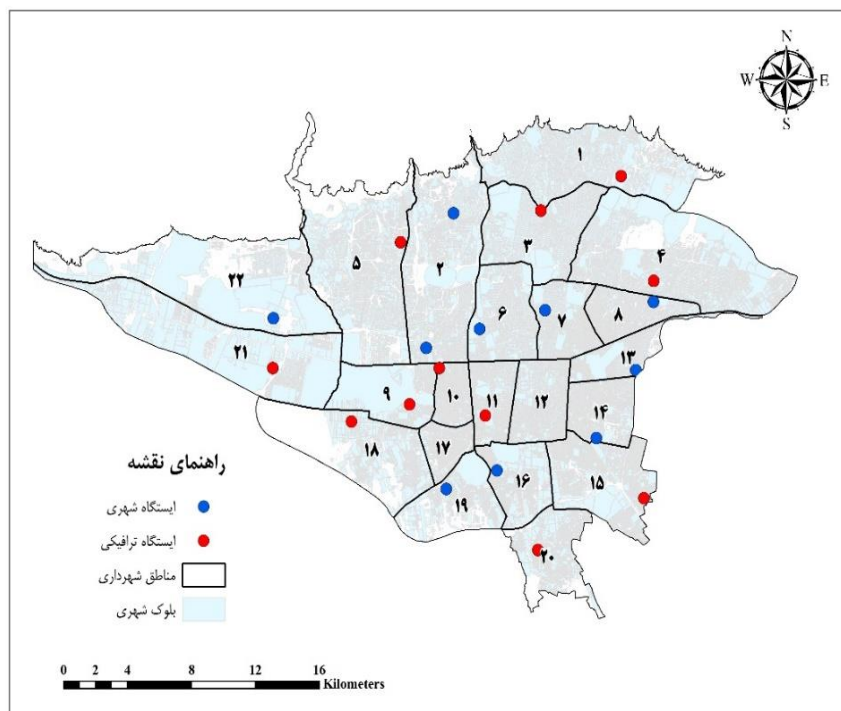
چهارچوب مفهومی این آماره به این صورت است که عارضه‌ای لکه داغ محسوب می‌شود که خود عارضه و عوارض اطراف آن از نظر آماری معنادار بوده و مقادیر بالایی داشته باشند. نمره منفی و معنادار این شاخص به معنای خوشه‌بندی مقادیر پایین خواهد بود و بیانگر لکه‌های سرد می‌باشد.

محدوده مورد مطالعه

مطابق شکل (۱) کلان‌شهر تهران در دامنه جنوبی رشته‌کوه‌های البرز واقع شده است (حسینی و شهبازی، ۲۰۱۶) و بالغ بر ۸/۵ میلیون نفر جمعیت دارد. ارتفاع شهر از سطح دریاهای آزاد در نواحی شمالی شهر ۱۷۰۰ متر، در مرکز ۱۲۰۰ و در جنوب ۱۱۰۰ متر و شیب عمومی شهر شمال به جنوب است (هگر و ساراف، ۲۰۱۸). به دلیل موقعیت خاص جغرافیایی شهر، در قسمت‌های شمالی دارای

1. Hot Spot
2. Cold Spot
3. Anselin Local Moran's
4. High-High
5. Low-Low
6. High-Low
7. Low-High
8. Getis-Ord-Gi

آب‌وهوای معتدل و کوهستانی و در نقاط کم ارتفاع نیمه‌خشک است. در حال حاضر ۲۱ ایستگاه فعال سنجش آلودگی هوا (۱۰) ایستگاه در گروه ایستگاه‌های شهری و غیر ترافیکی و ۱۱ ایستگاه در گروه ایستگاه‌های) در سطح شهر کار پایش و ثبت غلظت آلاینده‌های جو را در مقیاس‌های زمانی ساعتی، روزانه، ماهیانه و سالانه انجام می‌دهند.



شکل ۳. موقعیت مکانی منطقه مورد مطالعه و ایستگاه‌های پایش آلودگی هوا

یافته‌های پژوهش

اولین مرحله در اجرای مدل ANFIS تعیین ورودی و هدف می‌باشد. بدین منظور شبکه‌ای با ۵ پارامتر شامل سرعت و جهت باد، دما، رطوبت نسبی و حجم ترافیک به عنوان ورودی و غلظت PM_{10} خروجی مدل در نظر گرفته شد و مدل‌های ANFIS و GA-ANFIS در محیط MATLAB2020a پیاده‌سازی شد. جهت دستیابی به یک خروجی مناسب و عملکرد مطلوب مدل ANFIS تعیین تعداد کافی و مناسب خوشه‌ها بسیار حائز اهمیت می‌باشد. از روش خوشه‌بندی فازی c-means برای تشکیل یک سیستم استنتاج فازی و برای تعیین تعداد قوانین و توابع عضویت از تابع خوشه‌بندی FCM که به genfis3 معروف است، استفاده شد. از مجموع ۵۹۳۵۶ داده، ۸۰ درصد جهت آموزش شبکه، ۱۰ درصد جهت اعتبارسنجی و ۱۰ درصد باقی‌مانده جهت تست مدل مورد استفاده قرار گرفته‌منظور اجرای یک سیستم فازی با استفاده از مدل ANFIS، ابتدا تابع genfis3 برای ایجاد یک ساختار FIS از نوع تاکاگی-سوگنو (TSK) با استفاده از خوشه‌بندی فازی c-means جهت استخراج مجموعه‌ای از قوانین و توابع عضویت که داده‌های آموزش را مدل می‌کند، اجرا می‌شود و یک تابع گوسین جهت بهینه‌سازی پارامترها بکار برده می‌شود. در اجرای مدل GA-

ANFIS، پارامترهای اولیه الگوریتم GA از قبیل اندازه جمعیت اولیه، حداکثر تعداد تکرارها، روش selection، مقدار پارامتر گاما^۱ و بناً، درصد crossover، درصد و نرخ Mutation برای دستیابی به نتایج بهینه و مطلوب با روش سعی و خطا و ارزیابی خروجی نتایج در هر مرحله تعیین گردید (بانو و سوجا، ۲۰۱۴؛ رضا کاظمی و همکاران، ۲۰۱۷؛ سیلان و همکاران، ۲۰۱۸). الگوریتم GA جهت بهینه‌سازی پارامترهای مدل ANFIS و به حداقل رساندن میزان خطا با تنظیم و بهینه‌سازی توابع عضویت با سیستم استنتاج فازی از نوع سوگنو بکار برده شد (حسینی و همکاران، ۲۰۱۸).

خلاصه‌ای از مقادیر پارامترهای اولیه مدل‌های ANFIS و GA-ANFIS به منظور پیش‌بینی غلظت آلاینده PM_{10} در جدول ۱ آورده شده است. مقایسه نتایج خروجی حاصل از مدل‌های ANFIS و GA-ANFIS چهار شاخص میانگین انحراف خطا (MBE)، میانگین قدرمطلق خطای نسبی (MARE)، مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی (R^2) محاسبه شد. در جدول ۲ نتایج محاسبه شاخص‌های ارزیابی مدل‌های ANFIS و GA-ANFIS باهم مقایسه شده است. با توجه به نتایج حاصل، همانطوری که انتظار می‌رفت مدل GA-ANFIS در مقایسه با مدل ANFIS عمل‌مطلوب‌تری در پیش‌بینی غلظت آلاینده PM_{10} ارائه کرده است.

جدول ۱. پارامترهای مدل‌های ANFIS و GA-ANFIS جهت پیش‌بینی غلظت آلاینده PM_{10}

پارامترها		مقدار/شرح	
ANFIS Model		GA-ANFIS Model	
Fuzzy Structure	Takagi-Sugeno (TSK)	Population Size	25
Initial FIS for training	Genfis3	Maximum Iterations Number	1000
Input MF Type	Gaussian	Crossover Percentage	0.4
Output MF Type	Linear	Mutation Percentage	0.7
Maximum Iterations Number	1000	Mutation Rate	0.15
Number of Fuzzy Rules	15	Selection Pressure (beta)	8
Initial Step Size	0.01	Gamma	0.7
Step Size Decrease Rate	0.9	Selection Method	Roulette wheel
Step Size Increase Rate	1.1		

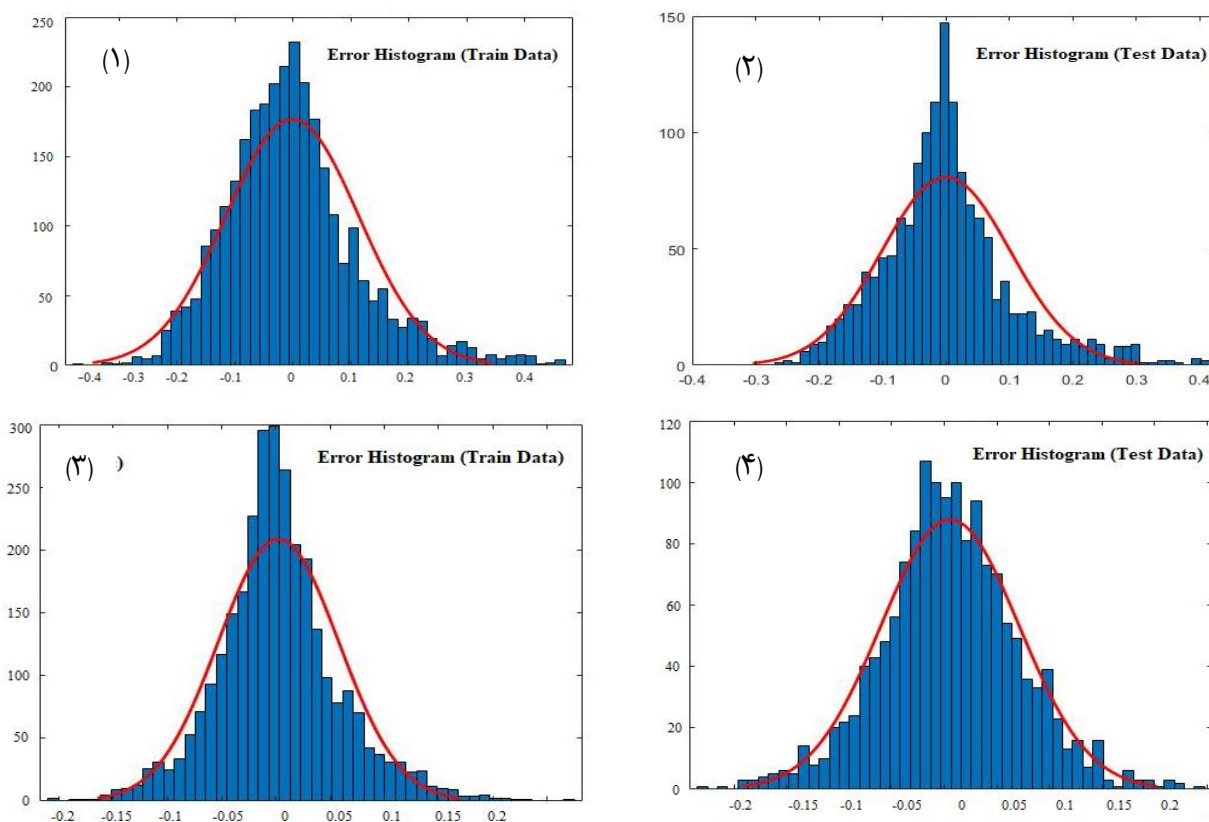
روش دیگری که می‌تواند جهت بررسی دقت و صحت نتایج پیش‌بینی غلظت آلاینده PM_{10} مورد استفاده قرار گیرد، هیستوگرام خطا می‌باشد. هیستوگرام خطا رفتار مدل را نسبت به داده‌های آموزشی و تست نشان می‌دهد. هرچه هیستوگرام خطای یک روش مدل‌سازی به توزیع نرمال نزدیک‌تر باشد، نشان‌دهنده این است که مدل موردنظر عملکرد بالایی در فرآیند پیش‌بینی داشته است.

جدول ۲. مقایسه بین شاخص‌های ارزیابی مدل‌های ANFIS و GA-ANFIS

داده‌های تست				داده‌های آموزشی			مدل
RMSE	MARE	MBE	R^2	RMSE	MARE	MBE	R^2
0.6754	0.4656	0.0161	0.96107	0.6534	0.4321	0.0213	0.8938
0.4513	0.3876	0.0152	0.97327	0.4387	0.3546	0.0186	0.9269


بر طبق نمودارهای شکل ۴ هیستوگرام خطای مربوط به داده‌های آموزش و تست مدل ANFIS و GA-ANFIS به توزیع نرمال نزدیک می‌باشد و میزان خطای با فراوانی بیش‌تر به مقدار صفر نزدیک است. تمامی این نمودارها مقارن بوده و نشان می‌دهد نتایج آزمون قابل قبول و توزیع خطا معقول می‌باشد.

1. Gamma
2. Beta



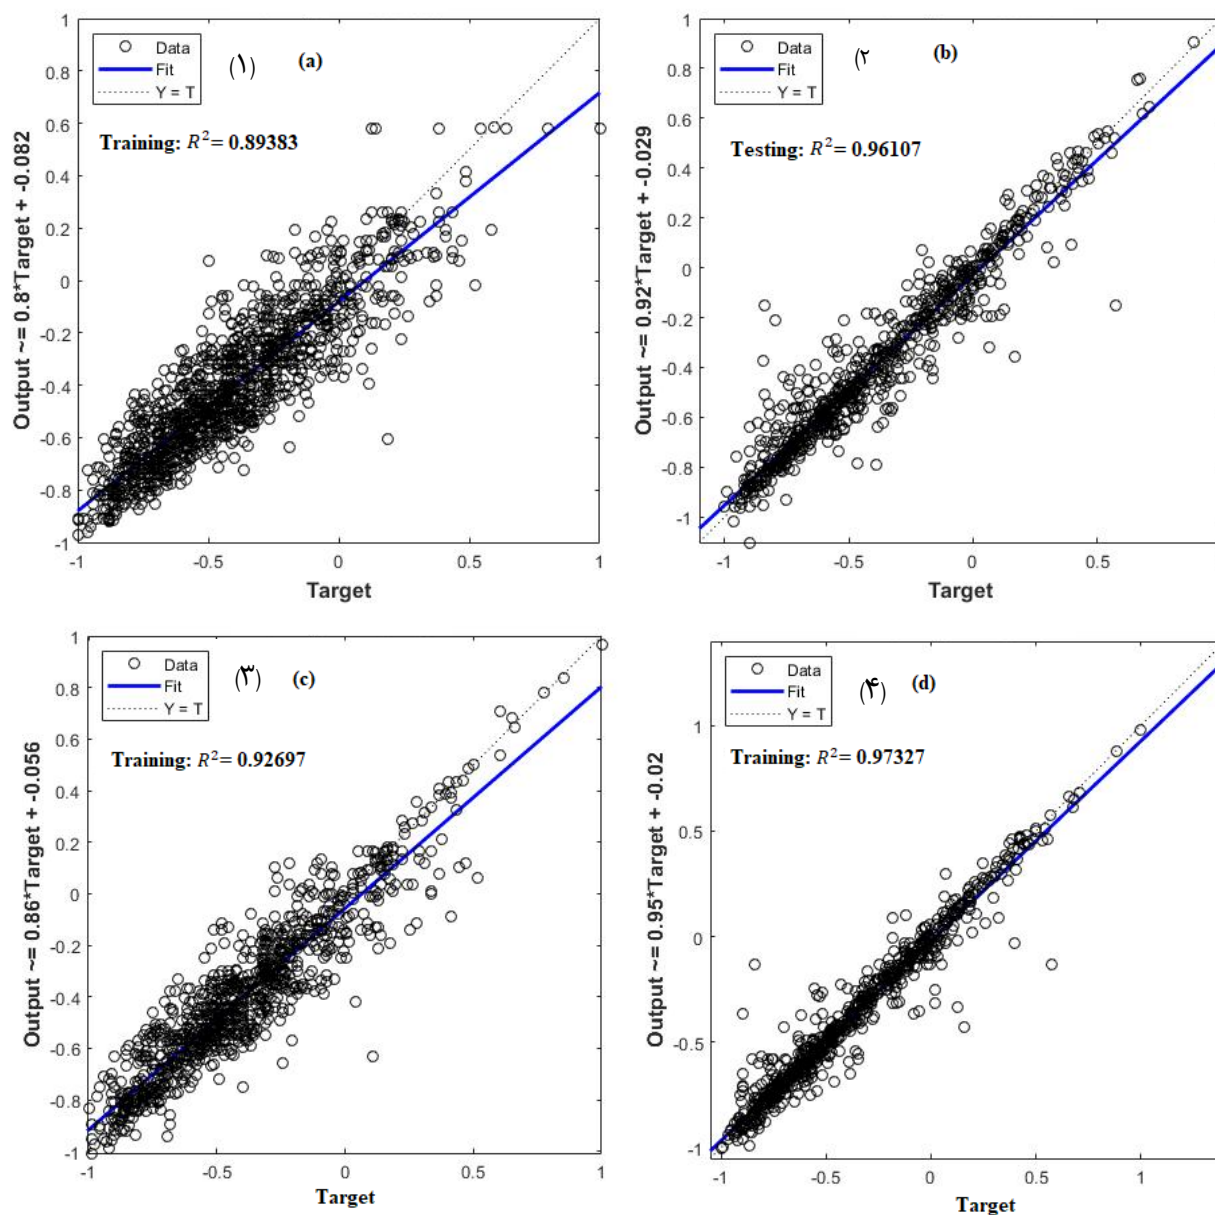
شکل ۴. هیستوگرام خطا داده‌های آموزشی و تست ((۱ و ۲) مدل ANFIS – (۳ و ۴) مدل GA-ANFIS)

نمودارهای شکل ۵ مقادیر مشاهده شده و پیش‌بینی شده در طی فرآیند آموزش و تست برای مدل‌های ANFIS و GA-ANFIS را نشان می‌دهد. همانطوری که مشاهده می‌شود، مدل GA-ANFIS برازش مطلوب‌تری بین مقادیر مشاهده شده و پیش‌بینی شده برقرار کرده است.



شکل ۵. نتایج خروجی حاصل از برازش بین مقدار مشاهده شده و پیش‌بینی شده در مدل‌های ANFIS و GA-ANFIS (۱ و ۲) مدل ANFIS (۳ و ۴) مدل GA-ANFIS

ضریب همبستگی (R^2) میزان همبستگی بین مقادیر مشاهده شده و پیش‌بینی شده را مورد ارزیابی قرار می‌دهد. هر چه میزان این شاخص بالاتر باشد نشان‌دهنده این است که مدل توانسته است بین مقادیر مشاهده شده و پیش‌بینی شده تناسب مناسبی برقرار کند. مقدار این ضریب برای آموزش مدل‌های ANFIS و GA-ANFIS به ترتیب $0/۸۹۳۸۳$ و $0/۹۲۶۹۷$ بدست آمد. برای درک بهتر از عملکرد مدل‌های موردنظر، مقادیر واقعی در برابر مقادیر پیش‌بینی شده و ضرایب همبستگی هر کدام از این نمودارهای پراکنده در شکل ۶ نمایش داده شده است.



شکل ۶. مقادیر پیش‌بینی شده در برابر مقادیر واقعی برای مدل‌های ANFIS و GA-ANFIS ((۱ و ۲) مدل ANFIS - (۳ و ۴) مدل GA-ANFIS)

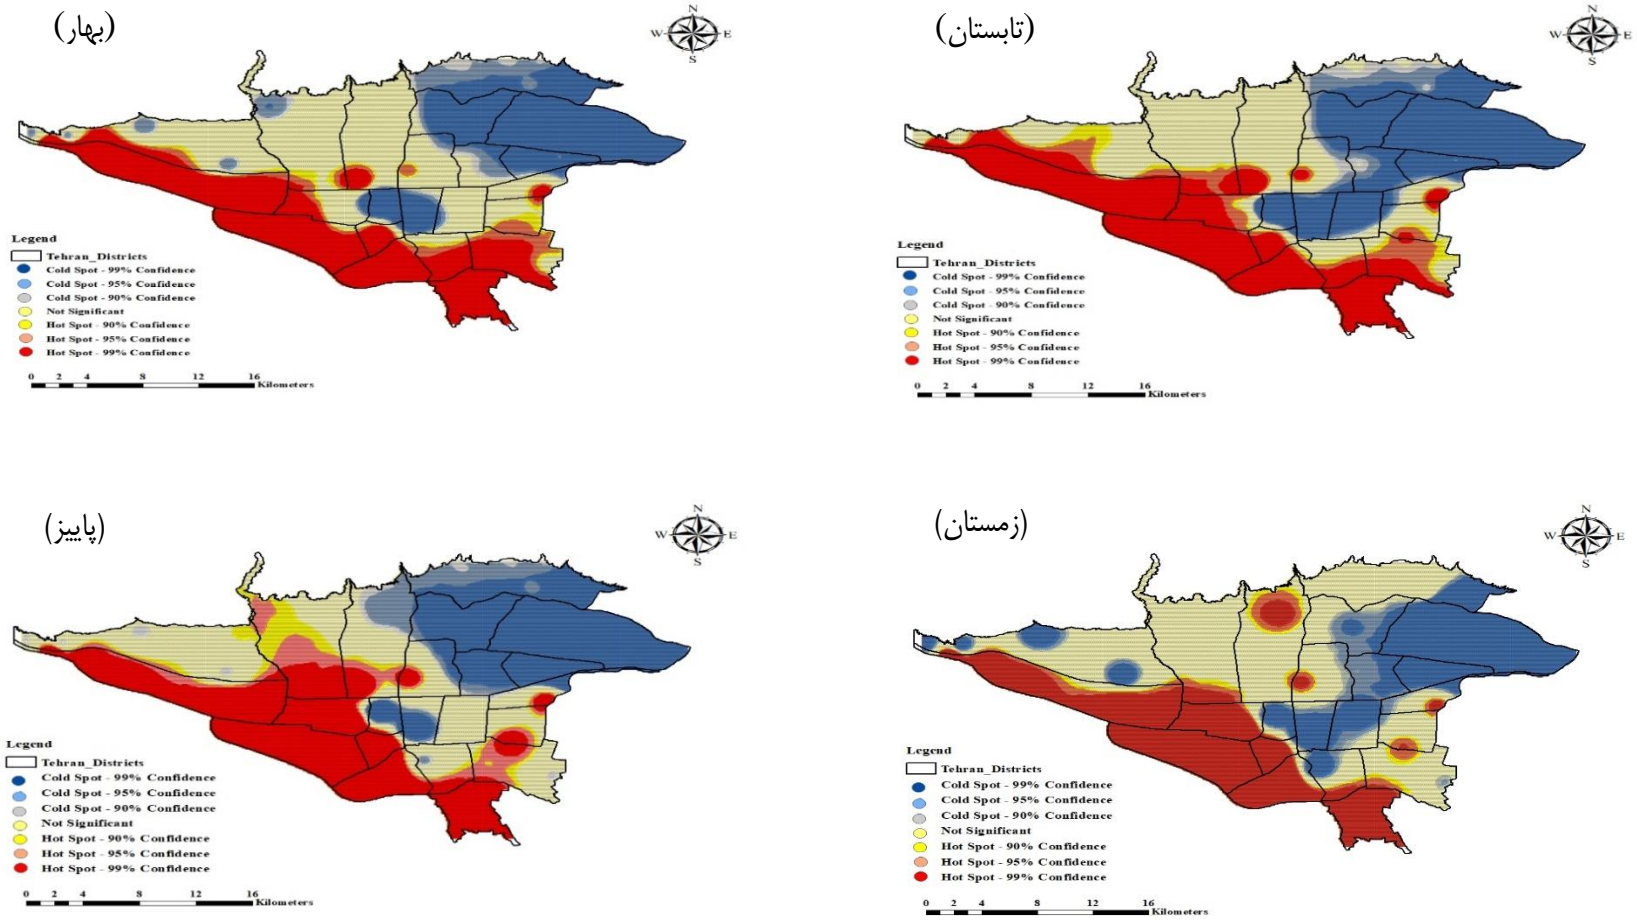
به‌منظور بررسی روند تغییرات مکانی-زمانی غلظت آلاینده PM_{10} در سطح شهر تهران و تحلیل لکه‌های داغ و سرد، بازه زمانی بصورت فصلی در نظر گرفته شد. جهت ایجاد یک سطح پیوسته از ویژگی مورد نظر (غلظت آلاینده PM_{10})، روش‌های مختلف درونیابی اجرا و مورد بررسی قرار گرفت. در بین تمامی روش‌ها، روش درونیابی IDW توانست نمایش مطلوبی از الگوی سراسری و فراگیر غلظت آلاینده PM_{10} ارائه دهد (وو و همکاران، ۲۰۰۶؛ سیبچی و همکاران، ۲۰۱۶؛ تالا و بالوگون، ۲۰۲۱). در این روش درونیابی، عکس مجذور فاصله هر نقطه از نقطه مجهول به عنوان وزن نقطه معلوم در نظر گرفته می‌شود. جهت پهنه‌بندی غلظت آلاینده PM_{10} ، از غلظت بدست آمده از مدل GA-ANFIS برای ایستگاه‌های آلودگی سنجی استفاده شد.

جدول ۳ مقادیر خودهمبستگی موران محلی و شاخص گتیس ارد جی را برای فصول مختلف در بازه زمانی مورد مطالعه نشان می‌دهد. نتایج تجزیه و تحلیل خودهمبستگی مکانی بروی مجموعه داده غلظت آلاینده PM_{10} نشان داد که حداکثر مقدار نمره Z برای شاخص موران در فصل پاییز (۱۹۱/۱۶) و حداقل مقدار در فصل زمستان (۱۸۱/۵۸) رخ داده است. از طرفی دیگر نتایج شاخص گتیس نشان می‌دهد که حداقل و حداکثر مقدار نمره Z محاسبه شده به ترتیب ۱۰۵/۲۸ و ۱۷۹/۱۰ در فصل پاییز و زمستان رخ داده است. نمره Z محاسبه شده برای شاخص موران محلی در تمامی فصول بیش‌تر از نمره Z محاسبه شده برای شاخص گتیس می‌باشد. در آغاز فصل پاییز همزمان با بازگشایی مدارس و دانشگاه‌ها و به دنبال آن افزایش ترافیک‌های سنگین در سطح شهر شاهد روزهای حساس از نظر آلودگی در سطح شهر هستیم. در بازه زمانی بین نیمه دوم آذر ماه و نیمه اول دی ماه (ماه دسامبر)، شهر تهران آلوده‌ترین روزها را در طی یک سال تجربه می‌کند که تداوم غلظت آلاینده‌ها در سطح شهر منجر به تعطیلی مدارس شده و وضعیت هوا برای تمامی اقشار جامعه ناسالم اعلام می‌گردد. در سه ماه اول سال و اسفند ماه کمترین مقادیر غلظت برای آلاینده PM_{10} ثبت شده است که علت اصلی آن شرایط جوی بهتر و افزایش سرعت وزش باد می‌باشد. شروع بارندگی در اواخر فصل زمستان و به دنبال آن کاهش آلودگی هوا و وزش بادهایی با سرعت بالای ۴ متر بر ثانیه در کاهش غلظت آلاینده‌ها بتأثیر نیست (آکینیمی و همکاران، ۲۰۱۶).

جدول ۳. نتایج فصلی و ماهانه شاخص موران و شاخص گتیس ارد جی برای غلظت آلاینده PM_{10} .


بازه زمانی	Moran's I		Getis	
	Index Value	Z- Score	Z-Score	
فصلی	بهار	0.987	190.38	138.78
	تابستان	0.990	191.05	113.95
	پاییز	0.991	191.16	105.28
	زمستان	0.940	181.58	179.10

مقادیر بالای نمره Z در طول دوره مطالعه نشان می‌دهد که توزیع مکانی غلظت آلاینده PM_{10} در سطح شهر خوشه‌ای است. شکل ۸ خوشه‌بندی فصلی غلظت آلاینده PM_{10} را در شهر تهران نشان می‌دهد. نتایج بدست آمده از آماره‌ی گتیس اردبه‌منظورنظور شناسایی نقاط داغ و سرد غلظت آلاینده PM_{10} نشان داد در فصل بهار با سطح اطمینان ۹۰ درصد لکه‌های داغ متعلق به ایستگاه شهر ری و مسعودیه می‌باشد و در فصل پاییز و زمستان با سطح اطمینان بالای ۹۹ درصد به ترتیب در ایستگاه‌های شهرداری منطقه ۱۹، منطقه ۱۸ و منطقه ۲۱ می‌باشند. علت گسترش لکه‌های داغ به بخش‌های مرکزی شهر، تراکم جمعیت، معابر با حجم ترافیک بالا و وجود مراکز تجاری و خرید اصلی شهر می‌باشد. لکه‌های سرد با سطح اطمینان ۹۵ درصد در بخش‌های غربی، شمال و شمال‌شرقی شهر تهران قرار دارند. همچنین نتایج تحلیل خودهمبستگی مکانی نشان داد که از سمت شمال به سمت مناطق جنوب و جنوب‌غربی روند افزایشی دارد.



شکل ۸. نتایج حاصل از خوشه‌بندی آماره گنیس ارد-جی به‌منظور شناسایی لکه‌های داغ و سرد آلاینده PM_{10} طی فصول مختلف سال.

نمودار شکل ۹ میانگین غلظت سالانه آلاینده PM_{10} را در ایستگاه‌های که به طور منظم در طول سال غلظت PM_{10} برداشت شده را نشان می‌دهد. تمامی ایستگاه‌هایی که بیش‌ترین غلظت PM_{10} در ثبت‌شده‌بت شده است در بخش‌های جنوبی و جنوب غرب تهران قرار دارند که بیش‌تر در معرض جریانات گردوغبار با منشأ خارج از شهر تهران هستند. شایان به ذکر است که عامل حجم ترافیک به عنوان منابع متحرک و فعالیت‌های ساختمانی و کارگاه‌های عمرانی به عنوان منابع ساکن آلودگی هوا در مجاورت ایستگاه‌های پایش آلودگی هوا در افزایش غلظت این آلاینده بسیار حائز اهمیت است. شایان به ذکر است در تمامی سال‌های مورد بررسی غلظت سالانه آلاینده PM_{10} در وضعیت نامطلوبی قرار داشته است و بالاتر از حد استاندارد (۲۰ میلی گرم در مترمکعب) بوده است.



شکل ۹. میانگین غلظت سالانه آلاینده PM_{10} در ایستگاه‌های پایش کنترل کیفیت هوای تهران

بحث

این مطالعه با هدف بکارگیری مدل ترکیبی GA-ANFIS جهت پیش‌بینی غلظت آلاینده PM_{10} در یک بازه زمانی ۱۰ ساله در تهران انجام گرفته است. نتیجه پژوهش حاضر بیانگر آن است که علاوه بر صحت داده‌های مورد استفاده برای آموزش مدل ANFIS، تعیین مقادیر بهینه پارامترهای مدل (پارامترهای لایه اول و چهارم) برای دستیابی به نتایج موثر و کارآمد لازم و ضروری است. استفاده از قابلیت بهینه‌سازی الگوریتم‌های فراابتکاری در تعیین پارامترهای اولیه مطلوب مدل‌های مبتنی بر یادگیری ماشین، رویکردی کارآمد در پیش‌بینی غلظت آلاینده‌ها می‌باشد، ضمناً می‌توان از سایر الگوریتم‌های فراابتکاری از قبیل گرگ خاکستری، کلونی زنبور عسل، ازدحام ذرات و غیره در حوضه‌های مشابه دیگر نیز بهره گرفت. مقایسه نتایج خروجی مدل‌های ANFIS و GA-ANFIS در پیش‌بینی غلظت آلاینده PM_{10} حاکی از آن است مدل GA-ANFIS با شاخص $R^2=0/92$ و $RMSE=0/43$ دقت بالاتری را نسبت به مدل ANFIS ارائه داد.

بررسی نقشه‌های حاصل از خوشه‌بندی آماره گنیس ارد-جی به منظور شناسایی لکه‌های داغ و سرد آلاینده PM_{10} نشان‌دهنده این است که طی تمامی فصول سال، عمده مکان‌هایی که به عنوان لکه‌های داغ شناخته شده‌اند (با سطح اطمینان ۹۵ درصد)، در نواحی جنوب و جنوب‌غربی تهران (شهرداری منطقه ۱۹، ۱۸، ۲۰ و ۲۱) قرار گرفته‌اند که بیش‌تر متاثر از جریانات حامل گرد و غبار می‌باشند و همچنین شعاع گسترش لکه‌های داغ از سمت شمال به بخش‌های جنوبی و مرکزی شهر روند افزایشی دارد. بررسی

میانگین غلظت آلاینده PM_{10} در بازه زمانی مورد مطالعه نشان می‌دهد که در سه ماهه ابتدایی سال و اسفند ماه در کمترین مقادیر خود بوده و در ماه دی به علت افزایش تعداد روزهای با وارونگی دمایی، کاهش سرعت باد و به دنبال آن پایداری جوی و انباشت آلاینده‌ها در هوا، بیش‌ترین غلظت را داشته و این در حالی است که در سال‌های همراه با افزایش طوفان‌های گرد و خاک (سال ۱۳۹۸) در ماه‌های مهر و تیر بیش‌ترین غلظت ثبت شده است.

بر طبق گزارشاتی که هر ساله از سوی شرکت کنترل کیفیت هوا منتشر می‌شود، غلظت آلاینده PM_{10} پس از روندی نسبتاً کاهشی در سال‌های ۹۰ تا ۹۳، تا سال ۹۶ روندی افزایشی و پس از کاهش مطلوبی در سال ۱۳۹۷ مجدداً با اندکی افزایش، روند نسبتاً ثابتی در سال‌های ۱۳۹۸ و ۱۳۹۹ داشته است. در مجموع غلظت این آلاینده در سال ۱۳۹۹ نسبت به سال ۱۳۹۰ تقریباً ۱۲ درصد افزایش پیدا کرده است.

نتیجه‌گیری

مسئله آلودگی هوای شهر تهران در دو دسته عوامل اولیه و ثانویه دسته‌بندی می‌شود. مکانیابی شهری و تمرکز اداری و تجاری، فناوری‌های ناسازگار با محیط زیست، شرایط توپوگرافی و اقلیم حاکم بر شهر، استقرار اکثر کارخانه‌ها در غرب شهر و حجم انبوه وسایل نقلیه موتوری و احتراق ناقص سوخت در این وسایل مهم‌ترین عوامل اولیه تاثیرگذار بر آلودگی هوای شهر تهران محسوب می‌شوند. از جمله عوامل ثانویه می‌توان به رشد و توسعه ناهمگون شهری بدون ارزیابی زیرساخت‌های لازم، افزایش بی‌رویه جمعیت به علت مهاجرت، مدیریت پسماند و دفن زباله، وسایل سرمایش و گرمایش خانگی و فعالیت‌های کشاورزی و معدنی اشاره کرد. در این پژوهش دو پارامتر ترافیک و عوامل هواشناسی مورد بررسی قرار گرفت.

طبق بررسی الگوهای مکانی-زمانی بلندمدت پارامترهای هواشناسی؛ در نیمه اول سال بویژه اردیبهشت ماه، میانگین سرعت باد بیش‌تر از نیمه دوم سال می‌باشد، اما در اسفند ماه روزهایی با مقادیر بیشینه سرعت باد به ثبت رسیده است. سرعت پایین باد منجر به فرونشست آلاینده PM_{10} شده و در نتیجه غلظت آن افزایش پیدا می‌کند. جهت غالب باد در سطح شهر تهران، غرب به شرق می‌باشد که تراکم ساختمان‌ها بلند در نواحی غربی موجب بسته شدن مسیر باد ورودی به داخل شهر است. کاهش بارندگی و رطوبت هوا و تغییر الگوهای فصلی باد، شرایط آلودگی PM_{10} را در تهران بویژه در فصل‌های گرم سال تشدید می‌کند. کبه‌طوریکه در همه سال‌های مورد بررسی، عمدتاً طی دو ماه ابتدایی سال کمترین غلظت این آلاینده ثبت شده و به دنبال افزایش دما و خشکی هوا در ماه‌های گرم سال، بیش‌ترین مقادیر غلظت رخ داده است. با توجه به موارد ذکر شده می‌توان گفت که شرایط نامطلوب هواشناسی ممکن است منجر به افزایش غلظت PM_{10} شود.

علاوه بر تأثیر غیرقابل انکار پارامترهای هواشناسی در طی فصول مختلف سال، عامل ترافیک در کلان‌شهر تهران جز جدائی‌ناپذیر تشدید آلودگی هوا می‌باشد. شبکه نامنظم حمل‌ونقل شهری، بالا بودن حجم ترافیک عبوری، افزایش تردد وسایل نقلیه تک سرنشین بجای استفاده از ناوگان حمل‌ونقل عمومی، افزایش مصرف سوخت‌های فسیلی و عدم انطباق آن‌ها با استانداردهای بین‌المللی و عدم کارکرد صحیح وسایل نقلیه به علت سردی هوا باعث تشدید آلودگی هوا و انباشت غلظت آلاینده‌ها می‌شود. به نظر می‌رسد عواملی خارج از محدوده شهر تهران در میزان غلظت این آلاینده سهمیم هستند از اینرو جهت مدیریت کاهش غلظت این آلاینده در نواحی جنوبی و جنوب‌غربی شهر تهران، کیفیت توزیع و تراکم کارگاه‌های صنعتی و عمرانی در حاشیه شهر، تغییرات کاربری‌های اراضی حومه باید مورد بررسی و ارزیابی قرار گیرد.

تقدیر و تشکر

بنا به اظهار نویسنده مسئول، این مقاله حامی مالی نداشته است.

منابع

- ۱) بهاری، روح‌الامین؛ عباس‌پور، رحیم علی و پهلوانی، پرهام. (۱۳۹۴). پهنه‌بندی آلودگی ذرات معلق (PM) با استفاده از مدل‌های آماری محلی در GIS (مطالعه موردی: کلان‌شهر تهران). *علوم و فنون نقشه‌برداری*، ۵ (۳)، ۷۴-۱۶۵.
- ۲) شرعی‌پور، زهرا. و علی اکبری بیدختی، عباسعلی. (۱۳۹۳). بررسی توزیع مکانی زمانی آلاینده‌های هوا در شهر تهران برای ماه‌های سرد سال‌های ۲۰۱۱-۲۰۱۳. *علوم و تکنولوژی محیط زیست*، ۱۶ (۱)، ۱۴۹-۱۶۶.
- ۳) نادیان، مرضیه؛ میرزایی، روح‌الله و سلطانی محمدی، سعید. (۱۳۹۷). کاربرد شاخص خودهمبستگی فضایی موران در تحلیل فضایی-زمانی آلاینده (مطالعه موردی: شهر تهران). *مهندسی بهداشت محیط*، ۵ (۳)، ۱۹۷-۲۱۳.

References

- 1) AL-Qaness, M. A., Fan, H., Ewees, A. A., Yousri, D. & Abd Elaziz, M. (2021). Improved ANFIS model for forecasting Wuhan City air quality and analysis COVID-19 lockdown impacts on air quality, *Environmental Research*, 194, 110607.
- 2) Akbary, M., Kermani, A. & Alijani, B. (2018). Simulation and analysis of polluted days in Tehran. *International Journal of Environmental Research*, 12, 67-75.
- 3) Arhami, M., Hosseini, V., Shahne, M. Z., Bigdeli, M., LAI, A. & Schauer, J. J. (2017). Seasonal trends, chemical speciation and source apportionment of fine PM in Tehran. *Atmospheric Environment*, 153, 70-82.
- 4) Akinyemi, M., Emetere, M., & Akinwumi, S. (2016). Dynamics of wind strength and wind direction on air pollution dispersion. *Asian Journal of Applied Sciences*, 4 (2), 1-12.
- 5) Azarmi, F., Kumar, P., Marsh, D. & Fuller, G. (2016). Assessment of the long-term impacts of PM 10 and PM 2.5 particles from construction works on surrounding areas. *Environmental Science: Processes & Impacts*, 18, 208-221.
- 6) Alizadeh-Chooabari, O., Bidokhti A A., Ghafarian, P., & Najafi, MS. (2016). Temporal and spatial variations of particulate matter and gaseous pollutants in the urban area of Tehran. *Atmos Environ*, 141, 443-53.
- 7) Anselin, L. (1995). Local indicators of spatial association—LISA. *Geographical analysis*, 27, 93-115.
- 8) Anselin, L. & Getis, A. (1992). Spatial statistical analysis and geographic information systems. *The Annals of Regional Science*, 26, 19-33.
- 9) Arjun, K., & Aneesh, K. (2015). Modelling studies by application of artificial neural network using matlab. *Journal of Engineering Science and Technology*, 10, 1477-1486.
- 10) Budnik, L. T., & Casteleyn, L. (2019). Mercury pollution in modern times and its socio-medical consequences. *Science of The Total Environment*, 654, 720-734.
- 11) Baldauf, R. W., Isakov, V., Deshmukh, P., Venkatram, A., Yang, B. & Zhang, K. M. (2016). Influence of solid noise barriers on near-road and on-road air quality. *Atmospheric Environment*, 129, 265-276.
- 12) Baghban, A., Ahmadi, M. A., & Shahraki, B. H. (2015). Prediction carbon dioxide solubility in presence of various ionic liquids using computational intelligence approaches. *The Journal of supercritical fluids*, 98, 50-64.
- 13) Basser, H., Karami, H., Shamshirband, S., Akib, S., Amirmojahedi, M., Ahmad, R., Jahangirzadeh, A. & Javidnia, H. (2015). Hybrid ANFIS-PSO approach for predicting optimum parameters of a protective spur dike. *Applied Soft Computing*, 30, 649-642.
- 14) Banu, G., & Suja, S. (2014). Fault location technique using GA-ANFIS for UHV line. *Archives of Electrical Engineering*, 12, 247-262.
- 15) Berkowicz, R., Palmgren, F., Hertel, O. & Vignati, E. (1996). Using measurements of air pollution in streets for evaluation of urban air quality—meteorological analysis and model calculations. *Science of the total environment*, 189, 259-265.

- 16) Cichowicz, R., Wielgosinski, G., & Fetter, W. (2020). Effect of wind speed on the level of particulate matter PM10 concentration in atmospheric air during winter season in vicinity of large combustion plant. *Journal of Atmospheric Chemistry*, 77, 35-48.
- 17) Cujia, A., Agudelo-Castaneda, D., Pacheco-Bustos, C. & Teixeira, E. C. (2019). Forecast of PM10 time-series data: A study case in Caribbean cities. *Atmospheric Pollution Research*, 10, 2053-2062.
- 18) Ceylan, Z., Pekel, E., Ceylan, S. & Bulkan, S. (2018). Biomass higher heating value prediction analysis by ANFIS, PSO-ANFIS and GA-ANFIS. *Global Nest Journal*, 20, 589-597.
- 19) Chen, Y. (2018). Prediction algorithm of PM2. 5 mass concentration based on adaptive BP neural network. *Computing*, 100, 825-838.
- 20) Chinneck, J. W. (2006). Practical optimization: a gentle introduction. *Systems and Computer Engineering*, Carleton University, Ottawa. <http://www.sce.carleton.ca/faculty/chinneck/po.html>, 11.
- 21) De Rooij, M. M., Heederik, D. J., Borlee, F., Hoek, G. & Wouters, I. M. (2017). Spatial and temporal variation in endotoxin and PM10 concentrations in ambient air in a livestock dense area. *Environmental research*, 153, 161-170.
- 22) Fang, C., Wang, Z., & Xu, G. (2016). Spatial-temporal characteristics of PM 2.5 in China: A city-level perspective analysis. *Journal of Geographical Sciences*, 26, 1519-1532.
- 23) Feng, Q., Wu, S., Du, Y., Xue, H., Xiao, F., Ban, X. & Li, X. (2013). Improving neural network prediction accuracy for PM10 individual air quality index pollution levels. *Environmental engineering science*, 30, 725-732.
- 24) Ghasemi, A., & Amanollahi, J. (2019). Integration of ANFIS model and forward selection method for air quality forecasting. *Air Quality, Atmosphere & Health*, 12, 59-72.
- 25) Ghotbi, S., Sotoudeheian, S. & Arhami, M. (2016). Estimating urban ground-level PM10 using MODIS 3km AOD product and meteorological parameters from WRF model. *Atmospheric Environment*, 141, 333-346.
- 26) Goldberg, D. E., & Holland, J. H. (1988). *Genetic algorithms and machine learning*.
- 27) Goodchild, M. F. (1986). *Spatial autocorrelation*. Geo Books.
- 28) Humpe, A., Brehm, L., & Gunzel, H. (2021). Forecasting Air Pollution in Munich: A Comparison of MLR, ANFIS, and SVM. *ICAART*, (2), 500-506.
- 29) Han, L., Zhao, J., Gao, Y., Gu, Z., Xin, K., & Zhang, J. (2020). Spatial distribution characteristics of PM2. 5 and PM10 in Xi'an City predicted by land use regression models. *Sustainable Cities and Society*, 61, 102329.
- 30) Heger, M., & SARRAF, M. (2018). *Air pollution in Tehran: Health costs, sources, and policies*, World Bank.
- 31) Hossaini, M., Mekhilef, S., Afifi, F., Halabi, L. M., Olatomiwa, L., Seyedmahmoudian, M., Horan, B. & Stojcevski, A. (2018). Application of the hybrid ANFIS models for long term wind power density prediction with extrapolation capability. *PloS one*, 13, e0193772.
- 32) Habibi, R., Alesheikh, A. A., Mohammadinia, A. & Sharif, M. (2017). An assessment of spatial pattern characterization of air pollution: A case study of CO and PM2. 5 in Tehran, Iran. *ISPRS international journal of Geo-information*, 6, 270.
- 33) Hosseini, V., & Shahbazi, H. (2016). Urban air pollution in Iran. *Iranian Studies*, 49, 1029-1046.
- 34) Haupt, R. L., & HAUPT, S. E. (2004). *Practical genetic algorithms*. John Wiley & Sons.
- 35) Johansson, C., Norman, M., & Gidhagen, L. (2007). Spatial & temporal variations of PM10 and particle number concentrations in urban air. *Environmental monitoring and assessment*, 127, 477-487.
- 36) Jang, J. S. (1996). *Input selection for ANFIS learning*. Proceedings of IEEE 5th International Fuzzy Systems, IEEE, 1493-1499.
- 37) Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23, 665-685.
- 38) Keykhosrowi, G., & Lashkari, H. (2014). *Analysis of the relationship between the thickness and height of the inversion and the severity of air pollution in Tehran*.
- 39) Khan, F., Latif, M. T., Juneng, L., Amil, N., Mohd Nadzir, M. S. & Syedul Hoque, H. M. (2015). Physicochemical factors and sources of particulate matter at residential urban environment in Kuala Lumpur. *Journal of the Air & Waste Management Association*, 65, 958-969.
- 40) Koza, J .R. (2007). Introduction to genetic programming. *Proceedings of the 9th annual conference companion on Genetic and evolutionary computation*, 3323-3365.
- 41) Katsouyanni, K., Pantazopoulou, A., Touloumi, G., Tselepidaki, I., Moustris, K., Asimakopoulos, D., Pouloupoulou, G. & Trichopoulos, D. (1993). Evidence for interaction between air pollution and high temperature in the causation of excess mortality. *Archives of Environmental Health: An International Journal*, 48, 235-242.

- 42) Li, H., Guo, B., Han, M., Tian, M. & Zhang, J. (2015). Particulate matters pollution characteristic and the correlation between PM (PM 2.5, PM 10) and meteorological factors during the summer in Shijiazhuang. *Journal of Environmental Protection*, 6, 457.
- 43) Lei, K. S., & Wan, F. (2012). Applying ensemble learning techniques to ANFIS for air pollution index prediction in Macau. *International Symposium on Neural Networks, Springer*, 509-516.
- 44) Masoudi, M., Sakhaei, M., Behzadi, F. & Jokar, P. (2016). Status of PM10 as an air pollutant and its prediction using meteorological parameters in Tehran, Iran. *Fresen. Environ. Bull*, 25, 2008-201.
- 45) Mihalache, S. F., Popescu, M. & Oprea, M. (2015). Particulate matter prediction using ANFIS modelling techniques. *19th International Conference on System Theory, Control and Computing (ICSTCC), 2015. IEEE*, 895-900.
- 46) Ord, J. K., & Getis, A. (1995). Local spatial autocorrelation statistics: distributional issues and an application. *Geographical analysis*, 27, 286-306.
- 47) Prasad, K., Gorai, A. K. & GOYAL, P. (2016). Development of ANFIS models for air quality forecasting and input optimization for reducing the computational cost and time. *Atmospheric environment*, 128, 246-262.
- 48) Paschalidou, A. K., Karakitsios, S., Kleanthous, S. & Kassomenos, P. A. (2011). Forecasting hourly PM 10 concentration in Cyprus through artificial neural networks and multiple regression models: Implications to local environmental management. *Environmental Science and Pollution Research*, 18, 316-327.
- 49) Rezakazemi, M., Dashti, A., Asghari, M. & Shirazian, S. (2017). H2-selective mixed matrix membranes modeling using ANFIS, PSO-ANFIS, GA-ANFIS. *International Journal of Hydrogen Energy*, 42, 15211-15225.
- 50) Rosenlund, M., Picciotto, S., Forastiere, F., Stafoggia, M., & Perucci, C. A. (2008). Traffic-related air pollution in relation to incidence and prognosis of coronary heart disease. *Epidemiology*, 15, 121-128.
- 51) Roberts, S. (2004). Interactions between particulate air pollution and temperature in air pollution mortality time series studies. *Environmental research*, 96, 328-337.
- 52) Sulaiman, G., & Younes, M. K. (2018). Modelling of traffic emissions using modified synchro-anfis integrated model on traffic signals. *Feb-Fresenius Environmental Bulletin*, 8308.
- 53) Shahbazi, H., Ganjiazad, R., Hosseini, V. & Hamed, M. (2017). Investigating the influence of traffic emission reduction plans on Tehran air quality using WRF/CAMx modeling tools. *Transportation Research Part D: Transport and Environment*, 57, 484-495.
- 54) Stoimenova, M., Voynikova, D., Ivanov, A., Gocheva-Ilieva, S. & Iliev, I. (2017). Regression trees modeling and forecasting of PM10 air pollution in urban areas. *AIP Conference Proceedings, AIP Publishing LLC*, 030005.
- 55) Sbihi, H., Tamburic, L., Koehoorn, M. & Brauer, M. (2016). Perinatal air pollution exposure and development of asthma from birth to age 10 years. *European Respiratory Journal*, 47, 1062-1071.
- 56) Shahbazi, H., Reyhanian, M., Hosseini, V. & Afshin, H. (2016). The relative contributions of mobile sources to air pollutant emissions in Tehran, Iran: an emission inventory approach. *Emission control science and technology*, 2, 44-56.
- 57) Shahraiyni, H. T., Sodoudi, S., Kerschbaumer, A. & Cubasch, U. (2015). A new structure identification scheme for ANFIS and its application for the simulation of virtual air pollution monitoring stations in urban areas. *Engineering Applications of Artificial Intelligence*, 41, 175-182.
- 58) Sharipour, Z., & Akbaribidokhti, A. (2014). Investigation of spatial and temporal distributions of air pollutants over Tehran in cold months of 2011-2013. *Journal of Environmental Science and Technology*, 16, 149-166.
- 59) Tella, A., & Balogun, A.-L. (2021). Prediction of ambient PM10 concentration in Malaysian cities using geostatistical analyses. *Journal of Advanced Geospatial Science & Technology*, 1, 115-127.
- 60) Taheri Shahraiyni, H., & Sodoudi, S. (2016). Statistical modeling approaches for PM10 prediction in urban areas; A review of 21st-century studies. *Atmosphere*, 7, 1-15.
- 61) Venegas, L., & MAazzeo, N. (2006). Modelling of urban background pollution in Buenos Aires City (Argentina). *Environmental Modelling & Software*, 21, 577-586.
- 62) Wu, J., Winer, A. M., & Delfino, R. J. (2006). Exposure assessment of particulate matter air pollution before, during, and after the 2003 Southern California wildfires. *Atmospheric Environment*, 40, 3333-3348.
- 63) Yanosky, J. D., Fisher, J., Liao, D., Rim, D., Vander Wal, R., Groves, W. & Puett, R. C. (2018). Application and validation of a line-source dispersion model to estimate small scale traffic-related particulate matter concentrations across the conterminous US. *Air Quality, Atmosphere & Health*, 11, 741-754.
- 64) Yavari, H., & Saligheh, M. (2011). *Air pollution inversion levels in Tehran city*.
- 65) Zhang, J. & Ding, W. (2017). Prediction of air pollutants concentration based on an extreme learning machine the case of Hong Kong. *International journal of environmental research and public health*, 14, 114.

- 66) Zhu, Y., Hinds, W. C., Kim, S., Shen, S. & Sioutas, C. (2002). Study of ultrafine particles near a major highway with heavy-duty diesel traffic. *Atmospheric environment*, 36, 4323-4335.