

ORIGINAL RESEARCH PAPER

Forecasting Ozone Density in Tehran Air Using a Smart Data-Driven Approach

Seyedeh Reyhaneh Shams¹, Ali Jahani^{2,*}, Mazaher Moeinaddini³, Nematallah Khorasani³, Saba Kalantary⁴

¹ Department of Human Environment and Environmental Pollution, College of Environment, Karaj, Iran

² Department of Natural Environment and Biodiversity, College of Environment, Karaj, Iran

³ Department of Environment, Faculty of Natural Resources, University of Tehran, Karaj, Iran

⁴ Department of Occupational Health Engineering, School of Public Health, Tehran University of Medical Science, Tehran, Iran

Received: 2020-01-25

Accepted: 2020-08-11

ABSTRACT

Introduction: As a metropolitan area in Iran, Tehran is exposed to damage from air pollution due to its large population and pollutants from various sources. Accordingly, research on damage induced by air pollution in this city seems necessary. The main purpose of this study was to forecast ozone in the city of Tehran. Considering the hazards of ozone (O₃) gas on human health and the environment and its ascending trend over the past decades, it is also essential to study and predict its quantities in the air. Forecasting ozone in the air can be further used to prevent and control pollution by authorities.

Material and Methods: Using an analytical-applied research method, this study was to predict ozone gas in this metropolitan area via daily ozone data of air quality measurement stations, traffic variables, green space, as well as time factors such as one-day time delay. In this regard, an artificial neural network (ANN) model was employed to forecast ozone concentration using the MATLAB software.

Results: The results of the ANN model were compared with a linear regression one. Correlation coefficient and root-mean-square error (RMSE) of the ANN model were subsequently compared with $R^2=0.734$ and $RMSE=0.56$ as well as $R^2=0.608$ and $RMSE=11.69$ regression equations.

Conclusion: It was concluded that the error in the ANN model was smaller than that in the regression one. According to the results of the sensitivity analysis of the season parameters, the length of sunshine hours had the most significant effect on the amount of ozone gas in Tehran air.

Keywords: Air pollution, Ozone gas, Artificial neural network, Multivariate regression, Sensitivity analysis

1. INTRODUCTION

The problem of environmental pollution has been undoubtedly recognized today as one of the main challenges facing urban life, since it is annually causing enormous damage to the lives and finances of residents of large cities. In the meantime, the problem of air pollution is high on the list of pollution hazards and a review of the World Health Organization (WHO) statistics can provide enough evidence in this regard. According to a 2013 report by the International Institute of Cancer Research (IARC), air pollution and particulate matter (PM)

are classified as 100% carcinogenic to humans. They are also the fourth leading cause of death in the world, as well as the seventh most common risk factor in Iran, with reference to the burden of diseases related to global air pollution. One method to manage and control the problem of air pollution in the city of Tehran, as a metropolis, is to utilize scientific and practical instrumentation to approximate and to forecast the increasing rate of each pollution factor. Recently, several models have been introduced to predict the quantities of air pollution in different cities. Artificial neural networks (ANNs) are one of the most accurate

* Corresponding Author Email: ajahani@ut.ac.ir

tools in the process of optimization as such networks can process and learn simultaneously. The bulk of advances in ANNs are also associated with new structures and learning methods. The given networks can be further detected as the electronic model of the central nervous system (CNS) in the human brain. In other words, an ANN is a mathematical model that is capable of modeling and creating non-linear relationships for interpolations. Accordingly, many scholars in this field have conducted several studies including the one in the polluted industrial areas of Slovenia. In this sense, comparing ANNs and classic regression models is common in the determination of modeling techniques.

2. MATERIALS AND METHODS

To fulfill this research, the data were collected from the 2015 Tehran Air Quality Control Company (AQCC), Tehran Meteorological Organization, Tehran Traffic Organization, and Tehran Gardens and Green Spaces Organization. The parameters measured in these organizations included ozone (O_3) concentration, green space information, weather parameters, such as temperature (0°), traffic parameters, e.g., length of north-south (y) and east-west (x) crossings (km), average number of vehicles at intersections, as well as time parameters such as one-day time delay (viz. ozone concentration in the previous day), two-day time delay (namely, ozone concentration in the past two days), and the day of the year (i.e., 1-365). The desired month was from the desired year (1-30) and the season was from the desired year (1-4) and the warm and cold seasons (1-2). In this research, the meteorological and pollution monitoring stations were located close to each other and the green space information as well as the traffic information of the streets near the stations. In order to predict air pollution, the given variables were studied using an ANN model, whose accuracy was measured by comparing its output and calculated indices including correlation coefficient (R^2), mean absolute error (MAE), mean square error (MSE), and root-mean-square error (RMSE) (8). To perform sensitivity analysis and to calculate the output sensitivity of the ANNs, each of the variables of the model was kept constant of all variables equal to their mean. The model outputs were then calculated. This process was performed for each of the input variables and the sensitivity of the model results to each of the variables was consequently determined.

Table 1. Results of ANN model to forecast ozone concentration in Tehran air

Statistic	R^2	MSE	RMSE	MAE
Training	0.851	0.169	0.411	0.339
Validation	0.597	0.412	0.641	0.483
Test	0.558	0.536	0.732	0.467
All	0.734	0.32	0.566	0.388




Fig. 1. Results of Multivariate regression model in the stepwise method in forecasting Ozone concentration in Tehran

Multiple linear regression (MLR) analysis was ultimately completed using the stepwise regression method. Therefore, the variables that had a significant effect on the dependent one were utilized. In this technique, the measured daily ozone concentration was considered as a dependent variable and the effective factors were taken into account as independent variables.

3. RESULTS AND DISCUSSION

To optimize the ANN, it was estimated using 61 neurons and two hidden layers. According to the trained network results, with two hidden layers and 30 neurons in each layer using sigmoid tangent function in both hidden layers, linear function in the output layer, optimal correlation in the network results, and homogeneity of correlation coefficients in training, validation, and data test; the total data as well as the minimum MSE of the entire data (as listed in Table 1) were found very accurate in predicting ozone concentration in Tehran air.

The MLR model was further used to investigate the relationship between changes in temporal, climatic, traffic, and green space factors on ozone concentration in Tehran. The study findings revealed that prediction of ozone concentration by the stepwise regression method via the variables of temperature, sunshine hours, wind speed, one-day

Table 2. Results of Neural Network Modeling and Multivariate Regression in Prediction of Tehran Air Ozone Concentration

Statistic	R ²	RMSE
Results of ANN	0.734	0.566
Results of MLR	0.608	11.690

time delay, and two-day time delay in the residual model had the highest impact on forecasting the amount of ozone per day. In the MLR model, the values of one dependent variable were also estimated from those of two or more independent ones. The results demonstrated that the stepwise MLR model with $R^2=0.608$ and $RMSE=11.690$ had better performance than non-linear models in forecasting ozone concentration in Tehran air.

The results of the ANN model were consequently compared with the linear regression one.

The results of the sensitivity analysis of the variables exploited for modeling indicated that the highest impact of input variables on ozone concentration was related to the season/year variables with an effective coefficient of 8.12 and the sunshine hours having an effective coefficient of 4.19, implying that other variables had less impact on ozone concentration in Tehran air.

4. CONCLUSION

The first objective of this study was to determine the model of ozone density forecast in Tehran air using ANNs. The results showed that the perceptron neural network designed with two hidden layers and 30 neurons in each hidden layer and the sigmoid tangent function had a good capability to model the changes of ozone density in the city of Tehran. The model obtained in this study provided the feasibility

of predicting the quantities of ozone condensation and enabling it to be utilized in the spatial decision system of air quality management and with the help of optimal urban transport management of Tehran metropolis. The second objective was to compare the results of the modeling prediction of Tehran ozone density by an ANN with an MLR model. The results revealed that the ANN model with a correlation coefficient of 0.85 was more effective in predicting ozone concentration than the MLR methods with a coefficient of determination of 0.78. Besides, the third objective was to explore the governing relationships between temporal, climatic, traffic, and green space parameters and the amount of ozone concentration in Tehran air. Performing sensitivity analysis and identifying the most effective parameters also showed that the season/year parameters and the sunshine hours were prioritized in order to predict ozone concentration in Tehran air, which could be effective in managing air pollution in this metropolitan area. Another significant parameter shaping ozone concentration was the length of street x and then the warm/cold season. This helped measure the amount of ozone in the air that day, and had a major impact on managing air pollution in the city. Accordingly, management decisions can be made to prevent some effects of air pollution, such as the less vulnerable strata of society, i.e., children, the elderly, and patients with cardiovascular diseases (CVDs). Forecasting air pollution in the coming days can thus help make managerial decisions to control air pollution and to provide the basic solutions and warnings. This issue is of particular importance in forecasting air pollution in industrial and populated cities such as Tehran.

پیش بینی تراکم ازن در هوای شهر تهران با استفاده از رویکرد هوشمند داده محور

سیده ریحانه شمس^۱، علی جهانی^{۲*}، مظاهر معین الدینی^۳، نعمت الله خراسانی^۴، صبا کلانتری^۴

^۱گروه محیط زیست انسانی و آلودگی محیط زیست، دانشکده محیط زیست، کرج، ایران

^۲گروه محیط زیست طبیعی و تنوع زیستی، دانشکده محیط زیست، کرج، ایران

^۳دانشکده منابع طبیعی، گروه محیط زیست، پردیس دانشگاه کشاورزی و منابع طبیعی تهران، کرج، ایران

^۴گروه مهندسی بهداشت حرفه ای، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران

تاریخ دریافت: ۹۸/۱۱/۵، تاریخ پذیرش: ۹۹/۵/۲۱

چکیده

شهر تهران به عنوان یک کلان شهر، به علت دارا بودن جمعیت زیاد و آلودگی شدید ناشی از منابع و آلاینده های گوناگون، در معرض آسیب های ناشی از آلودگی هوا قرار دارد. پژوهش بر روی آسیب های ناشی از آلودگی هوا در شهر تهران با توجه به آلاینده های مهم و شاخص های موثر امری ضروری به نظر می رسد. مطالعه حاضر با هدف پیش بینی ازن هوای شهر تهران انجام شد. با توجه به مضرات گاز ازن بر سلامت انسان و محیط زیست و افزایش آن در دهه های گذشته، بررسی و پیش بینی میزان آن در هوا از اهمیت بالایی برخوردار است. پیش بینی تراکم گاز ازن در هوا می تواند برای پیشگیری و کنترل توسط مسئولان استفاده شود. این پژوهش از نوع روش تحلیلی-کاربردی بوده و با استفاده از داده های روزانه ازن ایستگاه های سنجش کیفیت هوای شهر تهران، هواشناسی، فضای سبز، ترافیکی و متغیرهای زمانی مثل تاخیر زمانی یک روزه به پیش بینی گاز ازن در کلان شهر تهران پرداخته است. در این راستا از مدل شبکه عصبی مصنوعی جهت پیش بینی غلظت گاز ازن با استفاده از نرم افزار MATLAB و با روش کدنویسی استفاده شد. در پایان نتایج مدل شبکه عصبی مصنوعی با مدل رگرسیون خطی مقایسه گردید. ضریب همبستگی و خطای جذر میانگین مربعات مدل شبکه عصبی $R^2: 0/734$ و $RMSE: 0/566$ با معادلات رگرسیون $R^2: 0/608$ و $RMSE: 11/69$ مقایسه شد. بر اساس نتایج حاصل می توان عنوان نمود که خطای مدل شبکه عصبی کمتر از روش رگرسیون است. بر اساس نتایج آنالیز حساسیت پارامترهای فصل از سال، طول ساعات آفتابی به ترتیب بیش ترین تاثیر را در میزان تراکم گاز ازن در هوای شهر تهران دارند

کلمات کلیدی: آلودگی هوا، گاز ازن، شبکه عصبی مصنوعی، رگرسیون چند متغیره، آنالیز حساسیت

* پست الکترونیکی نویسنده مسئول مکاتبه: ajahani@ut.ac.ir

مقدمه

معضل آلودگی محیط زیست، بی هیچ تردیدی امروز به عنوان یکی از اصلی ترین چالش های زندگی شهرنشینی شناخته می شود و همه ساله خسارات فراوان جانی و مالی را به شهروندان و ساکنان شهرهای بزرگ و پرجمعیت تحمیل می کند. در این میان معضل آلودگی هوا در صدر فهرست مظاهر آلودگی از بابت خطرساز بودن قرار گرفته و مروری بر آمارهای سازمان بهداشت جهانی می تواند شاهی بر این ادعا باشد (۱). گسترش بی رویه شهرها و شهرنشینی و نیز رشد بخش صنعت به خصوص در مجاورت شهرهای بزرگ و پر جمعیت و ترکیب آنها با مجموعه عوامل طبیعی و اقلیمی نه تنها باعث افزایش آلودگی هوای شهرها شده، بلکه تغییراتی را در اقلیم جهانی به وجود آورده که در سال های اخیر به شدت مورد توجه محققان و برنامه ریزان قرار گرفته است (۲). براساس گزارش موسسه بین المللی تحقیقات سرطان (IARC) در سال ۲۰۱۳ آلودگی هوا و ذرات معلق در آن به عنوان ترکیبات صددرصد سرطان زا برای انسان طبقه بندی شده اند. همچنین براساس گزارش بار بیماری های جهانی، آلودگی هوا چهارمین عامل خطر برای مرگ در دنیا و همچنین هفتمین عامل خطر در ایران می باشد. کلان شهر تهران با توجه به شرایط توپوگرافی و اقلیمی آن و همچنین تردد نزدیک به ۵ میلیون وسیله نقلیه و استقرار تعداد زیادی واحدهای صنعتی بزرگ و کوچک، یکی از هشت شهر بزرگ کشور است که آلودگی هوا در آن به یکی از مشکلات بزرگ تبدیل شده است و در صورت عدم برنامه ریزی صحیح و اتخاذ راهکارهای کنترلی می تواند اثرات جبران ناپذیری بر سلامت افراد و محیط زیست وارد نماید. مهم ترین نکته در امر مدیریت کیفیت هوا اندازه گیری دقیق انواع آلاینده های هوا، منشاء یابی و سپس تدوین راهکارهای مناسب برای کاهش آنها می باشد (۳). استفاده از سیستم های کنترل آلودگی هوا و روش های تصفیه کننده از شیوه های عمومی کنترل آلودگی محیط زیست است که بایستی درست و با دقت زیاد مبتنی بر پایش ها صورت گیرد. از طرفی اغلب اوقات

اطلاعات در مورد پارامترهای سیستم های کنترل آلودگی هوا در دسترس نیست و تخمین های سختی باید زده شود و یا این که قسمت زیادی از اطلاعات در دسترس از قبیل دانش ضمنی تصمیم گیرندگان ممکن است کمیت پذیر نباشد (۴). یکی از روش های مقابله با کنترل آلودگی هوا می تواند استفاده از یک ابزار علمی و عملی باشد تا میزان رو به افزایش هریک از عوامل آلودگی را برآورد و پیش بینی کند (۵). در چند دهه گذشته، تلاش های پژوهشی متعددی در جهت تسهیل تصمیم گیری در حوزه مدیریت مسائل زیست محیطی از جمله کنترل کیفیت هوا صورت گرفته است. غالباً در این پژوهش ها، فنون تصمیم گیری سخت مورد توجه محققین بوده است و مدل های مختلف برنامه ریزی های ریاضی قطعی، احتمالی و فازی در زمینه مدیریت کیفیت هوا را به کار رفته اند (۱). در مقایسه با روش های ذکر شده، امروزه استفاده از شبکه های عصبی مصنوعی یکی از ابزارهای توانا در فرآیند بهینه سازی هستند، زیرا این شبکه ها توانایی گسترده ای در پردازش و یادگیری به صورت موازی را دارند (۶). در سال های اخیر تحقیقات گسترده ای در استفاده از شبکه های عصبی مصنوعی انجام شده و استفاده از این موضوع، کاربردهای متنوعی در رشته های مختلف پیدا کرده است. بیشتر پیشرفت ها در شبکه های عصبی به ساختارهای نوین و روش های یادگیری جدید مربوط می شود. در واقع شبکه های عصبی را می توان با اغماض زیاد، مدل های الکترونیکی از ساختار عصبی مغز انسان نامید (۷). به تعبیر دیگر شبکه عصبی مصنوعی، مدل ریاضی است که توانایی مدل سازی و ایجاد روابط غیرخطی برای درونیایی دارد (۸). محققین زیادی در این زمینه تا کنون مطالعاتی را انجام دادند. از این جمله می توان به مطالعه Boznar (۹) در نواحی صنعتی آلوده کشور اسلوونی و Ibarra-Berastegi (۱۰) در بیلباو اشاره کرد. با این وجود، تاکنون پژوهش های بسیار کمی در این زمینه در سطح کشور صورت گرفته است (۱۱). کاربرد و توسعه رویکردهای بهینه سازی احتمالی و تصمیماتی که در محیط پویای امروز گرفته می شوند

حداکثر: ۷۷۳۳۸۷۶) و همچنین پارامترهای زمانی نظیر روز از سال مورد نظر (۳۶۵-۱)، ماه از سال مورد نظر (۱۲-۱) و فصل از سال مورد نظر (۴-۱) و فصل گرم/سرد (۲-۱)، تاخیر زمانی یک روزه (میزان گاز ازن در یک روز قبل)، تاخیر زمانی دو روزه (میزان گاز ازن در دو روز قبل) است. دلیل استفاده از پارامترهای زمانی با تاخیر یک و دو روزه ماندگاری تراکم آلاینده ی ازن در جریان های هوایی می باشد و در نظر گرفتن تاخیر زمانی بیش از دو روز نتایج قابل قبولی را در میزان تراکم ازن هوا در روز هدف نخواهد داشت.

محدوده مورد مطالعه

تهران یکی از بزرگ ترین شهرهای غرب آسیا در کوهپایه های جنوب رشته کوه البرز و از نظر جغرافیایی در حد فاصل بین ۲۳° ۵۱' شمالی و ۳۵° ۳۵' الی ۳۰' ۳۵° عرض شمالی واقع گردیده است. گستردگی شهر از شمال به جنوب حدود ۲۷ کیلومتر و از شرق به غرب ۵۰ کیلومتر می باشد. ارتفاعات موجود در شمال و شمال شرق شهر تهران مانع عبور بادهایی که از سمت غرب و جنوب شهر تهران می وزند شده و جابجایی هوا صورت نمی گیرد در نتیجه و باعث انباشتگی آلاینده ها به سطح شهر می شود و در نتیجه پتانسیل آلودگی هوا در مرکز شهر را افزایش می دهد (۱۳).


مدل شبکه عصبی

شبکه های عصبی مصنوعی جزء سیستم های مکانیکی قرار دارند که با پردازش روی داده های تجربی، دانش یا قانون نهفته در ورا ی داده ها را به ساختار شبکه منتقل می کنند (۱۴، ۱۵). مسائل عمده ای که در مدل سازی شبکه های عصبی مصنوعی باید مد نظر قرار گیرند شامل: انتقال داده، انتخاب مناسب ورودی مدل، انتخاب یک هندسه مناسب شبکه، برآورد پارامترها و اعتبار مدل می باشد (۱۶، ۱۷، ۱۸). یک مدل ریاضی ساده جهت تحلیل رفتار شبکه عصبی در شکل ۱ نشان داده شده است؛ بردار X ها، Y ها، θ ها و $f(\text{net})$ به

دربگیرنده عدم قطعیت بالا و ملاحظات زیادی می باشند (۱۲). لذا هدف از این تحقیق، مدل سازی غلظت ازن هوا جهت ارائه مدل پیش بینی بهینه با استفاده از شبکه عصبی مصنوعی، سپس مقایسه آن با روش مدل رگرسیونی و در نهایت مشخص نمودن مدل برتر در پیش بینی غلظت ازن هوای شهر تهران است.

روش کار

در انجام این تحقیق از داده های روزانه ی سال ۱۳۹۴ شرکت کنترل کیفیت هوای شهر تهران، سازمان هواشناسی، سازمان حمل و نقل، فضای سبز و ترافیک تهران استفاده شد. پارامترهای اندازه گیری شده در سازمان های مذکور شامل میزان گاز ازن (ppb) (حداقل: ۸، حداکثر: ۱۳۶) در سطح شهر، پارامترهای هواشناسی شامل دما (°C) (حداقل: -۳، حداکثر: ۳۸)، فشار (hpa) (حداقل: ۵۰۳، حداکثر: ۹۰۰۲)، رطوبت (%) (حداقل: ۲، حداکثر: ۹۹)، سرعت باد (m/s) (حداقل: ۰، حداکثر: ۱۰)، جهت باد (حداقل: ۱۸، حداکثر: ۳۵۰)، بارندگی در ساعات گذشته (mm) (حداقل: ۰، حداکثر: ۴/۸۷)، طول ساعات آفتابی در روز (حداقل: ۰، حداکثر: ۱۲/۶)، پارامترهای ترافیکی شامل حجم ترافیک (km) (حداقل: ۹۳۱، حداکثر: ۱۹۲۸۵۰)، طول خیابان های شمالی- جنوبی (Y) (حداقل: ۰/۶۱، حداکثر: ۲/۹۵) و طول خیابان های شرقی- غربی (X) (حداقل: ۰/۹، حداکثر: ۵/۶۷)، اطلاعات فضای سبز مناطق که شامل تعداد پارک ها (حداقل: ۳، حداکثر: ۱۰)، مساحت مجموع پارک های مناطق مورد مطالعه (m^2) (حداقل: ۳۲۱۴۸۳، حداکثر: ۱۴۷۱۹۰۰۰)، میانگین فاصله هریک از پارک ها از ایستگاه های سنجش میزان گاز ازن (km) (حداقل: ۵۳۹۶۸/۰، حداکثر: ۶/۹۷۸۷۵)، شاخص پارک های مجاور ایستگاه سنجش میزان گاز ازن (که برابر است با میزان مساحت نزدیک ترین پارک به ایستگاه سنجش میزان گاز ازن تقسیم بر فاصله نزدیک ترین پارک تا ایستگاه سنجش گاز ازن) (m^2/km) (حداقل: ۷۰۹۲/۱۹۸۵۸۲، حداکثر: ۳۸۰۴۵۲۶/۷۴۹)، سطح فضای سبز مناطق (حداقل: ۶۱۵۰۶۰،



شکل ۱. یک مدل ریاضی نوعی از نرون ها در شبکه های عصبی مصنوعی

و در عین حال کارآمدترین چیدمان ها برای استفاده در مدل سازی عصب های واقعی، مدل پرسپترون چندلایه یا به اختصار MLP^1 است که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل یافته است. در این ساختار، تمام نرون های یک لایه به تمام نرون های لایه بعد متصل اند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می دهد (۲۵، ۲۶، ۲۷). در پژوهش انجام شده، ترکیب مختلفی از لایه ها و نرون های مختلف همراه با تابع فعال سازی تانژانت سیگموئید و خطی برای بهینه سازی شبکه استفاده شد. متداولترین الگوریتم یادگیری در شبکه های عصبی پرسپترون چند لایه الگوریتم آموزشی پس انتشار خطا^۲ است (۲۸، ۲۹، ۳۰). الگوریتم آموزشی پس انتشار خطا مقدار تابع خطا را کاهش داده و آن را از یک لایه به لایه پیشین آن انتشار می دهد. آموزش شبکه با استفاده از جفت ورودی-خروجی به کار گرفته شده در این مرحله صورت می گیرد به طوری که پس از آموزش اگر هر یک از این ورودی ها را به شبکه اعمال کنیم خروجی به دست آمده از شبکه نزدیک به خروجی مطلوب باشد. صحت مدل با مقایسه خروجی آن و شاخص های محاسبه شده شامل ضریب همبستگی^۳ (R^2)، میانگین خطای مطلق^۴ (MAE)، میانگین مربعات خطا^۵ (MSE) و ریشه میانگین مربعات خطا^۶ (RMSE) سنجیده شد (۳۱). هدف از انجام این تحقیق پیش بینی میزان غلظت ازن هوای شهر تهران با کمک شبکه عصبی مصنوعی و مقایسه آن با رگرسیون چند متغیره است. برای پیش بینی میزان غلظت ازن هوای شهر تهران، پارامتر اقلیمی هواشناسی، پارامتر های ترافیکی، پارامترهای زمانی و فضای سبز به عنوان متغیر های مستقل در نظر گرفته شد. خروجی حاصل از این مدل سازی، میزان غلظت ازن هوای شهر تهران است.

ترتیب بردارهای ورودی و وزن ها، مقدار بایاس و تابع در نظر گرفته شده برای نرون که خطی و غیرخطی در نظر گرفته می شوند، هستند. خروجی این مدل مطابق رابطه ۱ خواهد بود (۱۹، ۲۰، ۲۱).

$$y(k) = f(\sum_{j=1}^n W_j x_j(k) + W\theta) \quad (1)$$

به منظور پیش بینی آلودگی هوای شهر تهران با استفاده از مدل شبکه عصبی مصنوعی، از متغیرهای اقلیمی شهر تهران، میزان غلظت ازن هوا، پارامترهای ترافیکی خیابان ها، سطح فضای سبز و همچنین پارامترهای زمانی استفاده شد. در این پژوهش داده های ورودی برای استفاده از تابع آستانه سیگموئیدی در لایه پنهان، پیش از آموزش شبکه عصبی نرمال شدند به گونه ای که داده ها به اعدادی بین ۱- تا ۱ تبدیل شدند. از کل داده های پردازش شده ۲۰ درصد به عنوان مجموعه اعتبارسنجی، ۲۰ درصد به عنوان مجموعه آزمون و ۶۰ درصد به عنوان مجموعه آموزشی انتخاب شدند. با اختصاص حجم بیشتری از نمونه ها به آزمون شبکه می توان از قابلیت پیش بینی شبکه در نمونه های جدید اطمینان حاصل کرد لذا ترکیب به کار گرفته شده در این تحقیق در سایر مطالعات نیز استفاده شده است (۲۲، ۲۳، ۲۴). در مرحله بعد در فرآیند آموزش شبکه، مقادیر ورودی در لایه اول، وزن دار شدند و به لایه میانی فرستاده شدند. پس از آن خروجی های حاصله، توسط اتصالات بین لایه میانی و لایه خروجی، وزن دار شدند و نتایج در لایه خروجی تولید شدند. در این فرآیند خروجی مشخص به ورودی متناظر با آن به منظور آموزش و تنظیم وزن های ارتباطی در بین نرون ها مورد استفاده قرار گرفت. یکی از ساده ترین

1. Multilayer perceptron

2. Back Propagation

3. Coefficient of determination

4. Mean absolute error

5. Mean squared error

6. Root Mean Square Error

شبکه) بکاررفته با بیشترین مقدار ضریب همبستگی، بهترین عملکرد شبکه عصبی در پیش بینی و مدل سازی را نشان می دهد. با توجه به نتایج شبکه آموزش داده شده شبکه با ۲ لایه پنهان و ۳۰ نورون در هر لایه با تابع تانژانت سیگموئید رابطه (۲) در هر دو لایه مخفی، تابع خطی رابطه (۳) در لایه خروجی و همبستگی مطلوب در نتایج شبکه و همسانی نگه داشتن تمام متغیرها برابر با میانگین آنها شد و متغیر مورد نظر در دامنه انحراف معیار تغییر داده شد و با برآورد و شبیه سازی شبکه عصبی، انحراف معیار خروجی های مدل محاسبه گردید. این فرآیند برای یکایک متغیرهای ورودی انجام شده و حساسیت نتایج مدل به تک تک متغیرها تعیین شد.

== یافته ها

برای بهینه سازی شبکه هوشمند عصبی ابتدا با آزمون و خطا تعداد لایه ها و نورون های مختلف مورد آزمون قرار گرفت سپس ساختار بهینه شبکه عصبی مصنوعی با ۶۱ نورون و دو لایه پنهان برای پیشبینی میزان غلظت گاز ازن در هوای شهر تهران انتخاب شد. ویژگی های مورد آزمون برای دستیابی به ساختار بهینه شبکه عصبی در جدول ۱ نشان داده شده است.

ضرایب همبستگی در مراحل آموزش، اعتبارسنجی، آزمون داده ها و کل داده ها و همچنین حداقل میزان MSE کل داده ها که در جدول ۲ به آن اشاره شده است دقت شبکه عصبی در پیش بینی میزان غلظت ازن در هوای شهر تهران از سطح بسیار مطلوبی برخوردار است.

$$\text{tansig}(x) = \frac{2}{[1 + \exp(-2x_i)] - 1} \quad (2)$$

$$\text{Purelin}(x) = f(x) = x \quad (3)$$

در شکل ۲ نمودارهای نتایج شبکه عصبی بهینه شده ارائه شده است. این نمودارها تصویر واضحی از نحوه عملکرد شبکه عصبی ساخته شده را نشان می دهند. نمودارها ضریب همبستگی داده ها را نشان می دهد که

مدل رگرسیون خطی چندگانه (MLR)

در آنالیز رگرسیون خطی چندگانه MLR^7 از روش گام به گام استفاده گردید. بنابراین از متغیرهایی که دارای اثر معنی داری بر متغیر وابسته بود استفاده شد. در این تکنیک میزان غلظت ازن هوا اندازه گیری شده ی روزانه به عنوان یک متغیر وابسته و فاکتورهای موثر بر این عامل به عنوان متغیر مستقل در نظر گرفته شدند. در MLR ، بهترین معادله بر اساس تعداد توصیف کننده ها در مدل (n)، ضریب همبستگی، مقدار آماره F و ریشه متوسط مربعات خطا انتخاب می شود. هرچه در یک معادله مقدار ضریب همبستگی به ۱ نزدیکتر، مقدار F بیشتر و n و $RMSE$ کمتر باشد معادله از کیفیت مطلوب تری برخوردار است (۳۲، ۳۳). آماره R^2 به عنوان یک شاخص برای بیان دقت خط رگرسیون به کار رفته و مقدار آن بین صفر و یک تغییر می کند و مقادیر نزدیک به یک تطابق بهتر داده های مشاهده های و برآورده شده را نشان می دهد.

آنالیز حساسیت

آنالیز حساسیت متشکل از مطالعه تاثیرپذیری عدم قطعیت در متغیرهای خروجی به عدم قطعیت در متغیرهای ورودی یک مدل آماری با منابع مختلف می باشد (۳۴). به عبارت دیگر روشی برای تغییر دادن در ورودی های یک مدل آماری به صورت سازمان یافته (سیستماتیک) است که بتوان تأثیرات این تغییرها را در خروجی مدل پیش بینی کرد. لذا خروجی حاصل از مدل سازی شبکه عصبی مصنوعی، اولویت بندی متغیرهای تاثیر گذار بر میزان تراکم ازن هوای شهر تهران جهت بالا بردن سطح پیشبینی می باشد. جهت انجام آنالیز حساسیت و محاسبه حساسیت خروجی شبکه عصبی مصنوعی به هریک از متغیرهای مدل اقدام به ثابت در آموزش شبکه عصبی می توان از ترکیبات مختلف لایه های پنهان و با تعداد نورون مختلف استفاده نمود، اما بررسی ضرایب همبستگی R^2 به دست آمده میزان خطای شبکه در پیش بینی را نشان می دهد و توپولوژی (ساختار

7. Multiple linear regression

جدول ۱. نتایج ساختار بهینه شبکه عصبی مصنوعی برای پیش بینی میزان غلظت گاز ازن در هوای شهر تهران

ویژگی های ساختاری شبکه	لایه پنهان اول	لایه پنهان دوم	لایه خروجی
نوع شبکه	پرسپترون چندلایه	پرسپترون چندلایه	پرسپترون چندلایه
تابع انتقال	تانژانت سیگموئید	تانژانت سیگموئید	خطی
الگوریتم بهینه	لونیگ-مارکوارت	لونیگ-مارکوارت	لونیگ-مارکوارت
دوره یادگیری	۰/۰۱	۰/۰۱	۰/۰۱
ضریب مومنتوم	۰/۹	۰/۹	۰/۹
تعداد نوروها	۳۰	۳۰	۱
نرمال سازی	۱ تا -۱	۱ تا -۱	۱ تا -۱

جدول ۲. نتایج ساختار مدل شبکه عصبی مصنوعی جهت پیش بینی میزان غلظت ازن در هوای شهر تهران

آماره	R ²	MAE	MSE	RMSE
آموزش	۰/۸۵۱	۰/۳۳۹	۰/۱۶۹	۰/۴۱۱
اعتبارسنجی	۰/۵۹۷	۰/۴۸۳	۰/۴۱۲	۰/۶۴۱
آزمون	۰/۵۵۸	۰/۴۶۷	۰/۵۳۶	۰/۷۳۲
کل داده ها	۰/۷۳۴	۰/۳۸۸	۰/۳۲۰	۰/۵۶۶


مقادیر فوق بیانگر آن است که شبکه عصبی در مدل سازی و پیش بینی میزان غلظت

ازن هوای شهر تهران در بازه زمانی یک ساله سال ۱۳۹۴ موفق عمل کرده است. شکل (۲-الف) مربوط به داده های آموزش، (۲-ب) داده های اعتبارسنجی، (۲-ج) داده های آزمون و (۲-د) کل داده ها است.

به منظور مقایسه نتایج پیش بینی ازن با شبکه عصبی مصنوعی و مدل رگرسیون چند متغیره برای بررسی اعتبار نتایج به دست آمده از مدل ها، آماره R² مورد ارزیابی قرار گرفت ولی با توجه به این مسئله که مقدار R² تحت تأثیر پراکندگی داده ها است باید علاوه بر آن از پارامترهای دیگر استفاده کرد به همین دلیل از دیگر پارامترها نظیر ریشه متوسط مربعات خطا (RMSE) نیز برای بررسی اعتبار نتایج استفاده شد (۳۲). در ابتدا با استفاده از مدل رگرسیون چند متغیره به بررسی رابطه میان میزان تغییرات فاکتورهای زمانی، اقلیمی، ترافیکی و فضای سبز مورد نظر در شهر تهران بر روی میزان غلظت ازن هوا در شهر تهران پرداخته شد. در این مطالعه مشخص شد که پیش بینی میزان غلظت ازن هوا با توجه به روش گام به

گام مورد استفاده متغیرهای دما، طول ساعات آفتابی در روز، سرعت باد، نتایج آموزش کاربرد مدل رگرسیون چند متغیره به تاخیر زمانی یک روزه و تاخیر زمانی دو روزه در مدل باقیمانده و در نتیجه بیش ترین میزان تأثیر را بر پیش بینی میزان گاز ازن را در طول روز در شهر تهران را دارا هستند. در مدل MLR مقادیر یک متغیر وابسته از روی مقادیر دو یا چند متغیر مستقل دیگر برآورد می شود. نتایج نشان داد که مدل رگرسیون چندگانه به روش گام به گام با $RMSE=11/690$ ، $R^2=0/608$ بهترین عملکرد را نسبت به مدل های غیر خطی در پیش بینی غلظت ازن هوا در شهر تهران داشته است. نتایج آموزش کاربرد مدل رگرسیون چند متغیره به روش گام به گام در پیش بینی میزان غلظت ازن هوای شهر تهران در شکل و جدول ۳ نشان داده شده است و معادله به دست آمده به شکل زیر است رابطه (۴)، که در این رابطه X_1 دما و X_2 طول ساعات آفتابی در روز، X_3 سرعت باد، X_4 تاخیر زمانی یک روزه و X_5 تاخیر زمانی دو روزه را نشان می دهد.

$$O_3 = 0.255 X_1 + 0.363 X_2 - 0.758 X_3 + 0.561 X_4 + 0.175 X_5 + 3.140 \quad (4)$$



شکل ۲. نمودارهای مدل سازی داده ها با شبکه عصبی مصنوعی الف- داده های آموزش ، ب- داده های اعتبار سنجی ، ج- داده های آزمون ، د- کل داده ها

منبع: یافته های تحقیق، ۱۳۹۴


جدول ۳. نتایج مدل رگرسیون چند متغیره در پیش بینی میزان ازن شهر تهران

Sig	F	RMSE	R ²
۰/۰۰۰	۴۷۱/۴۹۲	۱۱/۶۹۰	۰/۶۰۸

منبع: یافته های تحقیق، ۱۳۹۴

رابطه میان متغیرهای زمانی، اقلیمی، ترافیکی و فضای سبز با غلظت ازن هوا و مدل سازی آن، شکل ۴ ضریب تأثیرگذاری هر یک از متغیرهای کاربردی بر اساس نتایج آنالیز حساسیت متغیرهای فصل/سال، طول ساعات آفتابی به ترتیب بیش ترین تأثیر را در میزان غلظت ازن هوای شهر تهران از خود نشان دادند، لذا به بررسی نتایج پیش بینی غلظت ازن هوا بر حسب تغییرات متغیرهای

روش گام به گام در پیش بینی میزان غلظت ازن هوا شهر تهران در شکل ۳ نشان داده شده است. جدول ۴ نتایج مدل سازی با شبکه عصبی مصنوعی و رگرسیون چند متغیره را نشان می دهد. مقایسه نتایج به دست نتایج مربوط به آنالیز حساسیت متغیرهای بکارگرفته شده برای مدل سازی در شکل ۴ نشان داده شده است. با توجه به هدف پژوهش در جهت کشف



شکل ۳. نتایج مدل رگرسیون چند متغیره به روش گام به گام در پیش بینی غلظت ازن هوای شهر تهران
منبع: یافته های تحقیق

جدول ۴. نتایج مدل سازی با شبکه عصبی و رگرسیون چند متغیره در پیش بینی غلظت ازن هوای شهر تهران

آماره	R ²	RMSE
نتایج شبکه عصبی	۰/۷۳۴	۰/۵۶۶
نتایج رگرسیون چند متغیره به روش گام به گام	۰/۶۰۸	۱۱/۶۹۰

منبع: یافته های تحقیق، ۱۳۹۴

صعودی و رابطه ای مستقیم دارد و با افزایش میزان طول ساعات آفتابی در روز میزان تراکم ازن در هوا نیز افزایش می یابد.


بحث و نتیجه گیری

آلودگی هوا یکی از مهم ترین مقوله هایی است که نه تنها سلامت انسان را تهدید می کند، بلکه بر کلیه عوامل محیط زیست اعم از گیاه و حیوان و حتی بناهای تاریخی، لوازم و تجهیزات خانگی، ماشین ها و تجهیزات صنعتی و ساختمانی نیز موثر بوده و آنها در معرض اثر های نامساعد ناشی از آلودگی هوا قرار دارند (۳۷، ۳۸).
۳۵، ۳۶. هوای کلان شهر تهران به شدت آلوده بوده که عواقب آن در درجه اول به صورت انواع امراض نصیب ساکنان شهر تهران شده و از طرف دیگر باعث افزایش بی رویه هزینه های جاری به منظور اندازه گیری، پایش و حذف این آلودگی ها شده است. هدف نخست تعیین


مذکور پرداخته می شود. روند تغییرات میزان غلظت ازن هوا بر حسب فصل/سال در شکل (۵- الف) بیانگر رابطه غیر خطی این پارامتر با میزان تراکم ازن در هوا است به طوری که نمودار آمده نشان دهنده این موضوع است که مدل شبکه عصبی توانایی بیش تری نسبت به روش های رگرسیون چندگانه دارد.

در پیش بینی میزان غلظت ازن هوای شهر تهران را نشان می دهد. بالاترین اثرگذاری متغیرهای ورودی بر روی میزان غلظت ازن هوای شهر مربوط به متغیرهای فصل/سال با ضریب اثرگذاری ۸/۱۲، طول ساعات آفتابی با ضریب اثرگذاری ۴/۱۹ و سایر متغیرها تأثیرات کمتری بر روی میزان غلظت ازن هوای شهر تهران داشته اند.

متغیر فصل/سال ابتدا رابطه غیرمستقیم و پس از آن رابطه مستقیم با میزان افزایش تراکم ازن هوا را نشان می دهد. روند تغییرات میزان ازن هوا بر حسب طول ساعات آفتابی در شکل (۵- ب) نشان می دهد که که پارامتر طول ساعات آفتابی با میزان تراکم ازن روندی



شکل ۴. ضریب تأثیرگذاری متغیرهای کاربردی در پیش بینی میزان غلظت ازن هوای شهر تهران
منبع: یافته‌های تحقیق، ۱۳۹۴



شکل ۵. (الف) رابطه متغیر فصل/سال با تراکم ازن در هوا، (ب) رابطه متغیر طول ساعات آفتابی با میزان تراکم ازن در هوا
منبع: یافته‌های تحقیق، ۱۳۹۴

پیش‌بینی تراکم ازن هوای شهر تهران توسط شبکه عصبی مصنوعی با مدل رگرسیون چند متغیره است. نتایج به دست آمده نشان داد که مدل شبکه عصبی با ضریب همبستگی 0.734 توانایی بیشتری در پیش بینی میزان غلظت ازن نسبت به روش رگرسیون چند متغیره با ضریب تعیین 0.608 دارد. تحقیقات بدست آمده توسط پژوهشگران دیگر نشان دهنده برتری شبکه عصبی در پیش بینی کوتاه مدت آلودگی هوا نسبت به رگرسیون چند متغیره است که می‌توان به مدل سازی غلظت CO (۳۹) و مدل سازی غلظت SO_x (۴۰، ۴۱) مدل سازی غلظت NO_x (۵) و مدل سازی غلظت ازن

مدل پیش بینی تراکم ازن هوای شهر تهران با استفاده از شبکه عصبی مصنوعی است. نتایج این پژوهش نشان داد که شبکه عصبی پرسپترون طراحی شده با ۲ لایه مخفی و ۳۰ نورون در هر لایه مخفی و تابع تانژانت سیگموئید، قابلیت خوبی در مدل کردن تغییرات تراکم ازن هوای شهر تهران را دارد. مدل به دست آمده در این پژوهش قابلیت پیش بینی میزان تراکم ازن هوا را فراهم کرده و امکان کاربرد در سامانه پشتیبانی تصمیم گیری فضایی مدیریت کیفیت هوا و با کمک به مدیریت بهینه حمل و نقل شهری کلان شهر تهران را فراهم می‌آورد. هدف دوم پژوهش حاضر مقایسه نتایج حاصل از مدل سازی

مدیریت آلودگی هوای شهر می تواند تاثیر بسزایی داشته باشد. از پارامترهای مهم دیگر بر میزان غلظت ازن هوا، پارامتر طول خیابان X و پس از آن پارامتر فصل گرم/ سرد است. با این کار می توانیم میزان تراکم ازن هوا را در آن روز بسنجیم و این امر نیز در مدیریت آلودگی هوای شهر تاثیر بسزایی خواهد داشت. پیرو این امر می توانیم تصمیم های مدیریتی در جهت پیشگیری از برخی اثرات آلودگی هوا نظیر آسیب دیدگی کمتر قشر آسیب پذیر جامعه نظیر اطفال، سال خوردگان و بیماران قلبی و تنفسی اتخاذ کنیم. با پیش بینی میزان آلودگی هوا در روزهای آینده می توان تصمیم گیری های مدیریتی برای کنترل آلودگی هوا و ارائه راهکارها و هشدارهای لازم را انجام داد. این موضوع به صورت ویژه در پیش بینی وضعیت آلودگی هوا در شهرهای صنعتی و پرجمعیتی همچون تهران از اهمیت بسزایی برخوردار است.

REFERENCES

- Golbabaie F, Azar A, Ganji Kazemian M. Designing a model for selection of air pollution control equipment using fuzzy logic . JHSW. 2014, 4 (2) :37-50
- Iran Census Center, Census of Iran, Tehran, 2006 (Persian)
- Naderi M, Roshani M, Abasian M, TORBATIAN S. Tehran annual air quality report(period of March 2016-March 2017). 2017, QM96/02/01.
- Lu, H.; Huang, G.; He, L., (2010). A Two-Phase Optimization Model Based on Inexact Air Dis-persion Simulaion for Regional Air Quality Control. Water Air Soil Pollut. 2010, 211, 121-134.
- Bodaghpour S ,Charkhestani A. Prediction of gas pollutant's concentration by means of artificial neural network in Tehran urban air. 2011, 1-10.
- Kuan C, White H. Artificial neural networks: an econometric perspective . Econometric reviews. 1994. 13(1):1-91.
- Shafabakhsh, G.H., Fathi, F., Zayarzaeh, A. Improvement of road eventful points prioritization by artificial neural network. Journal of Modeling in Engineering. 2010, 8. 20:71-81.
- Montazer, A., Azadegan, B., Shahraki, M., (2009): Evaluation of artificial neural network models to calculate the performance and utilization of crop water based on the climate factors and water supply of nitrogen. Iranian Water Research Journal. 2009, 3, 5:17-29.
- Boznar M, Lesjak M, Mlakar P. A neural network-based method for short-term predictions of ambient SO₂ concentrations in highly polluted industrial areas of complex terrain. Atmospheric Environment. Part B. Urban Atmosphere. 1993, 27(2):221-230.
- Ibarra-Berastegi G, Elias A, Barona A, Saenz J, Ezcurra A, Argandoña Jd. From diagnosis to prognosis for forecasting air pollution using neural networks: Air pollution monitoring in Bilbao. Environmental Modelling & Software. 2008, 23(5):622-637.
- Eshaghi, M.; Golmohammadi, R.; Riahi Khor-ram, M. Prioritizing of Noise Con-trol Methods in the Hamadan Glass Company by the Analytical Hierarchy Process (AHP). Journal of Health and Safety at Work. 2012, 1 (1), 75-84.
- Zhang, J., Wu, D., & Olson, D. L. The method of grey related analysis to multiple attribute decision making problems with interval numbers. Mathematical and

- Computer Modelling. 2005, 42(9-10), 991-998. doi: <http://dx.doi.org/10.1016/j.mcm.2005.03>.
13. Annual Report on Air Quality in Tehran, Air Quality Monitoring and Monitoring Company. 2015, 1-192(Persian)
 14. Alefi M, Sadeghi Yarandi M, Karimi A. Modeling of Occupational Risk Factors in the Development of Musculoskeletal Disorders in Nurses. Archives of Occupational Health. 2020;4(1):474-9.
 15. Mosaffaei, Z., Jahani, A., Zare Chahouki, M.A., Goshtasb, H., Etemad, V., Saffariha, M. Soil texture and plant degradation predictive model (STPDPM) in national parks using artificial neural network (ANN). Modeling Earth Systems and Environment. 2020.
 16. Maier, H. R., and Dandy, G. C. Neural Network Based Modelling of Environmental Variables: A Systematic Approach, Mathematical and Computer Modelling. 2001, 33: 669-682.
 17. Kalantary, S., Jahani, A., Pourbabaki, R., & Beigzadeh, Z. Application of ANN modeling techniques in the prediction of the diameter of PCL/gelatin nanofibers in environmental and medical studies. RSC Advances. 2019, 9 (43), 24858-24874.
 18. Kalantary S, Jahani A, Jahani R. MLR and Ann Approaches for prediction of Syn-thetic/natural Nanofibers Diameter in the Environmental and Medical Applications. Scien-tific Reports. 2020;10(1):1-0.
 19. Ghasemi, H., Forecasting the concentration of CO and NOX in the air of Tehran by artificial neural network metod. 2016, 1-71(persian)
 20. Jahani, A. Modeling of forest canopy density confusion in environmental assessment using artificial neural network. Forest and Poplar Research. 2016, 24(2): 310-322.
 21. Bahraminejad M, Rayegani B, Jahani A, Nezami B. Proposing an early-warning sys-tem for optimal management of protected areas (Case study: Darmiyan protected area, Eastern Iran). Journal for Nature Conservation. 2018;46:79-88.
 22. Khosravi, M., Salajegheh, A., Mahdavi, M., and Mohseni Saravi, M. The determination of the best activation function of output layer in neural network for peak water flow prediction. Iran-Watershed Management Science and Engineering. 2010, 4(12): 51-64. (In Persian)
 23. Barati B, Jahani A, Zebardast L, Raygani B. Integration Assessment of The Protect-ed Areas Using Lanscape Ecological Approach (Case: Kolah Ghazy National Park and Wildlife Refuge). Town and Country Planning. 2017,9(1):153-168.
 24. Rahmati O, Panahi M, Ghiasi SS, Deo RC, Tiefenbacher JP, Pradhan B, Jahani A, Goshtasb H, Kornejady A, Shahabi H, Shirzadi A. Hybridized neural fuzzy ensembles for dust source modeling and prediction. Atmospheric Environment. 2020;224:117320.
 25. Jahani A. Modeling of forest canopy density confusion in environmental assessment using artificial neural network, Iranian Journal of Forest and Poplar Research. 2016, 42(2):310-322.
 26. Jahani, A., Goshtasb, H., Saffariha, M. Tourism impact assessment modeling in vegetation density of protected areas using data mining techniques, Land Degradation & Development. 2020, <https://doi.org/10.1002/ldr.3549>.
 27. Jahani, A., Makhdoum, M., Feghhi, J., and Etemad, V. Determining of landscape quality and look out points for ecotourism land use (Case study: Patom District of Kheyroud Forest). Journal of Environment Researches. 2011, 2(3): 13-20.
 28. Dehghani A, Piri M, Hesam M, Dehghani N. Estimation of daily evaporation from evaporation pan using three multilayer perceptron neural networks radial and German base function. Journal of Soil and Water Conservation Research 2010, 2(17):49-67.
 29. Jahani, A., Mohammadi Fazel, A. Aesthetic quality modeling of landscape in urban green space using artificial neural network. Journal of forest and wood products (JFWP) (Iranian Journal of natural resources). 2017, 69(4), 951-963.
 30. Pourmohammad, P., Jahani, A., Zare Chahooki, M.A., Goshtasb Meigooni, H. Road impact assessment modelling on plants diversity inational parks using regression analysis in comparison with artificial intelligence. Modeling Earth Systems and Environment. 2020, Doi: 10.1007/s40808-020-00799-6
 31. Jahani A. Sycamore failure hazard risk modeling in urban green space. Journal of Spatial Analysis Environmental Hazarts. 2017;3(4):35-48.
 32. Samiei S, Alefi M, Alaei Z, Pourbabaki R. Risk Factors of Low Back Pain Using Adaptive Neuro-Fuzzy. Archives of occupational health. 2019 ;3(2):339-45.
 33. Shams SR, Jahani A, Moeinaddini M, Khorasani N, Air

- carbon monoxide forecasting using an artificial neural network in comparison with multiple regression, *Journal of Modeling Earth Systems and Environment*. 2020, Doi: 10.1007/s40808-020-00762-5
34. Saltelli A, M Ratto, T Andres, F Campolongo, J Cariboni, D Gatelli, M Saisana, S Tarantola. *Global Sensitivity Analysis: The Primer*. England: Wiley. 2008, 1-287.
 35. Gifford, RM. Interaction of Carbon Dioxide with Growth-limiting Environmental Factors in Vegetation Productivity: Implications for the Global Carbon Cycle. *Advances in Bioclimatology*. Springer Berlin Heidelberg. 1992, 24-58.
 36. Mosayebi M, Hajihosseini R, Ghorbanzadeh B, Kalantari S. A Risk for Nosocomial In-fec-tion: Contamination of Hospital Air Cooling Systems by *Acanthamoeba* spp. *International Journal of Hospital Research*. 2016;5(1):17-21.
 - 37. Tajmiri S, Azimi E, Hosseini MR, Azimi Y. Evolving multilayer perceptron, and factorial design for modelling and optimization of dye decomposition by bio-synthesized nano CdS-diatomite composite. *Environmental Research*. 2020;182:108997.
 38. Azimi Y, Khoshrou SH, Osanloo M. Prediction of blast induced ground vibration (BIGV) of quarry mining using hybrid genetic algorithm optimized artificial neural network. *Measurement*. 2019;147:106874.
 39. Postolache O, Girao P, Pereira M, editors. Neural network application in a carbon monoxide measurement system. *Neural Networks*, 2001. Proceedings. IJCNN'01. International Joint Conference on. IEEE. 2001, 2076-2081
 40. Chelani AB, Rao CC, KM Phadke, Hasan M. Prediction of sulphur dioxide concentration using artificial neural networks. *Environmental Modelling & Software*. 2002, 17(2):159-166.
 41. Sahin U, Ucan ON, Bayat C, Ozturun N. Modeling of SO₂ distribution in Istanbul using artificial neural networks. *Environmental Modeling and Assessment*. 2005, 10(2):135-142.
 42. SadrMousavi M, Rahimi A. Comparison of the results of multilayer perceptron neural networks and multiple linear regressions for prediction of ozone concentration in Tabriz city. 2010, 50-57
 43. Jie L, Peng Y, Wensheng L, Agudamu L. Comprehensive assessment grade of air pollutants based on human health risk and ANN method. *Procedia Engineering*. 2014, 84:715-720.