

پیش بینی غلظت آلاینده های هوای تهران بر اساس متغیرهای هواشناسی با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی در فصول گرم و سرد

سرد

راضیه فرهادی^۱؛ مجتبی هادوی فر^{۲*}؛ مظاهر معین الدینی^۳؛ محمود امین طوسی^۴

۱- کارشناس ارشد محیط زیست، دانشگاه حکیم سبزواری

۲- استادیار گروه محیط زیست، دانشگاه حکیم سبزواری

۳- استادیار گروه محیط زیست، دانشکده منابع طبیعی، دانشگاه تهران

۴- استادیار دانشکده ریاضی و علوم کامپیوتر، دانشگاه حکیم سبزواری

(تاریخ دریافت ۹۸/۰۱/۱۱- تاریخ دریافت ۹۸/۰۴/۰۹)

چکیده:

تهران آلوده ترین شهر کشور محسوب می شود که این آلودگی می تواند آثار دراز مدت و کوتاه مدتی بر سلامت انسان داشته باشد. از این رو پیش بینی غلظت آلاینده ها می تواند در برنامه ریزی های پیشگیری و کنترل مفید واقع شود. روشهای متفاوتی برای پیش بینی وجود دارد و در این میان سالها، روش های شبکه ی عصبی پیشرفت قابل توجهی در پیش بینی آلودگی هوا داشته است. در این مطالعه، از شبکه ی عصبی مصنوعی پرسپترون سه لایه به منظور پیش بینی غلظت آلاینده های PM_{10} ، CO و شاخص کیفیت هوا (AQI) در هوای شهر تهران استفاده شد. داده های غلظت آلاینده ها از اداره ی کنترل کیفیت هوای تهران جمع آوری شد و داده های هواشناسی از اداره ی کل سازمان هواشناسی کشور طی سال های ۱۳۹۲ و ۱۳۹۳ جمع آوری شد. بیشترین ضریب همبستگی (R^2) برای آلاینده PM_{10} با مقدار 0.83 در فصول گرم بود و بیشترین ضریب همبستگی آلاینده CO مربوط به فصول سرد بود ($R^2=0.74$). در نهایت بیشترین ضریب همبستگی AQI در فصل سرد ($R^2=0.57$) بود. در مدل رگرسیون خطی بیشترین ضریب همبستگی با مقدار 0.58 برای آلاینده PM_{10} در فصول گرم بود. بیشترین ضریب همبستگی در این مدل برای آلاینده CO با مقدار 0.33 در فصل سرد بود. در نهایت بیشترین ضریب همبستگی AQI ($R^2=0.31$) در فصل گرم بود. این به این معنی است که با تغییرات متغیرهای هواشناسی، غلظت CO و ذرات معلق و مقادیر شاخص AQI تغییر می کند به گونه ای که افزایش باد باعث پراکنش آلاینده و کاهش غلظت آن می شود و افزایش درجه حرارت باعث افزایش غلظت آلاینده می شود. بنابراین بین آنها ارتباط وجود دارد.

کلید واژگان: پیش بینی آلودگی هوا، مونوکسید کربن، ذرات معلق، شاخص کیفیت هوا

۱. مقدمه

داده‌هاست. (Yi and Prybutok 1996) در تحقیقی سه روش شبکه‌ی عصبی، رگرسیون و آریمای را جهت پیش‌بینی غلظت آزون در یک منطقه در تگزاس به کار بردند که طبق تحقیقات نشان داد که شبکه‌ی عصبی نسبت به دو مدل دیگر دقیق‌تر است. Park و همکاران (۲۰۱۸)، در پایتخت سئول برای پیش‌بینی غلظت PM₁₀ از شبکه‌ی عصبی استفاده کردند. مدل ANN یک ضریب همبستگی بالا (۶۸٪-۸۰٪) را بین مقادیر اندازه‌گیری شده و مقادیر واقعی نشان داد. از شبکه‌ی عصبی برای بررسی ارتباط بین پارامترهای هواشناسی و غلظت O₃ و PM₁₀ استفاده شد. نتایج نشان داد که به طور کلی، همبستگی بین PM₁₀ و متغیرهای هواشناسی در زمان‌های مختلف، به عنوان یک تابع از تاخیر زمانی افزایش می‌یابد. بیشترین همبستگی در تابستان بود زمانیکه تابش خورشیدی افزایش پیدا می‌کرد (Demuzere et al., 2009). McKendry و همکاران (۲۰۱۵) برای پیش‌بینی غلظت PM₁₀ و PM_{2.5} از شبکه‌ی عصبی مصنوعی استفاده کردند.

نتایج تحقیق برتری کم‌تر شبکه‌ی عصبی را نسبت به رگرسیون نشان داد. و اما در ایران Hassani و همکاران (۲۰۱۵) از مدل ترکیبی ANN-ACO برای پیش‌بینی و کاهش انتشارات موتور دیزلی استفاده کردند. مدل شبکه‌ی عصبی مدل مناسبی برای انتشارات NO_x و دوده ناشی از موتور دیزلی بود. Nejadkoorki و Baroutian (۲۰۱۲) در تحقیقی بر روی پیش‌بینی حداکثر غلظت PM₁₀ در طی ۲۴ ساعت آتی در شهر تهران پرداختند. از داده‌های هواشناسی و غلظت آلاینده‌ها به عنوان پارامترهای ورودی شبکه پس انتشار خطا استفاده شد. نتایج پیش‌بینی با شاخص توافق بالای ۰/۸۳،

امروزه آلودگی هوا یکی از مهمترین مشکلات جوامع بشری است (Zannetti, 1990). این مشکل در شهرهای بزرگ و صنعتی حادثتر است (Karaca et al., 2006). آلودگی هوا می‌تواند اثراتی را در دراز مدت و کوتاه مدت بر سلامت انسان داشته باشد (Anderson, 2009). بنابراین آگاهی از غلظت آلاینده‌های هوا در محیط‌های شهری به منظور ارزیابی وضعیت آلودگی هوا و برنامه‌ریزی برای کنترل آن ضروری می‌باشد (Jiang et al., 2004). یکی از الزامات کنترل آلودگی هوا پیش‌بینی آن است (Sharma & Chaudhry, 2005).

در دو دهه‌ی اخیر مدل‌های آماری متعددی نیز جهت پیش‌بینی آلاینده‌های هوا مورد استفاده قرار گرفته است (Collett & Oduyemi, 1997). نتایج این اندازه‌گیری و پیش‌بینی‌ها می‌تواند در برنامه‌ریزی‌های مدیریت و کنترل آلودگی هوا مورد استفاده قرار بگیرد. یکی از این مدل‌ها مدل‌های رگرسیون^۱ می‌باشد اما یکی از محدودیت‌های آن خطی بودن این مدل می‌باشد (Harrison, 1997; Ziomas et al., 1995). از مدل‌های خطی دیگر می‌توان به مدل آریمای^۲ اشاره کرد (Jian et al., 2012). ممکن است بین خروجی‌ها و ورودی‌ها رابطه غیر خطی برقرار باشد که می‌توان از شبکه‌ی عصبی مصنوعی^۳ (ANN) به این منظور استفاده کرد (Agirre-Basurko et al., 2006). شبکه‌ی عصبی دارای خصوصیات ویژه‌ای همچون قابلیت یادگیری، تعمیم، خوشه‌بندی، یا مرتب‌سازی

- 1- Regression models
- 2- ARIMA model
- 3- Artificial neural network

رشته کوه البرز قرار گرفته است (شکل ۱). وسائل نقلیه بسیار زیادی در طول شبانه روز در آن به فعالیت مشغولند و بادهای غربی در تمام طول سال دود کارخانجات و سایر عوامل آلوده کننده را به سطح شهر تهران وارد می‌سازند. عوامل متعددی در آلودگی شهر تهران مؤثرند که در بین آنها عوامل جغرافیایی و هواشناسی از اهمیت بیشتری برخوردارند.

۲-۲. داده‌های مورد استفاده

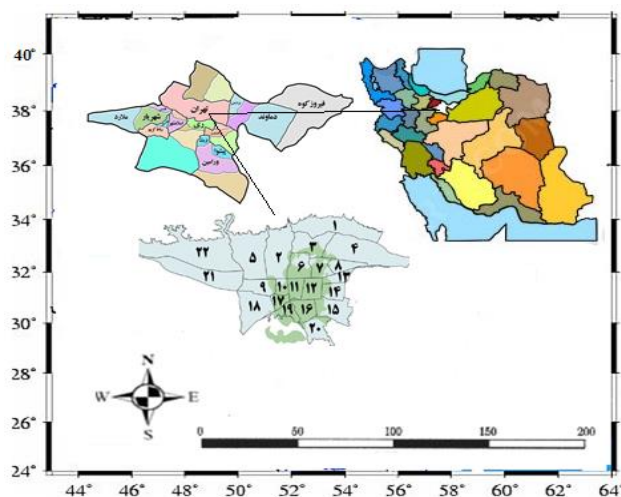
تعیین متغیرهای ورودی مدل، از مهم‌ترین مراحل توسعه مدل شبکه عصبی می‌باشد. پارامترهایی انتخاب شدند که منجر به بهترین پیش‌بینی غلظت آلاینده‌ها شدند. با در نظر گرفتن ملاحظات ذکر شده، بررسی تحقیقات گذشته و انجام سعی و خطاهای مکرر با ترکیبات مختلف متغیرهای ورودی، پارامترهای هواشناسی شامل دما ($^{\circ}\text{C}$)، رطوبت (%، سرعت (m/s) و جهت باد (درجه)، فشار به عنوان مؤثرترین پارامترهای هواشناسی و متغیرهای ورودی مدل طبق جدول ۱ انتخاب شدند. اطلاعات هواشناسی از اداره کل هواشناسی کشور (ایستگاه مهرآباد) و داده‌های ساعتی مربوط به غلظت هر یک از آلاینده‌های CO ، PM_{10} و AQI در یک دوره‌ی ۱۸ ماهه از فروردین ۹۲ تا مهر ۹۳ مربوط به ایستگاه دانشگاه شریف از کنترل کیفیت هوای تهران دریافت شد و به عنوان ورودی شبکه عصبی مورد استفاده قرار گرفت (جدول ۱).

مطلوب بود. از طرف دیگر شبکه با عملکرد مطلوب به خوبی می‌تواند نسبت به سایت‌های سنجش انسانی در شبکه پایش کیفیت هوا، برتری داشته باشد (Nejadkoorki and Baroutian 2012). از طرفی دیگر کیفیت هوای مونوکسیدکربن در شهر اصفهان مورد تجزیه و تحلیل قرار گرفت. نتایج نشان داد که بیشترین میزان غلظت CO در صبح و ابتدای شب اتفاق می‌افتاد و غلظت فصلی در بهار کمترین مقدار را نشان می‌داد، در حالی که بیشترین مقدار مربوط به تابستان بود (Masoudi and Gerami, 2017). هدف اصلی این تحقیق توسعه مدلی است که بتواند بین غلظت آلاینده‌ها با پارامترهای هواشناسی ارتباط برقرار کند در این تحقیق از شبکه پرسپترون سه لایه برای پیش‌بینی غلظت آلاینده‌های CO ، PM_{10} و AQI برای اولین بار در تهران در فصول گرم و سرد استفاده شد و در انتها این مدل با مدل رگرسیون خطی مقایسه شد.

۲. مواد و روش‌ها

۲-۱. منطقه مورد مطالعه

کلانشهر تهران، درکوهپایه‌های جنوبی رشته کوه البرز با حدود ۷۰۰ کیلومتر مربع مساحت گسترده شده است. شهرتهران دارای موقعیت خاص جغرافیایی است (اختلاف ارتفاع زیاد در شمال و جنوب آن) و دارای شرایط نامناسب بافت شهری است. در طول جغرافیایی بین ۵۱ درجه و ۲۰ دقیقه و ۵۱ درجه و ۶۱ دقیقه و عرض جغرافیایی بین ۳۵ درجه و ۵۶ دقیقه و ۳۵ درجه و ۸۳ دقیقه، در جنوب



شکل ۱- موقعیت ایستگاههای پایش هوای شهر تهران

جدول ۱- توصیف متغیرهای ورودی برای شبکه عصبی و آنالیز رگرسیون

متغیرهای اصلی	جزئیات متغیرها
آلاینده‌ها	CO: بر حسب پی پی ام (ppm)
	PM ₁₀ : میکروگرم بر متر مکعب (μg/m ³)
پارامترهای هواشناسی	حداکثر درجه حرارت ^۱ : درجه سانتی گراد (°C)
	حداقل درجه حرارت ^۲ : درجه سانتی گراد (°C)
	سرعت باد: متر بر ثانیه (m/s)
	جهت باد ^۳ : درجه
	فشار ^۴
	رطوبت: بر حسب درصد (%)

1- Maximum Temperature 2- Minimum Temperature 3- Direction Wind 4- Pressure

۳-۲. کلیات شبکه عصبی مصنوعی

روش شبکه‌ی عصبی را اولین بار McCulloch و Pitts (۱۹۴۳) ارائه کردند. امروزه کاربردهای بسیاری برای شبکه‌ی عصبی به وجود آمده است و با توجه به نوع کاربرد، ساختار قوانین یادگیری متفاوت است. انواع متفاوتی از شبکه‌ی عصبی وجود دارد که شامل پرسپترون چند لایه (MLP) (García et al., 2017)، شبکه خود سازمان^۴ (SOM)

(Patricia et al.,), (Gulson et al., 2007) (2014) LVQ^۵، هاپفیلد، تاخیر زمانی^۶ (TDNN) (Yang & Shi, 2003)، (RBF (Orr, 1996) شبکه عصبی الهام گرفته از نحوه‌ی کارکرد سیستم-های عصبی زیستی در پردازش داده‌ها برای یادگیری هستند. (Shepherd, 1990). در یک نگاه ساده، مدل یک سلول عصبی، شامل ورودی‌هایی

- 5- Learning vector quantization
- 6- Time delay neural network
- 7- Radial basis function network

4- Self-Organizing Map

لایه اول، بردار ورودی لایه دوم به حساب می آید. به همین ترتیب خروجی لایه دوم، بردار ورودی لایه سوم را تشکیل میدهد. خروجی های لایه سوم پاسخ واقعی شبکه را نشان می دهند (Chelani *et al.*, 2002). در این ساختار، تمام نرونهای یک لایه به تمام نرونهای لایه بعد متصل اند. قاعده یادگیری پرسپترون در دسته قواعد یادگیری نظارت شده قرار میگیرد. در این روش، هنگامیکه ورودی به شبکه اعمال می شود، خروجی آن با هدف مقایسه می گردد، سپس از قواعد یادگیری برای تنظیم وزنها و بایاسها استفاده می شود تا خروجی شبکه را به هدف نزدیک نماید (Fausett, 1994). با توجه به عملکرد مطلوب پرسپترون های چند لایه در این مطالعه از این شبکه ها برای پیش بینی غلظت آلاینده های PM_{10} ، CO و AQI استفاده شده است.

۲-۵. آنالیز رگرسیون خطی

در این تحقیق برای بررسی ارتباط بین پارامترهای هواشناسی و غلظت آلاینده ها از رگرسیون خطی استفاده شد. این روش برای ارتباط خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل مورد استفاده قرار می گیرد. که شکل عمومی آن به شرح زیر می باشد:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon \quad (3)$$

در این فرمول β ضریب رگرسیون بوده و X_i متغیرها هستند درحالی که ε خطای رگرسیون می باشد. (Biancofiore *et al.*, 2015).

۲-۶. شاخص کیفیت هوا (AQI)

شاخص کیفیت هوا، گزارش روزانه کیفیت هواست. توسط قانون هوای پاک برای چهار آلاینده اصلی مونوکسید کربن، ازن، دی اکسید گوگرد، ذرات معلق

است که در نقش سیناپسها انجام وظیفه می کنند. شبکه از یک لایه ورودی و یک لایه خروجی و یک یا چند لایه مخفی که اصطلاحاً مخفی نامیده می شود تشکیل شده اند. زمانیکه ورودی ها از طریق لایه ورودی به شبکه وارد می شود در وزن اتصال بین لایه ورودی ضرب شده و به سلول های لایه بعد منتقل می شوند. در لایه بعد تمام ورودی هایی که به هر نرون داده می شود، با هم جمع می شوند و بعضی اوقات با مقدار ثابتی با نام بایاس به آن اضافه می گردد (Giustolisi *et al.*, 2007). مجموع بدست آمده همان ورودی خالص نرون (h) می باشد که به صورت رابطه ۱ بیان می شود:

$$h_j = \sum_{i=1}^N w_{jxt} + b_j \quad (1)$$

به طوریکه x_t سیگنال ورودی i ام، w_{ij} وزن سیگنال i ام، b_j مقدار بایاس برای نرون j ام و N تعداد نرون های لایه قبل است. ورودی خالص نرون از تابعی به نام تابع فعالیت در نرون مورد نظر می گذرد تا خروجی نرون a بدست آید. این تابع به صورت رابطه ۲ می باشد:

$$a_j = f(h_j) \quad (2)$$

از بین شبکه های مذکور شبکه پرسپترون چند لایه بیشترین کاربرد را برای پیش بینی آلودگی هوا دارد که در این تحقیق از این شبکه استفاده شده است.

۲-۴. شبکه های عصبی پرسپترون چند لایه (MLP)

یکی از ساده ترین و در عین حال کارآمدترین چیدمان های پیشنهادی برای استفاده در مدل سازی عصب های واقعی، مدل پرسپترون چند لایه (MLP) می باشد (Beale & Demuth, 2002). شبکه MLP از چند لایه تشکیل شده است، لایه ورودی، خروجی و لایه یا لایه مخفی که خروجی

میان تابع انتقال^۸ سیگموئید عبور داده شده است (Agirre-Basurko *et al.*, 2006).

$$F(NET) = \frac{1}{1+e^{-net}} \quad (5)$$

برای آموزش و یادگیری شبکه از الگوریتم لونیبرگ مارکواریت (LMA)^۹ استفاده شده است. الگوریتم لونیبرگ - مارکواریت، به دلیل همگرایی سریع تر در آموزش شبکه‌های با اندازه‌ی متوسط، برای استفاده در تحقیق حاضر انتخاب شده است. برای ارزیابی عملکرد مدل از ضریب همبستگی (R^2)^{۱۰} و ریشه میانگین مربعات خطا (RMSE)^{۱۱} استفاده شد. سپس برای مدل‌سازی و کشف رابطه بین پارامترهای هواشناسی (متغیر مستقل) و غلظت آلاینده‌ها (متغیر وابسته) از رگرسیون خطی استفاده شد شکل ۴ و ۵ و برای سنجش شدت رابطه از ضریب همبستگی (R^2) استفاده شد. هر چه ضریب همبستگی به ۱ یا -۱ نزدیکتر باشد، شدت رابطه خطی بین متغیرهای مستقل و وابسته شدیدتر است. البته اگر ضریب همبستگی نزدیک به ۱ باشد جهت تغییرات هر دو متغیر یکسان است که به آن رابطه مستقیم می‌گوییم و اگر ضریب همبستگی به -۱ نزدیک باشد، جهت تغییرات متغیرها معکوس یکدیگر خواهد بود و به آن رابطه عکس می‌گوییم. ولی در هر دو حالت امکان پیش‌بینی مقدار متغیر وابسته برحسب متغیر مستقل وجود دارد. در این تحقیق جهت تغییرات مثبت بود. در انتها نتایج شبکه عصبی در فصول گرم و سرد شکل ۲ و ۳ با رگرسیون خطی در فصول گرم و سرد شکل ۴ و ۵ مقایسه شد.

8- Transfer function

9- Levenberg Marquardt

10- Correlation coefficient

11- Root mean square error

به صورت زیر محاسبه می‌شود (Salvador and Salvador, 2012):

$$I_P = \frac{I_{Hi} - I_{Lo}}{BP_{Hi} - BP_{Lo}} (C_P - BP_{Lo}) + I_{Lo} \quad (4)$$

در این رابطه:

I_P = شاخص کیفیت هوا برای آلاینده p است.

C_P = غلظت اندازه گیری شده برای آلاینده p است.

BP_{Hi} = نقطه شکستی که بزرگتر یا مساوی C_P است.

BP_{Lo} = نقطه شکستی که کوچکتر یا مساوی C_P است.

I_{Hi} = مقدار AQI منطبق با BP_{Hi} .




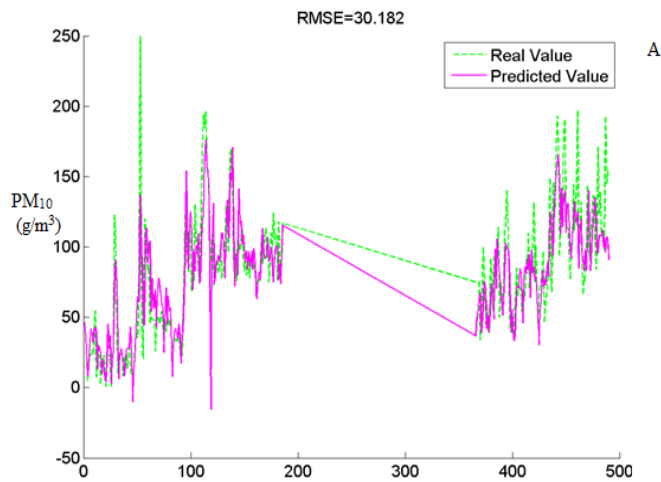
I_{Lo} = مقدار AQI منطبق با BP_{Lo} .

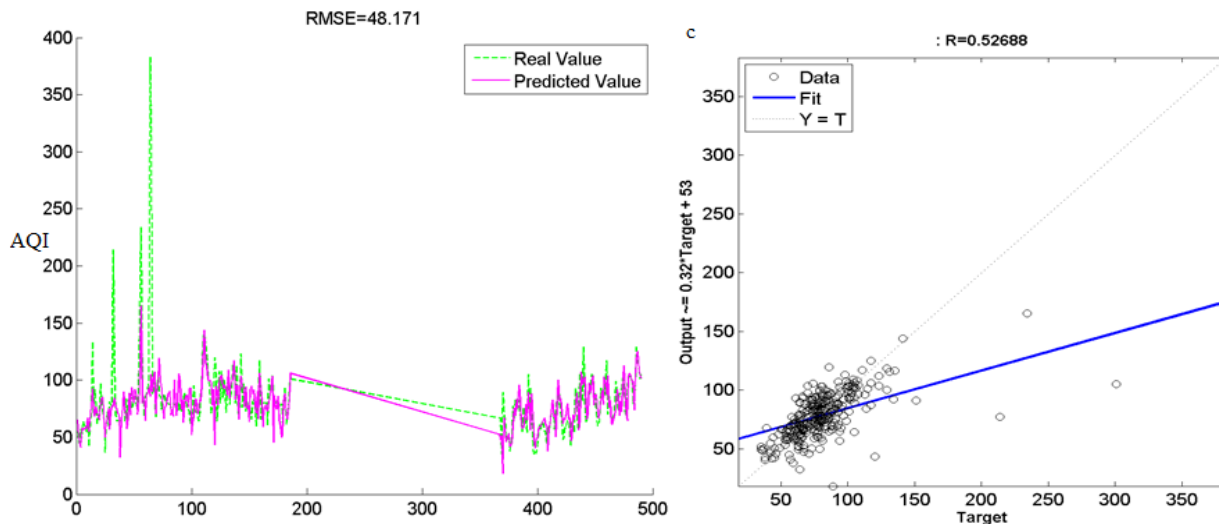
۳. نتایج

غلظت آلاینده‌ها (CO , PM_{10} , AQI) با پارامترهای هواشناسی (رطوبت، جهت باد، سرعت باد، فشار، حداکثر و حداقل درجه حرارت) با شبکه عصبی مصنوعی و رگرسیون خطی برای روز بعد پیش‌بینی شد. برای این منظور معماری شبکه به وسیله‌ی تعداد لایه‌ها، تابع انتقال، الگوریتم یادگیری و تعداد نرون‌ها مشخص می‌شود. تعداد لایه‌ها بستگی به تحقیق مورد نظر دارد، در بیشتر مطالعات از سه لایه‌ی خروجی، ورودی و پنهان استفاده می‌کنند اما زمانی که حجم داده‌ها زیاد باشد تعداد لایه‌ها را افزایش می‌دهند که با افزایش لایه‌های پنهان انجام می‌شود. ولی همچنان که تعداد لایه‌ها افزایش می‌یابد خطا هم افزایش می‌یابد. پارامترهای استفاده شده در پیش‌بینی غلظت آلاینده‌ها و شاخص AQI در جدول ۲ ارائه شده است. در این تحقیق برای کاهش خطا یک شبکه‌ی سه لایه با یک لایه پنهان و با تعداد ۱۰ نرون مدل‌سازی شد. این مجموع از

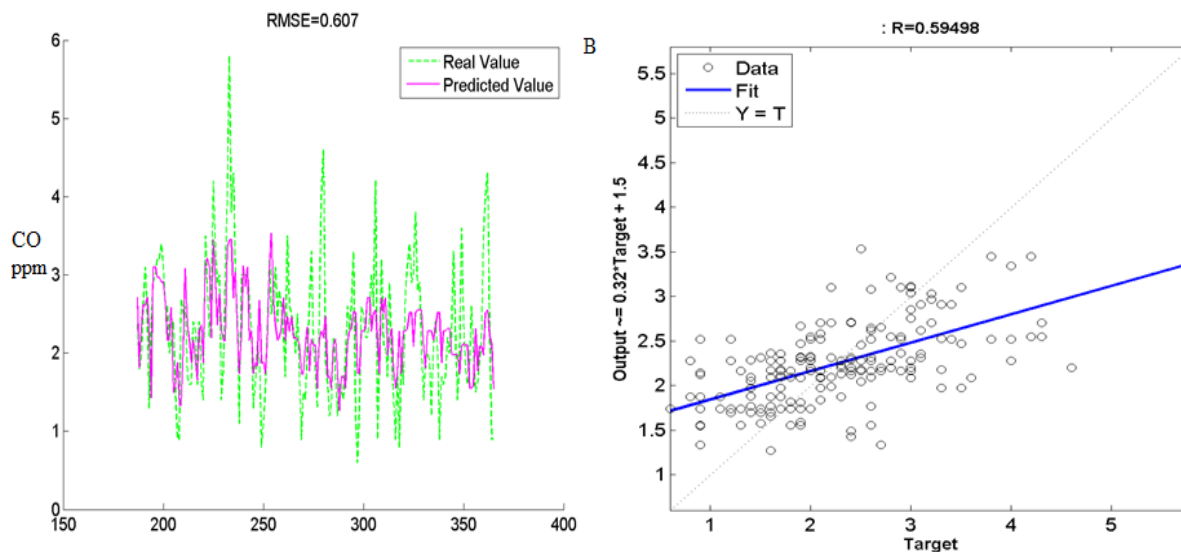
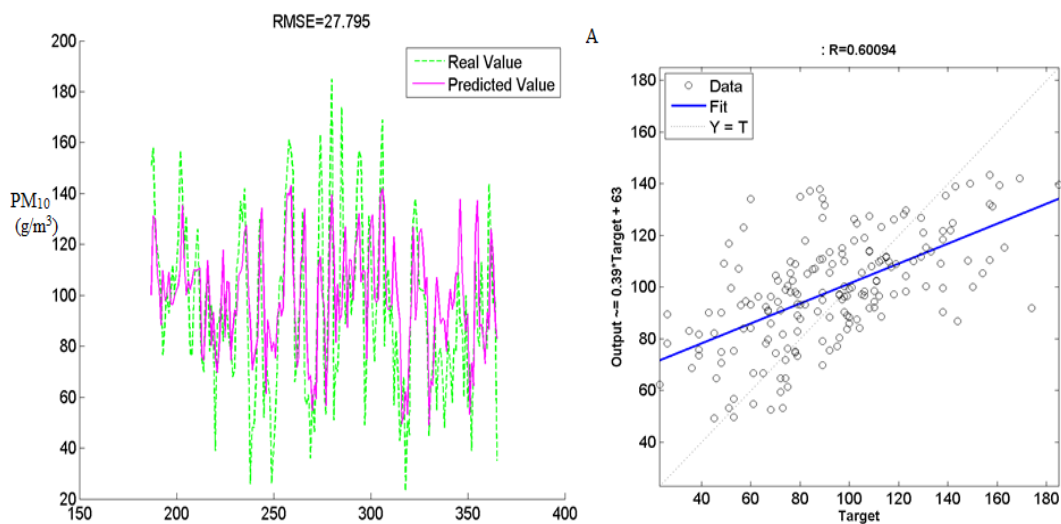
جدول ۲ - پارامترهای استفاده شده در پیش‌بینی غلظت PM_{10} ، CO و AQI با مدل شبکه عصبی مصنوعی

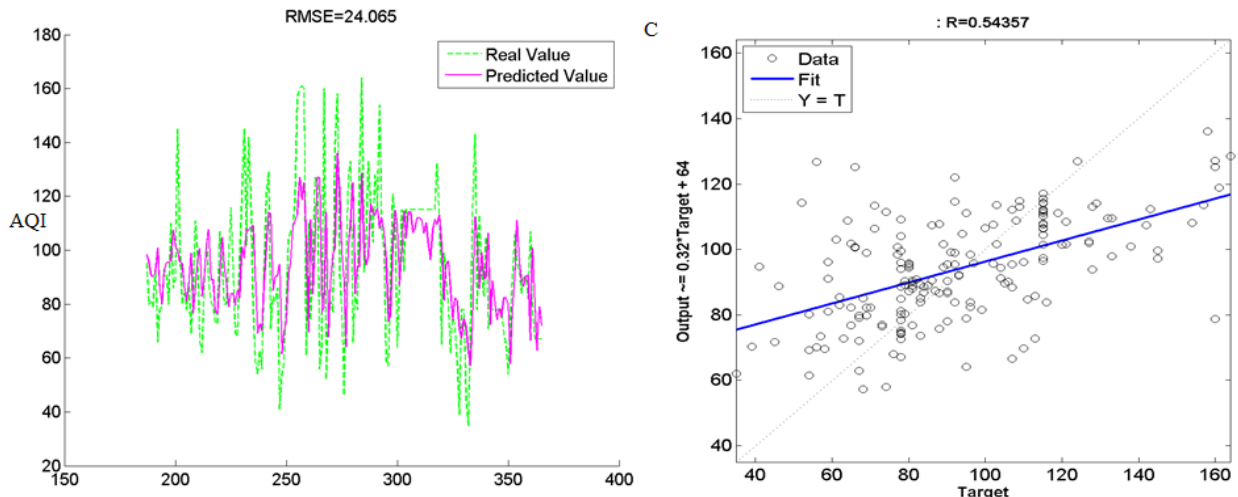
پارامترها	نوع
نوع شبکه	MLP
تعداد نرون در لایه مخفی	۱۰
الگوریتم یادگیری	LM
تابع انتقال	سیگموئید
ضریب همبستگی (R^2)	-
جذر میانگین مجذور خطا (RMSE)	-



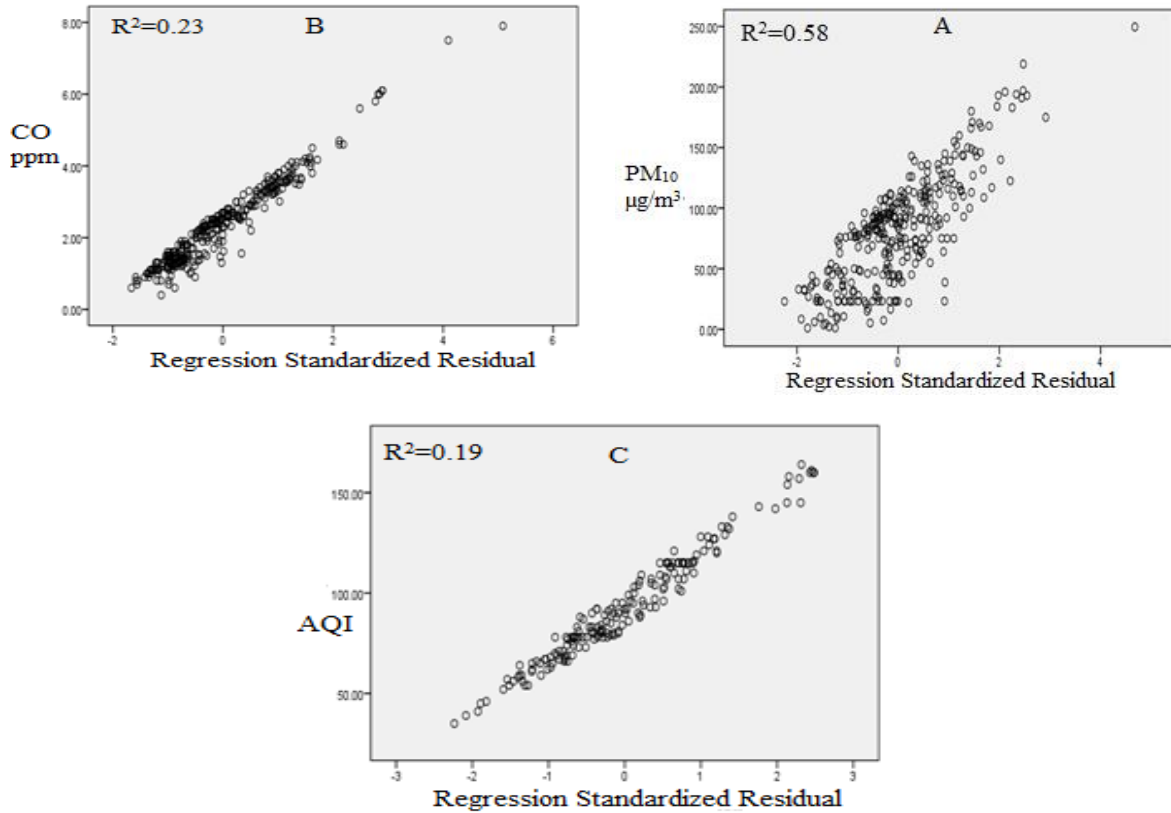


شکل ۲- پیش‌بینی غلظت آلاینده‌های PM_{10} (A)، CO (B) و AQI (C) در فصول گرم (بر مبنای مدل شبکه عصبی)

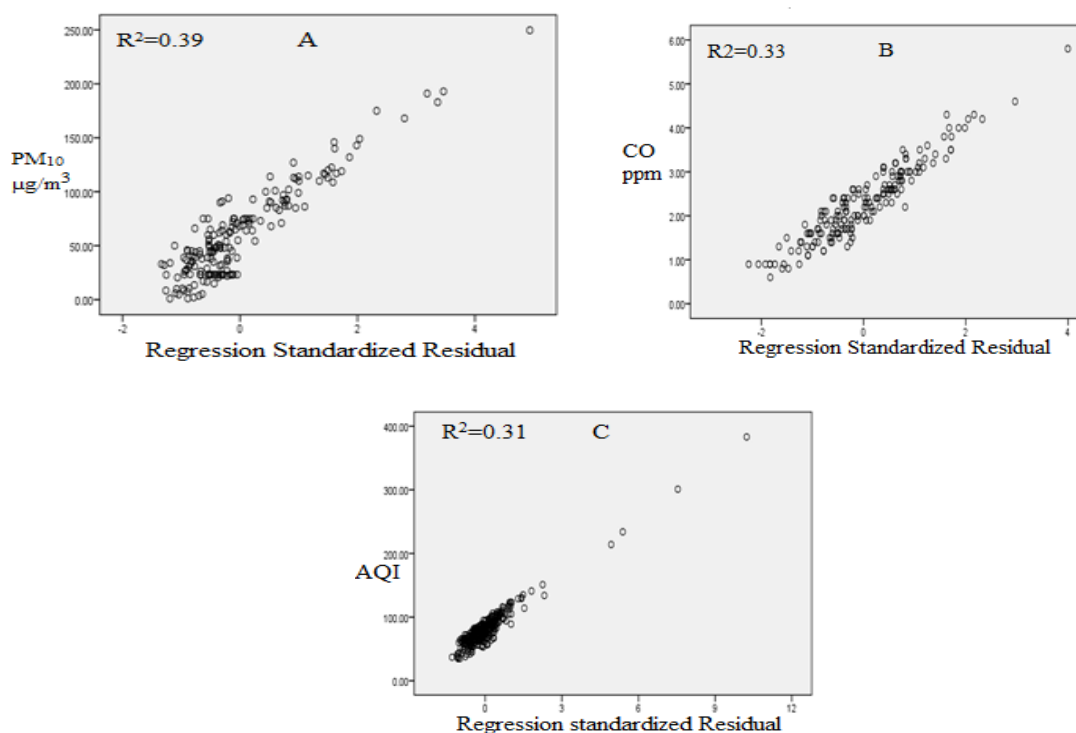




شکل ۳- پیش بینی غلظت آلاینده های PM_{10} (A)، CO (B) و AQI (C) در فصول سرد (بر مبنای مدل شبکه عصبی)



شکل ۴- پیش بینی غلظت آلاینده های PM_{10} (A)، CO (B) و AQI (C) در فصول گرم (بر مبنای رگرسیون خطی)



شکل ۵- پیش‌بینی غلظت آلاینده‌های (A) PM_{10} ، (B) CO و (C) AQI در فصول سرد (بر مبنای رگرسیون خطی)

۴. بحث و نتیجه گیری

بستگی دارد، بلکه تحت تأثیر مختلف آب و هوا و هوا قرار می‌گیرد (Giorgi and Meleux 2007). از این رو غلظت آلاینده‌ها (CO ، PM_{10} ، AQI) با پارامترهای هواشناسی (رطوبت، جهت باد، سرعت باد، فشار، حداکثر و حداقل درجه حرارت) با شبکه عصبی مصنوعی شکل‌های ۳ و ۴ و رگرسیون خطی برای روز بعد پیش‌بینی شد. با توجه به شکل‌های ۲ و ۳ ضریب همبستگی (R^2) و جذر میانگین مجذور خطا (RMSE) برای PM_{10} با مدل شبکه‌ی عصبی در فصول گرم ($R^2=0.83$ ، $RMSE=27.61$) و در فصول سرد ($R^2=0.64$ ، $RMSE=26.57$) آمد و با مدل سازی رگرسیون خطی، ضریب همبستگی در فصول گرم برای این آلاینده ($R^2=0.58$) و در فصول سرد ($R^2=0.39$) بدست آمد، بنابراین در هر دو مدل بیشترین ضریب همبستگی برای آلاینده PM_{10} در فصل گرم می‌باشد. علت وقوع بیشینه PM_{10} در فصل گرم

آلودگی هوای محیط نیز به شدت تحت تاثیر عوامل اقلیمی قرار می‌گیرد، به این دلیل که ترکیبی از فرآیندها و تأثیرات؛ انتشار، حمل و نقل، تحولات شیمیایی و حذف از طریق فرایندهای مرطوب و خشک است (Seinfeld and Pandis 2016). بنابراین عناصر آب و هوا (اقلیم) و محیط زیست در همه اجزاء این فرایندها نقش مهمی ایفا می‌کنند. در مقیاس محلی، انتشار (به عنوان مثال انتشار گرد و غبار) ممکن است به تغییرات آب و هوایی مانند درجه حرارت و رطوبت سطح بستگی داشته باشد؛ فرآیندهای شیمیایی بستگی به درجه حرارت، رطوبت، هوای آفتابی و ابری دارد؛ فرآیند بارش بر رطوبت تاثیر می‌گذارد. همچنین حمل و نقل کوتاه و بلند مدت بستگی به مقدار آشفته‌گی سطح و گردش جوی (در مقیاس سینوپتیک) دارد. این بدان معنی است که توزیع آلاینده‌ها نه تنها به انتشار آن

می‌باشد. افزایش مصرف سوخت‌های فسیلی و همچنین عدم کارکرد صحیح وسایل نقلیه در اثر سردی هوا نیز از دلایل افزایش این گاز محسوب می‌شود. همچنین احتمال وجود پدیده وارونگی هوا در فصل سرد به ویژه زمستان می‌تواند علت دیگری برای ثابت بودن نسبی غلظت مونوکسید کربن در این فصل باشد. همچنین بالا بودن ترافیک شهری و رفت و آمد زیاد به خصوص مدارس در اوایل صبح و عصر می‌تواند موجب ازدیاد غلظت این آلاینده شود. بنابراین وجود بیشینه در فصل سرد می‌تواند بر اثر استفاده از وسایل گرمایشی و وسایل نقلیه در کنار شرایط هواشناسی از قبیل سرما، افزایش فشار هوا، پایداری و وارونگی دما رخ دهد. هر چه درجه حرارت پایین‌تر باشد به خصوص در فصل زمستان از وسایل گرمایشی و سوخت‌های فسیلی بیشتری استفاده می‌شود. افزایش استفاده از این وسایل منجر به افزایش غلظت مونوکسید کربن می‌شود (Mamtimin, 2011). در نهایت ضریب همبستگی و جذر میانگین مجذور مربعات خطا برای AQI با مدل‌سازی شبکه‌ی عصبی در فصول گرم، $R^2=0.50$ ، $RMSE=16.64$ و در فصول سرد، $R^2=0.57$ ، $RMSE=23.70$ بود و با مدل‌سازی رگرسیون خطی، ضریب همبستگی در فصول گرم $R^2=0.31$ و در فصول سرد $R^2=0.19$ بدست آمد. با توجه به اهمیت و نقش پارامترهای هواشناسی در آلودگی هوا می‌توان مدل‌سازی و پیش‌بینی غلظت آلاینده‌ها را برای روزهای بعد در سایر شهرهای ایران به‌کاربرد. همچنین می‌توان از شاخص‌های ناپایداری که در بحث اقلیم بسیار مهم می‌باشد مانند شاخص همرفتی، شاخص تی و سایر شاخص‌ها استفاده کرد و نقش آن را بر روی آلودگی بررسی کرد.

می‌تواند ناشی از کاهش بارش، ناپایداری جوی در صحرا های عربستان، عراق، کویت و سوریه، خشکسالی، کاهش میزان بارندگی، رطوبت هوا و همچنین اثر وارونگی دمای سطحی دانست (Najafpoor et al., 2015). بر اساس نتایج بررسی‌های آماری بیشینه غلظت آلاینده در رطوبت نسبی کم رخ داده است. به بیانی دیگر افزایش خشکی هوا همراه با افزایش مقدار آلاینده بوده است. افزایش رطوبت نسبی هوا اگر همراه با پدیده بارش باشد، عمل شستشو می‌تواند باعث کاهش آلاینده‌ی هوا شود. بنابراین این موضوع یکی از عوامل اصلی کاهش مقدار آلاینده در هنگام رطوبت نسبی زیاد و بارندگی است (Demuzere et al., 2009). در مطالعه‌ای که توسط شاریه پور با عنوان بررسی تغییرات فصلی آلاینده های هوا در سال ۱۳۸۸ در تهران انجام گرفت، نتایج نشان داد که آلاینده ذرات معلق دارای دو پیک غلظت یکی در تابستان و دیگری در زمستان می‌باشد (Shariepour, 2010). در مطالعه دیگری که توسط Park و ju (۲۰۰۵) در کره صورت گرفت، بیشترین غلظت ازن و ذرات معلق در فصل گرم و سرد سال و برای مونوکسیدکربن در فصل زمستان است که با نتایج حاصل از مطالعه حاضر همخوانی دارد (Gratani, 2005). ضریب همبستگی (R^2) و جذر میانگین مجذور خطا (RMSE) برای CO با مدل شبکه عصبی در فصول گرم ($R^2=0.57$)، $RMSE=0.74$ و در فصول سرد ($R^2=0.67$)، $RMSE=0.61$ بدست آمد و با مدل‌سازی رگرسیون خطی، ضریب همبستگی در فصول گرم برای این آلاینده ($R^2=0.23$) و در فصول سرد ($R^2=0.33$) بدست آمد. بنابراین در هر دو مدل بیشترین ضریب همبستگی برای آلاینده CO در فصول سرد

References

- Agirre-Basurko, E., G. Ibarra-Berastegi, and I Madariaga. 2006. Regression and Multilayer Perceptron-Based Models to Forecast Hourly O₃ and NO₂ Levels in the Bilbao Area. In *Environmental Modelling and Software*, 21(4): 430–46.
- Anderson, H. R. 2009. Air Pollution and Mortality: A History. *Atmospheric Environment* 43: 142–52.
- Biancofiore, F., Verdecchia, M.C., Piero, T., Barbara, A., Eleonora, B., Marcella, B., Sebastiano, D., Tommaso, S., Colangeli, C. 2015. Analysis of Surface Ozone Using a Recurrent Neural Network ed. Edward A Keller. *Science of the Total Environment* 514(4): 379–87.
- Brian, G., Michae, K., Bruce, D., David, C., Karen, M., Michael, D. 2007. Comparison of Lead Isotopes with Source Apportionment Models, Including SOM, for Air Particulates. *Science of The Total Environment* 381(1–3): 169–79.
- Chelani, A.B., Chalapati Rao, C.V., Phadke, K.M., Hasan, M.Z. 2002. Prediction of Sulphur Dioxide Concentration Using Artificial Neural Networks. *Environmental Modelling & Software* 17(2): 159–66.
- Demuth, H., Beale, M. 2002. *Neural Network Toolbox Users Guide*. Copyright 1992-2002, by the Math Works, Inc, Version 4, PP, 840.
- Demuzere, M., Trigo, R.M., Vila-Guerau de Arellano, J., van Lipzig, N.P.M. 2009. The Impact of Weather and Atmospheric Circulation on O₃ and PM₁₀ Levels at a Rural Mid-latitude Site. *Atmospheric Chemistry and Physics* 9: 2695–2714.
- Demuzere, M., Trigo, R. M., Vila-Guerau de Arellano, J., van Lipzig, N. P. M. 2009. The impact of weather and atmospheric circulation on O₃ and PM₁₀ levels at a rural mid-latitude site. *Atmospheric Chemistry and Physics*. 9. 2695–2714.
- Fausett, L. 1994. *Fundamental of Neural Network: Architecture, Algorithms, and Applications*, Prentice. Hall Press.
- Giustolisi, O., Doglioni, A., Savic, D. A., Webb, B. W. 2007. A Multi-Model Approach to Analysis of Environmental Phenomena. *Environmental Modelling and Software* 22: 674–82.
- Gratani L, Varone L. 2005. Daily and Seasonal Variation of CO₂ in the City of Rome in Relationship with the Traffic Volume. *Atmospheric Environment* 39: 2619–2624.
- García, P.J., Sánche Lasherasa, F., García-Gonzaloo, E., de Cos Juez, F.J. 2017. PM₁₀ Concentration Forecasting in the Metropolitan Area of Oviedo (Northern Spain) Using Models Based on SVM, MLP, VARMA and ARIMA: A Case Study. *Science of The Total Environment*, 621: 753–61.
- Giorgi, F. and Meleux, F. 2007. Modelling the regional effects of climate change on air quality, *Comp. Rend. Geosci., researchgate*, 339 (11), 721–733.
- Harrison, JI., Ping, SHI., ROY, M. 1997. Regression modelling of hourly NO_x and NO₂ concentration in urban air in London. *Atmospheric Environmen*, 31(24): 4081–94.
- Jian, L., Zhao, Y., Zhu, YP., ZhangM, B., Bertolatti, D. 2012. An Application of ARIMA Model to Predict Submicron Particle Concentrations from Meteorological Factors at a Busy Roadside in Hangzhou, China.” *Science Total Environment*, 426: 336–345.
- Jiang, D., Zhang, D., Hu, Y., Zeng, X., Tan, Y., Jianguo, T., Demin, S. 2004. Progress in Developing an ANN Model for Air Pollution Index Forecast. *Atmospheric Environment*, 38(40 SPEC.ISS.): 7055–64.

- Karaca, F., Nikov, A., Alagha, O. 2006. NN-Airpol: A Neural-Networks-Based Method for Air Pollution Evaluation and Control. *International Journal of Environment and Pollution*, 28(3/4): 310–25.
- Mamtimin, B., Meixner, FX. 2011. Air Pollution and Meteorological Processes in the Growing Dryland City of Urumqi (Xinjiang, China). *Science of the Total Environment* 2011, 409(7): 199–226.
- Masoudi, M. and Gerami, S. 2017. Status of CO as an air pollutant and its prediction, using meteorological parameters in Esfahan, Iran. *Pollution*. 3 (4). 527-537
- McCulloch, W.S., Pitts, W. 1943. A Logical Calculus of the Ideas Imminent in Nervous Activity. *B.Math. Biophys*, 8: 115–33.
- McKendry, I.G. 2015. Evaluation of Artificial Neural Networks for Fine Particulate Pollution (PM10 and PM2.5) Forecasting.” *Journal of the Air & Waste Management Association* 52(9): 1096–1101.
- Mohammadhassani, J., Dadvand, A., Khalilarya, Sh., Solimanpur, M. 2015. Prediction and Reduction of Diesel Engine Emissions Using a Combined ANN–ACO Method. *Applied Soft Computing*, 34: 139–50.
- Nejadkoorki, F and and Baroutian, S. 2012. Forecasting Extreme PM10 Concentrations Using Artificial Neural Networks. *Statewide Agricultural Land Use Baseline* 2015, 1(1): 277–84.
- Orr, Mark J.L. 1996. Introduction to Radial Basis Function Networks. *Time*: 1–67.
- Park, S., Kim, M., Namgung, H.G., Kim, K. T., Cho, K. H., Kwon, S.B. 2018. Predicting PM10 concentration in Seoul Metropolitan Subway Stations Using Artificial Neural Network (ANN). *Journal of Hazardous Materials* 341: 75–82.
- Patricia, M., Jonathan, A., Fevrier, V., Oscar, C. 2014. A New Neural Network Model Based on the LVQ Algorithm for Multi-Class Classification of Arrhythmias. *Information Sciences*, 279: 483–97.
- Salvador, s and Salvador, El. 2012. Air Quality Index (AQI). 16-17.
- Shariepour, Z. 2010. Seasonal and Daily Variation of Air Pollutants and Their Relation to Meteorological Parameters. *Earth and Space Physics*, 35(2): 119–137 (In Persian).
- Sharma, N., Chaudhry, K., Rao, CC. 2005. Vehicular Pollution Modeling Using Artificial Neural Network Technique: A Review. *Journal of Scientific and Industrial research*. 64(9): 637.
- Shepherd, G.M. 1990. *The Synaptic Organization of the Brain*,. third edition, Oxford university press.
- Shi, Dan., Hongjian, Z., Liming, Y. 2003. Time-Delay Neural Network for the Prediction of Carbonation Tower ' s Temperature. 52(4): 1125–28.
- Seinfeld, J. H. and Pandis, S. N. 1998. *Atmospheric chemistry and physics from air pollution to climate change*, New York, John Wiley & Sons, Inc, 1113 pp.
- Yi, J and Prybutok, V.R. 1996. A Neural Network Model Forecasting for Prediction of Daily Maximum Ozone Concentration in an Industrialized Urban Area. *Environmental Pollution*, 92(3): 349–57.
- Zannetti, P. 1990. *Air Pollution Modeling, Theories, Computational Methods and Software's*, Computational Mechanics Publication.
- Ziomas, I. C., Melas, D., Zerefos, C.S., Bais, A.F., Paliatsos, A.G. 1995. Forecasting Peak Pollutant Levels from Meteorological Variables. *Atmospheric Environment* , 29(24): 3703–11.