

پیش بینی غلظت آلاینده منوکسید کربن در کلان شهر تهران با استفاده از شبکه های

عصبی مصنوعی

حمیدرضا جدی^۱

رحیم علی عباسپور^{۲*}

abaspour@ut.ac.ir

مینا خالصیان^۳

سید کاظم علوی پناه^۴

تاریخ پذیرش: ۱۳۹۴/۱۰/۰۷

تاریخ دریافت: ۱۳۹۳/۱۲/۰۶

چکیده

زمینه و هدف: راهکارهای متعددی برای کنترل آلودگی هوا وجود دارد که یکی از آنها پیش بینی میزان آن است. هدف از این تحقیق ارایه یک مدل شبکه عصبی مصنوعی با ساختار چندلایه، برای آلاینده CO در شهر تهران برای پیش بینی ۲۴ ساعت آینده آن می باشد. **روش بررسی:** از مشخصه های سرعت باد، جهت باد، دما، رطوبت نسبی و فشار هوا به عنوان داده های هواشناسی و از غلظت منوکسید کربن به عنوان پارامتر آلودگی هوا به منظور پیش بینی مقدار آلاینده CO در روز آتی (۲۴ ساعت آینده) استفاده شد. جهت حذف نویز داده ها، در مرحله پیش پردازش داده ها، از دو روش تبدیل موجک و تعیین حد آستانه به کمک توزیع نرمال استفاده گردید. **یافته ها:** نتایج حاصل از شاخص های آماری ضریب همبستگی، شاخص توافق، دقت پیش بینی و جذر میانگین مربعات خطا برای مدل ۱ با داده های تکراری به ترتیب ۰/۹۱۵، ۰/۸۴۸ و ۰/۱۰۱۲ و برای مدل ۲ با داده های تکراری به ترتیب ۰/۹۵۷۲، ۰/۹۷۸، ۰/۹۶۳ و ۰/۰۳۸۵ می باشد.

نتیجه گیری: نتایج حاصل نشان می دهد توافق خوبی بین داده های اصلی و داده های پیش بینی شده توسط مدل ها وجود دارد و مدل های ارایه شده در پیش بینی آلودگی هوا از قابلیت بالایی برخوردارند.

واژه های کلیدی: پیش بینی آلودگی هوا، شبکه عصبی مصنوعی، آلاینده منواکسید کربن.

۱- کارشناس ارشد گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران.

۲- (مسوول مکاتبات): استادیار، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، پردیس دانشکده های فنی، دانشگاه تهران، تهران، ایران.

۳- دکترای GIS، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، پردیس دانشکده های فنی، دانشگاه تهران، تهران، ایران.

۴- استاد گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران.

Prediction of Carbon Monoxide Concentration in Tehran using Artificial Neural Networks

Hamid Reza Jeddi¹

Rahim Ali Abbaspour^{2*}

abaspour@ut.ac.ir

Mina Khalesian³

Seyed Kazem Alavipanah⁴

Abstract

Background and Objective: Nowadays, air pollution is one of the most important problems almost all over the world. There are many strategies to control and reduce air pollution, one of which is prediction of this event and getting ready to deal with the negative effects of it. The aim of this study is to provide a multi-layer structure of artificial neural networks (ANN) for predicting of carbon monoxide pollution at subsequent 24 hours in Tehran metropolis.

Method: To predict the amount of CO emissions in near future (subsequent 24 hours), wind speed and direction, temperature, relative humidity, and barometric pressure characteristics are used as meteorological data, and concentration of carbon monoxide is considered as a pollution parameter. To eliminate the noise of data, wavelets transform method and determining the threshold with normal distribution are used before training the ANN. Finally, two neural networks as two general models are proposed and used for modelling.

Findings: The results show that the correlation coefficient, index of agreement, accuracy of prediction, and root mean square error for model no. 1 with duplicate data are 0.9012, 0.915, 0.848, and 0.1012 and for model no. 2 with duplicate data are 0.9572, 0.978, 0.963, and 0.0385 respectively. Moreover, the results of listed parameters for model no. 1 with new data are 0.9086, 0.89, 0.885, and 0.0825 and for model No. 2 with new data are 0.8678, 0.928, 0.932, and 0.1163 respectively.

Conclusion: Results showed that there is a good agreement between predicted and observed values, hence the proposed models have a high potential for air pollution prediction.

Keywords: Prediction of air pollution, Artificial Neural Network (ANN), Carbon Oxide (CO).

1- MSc in GIS/RS, Department of GIS/RS, Faculty of Geography, University of Tehran, Tehran ,Iran.

2- Assistant Professor, Faculty of Surveying and Geospatial information engineering, College of Engineering, University of Tehran, Tehran ,Iran.* (*Corresponding Author*)

3- PhD Faculty of Surveying and Geospatial Information Engineering, College of Engineering, University of Tehran, Tehran ,Iran.

4- Professor Department of GIS/RS, Faculty of Geography, University of Tehran, Tehran , Iran.

مقدمه

میزان آلاینده NO_x در شهر تهران پرداخت. به این منظور از آمار غلظت گازهای آلاینده هوای ثبت شده توسط حس‌گرهای نصب شده در ایستگاه بازار در سال‌های ۱۳۸۱ تا ۱۳۸۶ و از مدل اتورگرسیون و سری‌های زمانی جهت تعیین ورودی‌های شبکه عصبی استفاده شد و بر اساس این مدل غلظت گاز در زمان جاری به غلظت گازهای ۷ روز گذشته وابسته بود. نتایج این بررسی نشان داد که مدل‌های ارایه شده توانایی چشم‌گیری در پیش‌بینی میزان آلودگی هوای شهر تهران دارند (۸). نژادکردی و همکاران (۲۰۱۲) در تحقیقی که بر روی شهر تهران انجام دادند به پیش‌بینی حداکثر غلظت PM_{10} در ۲۴ ساعت آتی پرداختند. به این منظور از داده‌های هواشناسی و غلظت آلاینده‌ها به عنوان پارامترهای ورودی شبکه عصبی پس انتشار خطا استفاده شد. نتایج پیش‌بینی PM_{10} در همه ایستگاه‌های مورد مطالعه شاخص توافق بیش از ۰.۸۳ را نشان داد (۹). صدرموسوی (۱۳۸۷) از شبکه‌های عصبی مصنوعی برای پیش‌بینی غلظت CO در کلان‌شهر تبریز استفاده نمود. نتایج حاصل بیانگر آنست که استقرار مراکز بزرگ صنعتی در غرب و جنوب غرب شهر تبریز مهم‌ترین منبع آلودگی هوا است (۱۰). در بین عمده‌ترین منابع آلودگی هوا، منوکسیدکربن، به دلیل تأثیر قابل توجه بر سلامت انسان و گسترش روز افزون استفاده از سوخت‌های فسیلی مخصوصاً در کلان‌شهرها، به‌عنوان یکی از مهم‌ترین آلاینده‌های هوا به شمار می‌رود (۱۱). اکثر مطالعات انجام گرفته در زمینه بررسی شاخص‌های کیفیت هوا، این گاز سمی را یکی از آلاینده‌های مهم در پایین بودن کیفیت هوا در روزهای غیربهداشتی معرفی کرده‌اند (۱۲، ۱۳، ۱۴ و ۱۵). بر این اساس پژوهش پیش‌رو سعی در ارایه مدلی جهت پیش‌بینی غلظت آلاینده CO در هوای شهر تهران دارد تا بتوان به کمک آن راهکارهای مناسبی را به فراخور زمان و شرایط موجود در راستای کنترل آلودگی هوا ارایه و اجرا نمود.

مواد و روش‌ها

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی سیستم‌های محاسباتی هستند که برای یادگیری ماشینی در جهت پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده ایجاد شده‌اند (۱۶). ایده‌ی اصلی این گونه شبکه‌ها الهام‌گرفته از نحوه کارکرد سیستم عصبی زیستی در

امروزه آلودگی هوا یکی از مهم‌ترین مشکلات جوامع بشری است. حجم این آلودگی به حدی است که خود پالایی نتوانسته از شدت آن جلوگیری نماید و این مساله را به یکی از مباحث مطرح زیست محیطی در دهه‌های اخیر تبدیل کرده است (۱). یکی از راهکارهای کنترل آلودگی هوا پیش‌بینی آن است. مدل‌ها، الگوریتم‌ها و روش‌های متعددی به منظور پیش‌بینی آلودگی هوا گسترش یافته‌اند و هرکدام دارای نقاط قوت و ضعف مخصوص به خود می‌باشند (۲، ۳ و ۴). یکی از روش‌هایی که به منظور پیش‌بینی آلودگی هوا مورد تأکید محققان بوده است، استفاده از شبکه‌های عصبی مصنوعی می‌باشد. تاکنون تحقیقات زیادی با استفاده از شبکه‌های عصبی مصنوعی در زمینه پیش‌بینی آلودگی هوا در داخل و خارج از کشور صورت گرفته است. Ibarra-Berastegi (۲۰۰۸) در تحقیقی به منظور پیش‌بینی کوتاه مدت آلودگی هوا در کشور اسپانیا انجام دادند، از داده‌های آلودگی، ترافیک و داده‌های هواشناسی به منظور ورودی شبکه عصبی مصنوعی استفاده نمودند. مقایسه مقادیر به‌دست آمده از مدل شبیه‌سازی شده با مقادیر واقعی نشان داد که مدل شبکه‌های عصبی مصنوعی ابرازی قدرتمند به منظور شبیه‌سازی پارامترهای آلودگی هوا بوده و ارزش‌های شبیه‌سازی شده توسط مدل از توافق بالایی با مقادیر مشاهده شده برخوردارند (۵). Ul-Saufie (۲۰۱۱) از دو مدل رگرسیون خطی چندگانه و شبکه عصبی پس انتشار خطا به منظور پیش‌بینی آلودگی هوا در کشور مالزی استفاده کرد و نتایج به‌دست آمده از مقایسه آماری مقادیر دقت پیش‌بینی، شاخص توافق^۱، ضریب تشخیص^۲، خطای مطلق نرمال شده^۳ و خطای RMSE، نشان داد مدل شبکه عصبی در مقایسه با مدل رگرسیون خطی چندگانه از قابلیت بالاتری در پیش‌بینی آلودگی هوا برخوردار است (۶). Tecer (۲۰۰۷) به منظور پیش‌بینی مقدار غلظت SO_2 و PM از مدل شبکه‌های عصبی مصنوعی استفاده نمود و نتایج نشان داد که مدل شبکه‌های عصبی قابلیت بالایی در پیش‌بینی آلودگی هوا دارند به طوری که مقادیر حاصل از مدل همبستگی بالایی با مقادیر به‌دست آمده از ایستگاه‌های سنجش آلودگی هوا دارند (۷). بوداقپور (۱۳۹۰)، در تحقیقی به پیش‌بینی

1-Index of agreement

2-Coefficient of determination

3-Normalized absolute error

در مقایسه این مدل با یک نرون بیولوژیکی، W معادل شدت سیناپس، مجموعه‌ی جمع‌کننده و تابع محرک معادل هسته سلول و a معادل سیگنال گذرنده از اکسون است. خروجی نرون با معادله (۱) تعریف می‌شود:

$$a = \mathcal{F}(W\mathcal{P} + b) \quad (1)$$


پارامترهای a و \mathcal{P} به ترتیب خروجی و ورودی نرون هستند. میزان تاثیر \mathcal{P} بر روی a به وسیله W تعیین می‌شود. \mathcal{F} تابع محرک (تابع تبدیل) که می‌تواند خطی یا غیر خطی باشد و b جمله بایاس است. پارامترهای W و b قابل تنظیم هستند و تابع محرک \mathcal{F} نیز توسط طراح انتخاب می‌شود (۱۶).

دو یا چند نرون می‌توانند با هم در قالب یک لایه ترکیب شوند. در یک شبکه چند لایه، هر لایه ماتریس وزن (W) ویژه خود، بردار بایاس (b) خود، یک بردار ورودی (n) مربوط به خود و یک بردار خروجی (a) ویژه خود را دارد (۱۹). هرچند نحوه مدل کردن نرون جزء نکات اصلی در کارایی شبکه عصبی می‌باشد، اما نحوه برقراری اتصالات و چیدمان (توپولوژی) شبکه نیز عامل بسیار مهم و اثرگذاری است. یکی از کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی، مدل پرسپترون چندلایه یا به اختصار MLP می‌باشد که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است (۱۹). در این ساختار، تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصلند (شکل ۳). این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و سلول‌های عصبی، که اغلب تعداد آن‌ها زیاد نیست، یک نگاشت غیر خطی را با دقت دلخواه انجام دهند (۱۹). قاعده یادگیری پرسپترون در دسته قواعد یادگیری نظارت شده قرار می‌گیرد. در این روش، هنگامی که ورودی به شبکه اعمال می‌شود، خروجی آن با هدف مقایسه می‌گردد، سپس از قواعد یادگیری برای تنظیم وزن‌ها و بایاس‌ها استفاده می‌شود تا خروجی شبکه را به هدف نزدیک نماید (۱۸).

توپولوژی شبکه عصبی با تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، الگوریتم یادگیری و تابع انتقال در شبکه تعیین می‌گردد. بهینه سازی توپولوژی شبکه عصبی گام مهمی در مدل‌سازی شبکه به شمار می‌آید. روند طراحی شبکه شامل مراحل زیر است (۲۰):

۱. تهیه و آماده سازی بردارهای ورودی و خروجی
۲. گزینش تابع انتقال
۳. گزینش ساختمان و ترکیب شبکه


پردازش داده‌ها برای یادگیری است. عنصر اصلی این ایده، ایجاد ساختارهایی جدید برای سامانه پردازش اطلاعات است. با استفاده از برنامه‌نویسی رایانه‌ای می‌توان ساختار داده‌ای طراحی کرد که همانند یک نرون عمل نماید و سپس با ایجاد شبکه‌ای از این نرون‌های مصنوعی به هم پیوسته، ایجاد یک الگوریتم آموزشی برای شبکه و اعمال این الگوریتم به شبکه، آن را آموزش داد. این شبکه‌ها برای تخمین و تقریب کارایی بالایی از خود نشان داده‌اند (۱۷). نرون‌ها ساده‌ترین واحد ساختاری سیستم‌های عصبی هستند (شکل ۱). نرون‌ها از سه قسمت اصلی تشکیل شده‌اند: ۱- بدنه سلول، ۲- دندریت، ۳- اکسون که دو قسمت اخیر عناصر ارتباطی نرون هستند (۱۸).



شکل ۱- ساختار یک نرون طبیعی (۱۷)

Figure 1- Structure of a natural neuron (17)

یک نرون مصنوعی مدلی محاسباتی است که از نرون‌های عصبی واقعی انسان الهام گرفته است (۱۹). در یک نگاه ساده، مدل یک سلول عصبی مصنوعی باید شامل ورودی‌هایی باشد که در نقش سیناپس انجام وظیفه کنند. این ورودی‌ها در وزن‌هایی ضرب می‌شوند تا قدرت سیگنال را تعیین کنند. نهایتاً یک عملگر ریاضی تصمیم‌گیری می‌کند که آیا نرون فعال شود یا خیر و اگر جواب مثبت باشد، میزان خروجی را مشخص می‌سازد (۱۷). شکل (۲) مدل ریاضی یک نرون را نشان می‌دهد.



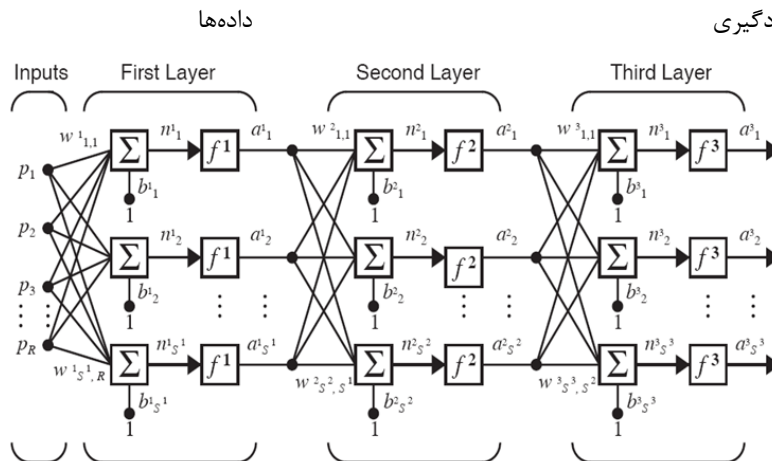
شکل ۲- مدل ریاضی سلول عصبی با چندورودی (۱۷)

Figure 2- Mathematical model of a neural cell with multiple input (17)

۴. گزینش وزن‌های تصادفی

۶. تهیه مجموعه آزمون و پیش‌بینی یا مجموعه تایید از

۵. گزینش روند یادگیری



شکل ۳- ساختار شبکه عصبی چند لایه (۱۷)

Figure 3-Structure of a multilayer neural network

منطقه مورد مطالعه


کلان‌شهر تهران، در کوهپایه‌های جنوبی رشته‌کوه البرز با حدود ۷۰۰ کیلومتر مربع مساحت گسترده شده‌است. شهر تهران دارای موقعیت خاص جغرافیایی است (اختلاف ارتفاع زیاد در شمال و جنوب آن) و دارای شرایط نامناسب بافت شهری است. وسائط نقلیه بسیار زیادی در طول شبانه‌روز در آن به فعالیت مشغولند و بادهای غربی در تمام طول سال دود کارخانجات و سایر عوامل آلوده‌کننده 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. چنین گفته می‌شود که به‌طور کلی مهم‌ترین منابع تولید آلاینده‌ها اشتعال سوخت‌های فسیلی می‌باشد.

ایستگاه‌های سنجش و پایش آلودگی هوا

سازمان محیط زیست و مرکز کنترل کیفیت آلودگی شهر تهران نهادهایی هستند که به بررسی و پایش آلودگی در شهر تهران می‌پردازند. در حال حاضر ۱۹ ایستگاه سنجش آلودگی وابسته به سازمان محیط زیست در شهر تهران فعال هستند (شکل ۴). هر چند این ایستگاه‌ها به صورت پیوسته به اندازه‌گیری و ثبت آلاینده‌ها می‌پردازند، با این حال اغلب به دلیل نقص فنی دستگاه‌های ثبت آلودگی، وجود گپ و شکاف در داده‌ها اجتناب ناپذیر بوده و در بیشتر داده‌های ارایه شده به چشم می‌خورد. در این بررسی نیز با توجه به وجود شکاف در بین داده‌های موجود در تمامی ایستگاه‌های پایش آلودگی، از اطلاعات ثبت شده در ایستگاه پایش آلودگی آزادی واقع در میدان آزادی، با عرض جغرافیایی ۳۵ درجه و ۴۲ دقیقه و ۱۶ ثانیه شمالی و طول جغرافیایی ۵۱ درجه و ۲۰ دقیقه و ۱۳ ثانیه شرقی، که دارای کمترین داده‌ی از دست رفته در طول سال‌های ۲۰۰۸ و ۲۰۰۹ در مقایسه با سایر ایستگاه‌ها بود استفاده شده است (شکل ۴).

پیش پردازش و آماده‌سازی داده‌ها

باتوجه به این‌که یکی از مسایل مهم در بحث شبکه‌های عصبی مصنوعی، تهیه داده‌های اولیه برای آموزش شبکه می‌باشد و توانایی شبکه عصبی در پاسخ به مسایل جدید تا حد زیادی به داده‌های اولیه بستگی دارد، لازم است به بررسی، جمع‌آوری، اندازه‌گیری و محاسبه ورودی‌های شبکه عصبی پرداخته شود تا



شکل ۴- موقعیت تعدادی از ایستگاه‌های پایش آلودگی هوا

شهر تهران

Figure 4- Position for some of the air pollution monitoring stations in Tehran

پارامترهای ورودی در جهت آموزش شبکه عصبی استفاده شدند.

- متوسط غلظت روزانه داده‌های ساعتی ثبت شده ایستگاه آزادی در دوره زمانی زمستان ۱۳۸۹ (۲۱ دسامبر ۲۰۱۰ تا ۲۰ مارس ۲۰۱۱) که در روند آموزش شبکه نقشی نداشته‌اند و به منظور ارزیابی دقت شبکه در امر پیش‌بینی استفاده شده است. با توجه به این که هدف این مطالعه پیش‌بینی روزانه میزان تغییرات غلظت مونوکسیدکربن است، لذا از متوسط غلظت ساعتی ثبت شده به‌عنوان غلظت روزانه استفاده شد. جدول (۱) پارامترهای ورودی شبکه عصبی مصنوعی را نشان می‌دهد.

در مراحل بعدی با استفاده از این داده‌ها به آموزش و آزمایش شبکه‌های عصبی گوناگون پرداخته و بهترین شبکه برگزیده شود. در این بررسی به عنوان مشخصه‌های ورودی شبکه عصبی از میانگین روزانه داده‌های آب و هوایی شامل سرعت باد، رطوبت نسبی، جهت باد، دما و فشارها و داده‌های آلودگی هوا (غلظت آلاینده مونوکسیدکربن) استفاده گردید. به این منظور کل داده‌های موجود به دو گروه تقسیم شدند:

- متوسط غلظت روزانه داده‌های ساعتی ثبت شده ایستگاه آزادی در دوره زمانی سال‌های ۲۰۰۸ و ۲۰۰۹ که به عنوان


جدول ۱- پارامترهای ورودی مدل شبکه عصبی مصنوعی

Table 1- Input parameters to artificial neural network

پارامتر	میانگین	کمینه	بیشینه	انحراف معیار
مونوکسید کربن (ppm)	۵/۲۲۷۰۰	۱/۷۰۳۷۰۸	۵/۵۰۹۴۵۸	۲/۰۸۹۱۵۴
رطوبت نسبی (%RH)	۳۶/۷۸۳۹۹	۹/۹۹۴۷۵	۸۹/۸۵۲۵	۱۷/۴۶۸۳۲
فشار هوا (mBar)	۸۹۸/۹۲۱۱	۷۱۷/۹۵۶۵	۱۰۵۷/۴۷۵	۱۰۶/۶۴۹۶
دما (DegC°)	۱۹/۸۳۷۰۳	-۵/۲۶۱۷۱	۳۷/۹۸۷۹۲	۱۰/۱۱۱۹۷
جهت باد (Deg)	۱۸۹/۱۱۸۲	۸۶/۲۲	۲۸۲/۰۵	۴۶/۰۰۵۱۲
سرعت باد (m/s)	۱/۶۲۲۳۱	۰/۶۷۸۰۸۳	۵/۷۳۷۲۹۲	۰/۶۵۷۴۲۴

مقادیر غلظت مونوکسیدکربن را به خود اختصاص داده است. هم‌چنین میانگین غلظت ماهیانه مونوکسید کربن در سال ۲۰۰۹ نسبت به ماه‌های مشابه در سال ۲۰۰۸ به‌طور کلی بیشتر است.

روند تغییرات ماهیانه غلظت مونوکسید کربن در سال‌های ۲۰۰۸ و ۲۰۰۹ در نمودار شکل (۵) نشان داده شده است. این نمودار نشان می‌دهد که روند تغییرات در ماه‌های آخر سال ۲۰۰۸ و اوایل سال ۲۰۰۹ (فصل زمستان) شدیدتر بوده و بالاترین



شکل ۵- روند تغییرات ماهانه مونوکسید کربن در سال‌های ۲۰۰۸ تا ۲۰۰۹

Figure 5- Monthly changes trends of CO from 2008 to 2009

جدول ۲- نتایج تست کولموگروف

Table 2-The results of Kolmogorov-Smirnov test

آزمون آماری	کولموگروف - شاپیرو-ویلک		
	Sig.	df	Statistic
متغیر	۰/۱۷۴	۱۰	۰/۲۰

تبدیل موجک

از آنجایی که سیگنال بازسازی شده تقریبی از سیگنال اولیه است که با قرار دادن صفرها بین نمونه‌ها به دست می‌آید، لذا هرچه درجه تجزیه بیشتر باشد، سیگنال بازسازی شده انحراف بیشتری از سیگنال اولیه دارد. زیرا جزییات بیشتری را از دست داده و در واقع از فیلترهای پایین‌گذر بیشتری عبور داده شده است. بنابراین، جهت به دست آوردن معیاری برای سطح تجزیه از الگوریتم معکوس تبدیل موجک استفاده می‌شود. در این تحقیق موجک Haar با درجه تجزیه ۲ در نظر گرفته شده است، چرا که در این سطح، سیگنال بازسازی شده بیشترین شباهت را به سیگنال اصلی داشته است و از این سطح تجزیه به بعد، انحراف سیگنال بازسازی شده از سیگنال اصلی بسیار زیادتر بوده است. در پایان، بازسازی موجک‌ها بر اساس حد آستانه انتخاب شده و درجه N انجام گرفته است (شکل ۶).

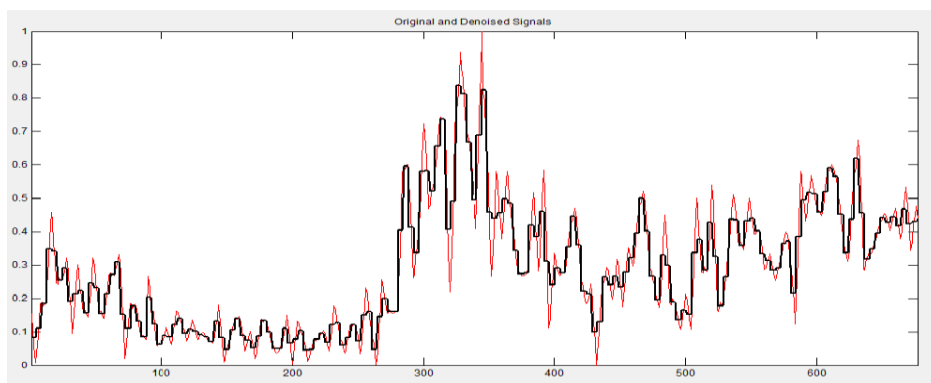
در این تحقیق داده‌های جا افتاده یا ثبت نشده و داده‌های پرت که به علت نقص دستگاه و خطای اندازه‌گیری به وجود می‌آید، دو مشکل اساسی در استفاده از مجموعه داده‌های اصلی بود. به منظور رفع مشکل داده‌های پرت از دو روش تبدیل موجک و تعیین حد آستانه به کمک منحنی توزیع نرمال استفاده گردید.

تعیین حد آستانه به کمک منحنی توزیع نرمال

به این منظور ابتدا داده‌ها از نظر تبعیت از توزیع نرمال بررسی شدند. (جدول ۲). با توجه به جدول ۲، عدد متناظر با Sig. اگر مساوی یا بزرگتر از $P=0/05$ باشد (همانطور که در تست کولموگراف برابر با $0/2$ و در تست شاپیرو برابر با $0/691$ است)، به این معنی است که متغیر مورد نظر دارای توزیع نرمال است. با توجه به برخورداری داده‌ها از توزیع نرمال برای هر یک از پارامترهای ورودی شبکه حد آستانه‌ای با استفاده از معادله (۲) تعیین و داده‌های خارج از این محدوده حذف گردیدند. (۲۲). لذا، از ۷۳۱ روز داده‌های مورد مطالعه، ۴۰ روز داده ثبت نشده و ۳۱ روز داده پرت و مابقی به عنوان داده اصلی لحاظ شد.

$$T = \frac{\sum_{i=1}^n x_i}{N} \pm (1.96) \sqrt{\frac{\sum_{i=1}^n (x_i - \mu_x)^2}{N}} \quad \text{معادله (۲)}$$

که در این رابطه x_i داده‌های اصلی، N تعداد کل داده‌ها، μ_x میانگن داده‌ها و T مقدار حد آستانه است.



شکل ۶- سیگنال بازسازی شده

Figure 6-Reconstructed signal

نرمال سازی داده‌ها

پس از انجام مراحل فوق، در جهت آموزش بهینه شبکه مشخصه‌های آب و هوایی و آلودگی، پیش از این که وارد شبکه شوند، مطابق معادله (۳) در محدوده صفر تا یک نرمال سازی شدند. از جمله فواید نرمال سازی داده‌های ورودی این است که

از به وجود آمدن وزن‌های با مقدار عددی خیلی بزرگ یا کوچک در طول محاسبات جلوگیری می‌کند (۲۵)

$$X_{nor} = \frac{(X - X_{min})}{X_{max} - X_{min}} \quad \text{معادله (۳)}$$

حاصل می‌شود. حال نوبت به انجام دور دوم برنامه می‌رسد و با توجه به این نکته که مقدار دهی اولیه وزن‌ها و بایاس‌ها کاملاً تصادفی است، این بار نیز با مقدار F متفاوتی برای همان ساختار شبکه عصبی با A لایه پنهان که در بالا اشاره شد مواجه می‌شویم. به این منظور مقدار میانگین تابع F برای ۲ تکرار محاسبه و در آرایه‌ای ذخیره می‌شود. در نهایت این الگوریتم روند ذکر شده را برای ۱۰۰۰ دور تکرار متوالی انجام و مقادیر به دست آمده برای تابع F با ساختارهای مختلف با یکدیگر مقایسه و ساختار مربوط به کمترین مقدار تابع F به عنوان بهترین ساختار شبکه عصبی انتخاب گردید. در روند آموزش شبکه در هر تکرار برنامه برای جلوگیری از آموزش بیش از حد شبکه که منجر به ایجاد خطا در نتایج می‌شود، شروط زیر در نظر گرفته شد:

- روال آموزش در صورتی که خطای ارزیابی طی ۱۰ تکرار متوالی افزایش یابد، متوقف شود.
- روال آموزش هر زمان که عملکرد نهایی شبکه به مقداری کمتر از ۰/۰۱ رسید، متوقف گردد.
- روال آموزش در صورتی که در ۵۰۰ تکرار متوالی هیچ یک از دو شرط بالا محقق نشد، متوقف شود.

در این مرحله، ابتدا از داده‌هایی که با استفاده از روش تعیین حد آستانه به کمک منحنی توزیع نرمال، حذف نویز شده بودند و سپس از داده‌هایی که با استفاده از روش تبدیل موجک حذف نویز گردیده بودند، به عنوان بردارهای ورودی آموزش شبکه استفاده شد. بر این اساس، در ارتباط با داده‌هایی که با روش اول حذف نویز گردیدند، ساختار شبکه عصبی با ۲ لایه پنهان شامل ۴ نرون در لایه اول و ۶ نرون در لایه دوم با توابع انتقال تانژانت سیگموئید ($tansig$) در دو لایه پنهان و تابع خطی ($purelin$) در لایه خروجی (شکل ۷) و با الگوریتم آموزش لئونبرگ-مارکوئست ($Levenberg-Marquardt$) دارای کمترین مقدار F بوده است. در ادامه، از این ساختار شبکه با عنوان مدل ۱ یاد خواهد شد (شکل ۸). هم‌چنین در ارتباط با داده‌هایی که با روش دوم حذف نویز گردیدند، ساختار شبکه عصبی با ۲ لایه پنهان شامل ۸ نرون در لایه اول و ۷ نرون در لایه دوم با توابع انتقال تانژانت سیگموئید ($tansig$) در دو لایه پنهان و تابع خطی ($purelin$) در لایه خروجی و با الگوریتم

X_{min} و X_{max} مقادیر کمینه و بیشینه مشاهده شده داده اصلی و X_{nor} داده نرمال سازی شده است. داده‌های نرمال سازی شده پس از مدلسازی، با بهره‌گیری از فرمول زیر (معادله ۴) به داده اصلی (X) برگردانده می‌شوند.

$$X = [X_{nor}(X_{max} - X_{min})] + X_{min} \quad (4)$$

معماری شبکه عصبی

برای تعیین بهترین توپولوژی شبکه عصبی شامل بهترین تعداد لایه، تعداد نرون در هر لایه، تابع انتقال و الگوریتم آموزش، برنامه‌های لازم در محیط نرم افزار متلب پیاده‌سازی شد. الگوریتم به‌گونه‌ای طراحی شد که قابلیت بررسی تمامی حالات ممکن از نظر تعداد لایه، تعداد نرون در هر لایه، توابع انتقال مختلف و هم‌چنین الگوریتم‌های آموزش متفاوت را دارا باشد. به این منظور از تابع F مطابق تعریف زیر، به عنوان تابع هدف در بهینه‌سازی شبکه استفاده شده است (معادله ۵). تابع F طوری تعریف شد که میزان خطای مرتبط با هر سه گروه داده شامل داده‌های آزمایش، آموزش و تایید را در نظر بگیرد. از طرفی با توجه به این‌که الگوریتم به‌گونه‌ای طراحی شد که ۶۰٪ داده‌های ورودی در جهت آموزش شبکه و ۲۰٪ به عنوان داده‌های تایید و ۲۰٪ به عنوان داده‌های آزمایش در نظر گرفته شد، به مقدار خطای حاصل از داده‌های آموزش، ضریب کمتری اعمال شد تا نتایج حاصل، کمتر تحت تاثیر این پارامتر قرار گیرند.

$$F = 0.3perf + 0.35vperf + 0.35tperf \quad (5)$$


معادله (۵) $perf$ عملکرد شبکه در ارتباط با داده‌های آموزش، $vperf$ عملکرد شبکه در ارتباط با داده‌های تایید و $tperf$ عملکرد شبکه در ارتباط با داده‌های آموزش شبکه است.

روند کار اینگونه است که برای مثال در اولین تکرار الگوریتم، بردارهای ورودی (داده‌های سال‌های ۲۰۰۸ و ۲۰۰۹) به شبکه-ای با ساختار A لایه پنهان که دارای B نرون در هر یک از لایه‌ها با تابع انتقال X و الگوریتم آموزش Y است، اعمال و مقادیر به دست آمده برای سه پارامتر عملکرد شبکه در ارتباط با داده‌های آزمایش، داده‌های تایید و داده‌های آموزش در ضرایب در نظر گرفته شده در معادله (۵) ضرب و مقدار F برای ساختار شبکه عصبی با مشخصات فوق حاصل می‌شود. این روند برای تمامی ساختارهای دیگر شبکه عصبی در یک تکرار برنامه ادامه یافته و در نهایت پس از پایان یک دور تکرار، مقادیر متفاوتی از تابع F برای ساختارهای مختلفی از شبکه عصبی

که در مرتبه نخست از همان داده‌هایی که برای آموزش شبکه استفاده شده بود (داده‌های سال ۲۰۰۸ و ۲۰۰۹)، مجدداً به عنوان ورودی به مدل‌ها استفاده شد (داده‌های تکراری). در ادامه نیز داده‌های زمستان سال ۱۳۸۹ (۲۱ دسامبر ۲۰۱۰ تا ۲۰ مارس ۲۰۱۱) که در روند آموزش شبکه استفاده نشده بودند (داده‌های جدید)، به مدل‌های شبکه عصبی اعمال شد که جدول (۳) به مقایسه نتایج شاخص‌های آماری به دست آمده از مدل‌ها پرداخته است.

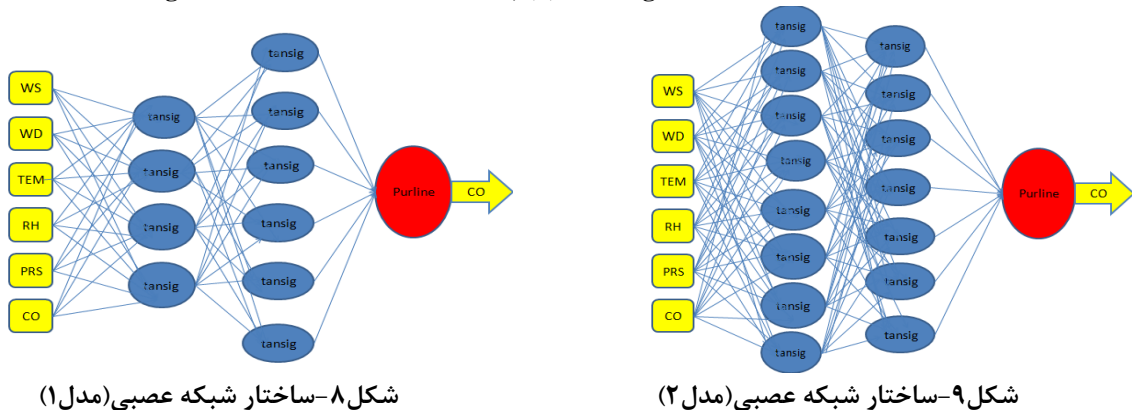
آموزش لونیبرگ-مارکوئت دارای کمترین مقدار F است. در ادامه، از این ساختار شبکه با عنوان مدل ۲ یاد می‌شود (شکل ۹).
یافته‌ها

در این تحقیق از شاخص‌های آماری ضریب همبستگی، شاخص توافق (IA)، دقت پیش‌بینی (PA) و جذر میانگین مربعات خطا (RMSE) برای بررسی دقت مدل‌های ارایه شده استفاده شد. به منظور ارزیابی دقت مدل‌های شبکه عصبی در امر پیش‌بینی، دو گروه داده به مدل‌های ارایه شده اعمال گردید، به این صورت



شکل ۷- تابع انتقال خطی (a)، تابع انتقال تانزانت سیگموئید (b)

Figure 7-linear transfer function, (b) Tan-Sigmoid transfer function



شکل ۸- ساختار شبکه عصبی (مدل ۱)

شکل ۹- ساختار شبکه عصبی (مدل ۲)

Figure 8- Structure of neural network (model no. 1) Figure 9- Structure of neural network (model no. 2)

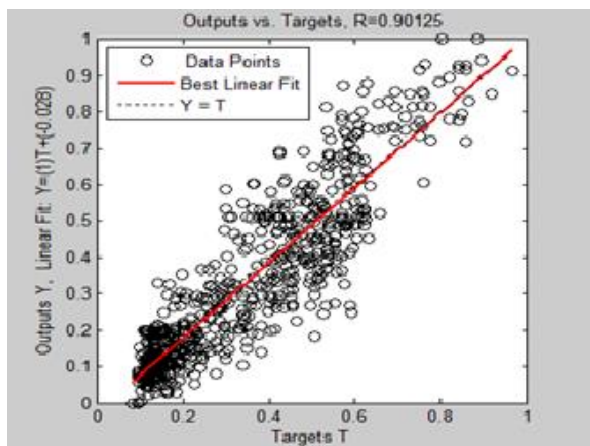
جدول ۳- شاخص‌های آماری

Table 3- Statistical indices

داده‌های جدید		داده‌های تکراری		شاخص‌های آماری
مدل ۲	مدل ۱	مدل ۲	مدل ۱	
۰/۱۱۶۳	۰/۰۸۲۵	۰/۰۳۸۵	۰/۱۰۱۲	خطای جذر میانگین مربعات
۰/۸۶۷۸	۰/۹۰۸۶	۰/۹۵۷۲	۰/۹۰۱۲	ضریب همبستگی
۰/۹۲۸	۰/۸۹	۰/۹۷۸	۰/۹۱۵	شاخص توافق
۰/۹۳۲	۰/۸۸۵	۰/۹۶۳	۰/۸۴۸	شاخص دقت پیش‌بینی

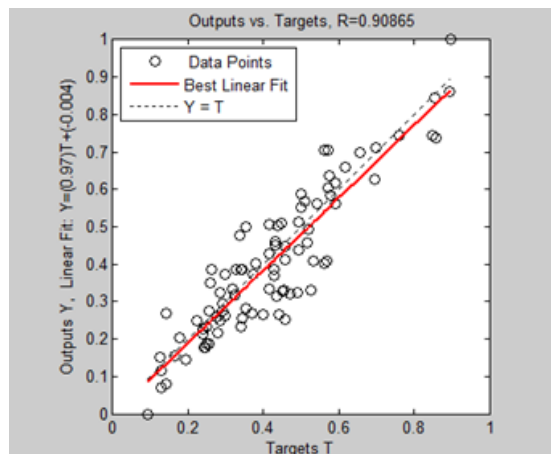
شبیه‌سازی شده توسط مدل‌ها را نشان می‌دهد. برای داده‌های جدید، مدل ۱ ضریب همبستگی بالاتری از مدل ۲ دارد، در حالی که در ارتباط با داده‌های تکراری مدل ۲ نتایج بهتری دارد.

در مرحله حذف نویز و پیش‌پردازش بردارهای ورودی، استفاده از تبدیل موجک در مقایسه با تعیین حد آستانه نتایج بهتری دارد. شکل‌های ۱۰ و ۱۱ ضریب همبستگی داده‌های واقعی و




شکل (۱۰ب)- ضریب همبستگی بین داده‌های تکراری و شبیه‌سازی شده توسط مدل ۱

Figure 10-(b) Correlation coefficient between repeated data and simulated data generated by model no. 1




شکل (۱۰الف)- ضریب همبستگی بین داده‌های جدید و شبیه‌سازی شده توسط مدل ۱

Figure 10-(a) Correlation coefficient between new data and simulated data generated by model no. 1



شکل (۱۱ب)- ضریب همبستگی بین داده‌های تکراری و شبیه‌سازی شده توسط مدل ۲

Figure 11-(b) Correlation coefficient between repeated data and simulated data generated by model no. 2

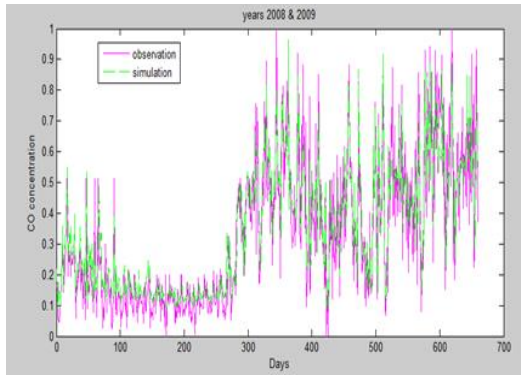


شکل (۱۱الف)- ضریب همبستگی بین داده‌های جدید و شبیه‌سازی شده توسط مدل ۲

Figure 11-(a) Correlation coefficient between new data and simulated data generated by model no. 2


شبیه‌سازی شده با بردارهای ورودی تکراری، بارزتر است که مهم‌ترین دلیل آن استفاده از همین بردارها در مرحله آموزش شبکه است (شکل‌های ۴-۵ و ۴-۷)، اما در ارتباط با داده‌های زمستان ۱۳۸۹ (داده‌های جدید) که هیچ نقشی در روند آموزش شبکه‌ها نداشته‌اند، توافق کمتری مشاهده می‌شود.

همانطور که از مقایسه مقادیر شبیه‌سازی شده با مقادیر واقعی مشخص است (شکل‌های ۱۲ الف و ۱۲ ب، ۱۳ الف و ۱۳ ب)، مدل‌های شبکه عصبی مصنوعی آرایه شده در این بررسی ابزارهایی قدرتمند به منظور شبیه‌سازی پارامترهای آلودگی هوا بوده و ارزش‌های شبیه‌سازی شده توسط مدل‌ها از توافق بالایی با مقادیر مشاهده شده برخوردارند. این توافق در داده‌های



شکل (۱۲ب)- داده‌های شبیه‌سازی شده توسط مدل ۱ برای داده-های تکراری (سال‌های ۲۰۰۸ و ۲۰۰۹)

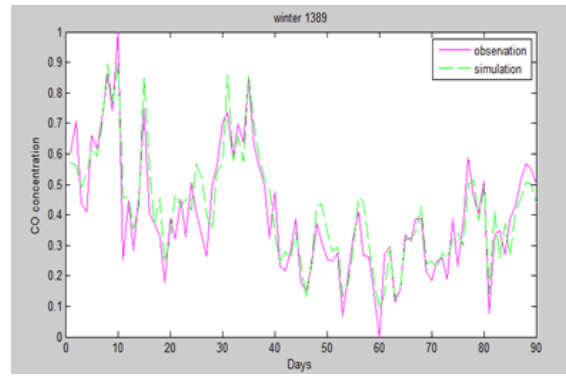
Figure 12-(b) simulated data generated by model no. 1 for repeated data (winter 2008-2009)



شکل (۱۳ب)- داده‌های شبیه‌سازی شده توسط مدل ۲ برای داده-های تکراری (سال‌های ۲۰۰۸ و ۲۰۰۹)

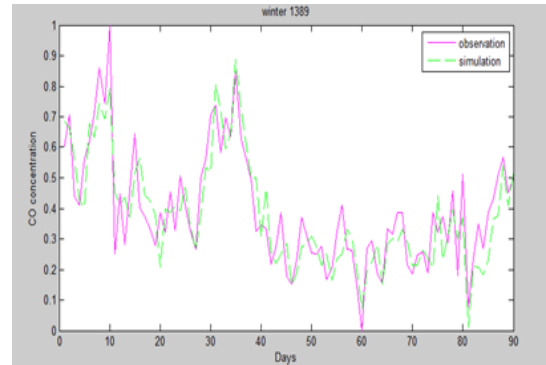
Figure 13- (b) simulated data generated by model no. 2 for repeated data (winter 2008-2009)

استفاده از دو روش تبدیل موجک و تعیین یک حد آستانه به کمک توزیع نرمال، دو مدل شبکه عصبی مصنوعی به منظور پیش‌بینی میزان آلودگی برای روزهای آتی ارائه شد. نتایج نشان می‌دهد با توجه به این‌که ماهیت تغییرات و نوسانات غلظت آلاینده منوکسیدکربن و به طور کلی پدیده‌های طبیعی، غیر خطی است و با بررسی نمودارها و جداول موجود در این پژوهش می‌توان دریافت که مدل‌های شبیه‌سازی ارائه شده، به خوبی توانایی شبیه‌سازی شرایط آینده را دار هستند، این خود نشان از قابلیت بالای شبکه‌های عصبی در تخمین و تقریب نگاشت‌های غیر خطی است. مقایسه نتایج حاصل از مدل‌های ارائه شده بیان‌گر اهمیت پیش‌پردازش و آماده‌سازی داده‌های ورودی شبکه عصبی است، چرا که با توجه به رابطه مستقیم توان عصبی و آمارهای استفاده شده در آموزش آن،



شکل (۱۲الف)- داده‌های شبیه‌سازی شده توسط مدل ۱ برای داده‌های جدید (زمستان ۱۳۸۹)

Figure 12-(a) simulated data generated by model no. 1 for new data (winter 2008-2009)



شکل (۱۳الف)- داده‌های شبیه‌سازی شده توسط مدل ۲ برای داده‌های جدید (زمستان ۱۳۸۹)

Figure 13- (a) simulated data generated by model no. 2 for new data (winter 2008-2009)

با توجه به معیارهای ارزیابی، نتایج نشان دهنده توانایی بالای مدل مورد استفاده است. برای مقایسه نتایج حاصل از این پژوهش با پژوهش‌های مشابه مورد اشاره در پیشینه تحقیق، با توجه به تفاوت شاخص‌های مورد استفاده و تمرکز این پژوهش‌ها بر برخی از پارامترها، عملاً امکان مقایسه فراهم نگردد.

بحث و نتیجه‌گیری

منوکسیدکربن یکی از عمده‌ترین منابع آلودگی هوا است. پژوهش پیش‌رو سعی در ارائه مدلی جهت پیش‌بینی غلظت آلاینده منوکسیدکربن در هوای تهران دارد تا بتوان به کمک آن راهکارهای مناسبی را به فراخور زمان و شرایط موجود در راستای کاهش و کنترل آلودگی هوا ارائه و اجرا نمود.

روش مورد استفاده در این پژوهش بدین گونه است که پس از پیش‌پردازش داده‌ها و حذف داده‌های نویزی و دارای خطا با

مصنوعی، علوم و تکنولوژی محیط زیست، دوره ۱۳، صص ۱-۱۰.

9- Nejadkoorki, F. and S. Baroutian, 2012. "Forecasting extreme PM10 concentrations using artificial neural networks." *Int. J. Environ. Res* 6(1): 277-284.

۱۰- سبحانی اردکانی. س، اسماعیلی ساری. ع، چراغچی. م، طیبی. ل و قاسمرودی. م، ۱۳۸۶، تعیین کیفیت بهداشتی هوای تهران در سال ۱۳۸۳ با استفاده از شاخص کیفیت هوا، علوم تکنولوژی و محیط زیست، شماره ۴، صص ۳۸-۳۳.

۱۱- صدر موسوی. میرستار، و رحیمی. اکبر، ۱۳۸۷، ارزیابی کاربرد شبکه‌های عصبی مصنوعی در پیش-بینی منوکسید کربن در هوای شهر تبریز، فصل نامه منابع طبیعی ایران، سال شصت و یکم، شماره ۳

۱۲- سبحانی اردکانی. س و اسماعیلی ساری. ع، چراغچی. م، طیبی. ل و قاسمرودی. م، ۱۳۸۶، تعیین کیفیت بهداشتی هوای تهران در سال ۱۳۸۳ با استفاده از شاخص کیفیت هوا، علوم تکنولوژی و محیط زیست، شماره ۴، صص ۳۸-۳۳.

۱۳- نظم آرا. ش، هاشم خانی. م، ذوقی. الف، ۱۳۸۶، بررسی وضعیت CO موجود در شهر تهران با استفاده از شاخص کیفیت هوا (AQI) دهمین همایش ملی بهداشت محیط، دانشگاه علوم پزشکی همدان.

۱۴- اله حسینی، الف، هاشمی. ه و نیکروان، م، ۱۳۸۹، تحلیل و بررسی آماری داده‌های شاخص آلودگی هوای تهران از سال ۱۳۸۱ الی ۱۳۸۷، پنجمین کنگره ملی مهندسی عمران، دانشگاه فردوسی، مشهد.

۱۵- منهاج. محمدباقر، ۱۳۸۴، مبانی شبکه‌های عصبی مصنوعی، انتشارات دانشگاه صنعتی امیر کبیر.

16- Patterson, W. 1996; *Artificial Neural Network: Theory and Applications*, second edition, Prentice Hall Press.

17- Shepherd, G.M, 1990, *The synaptic organization of the brain*, third edition, Oxford university press

لازم است در تهیه داده‌های آموزش شبکه عصبی دقت لازم به عمل آید تا شبکه عصبی تعمیم پذیری مناسبی در مواجهه با داده‌های جدید داشته باشد.

منابع

- ۱- اصیلیان. حسن، قانعیان. محمدتقی و غنی‌زاده. قادر، ۱۳۸۶، آلودگی هوا، انتشارات میترا.
- 2- Zannetti, p. 1990; *Air pollution modeling, theories, computational methods and software's, computational mechanics publication*, WIT Press.
- 3- Collett RS, Oduyemi K. 1997; *Air quality modelling: a technical review of mathematical approaches. Meteorological Applications*. 4(03):235-46.
- 4- 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.
- 5- Ibarra-Berastegi G, Elias A, Barona A, Saenz J, Ezcurra A, de Argandoña JD. 2008; *From diagnosis to prognosis for forecasting air pollution using neural networks: Air pollution monitoring in Bilbao. Environmental Modelling & Software*. 23(5):622-37.
- 6- Ul-Saufie AZ, Yahya AS, Ramli NA, Hamid HA. 2011; *Comparison between multiple linear regression and feed forward back propagation neural network models for predicting PM10 concentration level based on gaseous and meteorological parameters. International Journal of Applied*. 1(4).
- 7- Tecer LA, 2007; *Prediction of SO2 and PM Concentrations in a Coastal Mining Area (Zonguldak, Turkey) Using an Artificial Neural Network. Polish J. of Environ. Stud*. 16(04): 633-638

۸- بوداقپور. سیامک، ۱۳۹۰، پیش بینی میزان غلظت آلاینده‌های هوای تهران با استفاده از شبکه عصبی-

۲۰- شرعی پور. زهرا، ۱۳۸۹، بررسی غلظت آلاینده‌های هوا و ارتباط آن با پارامترهای هواشناسی، چهاردهمین کنفرانس ژئوفیزیک ایران، ایران.

21- Narasimhan, S.V., Nandini Basumallick, S. 2011, Introduction to Wavelet Transform: A Signal Processing Approach.

18- Fausett, Larson. 1994; Fundamental of neural network: architecture, algorithms, and applications, prentice Hall Press.

19- Chelani, Asha B., Chalapati Rao, K.M. Phadke & M.Z. Hasan, 2002; Prediction of Sulphur dioxide concentration using artificial neural networks. Environmental Modelling & Software; 17: 161–168.