

## پیش‌بینی غلظت آلاینده‌های گازی در هوای شهر تبریز با استفاده از شبکه عصبی

ناهیده محمدی<sup>۱</sup>، خالد ظروفچی‌بنیس<sup>۲</sup>، محمد شاکر خطیبی<sup>۳\*</sup>، اسماعیل فاتحی‌فر<sup>۴</sup>، علیرضا بهروزسرنند<sup>۴</sup>، امیر

محمودیان<sup>۱</sup> و فرید شیخ‌الاسلامی<sup>۱</sup>

<sup>۱</sup> کمیته تحقیقات دانشجویی، دانشگاه علوم پزشکی تبریز

<sup>۲</sup> دانشکده مهندسی شیمی، مرکز تحقیقات مهندسی محیط زیست، دانشگاه صنعتی سهند

<sup>۳</sup> گروه مهندسی بهداشت محیط، دانشکده بهداشت، دانشگاه علوم پزشکی تبریز

<sup>۴</sup> گروه مهندسی شیمی، دانشگاه صنعتی ارومیه

\* نویسنده مسئول

دریافت ۹۴/۷/۲۶ پذیرش ۹۴/۱۲/۳

## چکیده

آلودگی هوا به عنوان یک چالش مهم در شهرهای بزرگ مطرح می‌باشد که در نتیجه صنعتی شدن، گسترش شهرنشینی، رشد سریع ترافیک و افزایش فعالیت‌های انسان تشدید شده است. آلاینده‌های هوا باعث بروز اثرات منفی بر سلامت انسان و تخریب محیط زیست شده لذا آگاهی از غلظت آلاینده‌ها می‌تواند به عنوان اطلاعات کلیدی در برنامه‌های کنترل آلودگی مورد استفاده قرار گیرد. روش‌های متعددی برای پیش‌بینی غلظت آلاینده‌های هوا وجود دارد و در این میان، در سال‌های اخیر پیشرفت قابل توجهی در توسعه مدل‌های شبکه عصبی برای پیش‌بینی غلظت آلاینده‌های هوا صورت گرفته است. در این مطالعه، از شبکه‌های عصبی مصنوعی به منظور پیش‌بینی غلظت آلاینده‌های CO، SO<sub>2</sub> و NO<sub>x</sub> در هوای شهر تبریز استفاده شده است. داده‌های غلظت آلاینده‌ها از ایستگاه سنجش ثابت مستقر در میدان نماز و داده‌های هواشناسی شامل سرعت و جهت باد، دما و رطوبت هوا از اداره کل هواشناسی جمع‌آوری شده و پس از نرمال‌سازی به عنوان متغیرهای ورودی شبکه عصبی مورد استفاده قرار گرفت. تعداد ۵-۳ لایه مخفی و ۲۵-۸ نرون در هر لایه مخفی نتایج قابل قبولی داشته است. از تابع تانژانت سیگموئید به عنوان تابع انتقال و الگوریتم لونیگ مارکوات برای بهینه‌سازی وزن‌ها و بایاس‌های شبکه استفاده شد. بر اساس نتایج به دست آمده، شبکه عصبی مصنوعی روشی قابل اعتماد برای پیش‌بینی غلظت ساعتی آلاینده‌های هوا بوده به طوری که، ضریب همبستگی بالای ۰/۹۰ بین غلظت آلاینده‌های پیش‌بینی شده و غلظت واقعی آلاینده‌های CO، SO<sub>2</sub> و NO<sub>x</sub> به دست آمد.

**واژگان کلیدی:** آلودگی هوا، شبکه عصبی مصنوعی، مدل‌های پیش‌بینی.

## ۱- مقدمه

ضروری می‌باشد. اندازه‌گیری آلاینده‌های هوا در شهرها به طور معمول با استفاده از ایستگاه‌های پایش ثابت و سیار انجام می‌گیرد. با توجه به محدودیت‌های موجود در روش سنجش دستگاهی، در طی دو دهه اخیر مدل‌های آماری متعددی نیز جهت پیش‌بینی غلظت آلاینده‌های هوا مورد استفاده قرار گرفته است. نتایج حاصل از این مدل‌ها می‌تواند در برنامه‌ریزی مدیریت و کنترل آلودگی هوا مورد استفاده قرار گیرد. در این میان، شبکه‌های عصبی مصنوعی در پژوهش‌های مربوط به آلودگی هوا در سال‌های اخیر به طور موفقیت‌آمیزی مورد استفاده قرار گرفته‌اند [۴]. از جمله این مطالعات می‌توان به مطالعه Boznar و همکاران [۵] در خصوص پیش‌بینی غلظت SO<sub>2</sub> با بهره‌گیری از شبکه عصبی در مناطق صنعتی اسلوونی در سال

آلودگی هوا یکی از مهم‌ترین چالش‌های زیست محیطی شهرهای بزرگ و صنعتی به شمار می‌رود که با افزایش جمعیت، گسترش شهرنشینی و مصرف بیشتر سوخت‌های فسیلی، روز به روز بر شدت آن افزوده می‌شود [۱]. آلودگی هوا به طرق گوناگون می‌تواند اثراتی را در دراز مدت و کوتاه مدت بر سلامت انسان‌ها داشته باشد، به طور کلی اثرات آلودگی هوا بر انسان عمدتاً بر روی چشم‌ها و دستگاه تنفسی می‌باشد که در کوتاه مدت سبب سوزش و تحریک چشم، بینی، گلو و شش‌ها و در دراز مدت سبب بروز بیماری‌های قلبی-عروقی، آسم، برونشیت و آلرژی‌های مختلف تنفسی در انسان می‌گردد [۲، ۳].

آگاهی از غلظت آلاینده‌های هوا در محیط‌های شهری به منظور ارزیابی وضعیت آلودگی هوا و برنامه‌ریزی برای کنترل آن

CO در این شهر انجام شده و به منظور ارتقاء و اعتبارسنجی سیستم اطلاعاتی موجود پایش آلاینده‌های هوا ضروری است تا در کنار استفاده از دستگاه‌های سنجش ثابت مستقر در نقاط مختلف شهر، از روش‌های ریاضی مشتعل بر مدل‌های پیش‌بینی به نحو مطلوب بهره‌برداری شود. در این راستا، این مطالعه با هدف بهینه‌سازی مدل شبکه عصبی جهت نیل به دقیق‌ترین پیش‌بینی غلظت ساعتی آلاینده‌های گازی در محدوده یکی از ایستگاه‌های ثابت سنجش اداره کل محیط زیست در شهر تبریز انجام شده است.

## ۲- روش تحقیق

### ۲-۱- منطقه مورد مطالعه


شهر تبریز در شمال‌غرب ایران، با وسعتی معادل ۳۲۴ کیلومتر مربع در ۵۰ کیلومتری قله سه‌سند واقع شده است. این کلانشهر با بیش از ۱/۵ میلیون نفر جمعیت به عنوان بزرگ‌ترین شهر شمال غرب کشور محسوب می‌شود. استقرار صنایع بزرگ نظیر پالایشگاه نفت، نیروگاه حرارتی، مجتمع پتروشیمی، ماشین‌سازی، تراکتورسازی و ده‌ها صنعت بزرگ و کوچک دیگر، این شهر را در زمره یکی از بزرگ‌ترین قطب‌های صنعتی کشور قرار داده است. این شهر دارای زمستان‌های طولانی و تابستان‌های معتدل بوده و دمای حداقل، میانگین و حداکثر هوا در طول سال به ترتیب  $15^{\circ}\text{C}$ ،  $13^{\circ}\text{C}$  و  $38^{\circ}\text{C}$  می‌باشد. حداقل ساعات آفتابی به میزان ۱۱۴/۳ ساعت در آبان ماه و حداکثر آن ۳۵۳/۸ ساعت در مرداد ماه اتفاق می‌افتد. بررسی جریان باد به لحاظ جهات جغرافیایی، سرعت و تعداد و درصد دفعات وزش در شهر تبریز در طی یک دوره ده ساله نشان می‌دهد که بادهای محلی با شدت و ضعف از تمامی جهات به این شهر می‌وزند و در این میان، بادهای سمت شرق و شمال شرق به ترتیب اولویت به عنوان بادهای غالب به شمار می‌روند. با این حال، در فصل سرد سال بادهای غربی به عنوان باد غالب بوده و با توجه به این که اغلب صنایع بزرگ در منطقه غربی شهر مستقر شده‌اند، به عنوان عامل اصلی انتقال آلودگی هوای ناشی از این صنایع به سطح شهر به شمار می‌رود. شکل (۱) جهت و سرعت بادهای غالب را در شهر تبریز به صورت نمودار گلباد نشان می‌دهد.

۱۹۹۳، مطالعه Gardner و Dorling [۶] در زمینه پیش‌بینی غلظت  $\text{NO}_x$  و  $\text{NO}_2$  در شهر لندن با استفاده از الگوریتم لونبرگ مارکوات (LM) در سال ۱۹۹۹، مطالعه Postolache و همکاران [۷] در پیش‌بینی غلظت CO با بهره‌گیری از شبکه‌های پرسپترون چندلایه در سال ۲۰۰۱، مطالعه Hooyberghs و همکاران [۸] در پیش‌بینی غلظت آلاینده‌های هوا در بلژیک با به کارگیری شبکه‌های عصبی چند لایه در سال ۲۰۰۵، مطالعه Ming و همکاران [۹] در خصوص پیش‌بینی غلظت ساعتی آلاینده‌های هوا در مجاورت مناطق اصلی شهری با استفاده از شبکه عصبی مصنوعی در سال ۲۰۰۹، پیش‌بینی غلظت ساعتی آلاینده‌های هوا توسط شبکه عصبی با به کارگیری میانگین بهینه زمانی پارامترهای هواشناسی و غلظت آلاینده‌ها توسط Hrust و همکاران [۱۰] در ۲۰۰۹ اشاره نمود. مطالعات محدودی نیز در این زمینه در ایران انجام شده است که از آن جمله می‌توان به مطالعه موسوی و رحیمی [۱۱] در خصوص کاربرد شبکه عصبی در پیش‌بینی غلظت منواکسید کربن در شهر تبریز در سال ۱۳۸۶، مطالعه بداقپور و چرخستانی در زمینه پیش‌بینی غلظت آلاینده‌های هوای شهر تهران با استفاده از شبکه‌های عصبی مصنوعی در سال ۱۳۹۰ [۱۲]، مطالعه ارحمی و همکاران [۱۳] در زمینه طراحی مدل‌های ANN برای پیش‌گویی غلظت ساعتی  $\text{CO}$ ،  $\text{NO}_x$ ،  $\text{NO}_2$ ،  $\text{NO}$ ،  $\text{O}_3$  و  $\text{PM}_{10}$  به همراه آنالیز غیر قطعی<sup>۱</sup> با شبیه‌سازی Monte Carlo در شهر تهران در سال ۱۳۹۱ و مطالعه شاکرخطیبی و همکاران [۱۴] در زمینه مقایسه کارایی مدل‌های EPR و ANN در پیش‌بینی غلظت CO در شهر تبریز در سال ۲۰۱۵ اشاره نمود.

لازم به ذکر است اکسیدهای نیتروژن ( $\text{NO}_x$ ) عمدتاً شامل نیتروس اکسید ( $\text{N}_2\text{O}$ ) مونوکسید نیتروژن ( $\text{NO}$ ) و دی اکسید نیتروژن ( $\text{NO}_2$ ) می‌باشد. با توجه به این که  $\text{N}_2\text{O}$  گازی غیر سمی با مزه و بوی نسبتاً خوب است و بالعکس  $\text{NO}$  و  $\text{NO}_2$  هر دو برای سلامتی انسان مضرند به طوری که اثر  $\text{NO}_2$  چهار برابر بیشتر از  $\text{NO}$  است. بنابر این آلاینده  $\text{NO}_x$  مجموع دو  $\text{NO}$  و  $\text{NO}_2$  در نظر گرفته می‌شود.

در مجموع، نتایج این مطالعات نشان‌دهنده کارایی بالای شبکه‌های عصبی مصنوعی در پیش‌بینی غلظت آلاینده‌ها در هوای شهرها بوده است. با توجه به این که شهر تبریز به عنوان یکی از کلانشهرهای کشور که با مشکل آلودگی هوا مواجه است، مطرح می‌باشد، تنها یک مطالعه در خصوص پیش‌بینی غلظت

اداره کل محیط زیست استان آذربایجان شرقی جمع‌آوری شده و پس از نرمال‌سازی، به عنوان ورودی شبکه عصبی مورد استفاده قرار گرفت. نرمال‌سازی داده‌ها به منظور افزایش دقت و سرعت شبکه و همچنین به حداقل رساندن تغییرات وزن نرون‌ها و پاسخ سریع‌تر نرون‌ها به سیگنال‌های ورودی انجام گرفت. بدین منظور، داده‌های هواشناسی در محدوده -۱ و ۱ و داده‌های آلودگی هوا در محدوده -۰/۹ و ۰/۹ با استفاده از رابطه (۱) نرمال شده و در نهایت، داده‌های خروجی شبکه عصبی با معکوس نمودن الگوریتم استانداردسازی با استفاده از رابطه (۲) به حالت واقعی اولیه برگردانده شد [۱۱].



شکل ۱- نمودار گلباد شهر تبریز با استفاده از داده‌های هواشناسی یک دوره ده ساله

$$X_{norm} = \frac{(X - X_{min})}{(X_{max} - X_{min})} * (r_{max} - r_{min}) + r_{min} \quad (1)$$

$$X = \left( \frac{(X_{norm} - r_{min}) * (X_{max} - X_{min})}{r_{max}} \right) + X_{min} \quad (2)$$

در این روابط،  $X$  به عنوان داده اصلی،  $X_{min}$  و  $X_{max}$  به ترتیب به عنوان مقادیر بیشینه و کمینه داده اصلی و  $r_{max}$  و  $r_{min}$  به ترتیب معادل ۰/۹ و -۰/۹ برای داده‌های آلودگی و ۱ و -۱ برای پارامترهای هواشناسی در نظر گرفته شده است.

علاوه بر متغیرهای هواشناسی در نظر گرفته، متغیرهای زمانی که بتواند چرخه‌های مختلف (همچون تغییرات حجم ترافیک در طول روز، هفته و سال، ساعات آفتابی، شرایط پایداری اتمسفر از قبیل ارتفاع اختلاط و شدت تابش آفتاب) را وارد مدل کرده و سبب افزایش کارایی مدل شود مورد بررسی قرار گرفتند. با توجه به نتایج حاصل از بررسی‌های صورت گرفته و انجام سعی و خطاهای مکرر، ساعت از روز و روز از هفته نیز به عنوان متغیرهای موردی مدل در نظر گرفته شدند. همچنین توسعه مدل به صورت ماهیانه (مدلی جداگانه برای هر ماه) باعث افزایش چشمگیر کارایی مدل شد. در نهایت شبکه‌های عصبی به صورت ماهیانه (۱۲ مدل برای هر آلاینده) و با در نظر گرفتن ۶ متغیر ورودی (دما، رطوبت، سرعت و جهت باد، روز از هفته و ساعت از روز) آموزش داده شدند.

### ۲-۳- کلیات شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی سیستم‌های دینامیکی هستند که با پردازش داده‌های تجربی قانون نهفته در ورای اطلاعات را به ساختار شبکه منتقل می‌کنند. این سیستم‌های هوشمند بر اساس محاسبات روی داده‌های عددی، قوانین کلی را فرا می-

در این تحقیق ایستگاه پایش آلاینده‌های هوا واقع در میدان نماز شهر تبریز به عنوان مورد مطالعاتی انتخاب شده است. این ایستگاه در مرکز شهر تبریز و در کنار یکی از خیابان‌های پر تردد شهر (با حجم ترافیک بالا) قرار دارد.

### ۲-۲- داده‌های مورد استفاده

تعیین متغیرهای ورودی مدل که تأثیر بسزایی در کارایی مدل دارند، از مهمترین مراحل توسعه مدل شبکه عصبی می‌باشد [۱۳]. به طور کلی انتخاب متغیرهای ورودی مدل را می‌توان با استفاده از اطلاعات قبلی از ویژگی‌های متغیرها و بررسی مطالعات گذشته و همچنین آموزش تعداد زیادی از شبکه‌های مختلف و بررسی تأثیر پارامترها در صحت نتایج مدل به دست آورد [۱۵]. بنابر این در این تحقیق مناسب‌ترین پارامترهای هواشناسی با در نظر گرفتن ملاحظات کلیدی زیر انتخاب شدند:

- ۱- با توجه به هدف مدل‌سازی که پیش‌بینی غلظت آلاینده‌ها می‌باشد، پارامترهای هواشناسی که قابل پیش‌بینی با روش‌های متداول هستند به عنوان متغیر ورودی مدل انتخاب شدند.
- ۲- پارامترهایی انتخاب شدند که منجر به بهترین پیش‌بینی از غلظت آلاینده‌ها شوند. 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، رطوبت، سرعت و جهت باد به عنوان مؤثرترین پارامترهای هواشناسی و متغیرهای ورودی مدل انتخاب شدند.

اطلاعات هواشناسی از اداره کل هواشناسی استان آذربایجان شرقی (ایستگاه سینوپتیک واقع در فرودگاه بین‌المللی تبریز) و داده‌های ساعتی مربوط به غلظت هر یک از آلاینده‌های  $SO_2$ ،  $CO$  و  $NO_x$  (مجموع  $NO$  و  $NO_2$ ) در یک دوره پنج ساله از سال ۱۳۸۶ تا ۱۳۹۰ مربوط به ایستگاه سنجش میدان نماز از

نتایج، در این مطالعه از این شبکه‌ها برای پیش‌بینی غلظت آلاینده‌های  $NO_x$ ،  $SO_2$  و CO استفاده شده است.

## ۲-۵- ساختار شبکه عصبی مورد استفاده در این مطالعه

به منظور ایجاد شبکه عصبی، ۸۰-۷۰ درصد کل داده‌های پردازش شده موجود برای آموزش شبکه، ۱۵-۱۰ درصد داده‌ها برای ارزیابی و ۱۵-۱۰ درصد باقیمانده برای اعتبارسنجی نتایج حاصل از شبکه مورد استفاده قرار گرفت. این دسته‌بندی پس از انجام آزمون‌های متعدد و با استفاده از روش سعی و خطا انتخاب شده است. شبکه مورد نظر با تغذیه پیشرو با یک لایه ورودی، ۳ تا ۵ لایه میانی و یک لایه خروجی ساخته شد. تابع انتقال در لایه میانی از نوع تابع تانژانت سیگموئید و تابع انتقال در لایه خروجی از نوع تابع خطی در نظر گرفته شد. با توجه به سرعت همگرایی الگوریتم لوبنبرگ-مارکوات در شبکه‌های پیشرو، از این الگوریتم برای آموزش شبکه استفاده شد. تعداد نرون‌ها در لایه میانی با روش سعی و خطا به گونه‌ای انتخاب شد که بهترین جواب ممکن به دست آید. بدین منظور از امکانات و توابع موجود در محیط برنامه‌نویسی Matlab بهره‌گرفته شد. تنظیمات شبکه مورد استفاده در شرایط بهینه در جدول (۱) ارائه شده است.

جدول ۱- پارامترهای تنظیمات شبکه

پارامتر	مقدار
تابع یادگیری	Trainlm
تابع تقسیم بندی	Dividerand
نرخ یادگیری	۰/۷-۰/۸
نرخ اعتبارسنجی	۰/۱-۰/۱۵
نرخ آزمون	۰/۱-۰/۱۵
تابع عملکرد	MAE
Validation checks	۳۰۰
تعداد اپوک	۱۰۰۰۰
تعداد لایه‌های مخفی	۱-۴
تعداد نرون‌ها	۸-۲۵

معیارهای پذیرش نتایج پیش‌بینی شده در هر یک از ساختارهای شبکه عصبی، بر مبنای کمتر بودن خطای کمی حاصل از مقادیر محاسباتی شامل میانگین مربعات خطا (MSE)، جذر میانگین مجذور خطا (RMSE) حداکثر خطای مطلق (MAE)، ضریب همبستگی ( $R^2$ ) مطابق با روابط (۵) - (۸) بوده است.

گیرند. شبکه‌های عصبی مصنوعی با وجود این که با سیستم‌های عصبی طبیعی قابل مقایسه نیستند، ولی ویژگی‌هایی دارند که آن‌ها را در بعضی کاربردها مانند تفکیک الگوها، رباتیک، کنترل و به طور کلی هر جا که نیاز به یادگیری یک الگوی خطی یا غیر خطی باشد، ممتاز می‌نماید. این ویژگی‌ها شامل قابلیت یادگیری، پردازش توزیعی و قابلیت تعمیم دهی می‌باشند. شبکه‌ها از یک لایه ورودی و یک لایه خروجی و یک یا چند لایه میانی که اصطلاحاً لایه مخفی نامیده می‌شوند، تشکیل شده‌اند. زمانی که ورودی‌ها از طریق لایه ورودی به شبکه داده شوند، در وزن اتصال‌های بین لایه ورودی و لایه بعدی ضرب شده و به سلول‌های لایه بعدی منتقل می‌شوند. در لایه بعدی تمام ورودی‌هایی که به هر نرون وارد می‌شوند با هم جمع شده و بعضی اوقات مقدار ثابتی به نام بایاس به آن اضافه می‌گردد [۱۶]. مجموع به دست آمده، همان ورودی خالص نرون ( $h_j$ ) می‌باشد که به صورت رابطه (۳) قابل بیان می‌باشد:

$$h_j = \sum_{i=1}^N W_{ij} X_i + b_j \quad (3)$$

به طوری که  $X_i$  سیگنال ورودی  $i$  ام به نرون  $j$  ام،  $W_{ij}$  وزن سیگنال  $i$  ام به نرون  $j$  ام،  $b_j$  مقدار بایاس برای نرون  $j$  ام و  $N$  تعداد نرون‌های لایه قبل است. ورودی خالص نرون از تابعی به نام تابع فعالیت در نرون مورد نظر می‌گذرد تا خروجی نرون  $a$  به دست آید. این تابع به صورت رابطه (۴) می‌باشد:

$$a_j = f(h_j) \quad (4)$$

## ۲-۴- شبکه‌های پرسپترون چند لایه (MLP)

یکی از ساده‌ترین و در عین حال کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی عصب‌های واقعی، مدل پرسپترون چندلایه (MLP) می‌باشد که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. در این ساختار، تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصل هستند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می‌دهد. آموزش این گونه شبکه‌ها معمولاً با روش پس انتشار خطا انجام می‌شود که یکی از پرکاربردترین مدل‌های شبکه عصبی در مدل‌سازی و پیش‌بینی آلاینده‌های هوا می‌باشد [۱۷]. با توجه به عملکرد مطلوب شبکه‌های پرسپترون چند لایه پیشخور در مسائل پیش‌بینی و قابلیت بالای آن‌ها در تعمیم

پیش‌بینی شده و مقادیر واقعی برابر ۰/۹۲ و ۰/۸۶ به ترتیب برای آبان و شهریور به دست آمده است. مقادیر بیشینه و کمینه حداکثر خطای مطلق برای این آلاینده معادل ۲/۲۸ و ۰/۴۴ به ترتیب مربوط به بهمن و تیر بوده است. همچنین، مقادیر بیشینه و کمینه MSE برابر با ۲۰/۰۵ و ۰/۴۹ به ترتیب مربوط به آذر و مهر محاسبه شده است. مقادیر بیشینه و کمینه RMSE نیز به ترتیب مربوط آذر (۴/۴۷) و مهر (۰/۷) بوده است.

بررسی نتایج کارایی شبکه در پیش‌بینی آلاینده NO<sub>x</sub> نیز نشان داد که بیش‌ترین و کمترین ضریب همبستگی بین مقادیر پیش‌بینی شده و مقادیر واقعی با مقادیر ۰/۸۳ و ۰/۷۴ به ترتیب مربوط به فروردین و آبان ماه می‌باشد. مقادیر بیشینه و کمینه حداکثر خطای مطلق برای این آلاینده به ترتیب مربوط به آذر (۱۳/۵۶) و فروردین (۳/۱۶) می‌باشد. همچنین، بیشینه و کمینه MSE برای این آلاینده به ترتیب مربوط به بهمن (۱۳۹۸) و فروردین (۲۳/۶) می‌باشد. مقادیر بیشینه و کمینه RMSE نیز به ترتیب مربوط به بهمن (۱۹/۹) و فروردین (۴/۸۶) می‌باشد.

در مطالعه ارحمی و همکاران، مجموع مقادیر بهینه  $R^2$ ، MAE و RMSE در پیش‌بینی غلظت CO به ترتیب ۰/۹۵، ۰/۲۸ و ۰/۶۹ و در پیش‌بینی غلظت NO<sub>x</sub> به ترتیب ۰/۷۹۵، ۱۵/۷۶ و ۲۱/۰۶ به دست آمده است [۱۳]. همچنین، در مطالعه Viotti و همکاران (۲۰۰۲) پیش‌بینی غلظت CO و NO<sub>x</sub> با استفاده از شبکه عصبی با مقادیر MSE کمتر از ۱۰ درصد گزارش شده است [۱۸].

نمودار همبستگی بین داده‌های پیش‌بینی شده و داده‌های واقعی برای آلاینده‌های CO، SO<sub>2</sub> و NO<sub>x</sub> به ترتیب در شکل (۲)، (۳) و (۴) ارائه شده است. این نمودارها ارتباط بین داده‌های ورودی و خروجی شبکه عصبی را به صورت یک معادله درجه اول نشان داده و میزان انحراف معیار از نیم‌ساز ربع اول را نیز ارائه نموده‌اند. در واقع، هرچه داده‌ها به نمودار یک به یک نزدیک‌تر باشند نشان دهنده توانایی بیشتر مدل در پیش‌بینی غلظت آلاینده‌ها خواهد بود. نتایج بررسی خروجی مجموعه‌های آموزشی، ارزیابی و تست نشان دهنده مقادیر  $R$  برای CO و SO<sub>2</sub> برابر ۰/۹۶ و برای NO<sub>x</sub> معادل ۰/۹۴ بوده است. بالا بودن مقادیر  $R$  برای مجموعه‌های آموزشی، ارزیابی و تست نشان دهنده مناسب بودن عکس‌العمل شبکه در این مطالعه بوده که می‌توان با استناد به آن و به کارگیری تابع sim در مورد ورودی-های جدید نیز شبیه‌سازی انجام داد.

$$MSE = \frac{1}{N} \sum (P_i - O_i)^2 \quad (5)$$

$$RMSE = \left[ \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \right]^{1/2} \quad (6)$$

$$MAE = \frac{1}{N} \sum |P_i - O_i| \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N [O_i - P_i]^2}{\sum_{i=1}^N [O_i - \bar{O}]^2} \quad (8)$$

که  $N$  شمار داده‌ها،  $O_i$  داده‌های اصلی،  $P_i$  مقادیر پیش‌بینی و  $\bar{O}$  میانگین داده‌های اصلی می‌باشد.  $R^2$  یکی از شاخص‌های مهم در ارزیابی شبکه عصبی می‌باشد که بیان‌کننده میزان همبستگی بین نتایج پیش‌بینی شده مدل و داده‌های واقعی است. بدیهی است که هر چقدر مقدار آن به یک نزدیک‌تر باشد، نشان دهنده نزدیکی بیشتر مقادیر پیش‌بینی شده به مقادیر واقعی خواهد بود.

### ۳- نتایج و بحث

از آن‌جایی که هیچ شبکه عصبی با ساختار اطلاعاتی مشخص را نمی‌توان به طور عمومی به عنوان مناسب‌ترین شبکه در نظر گرفت، شبکه‌ها براساس سعی و خطاهای مکرر انتخاب و با معیارهای مختلف ارزیابی می‌شوند. نتایج حاصل از مدل‌سازی غلظت آلاینده‌های مورد مطالعه با استفاده از مدل شبکه عصبی مصنوعی در جدول (۲) ارائه شده است. بر این اساس، نتایج بررسی کارایی شبکه در پیش‌بینی غلظت مونوکسیدکربن نشان می‌دهد که بیشترین و کمترین مقادیر ضریب همبستگی ( $R^2$ ) بین مقادیر پیش‌بینی شده و مقادیر واقعی برابر ۰/۹۳ و ۰/۸۶ به ترتیب مربوط به داده‌های خرداد و مهر می‌باشد. این نتایج، نشان دهنده همبستگی خوب بین غلظت آلاینده‌های حاصل از مدل-سازی و اندازه‌گیری بوده است. همچنین، بیشینه و کمینه حداکثر خطای مطلق (MAE) برای این آلاینده در ماه‌های فروردین و مهر به ترتیب ۰/۶۵ و ۰/۲۵، بیشینه و کمینه میانگین مربعات خطا (MSE) به ترتیب ۰/۱۸ و ۱/۲، بیشینه و کمینه جذر میانگین مجذور خطا (RMSE) به ترتیب ۰/۴۲ و ۱/۱۱ بوده است.


با بررسی نتایج کارایی شبکه در پیش‌بینی SO<sub>2</sub> مشاهده می‌شود که بیشترین و کمترین ضریب همبستگی بین مقادیر

جدول ۲- نتایج بررسی کارایی شبکه در پیش‌بینی غلظت  $CO$ ،  $SO_2$  و  $NO_x$

Y	$R^2$	RMSE	MSE	MAE	ماه	آلاینده
$Y=0.792X+0.101$	۰/۹۳	۰/۴۲	۰/۱۸	۰/۲۵	۱	CO
$Y=0.966X+0.138$	۰/۹۲	۰/۴۹	۰/۲۴	۰/۲۸	۲	
$Y=0.972X+0.108$	۰/۹۱	۰/۴۹	۰/۲۴	۰/۳۲	۳	
$Y=0.964X+0.096$	۰/۹۲	۰/۴۴	۰/۱۹	۰/۲۵	۴	
$Y=0.972X+0.101$	۰/۹۱	۰/۴۷	۰/۲۲	۰/۳۰	۵	
$Y=0.976X+0.073$	۰/۸۷	۰/۷۲	۰/۵۲	۰/۴۸	۶	
$Y=0.948X+0.258$	۰/۸۶	۱/۱۱	۱/۲	۰/۶۵	۷	
$Y=0.972X+0.118$	۰/۸۹	۰/۷۳	۰/۵۴	۰/۴۸	۸	
$Y=0.970X+0.119$	۰/۹۱	۰/۶۹	۰/۴۷	۰/۴۳	۹	
$Y=0.980X+0.080$	۰/۹۱	۰/۵۷	۰/۳۱	۰/۳۷	۱۰	
$Y=0.974X+0.114$	۰/۹۲	۰/۵۶	۰/۳۶	۰/۳۵	۱۱	
$Y=0.951X+0.176$	۰/۸۹	۰/۷۷	۰/۶۶	۰/۴۰	۱۲	
$Y=0.963X+0.232$	۰/۸۸	۱/۸	۳/۳	۱/۲۲	۱	SO <sub>2</sub>
$Y=0.982X+0.101$	۰/۸۷	۱/۹۴	۳/۷۷	۱/۳۳	۲	
$Y=0.955X+0.291$	۰/۹۰	۲/۱۴	۴/۶۱	۱/۱۹	۳	
$Y=0.962X+0.209$	۰/۸۸	۰/۷۰	۰/۴۹	۰/۴۴	۴	
$Y=0.987X-0.004$	۰/۸۸	۱/۹	۳/۶۲	۱/۲۸	۵	
$Y=0.940X+0.594$	۰/۸۶	۲/۴۵	۰/۶	۱/۱۹	۶	
$Y=0.967X+0.247$	۰/۹	۱/۷	۳/۰۹	۰/۹۹	۷	
$Y=0.954X+0.389$	۰/۹۲	۲/۷۰	۷/۳	۱/۴۵	۸	
$Y=0.976X+0.375$	۰/۹۱	۴/۴۷	۲۰/۰۵	۲/۲۷	۹	
$Y=0.949X+0.826$	۰/۹۰	۴/۲۵	۱۸/۹	۱/۸۷	۱۰	
$Y=0.954X+0.748$	۰/۸۸	۳/۸۰	۱۴/۴۶	۲/۲۸	۱۱	
$Y=0.969X+0.386$	۰/۹۰	۲/۵۶	۶/۵۷	۲/۶۳	۱۲	
$Y=0.983X+0.528$	۰/۸۳	۴/۸۶	۲۳/۶۸	۳/۱۶	۱	NO <sub>x</sub>
$Y=0.932X+2.963$	۰/۸۲	۱۵/۶۱	۲۴۳/۹۷	۹/۴۴	۲	
$Y=0.909X+3.210$	۰/۷۴	۱۴/۵۶	۲۱۲/۲۰	۹/۵۹	۳	
$Y=0.924X+2.121$	۰/۷۸	۱۱/۹۰	۱۴۱/۷۰	۸/۱۴	۴	
$Y=0.938X+2.060$	۰/۸۰	۱۱/۲۶	۱۲۶/۹	۷/۰۲	۵	
$Y=0.929X+1.983$	۰/۷۸	۱۱/۶۰	۱۳۴/۶۳	۷/۴۵	۶	
$Y=0.922X+2.782$	۰/۸۲	۱۰/۲۵	۱۰۵/۱۵	۶/۳۲	۷	
$Y=0.941X+2.250$	۰/۷۴	۱۴/۶۳	۲۱۴/۲۰	۱۰	۸	
$Y=0.948x+4.011$	۰/۷۷	۱۹/۷۸	۳۹۱/۵۹	۱۳/۵۶	۹	
$Y=0.933X+5.772$	۰/۷۹	۱۹/۸۶	۳۹۴/۶۶	۱۳/۰۹	۱۰	
$Y=0.952X+3.349$	۰/۷۷	۱۹/۹۵	۳۹۸/۰۴	۱۳/۳۴	۱۱	
$Y=0.939X+3.811$	۰/۸۲	۷۷/۰۱	۲۸۹/۴۶	۱۰/۷۴	۱۲	

احتراق سوخت در وسایل نقلیه می‌باشد. بنابر این در نظر گرفتن پارامتر ساعت از روز و روز از هفته که منجر به در نظر گرفته شدن نوسانات حجم ترافیک شده است، باعث افزایش کارایی مدل در پیش‌بینی غلظت این آلاینده گشته است. به طوری که با حذف متغیرهای ذکر شده از فرایند یادگیری (ساعت از روز و روز از هفته) ضریب همبستگی به شدت کاهش می‌یابد. با توجه به مطالب ذکر شده، واضح است که استفاده از شاخصی بهتر برای

در مجموع، با توجه به بررسی نتایج پیش‌بینی کارایی شبکه برای آلاینده‌های مورد مطالعه و همچنین پارامترهای ارزیابی مشخص گردید که شبکه عصبی مصنوعی مورد مطالعه در پیش‌بینی غلظت منواکسیدکربن نتایج بهتری را نسبت به دو آلاینده دیگر ارائه می‌دهد (ضریب همبستگی بالای ۰/۹۳). دلیل این امر را می‌توان به منبع و نوع تولید CO نسبت داد. این آلاینده در شهر تبریز و در مجاورت ایستگاه مورد مطالعه، عمدتاً حاصل از




شکل ۴- نمودار همبستگی بین مقادیر پیش‌بینی شده و مقادیر واقعی غلظت NO<sub>x</sub>


#### ۴- نتیجه‌گیری

آلودگی هوای شهر تبریز به دلیل استقرار صنایع در جنوب غرب، تردد وسایط نقلیه و توپوگرافی ویژه منطقه از مهم‌ترین مشکلات این شهر به حساب می‌آید. از این رو، پیش‌بینی غلظت آلاینده‌ها در اتخاذ تصمیمات لازم برای پیشگیری و کاهش اثرات زیان‌بار آن از اهمیت بسزایی برخوردار است. لذا، هدف از این تحقیق پیش‌بینی غلظت آلاینده‌های گازی شامل CO، SO<sub>2</sub> و NO<sub>x</sub> با استفاده از روش شبکه‌های عصبی مصنوعی می‌باشد. شبکه‌های عصبی مصنوعی در واقع سیستم‌های موازی هستند که می‌توان از آن‌ها برای تشخیص الگوهای پیچیده در میان داده‌ها استفاده کرد. این شبکه‌ها در تشخیص الگوها و نیز زمانی که اطلاعات در دسترس برای تفسیر کافی نباشد، می‌توانند ابزاری سودمند باشند. از آنجایی که تعداد نرون‌های لایه ورودی تابعی از عوامل مؤثر بر خروجی مورد نظر هستند، بنابراین در گزینش متغیرهای ورودی به گونه‌ای عمل شده است که بیشتر عوامل مؤثر بر خروجی پوشش داده شوند. تعیین نرون‌های موجود در لایه میانی کاملاً به تجربه و تکرار شبکه با تعداد نرون‌های مختلف وابسته است، به گونه‌ای که در این مطالعه پس از امتحان تعداد نرون‌های مختلف در لایه میانی، شبکه با ۲۵ نرون بهترین نتیجه را در برداشت. همچنین با تأثیر دیده شده از دیگر عوامل بر روی کارکرد شبکه مانند شکل داده‌های ورودی، نوع تابع انتقال و دیگر متغیرهای بررسی شده برای دستیابی به یک برآورد مناسب، این متغیرها نیز در طراحی شبکه مورد توجه قرار گرفت که انواع مناسب این طراحی‌ها منجر به ساختار بهینه شبکه شد. نتایج به دست آمده در این تحقیق نشان دهنده دقت بالای شبکه عصبی در پیش‌بینی غلظت آلاینده‌ها بوده است.

حجم ترافیک، کارایی مدل را افزایش خواهد داد. بر خلاف CO، میزان غلظت NO<sub>x</sub> تحت تأثیر واکنش‌های شیمیایی اتمسفر قرار دارد و پارامتری که به صورت مستقیم بیانگر این واکنش‌ها باشد در متغیرهای ورودی در نظر گرفته شده موجود نمی‌باشد. به عنوان مثال میزان غلظت NO<sub>x</sub> تحت تأثیر شدت تابش آفتاب و غلظت ازن قرار دارد. واکنش فوتولیز NO<sub>2</sub> ( $NO_2 + hv \rightarrow O + NO$ ) که در حضور نور خورشید و در طول روز رخ می‌دهد، با تولید رادیکال اکسیژن و طی واکنش ( $O + O_2 + M \rightarrow O_3 + M$ ) منجر به تولید ازن می‌شود. واکنش ( $O_3 + NO \rightarrow O_2 + NO_2$ ) که اصطلاحاً واکنش تیراسیون نامیده می‌شود و در طول شب و روز نیز رخ می‌دهد باعث حذف و تعادل ازن می‌شود [۱۹]. بنابر این انتظار می‌رود در صورت وجود داده‌های مربوط به غلظت ازن و در نظر گرفتن غلظت این آلاینده به عنوان متغیر ورودی، کارایی مدل در پیش‌بینی میزان NO<sub>x</sub> غلظت افزایش یابد. با این حال کارایی مدل‌های ارائه شده در این تحقیق برای NO<sub>x</sub> قابل قبول می‌باشد.



شکل ۲- نمودار همبستگی بین مقادیر پیش‌بینی شده و مقادیر واقعی غلظت CO



شکل ۳- نمودار همبستگی بین مقادیر پیش‌بینی شده و مقادیر واقعی غلظت SO<sub>2</sub>

- Network Approach", Transportation Research, 2009, 14, 32-41.
- [10] Hrust, L., Klaic, Z. B., Krizan, J., Antonic, O., Hercog, P., "Neural Network Forecasting of Air Pollutants Concentrations Using Optimized Temporal Averages of Meteorological Variables and Pollutant Concentrations", Atmospheric Environment, 2009, 43, 5588-5596.
- [11] Mousavi, M. S., Rahimi, A., "The Application of Artificial Neural Network in Prediction of CO Concentration: A case study of Tabriz", Iranian Journal of Natural Resources, 2008, 61 (3), 681-691.
- [12] Bodaghpour, S., Charkhestani, A., "Prediction of Gas Pollutants Concentration by Means of Artificial Neural Network in Tehran Urban Air", Journal of Environmental Science and Technology, 2011, 13 (1), 1-10.
- [13] Arhami, M., Kamali, N., Rajabi, M. M., "Predicting Hourly Air Pollutant Levels Using Artificial Neural Networks Coupled with Uncertainty Analysis by Monte Carlo Simulations", Environmental Science and Pollution Research, 2013, 20, 4777-4789.
- [14] Shakerkhatibi, M., Mohammadi, N., Zoroufchi Benis, K., Behrooz Sarand, A., Fatehifar, E., Asl Hashemi, A., "Using ANN and EPR Models to Predict Carbon Monoxide Concentrations in urban Area of Tabriz", Environmental Health Engineering and Management Journal, 2015, 2, 117-122.
- [15] Shahin, M. A., Jaksa, M. B., Maier, H. R., "State of the Art of Artificial Neural Networks in Geotechnical Engineering", Electronic Journal of Geotechnical Engineering, 2008, 8, 1-26.
- [16] Giustolisi, O., Doglioni, A., Savic, D. A., Webb, B. W., "A Multi-Model Approach to Analysis of Environmental Phenomena", Environmental Modelling and Software, 2007, 22, 674-682.
- [17] Demuth, H., Beale, M., "Neural Network Toolbox users Guide", Copyright 1992-2002, by the Math Works, Inc, Version 4, 840PP.
- [18] Viotti, P., Liuti, G., Di Genova, P., "Atmospheric Urban Pollution: Applications of an Artificial Neural Network (ANN) to the City of Perugia", Ecological Modeling, 2002, 148, 27-46.
- [19] Calvert, J. G., Orlando, J. J., Stockwell, W. R., Wallington, T. J., "The Mechanisms of Reactions Influencing Atmospheric Ozone", 2015, Oxford University Press.
- ۵- تشکر و قدردانی**
- این مطالعه با حمایت معاونت تحقیقات و فناوری دانشگاه علوم پزشکی تبریز انجام شده است. داده‌های مورد استفاده از ادارات کل محیط زیست و هواشناسی استان آذربایجان شرقی تهیه شده که نویسندگان مقاله از این ادارات تشکر و قدردانی می‌نمایند.
- ۶- مراجع**
- [1] Karaca, F., Nikov, A., Alagha, O., "NN-Airpol: A Neural-Networks-Based Method for Air Pollution Evaluation and Control", International Journal of Environment and Pollution, 2006, 28 (3/4), 310-325.
- [2] WHO, "Fact Sheet on Outdoor Air Pollution (No 313): Air Quality and Health", <http://www.who.int/mediacentre/factsheets/fs313/en/index.html>, 2008.
- [3] Anderson, H. R., "Air Pollution and Mortality: A History", Atmospheric Environment, 2009, (43), 142-152.
- [4] Jiang, D., Zhang, Y., Hu, X., Zeng, Y., Tan, J., Shao, D., "Progress in Developing an ANN Model for Air Pollution Index Forecast", Atmospheric Environment, 2004, 38 (40), 7055-7064.
- [5] Boznar, M., Lesjak, M., Mlakar, P., "A Neural Network-Based Method for Short-Term Prediction of Ambient SO<sub>2</sub> Concentrations in Highly Polluted Industrial Areas of Complex Terrain", Atmospheric Environment, 1993, 27B (2), 221-230.
- [6] Gardner, M. W., Dorling, S. R., "Neural Network Modeling and Prediction of Hourly NO<sub>x</sub> and NO<sub>2</sub> Concentrations in Urban Air in London", Atmospheric Environment, 1993, 33, 709-719.
- [7] Postolache, O., Girao, M., Pereira, M., "Neural Network Application in a Carbon Monoxide Measurement System", International Joint Conference on Neural Network, 2001, 3, 2076-2081.
- [8] Hooyberghs, J., Mensink, C., Dumont, G., Fierens, F., Basseur, O., "Neural Network Forecast for Daily Average PM<sub>10</sub> Concentrations in Belgium", Atmospheric Environment, 2005, 39, 3279-3289.
- [9] Ming, C., Yafeng, Y., Min, X., "Prediction of Hourly Air Pollutant Concentrations near Urban Arterials Using Artificial Neural



**EXTENDED ABSTRACT**

## Forecasting Concentrations of Gaseous Air Pollutants Using Artificial Neural Networks in Tabriz

Nahideh Mohammadi<sup>1</sup>, Khaled Zoroufchi Benis<sup>2</sup>, Mohammad Shakerkhatibi<sup>3,\*</sup>, Esmaeil Fatehifar<sup>2</sup>, Alireza Behrooz Sarand<sup>4</sup>, Amir Mahmoudian<sup>1</sup>, Farid Sheikholeslami<sup>1</sup>

<sup>1</sup> Student Research Committee, Tabriz University of Medical Sciences

<sup>2</sup> Faculty of Chemical Engineering, Environmental Engineering Research Center, Sahand University of Technology

<sup>3</sup> Department of Environmental Health Engineering, Tabriz University of Medical Sciences

<sup>4</sup> Department of Chemical Engineering, Urmia University of Technology

**Received:** 18 October 2015; **Accepted:** 22 February 2016

---

### Keywords:

Air pollution, Artificial neural network, Forecasting

---

### 1. Introduction

Today, air pollution is considered as an important and challenging problem in the megacities all over the world. It is usually caused due to industrialization, urbanization, rapid development in traffic and increasing amounts of anthropogenic emissions. Urban air pollution in developing countries has been represented as a growing problem for communities. Reliable forecasting of air pollution would allow taking more efficient countermeasures to prevent air pollution crisis and protect public health. The artificial Neural Network (ANN) has emerged out to be more flexible, less assumption dependent and adaptive methodology to obtain reliable prediction values of air pollutants. ANNs have been shown to be quite powerful in capturing the complex and usually nonlinear relationships between meteorological variables and air pollutant concentrations [1-3].

### 2. Methodology

#### 2.1. Description of study area

This paper focuses on applying an ANN approach for forecasting CO, SO<sub>2</sub> and NO<sub>x</sub> concentration in Tabriz. Tabriz, located in the northwest of Iran, the capital city of East Azerbaijan lies at 46.13 east and 38.8 north with an altitude of 1351 m above the sea level. It has a semi-arid climate with annual precipitation around 380 mm and the mean, maximum and minimum temperatures are 13, 38 and -15°C, respectively.

#### 2.2. Model inputs

Selection of the model input variables that have the most significant impact on model performance is the most important step in developing an ANN model [1, 4]. The effective meteorological parameters which are predictable by conventional weather forecasting were selected considering the similar studies. The selected meteorological variables included wind speed and direction, air temperature and relative humidity were obtained from the East Azerbaijan Meteorological Bureau. Also, the time of day and day of week were considered as the input variables to cover the changes in traffic patterns during the day time and week days. The current study is based on data collected at a single station (i.e., Meydan Namaz station) in the densely populated center of Tabriz, surrounded by several

---

\* Corresponding Author

E-mail addresses: mohammadinahideh@yahoo.com (Nahideh Mohammadi), kh.zoroufchi.b@gmail.com (Khaled Zoroufchi Benis), shakerkhatibim@tbzmed.ac.ir (Mohammad Shakerkhatibi), fatehifar@gmail.com (Esmaeil Fatehifar), alireza.behroozsarand@gmail.com (Alireza Behrooz Sarand), amirmahmoudian1990@gmail.com (Amir Mahmoudian), f.sheikholeslami@yahoo.com (Farid Sheikholeslami).

major streets with heavy traffic. The Multilayer Perceptrons (MLP) neural networks, was used in the current study to predict hourly pollutant levels. The settings of ANN are presented in Table 1. The pollutants concentrations dataset were divided into 3 subsets, namely training (70%-80% of all), validation (10%-15% of all) and a test set (10%-15% of all) as an input for the ANN. The network overflow can occur as a result of very large or very small values of input variables [5]. In order to overcome this problem, all meteorological and pollutant values as model input were normalized.


**Table 1.** The settings of the ANN

Train parameter	Value
Train function	Train lm
Divide function	Divide rand
Train ratio	0.7-0.8
Valid ratio	0.1-0.15
Performance function	MAE
Validation checks	300
Number of epochs	10000
Number of layers	3-5
Number of neurons	8-25


### 3. Results and discussion

The results showed the reliability of ANN in forecasting of hourly air pollutants in urban areas. High correlations were obtained with  $R^2$  values more than 0.90 between the observed and modeled values for CO, SO<sub>2</sub> and NO<sub>x</sub>. The maximum and minimum values of  $R^2$  between real and modeled values of CO were obtained 0.93 and 0.86 respectively. Accordingly, the maximum and minimum values of  $R^2$  between real and modeled values of SO<sub>2</sub> were obtained 0.92 and 0.86 respectively. Also, the maximum and minimum values of  $R^2$  between real and modeled values of NO<sub>x</sub> were obtained 0.83 and 0.74 respectively. According to the results, the best correlations were achieved for CO and SO<sub>2</sub> and the poor agreement between real and ANN prediction results were obtained for NO<sub>x</sub>.

In comparison with CO and SO<sub>2</sub> levels, NO<sub>x</sub> levels are more affected by atmospheric reactions. The considered input variables may not fully cover these reactions which lead to rather less accurate predictions [1]. However, the predicted NO<sub>x</sub> concentrations are still in a good agreement with their measured corresponding concentrations. Fig. 1 to 3 illustrate the predicted vs. observed concentrations for CO, SO<sub>2</sub> and NO<sub>x</sub> respectively.



**Fig. 1.** Predicted vs. observed concentration for CO



**Fig. 2.** Predicted vs. observed concentration for SO<sub>2</sub>




Fig. 3. Predicted vs. observed concentration for NOx

#### 4. Conclusions

ANN models can be used as reliable forecasting method for the prediction of hourly air pollutants in urban areas. Selection of optimal setting for ANN and also normalization of input variables will lead to proper forecasting models with acceptable error. The produced information from the provided models could be helpful for decision makers in dealing with air quality problems. Also proper selection of input parameters and model architecture has an important role in the construction of these models.

#### 5. References

- [1] Arhami, M., Kamali, N., Rajabi, M. M., "Predicting Hourly Air Pollutant Levels Using Artificial Neural Networks Coupled with Uncertainty Analysis by Monte Carlo Simulations", *Environmental Science and Pollution Research*, 2013, 20, 4777-4789.
- [2] Cai, M., Yafeng, Y., Min, X., "Prediction of Hourly Air Pollutant Concentrations Near Urban Arterials Using Artificial Neural Network Approach", *Transportation Research Part D: Transport and Environment*, 2009, 14, 32-41.
- [3] Shakerkhatibi, M., Mohammadi, N., Zoroufchi Benis, k., Behrooz Sarand, A., Fatehifar, E., Asl Hashemi, A., "Using ANN and EPR Models to Predict Carbon Monoxide Concentrations in Urban Area of Tabriz", *Environmental Health Engineering and Management Journal*, 2015, 2, 117-122.
- [4] Barai, S. V., Dikshit, A. K., Sharma, S., "Neural Network Models for Air Quality Prediction: A Comparative Study", *Soft Computing in Industrial Applications*, 2007, 290-305.
- [5] Gardner, M. W., Dorling, S. R., "Neural Network Modelling and Prediction of Hourly NOx and NO<sub>2</sub> Concentrations in Urban Air in London", *Atmospheric Environment*, 1999, 33, 709-719.