

## مدل سازی خطی و غیر خطی آلاینده های هوای شهر تهران با استفاده از خصیصه های محیطی و ترافیک

محمدرضا عبودی<sup>۱</sup>، جلال کرمی<sup>۲\*</sup>، علی شمس الدینی<sup>۳</sup>

۱- دانشجوی کارشناسی ارشد سنجش از دور و سیستم اطلاعات جغرافیایی، گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم انسانی دانشگاه تربیت مدرس

۲- استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم انسانی دانشگاه تربیت مدرس

۳- استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم انسانی دانشگاه تربیت مدرس

### چکیده:

در سال های اخیر، آلودگی هوای تهران، به عنوان پایتخت ایران، به صورت یک چالش، تهدیدی جدی برای سلامت انسان ها و عناصر محیط زیست، مطرح گردیده است. به منظور ارتقاء شاخص های کیفیت زندگی، از جمله سطح سلامت، بخصوص در کلان شهرها از جمله تهران، درک صحیحی از آلودگی هوا به منظور حفظ محیط زیست شهری و طراحی سیاست های کلان در کشور مورد نیاز می باشد. برای رسیدن به این هدف، پیش بینی کوتاه مدت آلودگی هوا ضروری می باشد. هدف از این پژوهش، طراحی یک شبکه عصبی مصنوعی بهینه به عنوان یک مدل غیر خطی و مقایسه عملکرد آن با عملکرد رگرسیون خطی چندمتغیره به عنوان یک مدل خطی، به منظور پیش بینی مقادیر منواکسید کربن و دی اکسید نیتروژن بود. بدین منظور، کارایی ویژگی های محیطی و ترافیک مورد بررسی قرار گرفتند. نتایج به دست آمده نشانگر دقت بیشتر مدل پیش بینی کننده دی اکسید نیتروژن نسبت به مدل پیش بینی کننده منواکسید کربن بود. همچنین به منظور پیش بینی غلظت منواکسید کربن، شبکه عصبی پرسپترون چندلایه نسبت به مدل رگرسیون خطی چندمتغیره، از لحاظ آماری دقت بالاتری را نشان داد، در حالی که اختلاف معنی داری بین این مدل ها برای پیش بینی دی اکسید نیتروژن وجود نداشت.

واژه های کلیدی: مدل سازی آلودگی هوا، دی اکسید نیتروژن، منواکسید کربن، خصیصه های محیطی، ترافیک



## ۱- مقدمه

بهبود کیفیت هوا، حفاظت از سلامت جامعه و ایجاد رفاه اجتماعی از جمله برنامه‌های بنیادین در هر کشور محسوب می‌گردند. در دهه‌های اخیر، دولت‌ها خود را به توسعه پایدار از طریق توجه به رفاه اقتصادی، حفظ محیط‌زیست و انسجام اجتماعی متعهد کرده‌اند [۱]. توسعه پایدار، پاسخ مؤثری را برای نیازها و منافع اجتماعی و اقتصادی مردم فراهم می‌کند و به تناسب آن خطرات و تهدیدات زیست‌محیطی را کاهش می‌دهد. از مهم‌ترین آسیب‌های زیست‌محیطی که تهدیدی جدی برای سلامت انسان به شمار می‌آید، آلودگی هوا می‌باشد [۲]. آلودگی هوا منجر به بی‌ثباتی، و آثار زیان‌آور و نامطلوب در محیط‌زیست می‌شود [۳ و ۴]. اکثر شهرهای بزرگ کشورهای در حال توسعه، به‌طور فزاینده‌ای با آلودگی هوا به‌عنوان عاملی تأثیرگذار بر کیفیت زندگی و سلامت عمومی جامعه مواجه هستند [۵]. آلودگی هوای شهری متأثر از شرایط اقلیمی (موقعیت جغرافیایی، میزان دما، رطوبت هوا، وزش باد، میزان بارندگی)، افزایش جمعیت و رشد سریع شهرنشینی، منابع آلوده‌کننده، استفاده بیش‌ازحد از سوخت‌های فسیلی و ترافیک در شهرها و الگوی نامناسب سیستم‌های حمل‌ونقل می‌باشد و به یک نگرانی قابل توجه بدل گشته است [۳ و ۶ و ۷].

بر طبق گزارش اتحادیه اروپا، آلودگی هوای شهری تا سال ۲۰۵۰، جایگاه بالاتری را در مسائل زیست‌محیطی نسبت به بحران کمبود آب و بهداشت محیطی کسب خواهد کرد [۲]. غلظت بالای آلاینده‌ها باعث ایجاد اثراتی سوء بر سلامت انسان و حتی مرگ زودرس در میان گروه‌های حساس مانند افراد مبتلا به آسم و افراد مسن می‌گردد [۸]. همچنین مطابق گزارش سازمان بهداشت جهانی، آلودگی هوا باعث مرگ حدود ۳/۷ میلیون نفر در سن زیر ۶۰ سال در سال ۲۰۱۲ شده است [۲]. شناسایی، کنترل و کاهش آلاینده‌های هوا در دوره‌های زمانی و موقعیت‌های مکانی متفاوت به‌منظور ارتقای شاخص‌های کیفیت زندگی و حفظ محیط‌زیست از رویکردهای مدیریت جامع شهری جهت سیاست‌گذاری‌های کلان در سطح کشور محسوب می‌شود. داشتن تصویری روشن از آینده‌ی وضعیت آلودگی هوا بی‌تردید کمک بسیاری به برنامه‌ریزی و تصمیم‌سازی در جهت جلوگیری از وقوع بحران زیستی و یا کاهش اثرات مخرب آن می‌نماید. همچنین با در اختیار داشتن چنین ابزاری امکان ارزیابی و سنجش اثرات سیاست‌های کاهش آلودگی هوا نیز وجود دارد. مطالعه بر روی روند گذشته کیفیت هوا، می‌تواند معیاری برای ارزیابی اقدامات انجام‌گرفته در زمینه کنترل آلودگی هوا و برنامه‌ریزی برای کاهش آلودگی هوا در آینده فراهم آورد [۹]. به‌منظور برنامه‌ریزی برای کاهش آلودگی هوا و اعمال سیاست‌های کنترلی، تصمیم‌سازان و مدیران شهری و زیست‌محیطی، نیازمند ابزاری برای پیش‌بینی غلظت آلاینده‌های هوا می‌باشند. یکی از مهم‌ترین اقدامات در زمینه کاهش آلودگی هوا، پیش‌بینی مقادیر غلظت آلاینده‌ها می‌باشد که این امر به علت پیچیدگی فرآیند و دخالت عوامل غیرقطعی در آن، مشکلاتی را به همراه دارد. پیش‌بینی کوتاه‌مدت کیفیت هوا به‌منظور اقدامات پیشگیرانه آلودگی هوا مورد نیاز است [۱۰]. از این‌رو در دهه‌های اخیر، توجه زیادی به مدل‌هایی شده است که قابلیت ارتباط مستقیم بین داده‌های ورودی و خروجی بدون نیاز به درک کامل از فرآیند را فراهم آورند. این مدل‌ها برای برآورد جریان، زمانی که هدف اصلی، پیش‌بینی با دقت بالا باشد بسیار سودمند است [۶]. مدل‌های پیش‌بینی کیفیت هوا، نقش مهمی در تمام جنبه‌های کنترل آلودگی هوا که در آن پیش‌بینی، یک جزء اصلی است، ایفا می‌کنند [۱۱]. طیف گسترده‌ای از سیستم‌های هشداردهنده آلودگی هوای اساسی مدل‌های تجربی، آماری و ترکیبی به‌منظور اقدامات پیشگیرانه توسعه یافته‌اند.

شهر تهران یکی از بزرگ‌ترین و آلوده‌ترین شهرهای جهان می‌باشد. در سال‌های اخیر، آلودگی هوای تهران به‌عنوان یک چالش جدی مطرح شده است تا جایی که آلودگی هوای تهران در روزهای زیادی از سال بیشتر از استانداردهای کیفیت هوا می‌باشد [۳]. انتشار روزافزون آلاینده‌ها از منابع متحرک و گردش هوای ضعیف که ناشی از شرایط جغرافیایی و آب و هوایی می‌باشد، مهم‌ترین عامل آلودگی زیاد این شهر می‌باشد. شرایط کیفیت هوای شهر تهران، توسط منابع آلاینده صنعتی، تجاری، مسکونی و سیستم حمل‌ونقل گسترده و قدیمی، تحت تأثیر قرار می‌گیرد [۳ و ۱۲]. بنابراین این شهر توسط انتشار گازهای تولیدشده، احاطه شده و معمولاً یک‌لایه ضخیم از ذرات معلق در هوا یافت می‌شود [۳]. با توجه به



اثرات زیان‌بار آلودگی هوا بر سلامت مردم و محیط‌زیست و همچنین صرف هزینه‌های زیاد برای جبران خسارات ناشی از آلودگی هوا، توجه به این معضل زیست‌محیطی اهمیت فراوانی دارد.

در میان آلاینده‌های عمده شهر تهران منواکسید کربن و دی‌اکسید نیتروژن دارای اهمیت زیادی از نظر تأثیر بر سلامت انسان‌ها دارند. منواکسید کربن (CO)، یکی از فراوان‌ترین و گسترده‌ترین آلاینده‌های هوا است که در اتمسفر یافت می‌شود. منواکسید کربن گازی بی‌رنگ، بی‌بو و غیر محرک است که در نتیجه اکسایش ناقص کربن در حین احتراق به وجود می‌آید. منابع اصلی تولید این گاز، احتراق سوخت، آلاینده‌های صنعتی و همچنین عواملی مانند آتش‌سوزی در جنگل و گازهای طبیعی هستند. بیش از ۷۰ درصد از منواکسید کربن منتشرشده در هوا از طریق حمل‌ونقل شهری تولید می‌شود. غلظت بالای این گاز باعث سردرد و سرگیجه و مرگ می‌شود. دی‌اکسید نیتروژن ( $\text{NO}_2$ ) گازی است با رنگ قرمز - قهوه‌ای، بی‌بو و شدیداً خفکان‌آور که در ترکیب با هیدروکسید رادیکالی منجر به تولید اسید نیتریک می‌شود که در نهایت به صورت باران اسیدی بر سطح زمین می‌بارد. منابع اصلی این گاز، احتراق ناشی از وسایل نقلیه، تأسیسات الکتریکی و دیگر منابع صنعتی و تجاری می‌باشند که از سوخت‌های فسیلی استفاده می‌کنند. در اثر افزایش غلظت این آلاینده، ممکن است پیامدهایی از قبیل مشکلات تنفسی، تحریک چشم و گلو، ناراحتی‌های اعصاب یا بروز التهاب در بافت‌های ریوی پدید آید [۱۳].

به دلیل اهمیت پیش‌بینی و مدل‌سازی پارامترهای کیفیت هوا، مطالعه حاضر با به‌کارگیری مدل‌های رگرسیون چند متغیره به‌عنوان یک مدل خطی و شبکه عصبی مصنوعی به‌عنوان یک مدل غیرخطی به‌منظور پیش‌بینی شاخص‌های آلاینده هوای تهران، اهداف زیر را دنبال می‌نماید:

- طراحی و توسعه مدل بهینه شبکه عصبی مصنوعی به‌عنوان روشی غیرخطی برای پیش‌بینی غلظت منواکسید کربن و دی‌اکسید نیتروژن در ۵ ایستگاه در شهر تهران
- ارزیابی پتانسیل خصیصه‌های مختلف محیطی و ترافیک به‌منظور مدل‌سازی آلودگی هوا و ارائه پیش‌بینی‌های قابل‌اعتماد
- مقایسه عملکرد مدل توسعه‌یافته شبکه عصبی با مدل رگرسیون چند متغیره به‌عنوان روشی خطی

## ۲- مرور مطالعات انجام‌شده

در سال‌های اخیر در زمینه پیش‌بینی زمانی - مکانی غلظت آلاینده‌های موجود در هوا مطالعات گوناگونی صورت گرفته است. گاردنر و دورلینگ<sup>۱</sup> (۱۹۹۸)، مدل شبکه عصبی پرسپترون چندلایه (MLP)<sup>۲</sup> را با استفاده از داده‌های ساعتی  $\text{NO}_x$ ، دی‌اکسید نیتروژن ( $\text{NO}_2$ ) و داده‌های هواشناسی توسعه دادند. نتایج نشان از عملکرد بهتر مدل پرسپترون چندلایه نسبت به مدل رگرسیون خطی (MLR)<sup>۳</sup> توسعه داده‌شده توسط شای و هریسون (۱۹۹۷)، داشت [۱۴]. پرز و تریر<sup>۴</sup> (۲۰۰۱)، مدل شبکه عصبی پرسپترون چندلایه را برای پیش‌بینی غلظت منواکسید نیتروژن ( $\text{NO}$ ) و دی‌اکسید نیتروژن در یک تقاطع در شیلی توسعه دادند. نتایج نشان از عملکرد بهتر مدل عصبی در مقایسه با مدل رگرسیون خطی داشت [۱۵]. صدر موسوی و رحیمی (۱۳۸۹) در پژوهشی به پیش‌بینی غلظت ازن در شهر تبریز

[<sup>۱</sup>] Gardner and Dorling

[<sup>۲</sup>] Multiple Linear Perceptron

[<sup>۳</sup>] Multiple Linear Regression

[<sup>۴</sup>] Perez and Trier



با استفاده از روش‌های شبکه عصبی پرسپترون چندلایه و رگرسیون خطی چندگانه پرداختند. بدین منظور از داده‌های ازن در ماه‌های آذر و دی سال ۱۳۸۵ به صورت ساعتی استفاده شد. نتایج به دست آمده نشان داد که مدل شبکه‌های عصبی پرسپترون چندلایه توانایی بیشتری نسبت به روش رگرسیون خطی چندمتغیره داشته است. با توجه به نتایج حاصل از این تحقیق، ضریب همبستگی به دست آمده از پیش‌بینی مدل رگرسیون چندمتغیره،  $0/45$  بود در حالی که ضریب همبستگی این پیش‌بینی با استفاده از مدل شبکه‌های عصبی  $0/91$  بود [۱۶].

مک‌کندری<sup>۵</sup> (۲۰۰۲) در تحقیقی به بررسی مدل‌های حاصل از شبکه عصبی به منظور پیش‌بینی آلودگی ذرات معلق در هوا پرداخت. در این مطالعه مدل پرسپترون چندلایه با مدل رگرسیون خطی چندگانه برای پیش‌بینی حداکثر و متوسط روزانه غلظت ازن و  $PM_{10}$  مقایسه شد. نتایج نشان داد که مدل پرسپترون چندلایه بهتر از رگرسیون خطی چندمتغیره، غلظت ذرات معلق را پیش‌بینی می‌کند و همچنین این مدل غلظت ازن را بهتر از ذرات معلق تخمین می‌زند [۱۷]. گریواس و چالولاکو<sup>۶</sup> (۲۰۰۶) در مطالعه‌ای به ارزیابی توانایی شبکه عصبی برای ارائه پیش‌بینی‌های قابل اعتماد از عنصر  $PM_{10}$  پرداختند. در این پژوهش از داده‌های غلظت ساعتی  $PM_{10}$  در طی سال‌های ۲۰۰۱ تا ۲۰۰۲ در ۴ ایستگاه در شهر آتن یونان استفاده شد. مدل‌های شبکه عصبی مصنوعی با استفاده از ترکیب متغیرهای هواشناسی و در مقیاس زمان به عنوان ورودی، توسعه داده شدند. همچنین یک روش بهینه‌سازی بر مبنای الگوریتم ژنتیک برای انتخاب متغیرهای ورودی مورد بررسی قرار گرفت و متغیرهای دما، رطوبت نسبی، سرعت و جهت باد انتخاب شدند. نتایج حاصل از شبکه عصبی پرسپترون چندلایه که از تمام داده‌ها به عنوان ورودی استفاده نمود. در تمام ایستگاه‌ها نسبتاً رضایت‌بخش بود و شاخص توافق<sup>۷</sup> بین  $0/8$  تا  $0/89$  به دست آمد. همچنین عملکرد مدل‌های شبکه عصبی در مقایسه با رگرسیون خطی چندگانه برتری محسوسی داشت [۱۸].

کای و همکاران<sup>۸</sup> (۲۰۰۹) در تحقیقی به پیش‌بینی غلظت در ۱۰ ساعت آینده آلاینده‌های منواکسید کربن، دی‌اکسید نیتروژن و ازن در کنار بزرگراهی در گوانژو چین با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه و رگرسیون خطی چند متغیره پرداختند. در این مدل‌ها از غلظت ساعتی آلاینده‌ها در سه ایستگاه نظارت آلودگی هوا و همچنین پارامترهای هواشناسی استفاده شد. نتایج نشان داد که مدل شبکه عصبی پرسپترون چندلایه عملکرد بهتری نسبت به رگرسیون خطی چندمتغیره دارد [۹]. سافی<sup>۹</sup> (۲۰۱۱) در تحقیقی به پیش‌بینی غلظت آلاینده  $PM_{10}$  در کشور مالزی با استفاده از دو مدل رگرسیون خطی چندمتغیره و شبکه عصبی مصنوعی پس انتشار خطا<sup>۱۰</sup> پرداخت. او از متغیرهای رطوبت نسبی، دما، سرعت باد، مونواکسید کربن، دی‌اکسید نیتروژن ازن و غلظت  $PM_{10}$  روز قبل به عنوان پارامترهای ورودی مدل‌ها استفاده نمود. نتایج به دست آمده از مقایسه آماری مقادیر دقت پیش‌بینی، شاخص توافق، خطای مطلق نرمال شده و ریشه میانگین مربعات خطا نشان داد که مدل شبکه عصبی پرسپترون چندلایه در مقایسه با مدل رگرسیون خطی چندگانه از قابلیت بالاتری در پیش‌بینی آلودگی هوا برخوردار است [۱۹]. آنتاناسیویچ و همکاران<sup>۱۱</sup> (۲۰۱۳) در مطالعه‌ای به توسعه مدل شبکه عصبی مصنوعی برای پیش‌بینی  $PM_{10}$  پرداختند. داده‌های ورودی شبکه عصبی مربوط به غلظت  $PM_{10}$  بین سال‌های ۱۹۹۹ تا ۲۰۰۶، با استفاده از الگوریتم ژنتیک بهینه شدند. میانگین خطای مطلق پیش‌بینی شده، ۱۰ درصد به دست آمد که سه برابر بهتر از پیش‌بینی‌های حاصل از رگرسیون خطی چند متغیره و روش رگرسیون مؤلفه‌های اصلی بود [۱].

[<sup>5</sup>] McKendry

[<sup>6</sup>] Grivas and Chaloulakou

[<sup>7</sup>] Index of agreement

[<sup>8</sup>] Cai et al.

[<sup>9</sup>] Saufie

[<sup>10</sup>] Back Propagation Algorithm

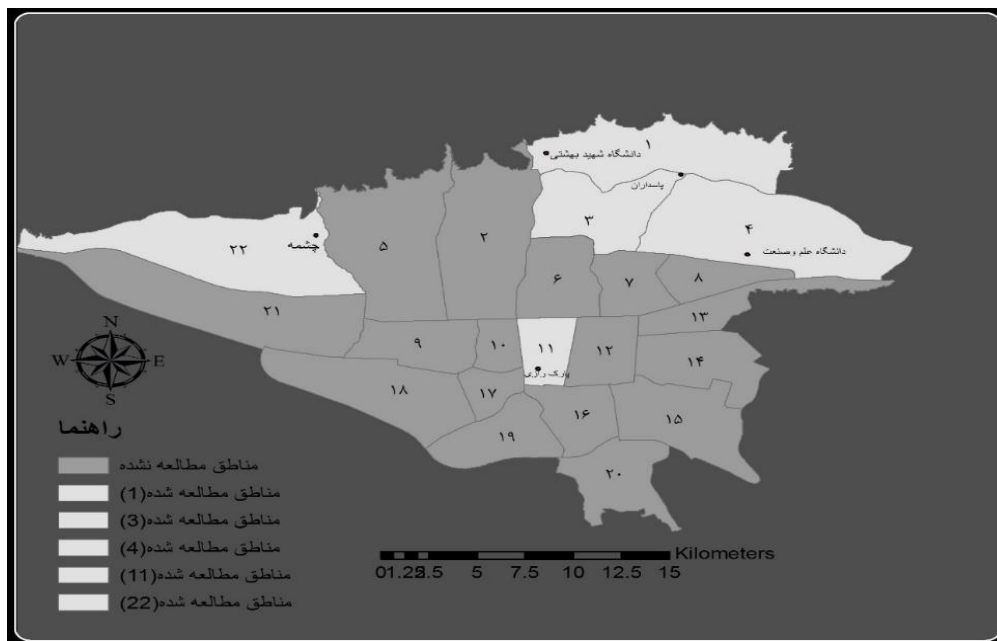
[<sup>11</sup>] Antanasijević et al.



با توجه به مطالعات اشاره‌شده، در طول سال‌های اخیر، مدل‌های آماری و بخصوص شبکه‌های عصبی مصنوعی برای ارزیابی روش‌های رگرسیونی و پیش‌بینی کیفیت هوا استفاده شده‌اند. پیشرفت‌های اخیر در توسعه مدل‌های شبکه عصبی مصنوعی، راه را برای استفاده عملی از آن‌ها در مدل‌سازی و پیش‌بینی آلاینده‌ها در محیط‌های شهری هموار می‌سازد. در پیش‌بینی آلودگی هوا، انتخاب متغیرهای ورودی تأثیرگذار، یکی از مراحل مهم مدل‌سازی می‌باشد. زیرا اندازه‌گیری‌ها از منابع آلاینده مختلف انجام شده و ارتباط این منابع آلوده‌کننده اغلب پیچیده و غیرخطی است [۲۰]. با وجود مطالعات انجام شده در زمینه پیش‌بینی آلودگی هوا، بهبود عملکرد روش‌های استفاده شده در پیش‌بینی از طریق انتخاب پارامترهای ورودی مناسب و بهینه کردن ساختار معماری شبکه نیاز به مطالعه بیشتری دارد که در این پژوهش بدان پرداخته شده است.

## ۲- منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، شهر تهران با مساحت ۸۰۰ کیلومتر مربع و دارای ۲۲ منطقه شهری می‌باشد که در طول جغرافیایی ۵۱ درجه و ۱۷ دقیقه تا ۵۱ درجه و ۳۳ دقیقه و عرض جغرافیایی ۳۵ درجه و ۳۵ دقیقه تا ۳۵ درجه و ۴۲ دقیقه قرار گرفته است. شهر تهران، در جنوب رشته‌کوه البرز واقع شده است و فاقد بادهای دائمی می‌باشد. شکل ۱ نشان‌دهنده شهر تهران و مناطق مختلف شهری آن می‌باشد.



شکل ۱: نقشه مناطق شهری تهران و پراکندگی ایستگاه‌های مورد استفاده سنجش آلودگی هوای تهران

## ۳- داده‌ها و روش تحقیق

### ۳-۱- داده‌های مورد استفاده

آلودگی هوا در یک منطقه شهری دارای الگوی فضایی پیچیده‌ای می‌باشد و سطوح آلودگی در مسافت‌های کوچک و در زمان‌های مختلف به طور چشمگیری متفاوت هستند [۳]. اطلاعات انتشار آلاینده‌ها یکی از عناصر اساسی در مدل‌سازی کیفیت هوا است [۲۱]. در این پژوهش، عناصر تأثیرگذار روی غلظت آلاینده‌ها در ۴ دسته ترافیکی، غلظت آلاینده‌ها در روزهای قبلی، آب و هوایی و جغرافیایی طبقه‌بندی شده‌اند.



- داده‌های هواشناسی مورد استفاده شامل دما، رطوبت نسبی، سرعت باد، جهت باد، پوشش ابر و فشار سطح (استخراج شده از سایت (Ecmwf.int)) به صورت میانگین روزانه می‌باشند. به منظور جایگزینی شاخص‌های سرعت و جهت باد به منظور تداوم مؤلفه‌های سرعت و جهت باد به دلیل تغییر در زاویه جهت باد، مؤلفه‌های زیر تعریف شدند که در رابطه ۱ نشان داده شده‌اند [۲۲].

$$\begin{aligned} Wx &= |W| * \cos \varphi & Wy \\ &= |W| * \sin \varphi \end{aligned} \quad (1)$$

در معادله ۱، W معرف سرعت باد و  $\varphi$  معرف جهت باد می‌باشد.

کیفیت هوای محیط به شدت می‌تواند توسط عوامل هواشناسی مانند تابش موج کوتاه، دمای هوا، سرعت و جهت باد و رطوبت نسبی و توپوگرافی تحت تأثیر قرار گیرد. عوامل هواشناسی، به طور کلی نقش مهمی در روند گسترش آلاینده، انتقال و واکنش شیمیایی ایفا می‌کنند و به صورت مستقیم و غیرمستقیم کیفیت هوا را تحت تأثیر قرار می‌دهند [۲۳]. عوامل هواشناسی ارتباط نزدیکی با منشأ تولید، انتقال و انتشار آلاینده‌ها و همچنین تشکیل شرایط مطلوب برای تجمع و پراکنده‌سازی آلاینده‌ها دارند [۲۴]. بنابراین منطقی است که به مطالعه غلظت آلاینده‌های هوا با توجه به شرایط آب و هوایی محلی پرداخته شود. به منظور بهبود عملکرد مدل‌ها، پارامتر ماه در سال برای ارائه تغییرات آلاینده‌ها به واسطه تغییرات شرایط اتمسفر در طی سال از رابطه ۲ محاسبه گردید [۱۲].

$$MOY = \cos\left(\frac{2\pi m}{12}\right) \quad (2)$$

در معادله ۲، m بیانگر عدد ماه مورد نظر می‌باشد.

- غلظت آلاینده‌های مونوکسید کربن و دی‌اکسید نیتروژن ایستگاه‌های واقع در شهر تهران برای سال ۱۳۹۱ شامل ۵ ایستگاه ثابت پایش آلودگی هوا (ایستگاه‌های شهید بهشتی، چشمه، علم و صنعت، پارک رازی و پاسداران) که مطابق شکل ۱ در سطح شهر پراکنده می‌باشند، از طریق سازمان حفاظت محیط زیست تهیه گردید.
- داده‌های ترافیکی شامل شاخص ترافیکی تا شعاع ۱ کیلومتری در هر ایستگاه بود که در این مطالعه تعریف گردید. برای محاسبه پارامتر شاخص ترافیکی بافرهایی به شعاع ۱۰۰ متر از هر ایستگاه و تا شعاع ۱ کیلومتری ترسیم گردید. واضح است که غلظت آلاینده‌ها با فاصله از جاده تغییر می‌کند. بنابراین برای به دست آوردن عدد شاخص ترافیکی هر بافر، فاصله خیابان‌ها از هر ایستگاه محاسبه شده و در عرض خیابان ضرب شد و در نهایت میانگین وزنی آن‌ها محاسبه گردید.
- داده‌های جغرافیایی استفاده شده در این تحقیق شامل مختصات ایستگاه‌ها، و میانگین پوشش گیاهی تا شعاع ۱ کیلومتری از هر ایستگاه (تعریف شده در این تحقیق) می‌باشند. به منظور محاسبه پارامتر میانگین پوشش گیاهی، با استفاده از تصاویر ماهواره لندست ۷ در منطقه مورد مطالعه، ابتدا از هر ایستگاه به فواصل ۱۰۰ متری تا شعاع ۱ کیلومتر بافرهایی ترسیم شد و میانگین پوشش گیاهی برای هر شعاع محاسبه گردید.

### ۳-۲- مدل سازی

در سال‌های اخیر روش‌های آماری از جمله رگرسیون خطی چند متغیره و شبکه‌های عصبی مصنوعی به منظور پیش‌بینی آلودگی هوا مورد استفاده قرار گرفته‌اند [۲۵]. در این پژوهش از مدل‌های رگرسیون چند متغیره و شبکه



عصبی پرسپترون چندلایه برای پیش‌بینی حداکثر غلظت آلاینده‌ها استفاده شد. روش رگرسیون خطی محاسبات آسانی دارد و اجرای آن‌ها راحت‌تر است و در مسائلی با پیچیدگی کم و روابط خطی استفاده می‌شود و به همین دلایل از جمله رایج‌ترین روش‌های مدل‌سازی محسوب می‌گردد. روش‌های مختلف شبکه عصبی مصنوعی، پیچیده‌تر ولی در عین حال قابل‌انعطاف‌تر از مدل‌های آماری خطی هستند و قادر به توصیف داده‌هایی با وابستگی غیرخطی بالا می‌باشند. روش‌های مختلف شبکه عصبی مصنوعی اجازه می‌دهند تا از داده‌های مبهم و غیرخطی اطلاعات را استخراج نماییم. دومین مزیت مدل‌های شبکه‌های عصبی مصنوعی توانایی آن‌ها برای یادگیری روابط پیچیده و ناشناخته از داده‌های آموزشی است [۲۶]. مدل‌سازی شبکه‌های عصبی مصنوعی بر اساس یک فرایند یادگیری صورت می‌پذیرد، سپس شبکه عصبی مقادیر متغیر خروجی را با متغیرهای ورودی تخمین می‌زند [۱]. مشخصه مهم شبکه‌های عصبی، ذات تطبیقی آن‌ها است که در آن یادگیری به‌وسیله مثال‌های جایگزین انجام می‌شود. این ویژگی باعث می‌شود که تکنیک‌های شبکه عصبی در حوزه‌های کاربردی و برای حل پدیده‌های بسیار غیرخطی بکار روند [۱۱]. با توجه به ارتباط پیچیده بین ورودی‌های شبکه عصبی و معماری شبکه عصبی (پیچیدگی نگاشت ورودی و خروجی، میزان نوز و تعداد داده‌های آموزشی)، انتخاب معماری (ساختار) شبکه عصبی مصنوعی باید به‌دقت انجام شود [۷].

برای جلوگیری از ناهمگونی شبکه، با توجه به وزن‌های کوچک و بزرگ و از بین بردن تأثیر ابعاد مختلف داده‌ها، ورودی‌های شبکه عصبی باید نرمال شوند. بدین منظور، خصیصه‌های مورد استفاده در این تحقیق در بازه [۰ و ۱] با استفاده از رابطه ۳ نرمال شدند [۹].

$$X_{norm} = \frac{(X_i - X_{min})}{(X_{max} - X_{min})} \quad (3)$$

در معادله ۳،  $X_{norm}$  مقدار نرمال شده یک خصیصه،  $X_i$  مقادیر اصلی و  $X_{min}$  و  $X_{max}$  مقادیر کمینه و بیشینه مقادیر اصلی همان خصیصه می‌باشند. شبکه عصبی پرسپترون چندلایه، رایج‌ترین شبکه عصبی پیش‌خور<sup>۱۲</sup> می‌باشد. مدل پرسپترون چندلایه متشکل از شبکه‌ای از عناصر ساده و ارتباطها می‌باشد. عناصر پردازشی (نورون‌ها) در لایه‌های ورودی، لایه‌های پنهان و لایه‌های خروجی قرار می‌گیرند. تعداد نورون ورودی و خروجی شبکه‌های عصبی مصنوعی توسط ماهیت مسئله تعیین می‌گردد. هر نورون مجموع وزن‌داری از ورودی‌های نورون مجاور را محاسبه می‌کند. این پردازش‌ها با استفاده از یک تابع فعال انجام می‌شود و در لایه‌های بعدی توزیع می‌شود. نتایج به‌دست‌آمده از مدل پرسپترون چندلایه به معماری شبکه و پارامترهای مدل شامل الگوریتم آموزش و توابع انتقال بستگی دارد [۲۷]. رایج‌ترین الگوریتم یادگیری نظارت‌شده، الگوریتم پس انتشار خطا می‌باشد. این الگوریتم یک الگوریتم گرادیان نزولی است که برای آموزش شبکه پرسپترون چندلایه استفاده می‌شود [۲۸].

جهت انجام مدل‌سازی، پارامترهای معرفی شده در قسمت داده‌ها و همچنین میانگین و بیشینه غلظت آلاینده مورد نظر تا ۴ روز قبل، به‌عنوان ورودی مدل‌ها و ماکزیمم غلظت آلاینده‌ها در هر روز به‌عنوان خروجی مدل معرفی گردیدند. در این پژوهش مجموعه داده‌ها شامل ۱۷۸۰ نمونه از میانگین غلظت ساعتی برداشت‌شده از ۵ ایستگاه پایش در شهر تهران می‌باشد. مجموعه داده‌ها به‌منظور آموزش و آزمایش مدل‌ها و ایجاد یک مجموعه برای ارزیابی به‌منظور تنظیم پارامترهای مدل به‌صورت تصادفی به سه زیرمجموعه شامل ۷۰ درصد برای آموزش، ۱۵ درصد برای اعتبارسنجی پارامترهای مدل شبکه عصبی و یافتن پارامترهای بهینه، و ۱۵ درصد برای آزمایش مدل تقسیم شدند. به‌منظور اجرای شبکه عصبی پرسپترون چندلایه از تابع آموزشی لوبنبرگ-مارکوارت (LM)<sup>۱۳</sup> استفاده شد. همچنین جهت یافتن تعداد

[12] Feedforward Artificial Neural Network

[13] Levenberg- Marquart



نورون‌های مناسب، شبکه چندین بار اجرا شد و تعداد نورون مناسب در لایه پنهان، برای هر آلاینده استخراج گردید که نتایج آن به صورت خلاصه در جدول ۱ ارائه گردیده است. با توجه به نتایج به دست آمده در جدول ۱، در این پژوهش جهت اجرای شبکه عصبی پرسپترون چندلایه و برای آلاینده منواکسید کربن از یک شبکه ۳ لایه با ۲۴ نورون و حداکثر تکرار ۲۰۰ و برای آلاینده دی‌اکسید نیتروژن از شبکه‌ای با ۱۲ نورون و حداکثر تکرار ۲۵۰ استفاده شد. حد بالای نرخ آموزش شبکه عصبی پرسپترون چندلایه ۰/۰۱، ثابت مومنتوم<sup>۱۴</sup> برابر با ۰/۰۱ می‌باشد.

جدول ۱: نتایج انتخاب تعداد نورون مناسب در لایه پنهان برای هر آلاینده

تعداد نورون برای آلاینده منواکسید کربن	ریشه میانگین مربعات خطا	تعداد نورون برای آلاینده دی‌اکسید نیتروژن	ریشه میانگین مربعات خطا
۷	۱/۵۹	۸	۱۶/۴۶
۱۰	۱/۴۵	۱۲	۱۲/۴۴
۱۴	۱/۵	۱۵	۱۹/۷۴
۲۰	۱/۴۴	۲۰	۲۲/۸۹
۲۴	۱/۴۲	۲۴	۱۸/۱۸
۳۰	۱/۸۶	۲۸	۱۲/۲۵
۳۴	۱/۵۴	۳۵	۲۱/۸۶
۴۰	۱/۵۴	۳۸	۲۳/۷۶

جهت استفاده از روش رگرسیون چندمتغیره، مسئله هم‌خطی چندگانه مدل‌ها مورد توجه قرار گرفت. به همین منظور شاخص شرطی<sup>۱۵</sup> و رواداری<sup>۱۶</sup> و نیز پی-مقدار<sup>۱۷</sup> برای هر یک از مدل‌ها، محاسبه گردید و مدل‌هایی که دارای شاخص شرطی بزرگ‌تر از ۳۰، مقدار رواداری کمتر از ۰/۱ و یا پی-مقدار بیشتر از ۰/۰۵ بودند به عنوان مدل‌های تحت تأثیر هم‌خطی چندگانه شناسایی شده و حذف گردیدند. به منظور ارزیابی عملکرد مدل‌های پیش‌بینی، شاخص‌های ریشه میانگین مربعات خطا (RMSE)<sup>۱۸</sup>، خطای استاندارد تخمین (SSE)<sup>۱۹</sup>، ضریب تعیین (R<sup>2</sup>)<sup>۲۰</sup> و درصد خطا محاسبه شدند. فرمول شاخص‌های استفاده شده مطابق روابط زیر می‌باشد:

$$RMSE = \left( \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \right)^{\frac{1}{2}} \quad (۴)$$

$$R^2 = \frac{\sum_{i=1}^N (P_i - \bar{O})^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (۵)$$

$$SSE = \left( \frac{1}{N-m-1} \sum_{i=1}^N (P_i - O_i)^2 \right)^{\frac{1}{2}} \quad (۶)$$

در معادلات بالا،  $P_i$  و  $O_i$  به ترتیب نشان‌دهنده مقدار پیش‌بینی شده و مقدار مشاهده شده و  $\bar{O}$  بیانگر میانگین مقادیر مشاهده شده می‌باشند. در معادله ۶،  $N$  بیانگر تعداد نمونه‌ها و  $m$  تعداد پیش‌بینی کننده‌ها می‌باشد. خطای مربوط به

[14] Momentum

[15] Condition Index

[16] Tolerance

[17] P-Level

[18] Root-Mean-Square Error

[19] Standard Error Of Estimation

[20] Correlation Of Determination





تخمین داده‌ها از طریق تقسیم نمودن مقادیر خطای استاندارد تخمین برای هر یک از آلاینده‌ها بر مقدار میانگین مقادیر اندازه‌گیری شده برای آن آلاینده و ضرب حاصل آن در عدد ۱۰۰، به درصد محاسبه گردید. آزمون تی نمونه‌های جفت شده<sup>۲۱</sup> جهت ارزیابی آماری مدل‌های به‌دست‌آمده و مقایسه عملکرد مدل‌ها با یکدیگر مورد استفاده قرار گرفت. این آزمون بر روی مقادیر مطلق باقیمانده حاصل از اختلاف بین مقادیر اندازه‌گیری شده و مقادیر برآورد شده آن‌ها اعمال گردید.

#### ۴- نتایج و بحث

پس از استفاده از روش‌های رگرسیون چند متغیره و شبکه عصبی پرسپترون چندلایه، با توجه به شرایط عنوان شده در قسمت روش تحقیق، مدل‌های بهینه تعیین گردیدند که نتایج به‌دست‌آمده برای آلاینده‌ها در جدول‌های ۳ و ۴ نشان داده شده است. با توجه به نتایج به‌دست‌آمده از داده‌های آموزشی در روش رگرسیون چندمتغیره، مدل‌های نشان داده شده در قالب روابط ۷ و ۸ به ترتیب برای منواکسید کربن و دی‌اکسید نیتروژن به‌عنوان مدل‌های نهایی استخراج گردیدند.

$$Z_{CO} = 0.44(a_1) + 0.1(a_2) - 14.73(a_3) - 0.47(a_4) - 0.01(a_5) - 0.64(a_6) + 3.62 \quad (7)$$

$$Z_{NO_2} = 0.37(\beta_1) + 0.22(\beta_2) - 9(\beta_3) - 0.38(\beta_4) - 85.4(\beta_5) - 0.1(\beta_6) \quad (8)$$

پارامترهای مؤثر در تخمین آلاینده منواکسید کربن با توجه به معادله ۷ با ضرایب  $a_i$  نشان داده شده است که  $a_1$  و  $a_2$  به ترتیب نشان‌دهنده بیشینه غلظت آلاینده در یک و چهار روز قبل،  $a_3$  بیانگر میانگین پوشش گیاهی در فاصله ۱۰۰۰ متری از ایستگاه‌ها،  $a_4$  نمایانگر شاخص ماه در سال،  $a_5$  شاخص ترافیکی در فاصله ۷۰۰ متری از ایستگاه‌ها و  $a_6$  بیانگر میانگین پوشش ابر می‌باشد. همچنین با توجه به معادله ۸، برای تخمین آلاینده دی‌اکسید نیتروژن، ضرایب  $\beta_1$  و  $\beta_2$  به ترتیب بیانگر بیشینه و میانگین غلظت در یک و سه روز قبل هستند.  $\beta_3$  نشان‌دهنده میانگین پوشش ابر و  $\beta_4$  میانگین غلظت در یک روز قبل می‌باشند. ضرایب  $\beta_5$  و  $\beta_6$  نیز به ترتیب بیانگر میانگین پوشش گیاهی در فاصله ۱۰۰۰ متری از ایستگاه‌ها و بیشینه غلظت در چهار روز قبل می‌باشند.

با استفاده از ضریب  $\beta$  استاندارد شده در روش رگرسیون چند متغیره، تأثیر هر یک از متغیرهای مستقل بر روی پیش-بینی آلاینده‌ها، در جدول ۲ نشان داده شده است. ضریب استاندارد با ضرب ضریب استاندارد نشده در نسبت انحراف معیار متغیر مستقل به انحراف معیار متغیر وابسته به دست می‌آید. ضریب استاندارد، تمام متغیرها را به واحدهای انحراف معیار تبدیل می‌کند [۲۹ و ۳۰].

[21] Paired-Samples T-test



جدول ۲: رتبه‌بندی تأثیر متغیرهای مستقل بر آلاینده‌ها با استفاده از روش رگرسیون چند متغیره

رتبه	آلاینده	مناوکسید کربن (PPM)	دی‌اکسید نیتروژن (PPB)
۱		بیشینه غلظت در یک روز قبل	بیشینه غلظت در یک روز قبل
۲		میانگین پوشش گیاهی در فاصله ۱۰۰۰ متری	میانگین غلظت در یک روز قبل
۳		شاخص ماه در سال	میانگین غلظت در سه روز قبل
۴		شاخص ترافیکی در فاصله ۷۰۰ متری	میانگین پوشش گیاهی در فاصله ۱۰۰۰ متری
۵		بیشینه غلظت در چهار روز قبل	میانگین پوشش ابر
۶		میانگین پوشش ابر	بیشینه غلظت در چهار روز قبل

با توجه به جدول ۲، مهم‌ترین عامل مؤثر بر پیش‌بینی آلاینده‌های مناوکسید کربن و دی‌اکسید نیتروژن، غلظت آلاینده‌ها در روز قبل می‌باشد که می‌تواند نشان‌دهنده پایداری بالای این آلاینده‌ها در جو باشد. با توجه به رابطه ۷، مقادیر غلظت آلاینده مناوکسید کربن به غلظت آلاینده در روزهای قبل وابستگی نشان می‌دهد. این امر می‌تواند نشان‌دهنده ماندگاری بالای این آلاینده در منطقه باشد که بر روی تخمین غلظت آلاینده در روزهای آینده تأثیرگذار است. با توجه به وجود پوشش گیاهی در رابطه ۷ و اهمیت آن با توجه به جدول ۲، به نظر می‌رسد جذب آلاینده توسط گیاهان عاملی است که باید در پیش‌بینی غلظت مناوکسید کربن به‌عنوان یک عامل مؤثر مورد توجه قرار گیرد. با توجه به جدول ۲، شاخص ترافیک به‌عنوان عاملی مهم در پیش‌بینی میزان مناوکسید کربن در هوا شناخته شده است. این مسئله نشان می‌دهد که وسایل نقلیه یکی از منابع مهم در ایجاد آلاینده مناوکسید کربن و پیش‌بینی این آلاینده می‌باشد. شاخص ماه در سال نشان‌دهنده تأثیر شدت منابع انتشار بر مدل‌های پیش‌بینی کننده می‌باشد [۱۸]. هرچند انتخاب شاخص ترافیک در کنار شاخص ماه در سال، بر لزوم توجه به شاخص ترافیک در کنار این شاخص تأکید نموده است. میانگین پوشش ابر به‌عنوان یکی دیگر از خصیصه‌های مؤثر در پیش‌بینی مناوکسید کربن در جدول ۲ شناخته شده است. در واقع، وجود پارامتر ابر در منطقه می‌تواند باعث ایستایی آلاینده مورد نظر شود و غلظت پیش‌بینی شده را تحت تأثیر قرار دهد.

با توجه به مدل ارائه شده برای تخمین آلاینده دی‌اکسید نیتروژن (رابطه ۸)، همانند آلاینده مناوکسید کربن، مقادیر این آلاینده به غلظت در روزهای قبل وابسته هستند و در نتیجه اهمیت واکنش‌های شیمیایی و فتوشیمیایی را در تولید و واپاشی این آلاینده نشان می‌دهد [۳۱]. به نظر می‌رسد وجود ابر منجر به کاهش جریان‌های هوایی و نتیجتاً ایستادن دی‌اکسید نیتروژن در منطقه می‌شود و در پیش‌بینی این آلاینده نقش مهمی را ایفا می‌کند. با توجه به جدول ۲، وجود شاخص پوشش گیاهی در فاصله ۱۰۰۰ متری از ایستگاه‌ها نشان‌دهنده نقش این شاخص در کاهش غلظت آلاینده دی‌اکسید نیتروژن است که آلاینده را جذب می‌کند.

بر اساس نتایج نشان داده شده در جدول ۳، برای آلاینده مناوکسید کربن، مدل به‌دست آمده با استفاده از شبکه عصبی پرسپترون چندلایه با ضریب تعیین ۰/۵۳ و خطای برآورد ۳۲/۹ درصد نتیجه به‌مراتب بهتری را نسبت به مدل رگرسیون چند متغیره ارائه نموده است. نتایج حاصل از آزمون تی برای مقایسه عملکرد این دو روش در پیش‌بینی آلاینده مناوکسید کربن با پی مقدار کمتر از ۰/۰۵، نشان‌دهنده اختلاف آماری معنی‌دار بین نتایج روش‌های رگرسیون



چند متغیره و شبکه عصبی پرسپترون چندلایه می‌باشد. بهبود عملکرد شبکه عصبی پرسپترون چندلایه برای پیش‌بینی منواکسید کربن با توجه به رابطه بسیار غیرخطی غلظت این آلاینده و متغیرهای ورودی، نسبت به عملکرد مدل رگرسیون چند متغیره قابل توجیه می‌باشد [۱۸].

جدول ۳: نتایج حاصل از روش‌های رگرسیون چند متغیره و شبکه عصبی پرسپترون چندلایه بر روی داده‌های آزمایشی آلاینده منواکسید کربن (PPM)

خطای برآورد (%)	خطای استاندارد تخمین	ریشه میانگین مربعات خطا	ضریب تعیین	شاخص‌های کارایی روش‌ها
۵۰/۴۳	۲/۳۳	۲/۳	۰/۵۶	روش‌ها
				رگرسیون چند متغیره
۳۲/۹	۱/۵۲	۱/۴۱	۰/۵۳	شبکه عصبی پرسپترون چندلایه

جدول ۴: نتایج حاصل از روش‌های رگرسیون چند متغیره و شبکه عصبی پرسپترون چندلایه بر روی داده‌های آزمایشی آلاینده دی‌اکسید نیتروژن (PPB)

خطای برآورد (%)	خطای استاندارد تخمین	ریشه میانگین مربعات خطا	ضریب تعیین	شاخص‌های کارایی روش‌ها
۲۷/۱۶	۱۵/۶۶	۱۵/۵۴	۰/۷۴	روش‌ها
				رگرسیون چند متغیره
۲۶/۹	۱۵/۱۲	۱۴/۹۲	۰/۷۴	شبکه عصبی پرسپترون چندلایه

با توجه به جدول ۴، برای آلاینده دی‌اکسید نیتروژن، ضریب تعیین برای روش‌های رگرسیون چند متغیره و شبکه عصبی پرسپترون چندلایه ۰/۷۴ و خطای برآورد برای شبکه عصبی پرسپترون چندلایه ۲۶/۹ درصد می‌باشد که تفاوت اندکی با خطای برآورد ۲۷/۱۶، حاصل از رگرسیون چند متغیره دارد. نتایج آزمون آماری برای مقایسه عملکرد این دو روش به منظور پیش‌بینی آلاینده دی‌اکسید نیتروژن، پی مقدار ۰/۷۲ را نشان داد که نشانه عدم وجود اختلاف معنی‌دار بین عملکرد این دو روش می‌باشد. با توجه به ضریب تعیین به دست آمده برای آلاینده دی‌اکسید نیتروژن می‌توان گفت که ۷۴ درصد از تغییرات این آلاینده را با استفاده از متغیرهای مورد استفاده و مدل‌های ارائه شده می‌توان تخمین زد.



بر این اساس، می‌توان نتیجه گرفت که تغییرات آلاینده دی‌اکسید نیتروژن و عوامل تأثیرگذار بر این تغییرات نسبت به تغییرات منواکسید کربن و عوامل تأثیرگذار بر تغییرات این آلاینده پیچیدگی کمتری دارند.

با توجه به جدول‌های ۳ و ۴، نتایج تخمین آلاینده دی‌اکسید نیتروژن با روش‌های رگرسیون چند متغیره و شبکه عصبی پرسپترون چندلایه، نسبت به تخمین آلاینده منواکسید کربن از دقت بیشتری برخوردار است. این امر می‌تواند به دلایل زیر مرتبط باشد:

- روابط پیچیده و غیرخطی بین پارامترهای ورودی مدل و آلاینده منواکسید کربن می‌تواند به دقت کمتر این آلاینده نسبت به دی‌اکسید نیتروژن منجر شود.
- دقت پایین منواکسید کربن می‌تواند ناشی از ایجاد آلاینده منواکسید کربن از منابع متنوع و تغییرپذیر مانند حمل‌ونقل منطقه‌ای و فرا منطقه‌ای و منابع ترافیکی و غلظت بالای انباشته‌شده آلاینده در مناطق شهری باشد.
- عامل دیگر دقت کمتر منواکسید کربن، می‌تواند ناشی از رفتار تصادفی (وجود نویز بیشتر) و نوسان بیشتر این آلاینده نسبت به دی‌اکسید نیتروژن باشد. واریانس منواکسید کربن با مقدار ۳۹۵۲۱۴۴، نسبت به واریانس دی‌اکسید نیتروژن با مقدار ۷۸۴، به دست آمده بر اساس داده‌های مورد استفاده در این تحقیق، تأییدکننده این مطلب می‌باشد.
- دقت پایین تخمین منواکسید کربن می‌تواند به دلیل عدم توانایی پارامترهای ورودی مدل در بازسازی فرآیندهای اکسیداسیون تشکیل شده در جو باشد [۱۲].

مقایسه نتایج حاصل از روش‌های ارائه شده در این پژوهش و پژوهش‌های مشابه نشان می‌دهد که مدل‌های به دست آمده توانایی بالایی در پیش‌بینی غلظت آلاینده‌های منواکسید کربن و دی‌اکسید نیتروژن را دارا می‌باشند [۳۲].

##### ۵- نتیجه‌گیری

در این پژوهش با استفاده از مدل‌های رگرسیون چند متغیره به عنوان مدلی خطی و شبکه عصبی پرسپترون چندلایه به عنوان مدلی غیرخطی، به مدل‌سازی حداکثر غلظت آلاینده‌های منواکسید کربن و دی‌اکسید نیتروژن با استفاده از خصیصه‌های هواشناسی، جغرافیایی و ترافیک پرداخته شد. در این میان خصیصه‌های جدیدی شامل شاخص ترافیک و نیز شاخص پوشش گیاهی به منظور پیش‌بینی این آلاینده‌ها، در این تحقیق ارائه گردید که نتایج نشان‌دهنده کارایی بالای این شاخص‌ها بود. نتایج این پژوهش به صورت کلی عبارت‌اند از:

- مدل‌سازی منواکسید کربن با استفاده از شبکه عصبی پرسپترون چندلایه دقت به مراتب بالاتری را نسبت به مدل رگرسیون چند متغیره ارائه نموده است.
- نتایج حاصل از مدل‌سازی دی‌اکسید نیتروژن با استفاده از مدل‌ها، اختلاف معنی‌داری را نشان نمی‌دهد.
- نتایج تخمین آلاینده دی‌اکسید نیتروژن با روش‌های رگرسیون چند متغیره و شبکه عصبی پرسپترون چندلایه، نسبت به آلاینده منواکسید کربن از دقت بیشتری برخوردار است.
- با توجه به پارامترهای استفاده شده برای مدل‌سازی منواکسید کربن و دی‌اکسید نیتروژن، پارامترهای غلظت در روزهای قبل، میانگین پوشش گیاهی در فاصله ۱۰۰۰ متری و میانگین پوشش ابر از اهمیت زیادی برای پیش‌بینی این آلاینده‌ها برخوردار بود.



در پایان به منظور مدل‌سازی بهینه آلاینده‌های هوای شهر تهران، استفاده از سایر روش‌های شبکه عصبی و نیز استفاده از روش‌های انتخاب خصیصه پیش از استفاده از خصیصه‌ها جهت مدل‌سازی آلاینده‌ها پیشنهاد می‌گردد که در تحقیقات آتی به آن‌ها پرداخته خواهد شد.

## مراجع

- [1] D. Antanasijević, V. Pocajt, D. Povrenović, M. Ristić, A. Perić-Grujić, "PM10 emission forecasting using artificial neural networks and genetic algorithm input variable optimization", *Science of the Total Environment*, Vol. 443, pp. 511–519, 2013
- [2] D. Dunea, A. Pohoata, S. Iordache, "Using wavelet–feedforward neural networks to improve air pollution forecasting in urban environments", *Environ Monit Assess*, 187(7), pp. 1-16, 2015.
- [3] M. Akbari, F. Samadzadegan, "Identification of air pollution patterns using a modified fuzzy co-occurrence pattern mining method", *Int. J. Environ. Sci. Technol*, Vol. 12, pp. 3551–3562, 2015.
- [4] V. Valverde, M. Pay, J. Baldasano, "A model-based analysis of SO<sub>2</sub> and NO<sub>2</sub> dynamics from coal-fired power plants under representative synoptic circulation types over the Iberian Peninsula", *Science of the Total Environment*, Vol. 541, pp. 701–713, 2015.
- [5] M. J. Molina, L.T. Molina, "Megacities and atmospheric pollution", *Airwate manage Assoc*, Vol. 54, pp. 644-680, 2004.
- [6] M. Tavakoli, and A. Esmaili, "Performance of ANN and fuzzy neural network adaptive for estimating of the concentration of suspended particles in the air of Tehran", *Journal of Environmental Science and Engineering*, Vol. 2, pp. 84-75, 2014.
- [7] M. Cai, Y. Yin, M. Xie, "Prediction of hourly air pollutant concentrations near urban arterials using artificial neural network approach", *Transportation Research Part D*, Vol. 14, pp. 32–41, 2009.
- [8] H. Niska, T. Hiltunen, A. Karppinen, J. Ruuskanen, M. Kolehmainen, "Evolving the neural network model for forecasting air pollution time series", *Engineering Applications of Artificial Intelligence*, Vol. 17, pp. 159 – 167, 2004.
- [9] J. Xing, R. Mathur, J. Pleim, C. Hogrefe, C.M. Gan, D. C. Wong, C. Wei, R. Gilliam, G. Pouliot, "Observations and modeling of air quality trends over 1990–2010 across the Northern Hemisphere: China, the United States and Europe", *Atmos. Chem. Phys.*, Vol. 15, pp. 2723-2747, 2015.
- [10] M. Kolehmainen, H. Martikainen, J. Ruuskanen, "Neural networks and periodic components used in air quality forecasting", *Atmospheric Environment*, Vol. 35, pp. 815-825, 2001.
- [11] S. M. Nagendra, M. Khare, "Artificial neural network approach for modelling nitrogen dioxide dispersion from vehicular exhaust emissions", *Ecological Modelling*, Vol. 190, pp. 99–115, 2006.
- [12] M. Arhami, N. Kamali, M. Rajabi, "Predicting hourly air pollutant levels using artificial neural networks coupled with uncertainty analysis by Monte Carlo simulations", *Environ Sci Pollut Res*, Vol 20, pp. 4777–4789, 2013.
- [13] H. Amirbeygi, and A. Ahmadi, *Health and techniques to combat air pollution*, Tehran: Andishe Rafi, 2007.
- [14] M. W. Gardner, S. R. Dorling, "Neural network modelling and prediction of hourly NO<sub>x</sub> and NO<sub>2</sub> concentrations in urban air in London", *Atmospheric Environment*, Vol 33, pp. 709-719, 1999.
- [15] P. Perez, and A. Trier, "Prediction of NO and NO<sub>2</sub> concentrations near a street with heavy traffic in Santiago, Chile", *Atmos. Environ.*, Vol. 35, pp. 1783-1789, 2011.



- [16] M. S. Sadr Mousavi, and A. Rahimi, "Comparison of Multilayer Perceptron Neural Networks with multiple regression to predict the concentration of ozone in Tabriz", *Natural Geography Research*, Vol. 71, pp. 65-72, 2010.
- [17] I. G. McKendry, "Evaluation of artificial neural networks for fine particulate pollution (PM10 and PM2.5) forecasting", *Airwate manage Assoc*, Vol. 52(9), PP. 1096-1101, 2002.
- [18] G. Grivas, and A. Chaloulakou, "Artificial neural network models for prediction of PM<sub>10</sub> hourly concentrations, in the Greater Area of Athens, Greece", *Atmospheric Environment*, Vol. 40, pp. 1216 – 1229, 2006.
- [19] U. L. Saufie, "Comparison Between Multiple Linear Regression and Feed forward Back Propagation Neural Network Model for predicting PM<sub>10</sub> Concentration Level Based on Gaseous and meteorological Parameters", *International Journal of Applied Science and Technology*, Vol. 1:4, pp. 42-49, 2011.
- [20] D. Jiang, Y. Zhanga, X. Hua, Y. Zenga, J. Tanb, D. Shao, "Progress in developing an ANN model for air Pollution index forecast. *Atmospheric Environment*", Vol. 38, pp. 7055–7064, 2004.
- [21] R. Dennis, T. Fox, M. Fuentes, A. Gilliland, S. Hanna, C. Hogrefe, "A framework for evaluating regional-scale numerical photochemical modeling systems", *Environ Fluid Mech*, Vol. 10, pp. 471 – 489, 2010.
- [22] K. Siwek, and S. Osowaski, "Improving the accuracy of prediction of PM<sub>10</sub> pollution by the wavelet transformation and an ensemble of neural predictors", *Engineering Applications of Artificial Intelligence*, Vol. 25, pp. 1246–1258, 2012.
- [23] X. Feng, Q. Li, Y. Zhu, J. Hou, L. Jin, J. Wang, "Artificial neural networks forecasting of PM<sub>2.5</sub> pollution using air mass trajectory based geographic model and wavelet transformation", *Atmospheric Environment*, Vol. 107, pp. 118-128, 2015.
- [24] S. Lee, CH. Ho, YS. Choi, "High-PM10 concentration episodes in Seoul, Korea: background sources and related meteorological conditions", *Atmos Environ*, Vol. 45(39), pp. 7240–7247, 2011.
- [25] Wang, P., Liu, Y., Qin, Z., Zhang, G., "A novel hybrid forecasting model for PM<sub>10</sub> and SO<sub>2</sub> daily concentrations", *Science of the Total Environment* Vol. 505, pp. 1202–1212, 2015.
- [26] H. Zhang, W. Zhang, A. Palazoglu, "Sun W. Prediction of ozone levels using a Hidden Markov Model HMM with Gamma distribution", *Atmos Environ*, Vol. 62: pp. 64–73, 2012.
- [27] J. Kukkonen, L. Partanen, A. Karppinen, J. Ruuskanen, H. Junninen, M. Kolehmainen, H. Niska, S. Dorling, T. Chatterton, R. Foxall, G. Cawley, "Extensive evaluation of neural network models for the prediction of NO<sub>2</sub> and PM<sub>10</sub> concentrations, compared with a deterministic modelling system and measurements in central Helsinki", *Atmospheric Environment*, Vol. 37, pp. 4539 – 4550, 2003.
- [28] M. Kolehmainen, H. Martikainen, J. Ruuskanen, "Neural networks and periodic components used in air quality forecasting", *Atmospheric Environment*, Vol. 35, pp. 815-825, 2001.
- [29] A. Bryman, and D. Gramer, *Quantitative Data Analysis with IBM SPSS 17, 18 & 19: A Guide for Social Scientists*, Taylor and Francis, 2012.
- [30] J. H. Davis, *Statistics for Compensation: A Practical Guide to Compensation Analysis*, Wiley, 2011.
- [31] L. Hrust, Z. Bencetic, J. Krizan, O. Antonic, P. Hercog, "Neural network forecasting of air pollutants hourly concentrations using optimized temporal averages of meteorological variables and pollutant concentrations", *Atmospheric Environment*, Vol. 43, pp. 5588–5596, 2009.
- [32] A. Matkan, A. Shakiba, H. Pourali, I. Baharlou, "Determining of spatial and temporal variations of carbon monoxide and particulate matter pollution, using GIS techniques in Tehran", *Iranian Remote Sensing & GIS*, Vol. 1(1), pp. 57-72, 2009.



## Linear and nonlinear modeling of Tehran air pollutants based on environmental and traffic attributes

Aboodi, M.R.<sup>1</sup>, Karami, J.\*<sup>2</sup>, Shamsoddini, A.<sup>3</sup>

1-M.Sc. student of remote sensing and GIS in Department of RS and GIS, Faculty of Humanities, Tarbiat Modares University, Tehran, Iran

2- Assistant Professor in Department of RS and GIS, Faculty of Humanities, Tarbiat Modares University, Tehran, Iran

3- Assistant Professor in Department of RS and GIS, Faculty of Humanities, Tarbiat Modares University, Tehran, Iran

### Abstract

In the recent years, the air pollution of Tehran, as capital city of Iran, emerged as a serious challenge threatening the people's health and environment elements. In order to improve the quality of life including health level, especially in the metropolitans such as Tehran, a good understanding of air pollution is required to preserve the urban environment and making macro policies in a country. To achieve this goal, short-term prediction of the air pollution is demanding. The aim of this research is to design and develop an optimal artificial neural network-based model as a nonlinear model and compare its performance with performance of a multiple-linear regression-based model (MLR) as a linear model for predicting carbon monoxide (CO) and nitrogen dioxide (NO<sub>2</sub>) amounts. For this purpose, of the feasibility of the environmental and traffic attributes were examined. The results indicated NO<sub>2</sub> to be more accurately predicted than CO. Moreover, while, multi-layer perceptron neural networks statistically performed more accurate than MLR for predicting CO concentration, there is no significant difference between these methods predicting NO<sub>2</sub>.

**Keywords:** Air pollution modeling, Nitrogen dioxide, Carbon monoxide, Environmental attributes, traffic.

\*Correspondence Address: Department of Remote Sensing and GIS, Faculty of Humanities, Tarbiat Modares University, Tehran, Iran. Tel: + 98 21 82883696  
Email: JL.Karami@modares.ac.ir