

## یک روش مبتنی بر شبکه عصبی جهت اندازه‌گیری بهنگام غلظت آلاینده‌های گازی شهر تهران با استفاده از تصاویر سنجنده مادیس

مینا صالح<sup>۱</sup>، رضا شاه‌حسینی<sup>۲\*</sup>، زهرا بهرامیان<sup>۲</sup>، سارا خانبانی<sup>۲</sup>

۱- کارشناس ارشد سیستم‌های اطلاعات مکانی، موسسه آموزش عالی غیرانتفاعی غیردولتی پویندگان دانش، چالوس  
۲- استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکده فنی، دانشگاه تهران  
۳- دانشجوی دکتری فتوگرامتری، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکده فنی، دانشگاه تهران

تاریخ دریافت مقاله: ۱۴۰۲/۰۵/۰۱ تاریخ پذیرش مقاله: ۱۴۰۲/۱۰/۰۳

### چکیده

امروزه آلاینده‌های گازی به عنوان چالشی مهم در شهرهای بزرگ مطرح می‌باشند. با توجه به این که این آلاینده‌ها باعث بروز اثرات منفی بر سلامت انسان و تخریب محیط زیست می‌شود، روش‌های متعددی به منظور پیش‌بینی غلظت آلاینده‌های گازی از جمله مونواکسیدکربن ( $CO$ )، دی‌اکسیدنیترژن ( $NO_2$ ) و دی‌اکسیدگوگرد ( $SO_2$ )، توسط پژوهشگران ارایه شده است. هدف از پژوهش حاضر محاسبه بهنگام غلظت آلاینده‌های گازی با استفاده از داده‌های سنجنده مادیس شامل دمای سطح زمین به صورت شبانه و روزانه، عمق نوری آئروسول، شاخص پوشش گیاهی و داده‌های ایستگاه‌های زمینی پایش غلظت آلاینده‌ها با استفاده از شبکه عصبی پرسپترون چند لایه می‌باشد. با توجه به نتایج، شبکه عصبی پرسپترون با ۸ نورون بهترین عملکرد را نشان داده است. این ۸ نورون شامل ۴ نورون در لایه ورودی، ۳ نورون در لایه پنهان و یک نورون در لایه خروجی می‌باشد. ۸۰ درصد از داده‌ها به عنوان داده آموزشی و ۲۰ درصد داده‌ها به عنوان داده آزمایشی و ۱۵ درصد از داده‌های آموزشی نیز به منظور صحت‌سنجی شبکه در نظر گرفته شده است. با استفاده از داده‌های آموزشی و آزمایشی مذکور، پارامترهای تعداد دوره و نرخ یادگیری تحلیل حساسیت شده و مناسب‌ترین پارامترها انتخاب شده است. به منظور ارزیابی مقایسه‌ای نیز از روش رگرسیون جنگل تصادفی استفاده شده است. با توجه به نتایج، شبکه عصبی پرسپترون چند لایه نسبت به رگرسیون جنگل تصادفی عملکرد بهتری را نشان داد. در گام آخر نیز به تجزیه و تحلیل کیفی نقشه غلظت آلاینده‌ها و ارتباط آن‌ها با کاربری زمین و معابر موجود حول هر یک از ایستگاه‌های زمینی پایش کنترل کیفیت هوا پرداخته شده است. داده‌های شهر تهران به صورت سری زمانی ۶ ساله از سال ۱۳۹۳ تا ۱۳۹۹ مورد استفاده قرار گرفت. ارزیابی دقت روش پیشنهادی با استفاده از داده‌های آزمایشی، دقت ۸۶ درصدی در اندازه‌گیری آلاینده مونواکسیدکربن ( $CO$ ) و دی‌اکسیدنیترژن ( $NO_2$ ) و دقت ۹۶ درصدی را در اندازه‌گیری آلاینده دی‌اکسیدگوگرد ( $SO_2$ ) نشان داد.

کلیدواژه‌ها: آلودگی هوا، شبکه عصبی پرسپترون، آلاینده‌های گازی، رگرسیون جنگل تصادفی، سیستم اطلاعات مکانی، سنجنده مادیس.

\* نویسنده مکاتبه کننده: گروه فتوگرامتری و سنجش‌ازدور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران.

## ۱- مقدمه

امروزه به دنبال توسعه شهرها، افزایش ترافیک، صنعتی شدن و تغییرات اقلیمی، آلودگی هوا رو به افزایش بوده و به یکی از معضلات اساسی تبدیل شده است [۲]. صنعتی شدن شهرها و افزایش غلظت آلاینده‌های گازی در محیط از عوامل ایجاد آلودگی هوا به شمار می‌آیند. فعالیت‌های انسانی مانند سوزاندن سوخت‌های فسیلی و جنگل‌زدایی نیز از دیگر عوامل ایجاد آلودگی هوا محسوب می‌شوند [۴۱]. اثر گلخانه‌ای که شامل بخار آب، دی‌اکسیدکربن ( $CO_2$ )، متان ( $CH_4$ )، دی‌نیتروژن مونوکسید ( $NO_2$ ) و اوزون ( $O_3$ ) می‌باشد، منجر به آلودگی هوا می‌شود. در مناطق صنعتی و مناطق بزرگ شهری، عمده‌ترین آلاینده‌های دی‌اکسیدنیتروژن ( $NO_2$ ) و دی‌اکسیدگوگرد ( $SO_2$ ) تولید می‌شوند. در اصل انتشار گازهای گلخانه‌ای باعث افزایش دمای سطح زمین شده است. آلودگی هوا پدیده‌ای سطحی است اما گرم شدن زمین پدیده اتمسفری در سطوح بالاتر جو است [۸]. آلودگی هوا اثرات بدی بر سلامت انسان دارد و علت بسیاری از اختلالات پوستی و تنفسی در انسان به شمار می‌رود و همچنین باعث بروز بیماری‌های قلبی و دیگر بیماری‌ها می‌شود [۳۵]. در برخی موارد آلودگی هوا در شهرهای بزرگ از حد استاندارد فراتر رفته که نگرانی‌ها را به دنبال داشته است و بررسی آن به عنوان یک موضوع حیاتی حایز اهمیت است. داشتن تصویر روشن از آلودگی هوا این امکان را به مدیران شهری و محیط زیست می‌دهد تا با اتخاذ تصمیمات درست، از تشدید مساله جلوگیری کرده و همچنین اثرات اعمال طرح‌های مختلف به منظور کاهش آلودگی هوا را مورد ارزیابی و بازنگری قرار دهند [۶].

تاکنون پژوهش‌های متعددی جهت بررسی میزان غلظت آلاینده‌های گازی انجام شده است. در برخی مقالات از داده‌های ایستگاه‌های زمینی به طور مستقل برای اندازه‌گیری غلظت آلاینده‌ها و در برخی دیگر از مقالات از اطلاعات مبتنی بر تصاویر سنجش از دوری

به منظور بررسی غلظت آلاینده‌ها استفاده شده است [۶، ۸، ۴۱، ۴۹ و ۵۱]. با توجه به محدودیت تعداد ایستگاه‌های زمینی و محدودیت ثبت داده‌ها در برخی سنجنده‌ها مانند سنتینل 5P و همچنین محدودیت در قدرت تفکیک مکانی برخی سنجنده‌ها، ارایه روشی که قادر باشد به صورت همزمان از داده‌های سنجش از دوری با قدرت تفکیک زمانی بالا و همچنین از اطلاعات ایستگاه‌های زمینی به منظور اندازه‌گیری بهنگام غلظت آلاینده‌ها در سطح وسیع استفاده کند، حایز اهمیت است. در این پژوهش، ترکیب داده‌های مادیس با قدرت تفکیک زمانی ۲۴ ساعت و داده‌های ایستگاه‌های زمینی پایش غلظت آلاینده‌ها به منظور اندازه‌گیری بهنگام غلظت آلاینده‌ها در سطح شهر تهران به صورت داده‌های سری زمانی ۶ ساله، با استفاده از شبکه عصبی پرسپترون چندلایه پیشنهاد شده است. آموزش شبکه بصورت نقطه‌ای در سطح ایستگاه‌ها انجام شده و سپس نقشه‌های غلظت آلاینده‌ها در سطح وسیع به صورت رستری ایجاد شده است. به منظور بررسی اثر پارامترهای کاربری زمین و سطح دسترسی به شریان‌های اصلی و فرعی بر روی تغییرات غلظت آلاینده‌های گازی، مناطق حریمی با شعاع مشخص حول هر یک از ایستگاه‌های پایش کنترل کیفیت هوا در هر یک از نقشه‌های تولید شده تعریف می‌شود، سپس مقدار غلظت آلاینده‌ها و پارامترهای کاربری و شریان‌های موجود در هر منطقه حریم مورد تجزیه و تحلیل قرار می‌گیرد و در آخر خروجی‌های شبکه عصبی پرسپترون با نتایج خروجی رگرسیون جنگل تصادفی مورد مقایسه قرار می‌گیرد.

## ۲- مروری بر مطالعات پیشین

تاکنون تحقیقات متعددی به منظور پیش‌بینی و اندازه‌گیری غلظت آلاینده‌های گازی ارائه شده است. برخی از این تحقیقات مبتنی بر داده‌های سنجش از دوری و سیستم اطلاعات مکانی بوده که با توجه به موضوع تحقیق در ادامه مروری بر این مطالعات انجام شده است. در پژوهش انجام شده توسط اقبال (۲۰۱۱)،

ساختار شبکه عصبی مصنوعی با ۳۰ نورون بهترین عملکرد را در این مطالعه نشان داد. با توجه به نتایج مقاله، شبکه عصبی پرسپترون چند لایه نسبت به مدل‌های رگرسیون خطی عملکرد بهتری را نشان داده است [۴۱]. در مطالعه مروری بای و همکاران (۲۰۱۸)، روش‌های آماری مورد استفاده در پیش‌بینی آلودگی هوا (مدل پیش‌بینی پتانسیل، روش‌های پیش‌بینی سه بعدی و مدل ترکیبی) مورد بررسی قرار گرفت. با توجه نتایج نشان داد مدل‌های آماری کاربرد گسترده‌ای دارند و وابستگی زیادی به رویکرد داده‌های سری زمانی نشان می‌دهند [۷]. در مقاله دل‌اور و همکاران (۲۰۱۹)، با استفاده از پارامترهای دما، سرعت باد و بارش از طریق روش‌های تطبیقی الگوریتم‌های یادگیری ماشین شامل الگوریتم تقویت گرادیان<sup>۴</sup> رگرسیون وزن‌دار مکانی<sup>۵</sup> ماشین بردار پشتیبان<sup>۶</sup> و شبکه عصبی مصنوعی برای پیش‌بینی آلودگی هوای شهر تهران استفاده شد. نتایج نشان دادند که شبکه عصبی مصنوعی عملکرد بهتری داشته است [۱۲]. در پژوهش میرزایی (۱۳۹۹)، از شاخص ضریب همبستگی ( $R^2$ ) برای تعیین بهترین مدل شبکه عصبی آلاینده‌های ازن ( $O_3$ )، مونواکسیدکربن ( $CO$ )، دی‌اکسیدنیترژن ( $NO_2$ ) و دی‌اکسیدگوگرد ( $SO_2$ ) استفاده شد. نتایج تحقیق عملکرد بهتر شبکه عصبی در مقایسه با رگرسیون خطی در مدل‌سازی غلظت آلاینده‌های گازی را نشان داد که حاکی از توانایی شبکه عصبی در مدل‌سازی روابط پیچیده غیرخطی بین داده‌های ورودی و غلظت آلاینده‌ها می‌باشد [۲]. در مطالعه پویانگ و همکاران (۲۰۲۰)، به بررسی آلودگی و کیفیت هوا در اطراف

غلظت آلاینده‌های ذرات معلق ( $PM_{10}$ )، اکسیدهای نیتروژن ( $NO_x$ )، اوزون ( $O_3$ )، دی‌اکسیدکربن ( $CO_2$ ) و دی‌اکسیدگوگرد ( $SO_2$ ) با استفاده از سیستم اطلاعات مکانی و سنجش از دور مورد بررسی قرار گرفت. در این مطالعه، میزان تاثیر کاربری زمین بر روی مقادیر غلظت آلاینده‌ها در نظر گرفته شد و با توجه به نتایج به دست آمده، همه آلاینده‌ها بجز اوزون ( $O_3$ ) متاثر از حجم ترافیک بوده و غلظت آلاینده‌ها ارتباط مستقیمی با تراکم جاده‌ها داشتند [۲۳]. در پژوهش انجام شده توسط امینی و همکاران (۲۰۱۳)، داده‌های ذرات معلق ( $PM_{10}$ )، دی‌اکسیدگوگرد ( $SO_2$ ) و دی‌اکسیدنیترژن ( $NO_2$ ) از بیست و سه ایستگاه نظارت بر کیفیت هوای تهران در سال ۲۰۱۰ استخراج شدند. غلظت آلاینده‌های هوا با انواع کاربری‌های زمینی و اقدامات ترافیکی به عنوان کار مقدماتی برای توسعه مدل‌های رگرسیون خطی در تهران مورد تجزیه و تحلیل قرار گرفته شد. بدین ترتیب یک روش چند معیاره مبتنی بر سری‌های زمانی برای پیش‌بینی کیفیت هوا پیشنهاد شد [۶]. در مقاله ارایه شده توسط سجادیان (۱۳۹۴)، غلظت آلاینده مونواکسیدکربن ( $CO$ ) در یک ایستگاه در شهر تهران مورد بررسی قرار گرفت. داده‌های هواشناسی شامل سرعت باد، جهت باد و دما در یک ایستگاه استفاده شد. از روش رگرسیون خطی برای تحلیل و از شبکه عصبی مصنوعی به منظور پیش‌بینی زمانی احتمال وقوع آلودگی هوا به کار گرفته شد. نتایج نشان داد مهم‌ترین آلاینده هوا متاثر از حمل و نقل در کلان‌شهر تهران، آلاینده  $CO$  بوده است [۱]. در مقاله رحیمی (۲۰۱۷)، غلظت آلاینده  $NO_2$  و  $NO_x$  در شهر تبریز بررسی شد که در آن از داده‌های هواشناسی شامل جهت باد، سرعت باد و دما استفاده شد. طراحی معماری شبکه بر اساس تئوری تقریب کولموگوروف<sup>۱</sup> و

<sup>۲</sup> Artificial Neural Network (ANN)

<sup>۳</sup> Multilayer Perceptron neural network (MLP)

<sup>۴</sup> Linear regression models (LUR)

<sup>۵</sup> Gradient Boosting Algorithms

<sup>۶</sup> Geographically Weighted Regression (GWR)

<sup>۷</sup> Support Vector Machine (SVM)

<sup>۱</sup> Kolmogorov

معدن در منطقه لونگ سون استان هوآبین کشور ویتنام پرداخته شد. از تصاویر ماهواره‌های لندست ۸<sup>۱</sup> با قدرت تفکیک مکانی ۳۰ متر در ۳ دوره در سال‌های ۲۰۱۳، ۲۰۱۵ و ۲۰۱۷ برای محاسبه شاخص‌های پوشش گیاهی و شاخص کیفیت هوا<sup>۲</sup> استفاده شد. نتایج به دست آمده نشان داد که سطح آلودگی هوا به تدریج از سال ۲۰۱۵ به شدت افزایش یافت که نشان از نبود *AQI* داشت [۳۱]. در پژوهش سلیمانی و گروبلیاوسکاس (۲۰۲۰)، داده‌های ایستگاه محیطی و داده‌های ماهواره‌های سنجنش از دور، شامل سنجنده تراآگوا<sup>۴</sup>، ام‌آی، سنتینل ۵<sup>۵</sup> و داده‌های آلاینده‌های  $SO_2$  و  $NO_2$  از ایستگاه‌های پایش کیفیت هوا واقع در نقاط مختلف شهر کاوناس در کشور لیتوانی جمع‌آوری شد. نتایج نشان دادند که تصاویر ماهواره‌ای سنتینل ۵<sup>۵</sup> به منظور پایش غلظت آلاینده‌های  $SO_2$  و  $NO_2$  نسبت به دیگر تصاویر ماهواره‌ای عملکرد بهتری داشته است [۴۹].

در تحقیقات انجام شده، از روش‌های رگرسیونی مانند رگرسیون خطی، رگرسیون وزن دار، رگرسیون وزنی جغرافیایی و همچنین الگوریتم‌های یادگیری ماشین مانند ماشین بردار پشتیبان، الگوریتم‌های شبکه عصبی مانند شبکه عصبی پرسپترون چند لایه و شبکه عصبی بازگشتی، روش‌های یادگیری عمیق، الگوریتم‌های بهینه‌سازی مانند ژنتیک و مدل‌های آماری وابسته به سری‌های زمانی، به منظور مدل‌سازی و سپس پیش‌بینی غلظت آلاینده‌ها استفاده شده است. در برخی موارد با توجه به هدف، از داده‌های زمینی مانند توپوگرافی، سرعت باد، جهت باد، فشار هوا، بارش، دما، رطوبت نسبی و کاربری زمین نیز در کنار داده‌های

<sup>۱</sup> Landsat8 satellite<sup>۲</sup> Air quality index (AQI)<sup>۳</sup> Terra satellite<sup>۴</sup> Aqua satellite<sup>۵</sup> OMI sensor<sup>۶</sup> Sentinel-5P

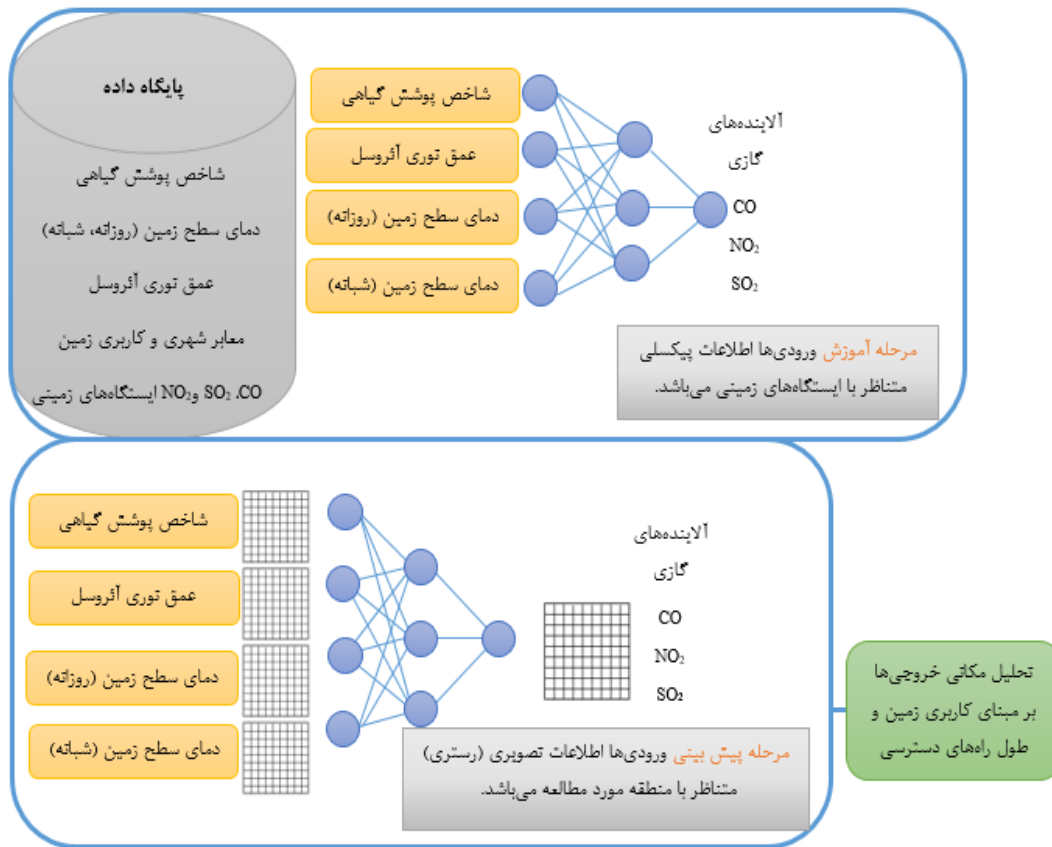
سنجنش از دوری استفاده شده است. با توجه به نتایج مطالعات پیشین ارائه روشی که همزمان قادر به بکارگیری داده‌های ایستگاه‌های زمینی و داده‌های سنجنش از دوری باشد، حائز اهمیت می‌باشد. روش شبکه عصبی پرسپترون چندلایه با توجه به توانایی مدلسازی روابط غیرخطی، ابزاری مهم در بحث اندازه‌گیری غلظت آلاینده‌ها و برقراری ارتباط بین داده‌های سنجنش از دوری و زمینی می‌باشد. فاصله ایستگاه‌های پایش کیفیت غلظت آلاینده‌ها در سطح منطقه مورد مطالعه (شهر تهران) زیاد است، لذا ارائه مقادیر غلظت آلاینده‌ها در سطح شهر (نقشه غلظت آلاینده‌ها) می‌تواند اطلاعات غنی را فراهم کند. بررسی پارامترهای کاربری و دسترسی به شریان‌ها و ارتباط آن‌ها با مقادیر غلظت آلاینده‌ها نیز اطلاعات مهمی را به منظور بازنگری طرح‌های محدودیتی کنترل آلودگی می‌تواند فراهم کند.

### ۳- روش‌شناسی تحقیق

روش ارائه شده در این تحقیق به منظور اندازه‌گیری بهنگام غلظت آلاینده‌ها و بررسی اثرات کاربری زمین و شریان‌ها بر روی مقادیر غلظت آلاینده‌ها در پنج گام کلی ارائه شده است:

گام اول: مدل‌سازی غلظت آلاینده‌های گازی با استفاده از شبکه عصبی پرسپترون چند لایه  
گام دوم: ارزیابی شبکه آموزش دیده شده  
گام سوم: تخمین آلاینده گازی از شبکه آموزش دیده به صورت رستری با استفاده از شبکه عصبی پیشنهادی  
گام چهارم: بررسی تاثیر کاربری زمین و دسترسی به معابر بر روی تغییرات غلظت آلاینده‌های گازی  
گام پنجم: ارزیابی مقایسه‌ای

در ادامه هر یک از پنج گام مذکور به تفصیل تشریح شده است. نمایش شماتیک گام اول تا سوم در شکل (۱) آورده شده است.



شکل ۱: مدل مفهومی روش پیشنهادی

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{رابطه (۱)}$$

با توجه به توانایی سنجنده مادیس در فراهم آوردن اطلاعات با قدرت تفکیک زمانی بالا و قابلیت محصولات این سنجنده مانند شاخص عمق نوری اپتیکی آئروسول<sup>۲</sup>، شاخص دمای سطح زمین<sup>۳</sup> و شاخص پوشش گیاهی<sup>۴</sup> و تاثیر آنها بر مقادیر غلظت آلاینده‌های گازی، در این تحقیق از شاخص‌های مذکور به عنوان شاخص‌های اثرگذار بر غلظت آلاینده‌ها استفاده شد. در

<sup>۲</sup> Aerosols optical depth (AOD)

<sup>۳</sup> Land surface temperature (LST)

<sup>۴</sup> Normalized difference vegetation index (NDVI)

### گام اول: مدل‌سازی غلظت آلاینده‌های گازی با استفاده از شبکه عصبی پرسپترون چند لایه

در گام اول به منظور مدل‌سازی و محاسبه بهنگام آلاینده‌های گازی در سطح شهر تهران، داده‌های سنجنش از دوری و داده‌های زمینی پایش غلظت آلاینده‌ها به صورت سری زمانی ۶ ساله مبنای مطالعه قرار گرفت. با توجه به قابلیت شبکه‌های عصبی در مدل‌سازی توابع غیرخطی و توانایی این شبکه‌ها در بررسی داده‌های پرت، در این تحقیق از شبکه عصبی پرسپترون چند لایه با تابع فعال‌سازی سیگموئید و تابع تنه<sup>۱</sup> مطابق با رابطه (۱) استفاده شد.

<sup>۱</sup> Tanh

نشان می‌دهد و حتی در شرایط متفاوت سلامتی گیاه، انعکاس طیفی تحت تاثیر قرار می‌گیرد.  $NDVI$  یکی از مهم ترین شاخص‌های گیاهی است که می‌توان به منظور بررسی سلامت گیاه به آن استناد کرد. غلظت آلاینده‌ها به صورت مستقیم بر روی سلامت گیاه تاثیر گذار است؛ به همین دلیل استفاده از شاخصی که بتواند سلامت گیاه را نشان دهد عاملی موثر در بررسی غلظت آلاینده‌ها خواهد بود.

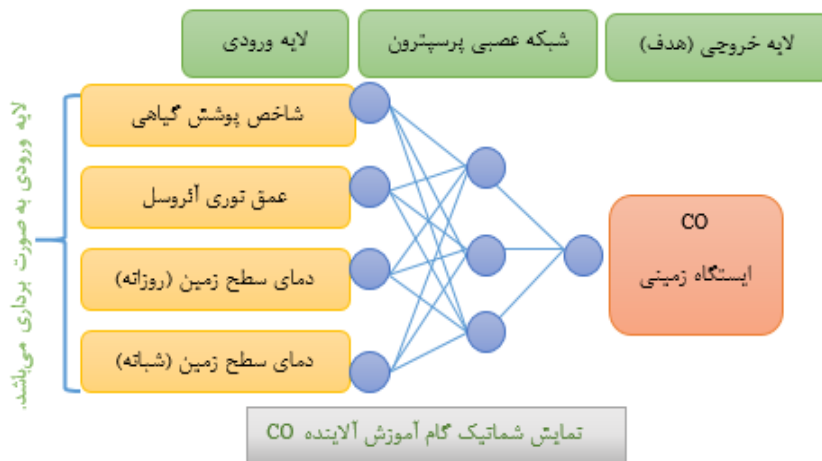
به منظور مدل‌سازی غلظت آلاینده‌ها با استفاده از روش شبکه عصبی پرسپترون چند لایه و با استفاده از داده‌های مذکور، ابتدا داده‌های سنجش از دوری متناظر با طول و عرض جغرافیایی ایستگاه‌های پایش کیفیت آلودگی در محدوده‌های زمانی که داده‌های زمینی جمع‌آوری شده و یا موجود بودند، تهیه و آماده‌سازی شده و مطابق با شکل وارد شبکه عصبی پرسپترون چند لایه می‌شود. شکل (۲) مدل مفهومی گام ۱ را به صورت شماتیک برای آلاینده‌ی گازی  $CO$  نمایش می‌دهد.

ادامه به شرح هر یک از این شاخص‌ها پرداخته شده است:

عمق نوری اپتیکی آئروسول میزان جلوگیری از گذر نور زیاد در جو به خاطر جذب و پراکنش ناشی از وجود آئروسول (هواویزها) در مسیر عبور نور می‌باشد. همچنین  $AOD$  به عنوان ضریب خاموشی کاهش تشعشع بر روی یک ستون قائم در واحد طول تعریف می‌شود. این شاخص یکی از پارامترهای مهم در آب و هوا و گرد و غبارها می‌باشد و در واقع به توزیع آئروسول‌های موجود در جو اشاره دارد [۷].

دمای سطح زمین در تصاویر ماهواره‌ای شامل میانگین دمای پیکسلی بوده که پوشش‌دهنده سطح زمین است. این شاخص بر اساس انرژی رسیده به سنجنده (رادیانس) در باند حرارتی محاسبه می‌شود و به صورت روزانه و شبانه در دسترس قرار می‌گیرد.

استفاده از شاخص‌های گیاهی استخراج شده از تصاویر سنجش از دوری اطلاعات مفیدی را درباره سلامت گیاه در اختیار قرار می‌دهند. طیف الکترومغناطیسی در شرایط مختلف گیاه، انعکاس‌های متفاوتی را از خود



شکل ۲: نمایش شماتیک گام آموزش آلاینده  $CO$

از سه لایه شامل یک لایه ورودی، یک لایه پنهان و یک

شبکه عصبی پرسپترون چند لایه<sup>۱</sup> ( $MLP$ ) پیشنهادی


<sup>۱</sup>multilayer perceptron neural network

جغرافیایی ایستگاه‌های پایش کیفیت غلظت آلاینده‌ها در طی ۶ سال آماده‌سازی شده است. داده‌ها به دو دسته آموزش و آزمایش طبقه‌بندی شده است. از ۳۹۶۲۶ داده، ۳۱۶۶۱ داده (معادل ۸۰ درصد) به منظور آموزش شبکه، ۷۹۶۵ داده (معادل ۲۰ درصد) برای آزمایش شبکه و ۱۵ درصد از داده‌های آموزشی نیز برای صحت سنجی شبکه در نظر گرفته شده است. شکل (۳) نمایش شماتیک مرحله ارزیابی شبکه را نشان می‌دهد. در مرحله آزمایش، خروجی شبکه *MLP* با مقادیر آلاینده‌های گازی ثبت شده در ایستگاه‌های زمینی پایش کنترل کیفیت هوا مقایسه شده است.

لایه خروجی تشکیل شده است. این شبکه، از ۴ نورون در لایه ورودی شامل شاخص پوشش گیاهی، دمای سطح زمین به صورت شبانه و روزانه و عمق نوری اپتیکی آئروسول می‌باشد که هر چهار شاخص مذکور، از محصولات سنجنده مادیس با قدرت تفکیک یک کیلومتر هستند. لایه پنهان از ۳ نورون تشکیل شده و لایه خروجی از یک نورون که یکی از آلاینده‌های گازی شامل مونوکسید کربن ( $CO$ )، دی‌اکسید نیتروژن ( $NO_2$ ) و دی‌اکسید گوگرد ( $SO_2$ ) می‌باشد که از ایستگاه‌های پایش کنترل کیفیت هوا گرفته شده است.

### گام دوم: ارزیابی شبکه آموزش دیده شده

در این پژوهش جمعاً ۳۹۶۲۶ داده متناظر با مختصات




شکل ۳: نمایش شماتیک گام آزمایش شبکه برای آلاینده  $CO$

سنجنده مادیس و بصورت رستری فراهم می‌شود. داده‌ها از حالت رستری به برداری تبدیل شده و وارد شبکه‌ای که در گام دوم آموزش دیده است، می‌شوند و سپس نتایج مجدد به حالت رستری تبدیل می‌شود. شکل (۴) نمایش شماتیک تخمین و پیش‌بینی آلاینده‌های گازی را نشان می‌دهد.

**گام سوم: تخمین آلاینده گازی از شبکه آموزش دیده به صورت رستری با استفاده از شبکه عصبی پیشنهادی**

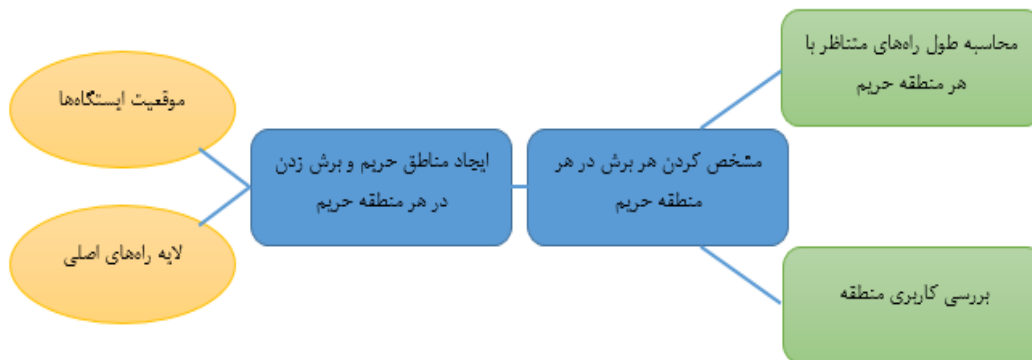
پس از آموزش شبکه عصبی و انتخاب پارامترهای مناسب برای تخمین هر یک از آلاینده‌های مطرح شده، تصاویر مربوط به هر یک از شاخص‌ها، از داده‌های



شکل ۴: نمایش شماتیک گام تخمین آلاینده CO از شبکه آموزش یافته

و دسترسی به شریان‌های موجود بر روی تغییرات غلظت آلاینده‌ها، مناطق حریم با اندازه‌های مشخص و به صورت یک بخشی حول هر یک از ایستگاه‌های پایش کنترل کیفیت هوا در نظر گرفته می‌شود. مطابق شکل (۵) در هر منطقه حریم طول راه‌های اصلی و فرعی مورد بررسی قرار گرفته و مجموع فواصل حول هر ایستگاه ثبت می‌شود.

**گام چهارم: بررسی تاثیر کاربری زمین و دسترسی به معابر بر روی تغییرات غلظت آلاینده‌های گازی**  
در گام چهارم تاثیر کاربری زمین و طول راه‌ها در افزایش و کاهش غلظت آلاینده‌های گازی مناطق حریم مورد تجزیه و تحلیل قرار گرفت. پس از محاسبه آلاینده‌های گازی مطابق با روش پیشنهادی در ۳ گام گذشته، به منظور بررسی اثر پارامترهای کاربری زمین



شکل ۵: نمایش شماتیک بررسی کاربری

ماشینی است که برای حل مسائل مربوط به رگرسیون و طبقه‌بندی مورد استفاده قرار می‌گیرد. مبنای روش جنگل تصادفی، یادگیری گروهی است؛ تکنیکی که بسیاری از طبقه‌بندی‌کننده‌ها را برای ارائه راه‌حل‌هایی برای حل مسائل پیچیده ترکیب می‌کند.

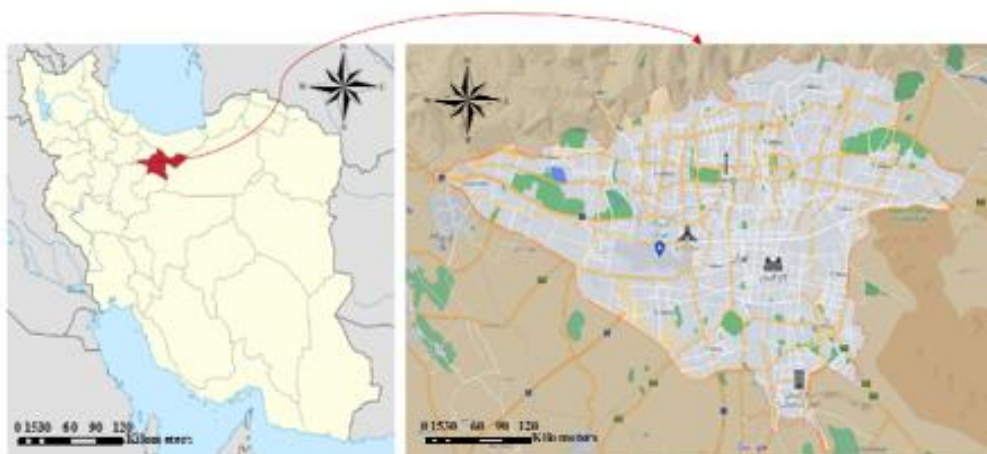
**گام پنجم: ارزیابی مقایسه‌ای**

در گام پنجم به منظور ارزیابی مقایسه‌ای، نتایج خروجی شبکه عصبی پرسپترون چند لایه با نتایج خروجی روش رگرسیون جنگل تصادفی مورد مقایسه قرار گرفت. روش جنگل تصادفی یک تکنیک یادگیری

#### ۴- داده‌ها و منطقه مورد مطالعه:

شهر تهران در ۵۱ درجه و ۶ دقیقه تا ۵۱ درجه و ۳۸ دقیقه طول شرقی، و ۳۵ درجه و ۳۴ دقیقه تا ۳۵ درجه و ۵۱ دقیقه عرض شمالی قرار دارد و ارتفاع آن از سطح آب‌های آزاد بین ۱۸۰۰ متر در شمال تا ۱۲۰۰ متر در مرکز و ۱۰۵۰ متر در جنوب آن متغیر است. تهران به عنوان بزرگترین کلان‌شهر ایران در زمره آلوده‌ترین شهرهای جهان به حساب می‌آید. با توجه به تأثیرات آلودگی هوا بر سلامت و محیط‌زیست، ضرورت شناخت دقیق آلاینده‌ها و مشخص نمودن پهنه‌های آلوده، ضروری به نظر می‌رسد. میزان غلظت آلاینده‌های

گازی از جمله  $CO$ ،  $NO_2$  و  $SO_2$  در شهرهای مختلف ایران به خصوص شهر تهران، طی سال‌های اخیر افزایش یافته است که این موضوع باعث بروز نگرانی روز افزون ساکنان آن شده است. علی‌رغم استمرار معضل آلودگی هوا، فقدان مدلی که بتواند غلظت ساعتی آلاینده‌های هوا را برای تهران با دقت بالا مدل‌سازی کند، بسیار احساس می‌شود. شکل (۶) نمایی از موقعیت شهر تهران را نشان می‌دهد. داده‌های مورد استفاده در پژوهش حاضر، مطابق با جدول (۱) تهیه و جمع‌آوری شده است.



شکل ۶: نقشه تهران

جدول ۱: داده‌های مورد استفاده در پژوهش

سنجنده مادیس	محصولات	داده‌های سنجش از دوری از گوگل ارث انجین از سال ۱۳۹۳ تا ۱۳۹۹
<i>MODIS/006/MCD19A2_GRANULES</i> <i>MODIS/061/MOD11A1</i> <i>MODIS/MOD09GA_006_NDVI</i>	<i>Optical_Depth_049</i> <i>LST_Day_1km\LST_Night_1km</i> <i>NDVI</i>	
۲۱ ایستگاه پایش کنترل کیفیت هوا در تهران شامل $NO_2$ ، $SO_2$ و $CO$ کاربری زمین طول معابر شهری (اصلی و فرعی)		داده‌های زمینی از سال ۱۳۹۳ تا ۱۳۹۹

#### ۵- پیاده‌سازی و ارائه نتایج

در ادامه به بررسی نتایج مدل‌سازی غلظت آلاینده‌های گازی  $CO$ ،  $NO_2$  و  $SO_2$  با استفاده از شبکه عصبی

پرسپترون چند لایه می‌پردازیم. در گام اول روش پیشنهادی، آموزش شبکه به منظور تخمین آلاینده‌های گازی  $CO$ ،  $NO_2$  و  $SO_2$  با استفاده

تحلیل قرار می‌گیرد. تصاویر متناظر با شاخص‌ها به صورت برداری تبدیل شده، سپس وارد شبکه آموزش داده شده در گام اول می‌شوند و خروجی‌های متناظر با آلاینده‌ها مجدد به حالت رستر تبدیل می‌شود. شکل (۴) مرحله سوم را به صورت شماتیک برای آلاینده  $CO$  نشان می‌دهد. به همین ترتیب مراحل فوق برای آلاینده‌های  $SO_2$  و  $NO_2$  نیز تکرار می‌شود.

در گام چهارم به منظور تحلیل مکانی خروجی‌ها، نقشه‌های تولید شده در گام سوم با در نظر گرفتن مناطق حریمی به شعاع ۳۰۰۰ متری حول هر ایستگاه از نظر کاربری زمینی و طول شریان‌های اصلی و فرعی مورد تجزیه و تحلیل قرار می‌گیرند.

در جدول (۲) پارامتر جذر میانگین مربع خطاها<sup>۱</sup> به ازای تعداد اپک‌ها<sup>۲</sup> و نرخ‌های یادگیری<sup>۳</sup> مختلف برای هریک از آلاینده‌های گازی نشان داده شده است. برای آلاینده  $CO$ ، بهترین عملکرد در ۷۰ اپک و نرخ یادگیری ۰٫۷ مشاهده شد که کمترین مقدار  $RMSE$  و بیشترین مقدار  $R^2$  را در مقایسه با سایر مقادیر داشته است. برای آلاینده  $NO_2$ ، بهترین عملکرد را ۸۰ اپک و نرخ یادگیری ۰٫۸ نشان داد که دارای کمترین مقدار  $RMSE$  و بیشترین مقدار  $R^2$  است. برای آلاینده  $SO_2$ ، بهترین عملکرد را ۸۰ اپک و نرخ یادگیری ۰٫۲ نشان می‌دهد که دارای کمترین مقدار  $RMSE$  و بیشترین مقدار  $R^2$  است. برای هر پارامتر آنالیز حساسیت انجام شد که میانگین مقادیر حاصل در جدول (۲) آمده است. جدول (۳) مقادیر مناسب تعداد دوره و نرخ یادگیری را برای هر آلاینده در منطقه مورد مطالعه نشان می‌دهد. پارامترهای بهینه در شبکه آموزش یافته، مبنای سایر تحلیل‌ها قرار گرفته شده است.

از داده‌های ورودی انجام شده است. تعداد ۳۹۶۲۶ داده از داده‌های سنجش از دوری متناظر با ایستگاه‌های پایش کیفیت هوا (۲۱ ایستگاه) با استفاده از زیرساخت گوگل ارث انجین متناظر با سال‌های ۱۳۹۳ تا ۱۳۹۹ استخراج شده است. این داده‌ها شامل  $NDVI$ ،  $AOD$ ،  $LST Day$  و  $LST Night$ ، که به عنوان داده‌های لایه ورودی، مطابق با شکل (۲) وارد شبکه عصبی پرسپترون چند لایه می‌شوند. داده‌های غلظت آلاینده گازی متناظر با ایستگاه‌های پایش کیفیت هوا نیز در محل ایستگاه‌ها اندازه‌گیری شده است. شبکه در قسمت لایه خروجی، هر بار غلظت یکی از گازها که شامل  $NO_2$ ،  $CO$  و  $SO_2$  می‌باشد را به صورت خروجی معیار قرار می‌دهد و آموزش شبکه صورت می‌گیرد. داده‌های ورودی قبل از آموزش شبکه با توجه به رابطه (۲) نرمال‌سازی شده و شبکه عصبی به ازای پارامترهای مختلف آنالیز حساسیت می‌شود. شکل (۲) نمایش شماتیک مرحله آموزش شبکه را برای پارامتر  $CO$  نشان می‌دهد. داده در این مرحله به منظور آموزش شبکه مورد استفاده قرار گرفته که به صورت تصادفی از پایگاه داده تهیه و انتخاب شده‌اند. به همین ترتیب مراحل فوق برای  $SO_2$  و  $NO_2$  نیز تکرار می‌شود.

$$\text{رابطه (۲)} \quad X_{norm} = \frac{x - X_{min}}{X_{max} - X_{min}}$$

در گام دوم، پس از آموزش شبکه و آنالیز حساسیت شبکه در گام اول، داده‌های متناظر در مرحله آزمایش وارد شبکه شده تا برای غلظت آلاینده‌ها تخمین زده شود. مقادیر محاسبه شده در این گام با مقادیر متناظر زمینی مقایسه گردیده و ارزیابی دقت صورت می‌پذیرد. مطابق شکل (۳) نمایش شماتیک گام آزمایش شبکه به عنوان نمونه برای آلاینده گازی  $CO$  نشان داده شده است. مراحل نشان داده شده برای  $SO_2$  و  $NO_2$  نیز تکرار می‌شود.

در گام سوم شاخص‌های استخراج شده متناظر با لایه‌های شیب فایل نقشه تهران به صورت رستری مورد

<sup>1</sup>Root Mean Square Error (RMSE)

<sup>2</sup>Epoch

<sup>3</sup>Learning rate

جدول ۲: آنالیز حساسیت شبکه عصبی پیشنهادی برای آموزش شبکه به ازای پارامترهای مختلف

تعداد دوره	نرخ یادگیری	جذر میانگین مربعات خطاها			میانگین خطاها		
		آلاینده $CO$	آلاینده $NO_2$	آلاینده $SO_2$	آلاینده $CO$	آلاینده $NO_2$	آلاینده $SO_2$
۱۰	۰٫۱	۰٫۲۲۴	۰٫۲۱۱	۰٫۱۵۱	۰٫۰۵	۰٫۰۸	۰٫۰۲۵
۲۰	۰٫۱	۰٫۲۲۴	۰٫۱۸۶	۰٫۱۴۹	۰٫۰۵	۰٫۰۸۰	۰٫۰۲۰
۳۰	۰٫۱	۰٫۲۲۴	۰٫۱۷۶	۰٫۱۵۱	۰٫۰۵	۰٫۰۸	۰٫۰۲۳
۴۰	۰٫۱	۰٫۲۲۴	۰٫۲۸	۰٫۱۵۴	۰٫۰۵	۰٫۰۷	۰٫۰۲
۵۰	۰٫۱	۰٫۲۱۲	۰٫۲۹	۰٫۱۵۱	۰٫۰۵	۰٫۰۸	۰٫۰۲۳
۶۰	۰٫۱	۰٫۱۸۵	۰٫۲۹	۰٫۱۵۴	۰٫۰۴	۰٫۰۸	۰٫۰۲۳
۷۰	۰٫۷	۰٫۱۴	۰٫۲۹	۰٫۱۵۶	۰٫۰۵	۰٫۰۸	۰٫۰۲۳
۸۰	۰٫۲	۰٫۱۵	۰٫۱۴	۰٫۰۸	۰٫۰۴	۰٫۰۶	۰٫۰۲۰

جدول ۳: پارامترهای بهینه در شبکه آموزش یافته

دقت	تعداد دوره	نرخ یادگیری	آلاینده گازی
۸۶ درصد	۷۰	۰٫۷	$CO$
۸۶ درصد	۸۰	۰٫۸	$NO_2$
۹۲ درصد	۸۰	۰٫۲	$SO_2$

به ترتیب در بازه ۰٫۱۶ تا ۰٫۲۲ ppm و ۰٫۱۱ تا ۰٫۱۷ ppm قرار دارد.

با توجه به نقشه‌های رستری، خروجی رگرسیون جنگل تصادفی در هر یک از ایستگاه‌های پایش کنترل کیفیت هوا مورد ارزیابی قرار گرفت. مطابق با خروجی‌های رگرسیون جنگل تصادفی، غلظت آلاینده‌ها در روزهایی از سال ۱۳۹۶ تا ۱۳۹۹ در شکل (۸) آمده است.

با توجه به نقشه‌های رستری، خروجی شبکه عصبی پرسپترون چند لایه در هر یک از ایستگاه‌های پایش کنترل کیفیت هوا مورد ارزیابی قرار گرفت.

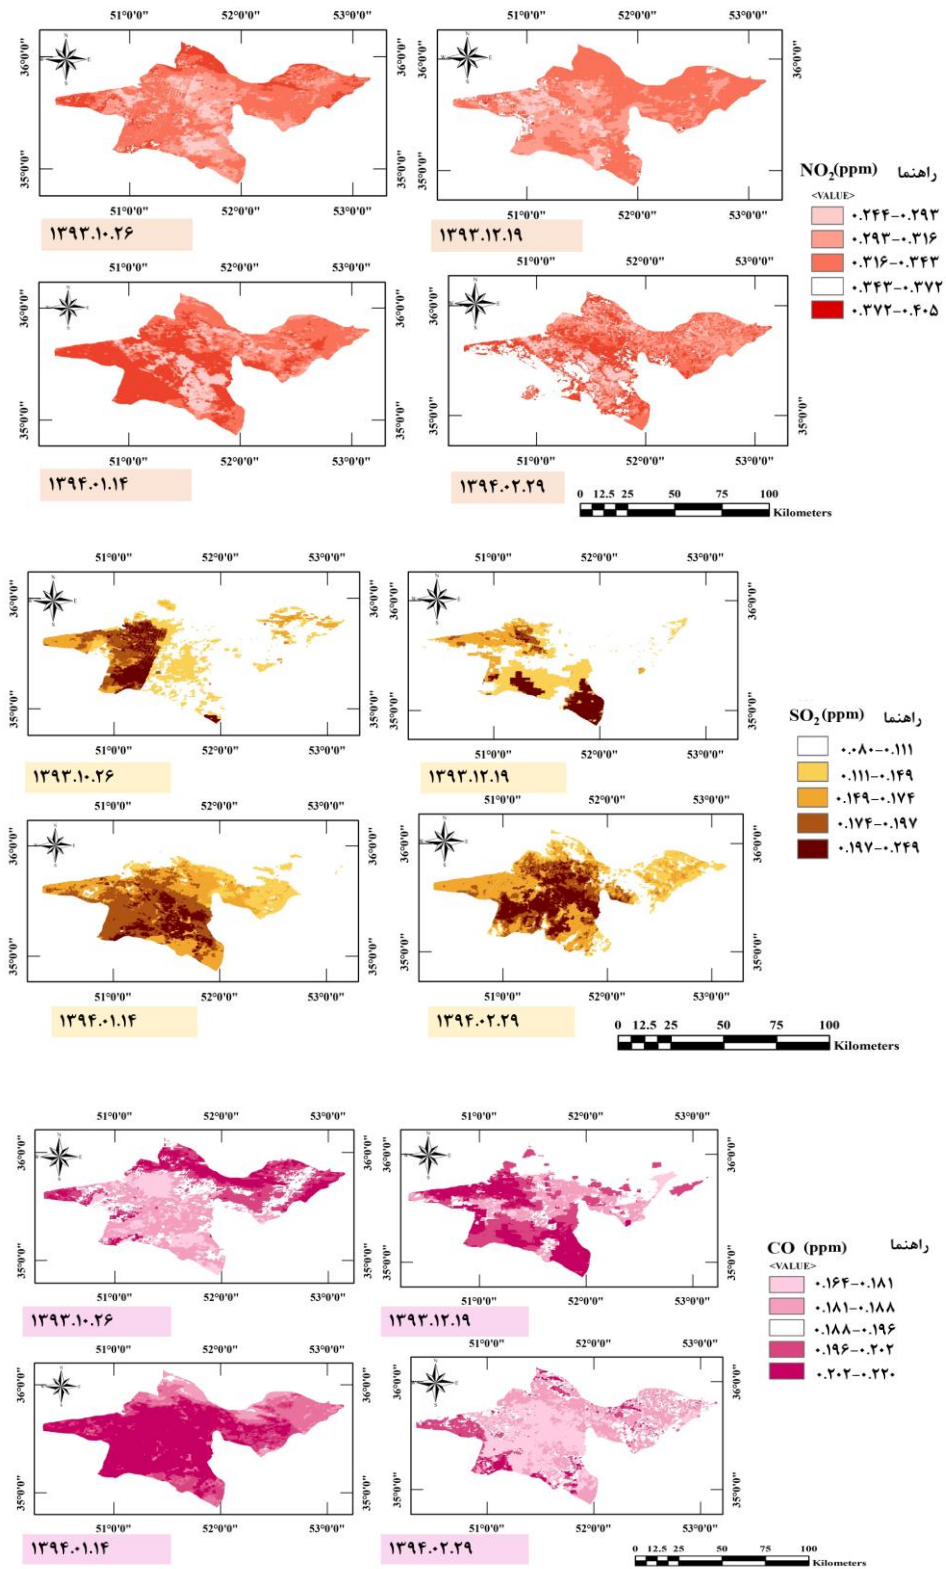
مطابق با خروجی‌های شبکه، نمودارهای غلظت آلاینده‌ها در روزهایی از سال ۱۳۹۳ و ۱۳۹۴ در شکل (۹) آمده است. در شکل (۹)، نمودار میله‌ای سبز نشان‌دهنده آلاینده  $NO_2$ ، نمودار میله‌ای قرمز مربوط به  $SO_2$  و نمودار میله‌ای آبی مربوط به آلاینده  $CO$  می‌باشد.

میزان غلظت آلاینده‌های گازی در روزهایی از سال ۱۳۹۳ و روزهایی از سال ۱۳۹۴، که با بررسی خروجی‌های شبکه عصبی پرسپترون بدست آمده، در شکل‌های (۷)، (۸) و (۹) نشان داده شده است.


نتایج خروجی‌های مذکور به طور خلاصه در جدول (۴) آورده شده است. با توجه به این نتایج، آلاینده  $NO_2$  در تاریخ ۱۳۹۳/۱۲/۱۴ بیشترین غلظت را نشان داده که در بازه ۰٫۲۴ تا ۰٫۴۰ ppm قرار دارد و کمترین غلظت این آلاینده نیز مربوط به تاریخ ۱۳۹۴/۲/۱۹ است که در بازه ۰٫۲۱ تا ۰٫۳۷ ppm قرار دارد.

آلاینده  $SO_2$  بیشترین غلظت را در تاریخ‌های ۱۳۹۴/۱/۱۲ و ۱۳۹۴/۲/۱۹ نشان داده که در بازه ۰٫۰۸ تا ۰٫۲۴ ppm قرار دارد و در تاریخ ۱۳۹۳/۱۰/۲۶ نیز کمترین غلظت این آلاینده بوده که در بازه ۰٫۰۷ تا ۰٫۱۹ ppm قرار دارد.

آلاینده  $CO$  بیشترین و کمترین غلظت را به ترتیب در روزهای ۱۳۹۳/۱۰/۲۶ و ۱۳۹۳/۱۲/۱۴ نشان داده که



شکل ۷: نقشه‌های میزان غلظت آلاینده‌های NO<sub>2</sub>، SO<sub>2</sub> و CO خروجی شبکه پرسپترون چندلایه



شکل ۸: نقشه‌های میزان غلظت آلاینده‌های  $NO_2$ ،  $SO_2$  و  $CO$  خروجی روش جنگل تصادفی



شکل ۹: نمودارهای غلظت آلاینده‌های گازی در هر ایستگاه کنترل کیفیت هوا در روزهایی از سال ۱۳۹۴ و ۱۳۹۳

جدول ۴: غلظت آلاینده‌های گازی در خروجی‌های شبکه عصبی پرسپترون


تاریخ	بازه غلظت آلاینده $CO$ ( $ppm$ )	بازه غلظت آلاینده $NO_2$ ( $ppm$ )	بازه غلظت آلاینده $SO_2$ ( $ppm$ )
۱۳۹۳/۱۰/۲۶	۰٫۲۲ الی ۰٫۱۶	۰٫۳۹ الی ۰٫۲۸	۰٫۱۹ الی ۰٫۰۷
۱۳۹۳/۱۲/۱۴	۰٫۱۷ الی ۰٫۱۱	۰٫۴۰ الی ۰٫۲۴	۰٫۲۱ الی ۰٫۰۸
۱۳۹۴/۱/۱۲	۰٫۱۷ الی ۰٫۱۳	۰٫۳۷ الی ۰٫۲۶	۰٫۲۴ الی ۰٫۰۸
۱۳۹۴/۲/۱۹	۰٫۲۱ الی ۰٫۱۶	۰٫۳۷ الی ۰٫۲۱	۰٫۲۴ الی ۰٫۰۸
۱۳۹۴/۳/۲۷	۰٫۱۷ الی ۰٫۱۳	۰٫۳۸ الی ۰٫۲۱	۰٫۲۴ الی ۰٫۰۷
۱۳۹۴/۵/۳	۰٫۱۷ الی ۰٫۱۲	۰٫۳۷ الی ۰٫۲۵	۰٫۲۱ الی ۰٫۰۸

می‌دهد. با توجه به خروجی‌های بدست آمده، میزان میانگین مربعات خطاها در شبکه عصبی پرسپترون چند لایه و رگرسیون جنگل تصادفی برای هر آلاینده مطابق با جدول (۵) مقایسه شده است که نتایج حاکی از آن است که شبکه عصبی پرسپترون چند لایه نسبت به رگرسیون جنگل تصادفی عملکرد بهتری داشته است.

با توجه به میانگین‌های مربعات خطاها ( $RMSE$ ) و نرخ یادگیری ( $Learning Rate$ ) بدست آمده در این پژوهش، از خروجی‌های شبکه پرسپترون چند لایه، نمودارهای همگرایی غلظت آلاینده‌های گازی مطابق با شکل (۱۰) ایجاد شد که نتایج بدین شرح می‌باشد: برای آلاینده  $CO$  و  $NO_2$  دقت ۸۶ درصدی و برای آلاینده  $SO_2$  به دقت ۹۲ درصدی رسیده است که عملکرد بسیار خوب شبکه عصبی پرسپترون را نشان

جدول ۵: مقایسه میانگین مربعات خطاها در شبکه عصبی پرسپترون چند لایه و رگرسیون جنگل تصادفی

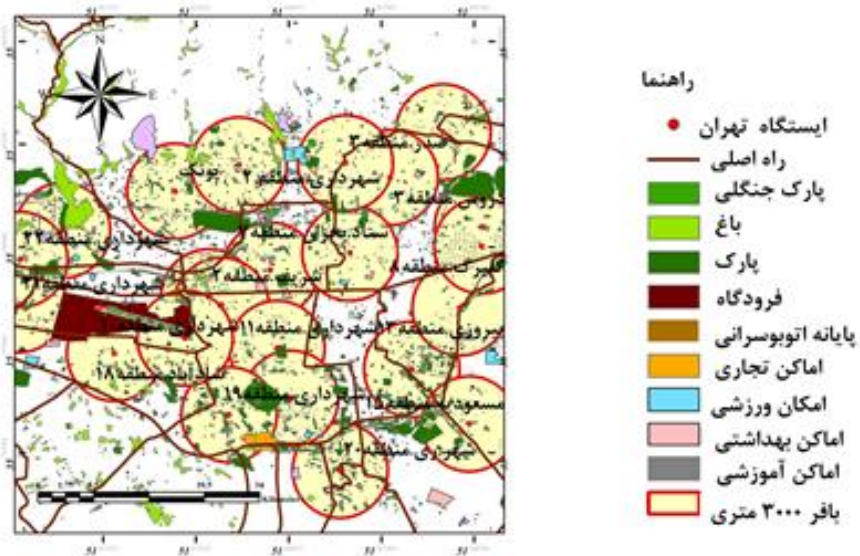
میانگین مربعات خطاها آلاینده $CO$		میانگین مربعات خطاها آلاینده $SO_2$		میانگین مربعات خطاها آلاینده $NO_2$		تاریخ
شبکه عصبی پرسپترون	جنگل تصادفی	شبکه عصبی پرسپترون	جنگل تصادفی	شبکه عصبی پرسپترون	جنگل تصادفی	
۰٫۰۳۴	۰٫۰۳۸۴	۰٫۰۲۱۳	۰٫۰۲۱۶	۰٫۰۶۱۵	۰٫۰۶۴	۱۳۹۶/۵/۴
۰٫۰۳۴	۰٫۰۴۰۰	۰٫۰۲۱۲	۰٫۰۲۱۸	۰٫۰۶۱۵	۰٫۰۶۳۶	۱۳۹۷/۵/۴
۰٫۰۳۴۳	۰٫۰۳۸۷	۰٫۰۲۰۱	۰٫۰۲۰۹	۰٫۰۶۲	۰٫۰۶۳۱	۱۳۹۸/۵/۴
۰٫۰۳۴	۰٫۰۳۹۹	۰٫۰۲۱۷	۰٫۰۲۲	۰٫۰۶۱۳	۰٫۰۶۱۴	۱۳۹۹/۵/۴



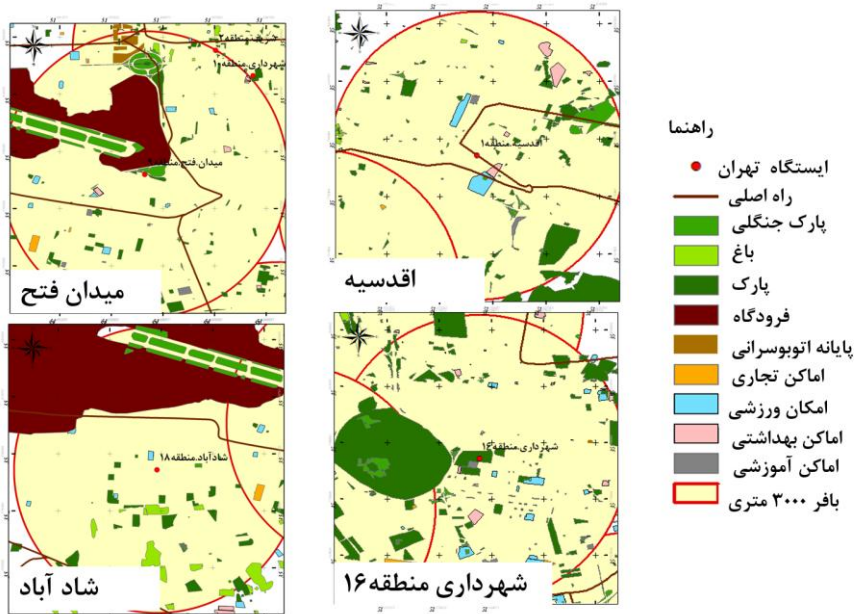
شکل ۱۰: نمودارهای بررسی آلاینده‌های گازی پس از خروجی‌های شبکه عصبی پرسپترون (الف) معیار خطا برای آلاینده NO<sub>2</sub> (ب) معیار خطا برای آلاینده SO<sub>2</sub> (ج) معیار خطا برای آلاینده CO

در بخش بعد، کاربری زمین حول هر منطقه حریم به شعاع ۳۰۰۰ متری مورد بررسی قرار گرفته است. شکل (۱۲) نقشه شماتیک کاربری زمین حول ۴ ایستگاه را نشان می‌دهد. با توجه به روزهایی که در سال‌های ۱۳۹۳ و ۱۳۹۴ در آنها میزان غلظت آلاینده‌ها در بخش‌های قبل همین مطالعه بررسی شدند، در ادامه تاثیر نوع کاربری زمین بر روی میزان غلظت این آلاینده‌ها مورد بررسی قرار گرفت. با توجه به نتایج جدول (۶)، برخی از کاربری‌ها نقش مثبت بر روی غلظت آلاینده‌ها و برخی از کاربری‌ها نقش منفی داشته‌اند که اصطلاحاً به آن‌ها کاربری منفی زمین اطلاق می‌شود.

در گام چهارم به منظور بررسی رفتار مکانی و زمانی آلاینده‌ها در هر ایستگاه، حریمی به شعاع ۳۰۰۰ متری حول هر ایستگاه کنترل کیفیت هوا در نظر گرفته شد. به علت این که قدرت تفکیک مکانی سنجنده مادیس یک کیلومتر بوده و از سه پیکسل بایست استفاده می‌شد، تنها شعاع پوشش‌دهنده در این پژوهش ۳۰۰۰ متری محسوب می‌شود. مناطق حریم مشخص شده حول هر ایستگاه مطابق با شکل (۱۱) و نوع کاربری زمین در این محدوده‌ها محاسبه شد. بررسی مناطق حریم یک بخشی به این علت بوده که در شعاع ۳۰۰۰ متری، کاربری اراضی مورد تجزیه و تحلیل و ارزیابی قرار گرفته شود، بنابراین



شکل ۱۱: نقشه مناطق حریم ایجاد شده حول هر یک از ایستگاه‌های کنترل کیفیت هوا با شعاع ۳۰۰۰ متری



شکل ۱۲: نقشه شماتیک کاربری زمین حول هر ایستگاه

جدول ۶: تاثیر کاربری زمین در مناطق حریم ایجاد شده به شعاع ۳۰۰۰ متر برای هر ایستگاه

نام ایستگاه	طول معابر (متر)		کاربری زمین	
	اصلی	فرعی	مثبت	منفی
اقدسیه	۴۸۰	۳۵۲	پارک‌ها، بوستان‌های متعدد و جهت باد از جنوب غربی به شمال شرقی	
شادآباد	۴۵۰	۳۲۳		فرودگاه، مراکز تاسیساتی فرودگاه
شهرداری منطقه ۱۶	۴۴۵	۲۷۱		ترمینال اتوبوسرانی، پارک سوار جنوب، مراکز اداری
میدان فتح	۴۰۶	۲۷۱		فرودگاه، مراکز تاسیساتی فرودگاه

شهرداری منطقه ۲ به علت وجود چندین باغ و پارک‌ها و بوستان‌های متعدد و همچنین ایستگاه ستاد بحران نیز به علت نزدیکی به پارک جنگلی و پارک‌ها و بوستان‌های متعدد و توزیع مناسب آن در محدوده ۳۰۰۰ متری، از شرایط خوبی برخوردار بودند که این موضوع منجر به ایجاد هوای پاک در این نواحی شده که از مناطق هوای پاک در این دوره‌ها بودند.

در شکل (۱۳)، نمودارهای غلظت آلاینده‌های گازی در ایستگاه‌های کنترل کیفیت هوا در تاریخ سوم مرداد سال‌های ۱۳۹۶، ۱۳۹۷، ۱۳۹۸ و ۱۳۹۹ نشان داده شده است. در این شکل، نمودار میله‌ای سبز نشان‌دهنده آلاینده  $NO_2$ ، نمودار میله‌ای قرمز مربوط به  $SO_2$  و نمودار میله‌ای آبی مربوط به آلاینده  $CO$  می‌باشد. با توجه به بررسی‌های انجام شده و مطابق شکل (۱۳)، در تاریخ ۱۳۹۶/۵/۳ غلظت آلاینده  $CO$  و  $SO_2$  در تمامی ایستگاه‌های کنترل کیفیت هوا در شرایط تقریباً یکسان در بازه بین ۰/۱۳ تا ۰/۱۸ ppm و آلاینده  $NO_2$  در بین ایستگاه‌ها در بازه ۰/۲۸ تا ۰/۳۲ ppm متغیر بود. همچنین در تاریخ ۱۳۹۷/۵/۳ غلظت آلاینده  $CO$  در تمامی ایستگاه‌های کنترل کیفیت هوا

با توجه به نتایج، ایستگاه اقدسیه از شرایط بهتری برخوردار بود. با بررسی کاربری‌های زمین در شعاع ۳۰۰۰ متری این ایستگاه مشخص شد که چندین باغ از جمله منطقه لویزان، پارک‌ها و بوستان‌های متعدد در این منطقه قرار دارد. همچنین جهت باد غالب در این منطقه از جنوب غربی به شمال شرقی است.

از طرف دیگر، ایستگاه‌های میدان فتح، شادآباد و شهرداری منطقه ۱۶ از ایستگاه‌های آلوده به شمار می‌آیند. ایستگاه شادآباد، به علت مجاور بودن این ایستگاه به فرودگاه مهرآباد و مجاورت با مراکز تاسیساتی فرودگاه شرایط نامطلوبی دارد. ایستگاه شهرداری منطقه ۱۶ به علت مجاور بودن به ترمینال اتوبوسرانی، پارک سوار جنوب و مراکز اداری بسیار، از ایستگاه‌های آلوده در تهران بوده است. ایستگاه میدان فتح به علت مجاور بودن با فرودگاه مهرآباد و توزیع فضای سبز نامناسب و مراکز خدماتی تاسیساتی فرودگاه در آن و نزدیکی به محل آهن‌فروشان و قرارگرفتن در محدوده پایانه مسافربری غرب تهران از مکان‌های آلوده در این دوره زمانی بود.

با توجه به بررسی‌های انجام شده، ایستگاه‌های پونک و





ایستگاه پیروزی به علت مجاورت با بزرگراه امام‌علی، بیمارستان‌های بعثت و فجر و همچنین مجاورت با پادگان و مراکز خرید و مراکز آموزشی و عدم دسترسی به فضای سبز مناسب، در معرض آلودگی قرار دارد. شکل (۱۴) نمودارهای غلظت آلاینده‌های گازی  $NO_2$  و  $SO_2$ ،  $CO$  در هر ایستگاه کنترل کیفیت هوا را در سال‌های ۱۳۹۳ تا ۱۳۹۹ نشان می‌دهد. با توجه به نتایج سال‌های ۱۳۹۳ تا ۱۳۹۹ برای روز سوم از ماه مرداد، ایستگاه‌های اقدسیه، ستاد بحران و پارک رز به علت توزیع مناسب فضای سبز و پارک جنگلی و وجود چندین باغ در محدوده خود از نقاط با کمترین آلودگی از آلاینده  $NO_2$  هستند. همچنین در روز ۱۳۹۴/۵/۳ آلودگی همه ایستگاه‌ها در شرایط نامطلوب قرار داشته است. با توجه به نمودارهای شکل (۱۴)، روزهای ۱۳۹۶/۵/۳ و ۱۳۹۷/۵/۳ و ۱۳۹۸/۵/۳ روند کاهش غلظت آلاینده‌ها را نشان می‌دهند. در تاریخ ۱۳۹۹/۵/۳ با توجه به شرایط کرونا و با اتخاذ تدابیر وزارت بهداشت، تردد در سطح شهر کاهش یافته که با توجه به نتایج، کیفیت هوا در شرایط مطلوبی قرار گرفته است.

در شرایط تقریباً یکسان در حدود  $0.13$  ppm قرار داشته و آلاینده  $SO_2$  بین بازه  $0.13$  تا  $0.18$  ppm متغیر بوده است. آلاینده  $NO_2$  نیز در بین ایستگاه‌ها در بازه  $0.28$  تا  $0.32$  ppm متغیر بود. در سری زمانی غلظت آلاینده  $CO$  در  $1398/5/3$  روند به این صورت بود که تمامی ایستگاه‌ها در شرایط یکسان بودند و غلظتی در حدود  $0.2$  ppm داشتند. غلظت آلاینده  $SO_2$  همه ایستگاه‌ها در شرایط یکسان و در بازه  $0.2$  تا  $0.23$  ppm متغیر بودند، بجز ایستگاه ستاد بحران که به خاطر وجود چندین باغ جنگلی در محدوده خود، کمترین غلظت در سطح  $SO_2$  را (حدود  $0.1$  ppm) داشت و بیشترین غلظت را اتوبان محلاتی در بین ایستگاه‌ها، به علت مجاور بودن به دو ترمینال اتوبوسرانی و نزدیکی به بازار تهران و قرارگیری مراکز اداری در این منطقه که در محدوده  $3000$  متری آن واقع هستند، دارا بود. ایستگاه میدان فتح و ایستگاه شهرداری منطقه ۱۱ به علت نامناسب بودن توزیع فضای سبز در این منطقه، وجود مراکز آموزشی، بهداشتی، درمانی و مراکز اداری زیاد دارای غلظت آلاینده گازی در حدود  $0.23$  ppm بودند.

با توجه به نمودارهای شکل (۱۳)، غلظت آلاینده  $NO_2$  در بین ایستگاه‌ها متفاوت بوده و در بازه  $0.27$  تا  $0.33$  ppm متغیر بود. در این میان ایستگاه ستاد بحران بیشترین و اقدسیه کمترین غلظت را داشته‌اند.

در بررسی سری زمانی غلظت آلاینده  $CO$  و  $SO_2$  در تاریخ ۱۳۹۹/۵/۳ تمامی ایستگاه‌ها در شرایط یکسان (بازه  $0.1$  تا  $0.17$  ppm) قرار داشتند. ایستگاه شهرداری منطقه ۱۶ کمترین و ایستگاه‌های اتوبان محلاتی، پیروزی، شادآباد و شهرری بیشترین غلظت آلاینده‌ها را نشان دادند.

غلظت آلاینده  $NO_2$  همه ایستگاه‌ها در شرایط تقریباً یکسان و در بازه  $0.27$  تا  $0.32$  ppm متغیر بودند که بیشترین غلظت (حدود  $0.32$  ppm) را ایستگاه پیروزی و شهرری در بین ایستگاه‌ها نشان می‌دهند.



■ CO(ppm) ■ SO2(ppm) ■ NO2(ppm)

شکل ۱۳: نمودارهای غلظت آلاینده‌های گازی در هر ایستگاه کنترل کیفیت هوا در تاریخ سوم مرداد سال‌های ۱۳۹۶، ۱۳۹۷، ۱۳۹۸ و ۱۳۹۹



شکل ۱۴: نمودارهای غلظت آلاینده‌های گازی NO<sub>2</sub> و SO<sub>2</sub> و CO در هر ایستگاه کنترل کیفیت هوا در سال‌های ۱۳۹۳ تا ۱۳۹۹

جنگلی و وجود چندین باغ در محدوده خود از نقاط با کمترین آلودگی برای این آلاینده بوده‌اند. طبق نمودارهای شکل (۱۳) در سال ۱۳۹۷ آلودگی همه ایستگاه‌ها در شرایط نامطلوب بوده ولی در سال ۱۳۹۸

در سری زمانی غلظت آلاینده SO<sub>2</sub> در سال‌های ۱۳۹۳ تا ۱۳۹۹ برای روز سوم از ماه مرداد، ایستگاه‌های پونک و شهرداری منطقه ۲ در سال ۱۳۹۷ و ستاد بحران در سال ۱۳۹۹ به علت توزیع مناسب فضای سبز و پارک

از طرف دیگر، برای بررسی تاثیر معابر بر روی غلظت آلاینده‌ها، با استفاده از ابزار مدل بیلدر در نرم‌افزار آرک جی آی اس، اندازه‌گیری طول راه‌های فرعی و اصلی در مناطق حریم هر یک از ایستگاه‌های کنترل کیفیت هوا (به شعاع ۳۰۰۰ متری) بر حسب متر محاسبه شد. طول راه‌های اصلی و فرعی کل ایستگاه‌ها (محدوده مناطق حریم به شعاع ۳۰۰۰ متری برای هر ایستگاه) در جدول (۷) نشان داده شده است.

این روند کاهش یافته است. در سری زمانی غلظت آلاینده CO در سال‌های ۱۳۹۳ تا ۱۳۹۹ برای روز سوم مرداد ماه تمامی ایستگاه‌ها در شرایط یکسان قرار داشتند. طبق نمودارهای شکل (۱۴) در سال ۱۳۹۹ باتوجه به همه‌گیری کرونا و کاهش تردد، روند کیفیت هوا رو به بهبود رفته و به شرایط مطلوبی رسیده است، در حالی که ایستگاه‌های گلبرگ، پیروزی و شهرداری در همان تاریخ در بالاترین سطح آلودگی خود قرار داشتند.

جدول ۷: طول کلیه راه‌های اندازه‌گیری شده از مدل بیلدر در مناطق حریم به شعاع ۳۰۰۰ متری هر ایستگاه

ایستگاه	راه‌ها (متر)		ایستگاه	راه‌ها (متر)	
	اصلی	فرعی		اصلی	فرعی
پیروزی	۴۸۱	۳۳۰	شهرداری منطقه ۱۰	۴۴۴	۳۲۷
اتوبان محلاتی	۳۶۵	۲۶۵	تربیت مدرس	۴۵۲	۳۲۸
گلبرگ	۴۵۵	۳۲۵	میدان فتح	۴۰۶	۲۷۱
شهرداری منطقه ۴	۴۸۱	۳۲۷	شهرداری منطقه ۱۱	۴۵۰	۳۲۲
اقدسیه	۴۸۰	۳۵۲	شادآباد	۴۵۰	۳۲۳
دروس	۳۷۳	۲۸۰	مسعودیه	۴۹۳	۳۸۷
شهرداری منطقه ۲	۳۸۷	۳۲۴	شهرداری منطقه ۱۹	۴۰۳	۲۹۶
پونک	۴۵۱	۳۲۹	پارک رز	۴۴۱	۳۲۴
شریف	۴۱۱	۳۲۷	شهرداری منطقه ۱۶	۴۴۵	۲۷۱
شهرداری منطقه ۲۲	۴۰۷	۳۲۳	ستاد بحران	۴۴۷	۳۳۰
شهر ری	۴۵۰	۳۲۹			

وجود اینکه طول کلیه راه‌های این منطقه تقریباً کمتر از سایر ایستگاه‌های دیگر است، ولی از ایستگاه‌های آلوده در این سری زمانی می‌باشد. طول کلیه راه‌های اصلی ایستگاه شریف ۴۱۱ متر و طول کلیه راه‌های فرعی آن ۳۲۷ متر است. با وجود اینکه طول کلیه راه‌های این منطقه تقریباً کمتر از سایر ایستگاه‌های دیگر است، ولی از ایستگاه‌های آلوده در این سری زمانی می‌باشد. طول کلیه راه‌های اصلی ایستگاه ستاد

با توجه به جدول (۷) مشاهده می‌شود که طول کلیه راه‌های اصلی اقدسیه ۴۸۱ متر و طول کلیه راه‌های فرعی آن ۳۲۷ متر است. این ایستگاه به علت اینکه طول راه‌های اصلی و فرعی آن در شرایط متوسطی به سر می‌برد و همچنین باتوجه به کاربری زمین‌های آن منطقه، از ایستگاه‌هایی با آلودگی کمتر محسوب می‌شود. طول کلیه راه‌های اصلی ایستگاه شادآباد ۴۵۰ متر و طول کلیه راه‌های فرعی آن ۳۲۳ متر است که با

بهینه انتخاب می‌شود که مدلی برای اندازه‌گیری بهنگام از غلظت آلاینده‌ها با دقت بالا ارایه می‌کند. به منظور ارزیابی مقایسه‌ای، نتایج شبکه عصبی پرسپترون پیشنهادی با خروجی‌های حاصل از روش رگرسیون جنگل تصادفی مورد مقایسه قرار گرفت. نتایج حاکی از آن بود که خروجی‌های شبکه عصبی پرسپترون چند لایه نسبت به خروجی‌های حاصل از روش رگرسیون جنگل تصادفی عملکرد بهتری را نشان داده است که برای آلاینده  $SO_2$  به دقت ۹۲ درصدی و برای آلاینده‌های  $CO$  و  $NO_2$  به دقت ۸۶ درصدی رسیده است. در نهایت به وسیله نقشه‌های غلظت آلاینده‌ها در شهر تهران، به تجزیه و تحلیل اثر کاربری زمین و جریان‌های اصلی و فرعی راه‌ها بر غلظت آلاینده‌ها پرداخته شد. در تحلیل مکانی میزان غلظت آلاینده در ایستگاه‌ها، مشخص شد نوع کاربری اراضی تاثیر به-سزایی بر تغییرات غلظت آلاینده‌ها داشته است. ایستگاه‌های میدان فتح و دانشگاه شریف و شهرداری منطقه ۱۰ به علت وجود کارگاه‌های تاسیساتی فرودگاه و نزدیکی به فرودگاه مهرآباد، از ایستگاه‌های آلوده در سطح شهر تهران بودند، در حالی که ایستگاه‌های ستاد بحران و شهرداری منطقه ۲ به علت وجود پارک‌های جنگلی و بوستان‌های متعدد، از هوای سالم‌تری برخوردار بودند. به علت عدم دسترسی به داده‌های ترافیکی و صرفاً با استناد به طول راه‌های اصلی و فرعی، نمی‌توان طول راه‌ها را به خودی خود به صورت پارامتری تاثیرگذار در افزایش و یا کاهش غلظت آلاینده‌ها دانست. همچنین نتایج نشان دادند که کاربری زمین رابطه معناداری در میزان غلظت آلاینده‌ها داشته است. فاصله از راه‌ها در کاهش و افزایش غلظت آلاینده‌ها چندان تاثیرگذار نبوده و رابطه معناداری با میزان غلظت آلاینده‌ها نداشته است.

[1] N. Sajadian, "Prediction of air pollution caused by urban transportation in Tehran metropolis using LUR integration with GIS model and artificial network", *Geographic*

بحران ۴۴۷ متر و طول کلیه راه‌های فرعی آن ۳۳۰ متر است که طول راه‌های اصلی و فرعی این ایستگاه متوسط محسوب می‌شود. با بررسی دیگر ایستگاه‌ها، می‌توان گفت که هر چند طول راه‌ها می‌تواند عامل تاثیرگذاری در افزایش غلظت آلاینده‌ها محسوب شود؛ اما کاربری زمین پارامتر موثرتری محسوب می‌شود. قابل ذکر است که در این تحقیق، از داده‌های ترافیکی استفاده نشده است؛ ولی چنانچه داده‌های ترافیکی موجود بوده و از آنها در تحقیق استفاده شود، می‌توان تحلیل کامل‌تری از عامل طول راه ارائه داد.

#### ۶- نتیجه‌گیری

در این تحقیق به محاسبه غلظت آلاینده‌های گازی شهر تهران با استفاده از داده‌های سنجش از دوری سنجنده مادیس در کنار داده‌های ایستگاه‌های زمینی پایش کیفیت هوا به صورت داده‌های سری زمانی بین سال ۱۳۹۳ الی ۱۳۹۹ و با استفاده از شبکه عصبی پرسپترون چند لایه پرداخته شده است. سپس به منظور بررسی عوامل تاثیرگذار بر روی غلظت آلاینده‌ها، داده‌های کاربری زمینی و داده‌های مربوط به طول راه‌های اصلی و فرعی، در شعاع مشخصی حول هر ایستگاه زمینی در کنار خروجی‌های شبکه پرسپترون چند لایه مورد تحلیل قرار گرفت.

شبکه عصبی پرسپترون چند لایه استفاده شده در این تحقیق، شبکه‌ای با ۸ نورون، شامل ۴ نورون در لایه ورودی (داده‌های سنجش از دوری شامل  $AOD$ ،  $NDVI$ ،  $Day LST$  و  $Night LST$ )، ۳ نورون در لایه پنهان و یک نورون در لایه خروجی (داده‌های ایستگاه‌های پایش کنترل و کیفیت هوا شامل آلاینده‌های گازی  $CO$ ،  $NO_2$  و  $SO_2$ ) می‌باشد. شبکه عصبی پیشنهادی به ازای پارامترهای تعداد دوره و نرخ یادگیری، تحلیل حساسیت شده و شبکه‌ای با حالت

#### مراجع

*Information Scientific-Research Quarterly*, Vol. 24 (95), pp.107-120, 1394.

[2] M. Mirzaie, "Modeling the concentration of

- air pollutants in Tehran using neural network and LUR", Sharif University, 2019.
- [3] M. "Abbod, et al. Application of artificial intelligence to the management of urological cancer", *The Journal of urology*, vol. 4 (178), pp. 1150-1156, 2007. DOI: <https://doi.org/10.1016/j.juro>.
- [4] B. Ainslie, et al. "A source area model incorporating simplified atmospheric dispersion and advection at fine scale for population air pollutant exposure assessment", *Atmospheric Environment*, vol. 42 (10), pp. 2394-2404, 2008 DOI: <https://doi.org/10.1016/j.atmosenv>.
- [5] S. Al-Alola, I. Alkadi, H. Alogayellail, S. Mohamed, and I. Ismail, "Air quality estimation using remote sensing and GIS-spatial technologies along Al-Shamal train pathway, Al-Qurayyat City in Saudi Arabia, Environmental and Sustainability Indicators", *Springer*, 100184, 2022. <https://doi.org/10.1016/j.indic.2022.100184>.
- [6] H. Amini, S. Taghavi Shahri, k. Naddafi, R. Nabizadeh, and m. Yunesian, "Correlation of air pollutants with land use and traffic measures in Tehran, Iran: A preliminary statistical analysis for land use regression modeling", *Journal of Advances in Environmental Health Research*, 1, 1, pp. 1-8, 2013.
- [7] L. Bai, J. Wang, X. Ma, and H. Lu, "Air Pollution Forecasts: An Overview", *International Journal of Environmental Research and Public Health*, 15, 4, pp. 1-44, 2018.
- [8] H. Bagheri, "Using deep ensemble forest for high-resolution mapping of PM2.5 from MODIS MAIAC AOD in Tehran, Iran", *National Library of Medicine*, DOI: 10.1007/s10661-023-10951-1, 2023.
- [9] A. Bekkar, B. Hssina, and S. D. Douzi, "Air pollution prediction in smart city", *deep learning approach. Journal of big Data*, 8, 161, pp. 1-21, 2021.
- [10] P. Bromandi, F. Karaca, A. Nikfal, A. Jahanbakhshi, M. Tamjidi, , & J. Kim, "Impact of COVID-19 event on the air quality in Iran", *Aerosol and Air Quality Research*, 20, pp. 1793-1804, 2020.
- [11] D. Ciresan, et al. "Flexible, high performance convolutional neural networks for image classification", in *Twenty-Second International Joint Conference on Artificial Intelligence*, 2011.
- [12] M. Delavar, A. Gholami, G. shiran, Y. Rashidi, G. Nakhaeizadeh, F. Kurt, and S. Hatefi Afshar, "A Novel Method for Improving Air Pollution Prediction Based on Mashine Learning Approaches: A Case Study Applied to the Capital City of Tehran", *International Journal of Geo-Information*, 8, 2, pp. 1-20, 2019.
- [13] R. Espinosa, J. Palma, F. Jiménez, J. Kamińska, G. Sciavicco, and E. Lucena-Sánchez, "A time series forecasting based multi-criteria methodology for air quality prediction", *Applied Soft Computing*, 113, 107850, 2021. <https://doi.org/10.1016/j.asoc>.
- [14] T. Filippini, K. Rothman, A. Goffi, F. Ferarri, G. Maffei, N. Orsini, and M. Vinceti, "Satellite-detected tropospheric nitrogen dioxide and spread of SARS-CoV-2 infection in Northern Italy", *Science of the Total Environment*, 739, 140278, 2020.
- [15] M. Gardner, and S. Dorling, "Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences", *Atmospheric environment*, vol. 32(14-15), pp. 2627-2636, 1998. DOI: <https://doi.org/10.1016/S>
- [16] I. Y. B. Goodfellow, and A. Courville. "Deep learning", *springer MIT press*, 2016.
- [17] K. S. Harishkumar, and Y. K. Ibrahim Gad, "Using Machine Learning Regression Models", *Procedia Computer Science*, 171, pp. 2057-2066, 2020.
- [18] Ian. Heaton, y. Goodfellow, and Courville. aaron. "Deep learning", *Springer*, 2018.

DOI: <https://doi.org/10.1007/s>

- [19] P. Hedelt, D. Efremenko, D. Loyola, R. Spurr, and L. Clarisse, "Sulfur dioxide layer height retrieval from Sentinel-5 Precursor/TROPOMI using FP\_ILM", *Atmospheric Measurement Techniques*, Vol. 12(10), pp. 5503-5517, 2019.
- [20] G. Hoek, et al. "Estimation of long-term average exposure to outdoor air pollution for a cohort study on mortality", *Journal of Exposure Science and Environmental Epidemiology*, vol. 11(6), pp. 459-469, 2001. DOI: <https://doi.org/10.1038/sj.jea.7500189>.
- [21] X. Huang, Chunjiang, S. Tianyu, Y. Shiji, L. Le, Y. Baoxian, and Wu. C. Wenjun, "Large scale air pollution prediction with deep convolutional networks", *Science China Information Sciences*, 64, 192107, 2021. <https://doi.org/10.1007/s11432-020-2951-1>.
- [22] I. Ialongo, H. Virta, H. Eskes, J. Hovila, and J. Douros, "Comparison of TROPOMI/Sentinel-5 Precursor NO2 product with ground-based observations in Helsinki and first societal applications", In *EGU General Assembly Conference Abstracts*, 4-8 May, pp.9963, 2020.
- [23] T. Iqbal, "An investigation of Spatial Patterns of Urban Air Pollution and Source Recognition through GIS and Remote Sensing in Lahore", 2011.
- [24] Iran Road Management Center [IRMC], 2022, Online; accessed 25, Nov, 2022. Available from: <https://141.ir>.
- [25] G. James, et al. "An introduction to statistical learning", Springer, Vol. 112, 2013.
- [26] A. Just, et al. "Using high-resolution satellite aerosol optical depth to estimate daily PM2.5 geographical distribution in Mexico City", *Environmental science & technology*, vol. 49(14), pp. 8576-8584, 2015. DOI: <https://doi.org/10.1021/acs.est.5b00859>.
- [27] B. Karlik, and A.V. Olgac, "Performance analysis of various activation functions in generalized MLP architectures of neural networks", *International Journal of Artificial Intelligence and Expert Systems*, vol. 1(4), pp. 111-122, 2011.
- [28] A. Kizrak, "Towards data science, Comparison of Activation Functions for Deep Neural Networks", Online accessed 9 jun, 2020.
- [29] M. E. Koukouli, I. Skoulidou, A. Karavias, I. Parcharidis, D. Balis, A. Manders, and J. Van Geffen, "Sudden changes in nitrogen dioxide emissions over Greece due to lockdown after the outbreak of COVID-19", *Atmospheric Chemistry and Physics*, 21, pp. 1759-1774, 2021.
- [30] R. Laumbach, and H. Kipen, "Respiratory health effects of air pollution: update on biomass smoke and traffic pollution", *Journal of allergy and clinical immunology*, vol. 129(1), pp. 3-11, 2012. DOI: <https://doi.org/10.1016/j.jaci.2011.11.021>.
- [31] Li. W. Thomas, R. El-Askary, H. Piechota, T. Struppa, D. and K. Ghaffar, "Investigating the significance of aerosols in determining the coronavirus fatality rate among three European Countries", *Earth Systems and Environment*, 4, pp. 513-522, 2020.
- [32] A. Lorente, K. Boersma, H. Eskes, J. Veeffkind, J. Van Geffen, M. De Zeeuw, M. Krol, "Quantification of nitrogen oxides emissions from build-up of pollution over Paris with TROPOMI", *Scientific reports*, vol. 9(1), pp.1-10, 2019.
- [33] A. L. A. Maas, and A. Y. Ng "Rectifier nonlinearities improve neural network acoustic models. in Proc", *Icml*, 2013.
- [34] M. A. R. Mohri & A. Talwalkar, "Foundations of machine learning", MIT press, 2018.
- [35] P. Muthukumar, E. Cocom, K. Nagrecha, D. Comer, I. Burga, J. Taub, M. Pourhomayoun, "Predicting PM2.5 atmospheric air pollution using deep

- learning with meteorological data and ground-based observations and remote-sensing satellite big data", *Air Quality, Atmosphere and Health*, 15, 7, pp. 1221-1234, 2022.
- [36] V. Nair, and G.E. Hinton, "Rectified linear units improve restricted boltzmann machines", in *Proceedings of the 27th international conference on machine learning (ICML-10)*, 2010.
- [37] M. Nielsen, "Neural networks and deep learning", Vol. 2018. 2015: Determination press San Francisco, CA, USA, 2015.
- [38] s. Oji, and H. Adamu, "Air Pollution Exposure Mapping by GIS in Kano Metropolitan Area", *Research Paper*, 7, 1, pp. 101-112, 2021.
- [39] H. Omrani, B. Omrani, B. Parmentier, and Helbich, "Spatio-temporal data on the air pollutant nitrogen dioxide derived from Sentinel satellite for France", *Data in brief*, 28, 105089, 2020.
- [40] S. Quesada-Ruiz, J. Attié, W. Lahoz, R. Abida, P. Ricaud, L. Amraoui, A. Segers, "Benefit of ozone observations from Sentinel-5P and future Sentinel-4 missions on tropospheric composition", *Atmospheric Measurement Techniques*, vol. 13(1), pp. 131-152, 2020.
- [41] A. Rahimi, "Short-term prediction of NO2 and NOX concentrations using multilayer perceptron, neural network a case study of Tabriz, Iran", *Ecological Processes*, 6, 4, pp. 1-9, 2017.
- [42] D. Ren Liu, Y.-K. Hsu, and H. J. Yu Chen, "Air pollution prediction based on factory-aware attentional LSTM neural network", *Computing*, 103, 1, pp.75-98, 2021.
- [43] B. Ripley, "Pattern recognition and neural networks", *Cambridge university press*, 2007.
- [44] D. Rumelhart, G.E. Hinton, and R.J. Williams, "Learning internal representations by error propagation", *California Univ San Diego La Jolla Inst for Cognitive Science*, 1985.
- [45] S. Russell, and P. Norvig, "Artificial intelligence: a modern approach (global 3rd edition)", *Essex: Pearson*, 2016.
- [46] O. Schneising, M. Buchwitz, M. Reuter, H. Bovensmann, J. Burrows, T. Borsdorff, F. Hase, "A scientific algorithm to simultaneously retrieve carbon monoxide and methane from TROPOMI onboard Sentinel-5 precursor", *Atmospheric Measurement Techniques*, 12, pp. 6771-6802, 2019.
- [47] J. Seinfeld, and S. Pandis, "Atmospheric Chemistry and Physics: From Air Pollution to Climate Change; JohnWiley & Sons", *New York, NY, USA*, 2012.
- [48] L. Shikwambana, P. Mhangara, and N. Mbatha, "Trend analysis and first time observations of sulphur dioxide and nitrogen dioxide in South Africa using TROPOMI/Sentinel-5 P data", *International Journal of Applied Earth Observation and Geoinformation*, 91, 102130, 2020.
- [49] A. Soleimany, and R. S. Grubliauskas, "Application of satellite data and GIS services for studying air pollutants in Lithuania (case study: Kaunas city)", *Air Quality, Atmosphere & Health*, 14, 3, pp. 411-429, 2020.
- [50] W. Sun, L. Zhu, I. De Smedt, B. Bai, D. Pu, Y. Chen, X. Wang, "Global significant changes in formaldehyde (HCHO) columns observed from space at the early stage of the COVID - 19 pandemic", *Geophysical Research Letters*, 48, 20GL091265, 2021.
- [51] A. Tella, and I. Balogun, Faye, "Spatiotemporal modelling of the influence of climatic variables and seasonal variation on PM10 in Malaysia using multivariate regression (MVR) and GIS, *Geomatics*", *Natural Hazards and Risk*, 12, 1, pp. 443-468, 2021.
- [52] N. Theys, P. Hedelt, I. De Smedt, C. Lerot, H. Yu, J. Vlietinck, C. Carlito, "Global monitoring of volcanic SO2 degassing with unprecedented resolution from TROPOMI

- onboard Sentinel-5 Precursor”, *Scientific reports*, vol. 9(1), pp. 1-10, 2019.
- [53] D. Thi Kim Phuong, M. Cong Nhut, and N. Duc Tri, “Air Pollution Assessment using RS and GIS in HO Chi Minh city, Vietnam: A case study of period 2015-2019 for SO<sub>2</sub> and NO<sub>2</sub>”, *IOP Conference Series: Earth and Environmental Science*, 652, 2020.
- [54] S. Tiwari, A. Srivastava, A. Singh, and S. Singh, “Identification of aerosol types over Indo-Gangetic Basin: implications to optical properties and associated radiative forcing”, *Environmental Science and Pollution Research*, vol. 22(16), pp. 12246-12260, 2015.
- [55] C. Vigouroux, B. Langerock, C. Bauer Aquino, Z. Cheng, M. DeMaziere, I. De Smedt, R. Kivi, “TROPOMI–Sentinel-5 Precursor formaldehyde validation using an extensive network of ground-based Fourier-transform infrared stations”, *Atmospheric Measurement Techniques*, vol. 13(7), pp. 3751-3767, 2020.
- [56] M. Virghileanu, I. Săvulescu, B. Mihai, C. Nistor, and R. Dobre, “Nitrogen Dioxide (NO<sub>2</sub>) Pollution Monitoring with Sentinel-5P Satellite Imagery over Europe during the Coronavirus Pandemic Outbreak”, *Remote Sensing*, vol. 12(21), 3575, 2020.
- [57] L. Wang, M. Li, S. Yu, X. Chen, Z. Li, Y. Zhang, W. Liu, “Unexpected rise of ozone in urban and rural areas, and sulfur dioxide in rural areas during the coronavirus city lockdown in Hangzhou, China: implications for air quality”, *Environmental Chemistry Letters*, 18, pp. 1713-1723, 2020.
- [58] K. Wark, and C. Warner, “Air Pollution: Its Origin and Control; Harper and Row. New York, NY, USA”, 1981.
- [59] C.F. Wark, and K. Warner, “Air Pollution: Its Origin and Control: Harper and Row: New York, USA”, 1981.
- [60] F. Zhao, C. Lic, Z. Cai, X. Liu, J. Bak, and Y. Kim, “Ozone profile retrievals from TROPOMI: Implication for the variation of tropospheric ozone during the outbreak of COVID-19 in China”, *Science of The Total Environment*, 764, 142886, 2021. <https://doi.org/10.1016/j.scitotenv.2020.142886>.



## ***A Neural Network-Based Approach for Real-Time Measurement of the Concentration of Gaseous Pollutants in Tehran Using MODIS***

*Mina Saleh<sup>1</sup>, Reza Shah-Hosseini<sup>2\*</sup>, Zahra Bahramian<sup>2</sup>, Sara Khanbani<sup>3</sup>*

*1- MSc Student, Geographic Information System (GIS), Non-Governmental Non-Profit Institute of Pouyandengan Danesh, Chalus*

*2- Assistant Professor, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.*

*3- PhD Student, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.*

### **Abstract**

Nowadays, gas pollutants are considered as an important challenge in big cities. Due to the fact that gaseous pollutants have negative effects on human health and destroy the environment, there are several methods for predicting the concentration of gaseous pollutants such as carbon monoxide (CO), nitrogen dioxide (NO<sub>2</sub>) and sulfur dioxide (SO<sub>2</sub>). The aim of the present research is to calculate the concentration of gaseous pollutants in real time using MODIS sensor data, including night and day surface temperature, aerosol light depth, vegetation index and the data from the ground stations monitoring the concentration of the pollutants using multi-layer perceptron neural network. The perceptron neural network had the best performance with 8 neurons, 4 of which in the input layer, 3 in the middle layer, and one in the output layer. 80% of the data were considered as the training data and 20% as the test data; and 15% of the training data were considered for Validation of the network. Using the aforementioned training and experimental data, the parameters of the number of periods and the learning rate were subjected to sensitivity analysis and the most suitable parameters were selected. In the next step, the random forest regression method was used to compare the results. The results showed that the multilayer perceptron neural network performed better than the random forest regression. In this research, the qualitative analysis of the pollutant concentration map and the pollutants' relationship with the land use and the existing roads around each of the air quality control monitoring stations was done. The data of Tehran city were used as a 6-year time series from 1393 to 1399. The accuracy evaluation of the proposed method using the experimental data shows 86% accuracy for measuring carbon monoxide (CO) and nitrogen dioxide (NO<sub>2</sub>) pollutants and 92% accuracy for sulfur dioxide (SO<sub>2</sub>) one.

**Key words:** Air Pollution, Perceptron Neural Network, Gaseous Pollutants, Random forest regression, GIS, MODIS.

---

**Correspondence Address:** Photogrammetry & Remote Sensing Group, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

**Tel:** +98 21 61114527

**Email:** rshahosseini@ut.ac.ir