

پیش‌بینی شاخص کیفیت هوا بر مبنای متغیرهای هواشناسی و مولفه‌های خودهمبسته با استفاده از شبکه عصبی مصنوعی

زینب رستمی فصیح: دانشجوی کارشناسی ارشد مهندسی بهداشت محیط، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران. rostamifasihz@yahoo.com
 * علیرضا مصداقی‌نیا: استاد گروه مهندسی بهداشت محیط، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران (نویسنده مسئول). mesdaghinia@sina.tums.ac.ir
 کاظم ندافی: استاد گروه مهندسی بهداشت محیط، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران. knadafi@sina.tums.ac.ir
 رامین نبی‌زاده نودهی: استاد گروه مهندسی بهداشت محیط، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران. rnbizadeh@sina.tums.ac.ir
 امیرحسین محوی: استادیار گروه مهندسی بهداشت محیط، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران. ahmahvi@yahoo.com
 مهدی هادی: دانشجوی دکتری تخصصی پژوهشی بهداشت محیط، مرکز تحقیقات کیفیت آب، پژوهشکده محیط زیست، دانشگاه علوم پزشکی تهران، تهران، ایران. hadi_rfm@yahoo.com

تاریخ پذیرش: ۹۴/۶/۲۳

تاریخ دریافت: ۹۴/۳/۲۴

چکیده

زمینه و هدف: شاخص کیفیت هوا (Air Quality Index-AQI) ارتباط کیفیت هوا را با سطوح سلامتی به صورت کمی بیان می‌کند. با استفاده از مدل شبکه عصبی مقدار AQI برای یک روز بعد بر مبنای متغیرهای هواشناسی و خودهمبستگی شاخص، برای شهر کرمانشاه پیش‌بینی شد. **روش کار:** بعد از آماده‌سازی داده‌های آلاینده‌های معیار و متغیرهای هواشناسی سال‌های ۹۱-۱۳۸۹، تأخیرهای زمانی یک روز قبل و بعد متغیرها ایجاد شد. مقدار شاخص یک روز بعد به عنوان متغیر وابسته و سایر متغیرها به عنوان ورودی مدل استفاده گردید. عملکرد مدل با استفاده از ضریب همبستگی (R²)، ضریب تبیین (R²) و ریشه میانگین مربع خطا ارزیابی شد. تحلیل حساسیت مدل بررسی و مهم‌ترین متغیرهای مؤثر برای پیش‌بینی AQI شناسایی گردید. **یافته‌ها:** مقدار r مراحل آموزش، اعتبارسنجی و آزمون مدل بالاتر از ۰/۷۵ تعیین و R² مرحله آزمون برابر ۰/۶ تعیین شد. در بین متغیرهای هواشناسی، میزان دید افقی و میزان بارندگی تأثیر بیشتری بر مقدار شاخص داشتند به نحوی که بارندگی در یک روز قبل به طور معناداری باعث کاهش مقدار AQI روز بعد خواهد شد. همچنین بین میزان دید افقی و AQI ارتباط معکوس مشخص گردید. **نتیجه‌گیری:** مدل پیشنهادی می‌تواند برای پیش‌بینی مقدار شاخص AQI شهر کرمانشاه مورد استفاده قرار گیرد. با توجه به مسئله آلودگی هوا و خصوصاً مشکل ریزگردها، چنانچه چنین مدلی به صورت دینامیک استفاده شود نقش آن در اعلان وضعیت هوا ملموس‌تر خواهد شد. پیشنهاد می‌گردد پیش‌بینی شاخص AQI در قالب یک مدل با قابلیت به روز شدن برای این استان در مطالعات بعد انجام گردد.

کلیدواژه‌ها: پیش‌بینی، شبکه عصبی مصنوعی، متغیرهای هواشناسی، شاخص کیفیت هوا

مقدمه

مشکل آلودگی هوا مواجهه است شهر کرمانشاه به عنوان یکی از کلان‌شهرهای غربی ایران می‌باشد. در این کلان‌شهر به دلیل تعدد بالای خودروهای بنزینی و دیزلی و همچنین کارخانجات مختلف و پالایشگاه و مهم‌تر از آن‌ها آلودگی ناشی از گردوغبار بیابان‌های دو کشور عراق و عربستان که در همسایگی با این شهر قرار دارند، مسئله آلودگی هوا و کنترل آن از اهمیت ویژه‌ای برخوردار است. در این خصوص استفاده از برنامه‌های مدیریتی برای کنترل و کاهش آلودگی هوا از مهم‌ترین راهکارهای اجرایی محسوب می‌شوند. این امر جز از طریق در دست داشتن یک منبع اطلاعاتی

رشد سریع شهرنشینی، توسعه بی‌رویه شهرها و مصرف سوخت‌های فسیلی باعث شده تا آلودگی هوا به عنوان یک مشکل زیست‌محیطی مرتبط با مناطق شهری در سراسر جهان شناخته شده باشد (۱ و ۲)؛ بنابراین آلودگی هوا تهدیدی دائم و جدی برای شهرهای پرجمعیت و تأثیرات زیان‌بار بر سلامت و بهداشت جامعه دارد و خسارت‌های اقتصادی قابل توجهی به بار می‌آورد (۳-۵). علاوه بر عوامل ذکر شده خودروهای بنزینی، کارخانجات و صنایع در اطراف و داخل شهرها قرار دارند که بر مشکلات فوق افزوده است. یکی از شهرهایی که با

توسعه مدل شبکه عصبی مصنوعی برای پیش‌بینی شاخص آلودگی هوا توسط یانگ ژانگ و همکاران از داده‌های هواشناسی به‌عنوان ورودی اصلی به شبکه MLP استفاده شد. نتایج به دست آمده نشانگر این بود که این مدل بدون هیچ مداخله‌ای تحت هر شرایط آب و هوایی با ضریب همبستگی مناسب می‌تواند نتایج قابل‌قبولی را ارائه دهد (۱۷). جورج ریس و پاتریسیو برای پیش‌بینی میزان غلظت ذرات معلق تا اندازه ۱۰ میکرومتر (Particulate Matter up to 10-PM₁₀) از ANN بهره گرفتند و داده‌های هواشناسی و کنترل کیفیت را به‌عنوان ورودی به شبکه عصبی بکار بردند. آن‌ها چنین اظهار داشتند که شبکه عصبی نسبت به روش‌های خطی با متغیرهای ورودی مشابه نتایج دقیق‌تری را نشان می‌دهد (۱۸). باروتیان برای پیش‌بینی حداکثر PM₁₀ ۲۴ ساعته آینده در شهر تهران با استفاده از مدل شبکه عصبی مصنوعی با الگوریتم لونیبرگ مارکوارت نشان داد که PM₁₀ با درصد بالای ۸۳٪ آلاینده مسئول بوده و می‌توان در اولویت‌بندی عملکرد ایستگاه‌های پایش کیفیت هوا از ANN استفاده کرد (۱۹). هویبرگز و دیگران نیز طی مطالعاتی که انجام دادند عملکرد شبکه‌های عصبی را برای پیش‌بینی غلظت آلاینده‌ها مناسب دانستند (۲۰). از سال ۱۹۹۹ به بعد سازمان EPA به جای شاخص استاندارد آلاینده (Pollution Standard index-PSI) برای سنجش کیفیت هوا، معیار دیگری به نام شاخص کیفیت هوا (Air Quality Index-AQI) که حساس‌تر و دقیق‌تر است را پیشنهاد نمود. این شاخص یک ابزار کلیدی جهت آگاهی از کیفیت هوا، نحوه اثر آلودگی هوا بر سلامت و روش‌های محافظتی در برابر آلودگی هوا است (۲۱-۲۳). شاخص AQI ارتباط کیفیت هوا را با سطوح سلامتی به‌صورت کمی بیان می‌کند. در این مطالعه مقدار AQI شهر کرمانشاه بر مبنای روابط خودهمبسته شاخص و متغیرهای هواشناسی برای یک روز آینده با استفاده از شبکه عصبی پرسپترون چندلایه پیش‌بینی و نتایج عملکرد مدل بررسی خواهد شد. همچنین تأثیر هر یک از متغیرهای خودهمبسته و متغیرهای

صحيح و دقيق از وضعیت هوای محیط و تأثیر آن بر انسان‌ها امکان‌پذیر نخواهد بود. به همین خاطر مدل‌های متعددی از جمله چیمر (۶) مدل Polair 3D (۷) برای پیش‌بینی آلودگی هوا پیشنهاد شد. این مدل‌ها پایه و اساس دقیق فیزیکی در مورد منبع آلاینده‌ها و دیگر پارامترهای شناخته شده، ندارند (۸). همچنین مدل Polyphemus برای یافتن داده‌های مفقود شده نیاز به استفاده از مدل‌های دیگر دارد (۹) که به منظور غلبه بر این محدودیت‌ها مطالعات متعددی بر اساس مدل‌های آماری در مناطق مختلف برای شناسایی شرایط هواشناسی محلی مخصوصاً ارتباط آن با آلاینده‌های هوا و پیش‌بینی معیارهای مربوطه صورت گرفته است (۱۰ و ۱۱). در این میان شبکه‌های عصبی مصنوعی پیشرفت‌های چشمگیری را به خود اختصاص داده‌اند که به علت ویژگی‌های منحصر به فرد توانستند از سایر مدل‌ها پیشی بگیرند.

شبکه‌های عصبی مصنوعی (Artificial Neural Networks-ANN) از اواسط دهه ۱۹۹۰ به علت ویژگی‌های منحصر به فردی که دارند، استفاده از آن‌ها در اکثر زمینه‌های علمی و مدل‌سازی تجربی فرآیندهای غیرخطی به‌طور گسترده‌ای افزایش یافته است (۱۲ و ۱۳). مدل‌های متفاوتی از شبکه عصبی در دسترس است که هر کدام برای هدف خاصی به کار می‌روند (۱۴). یکی از مدل‌های شبکه عصبی که به راحتی می‌تواند ارتباط‌های غیرخطی بین متغیرهای شناسایی کند شبکه عصبی پرسپترون چندلایه (Multi Layer-MLP Perceptron) است (۱۵). شبکه‌های پرسپترون چندلایه (MLP) می‌توانند با هر تعداد لایه ساخته و به کار گرفته شوند.

در سال ۲۰۰۴ مطالعه‌ای با عنوان ارزیابی پتانسیل مدل شبکه عصبی پیش‌خور (Feed-Forward Neural Network-FFNN) برای پیش‌بینی روند آلاینده در هوای شهر هنگ‌کینگ توسط وی‌ژن لو و همکارانش انجام شد. نتایج نشان داد که این مدل نسبت به سایر مدل‌های مرسوم شبکه عصبی یک ابزار بالقوه برای پیش‌بینی پارامترهای کیفیت هوا می‌باشد (۱۶). در مطالعه‌ای در زمینه

سال‌های ۹۱-۱۳۸۹ از سازمان هواشناسی کشور اخذ و به‌عنوان داده‌های ورودی برای مدل‌سازی استفاده گردید. موقعیت و فاصله دو ایستگاه زیبا پارک و ایستگاه سینوپتیک از همدیگر ۴/۳ کیلومتر است که در شکل ۱ نشان داده شده است. پردازش اولیه داده‌های خام یکی از اقدامات اصلی و ضروری قبل از مدل‌سازی می‌باشد. آماده‌سازی و پردازش اولیه داده‌ها هرچند زمان‌بر می‌باشند ولی به دلیل اینکه پردازش اولیه داده‌ها باعث تسریع آموزش شبکه عصبی و افزایش عملکرد شبکه می‌شود باید به دقت انجام شود (۱۹ و ۲۵). شناسایی داده‌های پرت و داده‌های مفقوده از اقداماتی است که در این مرحله باید صورت پذیرد.


داده‌هایی که از توزیع منطقی داده‌ها فاصله داشته باشند به‌عنوان داده‌های پرت تقسیم‌بندی می‌شوند. طی مرحله آموزش شبکه عصبی میزان خطای میانگین در رکورد داده‌های آموزش کاهش می‌یابد از این‌رو وجود داده‌های پرت می‌تواند اثر قابل توجهی بر وزن‌های آموزش دیده داشته باشد. شناسایی و حذف برونهشته‌ها (Outliers) یا داده‌های پرت می‌تواند سرعت آموزش شبکه و رسیدن به وزن‌های دقیق را افزایش دهد (۲۶) و (۲۷). در این مطالعه با ترسیم باکس-ویسکر پلات و هیستوگرام داده‌ها وجود یا عدم وجود برونهشته در بین داده‌ها برای هر متغیر بررسی شد. از آنجا که برای هیچ‌یک از متغیرها مقادیر برونهشته‌ای که با قضاوت علمی و آماری محرز باشد مشاهده نگردید، از این‌رو تمامی رکوردهای مربوط به تمام متغیرها برای مرحله مدل‌سازی مورد استفاده قرار

هواشناسی بر مقدار شاخص AQI با استفاده از روش تحلیل حساسیت بررسی خواهد شد.

روش کار

شهر کرمانشاه با جمعیت بالغ بر ۸۸۵۰۰۰ و حدود ۶۵ کیلومتر مربع وسعت در میانه ضلع غربی کشور، بین ۳۳ درجه و ۳۶ دقیقه تا ۳۵ درجه و ۱۵ دقیقه عرض شمالی و ۴۵ درجه و ۲۴ دقیقه تا ۴۸ درجه و ۳۰ دقیقه طول شرقی از نصف‌النهار گرینویچ قرار گرفته است. شهر کرمانشاه دارای آب و هوای معتدل کوهستانی است. میانگین دمای سالانه شهر کرمانشاه در حدود ۱۴ سانتی‌گراد و میزان بارش سالانه این شهر ۴۵۶/۸ میلی‌متر است و در ارتفاع ۱۴۲۰ متر از سطح دریا می‌باشد. مقدار متوسط اینورژن این شهر در پاییز ۵۵ درصد و در زمستان ۷۰ درصد است و سرعت باد غالب به‌طور متوسط 4m/s است که ۱۸ درصد از غرب و ۱۶ درصد آن از جنوب شرقی می‌وزد (۲۴).

اطلاعات ساعتی غلظت آلاینده‌های معیار شامل: دی‌اکسید نیتروژن (NO_2)، ازن سطح زمین (O_3)، مونوکسید کربن (CO)، دی‌اکسید گوگرد (SO_2) و ذرات معلق (PM_{10}) در ایستگاه زیبا پارک (مدل Horriba) از شرکت کنترل کیفیت هوای کرمانشاه و اطلاعات هواشناسی شامل: رطوبت نسبی (Hum)، فشار ایستگاه (StaPres)، میزان بارندگی (Rain)، ساعات آفتابی (SunShin)، میدان دید (HorizView)، دمای خشک (DryTem)، دمای بیشینه (MaxT)، دمای کمینه (MinT)، سرعت باد (Wind)، شاخص جهت باد (WindS)، پوشش ابر (Cloud) و نقطه شبنم (DewP)، مربوط به



شکل ۱- نقشه منطقه مطالعاتی و موقعیت دو ایستگاه پایش آلاینده‌ها (زیبا پارک) و سینوپتیک (اصلی)

می‌رود. در این مطالعه از رابطه (۱) برای نرمال‌سازی متغیرهای مستقل و وابسته استفاده گردید.

(۱)

$$X_{\text{norm}} = \frac{(X - X_{\text{min}})}{(X_{\text{max}} - X_{\text{min}})}$$

که در آن X_{norm} مقدار نرمال شده ورودی X ، X_{min} و X_{max} به ترتیب حداکثر و حداقل داده‌ها می‌باشد (۳۳). برای هر یک از متغیرها، متغیرهای خودهمبسته مربوط به یک روز قبل و یک روز بعد نیز ایجاد شد. به‌عنوان مثال برای شاخص AQI سه متغیر تعریف شد: متغیر مربوط به مقدار فردای شاخص (AQIV_2)، متغیر مربوط به مقدار امروز شاخص (AQIV_1) و متغیر مربوط به مقدار شاخص برای دیروز (AQIV). در این مطالعه متغیر AQIV_2 به‌عنوان متغیر وابسته در مرحله مدل‌سازی وارد شد. در جدول شماره ۲ مشخصات آماری مربوط به ۱۰۴۳ رکورد داده روزانه مربوط به هر یک از متغیرهای مستقل و متغیر وابسته که در این مطالعه برای مدل‌سازی استفاده شده‌اند، آورده شده است.

در تقسیم‌بندی داده‌ها برای آموزش، تست و اعتبارسنجی قانون خاصی وجود ندارد (۳۴). در این مطالعه ۶۵ درصد داده‌ها جهت آموزش شبکه، ۱۵ درصد به منظور اعتبارسنجی و ۲۰ درصد باقیمانده به منظور تست شبکه مورد استفاده قرار گرفت (۳۵) و کلیه مراحل مدل‌سازی در نرم‌افزار R انجام شد.

در این مطالعه از ساختار شبکه‌ی عصبی چندلایه (MLP) استفاده شد. یادگیری این نوع شبکه از نوع یادگیری با ناظر است. در ساختار MLP مورد استفاده از یک لایه ورودی جهت اعمال متغیرهای ورودی، یک لایه پنهان و یک لایه خروجی که نهایتاً پاسخ‌های مسئله را ارائه می‌نمایند، استفاده می‌شود (۳۶). مدل خودهمبسته غیرخطی برای پیش‌بینی مقادیر یک روز بعد شاخص کیفیت هوا، یک مدل خود همبسته و هتروژن می‌باشد که مطابق رابطه (۲)

گرفت.

وجود داده‌های مفقوده می‌تواند به اشتباه اپراتور در ثبت داده‌ها، نقص در دستگاه‌های اندازه‌گیری و بعضاً برخورد با روزهای تعطیل (در سری‌های زمانی) مربوط باشد. یکی از روش‌هایی که برای برخورد با داده‌های مفقوده استفاده می‌شود روش درون‌یابی خطی می‌باشد (۲۸ و ۲۹). در این مطالعه از آنجا که سری زمانی داده‌ها حائز اهمیت نیست لذا در مواردی که داده مفقوده وجود داشت از رکورد مربوط به آن ساعت یا روز صرف‌نظر گردید.

شاخص کیفیت هوا (AQI) برای پنج آلاینده اصلی هوا یعنی NO_2 ، O_3 ، CO ، SO_2 و PM_{10} محاسبه می‌شود. مقدار این شاخص بین ۰ تا ۵۰۰ درجه‌بندی و در از نظر اهمیت بهداشتی برای تهدید سلامت انسان در شش سطح تقسیم می‌شود. این شش سطح در جدول شماره ۱ آورده شده است (۳۰ و ۳۱).

پس از پردازش اولیه داده‌ها از کلیه متغیرهای موجود که به‌صورت ساعتی موجود بودند مطابق توصیه روش محاسبه شاخص، بسته به نوع آلاینده میانگین ۸ ساعته و یا میانگین ۲۴ ساعته گرفته شد. سپس مقدار شاخص کیفیت هوا بر اساس روش ارائه شده توسط آژانس حفاظت محیط‌زیست (۳۰) محاسبه گردید.

مقادیر ورودی‌های شبکه عصبی به دلیل اینکه واحدهای متفاوتی دارند، از این‌رو دارای پراکندگی زیادی می‌باشند. این پراکندگی سرعت آموزش و دقت شبکه را کاهش داده و در نتیجه شبکه نمی‌تواند جواب مطلوبی را ارائه دهد (۳۲). با انجام نرمال‌سازی داده‌ها، مقدار تمامی متغیرها بین ۱- تا ۱ قرار گرفته و عملاً واحد متغیرها از بین

جدول ۱- ارتباط شاخص کیفیت هوا با سطح اهمیت بهداشتی

شاخص کیفیت هوا	سطح اهمیت بهداشتی
۰-۵۰	خوب
۵۱-۱۰۰	متوسط
۱۰۱-۱۰۵	ناسالم برای گروه‌های حساس
۱۵۱-۲۰۰	ناسالم
۳۰۰-۳۰۱	خیلی ناسالم
۳۰۰ >	خطرناک

جدول ۲- مشخصات آماری مربوط به ۱۰۴۳ رکورد داده روزانه متغیرهای مستقل و متغیر وابسته

نوع	نام متغیر	میانگین	انحراف معیار	خطای استاندارد	حداکثر	حداقل	حد بالا	حد پایین
وابسته	AQIv_2	۸۸/۲	۶۳/۶۷	۳/۸۶۹	۵۰۰	۱۷/۱	۹۲/۱۲	۸۴/۳۸۲
مستقل	AQIv	۸۸/۳	۶۳/۶۶	۳/۸۶	۵۰۰	۱۷/۱	۹۲/۱۸	۸۴/۴۴
	AQIv_1	۸۸/۲	۶۳/۶۵	۳/۸۶	۵۰۰	۱۷/۱	۹۲/۱۴	۸۴/۴۱
	HorizView	۹۵۶۱	۱۷۶۸/۵۱	۱۰۷/۴۵	۱۶۲۵۰	۴۵۰	۹۶۶۸/۵۴	۹۴۵۳/۶۴
	HorizView_1	۹۵۵۹/۴	۱۷۶۸/۱۶	۱۰۷/۴۳	۱۶۲۵۰	۴۵۰	۹۶۶۶/۸۴	۹۴۵۱/۹۸
	HorizView_2	۹۵۵۷	۱۷۶۳/۶۰	۱۰۷/۱۵	۱۶۲۵۰	۴۵۰	۹۶۶۴/۱۷	۹۴۴۹/۸۶
	Cloud	۲/۱	۲/۳۰	۰/۱۴	۸/۱۲	۰	۲/۳۲	۲/۰۴
	Cloud_1	۲/۱	۲/۳۱	۰/۱۴	۸/۱۲	۰	۲/۳۲۹	۲/۰۴
	Cloud_2	۲/۱	۲/۳۲	۰/۱۴	۸/۱۲	۰	۲/۳۳	۲/۰۵
	Wind	۱۴۹/۱	۶۰/۵۶	۰/۶۸	۳۰۵	۰	۱۵۳/۱۶	۱۴۵/۸۰
	Wind_1	۱۴۹/۴	۶۰/۴۳	۳/۶۷	۳۰۵	۰	۱۵۳/۱۰	۱۴۵/۷۶
	Wind_2	۱۴۹/۴	۶۰/۴۱	۳/۶۷	۳۰۵	۰	۱۵۳/۱۳	۱۴۵/۷۹
	WindS	۲/۶	۱/۳۰	۰/۰۷۹	۹/۵	۰	۲/۷۳	۲/۵۷
	WindS_1	۲/۶	۱/۳۰	۰/۰۷۹	۹/۵	۰	۲/۷۴	۲/۵۸
	WindS_2	۲/۶	۱/۳۰	۰/۰۷۹	۹/۵	۰	۲/۷۴	۲/۵۸
	DryTem	۱۶	۹/۷۳	۰/۵۹	۳۴/۳۲	-۵/۰۳	۱۶/۵۹	۱۵/۴۰
	DryTem_1	۱۶	۹/۷۲	۰/۵۹	۳۴/۳۲	-۵/۰۳	۱۶/۵۹	۱۵/۴۱
	DryTem_2	۱۶	۹/۷۱	۰/۵۹	۳۴/۳۲	-۵/۰۳	۱۶/۶	۱۵/۴۲
	DewP	-۰/۵	۴/۹۸	۰/۳۰	۱۲/۹۱	-۱۷	-۰/۲۷	-۰/۸۸
	DewP_1	-۰/۵	۴/۹۹	۰/۳۰	۱۲/۹۱	-۱۷	-۰/۲۸	-۰/۸۸
	DewP_2	-۰/۵	۵/۰۱	۰/۳۰	۱۲/۹۱	-۱۷	-۰/۲۷	-۰/۸۸
	StaPres	۸۶۸/۳	۴/۴۵	۰/۲۷	۸۷۸/۳۸	۸۰۲/۳۲	۸۶۸/۶۲	۸۶۸/۰۸
	StaPres_1	۸۶۸/۳	۴/۴۵۱	۰/۲۷	۸۷۸/۳۸	۸۰۲/۳	۸۶۸/۶۳	۸۶۸/۰۹
	StaPres_2	۸۶۸/۳	۴/۴۴۹	۰/۲۷	۸۷۸/۳۸	۸۰۲/۳	۸۶۸/۶۳	۸۶۸/۰۹
	MaxT	۲۴/۲	۱۰/۸۸۲	۰/۶۶	۴۳/۲	۰/۷	۲۴/۸۶	۲۳/۵۴
	MaxT_1	۲۴/۲	۱۰/۸۸۱	۰/۶۶	۴۳/۲	۰/۷	۲۴/۸۶	۲۳/۵۴
	MaxT_2	۲۴/۲	۱۰/۸۷	۰/۶۶	۴۳/۲	۰/۷	۲۴/۸۷	۲۳/۵۵
	MinT	۷/۵	۷/۹۸۱	۰/۴۸	۲۷/۸	-۱۱/۲	۸/۰۸	۷/۱۱
	MinT_1	۷/۶۰	۷/۹۷۴	۰/۴۸	۲۷/۸	-۱۱/۲	۸/۰۸	۷/۱۱
	MinT_2	۷/۶	۳/۹۶۶	۰/۴۸	۲۷/۸	-۱۱/۲	۸/۰۹	۷/۱۲
	SunShin	۷/۸	۳/۵۸۵	۰/۲۱	۱۴/۲	۰	۸/۰۴	۷/۶۰
	SunShin_1	۷/۸	۳/۵۹۶	۰/۲۱	۱۴/۲	۰	۸/۰۳	۷/۶۰
	SunShin_2	۷/۸	۳/۵۹۵	۰/۲۱	۱۴/۲	۰	۸/۰۳	۷/۵۹
	Hum	۴۲/۵۵۵	۲۲/۹۸۹	۱/۳۹	۹۹/۵	۱۰/۷۵	۴۳/۹۵	۴۱/۱۵
	Hum_1	۴۲/۵۸۳	۲۲/۹۹۵	۱/۳۹	۹۹/۵	۱۰/۷۵	۴۳/۹۸	۴۱/۱۸
	Hum_2	۴۲/۵۷۴	۲۲/۹۸	۱/۳۹	۹۹/۵	۱۰/۷۵	۴۳/۹۷	۴۱/۱۷
	Rain	۰/۹۸۶	۳/۹۷۶	۰/۲۴	۴۶/۸	۰	۱/۲۲	۰/۷۴
	Rain_1	۰/۹۹	۳/۹۷۷	۰/۲۴	۴۶/۸	۰	۱/۲۳	۰/۷۴
	Rain_2	۰/۹۹	۳/۹۷۷	۰/۲۴	۴۶/۸	۰	۱/۲۳	۰/۷۴

بیان می‌شود.

خودهمبسته شاخص و x_t بیانگر سایر متغیرهای مستقل هتروژن و y_{t+1} بیانگر مقدار شاخص AQI برای یک روز آینده می‌باشد. یکی از مسائل مهم در رابطه شبکه‌های MLP این است که شبکه باید به گونه‌ای آموزش ببیند که تابع عملکرد شبکه به

$$y_{t+1} = f(y_t, x_t) \quad (2)$$

در این رابطه y_t بیانگر مؤلفه یا مؤلفه‌های

میانگین مقادیر واقعی، y_{est} ، مقادیر برآورد شده، \bar{y}_{est} ، میانگین مقادیر برآورد شده و n تعداد داده‌ها می‌باشند. هر چقدر ضریب همبستگی به ۱، RMSE به صفر نزدیک‌تر و مقدار R^2 بیشتر (به یک نزدیک‌تر) باشد نشان‌دهنده نزدیکی بیشتر مقادیر پیش‌بینی شده به مقادیر واقعی است، در نتیجه بیانگر دقت قابل قبول مدل است.

یافته‌ها

برای مدل MLP در این مطالعه تعداد بهینه نرون در لایه مخفی برابر با ۲۷ نرون برآورد شده که در شکل ۲- (الف) نشان داده شده است. مطابق شکل مدل پیشنهادی شامل ۳۸ متغیر ورودی (متغیرهای موجود در جدول ۲) می‌باشد و متغیر خروجی مقدار شاخص AQI برای یک روز آینده است. بنابراین مطابق شکل ۲- (ب)، ۳۸ گره در لایه ورودی نماینده متغیرهای ورودی و ۲۷ نرون در یک لایه مخفی به منظور شناسایی روابط غیرخطی بین متغیرها در نظر گرفته شد.

به منظور نشان دادن میزان تطابق مقادیر پیش‌بینی شده توسط مدل شبکه عصبی بر مقادیر مشاهداتی، نمودار میزان تطبیق پاسخ مدل بر مقادیر شاخص کیفیت هوای یک روز بعد ترسیم گردید. در شکل ۳ پلات مدل MLP برای مراحل تست، ارزیابی و آموزش مدل نشان داده شده است. در جدول ۳ نیز مقدار آماره‌های مختلف محاسبه شده برای تبیین همبستگی بین مقادیر پیش‌بینی شده توسط مدل و مقادیر مشاهداتی آورده شده است. مقدار r برای تمامی مراحل بالاتر از ۱/۷۵ می‌باشد که از نظر آماری مقدار قابل قبولی است. مقدار R^2 برای مرحله آزمون مدل برابر ۰/۶ می‌باشد و به عبارتی مدل پیشنهادی قادر است ۶۰ درصد تغییرات شاخص کیفیت هوا را برای یک روز آینده با استفاده از ۳۸ متغیر ورودی پیش‌بینی کند. مقدار RMSE محاسبه شده برابر با ۴۴/۲ تعیین شد به عبارتی مدل پیشنهادی تنها ۴۴/۲ واحد می‌تواند بالاتر یا پایینتر از مقدار واقعی پیش‌بینی نماید. از آنجا که این عدد از مقدار فاصله طبقات (۵۰ واحد) در جدول شماره ۲ کمتر است لذا می‌توان مدل را مدل مطلوبی منظور کرد.

خطای کمینه رسیده باشد. آموزش این‌گونه شبکه‌ها معمولاً با روش پس‌انتشار خطا انجام می‌شود. در این مطالعه از الگوریتم (BFGS) Broydon-Fletcher-Goldfarb-Shanno- منظور کمینه کردن خطا در مرحله آموزش استفاده گردید (۳۷ و ۳۸). برای عناصر پردازشگر (نرون‌ها) در لایه مخفی، از تابع آستانه سیگموئیدی استفاده شد (۳۹). لایه مخفی اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهد. خروجی شبکه شاخص کیفیت هوا است که متناظر با آن یک نرون خروجی وجود دارد و تابع تبدیل آن در لایه خروجی یک تابع تبدیل خطی است. در این مطالعه تعداد نرون‌ها در لایه مخفی از طریق آموزش شبکه با تعداد متفاوت نرون‌ها و کمینه کردن مقدار آماره RMSE تخمین زده شد. به منظور ارزیابی کارایی شبکه و توانایی آن برای پیش‌بینی دقیق و همچنین کارایی روابط بررسی شده، معیارهای مختلفی می‌تواند مورد استفاده قرار گیرد. در این مطالعه از ۳ تابع شامل ضریب همبستگی (r)، ریشه میانگین مربعات خطا (RMSE) و ضریب تبیین (R^2) استفاده شد. معادلات شاخص‌های مذکور در زیر آورده شده است.

(۳)

$$r = \frac{\sum_{i=1}^n (y_{act} - \bar{y}_{act})(y_{est} - \bar{y}_{est})}{\sqrt{\sum_{i=1}^n (y_{act} - \bar{y}_{act})^2 \sum_{i=1}^n (y_{est} - \bar{y}_{est})^2}}$$


(۴)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{est} - y_{act})^2}{n}}$$


(۵)

$$R^2 = \frac{[\sum_{i=1}^n (y_{act} - \bar{y}_{act})(y_{est} - \bar{y}_{est})]^2}{\sum_{i=1}^n (y_{act} - \bar{y}_{act})^2 \sum_{i=1}^n (y_{est} - \bar{y}_{est})^2}$$


در روابط بالا y_{act} ، مقادیر واقعی، \bar{y}_{act}



شکل ۲- تعیین تعداد بهینه نرون ها در لایه مخفی مدل (الف) طرح شماتیک مدل (ب)



شکل ۳- مقایسه بین پراکنش مقادیر مشاهده شده و باقی‌مانده‌ها مرحله تست (الف) اعتبار سنجی (ب) و آموزش (پ)



شکل ۴- مقایسه بین پراکنش مقادیر مشاهده شده و باقی‌مانده‌ها مرحله تست (الف) اعتبار سنجی (ب) و آموزش (پ)


نتیجه گرفت که مدل پیشنهادی از اعتبار قابل‌قبولی در پیش‌بینی شاخص کیفیت هوا برخوردار می‌باشد. از طرفی تجمع داده‌ها در محدوده ۵۰-۱۰۰ حاکی از آن است که شاخص

جدول ۳- ارزیابی عملکرد مدل MLP

مقادیر برازش شده	مرحله آموزش	مرحله ارزیابی	مرحله تست
RMSE	۱۵/۴۱	۱۴/۶۸	۴۴/۲۰
r	۰/۹۷	۰/۹۷	۰/۷۸
R ²	۰/۹۴	۰/۹۴	۰/۶

چرا که مقدار AQI پیش‌بینی شده در بدترین حالت پیش‌بینی، ممکن است تنها فقط یک طبقه جابه‌جا شود.

در شکل ۴ نمودار پراکنش مدل برای مراحل مختلف نشان داده شده است. مقدار استاندارد شده باقیمانده‌های مدل شبکه عصبی از الگوی خاصی در اطراف خط معادل صفر محور Y پیروی نمی‌کنند در هر دو طرف این خط پراکنده‌اند و از طرفی بالاتر از ۹۵٪ باقیمانده‌ها بین محدوده قابل‌قبول ۲ تا ۲- مجتمع شده‌اند، لذا می‌توان




شکل ۵- تغییرات آماره دوربین- واتسون شاخص کیفیت هوا در مرحله تست (الف) اعتبار سنجی (ب) و آموزش (پ)

باقیمانده‌های مدل در تاخیرهای زمانی مختلف محاسبه گردید. در شکل ۵ این مقادیر برای تمامی مراحل تست، ارزیابی و آموزش مدل نشان داده شده است. همان طور که دیده می‌شود مقدار آماره عددی نزدیک به دو بوده و در هیچ مورد، بزرگ‌تر از ۳ و یا کوچک‌تر از ۱ نمی‌باشد. از این رو در مدل پیشنهادی همبستگی سریالی بین باقیمانده‌های مدل وجود ندارد.

نتایج آنالیز حساسیت مدل در شکل ۶ نشان داده شده است. همان طور که دیده می‌شود در بین تمامی متغیرهای مورد بررسی متغیرهای HorizView_2، (شاخص AQI امروز)، Rain_1 (میزان بارندگی امروز)، HorizView (میزان دید افقی دیروز)، Cloud_2 (میزان پوشش ابر فردا)، StatPres_2 (مقدار دمای کمینه فردا)، جزو مهم‌ترین متغیرهای اثرگذار بر مقدار شاخص AQI یک روز بعد خواهند بود. از متغیرهای فوق بین مقدار شاخص AQI فردا با متغیرهای دید افقی و پوشش ابر ارتباط منفی وجود دارد و برای سایر متغیرهای مذکور این ارتباط مثبت است. به عبارتی افزایش مقدار دید افقی و پوشش ابر می‌تواند با کاهش مقدار شاخص و بهتر شدن کیفیت هوا همراه باشد. بر اساس نتایج مدل، با افزایش مقدار دمای کمینه و همچنین افزایش فشار هوا در فردا، مقدار شاخص کیفیت هوا افزایش می‌یابد. این مسئله می‌تواند حاکی از بروز پدیده اینورژن و حاکم شدن توده هوای سرد و پرفشار در مجاور با سطح زمین باشد.

کیفیت هوا در محدوده متوسط قرار دارد. در میحث آمار، آماره دوربین-واتسون (Durbin-Watson statistic) (۴۰) برای بررسی وجود خودهمبستگی بین باقیمانده‌ها استفاده می‌گردد. مقدار این آماره همواره بین ۰ تا ۴ قرار می‌گیرد. مقدار آماره آزمون اگر کمتر از ۱ یا بیشتر از ۳ باشد زنگ هشدار برای وجود خود همبستگی مثبت یا منفی بین باقیمانده می‌باشد. در این مطالعه مقدار آماره دوربین-واتسون برای



شکل ۶- نمودار حساسیت متغیرهای مستقل در مدل

بحث و نتیجه‌گیری

در جدول ۴ نتایج این مطالعه با سایر مطالعاتی که در زمینه پیش‌بینی پارامترهای مختلف آلودگی هوا انجام شده، مقایسه شده است. بررسی مطالعات نشان می‌دهد از شبکه عصبی در اغلب مطالعات برای پیش‌بینی مقدار عوامل آلاینده استفاده شده است و در مطالعات اندکی از جمله مطالعه انجام شده توسط کومار و همکاران (۳۳) از پارامترهای هواشناسی و به منظور پیش‌بینی مقدار شاخص آلودگی هوا استفاده شده است. در مطالعه انجام شده توسط کومار و همکاران (۳۳) از مدل شبکه

عصبی و تحلیل مؤلفه‌های اصلی (Principal Component Analysis - PCA) به منظور پیش‌بینی مقدار شاخص AQI استفاده شده است. در آن مطالعه برای فصول مختلف مدل‌های متفاوتی ایجاد شده است و همان طور که در جدول ۴ دیده می‌شود مقدار ضریب همبستگی برای مدل‌های ارائه شده برای فصول گرم و بارانی در حدود ۰/۶ و برای فصل زمستان برابر ۰/۷ برآورد شده است. این مقادیر با مقدار ضریب برآورد شده در این مطالعه قابل مقایسه بوده و مقدار ضریب ۰/۷۸ برای مدل پیشنهادی در این

جدول ۴- بررسی سایر مطالعات انجام شده در زمینه پیش‌بینی مشخصات کیفیت هوا

منبع	مقدار پارامتر خوب بودن انطباق	مدل	متغیرهای مستقل	متغیر پاسخ
[۱۶]	مقدار RMSE برای RSP، NO ₂ و NO _x به ترتیب ۲۱،۴۲، ۴۹،۲۵ و ۱۶،۲۸	مدل شبکه عصبی پیشخور با روش RBF/PCA	تشنوع خورشید، ذرات معلق قابل تنفس، جهت باد، سرعت باد	پیش‌بینی غلظت ذرات قابل تنفس، NO _x و NO ₂ ساعتی
[۱۷]	مقدار I برای SO ₂ ، PM ₁₀ و NO ₂ به ترتیب ۰/۶۹، ۰/۶۰ و ۰/۶۳	شبکه عصبی چند لایه (MLP) پس انتشار خطا	دمای حداقل و حداکثر، فشار هوا، رطوبت، سرعت باد، پوشش ابر، بارندگی روزانه	پیش‌بینی عوامل آلودگی هوا
[۱۸]	مقدار مطلق درصد خطا (APE) برابر ۱/۶٪	شبکه عصبی	داده‌های سال‌های ۲۰۰۳-۲۰۰۱ ایستگاه هواشناسی و کنترل کیفیت	پیش‌بینی میزان غلظت PM ₁₀
[۴۱]	۸۰ ARMSE= ۶/۷۴ MAE= ۰/۲۸ R ² =	دو مدل شبکه عصبی و ARIMA	داده‌های هواشناسی و PM ₁₀	پیش‌بینی ذرات معلق
[۳۹]	۰/۲۸ R ² = ۰/۰۰۳ MSE=	شبکه عصبی پیشخور	دمای بیشینه، سرعت باد، جهت باد، پوشش ابر، حداکثر ارتفاع و رطوبت	پیش‌بینی حداکثر ازن روزانه
[۱۹]	برای تمامی ایستگاهها مقدار محدوده I بین ۰/۰۵ تا ۰/۷۳ متغیر است.	شبکه عصبی پیشخور	تشنوع خورشید، مقادیر حداکثر و متوسط دما، متوسط جهت و سرعت باد	پیش‌بینی PM ₁₀ ۲۴ ساعته آینده ایستگاه‌های کنترل کیفیت تهران
[۴۲]	۰/۸۲ R ² =	شبکه عصبی مصنوعی به همراه تجزیه و تحلیل عدم قطعیت توسط شبیه‌سازی مونت کارلو	سرعت باد، دمای هوا، رطوبت نسبی و جهت باد	پیش‌بینی میزان آلودگی هوا در ساعات روز و دستیابی به دقیق‌ترین پیش‌بینی ساعت به ساعت
[۴۳]	مقدار RMSE برای PM ₁₀ ، CO و NO ₂ به ترتیب 3.82 و 6.77، 3.99	شبکه عصبی مصنوعی پس انتشار خطا	دی‌اکسید گوگرد، ذرات معلق، مونوکسید کربن، دی اکسید نیتروژن، ازن، سرعت باد، میزان رطوبت و دما	پیش‌بینی آلاینده‌های هوا
[۴۴]	۰/۸۸ R ² =	مقایسه مدل شبکه عصبی مصنوعی پیشخور و مدل رگرسیون چندگانه	رطوبت، سرعت باد، دی‌اکسید نیتروژن، دما، مونوکسید کربن، دی‌اکسید گوگرد، ازن، PM ₁₀ یک روز قبل	پیش‌بینی PM ₁₀
[۳۳]	مقدار I برای مدل فصل تابستان، فصل بارندگی، فصل بعد از بارندگی و زمستان به ترتیب برابر ۰/۷۰، ۰/۶۰، ۰/۶۱ و ۰/۶۳	شبکه عصبی مصنوعی و PCA	داده‌های کیفیت هوا و داده‌های هواشناسی	شاخص کیفیت هوا
این مطالعه	۰/۷۸، I، ۰/۶۲ R ² = ۴۴/۲ RMSE=	شبکه عصبی سه لایه با الگوریتم آموزش BFGS	مقدار تاخیرهای زمانی یک و دو روزه شاخص، رطوبت نسبی، فشار هوا، میزان بارندگی، ساعات آفتابی، میدان دید، دمای خشک، دمای پیشینه، دمای کمینه، سرعت باد، شاخص جهت باد، پوشش ابر و نقطه شبنم	شاخص کیفیت هوا

مقدار شاخص AQI برای ۲۴ ساعت آینده مورد استفاده قرار گیرد. بر اساس نتایج مطالعه حاضر، مدل ارائه شده می‌تواند با استفاده از توانایی داده‌کاو خود به‌طور قابل‌قبولی از روابط خودهمبستگی بین تاخیرهای زمانی شاخص AQI و متغیرهای هواشناسی منطقه استفاده کرده و برای پیش‌بینی مقادیر آینده شاخص، الگوی یک روز آینده را شبیه‌سازی نمایند. در این مطالعه نقش متغیرهای هواشناسی و تأثیر آن‌ها بر مقدار شاخص کیفیت هوا از طریق تحلیل حساسیت مدل انجام شد که از نقاط قوت این مطالعه به منظور مشخص کردن متغیرهای مهم اثرگذار بر کیفیت هوا می‌باشد. در بین این متغیرها میزان بارندگی می‌تواند تأثیر قابل‌توجهی بر مقدار شاخص داشته باشد و بروز بارندگی در یک روز قبل به‌طور معناداری باعث کاهش مقدار شاخص کیفیت هوای روز بعد خواهد شد.

با توجه به اینکه مسئله آلودگی هوا در ایران و خصوصاً شهرهای غربی کشور به دلیل ورود ریزگردها از کشورهای همسایه از اهمیت ویژه‌ای برخوردار است چنانچه مدل ارائه شده در این مطالعه بتواند به‌صورت دینامیک و در قالب یک سامانه، مقدار شاخص روز یا روزهای آینده را در معرض دید عموم مردم قرار دهد استفاده و نقش عملی آن در پیش‌آگاهی از وضعیت هوا ملموس‌تر خواهد شد.

به هر حال یکی از محدودیت‌های که در حال حاضر وجود دارد فقدان بانک ثبت دقیق اطلاعات کیفیت هوا و متغیرهای هواشناسی می‌باشد. در واقع برای پیاده‌سازی یک سیستم دینامیک لازم است اطلاعات کیفیت هوا و همچنین متغیرهای هواشناسی بعد از اندازه‌گیری به‌صورت آنلاین در یک سامانه بارگزاری شده و سپس وارد مدل شوند. بدین ترتیب مدل می‌تواند با توجه به مقادیر جدید، خود را آموزش داده و به‌طور روزانه خود را به‌روز کرده و مقدار شاخص را برای یک روز آینده از طریق سیستم‌های مختلف اطلاع‌رسانی نماید. لذا پیشنهاد می‌گردد که پیش‌بینی شاخص AQI در قالب یک مدل با قابلیت به‌روز شدن برای این استان یا سایر استان‌ها انجام گردد. این مطلب از

مطالعه نشان می‌دهد که مدل پیشنهادی در مقایسه با مدل پیشنهاد شده توسط کومار توانایی بیشتری برای پیش‌بینی شاخص AQI دارد.

بر اساس شکل ۶ و با در نظر گرفتن اینکه مدل پیشنهادی توانسته است ۶۰٪ واریانس مقدار شاخص فردا را پیش‌بینی کند. مقدار شاخص AQI امروز می‌تواند بیشترین سهم را در این پیش‌بینی داشته باشد که این مقدار کمی بیشتر از ۱۱۵٪ کل واریانس پیش‌بینی شده یعنی در حدود ۱۰٪ می‌باشد. متغیرهای میزان دید افقی فردا و میزان بارندگی امروز نیز به ترتیب در حدود ۶٪ و ۳٪ در پیش‌بینی واریانس مشارکت داشته‌اند. میزان بارندگی امروز یکی از متغیرهای مهم اثرگذار بر کاهش مقدار شاخص AQI فردا محسوب می‌شود. این پیش‌بینی در عمل نیز کاملاً منطقی بوده چرا که معمولاً بعد از یک روز بارانی در اغلب مواقع کیفیت هوای فردا از نظر شاخص AQI مطلوب‌تر می‌باشد. در این مطالعه سعی شد تأثیر تمامی متغیرهای مستقل بر مقدار شاخص AQI بررسی شود. لذا از در نظر گرفتن وجود همبستگی بین متغیرهای مستقل که در اغلب موارد بدیهی می‌باشد، صرف نظر گردید. به‌عنوان مثال مقدار بارندگی در یک روز می‌تواند بر میزان دید افقی و افزایش آن اثرگذار باشد. همچنین سرعت باد می‌تواند بر وضعیت هوا از نظر پوشش ابر تأثیرگذار باشد. لذا در این مطالعه با صرف نظر کردن از ارتباط بین متغیرهای مستقل نقش ناخالص هر یک از آن‌ها در مدل بررسی گردید. در بین تمامی متغیرهای مستقل، جهت باد امروز کمترین تأثیر را بر مقدار شاخص کیفیت هوای فردا داشت

استفاده از مدل‌های پیش‌بینی کننده می‌تواند در کنترل تبعات بهداشتی آلودگی هوا موثر باشد. در این مطالعه نتایج حاصل از پیش‌بینی شاخص کیفیت هوا برای یک روز آینده با استفاده از اطلاعات کیفیت هوا و هواشناسی مربوط به شهر کرمانشاه ارائه شد. بر اساس نتایج مثبتی که در خصوص عملکرد مدل شبکه عصبی در این مطالعه حاصل شد می‌توان اظهار داشت که مدل پیشنهادی می‌تواند با دیدگاهی مثبت در پیش‌بینی

particulate matter pollution in 111 Chinese cities by using economic burden of disease analysis. *J. Environ. Manage.* 2008;88(4):947-54.

4. Yang CY, Chang CC, Chuang HY, Tsai SS, Wu TN, Ho CK. Relationship between air pollution and daily mortality in a subtropical city: Taipei, Taiwan. *Environ. Int.* 2004;30(4):519-23.

5. Afroz R, Hassan MN, Ibrahim NA. Review of air pollution and health impacts in Malaysia. *Environ. Res.* 2003;92(2):71-7.

6. Schmidt H, Derognat C, Vautard R, Beekmann M. A comparison of simulated and observed ozone mixing ratios for the summer of 1998 in Western Europe. *Atmos. Environ.* 2001; 35(36):6277-97.

7. Boutahar J, Lacour S, Mallet V, Quelo D, Roustan Y, Sportisse B. Development and validation of a fully modular platform for numerical modelling of air pollution: POLAIR. *Int. J. Environ. Pollut.* 2004;22(1):17-28.

8. Chang J, Hanna S. Air quality model performance evaluation. *Meteorol. Atmos. Phys.* 2004;87(1-3):167-96.

9. Ali A, Amin S, Ramadan H, Tolba M, editors. A Neural Network preprocessing model for OMI Aerosol Optical Depth data assimilation. *Computer Engineering & Systems (ICCES), 2012 Seventh International Conference on; 2012: IEEE.*

10. Katsoulis B. Some meteorological aspects of air pollution in Athens, Greece. *Meteorol. Atmos. Phys.* 1988;39(3-4):203-12.

11. Aron RH, Aron LM. Statistical forecasting models: I. Carbon monoxide concentrations in the Los Angeles basin. *J. Air Pollut. Control Assoc.* 1978;28(7):681-8.

12. Prachi KN, Matta G. Artificial neural network applications in air quality monitoring and management. *Int. J. Environ. Rehabil. Conserv.* 2011; 2(1):30-64.

13. Agyare W, Park S, Vlek P. Artificial neural network estimation of saturated hydraulic conductivity. *Vadose Zone J.* 2007;6(2):423-31.

14. Haykin S, Network Network: A comprehensive foundation. *Neural Networks* 2004;2(2004):45-50.

15. Dutot A-L, Rynkiewicz J, Steiner FE, Rude J. A 24-h forecast of ozone peaks and exceedance levels using neural classifiers and weather predictions. *Environ. Modell. Softw.* 2007; 22(9): 1261-9.

16. Lu WZ, Wang WJ, Wang XK, Yan SH, Lam JC. Potential assessment of a neural network model with PCA/RBF approach for forecasting pollutant trends in Mong Kok urban air, Hong Kong. *Environ. Res.* 2004;96(1):79-87.

17. Jiang D, Zhang Y, Hu X, Zeng Y, Tan J, Shao D. Progress in developing an ANN model for air pollution index forecast. *Atmos. Environ.* 2004;38(40):7055-64.

طریق تلفیق کردن سیستم های نرم‌افزاری شبکه عصبی با سیستم های سخت افزاری جهت استفاده آنلاین از مدل امکان پذیر خواهد بود. همچنین با توجه به اینکه انتخاب موثرترین روش به منظور پیش بینی، کار بسیار دشواری است و بسیاری از محققان از روش های خطی و غیرخطی به منظور پیش بینی استفاده می‌کنند و در طبیعت فرآیندها صرفاً خطی و یا صرفاً غیرخطی نمی‌باشند. بهتر است در مطالعات آینده از مدل‌های هیبریدی که تلفیقی از مدل‌های خطی و غیرخطی می‌باشند نیز استفاده شود.

با توجه به اینکه مسئله آلودگی هوا ایران و خصوصاً شهرهای غربی کشور به دلیل ورود ریزگردها از کشورهای همسایه، از اهمیت خاصی برخوردار است استفاده از مدل‌های پیش بینی کننده می‌تواند در کنترل تبعات بهداشتی این پدیده موثر باشد. در این مطالعه پیش بینی مقدار شاخص کیفیت هوا برای یک روز آینده می‌تواند در پیش آگاهی عمومی و برنامه‌ریزی شهری موثر باشد.

تقدیر و تشکر

نویسندگان لازم می‌دانند از دانشگاه علوم پزشکی تهران و پژوهشکده محیط‌زیست این دانشگاه به منظور فراهم نمودن تسهیلات لازم برای انجام این پژوهش تشکر نمایند. همچنین از شرکت کنترل کیفیت شهر کرمانشاه و سازمان هواشناسی کل کشور که در تهیه اطلاعات مربوطه همکاری نمودند، تشکر و قدردانی می‌گردد.

منابع

1. Bishoi B, Prakash A, Jain V. A comparative study of air quality index based on factor analysis and US-EPA methods for an Urban Environment. *Aerosol. Air Qual. Res.* 2009;9(1):1-17.
2. Najafi MS, Khoshakhllagh F, Zamanzadeh SM, Shirazi MH, Samadi M, Hajikhani S. Characteristics of TSP loads during the Middle East springtime dust storm (MESDS) in Western Iran. *Arab. J. Geosci.* 2013;1-15.
3. Zhang M, Song Y, Cai X, Zhou J. Economic assessment of the health effects related to

conc_aqi_calc.

32. MMB. Principles of Artificial Neural Network. (2005).

33. Kumar A, Goyal P. Forecasting of Air Quality Index in Delhi Using Neural Network Based on Principal Component Analysis. *Pure Appl. Geophys.* 2013;170(4):711-22.

34. Nagendra SS, Khare M. Modelling urban air quality using artificial neural network. *Clean Technol. Envir.* 2005;7(2):116-26.

35. Vlachogianni A, Kassomenos P, Karppinen A, Karakitsios S, Kukkonen J. Evaluation of a multiple regression model for the forecasting of the concentrations of NO_x and PM₁₀ in Athens and Helsinki. *Sci. Total Environ.* 2011; 409(8):1559-71.

36. S Lira T, AS Barrozo M, J Assis A. Air quality prediction in Uberlândia, Brazil, using linear models and neural networks. *Comput. Aided Chem. Eng.* 2007;24:51-6.

37. Müller J-F, Stavrou T. Inversion of CO and NO_x emissions using the adjoint of the IMAGES model. *Atmos. Chem. Phys.* 2005; 5(5):1157-86.

38. Goyal S. Advanced computing research on cascade single and double hidden layers for detecting shelf life of kalakand: An artificial neural network approach. *Int. J. Comput. Sci. Emerg. Technol.* 2011;2(5):292-295.

39. Yi J, Prybutok VR. A neural network model forecasting for prediction of daily maximum ozone concentration in an industrialized urban area. *Environ. Pollut.* 1996;92(3):349-57.

40. Young G, Jettmar R. Modeling monthly hydrologic persistence. *Water Resour. Res.* 1976; 12(5):829-35.

41. Diaz-Robles LA, Ortega JC, Fu JS, Reed GD, Chow JC, Watson JG, et al. A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: the case of Temuco, Chile. *Atmos. Environ.* 2008; 42(35):8331-40.

42. Arhami M, Kamali N, Rajabi MM. Predicting hourly air pollutant levels using artificial neural networks coupled with uncertainty analysis by Monte Carlo simulations. *Environ. Sci. Pollut. Res.* 2013;20(7):4777-89.

43. Abdel-Galil HKEH. Estimation of air pollutant concentrations from meteorological parameters using artificial neural network. *J. Electrical Eng.* 2006;57(2):105-10.

44. Ul-Saufie AZ, Yahya AS, Ramli NA, Hamid HA. Comparison between multiple linear regression and feed forward back propagation neural network models for predicting PM₁₀ concentration level based on gaseous and meteorological parameters. *Int. J. App. Sci. Technol.* 2011;1(4):42-49.

18. Perez P, Reyes J. An integrated neural network model for PM₁₀ forecasting. *Atmos. Environ.* 2006;40(16):2845-51.

19. Nejadkoorki F, Baroutian S. Forecasting extreme PM₁₀ concentrations using artificial neural networks. *Int. J. Environ. Res.* 2011; 6(1):277-84.

20. Hooyberghs J, Mensink C, Dumont G, Fierens F, Brasseur O. A neural network forecast for daily average PM₁₀ concentrations in Belgium. *Atmos. Environ.* 2005;39(18):3279-89.

21. Wen X-J, Balluz L, Mokdad A. Association between media alerts of air quality index and change of outdoor activity among adult asthma in six states, BRFSS, 2005. *J. Commun. Health* 2009;34(1):40-6.

22. Stieb DM, Doiron MS, Blagden P, Burnett RT. Estimating the public health burden attributable to air pollution: an illustration using the development of an alternative air quality index. *J. Toxicol. Environ. Health A* 2005;68(13-14):1275-88.

23. Nikravan M, Husseini E, Hashemi SH, editors. Pollutant Standard Index (PSI), Comparing the published and real values in Tehran. 5th National Congress on Civil Engineering; 2010.

24. Mansouri N, Rajabinezhad TH. carbon monoxide exposure in kermanshah citizens, Iran.

25. Juhos I, Makra L, Tóth B. Forecasting of traffic origin NO and NO₂ concentrations by Support Vector Machines and neural networks using Principal Component Analysis. *Simul. Model. Pract. Th.* 2008;16(9):1488-502.

26. Abdul-Wahab SA, Al-Alawi SM. Assessment and prediction of tropospheric ozone concentration levels using artificial neural networks. *Environ. Monit. Assess.* 2002; 17(3):219-28.

27. Amakali S. Development of models for short-term load forecasting using artificial neural networks 2008. Thesis for the degree Master of Technology; Discipline Electrical Engineering, Faculty of Engineering, Cape Peninsula University of Technology.

28. Kurt A, Gulbagci B, Karaca F, Alagha O. An online air pollution forecasting system using neural networks. *Environ. Int.* 2008;34(5):592-8.

29. Mohanty U, Dimri A. Location-specific prediction of the probability of occurrence and quantity of precipitation over the Western Himalayas. *Weather Forecast.* 2004;19(3):520-33.

30. Mintz D. Technical Assistance Document for the Reporting of Daily Air Quality-the Air Quality Index (AQI): US Environmental Protection Agency, Office of Air Quality Planning and Standards; 2012.

31. EPA AC, <http://airnow.gov/index.cfm?action=resources>.

Forecasting the air quality index based on meteorological variables and autocorrelation terms using artificial neural network

Zeinab Rostami Fasih, MSc student of Environmental Health Engineering, Faculty of Health, Tehran University of Medical Sciences, Tehran, Iran. rostamifasihz@yahoo.com

***Alireza Mesdaghinia**, PhD, Professor of Environmental Health Engineering, Department of Environmental Health Engineering, Faculty of Health, Tehran University of Medical Sciences, Tehran, Iran (*Corresponding author). mesdaghinia@sina.tums.ac.ir

Kazem Nadafi, PhD, Professor of Environmental Health Engineering, Department of Environmental Health Engineering, Faculty of Health, Tehran University of Medical Sciences, Tehran, Iran. knadafi@sina.tums.ac.ir

Ramin Nabizadeh Nodehi, PhD, Professor of Environmental Health Engineering, Department of Environmental Health Engineering, Faculty of Health, Tehran University of Medical Sciences, Tehran, Iran. rnabizadeh@sina.tums.ac.ir

Amir Hossain Mahvi, PhD, Assistant Professor of Environmental Health Engineering, Department of Environmental Health Engineering, Faculty of Health, Tehran University of Medical Sciences, Tehran, Iran. ahmahvi@yahoo.com

Mahdi Hadi, PhD student, Center for Water Quality Research (CWQR), Institute for Environmental Research (IER), Tehran University of Medical Sciences, Tehran, Iran. hadi_rfm@yahoo.com

Abstract

Background: Air Quality Index (AQI) quantifies the relationship between air quality and the level of health. The value of AQI may be predicted using neural network model for a day in advance, based on the meteorological variables and autocorrelation behavior of the index in Kermanshah, a city in western Iran.

Methods: Data for air pollution and meteorological variables, collected during three years, were lagged for two preceding days. The AQI for a next day was considered as dependent variable and other were used as predictors. The performance of model was assessed with correlation coefficient (r). The most important variables to predict the AQI were identified using sensitivity analysis.

Results: The r coefficient for the training, validation and testing the model was 0.75. Among the meteorological variables, the horizontal view and precipitation had a greater impact on the AQI. One day preceding precipitation can significantly reduce the amount of AQI for the next day. An inverse relationship was found between AQI and horizontal view.

Conclusion: The proposed model can be used to predict the Kermanshah's AQI index. Regarding to the issue of air pollution in this city, especially fine particulate pollutions; if such a model is used dynamically to predict the AQI, it can be useful tools for the declaration of an air pollution alert. The preparation of an online model-based system for the prediction of AQI index for Kermanshah city is suggested to be conducted in future studies.

Keywords: Forecasting, Artificial neural networks, Meteorological variables, Air quality index