

نشریه تحقیقات کاربردی علوم جغرافیایی سال هفدهم، شماره ۴۷، زمستان ۹۶

## پیش‌بینی آلودگی PM<sub>10</sub> هوای شهر مشهد با استفاده از شبکه های عصبی مصنوعی MLP و مدل زنجیره مارکف

دریافت مقاله: ۹۵/۶/۲۴ پذیرش نهایی: ۹۶/۸/۲۱

صفحات: ۳۹-۵۹

حسین زنگویی: باشگاه پژوهشگران جوان و نخبگان، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

hossein.zangooei@yahoo.com

غلامرضا اسداله‌فردی: استاد گروه عمران، دانشکده فنی‌ومهندسی، دانشگاه خوارزمی، تهران<sup>۱</sup>.

asadollahfardi@yahoo.com

### چکیده

مدیریت ذرات معلق یکی از موارد مهم در کنترل آلودگی شهرها محسوب می‌شود. این ذرات باعث ایجاد و توسعه بیماری‌های قلبی و تنفسی مختلف در افراد می‌گردد. شهر مشهد به عنوان یکی از شهرهای اصلی و پرجمعیت ایران با توجه به شرایط اقلیمی و همچنین توریستی بودن، بیش از هر چیزی در معرض خطر این نوع آلودگی قرار دارد. در این تحقیق سعی شده با استفاده از مدل‌های پرسپترون شبکه‌های عصبی مصنوعی و مدل زنجیره مارکوف غلظت PM<sub>10</sub> پیش‌بینی و تحلیل گردد. برای این منظور از داده‌های ساعتی CO، SO<sub>2</sub>، PM<sub>2.5</sub> و دما برای دو ماه فروردین و اردیبهشت در سال ۱۳۹۴ استفاده شد. از مجموع ۱۴۸۸ سری داده، ۱۳۰۰ داده برای آموزش شبکه و ۱۸۸ داده جهت صحت‌سنجی استفاده گردید. نتایج نشان‌دهنده عملکرد مطلوب این روش‌ها در پیش‌بینی میزان آلاینده و همچنین احتمال وقوع ساعات با کیفیت‌های مختلف آلودگی بود. بهترین مدل پرسپترون میزان آلاینده ذرات معلق را با ضریب همبستگی ۰/۸۸، شاخص تطابق ۰/۹۱، میانگین بایاس خطای ۰/۰۸۷۴ و جذر میانگین مربعات خطای ۲/۲۶ پیش‌بینی نمود، همچنین مدل مارکوف با خطای مطلق متوسط حدود ۰/۱ درصد احتمالات انتقال وضعیت و تداوم وضعیت‌های مختلف آلودگی هوای ناشی از ذرات معلق را پیش‌بینی نمود.

کلیدواژگان: شبکه‌های عصبی مصنوعی، آلودگی هوا، PM<sub>10</sub>، زنجیره مارکف.

۱. نویسنده مسئول: گروه عمران، دانشکده فنی‌ومهندسی، دانشگاه خوارزمی. ۰۹۱۲۱۱۹۲۴۲۴

## مقدمه

مسائل زیست‌محیطی یکی از اصلی‌ترین دغدغه‌های جهان امروز بوده و بی‌توجهی به آن مانع بزرگی برای توسعه پایدار ایجاد می‌نماید. گسترش شهرنشینی و روی آوردن افراد به استفاده از وسایل نقلیه شخصی در کنار گسترش کارخانجات مختلف و نابودی محیط زیست از جمله عوامل اصلی افزایش آلودگی هوا در کشورهای درحال توسعه محسوب می‌شوند. یکی از آلاینده‌های اصلی و حساس هوا ذرات معلق می‌باشند. براساس مطالعات اپیدمیولوژی، ذرات معلق در مقایسه با اکسیدهای گوگرد و اکسیدهای ازت برای سلامتی انسان مخاطره آمیزترند. ذرات معلق در تشدید بیماری‌های قلبی-ریوی، کاهش مقاومت سیستم ایمنی بدن در مقابل بیماری‌ها، از بین رفتن بافت ریه، آسم، مرگ و میر زودرس و سرطان نقش عمده‌ای دارند (Slaughter و همکاران، ۲۰۰۳؛ Goss و همکاران، ۲۰۰۴؛ US.EPA، ۲۰۰۹؛ Du و همکاران، ۲۰۱۰؛ Qio و همکاران، ۲۰۱۳؛ Deng و همکاران، ۲۰۱۳). ذرات معلق با قطر آیرودینامیکی کوچکتر از ۱۰ میکرومتر با علامت  $PM_{10}$  نشان داده می‌شود. این ذرات همچنین باعث کاهش دید در شهر و جاده‌ها می‌شوند. آژانس حفاظت محیط زیست آمریکا (USEPA) شش آلاینده اصلی را به عنوان شاخص انتخاب نموده و آنها را به دو دسته اولیه و ثانویه تقسیم کرده است. آلاینده‌های اولیه موادی هستند که مستقیماً از منابع به هوای محیط وارد شده و شامل مونوکسید کربن (CO)، دی‌اکسید نیتروژن ( $NO_2$ )، دی‌اکسید گوگرد ( $SO_2$ )، ذرات معلق ( $PM_{10}$ ) و سرب (Pb) می‌باشند. آلاینده‌های ثانویه به موادی اطلاق می‌شوند که بر اثر فعل و انفعالات موجود در اتمسفر زمین بوجود می‌آیند مانند اوزون ( $O_3$ ). جدول (۱) میزان استاندارد برخی از این آلاینده‌ها را نشان می‌دهد (US.EPA، ۲۰۰۹).

جدول ۱- میزان استاندارد (EPA) برخی از آلاینده‌های هوا

کیفیت هوا	مونوکسید کربن (ppm)	ذرات معلق ( $\mu g/m^3$ )		دی‌اکسید نیتروژن (ppb)	دی‌اکسید گوگرد (ppb)
		$PM_{10}$	$PM_{2.5}$		
خوب	۴/۴-۰	۵۴-۰	۱۲-۰	۵۳-۰	۳۵-۰
متوسط	۹/۴-۴/۵	۱۵۴-۵۵	۳۵/۴-۱۲/۱	۱۰۰-۵۴	۷۵-۳۶
ناسالم برای افراد حساس	۱۲/۴-۹/۵	۲۵۴-۱۵۵	۵۵/۴-۳۵/۵	۳۶۰-۱۰۱	۱۸۵-۷۶
ناسالم	۱۵/۴-۱۲/۵	۳۵۴-۲۵۵	۱۵۰/۴-۵۵/۵	۶۴۹-۳۶۱	۳۰۴-۱۸۶
خیلی ناسالم	۳۰/۴-۱۵/۵	۴۲۴-۳۵۵	۲۵۰/۴-۱۵۰/۵	۱۲۴۹-۶۵۰	۶۰۴-۳۰۵
خطرناک	۵۰/۴-۳۰/۵	۶۰۴-۴۲۵	۵۰۰/۴-۲۵۰/۵	۲۰۴۹-۱۲۵۰	۱۰۰۴-۶۰۵

استفاده از نرم‌افزارهای مدل‌سازی رفتار آلودگی هوا همواره با محدودیت‌ها زیادی روبروست. لحاظ نشدن بسیاری از عوامل باعث ایجاد خطای زیاد این‌گونه مدل‌ها و در نتیجه رسیدن به نتایج نادرست می‌گردد (Caputo و همکاران (۲۰۰۳)، Hanna و همکاران (۲۰۰۷)، Harsham و همکاران (۲۰۰۸) و Sunna و همکاران (۲۰۱۵)). بررسی تغییرات سری‌های زمانی پارامترهای مختلف و تجزیه تحلیل آنها با روش‌های ریاضی مانند

<sup>۲</sup> Particle Materials

مدل زنجیره مارکف<sup>۳</sup> و همچنین استفاده از روش‌های هوش مصنوعی با کمک سایر داده‌های موجود موازی با داده‌های اصلی، یکی از روش‌های مناسب و معتبر و معمولاً با خطای کمتر در فرآیند پیش‌بینی آلودگی هوا می‌باشد.

در مطالعات گذشته پارامترهای آلاینده مختلف از (Bordignon و همکاران، ۲۰۰۲؛ Barrero و همکاران، ۲۰۰۶؛ Sousa و همکاران، ۲۰۰۷؛ Karatzas و Kaltsatos، ۲۰۰۷؛ Chattopadhyay و Chattopadhyay، ۲۰۱۲) و دی‌اکسید نیتروژن (Kukkonen و همکاران، ۲۰۰۳؛ Kalapanidas و Avouris، ۲۰۰۱؛ Khare و Nagendra، ۲۰۰۶؛ Moustiris و همکاران، ۲۰۱۰) با استفاده از روش‌های هوش مصنوعی پیش‌بینی نمودند. همچنین Kurt و همکاران در سال ۲۰۰۸ مقادیر NO<sub>2</sub>، PM<sub>10</sub> و CO و Moustiris و همکاران در سال ۲۰۱۳ پارامترهای آلاینده NO<sub>2</sub>، O<sub>3</sub>، SO<sub>2</sub> و CO را با استفاده از شبکه‌های عصبی مصنوعی<sup>۴</sup> پیش‌بینی کردند. Zickus و همکاران در سال ۲۰۰۲ با استفاده از چهار روش ماشینی رگرسیون لجستیک، شبکه‌های عصبی مصنوعی، رگرسیون چند متغیره و درخت تصمیم‌گیری غلظت مواد معلق روزانه در کشور فنلاند را پیش‌بینی نمودند. نتایج آنها نشان‌دهنده عملکرد مطلوب سه روش اول در مقایسه با روش درخت تصمیم‌گیری در پیش‌بینی آلودگی هوا بود. Kukkonen و همکاران در سال ۲۰۰۳ با به‌کارگیری پنج مدل شبکه‌های عصبی مصنوعی، یک مدل خطی آماری و یک سیستم مدلسازی قطعی (DET<sup>۵</sup>) آلودگی NO<sub>2</sub> و PM<sub>10</sub> هوای کشور فنلاند را با استفاده از داده‌های جریان ترافیک و پارامترهای هواشناسی برای سال‌های ۱۹۹۶ تا ۱۹۹۹ پیش‌بینی نمودند. نتایج آنها نشان‌دهنده عملکرد مناسب تر شبکه‌های عصبی مصنوعی در مقایسه با سایر روش‌ها بود. Niska و همکاران در سال ۲۰۰۵ دو آلاینده NO<sub>2</sub> و PM<sub>2.5</sub> را با به‌کارگیری شبکه‌های عصبی مصنوعی چندلایه پرسپترون (MLP<sup>۶</sup>) پیش‌بینی نمودند که نتایج نشان‌دهنده موفقیت عملکرد این روش برای هر دو آلاینده بود. Owega و همکاران در سال ۲۰۰۶ اطلاعات آلودگی هوای فراهم‌شده توسط تجزیه و تحلیل خوشه‌ای برای شهر تورنتو کانادا را با نتایج شبکه عصبی مصنوعی (منطبق بر نظریه رزونانس - ART-2A) مقایسه نمودند. نتایج این دو روش در تعیین میزان آلودگی و منبع آلاینده ذرات معلق مشابه بود. Slini و همکاران در سال ۲۰۰۶ میزان ذرات معلق کوچکتر از ۱۰ میکرومتر را (PM<sub>10</sub>) با به‌کارگیری داده‌های سال‌های ۱۹۹۴ تا ۲۰۰۰ در شهر تسالونیک<sup>۷</sup> کشور یونان با استفاده از روش‌های شبکه‌های عصبی مصنوعی و رگرسیون خطی پیش‌بینی کردند. نتایج آنها نشان‌دهنده عملکرد بهتر شبکه‌های عصبی مصنوعی بود. Kurt و همکاران در سال ۲۰۰۸ میزان NO<sub>2</sub>، PM<sub>10</sub> و CO و Moustiris و همکاران در سال ۲۰۱۳ پارامترهای آلاینده NO<sub>2</sub>، O<sub>3</sub>، SO<sub>2</sub> و CO را با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی کردند. Voukantsis و همکاران در سال ۲۰۱۱ با استفاده از دو روش از شبکه‌های عصبی مصنوعی (MLP) غلظت دو آلاینده PM<sub>10</sub> و PM<sub>2.5</sub> را در دو شهر در کشورهای یونان و فنلاند پیش‌بینی کردند. آنها با مقایسه بین نتایج با داده‌های مشاهده شده ضریب

<sup>۳</sup> Markov Chain

<sup>۴</sup> Artificial Neural Networks

<sup>۵</sup> Deterministic Modelling System

<sup>۶</sup> Multilayer Perceptron

<sup>۷</sup> Thessaloniki

شاخص تطابق (IA) را بین ۰/۸ تا ۰/۸۵ و شاخص کاپا را ۰/۶۰ محاسبه نمودند. Feng و همکاران در سال ۲۰۱۵ میزان ذرات معلق را در شهری در کشور چین با استفاده از یک روش ترکیبی به کمک شبکه‌های MLP پیش‌بینی نمودند. برای این منظور آنها از داده‌های روزانه ذرات معلق برای یک سال را در اختیار داشتند. زنجیره مارکوف کاربرد گسترده‌ای در تحقیقات آماری دارا می‌باشد (Wang و Liu، ۲۰۱۲). همچنین مطالعات فراوانی در زمینه استفاده از این روش در پیش‌بینی آلودگی هوا در سراسر جهان صورت گرفته است. Nicas و Jones (۲۰۱۴)، Chen و همکاران (۲۰۱۴) و Chen و همکاران (۲۰۱۵) با بکارگیری زنجیره مارکف کیفیت هوا مناطق مختلف را ارزیابی کردند. Romanof در سال ۱۹۸۲ غلظت روزانه آلاینده SO<sub>2</sub> در یک منطقه صنعتی در کشور رومانی را با استفاده از زنجیره مارکوف بررسی کردند. آنها برای این منظور از استاندارد آلودگی هوای ۲۴ ساعته کشور رومانی استفاده نمودند. Nicas در سال ۲۰۰۰ با توجه به ماهیت احتمالاتی وجود آلاینده در یک اتاق و قطعی بودن سایر روش‌ها، از مدل زنجیره مارکوف جهت بررسی میزان آسیب‌پذیری افراد مبتلا به بیماری سل در برابر آلاینده‌های موجود در یک اتاق با شرایط مختلف را بررسی کرد. Shamshad و همکاران (۲۰۰۵) سرعت باد در کشور مالزی را با استفاده از ماتریس احتمال انتقال مارکوف بررسی نمودند. همچنین Sun و همکاران (۲۰۱۳) با استفاده از یک مدل مخفی مارکوف (HMM) با توزیع غیرگوسی، غلظت PM<sub>2.5</sub> روزانه را در منطقه‌ای در شمال کالیفرنیا پیش‌بینی نمودند. آنها نشان دادند که پیش‌بینی صورت‌گرفته به وسیله توزیع غیر گوسی خطای کمتری نسبت به مدل دارای توزیع گوسی داشته است. در این تحقیق با توجه به اهمیت پارامتر PM<sub>10</sub> در استانداردهای آلودگی هوا (Yao و Chan، ۲۰۰۸) و همچنین وضعیت حساس آلودگی این پارامتر نسبت به سایر آلودگی‌ها در منطقه مورد مطالعه مانند اکثر مناطق کشور (اکبری، ۱۳۹۲)، با بکارگیری شبکه‌های عصبی مصنوعی چند لایه پرسپترون (ANN-MLP) و همچنین روش زنجیره مارکف میزان و نحوه بروز آلودگی ناشی از این پارامتر در شهر مشهد بررسی گردید. برای این منظور از داده‌های ساعتی CO، SO<sub>2</sub>، PM<sub>2.5</sub> و دما برای دو ماه (فروردین و اردیبهشت) در سال ۱۳۹۳ استفاده شد. از مجموع ۱۴۸۸ سری داده، ۱۳۰۰ داده برای آموزش شبکه و ۱۸۸ داده جهت صحت-سنجی استفاده گردید.

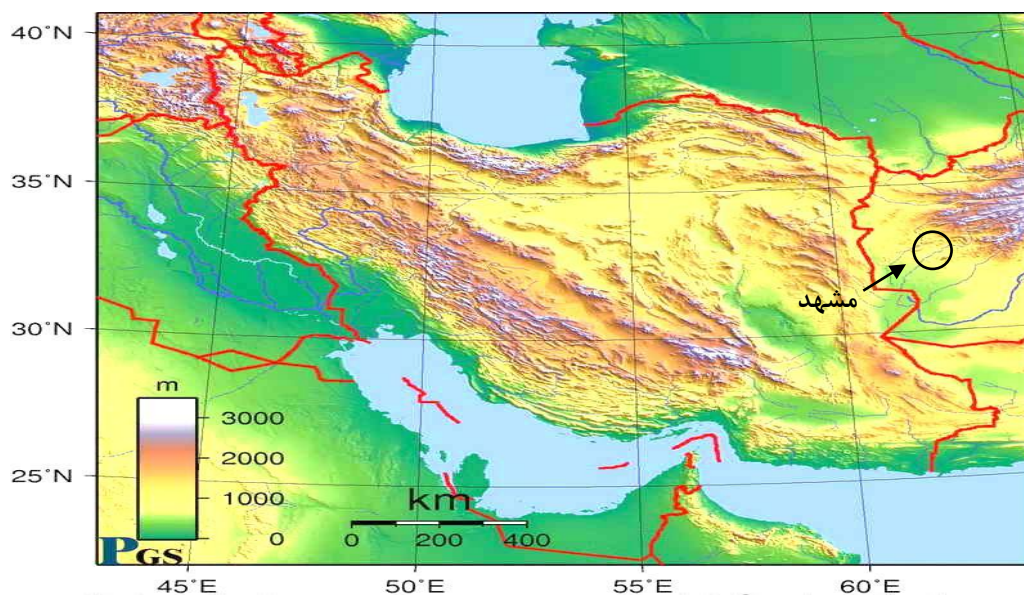
## روش تحقیق

### منطقه مورد مطالعه

شهر مشهد دومین شهر بزرگ کشور با جمعیتی برابر ۲,۷۶۶,۲۵۸ نفر می‌باشد. وسعت شهرستان مشهد ۱۷۳۵۸ کیلومتر مربع بوده و در حوضه آبریز کشف‌رود و در انتهای جنوبی دشت رسوبی توس واقع شده است. دو رشته کوه هزارمسجد در شمال و بینالود در جنوب این شهرستان قرار دارد. مشهد به دلیل موقعیت جغرافیایی خاص که در منطقه مرزی بین شمال و جنوب خراسان قرار دارد و همچنین تداخل جبهه‌های مختلف آب و هوایی، دارای آب و هوا و خصوصیات ویژه اقلیمی است. قسمت اعظم دشت مشهد-نیشابور، جزء اقلیم سرد و خشک و قسمتی از دشت مشهد - قوچان، نیم خشک و سرد و بخش کوچکی از بلندترین ارتفاعات رشته کوه‌های بینالود و هزار مسجد در محدوده اقلیم مرطوب سرد می‌باشد. در مجموع شهر مشهد دارای آب و هوای متغیر، اما معتدل و متمایل به سرد و خشک بوده و از تابستان‌های گرم و خشک و زمستان‌های سرد و مرطوب برخوردار است. بیشترین درجه حرارت در تابستان‌ها، ۴۳ درجه بالای صفر و کمترین آن در زمستان،

۲۳ درجه زیر صفر رخ داده، میزان بارندگی متغیر و دارای میانگین سالانه حدود ۲۵۳ میلی‌متر می‌باشد. شهر مشهد به دلیل ویژگی‌های فرهنگی- تفریحی در بخش‌هایی از سال با ورود جمعیت زیادی از گردشگران و در نتیجه حجم آلودگی بالایی مواجه می‌باشد.

ایستگاه مورد مطالعه در این تحقیق ایستگاه خیام واقع در طول جغرافیایی "۲۱' ۹۹" ۷۳° شرقی و عرض جغرافیایی "۹۷' ۲۱" ۴۰° شمالی می‌باشد. شکل (۱) موقعیت منطقه مورد مطالعه را نشان می‌دهد.



شکل (۱). منطقه مورد مطالعه

## انتخاب داده‌ها

یکی از مسائل مهم و موثر در عملکرد یک شبکه انتخاب پارامترهای ورودی جهت آموزش شبکه می‌باشد. برای این منظور در مطالعات گذشته الگوریتم‌های مختلفی استفاده شده است (John و Kohavi، ۱۹۹۷؛ Eleuteri و همکاران، ۲۰۰۵؛ Niska و همکاران، ۲۰۰۶). استفاده از این روش‌ها معمولاً با محدودیت‌ها و خطاهایی همراه است. لذا در این مطالعه با توجه به محدودیت‌های موجود در میزان دسترسی به اطلاعات جامع از تمامی آلاینده‌ها، داده‌های ساعتی  $SO_2$ ،  $PM_{10}$ ،  $PM_{2.5}$ ، CO و دما برای دو ماه فروردین و اردیبهشت مورد استفاده قرار گرفت. از مجموع ۱۴۸۸ داده ۱۳۰۰ داده برای انجام آموزش شبکه‌های عصبی مصنوعی و تعیین زنجیره مارکف و ۱۸۸ داده برای صحت‌سنجی انتخاب گردید. جدول (۲) مشخصات این داده‌ها که شامل اطلاعات هوای شهر مشهد در ماه‌های فروردین و اردیبهشت می‌باشد را نشان می‌دهد. علت انتخاب این دو ماه جهت بررسی، وقوع تغییر فصل و همچنین ورود جمعیت زیاد توریستی در این مدت به شهر مشهد بوده است.

جدول (۲). مشخصات داده‌های اندازه‌گیری شده

پارامتر	حداکثر	حداقل	میانگین	انحراف معیار
$PM_{10}$ ( $\mu g / m^3$ )	۷۲۴/۲۱۴	۱۰/۲۵۴	۷۲/۱۲۶	۳۴/۲۳
$PM_{2.5}$ ( $\mu g / m^3$ )	۵۶۳/۸۴	۲/۲۳	۲۷/۲	۲۳/۴۵
دما ( $^{\circ}C$ )	۲۳/۷	-۵/۳	۱۳/۲	۲/۱
مونوکسید کربن (ppm)	۵/۲۴۸	۱/۲۶۵	۲/۱۱۴	۰/۴۳
دی‌اکسید گوگرد (ppb)	۳۹/۲۸۴	۶/۳۵۴	۱۵/۶۱	۴/۵۸

جهت امکان‌سازی پیش‌بینی‌های بهتر خارج از مقادیر حدی داده‌های دوره آموزش داده‌های ورودی و خروجی به شبکه‌های عصبی مصنوعی در برخی تکرارها نرمال شدند. در این مطالعه برای نرمال کردن داده‌ها از رابطه (۱) استفاده گردید (Zurada, 1992). این تابع داده‌ها را در محدوده ۱ تا ۰ تنظیم می‌کند.

$$N_i = \left| \frac{X_i - X_{min}}{X_{max} - X_{min}} \right| \quad (1)$$

که در آن  $X_i$ ، مقادیر واقعی غیرنرمال،  $X_{min}$  و  $X_{max}$  مقادیر حداکثر و حداقل و  $N_i$  مقادیر نرمال شده متناظر  $X_i$  را نشان می‌دهند.

## شبکه‌های عصبی مصنوعی

یک شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده است و مانند مغز انسان به پردازش اطلاعات می‌پردازد. شبکه‌های عصبی مصنوعی همانند سیستم عصبی مغز انسان با کمک مثال‌ها آموزش می‌بینند و با پردازش روی داده‌های تجربی دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به همین دلیل به این سیستم‌ها هوشمند گفته می‌شود. روند کلی کارکرد شبکه‌های عصبی مصنوعی در قالب روابط (۲ و ۳) قابل مشاهده است (Haykin، ۱۹۹۹؛ Hambli، ۲۰۱۱).

$$y_i^m = f(v_i^m) \quad (2)$$

$$v_i^m = \sum_{j=1}^L w_{ji}^{m-1} y_j^{m-1} + b_i^m \quad \text{رابطه (۳)}$$

که در آن  $y_i^m$  ورودی‌های مدل،  $v_i^m$  خروجی لایه  $m$  ام،  $f$  معرف تابع انتقال،  $L$  تعداد رابطها با لایه‌های قبلی،  $w_{ji}^{m-1}$  معادل وزن هر رابط،  $b_i^m$  معرف بایاس یعنی جز ثابت تابع انتقال می‌باشد.

شبکه‌های عصبی مصنوعی انواع مختلفی دارند. در این تحقیق مدل‌های چندلایه پرسپترون مورد استفاده قرار گرفتند. شبکه‌های چندلایه پرسپترون قابلیت تعیین تعداد لایه مخفی، تعداد نرون‌های هر لایه و توابع انتقال مورد استفاده در این لایه‌ها را دارند. این توابع می‌توانند از نوع توابع سیگموئید طبق رابطه (۴)، خطی، شعاعی و .. باشند. شکل (۲) ساختار شبکه عصبی چندلایه پرسپترون مورد استفاده در این تحقیق را نشان می‌دهد.

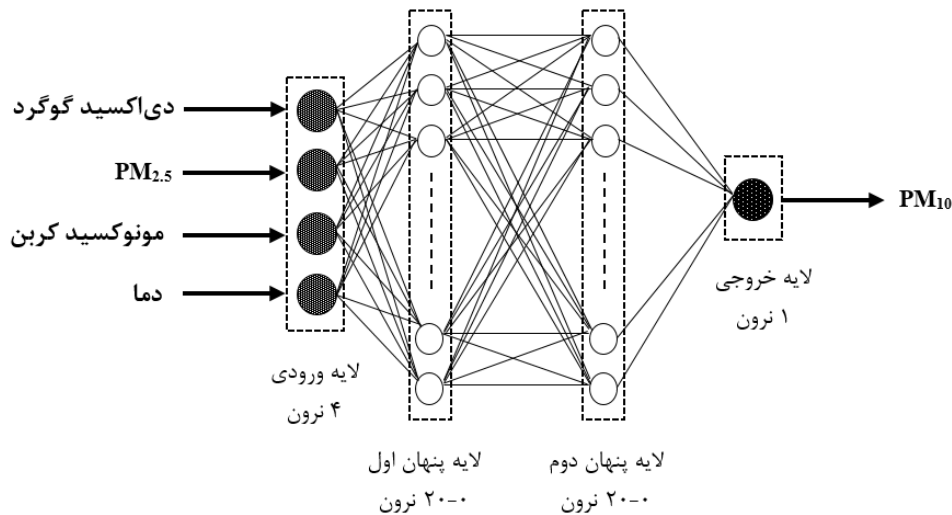
$$f(v_i^m) = \frac{1}{1 + \exp(-\theta v_i^m)} \quad \text{رابطه (۴)}$$

که در آن  $\theta$  پارامتر شیب تابع انتقال تعریف می‌شود ( $\theta = 0.9$ ).

الگوریتم‌های مختلفی برای آموزش شبکه‌های چندلایه پرسپترون وجود دارد. در ساده‌ترین پیاده‌سازی این شبکه‌ها، وزن‌ها و بایاس‌ها در جهتی که تابع کارایی کاهش می‌یابد (یعنی خلاف جهت شیب آن)، به‌روز می‌شود. رابطه (۵) یک تکرار از این الگوریتم را نشان می‌دهد (McClelland و Rumelhart، ۱۹۸۶).

$$x_{k+1} = x_k - \alpha_k g_k \quad \text{رابطه (۵)}$$

رابطه (۵) بردار فعلی وزن‌ها و بایاس‌ها،  $g_k$  شیب فعلی تابع کارایی و  $\alpha_k$  سرعت یادگیری ( $lr^A$ ) می‌باشند.



شکل (۲). شبکه MLP مورد استفاده

A. Learning rate

## انتخاب ساختار شبکه MLP

جدول (۳) مشخصات پارمترهای طراحی شبکه MLP را نشان می‌دهد. که در آن پارامتر show، نشان‌دهنده تعداد دفعات تکراری که پس از آن وضعیت آموزش نمایش داده می‌شود،  $\alpha$ ، مقدار سرعت یادگیری، goal، میزان خطای هدف،  $\beta$  ضریب مومنتوم و epochs تعداد دفعات تکرار آموزش می‌باشد. توقف آموزش زمانی اتفاق می‌افتد که آموزش به تعداد تکرار تعیین‌شده در epochs رسیده باشد و یا مقدار تابع کارایی از پارامتر goal کمتر شود. سرعت یادگیری در مقدار شیب ضرب شده و برای به روز رسانی وزن‌ها و بایاس‌ها استفاده می‌شود. اگر مقدار این پارامتر خیلی بزرگ انتخاب شود، فرآیند آموزش ثبات کافی نداشته و در صورتی که خیلی کوچک باشد، الگوریتم به زمان زیادی برای همگرا شدن نیاز دارد. پارامتر نرخ مومنتوم<sup>۹</sup> ( $\beta$ ) مقداری بین ۰ و ۱ را دریافت می‌کند. زمانی که نرخ مومنتوم صفر باشد، تغییرات وزن تنها از روی شیب تابع کارایی بوده و هنگامی که یک باشد، تغییرات وزن بر اساس آخرین تغییرات وزن قبلی می‌باشد و شیب نادیده گرفته خواهد شد.

نحوه عملکرد شبکه‌های MLP به این صورت است که در ابتدا وزن‌ها به صورت تصادفی انتخاب شده و پس از اعمال در مقادیر ورودی و اضافه شدن بایاس‌های تصادفی، با مقادیر خروجی مقایسه شده و میانگین مربعات خطا برای آنها محاسبه می‌گردد. در صورتیکه مقدار خطا از خطای دلخواه تعیین‌شده برای شبکه (goal) کمتر باشد آموزش متوقف و در غیر این صورت وزن‌ها و بایاس‌ها در جهت کاهش خطا اصلاح می‌گردند (Zangoeei و همکاران، ۲۰۱۶).

جدول (۳) - پارامترهای طراحی شبکه MLP

پارامتر	مقدار
show	۱۰۰۰
$\alpha$	۰/۴
goal	۰/۰۰۰۰۱
$\beta$	۰/۹
epochs	۱۰۰۰
تابع	newff

جهت محاسبه خطا در پیش‌بینی مقادیر آلاینده  $PM_{10}$  از ضرایب جذر میانگین مربعات خطا ( $RMSE^{10}$ ) و میانگین بایاس خطا ( $MBE^{11}$ ) و جهت مشخص کردن میزان همبستگی داده‌های اندازه‌گیری شده با مقادیر پیش‌بینی شده توسط مدل از ضریب همبستگی<sup>۱۲</sup> ( $R^2$ ) و شاخص تطابق ( $IA^{13}$ ) استفاده گردید (روابط ۶ تا ۹)

<sup>۹</sup> momentum ratio

<sup>۱۰</sup> Root Mean Square Error

<sup>۱۱</sup> Mean Bias Error

<sup>۱۲</sup> Coefficient of Determination

<sup>۱۳</sup> Index of Agreement



Voukantsis و همکاران، ۲۰۱۱؛ Feng و همکاران، ۲۰۱۵؛ Asadollahfardi و همکاران، ۲۰۱۷؛ Delnavaz و همکاران، ۲۰۱۶).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P - M)^2} \quad \text{رابطه (۶)}$$

$$MBE = \frac{1}{n} \sum_{i=1}^n \left| \frac{P - M}{M} \right| \quad \text{رابطه (۷)}$$

$$R^2 = \left( \frac{\sum (M - \bar{M})(P - \bar{P})}{\sqrt{\sum (M - \bar{M})^2 \sum (P - \bar{P})^2}} \right)^2 \quad \text{رابطه (۸)}$$

$$IA = 1 - \frac{\sum (F - A)^2}{\sum (|P - \bar{P}| + |M - \bar{M}|)^2} \quad \text{رابطه (۹)}$$

که در آن n تعداد داده‌ها، P داده‌های پیش‌بینی شده توسط مدل، M داده‌های اندازه‌گیری شده و  $\bar{P}$  و  $\bar{M}$  به ترتیب مقادیر متوسط آنها می‌باشد.

تاثیر نرمال‌سازی داده‌ها و تعداد نرون‌های لایه‌های مخفی

ساختار شبکه‌های عصبی مصنوعی اساسی‌ترین بخش در تعیین عملکرد این شبکه‌ها می‌باشد. جهت انتخاب مناسب‌ترین شبکه در پیش‌بینی میزان آلاینده PM<sub>10</sub> از تغییر تعداد لایه‌های مخفی، تعداد نرون‌های لایه‌های مخفی و نرمال کردن داده‌های ورودی به شبکه استفاده گردید. در شبکه‌های یک لایه از تابع انتقال تانژانت سیگموئید<sup>۱۴</sup> و در شبکه‌های دولایه از توابع تانژانت سیگموئید و لوگ سیگموئید<sup>۱۵</sup> در لایه‌های اول و دوم استفاده گردید. جدول (۴) مدل‌های مختلف ساخته شده را نشان می‌دهد.

جدول (۴). ساختار شبکه‌های ساخته‌شده

شماره مدل	تعداد لایه‌های مخفی	تعداد نرون‌ها		پردازش داده‌ها	شماره مدل	تعداد لایه-های مخفی	تعداد نرون‌ها		پردازش داده‌ها
		لایه اول	لایه دوم				لایه اول	لایه دوم	
۱	۱	۷	۰	خیر	۹	۲	۵	۹	خیر
۲	۱	۷	۰	بله	۱۰	۲	۵	۹	بله
۳	۱	۱۱	۰	خیر	۱۱	۲	۱۱	۸	خیر
۴	۱	۱۱	۰	بله	۱۲	۲	۱۱	۸	بله
۵	۱	۱۹	۰	خیر	۱۳	۲	۱۲	۱۵	خیر
۶	۱	۱۹	۰	بله	۱۴	۲	۱۲	۱۵	بله
۷	۲	۴	۳	خیر	۱۵	۲	۱۸	۱۴	خیر
۸	۲	۴	۳	بله	۱۶	۲	۱۸	۱۴	بله

۱۴ Tansig

۱۵ Logsig

## مدل زنجیره مارکف

روش‌های ریاضی زیادی برای بررسی غلظت آلاینده‌های هوا بکار برده شده است. در این تحقیق از مدل آماری زنجیره مارکف استفاده گردید (Taylor و Karlin, ۱۹۹۸). در این راستا کیفیت هوا با استناد به استاندارد EPA به چهار رده آلودگی (غلظت ۰-۵۴  $\mu\text{g}/\text{m}^3$ ) ساعت با کیفیت هوای خوب، ۵۵-۱۵۴  $\mu\text{g}/\text{m}^3$ ) کیفیت هوای متوسط، ۱۵۵-۲۵۴  $\mu\text{g}/\text{m}^3$ ) کیفیت حساس و  $\geq 255$  کیفیت ناسالم) تقسیم و جهت تعیین احتمال وقوع حالات مختلف آلودگی  $\text{PM}_{10}$  از مدل زنجیره مارکف استفاده شد. زنجیره مارکف روشی است ریاضی برای مدل‌بندی فرآیندهای احتمالاتی. یک زنجیره مارکف با دو ویژگی شناخته می‌شود: الف- فضای حالت و ب- مرتبه. اگر سیستم را در اینجا هوای شهر مشهد تعریف کنیم، فضای حالت (S) آن در یک ساعت معین یکی از سه وضعیت رابطه (۱۰) خواهد بود (Aitsahlia و Chung, ۲۰۰۳).

$$S = \{g, m, s, u\} \quad \text{رابطه (۱۰)}$$

که در آن g معرف ساعت با کیفیت هوای در رده خوب، m ساعات با کیفیت متوسط، s ساعت حساس و u معرف ساعت با کیفیت ناسالم است.

مرتبه زنجیره مارکف مشخص می‌کند که حالت فعلی یک سیستم به چند حالت قبلی آن وابستگی دارد. برای تعیین مناسب‌ترین مرتبه زنجیره مارکوف آزمون‌های متعددی ارائه شده است. در این تحقیق از آزمون‌های  $\text{AIC}^{۱۶}$  و  $\text{BIC}^{۱۷}$  استفاده شد روابط (۱۱ و ۱۲). بدین ترتیب که این آزمون‌ها برای مرتبه‌های مختلف انجام شده و مناسب‌ترین مرتبه براساس کمترین مقدار AIC یا BIC انتخاب گردید. آزمون‌های AIC و BIC براساس توابع درستنمایی بوده و مقادیر درستنمایی زنجیره مارکوف از مرتبه‌های صفر ( $L_0$ )، اول ( $L_1$ )، دوم ( $L_2$ ) و سوم ( $L_3$ ) طبق روابط (۱۳ الی ۱۶) می‌باشد (Taylor و Karlin, ۱۹۹۸).

$$\text{AIC}(m) = -2L^m + 2S^m(S-1) \quad \text{رابطه (۱۱)}$$

$$\text{BIC}(m) = -2L^m + 2S^m \ln(S-1) \quad \text{رابطه (۱۲)}$$

$$L_0 = \sum_{j=0}^{S-1} n_j \ln(\hat{P}_j) \quad \text{رابطه (۱۳)}$$

$$L_1 = \sum_{i=0}^{S-1} \sum_{j=0}^{S-1} n_{ij} \ln(\hat{P}_{ij}) \quad \text{رابطه (۱۴)}$$

$$L_2 = \sum_{h=0}^{S-1} \sum_{i=0}^{S-1} \sum_{j=0}^{S-1} n_{hij} \ln(\hat{P}_{hij}) \quad \text{رابطه (۱۵)}$$

$$L_3 = \sum_{k=0}^{S-1} \sum_{h=0}^{S-1} \sum_{i=0}^{S-1} \sum_{j=0}^{S-1} n_{khij} \ln(\hat{P}_{khij}) \quad \text{رابطه (۱۶)}$$

<sup>۱۶</sup> Akiake Information Criterion

<sup>۱۷</sup> Bayesian Information Criterion

که در آن S تعداد حالت‌ها، m مرتبه زنجیره مارکوف، n و P به ترتیب تعداد داده‌ها و احتمال مربوط به اتفاق هر گروه می‌باشد. اطلاعات بیشتر در این زمینه توسط ویلکس (Wilks, ۲۰۰۶) ارائه گردیده است. در این تحقیق با توجه به نتایج آزمون‌های AIC و BIC، زنجیره مارکوف از مرتبه اول تعریف گردید. بیان ریاضی آن بصورت رابطه (۱۷) می‌باشد (Logofet و Lensnaya, ۲۰۰۰).

$$\Pr\{X_t|X_{t-1}, X_{t-2}, \dots, X_1\} = \Pr\{X_t|X_{t-1}\} \quad \text{رابطه (۱۷)}$$

براساس رابطه (۷)، حالت یک متغیر در زمان t (X<sub>t</sub>) صرفاً به حالت آن در زمان t-1 (X<sub>t-1</sub>) وابسته است نه به مسیری که سیستم از طریق آن به حالت فعلی رسیده است. رفتار یک زنجیره مارکوف را می‌توان در قالب یک ماتریس احتمالات انتقال خلاصه نمود که هر یک از درایه‌های آن معرف مقدار احتمال انتقال از یک حالت در زمان قبل به حالت دیگر در زمان بعد است. ماتریس احتمال انتقال یک ماتریس k×k است که در آن k تعداد اعضای فضای حالت می‌باشد. رابطه (۱۸) نمونه یک ماتریس انتقال و رابطه (۱۹) ماتریس احتمال انتقال زنجیره مارکوف مرتبه نخست چهارحالتی مورد استفاده در این تحقیق را بیان می‌کنند (Shamshad و همکاران، ۲۰۰۵).

$$P = (P_{ij})_{(n \times n)} = \begin{bmatrix} P_{1,1} & \dots & P_{1,n} \\ \vdots & \ddots & \vdots \\ P_{n,1} & \dots & P_{n,n} \end{bmatrix} \quad \text{رابطه (۱۸)}$$

$$P = (P)_{(4 \times 4)} = \begin{bmatrix} P_{gg} & P_{gm} & P_{gs} & P_{gu} \\ P_{mg} & P_{mm} & P_{ms} & P_{mu} \\ P_{sg} & P_{sm} & P_{ss} & P_{su} \\ P_{ug} & P_{um} & P_{us} & P_{uu} \end{bmatrix} \quad \text{رابطه (۱۹)}$$

که در آن زیرنویس‌های g، m، s و u به ترتیب معرف ساعت با کیفیت سالم، متوسط، حساس و ناسالم است، به‌طوریکه اولین زیرنویس مربوط به زمان t-1 و دومین زیرنویس مربوط به زمان t می‌باشد (به عنوان مثال P<sub>uu</sub> معرف احتمال وقوع دو ساعت متوالی ناسالم و P<sub>gs</sub> احتمال وقوع یک ساعت حساس پس از یک ساعت با کیفیت خوب است). هر یک از درایه‌های ماتریس احتمال انتقال بر اساس رابطه (۲۰) تعیین می‌شوند.

$$P_{ij} = \frac{n_{ij}}{\sum n_{ij}} \quad \text{رابطه (۲۰)}$$

که در آن n معرف تعداد ساعات می‌باشد (به عنوان مثال N<sub>gu</sub> معرف تعداد دفعاتی است که یک ساعت ناسالم پس از یک ساعت پاک اتفاق افتاده است).

با تعیین ماتریس احتمال انتقال زنجیره مارکوف می‌توان تحلیل‌های مختلفی انجام داد که یکی از بارزترین آنها تداوم ساعات ناسالم از لحاظ آلودگی PM<sub>10</sub> است. با توجه به اینکه پس از وقوع یک تداوم n ساعته کیفیت هوای خوب یک ساعت با کیفیت متوسط، حساس یا ناسالم اتفاق می‌افتد رابطه (۲۱) جهت محاسبه احتمال تداوم n ساعته کیفیت هوای خوب و بطور مشابه روابط (۲۲، ۲۳ و ۲۴) به ترتیب برای محاسبه احتمال تداوم n ساعته کیفیت هوای متوسط، حساس و ناسالم استخراج گردیدند.

$$P_g(n) = P_{gg}^{n-1} \times P_{gm} + P_{gg}^{n-1} \times P_{gs} + P_{gg}^{n-1} \times P_{gu} \quad \text{رابطه (۲۱)}$$

$$P_m(n) = P_{mm}^{n-1} \times P_{mg} + P_{mm}^{n-1} \times P_{ms} + P_{mm}^{n-1} \times P_{mu} \quad \text{رابطه (۲۲)}$$

$$P_s(n) = P_{ss}^{n-1} \times P_{sg} + P_{ss}^{n-1} \times P_{sm} + P_{ss}^{n-1} \times P_{su} \quad \text{رابطه (۲۳)}$$

$$P_u(n) = P_{uu}^{n-1} \times P_{ug} + P_{uu}^{n-1} \times P_{um} + P_{uu}^{n-1} \times P_{us} \quad \text{رابطه (۲۴)}$$

### نتایج

با توجه به استاندارد EPA مقادیر  $SO_2$ ،  $CO$  و  $NO_2$  در اکثر مواقع در محدوده مجاز بوده و تنها آلودگی محسوس ناشی از مقادیر ذرات معلق بوده که چندین بار از مقدار استاندارد بالاتر رفته اند (US.EPA, ۲۰۰۹). لذا در این تحقیق سعی شده با استفاده از روش‌های ذکر شده نحوه تغییرات آلاینده  $PM_{10}$  پیش‌بینی و بررسی شود.

جدول (۵) مقادیر همبستگی<sup>۱۸</sup> بین داده‌های مورد استفاده در این تحقیق را نشان می‌دهد. بین پارامترهای مختلف مورد استفاده در مدلسازی نباید همبستگی بالایی وجود داشته باشد (Kuncheva, ۲۰۰۴). در صورت وجود وابستگی بالا بین داده‌های ورودی و خروجی، نیاز به استفاده از روش‌های مدلسازی پیچیده مانند شبکه‌های عصبی مصنوعی نبوده و کاربرد روش‌های رگرسیونی نتیجه بخش خواهد بود.

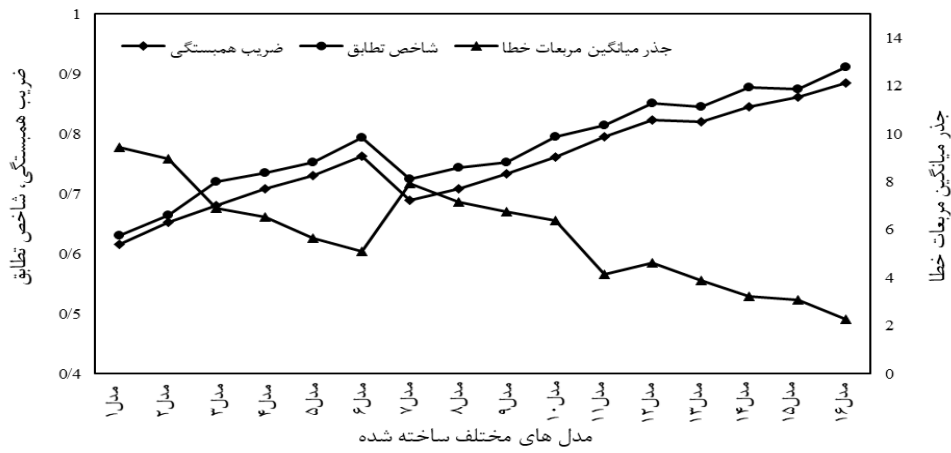
جدول (۵). همبستگی بین پارامترهای ورودی و خروجی

پارامترها	$PM_{10}$	$PM_{2.5}$	دما	دی‌اکسید گوگرد	مونوکسید کربن
$PM_{10}$	۱	-	-	-	-
$PM_{2.5}$	۰/۱۰۵	۱	-	-	-
دما	۰/۳۱۸	۰/۲۵۷	۱	-	-
دی‌اکسید گوگرد	۰/۲۲۴	۰/۰۸۶	۰/۱۲۴	۱	-
مونوکسید کربن	۰/۳۱۵	۰/۲۵۴	۰/۱۸۶	۰/۱۶۵	۱

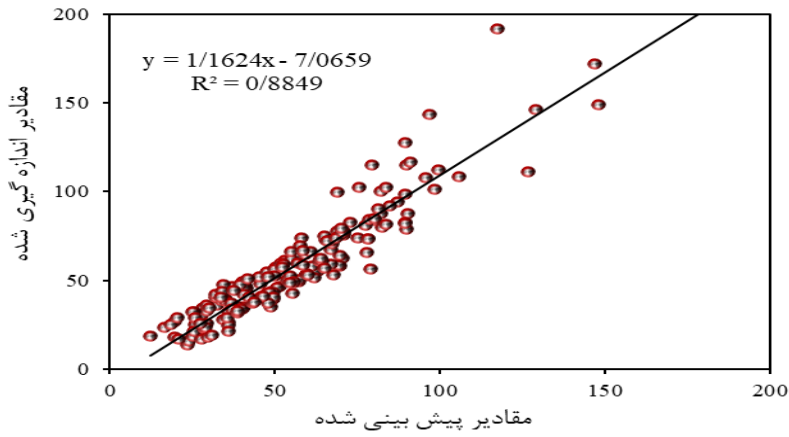
### شبکه‌های عصبی مصنوعی

شبکه برای پیش‌بینی میزان آلاینده  $PM_{10}$  در هوای شهر مشهد با استفاده از ۱۳۰۰ داده ساعتی آموزش دید. برای انتخاب مناسب‌ترین شبکه در پیش‌بینی ۱۸۸ داده تست، تعداد لایه‌های مخفی و نرون‌ها، نوع توابع انتقال، نرخ یادگیری و ضریب مومنتوم تغییر داده شده و داده‌نرمال شدند. شکل ۳ نحوه عملکرد شبکه‌های مختلف ساخته شده مدل‌های توصیف‌شده در جدول (۴) را نشان می‌دهد. نرمال‌سازی داده‌ها همواره باعث بهبود عملکرد شبکه می‌شود. همچنین افزایش تعداد نرون‌های لایه‌های مخفی در شبکه‌های MLP باعث کاهش خطای پیش‌بینی و بالا رفتن ضریب همبستگی و شاخص تطابق می‌گردد. شبکه‌ای ساخته‌شده با استفاده از دولایه مخفی و تعداد به ترتیب ۱۸ و ۱۴ نرون در لایه‌های پنهان اول و دوم با بکارگیری داده‌های نرمال‌شده مدل (۱۶) با ضریب همبستگی، شاخص تطابق، میانگین بایاس خطا و جذر میانگین مربعات خطای به ترتیب برابر ۰/۸۸، ۰/۹۱، ۰/۰۸۷۴ و ۲/۲۶ بهترین عملکرد را در پیش‌بینی غلظت ذرات معلق داشته است. اشکال (۴) و (۵) نحوه عملکرد این شبکه در پیش‌بینی مقدار ۱۸۸ داده تست پارامتر  $PM_{10}$  را نشان می‌دهد.

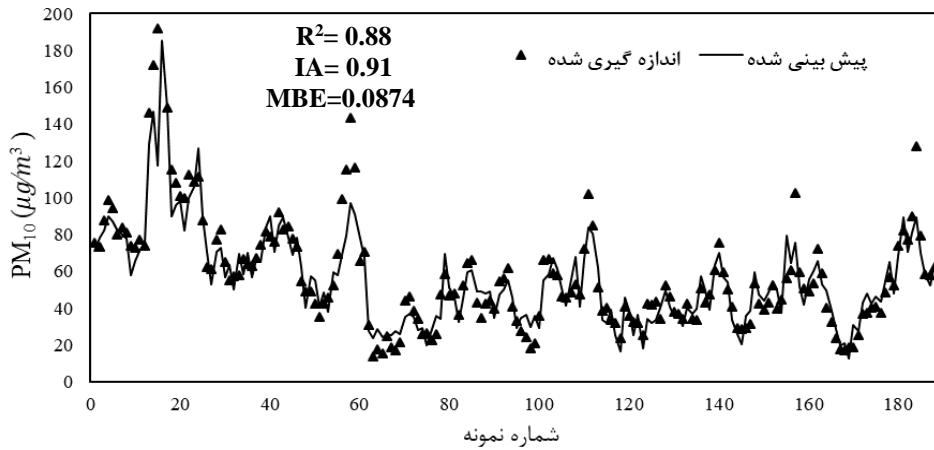
<sup>۱۸</sup> Correlation



شکل (۳). نحوه عملکرد شبکه‌های عصبی ساخته شده با ساختارهای مختلف



شکل (۴). عملکرد شبکه بهینه



شکل (۵). مقایسه مقادیر اندازه‌گیری شده PM<sub>10</sub> با مقادیر پیش‌بینی شده بوسیله مدل بهینه

مقایسه نتایج شبکه MLP ساخته شده در این تحقیق با نتایج Voukantsis و همکاران (۲۰۱۱) و Feng و همکاران (۲۰۱۵) نشان دهنده عملکرد بهتر این مدل در پیش‌بینی میزان آلودگی ذرات معلق شهر مشهد نسبت به این موارد است. Voukantsis و همکاران با شاخص تطابق ۰/۸ و Feng و همکاران با جذر میانگین مربعات خطای برابر ۰/۴ این پارامتر را پیش‌بینی نمودند. علت این امر را می‌توان در تعداد کمتر داده‌های استفاده شده در مطالعات ذکر شده و همچنین دربرگرفتن مدت زمان بیشتر بررسی که با نوسانات بیشتری نیز همراه است، دانست. در واقع تغییرات زیاد غظت ذرات معلق در طول سال باعث کاهش دقت شبکه در پیش‌بینی میزان این پارامتر می‌شود. یکی دیگر از عوامل موثر در نتیجه بخش بودن این شبکه‌ها انتخاب پارامترهای ورودی به شبکه است. از طرفی طراحی صحیح پارامترهای شبکه MLP مانند تعداد لایه‌ها، تعداد نرون‌های لایه‌های مخفی، توابع انتقال، نرخ یادگیری و ضریب مومنتوم و همچنین نرمال سازی داده‌ها نیز باعث افزایش دقت مدل‌سازی می‌گردد.

#### زنجیره مارکف

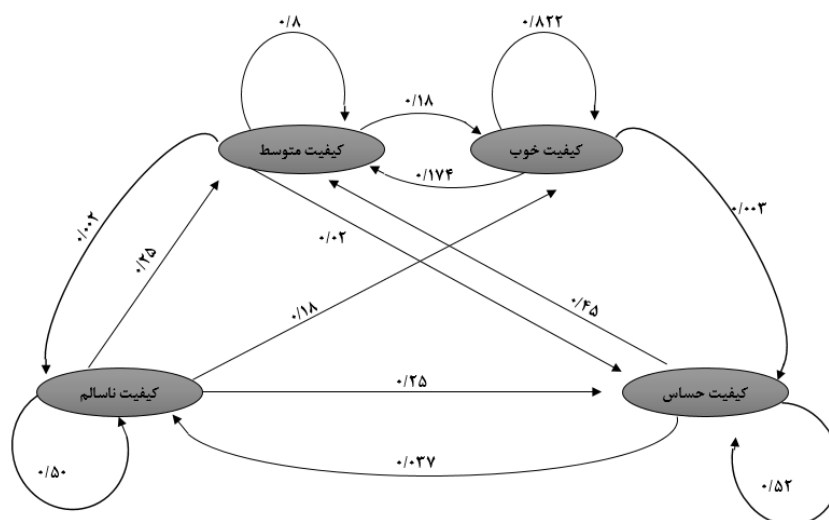
رابطه ۲۵ ماتریس احتمال انتقال و شکل ۶ نمایش تصویری آن برای ۱۶ حالت انتقال وضعیت مختلف را نشان می‌دهند. نتایج این ماتریس بیان می‌کنند که در صورت وقوع کیفیت هوای خوب یا متوسط احتمال تکرار وضعیت بالایی وجود دارد (احتمال به ترتیب ۸۲ و ۸۰ درصد). ولی در صورت وقوع آلودگی و یا کیفیت حساس در یکی از ساعات شبانه‌روز احتمال تکرار وضعیت مقداری تقریباً یکسان داشته (احتمال به ترتیب ۵۰ و ۵۲ درصد) و احتمال برابری برای سالم‌بودن کیفیت هوا در ساعت بعدی وجود دارد. به طور کلی تداوم حالات آلودگی هوا و تغییر وضعیت از هوای حساس به کیفیت متوسط بیش‌ترین احتمالات رخداد را به خود اختصاص داده‌اند.

$$P_{(4 \times 4)} = \begin{matrix} & \begin{matrix} g & m & s & u \end{matrix} \\ \begin{matrix} g \\ m \\ s \\ u \end{matrix} & \begin{bmatrix} 0.822 & 0.174 & 0.003 & 0 \\ 0.18 & 0.8 & 0.02 & 0.002 \\ 0 & 0.45 & 0.52 & 0.037 \\ 0 & 0.25 & 0.25 & 0.5 \end{bmatrix} \end{matrix} \quad \text{رابطه (۲۵)}$$

جدول (۶) تعداد رخدادها و احتمال وقوع هریک را برای دو دسته داده انتخابی برای محاسبات اولیه (۱۳۰۰ داده) و صحت‌سنجی (۱۸۸ داده) همراه با خطای بین آنها نشان می‌دهد. با محاسبه ماتریس احتمال انتقال برای ۱۸۸ داده تست مشخص شد که این ماتریس با خطای ناچیز مشابه ماتریس محاسبه شده برای داده‌های اولیه بوده است. بعنوان مثال احتمال انتقال وضعیت کیفیت هوای پاک به وضعیت متوسط (gm) برابر ۰/۱۷۴ محاسبه گردید که در مقایسه با احتمال وقوع این وضعیت در داده‌های صحت‌سنجی که برابر ۰/۱۵۶ بوده است با خطای مطلق ۰/۱ صحت و دقت قابل قبولی دارد. بنابراین می‌توان نتیجه گرفت که احتمال رخداد آلودگی PM<sub>10</sub> در زمان‌های مختلف با استفاده از این روش قابل پیش‌بینی است.

جدول (۶). تعداد رخداد و احتمال وقوع انتقال وضعیت‌های مختلف

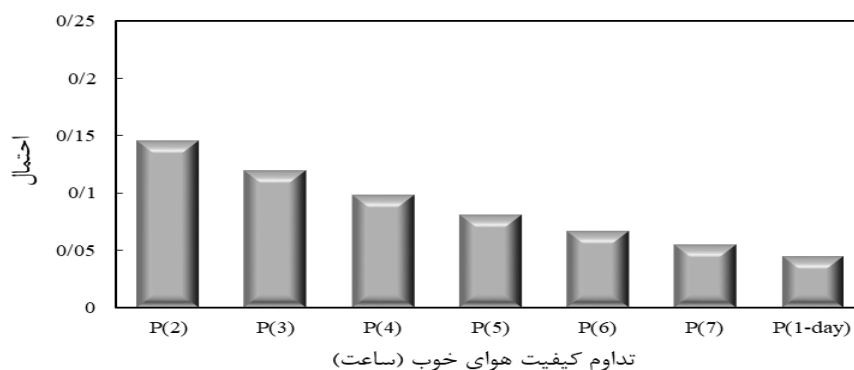
mu	ms	mm	mg	gu	gs	gm	gg	حالات مختلف انتقال وضعیت آلودگی	
۱	۱۰	۴۶۶	۱۰۵	۰	۲	۱۰۴	۴۹۰	تعداد رخداد	۱۳۰۰ داده اندازه-
۰/۰۰۲	۰/۰۲	۰/۸	۰/۱۸	۰	۰/۰۰۳	۰/۱۷۴	۰/۸۲۲	احتمال	گیری
۰	۲	۴۳	۹	۱	۱	۱۰	۵۲	تعداد رخداد	۱۸۸ داده صحت-
۰	۰/۰۳۷	۰/۷۹۶	۰/۱۶۶	۰/۰۱۵	۰/۰۱۵	۰/۱۵۶	۰/۸۱۲	احتمال	سنجی
۰/۰۰۲	۱/۱۵	۰/۰۰۵	۰/۰۷	۰/۰۱	۳/۶	۰/۱	۰/۰۱	خطا (%)	
uu	us	um	ug	su	ss	sm	sg	حالات مختلف انتقال وضعیت آلودگی	
۲	۱	۱	۰	۱	۱۴	۱۲	۰	تعداد رخداد	۱۳۰۰ داده اندازه-
۰/۵	۰/۲۵	۰/۲۵	۰	۰/۰۳۷	۰/۵۲	۰/۴۵	۰	احتمال	گیری
۱	۱	۱	۰	۰	۴	۴	۰	تعداد رخداد	۱۸۸ داده صحت-
۰/۳۳	۰/۳۳	۰/۳۳	۰	۰	۰/۵	۰/۵	۰	احتمال	سنجی
۰/۳۳	۰/۳۳	۰/۳۳	۰	۰/۰۳۷	۰/۰۳۵	۰/۱۲۵	۰	خطا (%)	



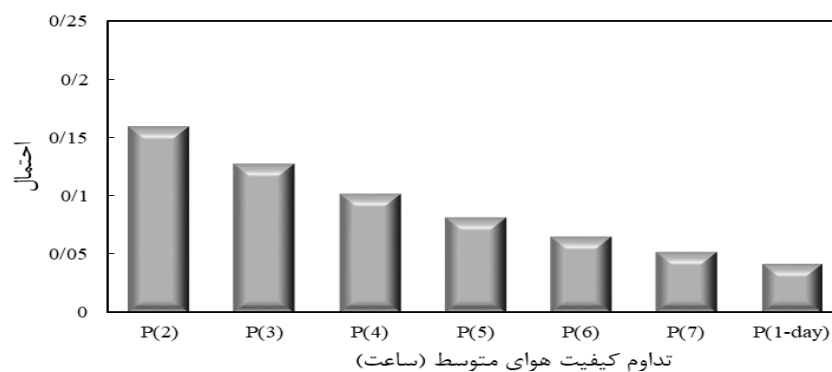
شکل (۶). نمایش تصویری احتمالات انتقال وضعیت

شکل (۷) وضعیت احتمال تداوم  $n$  ساعته برای ۲ ساعت تا ۱ روز هر یک از حالات کیفیت هوا را نشان می‌دهد. محور عمودی احتمال تداوم یک وضعیت و محور افقی زمان تداوم را نشان می‌دهد. به عنوان مثال در منحنی اول شکل (۷-الف)،  $P(n)$  عبارتست از احتمال اینکه وضعیت کیفیت هوای خوب برای  $n$  ساعت متوالی تداوم داشته باشد و پس از آن وضعیت تغییر یابد. با توجه به شکل (۷-ب) بالا بودن احتمال تداوم دوساعته حالت ناسالم (۰/۲۵) وضعیت نامناسب آلاینده PM<sub>10</sub> را نشان می‌دهد. ولی از احتمال تداوم این وضعیت در ساعات چهارم و پنجم کاسته شده و خطر قابل توجهی برای تداوم بیش از حد آلودگی وجود ندارد. در ساعات سوم و بعد از آن با احتمال زیاد وضعیت هوا از ناسالم به حساس و پس از آن به متوسط تغییر حالت

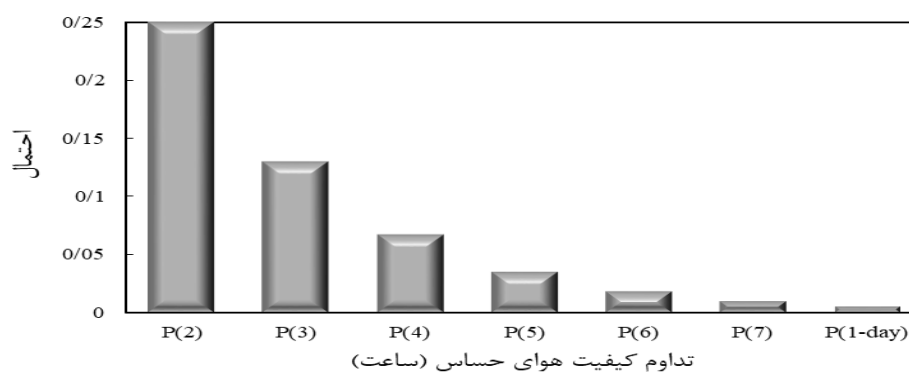
می‌دهد. وضعیت برای کیفیت هوای حساس نیز به همین ترتیب می‌باشد. به این ترتیب پس از وقوع یک ساعت آلوده یا حساس از نظر ذرات معلق در شهر مشهد، باید تا ۲ الی ۳ ساعت بعد به دلیل احتمال بالای تداوم وضعیت احتیاط لازم را در نظر گرفت، ولی پس از آن از شدت آلودگی کاسته شده و درصد احتمالی پایینی برای رخ دادن وضعیت ناسالم وجود خواهد داشت.



شکل (۷-الف)

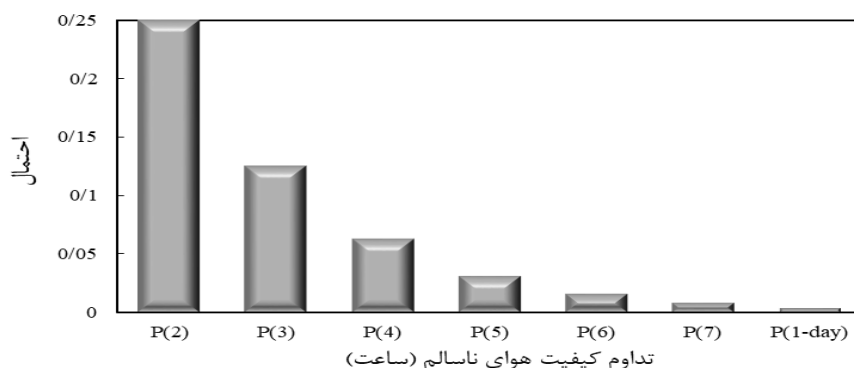


شکل (۷-ب)



شکل (۷-ج)





شکل (۷-د)

اشکال (۷). احتمال تداوم n ساعته وضعیت الف) کیفیت خوب ب) کیفیت متوسط ج) کیفیت حساس و د) کیفیت ناسالم هوا

### نتیجه‌گیری

نتایج کاربرد های عصبی مصنوعی MLP و زنجیره مارکوف در پیش‌بینی ذرات معلق کوچکتر از ۱۰ میکرومتر در شهر مشهد به قرار زیر است.

۱- شبکه‌های MLP به طراحی مناسب جهت عملکرد مطلوب نیاز دارند. در اینجا بهترین مدل، شبکه‌ی دولایه با توابع انتقال تانژانت سیگموئید و لوگ سیگموئید و تعداد ۱۸ و ۱۴ نرون به ترتیب در لایه‌های اول و دوم انتخاب گردید. جهت بهبود عملکرد شبکه داده‌ها نرمال شدند. این شبکه موفق به پیش‌بینی داده‌های صحت-سنجی با ضریب همبستگی ۰/۸۸، شاخص تطابق ۰/۹۱، میانگین بایاس خطای ۰/۰۸۷۴ و جذر میانگین مربعات خطای ۲/۲۶ گردید. با توجه به اثبات صحت عملکرد شبکه‌های عصبی مصنوعی در این تحقیق می‌توان از این روش در مدیریت آلودگی هوا و ارائه راهکارهای مناسب در کاهش آلودگی استفاده نمود.

۲- با بکارگیری مدل زنجیره مارکوف ماتریس احتمال انتقال وضعیت‌های مختلف آلودگی محاسبه گردید. نتایج این ماتریس نشان داد که در صورت وقوع کیفیت هوای خوب، متوسط، حساس و یا ناسالم با احتمال بالایی در ساعت اول پس از آن نیز این وضعیت تداوم می‌یابد. ولی با گذشت زمان کیفیت هوای ناسالم تداوم نداشته و به حالت حساس تغییر وضعیت می‌دهد. همچنین وضعیت حساس در ساعات سوم و بعد از آن با احتمال ۴۵ درصد به هوای متوسط که در محدوده غیرخطرناک آلودگی واقع است تبدیل خواهد شد. در صورتیکه کیفیت هوا در محدوده خوب باشد ۸۲ درصد احتمال دارد که در ساعت بعدی نیز این وضعیت تکرار گردد. مقایسه احتمالات محاسبه‌شده با داده‌های تست نشان‌دهنده خطای ناچیز و عملکرد مطلوب این روش داشت.

پیشنهاد می‌گردد سایر محققین با جمع‌آوری اطلاعات کامل‌تر از جمله سایر پارامترهای موثر هواشناسی و همچنین آلاینده‌های مختلف و اجرای مدلسازی بر روی ایستگاه‌های مناطق مختلف شهری به نتایج جامع‌تر و با دقت بیشتری دست یابند. همچنین این قابلیت وجود دارد با بررسی چگونگی پخش آلاینده‌ها از منابع آلاینده ثابت و متحرک، راه‌حل‌های مدیریتی حل این معضل بررسی و تجزیه و تحلیل گردد.

## منابع

- اکبری، مهری، محمدی، حسین، شمس‌پور، علی اکبر. (۱۳۹۳) بررسی تغییرات شاخص‌های دینامیکی همزمان با توفان‌های حوضه آبریز کارون، نشریه علمی - پژوهشی جغرافیا و برنامه‌ریزی، شماره ۴۸.
- سلیمی، سعدون، خسروانی، وحید، اکبری، مهری. (۱۳۹۲) بررسی نقش الگوهای سینوپتیکی جوی بر آلودگی هوا (مطالعه موردی آلودگی شدید هوای شهر تهران در روزهای ۱۶-۱۲ آذرماه ۱۳۹۱)، اولین همایش سراسری محیط زیست، انرژی و پدافند زیستی، تهران.
- علیجانی، بهلول. (۱۳۸۱) شناسایی تیپ‌های هوایی باران آور تهران بر اساس محاسبه چرخندگی، مجله تحقیقات جغرافیایی، شماره ۳۶ و ۶۴.
- فتاحی، ابراهیم؛ حجازی‌زاده، زهرا. (۱۳۸۵) تحلیل زمانی مکانی توده‌های هوا و کاربرد آن در پایش دوره‌های خشک و مرطوب در حوضه‌های جنوب غربی ایران، فصلنامه تحقیقات جغرافیایی، شماره ۸۱.
- فرج‌زاده اصل، منوچهر، محمدی، ع. (۱۳۹۰) پهنه‌بندی آسیب‌پذیری آب‌های زیرزمینی با کمک الگوریتم‌های فازی عصبی (مطالعه موردی: استان زنجان)، مجله سنجش از راه دور و GIS ایران، سال سوم شماره اول.
- کاوایی، مجدمرضا، علیجانی، بهلول. (۱۳۹۰) مبانی آب و هواشناسی، انتشارات سازمان مطالعه و تدوین کتب علوم انسانی دانشگاهها (سمت).

Asadollahfardi, G.R., Zangoeei, H., Aria, S.H., Danesh, E. (2017). **Application of Artificial Neural Networks to Predict Total Dissolved Solids at the Karaj Dam**, Environmental Quality Management. **26 (3):** 55-72

Barrero, M.A., Grimalt, J.O., Canto'n L. (2006). **Prediction of daily ozone concentration maxima in the urban atmosphere**. Chemom Intell Lab Syst., 80:67-76

Bordignon, S., Gaetan, C., Lisi, F. (2002). **Nonlinear models for groundlevel ozone forecasting**. Stat Meth Appl., **11(2):** 27-46.

Caputo, M., Gimenez, M., Schlamp, M. (2003). **Intercomparison of atmospheric dispersion models**, Atmos. Environ. **37:**2435-2449.

Chan C.K. and Yao, X. (2008). **Air pollution in mega cities in China**, Atmospheric Environment, **42(1):**1-42.

Chattopadhyay, S. and Chattopadhyay, G. (2012). **Modeling and Prediction of Monthly Total Ozone Concentrations by Use of an Artificial Neural Network Based on Principal Component Analysis**, Pure Appl. Geophys. **169:**1891-1908

Chen, C., Lin, C.H., Long, Z., Chen, Q. (2014). **Predicting transient particle transport in enclosed environments with the combined computational fluid dynamics and Markov chain method**, Indoor Air, **24:** 81-92.

Chen, C., Liu, W., Lin, C.H., Chen, Q. (2015). **A Markov chain model for predicting transient particle transport in enclosed environments**, Building and Environment, **90:** 30-36.

Chung, K.L., AitSahlia, F. (2003), **Elementary Probability Theory: With Stochastic Processes and an Introduction to Mathematical Finance**, Springer Undergraduate Texts in Mathematics and Technology, ISSN 0172-6056.

Cohen, S., Intrator, N. (2002). **Automatic model selection in a hybrid perceptron/radial network**, Information Fusion: Special Issue on Multiple Experts, **3(4):**259-266.

- Delnavaz, M., Zangooei, H., Zangooei, M. (2016). **Application of Mathematical Models and Fuzzy Regression Analysis to Determine the Microbial Growth Kinetic Coefficients and Predicting Quality of Treated Wastewater**, Nature Environment and Pollution Technology, **15** (1): 43-57.
- Deng, X., Zhang, F., Rui W. (2013). **PM<sub>2.5</sub>-induced oxidative stress triggers autophagy in human lung epithelial A549 cells**, Toxicology in Vitro, **27**(6): 1762–1770
- Du, X., Kong, Q., Ge, W., Zhang, S., Fu, L., (2010). **Characterization of personal exposure concentration of fine particles for adults and children exposed to high ambient concentrations in Beijing**. China J. Environ. Sci. **22**: 1757-1764.
- Eleuteri, A., Tagliaferri, R., Milano, L. (2005). **A novel information geometric approach to variable selection in MLP networks**. Neural Netw, **18**(10): 9–18
- Feng, X., Li, Q., Zhu, Y., Hou, J., Jin, L., Wang, J. (2015). **Artificial neural networks forecasting of PM<sub>2.5</sub> pollution using air mass trajectory based geographic model and wavelet transformation**. Atmospheric Environment, **107**:118-128.
- Goss, C.H., Newsom, S.A., Schildcrout, J.S., Sheppard, L. and Kaufman, J.D. (2004). **Effect of ambient air pollution on pulmonary exacerbations and lung function in cystic fibrosis**, American Journal of Respiratory and Critical Care Medicine, **169**(7): 816–821.
- Hanna, S.R., Paine, R., Heinold, D., Kintigh, E., Baker, D. (2007). **Uncertainties in air toxics calculated by the dispersion models AERMOD and ISCST 3 in the Houston ship channel area**, J. Appl. Meteorol. Climatol. **46**:1372–1382
- Harsham, D.K., Bennett, M. (2008). **A sensitivity study of validation of three regulatory dispersion models**, Am. J. Environ. Sci. **4**: 63–76.
- Jones RM, (2014). **Nicas M. Benchmarking of a Markov multizone model of contaminant transport**, Ann Occup Hyg, **58**(10):18-31.
- Kalapanidas, E., Avouris, N. (2001). **Short-term air quality prediction using a case-based classifier**, Environ Modell Softw, **16**(2):63–72.
- Karatzas, K., Kaltsatos, S. (2007). **Air pollution modelling with the aid of computational intelligence methods in Thessaloniki, Greece**. Simul Model Pract Theory, **15**(10):1–9.
- Kohavi, R., John, G.H. (1997). **Wrappers for feature subset selection**. Artif Intell., **97**:273–324.
- Kukkonen, J., Partanen, L., Karppinen, A., Ruuskanen, J., Junninen, H., Kolehmainen, M. (2003). **Extensive evaluation of neural network models for the prediction of NO<sub>2</sub> and PM<sub>10</sub> concentrations, compared with a deterministic modelling system and measurements in central Helsinki**, Atmos Environ., **37**(32), (pp. 39–50).
- Kuncheva, L. (2004). **Combining Pattern Classifiers: Methods and Algorithms**. Wiley, New York, USA.
- Kurt, A., Gulbagci, B., Karaca F., Alagha, O. (2008). **An online air pollution forecasting system using neural networks**, Environment International, **34**: 592–598.
- Logofet, D.O., Lensnaya, E.V. (2000). **The mathematics of Markov models: what Markov chains can really predict in forest successions**. Ecol Modell., **2**(3):285–98.

- Moustris, K.P., Ziomas I.C. and Paliatsos A.G. (2010). **3-Day-Ahead Forecasting of Regional Pollution Index for the Pollutants NO<sub>2</sub>, CO, SO<sub>2</sub>, and O<sub>3</sub> using a neural Networks in Athens, Greece**, Water Air Soil Pollut, 209, (pp. 29–43).
- Moustris, K.P. Larissi, I.K. Nastos P.T. Koukouletsos K.V. and Paliatsos, A.G. (2013). **Development and application of artificial neural network modeling in forecasting PM<sub>10</sub> Levels in a Mediterranean City**, Water air soil pollut. 224: 1634, (pp. 3-11).
- Nagendra, S.M., Khare, M. (2006). **Artificial neural network approach for modelling nitrogen dioxide dispersion from vehicular exhaust emissions**, Ecol Modell, 190, (pp. 99-115).
- Nicas M. (2000). **Markov modeling of contaminant concentrations in indoor air**, AIHAJ 61:48.
- Niska, H., Rantamäki, M., Hiltunen, T., Karppinen, A., Kukkonen, J., Ruuskanen, J. (2005). **Evaluation of an integrated modelling system containing a multi-layer perceptron model and the numerical weather prediction model HIRLAM for the forecasting of urban airborne pollutant concentrations**, Atmos Environ., 39:65, (pp. 24–36).
- Niska, H., Heikkinen, M., Kolehmainen, M. (2006). **Genetic algorithms and sensivity analysis applied to select inputs of a multi-layer perceptron for the prediction of air pollutant time-series**, Lect Notes Comput Sci., 4224:2, (pp. 24–31).
- Owega, S., Khan, B.U.Z., Evans, G.J., Jarvis, R.E., and Fila, M. (2006). **Identification of long-range aerosol transport patterns to Toronto via classification of back trajectories by cluster analysis and neural network techniques**. Chemometrics and intelligent laboratory systems, 83(1), (pp. 26-33).
- Qiu, H., Yu, I., Wang, X., Tian, L., Tse, L.A., Wong, T.W., (2013). **Differential effects of fine and coarse particles on daily emergency cardiovascular hospitalizations in Hong Kong**. Atmos. Environ., 64, (pp. 296-302).
- Rumelhart; D.E., Clelland; J.L.M. (1986). **Parallel distribution processing: Exploration in the microstructure of cognition**, Cambridge, MA: MIT Press (p. 1).
- Shamshad, A., Bawadi, M.A., Wan Hussin, W.M.A., Majid, T.A., Sanusi, S.A.M. (2005). **First and second order Markov chain models for synthetic generation of wind speed time series**, Energy, 30, (pp. 693–708).
- Slaughter, J.C., Lumley, T., Sheppard, L., Koenig, J.Q., and Shapiro, G.G., (2003). **Effects of ambient air pollution on symptom severity and medication use in children with asthma**, Annals of Allergy, Asthma and Immunology, vol. 91, no. 4, (pp. 346–353).
- Slini, T., Kaprara, A., Karatzas K., Moussiopoulos, N. (2006). **PM<sub>10</sub> forecasting for Thessaloniki, Greece**. Environ Modell Softw., 21:5, (pp. 59–65).
- Sousa, S.I.V., Martins, F.G., Alvim-Ferraz, M.C.M. and Pereira, M.C. (2007). **Multiple linear regression and artificial neural networks based on principal components to predict ozone concentrations**, Environmental Modelling and Software, 22, (pp. 97-103).
- Sun, W., Zhang, H., Palazoglu, A., Singh, A., Zhang, W., Liu, S. (2013). **Prediction of 24-hour-average PM<sub>2.5</sub> concentrations using a hidden Markov model with different emission distributions in Northern California**, Science of the Total Environment, 443, (pp. 93–103).

- Taylor, H., Karlin, S., (1998). **An Introduction to Stochastic Modeling**. Academic Press, San Diego, California.
- Tzima, F., Karatzas, K., Mitkas, P., Karathanasis, S. (2007). **Using data-mining techniques for PM<sub>10</sub> forecasting in the metropolitan area of Thessaloniki, Greece**. Proc of the 20th int joint conf on neural networks, Orlando, 275, (pp. 2–7).
- U.S. EPA (2009). **Technical Assistance Document for Reporting of Daily Air Quality-air Quality Index**. U.S. Environmental Protection Agency, Office of Air Quality Planning and Standards, Research Triangle Park, North Carolina.
- Voukantsis, D., Karatzas, K., Kukkonen, J., Räsänen, T., Karppinen, A., Kolehmainen, M. (2011). **Intercomparison of air quality data using principal component analysis, and forecasting of PM<sub>10</sub> and PM<sub>2.5</sub> concentrations using artificial neural networks, in Thessaloniki and Helsinki**. Science of the Total Environment, 409, (pp. 1266–1276).
- Wang, J., Hu, M., Xu, C., Christakos, G., Zhao, Y., (2013). **Estimation of citywide air pollution in Beijing**. PLOS One 8, e53400.
- Wang, X., Liu, W. (2012). **Research on Air Traffic Control Automatic System Software Reliability Based on Markov Chain**, Physics procedia, 24, (pp. 1601 – 1606).
- WHO Regional Office for Europe, 2006. **Air Quality Guideline: Global Updates 2005**.
- Wilks, D.S. (2006). **Statistical methods in the atmospheric sciences**. Academic Press, USA.
- Zangoeei, H., Delnavaz, M., Asadollahfardi, G.R. (2016). **Prediction of coagulation and flocculation processes using ANN models and fuzzy regression**, Water Science and Technology. 74 (6), (pp. 1296-1311).
- Zickus, M., Greig, A.J., Niranjana, M. (2002). **Comparison of four machine learning methods for predicting PM<sub>10</sub> concentration in Helsinki, Finland**. Water Air Soil Pollut, 2:7, (pp. 17–29).
- Zurada, J.M. (1992). **Introduction to Artificial Neural Systems**, PWS, Singapore, (pp. 195–196).