

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

پیش‌بینی آلودگی PM_{10} 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 زنگوئی: باشگاه پژوهشگران جوان و نخبگان، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

hossein.zangooei@yahoo.com

غلامرضا اسدالله‌فردی: استاد گروه عمران، دانشکده فنی و مهندسی، دانشگاه خوارزمی، تهران.^۱

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 شبکه های عصبی مصنوعی و مدل زنجیره مارکوف غلظت PM_{10} پیش‌بینی و تحلیل گردد. برای این منظور از داده‌های ساعتی CO , SO_2 , $PM_{2.5}$ 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 $0/0874$ و جذر میانگین مربعات خطای $2/26$ پیش‌بینی نمود، همچنین مدل مارکوف با خطای مطلق متوسط حدود $1/0$ درصد احتمالات انتقال وضعیت و تداوم وضعیت‌های مختلف آلودگی هوای ناشی از ذرات معلق را پیش‌بینی نمود.

کلیدواژگان: شبکه‌های عصبی مصنوعی، آلودگی هوای PM_{10} , زنجیره مارکف.

۱. نویسنده مسئول: گروه عمران، دانشکده فنی و مهندسی، دانشگاه خوارزمی.

مقدمه

مسائل زیست محیطی 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 در حال 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 تشديد بیماری‌های قلبی-ریوی، کاهش مقاومت سیستم ایمنی بدن در مقابل بیماری‌ها، از بین رفتگی 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 PM₁₀ 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 (NO₂)، دی‌اکسید گوگرد (SO₂), ذرات معلق (PM^x) و سرب (Pb) (US.EPA، ۲۰۰۹). آلاینده‌های ثانویه به موادی اطلاق می‌شوند که بر اثر فعل و انفعالات موجود در اتمسفر زمین بوجود آمیزند مانند اوزون (O₃). جدول (۱) میزان استاندارد برخی از آلاینده‌ها را نشان می‌دهد (Caputo و همکاران، ۲۰۰۷).

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

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

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

^۱ Particle Materials

مدل زنجیره مارکف^۳ و همچنین استفاده از روش‌های هوش مصنوعی با کمک سایر داده‌های موجود موازی با داده‌های اصلی، یکی از روش‌های مناسب و معترض و معمولاً با خطای کمتر در فرآیند پیش‌بینی آلودگی هوایی باشد.

در مطالعات گذشته پارامترهای آلاینده مختلف ازن (Bordignon و همکاران، ۲۰۰۲؛ Chattopadhyay و همکاران، ۲۰۰۶؛ Sousa و همکاران، ۲۰۰۷؛ Kaltsatos و Karatzas، ۲۰۰۷؛ Chattopadhyay و همکاران، ۲۰۰۱؛ Avouris و Kalapanidas، ۲۰۰۳؛ Kukkonen و همکاران، ۲۰۱۲) و دی‌اکسید نیتروژن (Zickus و همکاران، ۲۰۱۰؛ Khare Nagendra و همکاران، ۲۰۰۶؛ Moustris و همکاران، ۲۰۰۸) با استفاده از روش‌های هوش مصنوعی پیش‌بینی نمودند. همچنین Kurt و همکاران در سال ۲۰۰۸ مقادیر NO_2 و CO و PM_{10} و همکاران در سال ۲۰۱۳ پارامترهای آلاینده NO_2 ، O_3 و CO را با استفاده از شبکه‌های عصبی مصنوعی^۴ 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 هوای بود. Kukkonen و همکاران در سال ۲۰۰۳ با به‌کارگیری پنج مدل شبکه‌های عصبی مصنوعی، یک مدل خطی آماری و یک سیستم مدلسازی قطعی (DET^۵) آلودگی NO_2 و PM_{10} 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_2 و $PM_{2.5}$ را با به‌کارگیری شبکه‌های عصبی مصنوعی چندلایه پرسپترون (MLP^۶) 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_{10}) با به‌کارگیری داده‌های سال‌های ۱۹۹۴ تا ۲۰۰۰ در شهر تسالونیکی^۷ 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_2 و PM_{10} و CO و همکاران در سال ۲۰۱۳ پارامترهای آلاینده NO_2 و همکاران در سال ۲۰۱۱ SO_2 ، O_3 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 $PM_{2.5}$ و PM_{10} را در دو شهر در کشورهای یونان و فنلاند پیش‌بینی کردند. آنها با مقایسه بین نتایج با داده‌های مشاهده شده ضریب

^۳ Markov Chain^۴ Artificial Neural Networks^۵ Deterministic Modelling System^۶ Multilayer Perceptron^۷ 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 (۲۰۱۴) و همکاران (۲۰۱۵) با بکارگیری زنجیره مارکوف کیفیت هوا مناطق مختلف را ارزیابی کردند. Romanof در سال ۱۹۸۲ غلظت روزانه آلاینده SO_2 در یک منطقه صنعتی در کشور رومانی را با استفاده از زنجیره مارکوف بررسی کردند. آنها برای این منظور از استاندارد آلودگی هوا 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 پاد 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_{2.5} روزانه را در منطقه‌ای در شمال کالیفرنیا پیش‌بینی نمودند. آنها نشان دادند که پیش‌بینی صورت گرفته به وسیله توزیع غیرگوسی خطای کمتری نسبت به مدل دارای توزیع گوسی داشته است.

در این تحقیق با توجه به اهمیت پارامتر PM_{10} در استانداردهای آلودگی هوا (Chan و Yao ۲۰۰۸) و همچنین وضعیت حساس آلودگی این پارامتر نسبت به سایر آلودگی‌ها در منطقه مورد مطالعه ماند 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_2 و دما برای دو ماه (فوردین و اردیبهشت) در سال ۱۳۹۳ استفاده شد. از مجموع ۱۴۸۸ سری داده، ۱۳۰۰ داده برای آموزش شبکه و ۱۸۸ داده جهت صحت-سنجدی استفاده گردید.

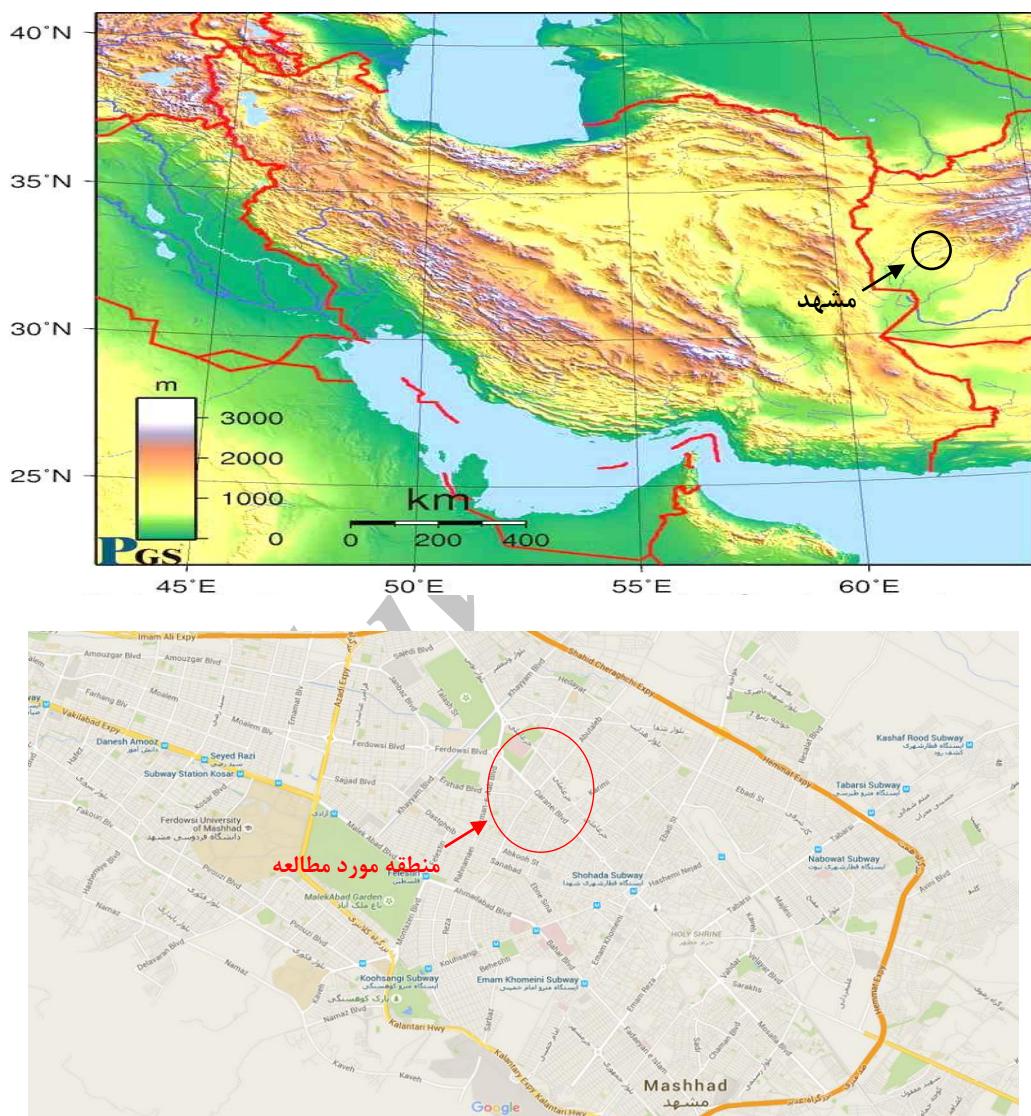
روش تحقیق

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 کش福德 و در انتهای جنوبی دشت رسوی توسعه 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 هزارمسجد 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' ۹۹" شرقی و عرض جغرافیایی "۴۰° ۲۱' ۹۷" 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 Kohavi؛ ۱۹۹۷؛ Eleuteri؛ ۲۰۰۵؛ Niska؛ 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} ، $PM_{2.5}$ و دما برای دو ماه فروردین و اردیبهشت مورد استفاده قرار گرفت. از مجموع ۱۴۸۸ داده برای انجام آموزش شبکه‌های عصبی مصنوعی و تعیین زنجیره مارکف و ۱۸۸ داده برای صحبت‌سنجی 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
$(\frac{\mu g}{m^3}) PM_{10}$	۷۲۴/۲۱۴	۱۰/۲۵۴	۷۲/۱۲۶	۳۴/۲۳
$(\frac{\mu g}{m^3}) PM_{2.5}$	۵۶۳/۸۴	۲/۲۳	۲۷/۲	۲۳/۴۵
$(^{\circ}C)$ دما	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). اینتابع 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؛ Hamblı، ۲۰۱۱).

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

$$v_i^m = \sum_{j=1}^L w_{ji}^{m-1} y_j^{m-1} + b_i^m \quad (3)$$

که در آن y_i^m ورودی‌های مدل، v_i^m خروجی لایه m ام، f معرف تابع انتقال، L تعداد رابطه‌ها با لایه‌های قبلی، w_{ji}^m معادل وزن هر رابطه، 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.

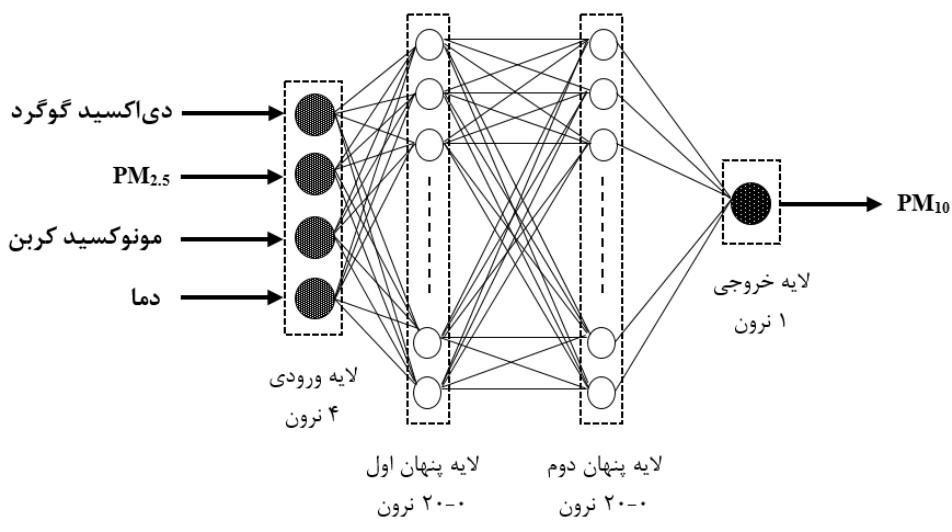
$$f(v_i^m) = \frac{1}{1 + \exp(-\theta v_i^m)} \quad (4)$$

که در آن θ 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 قابع کارایی کاهش می‌یابد (یعنی خلاف جهت شیب آن)، به روز می‌شود. رابطه (۵) یک تکرار از این الگوریتم را نشان می‌دهد (McClelland و Rumelhart, ۱۹۸۶).

$$x_{k+1} = x_k - \alpha_k g_k \quad (5)$$

رابطه (۵) بردار فعلی وزن‌ها و بایاس‌ها، g_k شیب فعلی تابع کارایی و α_k سرعت یادگیری (lr^k) می‌باشد.



شکل (۲) . شبکه MLP مورد استفاده

انتخاب ساختار شبکه MLP

جدول (۳) مشخصات پارامترهای طراحی شبکه MLP را نشان می‌دهد. که در آن پارامتر show، نشان‌دهنده تعداد دفعات تکراری که پس از آن وضعیت آموزش نمایش داده می‌شود، α ، مقدار سرعت یادگیری، goal، میزان خطای هدف، β 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^۹ (β) 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 خطای برای آنها محاسبه می‌گردد. در صورتیکه مقدار خطای دلخواه تعیین‌شده برای شبکه (goal) کمتر باشد آموزش متوقف و در غیر این صورت وزن‌ها و بایاس‌ها در جهت کاهش خطای اصلاح می‌گردند (Zangooei و همکاران، ۲۰۱۶).

جدول (۳) - پارامترهای طراحی شبکه MLP

پارامتر	مقدار
show	۱۰۰۰
α	۰/۴
goal	۰/۰۰۰۱
β	۰/۹
epochs	۱۰۰
تابع	newff

جهت محاسبه خطای در پیش‌بینی مقادیر آلاینده PM_{10} از ضرایب جذر میانگین مربعات خطای (RMSE^{۱۰}) و میانگین بایاس خطای (MBE^{۱۱}) و جهت مشخص کردن میزان همبستگی داده‌های اندازه‌گیری شده با مقادیر پیش‌بینی شده توسط مدل از ضریب همبستگی^{۱۲} (R^2) و شاخص تطابق (IA^{۱۳}) استفاده گردید (روابط ۶ تا ۹).

^۹ momentum ratio

^{۱۰} Root Mean Square Error

^{۱۱} Mean Bias Error

^{۱۲} Coefficient of Determination

^{۱۳} Index of Agreement

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

تأثیر نرمال‌سازی داده‌ها و تعداد نرون‌های لایه‌های مخفی

ساختار شبکه‌های عصبی مصنوعی اساسی ترین بخش در تعیین عملکرد این شبکه‌ها می‌باشد. جهت انتخاب مناسب‌ترین شبکه در پیش‌بینی میزان آلاینده PM_{10} 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^{۱۴} و در شبکه‌های دو لایه از تابع تانژانت سیگموئید و لوگ سیگموئید^{۱۵} در لایه‌های اول و دوم استفاده گردید. جدول (۴) مدل‌های مختلف ساخته شده را نشان می‌دهد.

جدول (۴). ساختار شبکه‌های ساخته شده

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

۱۴ Tansig

۱۵ Logsig

مدل زنجیره مارکف

روش‌های ریاضی زیادی برای بررسی غلظت آلاینده‌های هوای بکار برد شده است. در این تحقیق از مدل آماری زنجیره مارکف استفاده گردید (Karlin و Taylor, ۱۹۹۸). در این راستا کیفیت هوای با استناد به استاندارد EPA به چهار رده آلودگی (غلظت $0 - 54 \mu\text{g}/\text{m}^3$) ساعت با کیفیت هوای خوب، $55 - 154 \mu\text{g}/\text{m}^3$ کیفیت هوای متوسط، $155 - 254 \mu\text{g}/\text{m}^3$ کیفیت حساس و $\geq 255 \mu\text{g}/\text{m}^3$ کیفیت ناسالم تقسیم و جهت تعیین احتمال وقوع حالات مختلف آلودگی 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).

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

که در آن g معرف ساعت با کیفیت هوای در رده خوب، m ساعت 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 $AIC^{\text{۱۶}}$ و $BIC^{\text{۱۷}}$ 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 (Karlin و Taylor, ۱۹۹۸).

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

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

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

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

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

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

^{۱۶} Akiake Information Criterion

^{۱۷} 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) ارایه گردیده است. در این تحقیق با توجه به نتایج آزمون‌های AIC و BIC، زنجیره مارکف از مرتبه اول تعریف گردید. بیان ریاضی آن بصورت رابطه (۱۷) می‌باشد (Lensnaya و Logofet، ۲۰۰۰).

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

براساس رابطه (۷)، حالت یک متغیر در زمان t (X_t) صرفاً به حالت آن در زمان $t-1$ (X_{t-1}) وابسته است نه به مسیری که سیستم از طریق آن به حالت فعلی رسیده است. رفتار یک زنجیره مارکف را می‌توان در قالب یک ماتریس احتمالات انتقال خلاصه نمود که هریک 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 $k \times k$ است که در آن k تعداد اعضای فضای حالت می‌باشد. رابطه (۱۸) نمونه یک ماتریس انتقال و رابطه (۱۹) ماتریس احتمال انتقال زنجیره مارکف مرتبه نخست چهارحالته مورد استفاده در این تحقیق را بیان می‌کنند (Shamshad و همکاران، ۲۰۰۵).

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

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

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_{uu} معرف احتمال وقوع دو ساعت متوالی ناسالم و P_{gs} احتمال وقوع یک ساعت حساس پس از یک ساعت با کیفیت خوب است). هریک از درایه‌های ماتریس انتقال بر اساس رابطه (۲۰) تعیین می‌شوند.

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

که در آن n معرف تعداد ساعت‌های می‌باشد (به عنوان مثال N_{gu} معرف تعداد دفعاتی است که یک ساعت ناسالم پس از یک ساعت پاک اتفاق افتاده است).

با تعیین ماتریس احتمال انتقال زنجیره مارکف می‌توان تحلیل‌های مختلفی انجام داد که یکی از بالرزش‌ترین آنها تداوم ساعت‌های ناسالم از لحظه آلودگی PM_{10} 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.

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

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

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

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

نتایج

با توجه به استاندارد EPA مقادیر CO و NO_2 در اکثر موقع در محدوده مجاز بوده و تنها آلودگی محسوس ناشی از مقادیر ذرات معلق بوده که چندین بار از مقدار استاندارد بالاتر رفته است (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^{۱۸} 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 وجودوابستگی 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}	-	-	-	-	-
$PM_{2.5}$	-	-	-	-	-
دما	-	-	-	-	-
دی‌اکسید گوگرد	-	-	-	-	-
مونوکسید کربن	-	-	-	-	-
PM_{10}	۱	۰/۳۱۵	۰/۲۵۴	۰/۱۸۶	۰/۱۶۵
$PM_{2.5}$	۰/۱۰۵	۰/۳۱۸	۰/۲۵۷	۰/۱۲۴	۰/۰۸۶
دما	۰/۳۱۸	۰/۲۲۴	۰/۰۸۶	۰/۱۲۴	۰/۱۶۵
دی‌اکسید گوگرد	۰/۲۲۴	۰/۰۸۶	۰/۱۲۴	۰/۱۶۵	۰/۱۸۶
مونوکسید کربن	۰/۱۰۵	۰/۳۱۸	۰/۲۵۷	۰/۱۲۴	۰/۰۸۶

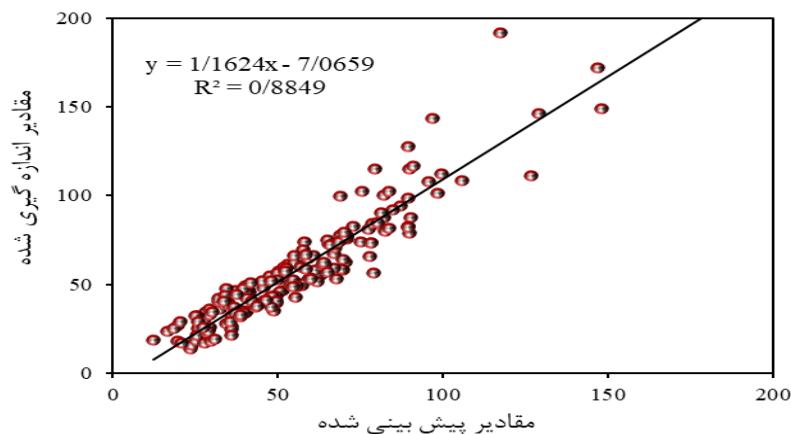
شبکه‌های عصبی مصنوعی

شبکه برای پیش‌بینی میزان آلاینده PM_{10} در هوای شهر مشهد با استفاده از ۱۳۰ 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 تووصیف شده 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 ساخته شده با استفاده از دولایه مخفی و تعداد به ترتیب ۱۸ و ۱۴ نرون در لایه‌های پنهان اول و دوم با بکارگیری داده‌های نرمال شده مدل (۱۶) با ضریب همبستگی، شاخص تطابق، میانگین بایاس خطای و جذر میانگین مربعات خطای به ترتیب برابر $۰/۸۸$ ، $۰/۹۱$ ، $۰/۰۸۷۴$ و $۰/۲۶$ 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.

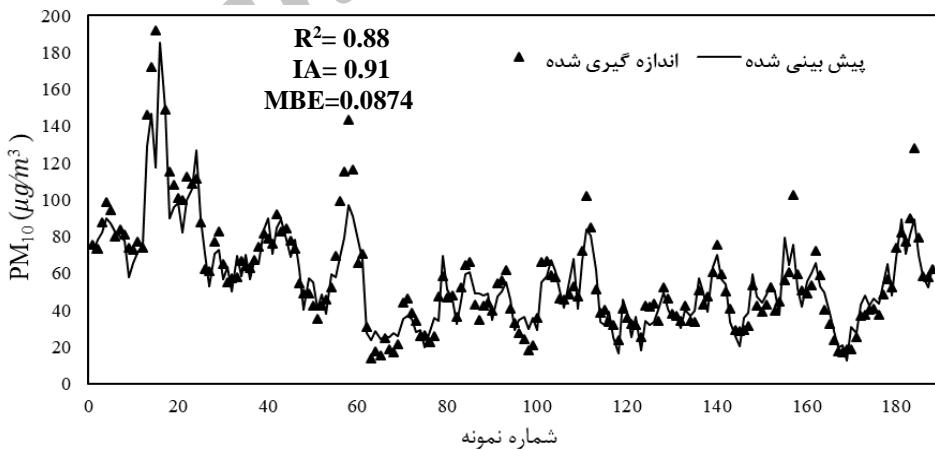
^{۱۸} Correlation



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



شکل (۴). عملکرد شبکه بهینه

شکل (۵). مقایسه مقادیر اندازه‌گیری شده PM_{10} با مقادیر پیش‌بینی شده بوسیله مدل بهینه

مقایسه نتایج شبکه MLP ساخته شده در این تحقیق با نتایج Voukantsis و Feng و همکاران (۲۰۱۱) 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 در برگرفتن مدت زمان بیشتر بررسی که با نوسانات بیشتری نیز میزان این دانست. در واقع تغییرات زیاد غشت 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.

زنگیره 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 ساعت شبانه‌روز احتمال تکرار وضعیت مقداری تقریباً یکسان داشته (احتمال به ترتیب ۵۰ و ۵۲ درصد) و احتمال برابر برای سالم‌بودن کیفیت هوای در ساعت بعدی وجود دارد. به طور کلی تداوم حالات آلودگی هوای تغییر وضعیت از هوای حساس به کیفیت متوسط بیشترین احتمالات رخداد را به خود اختصاص داده‌اند.

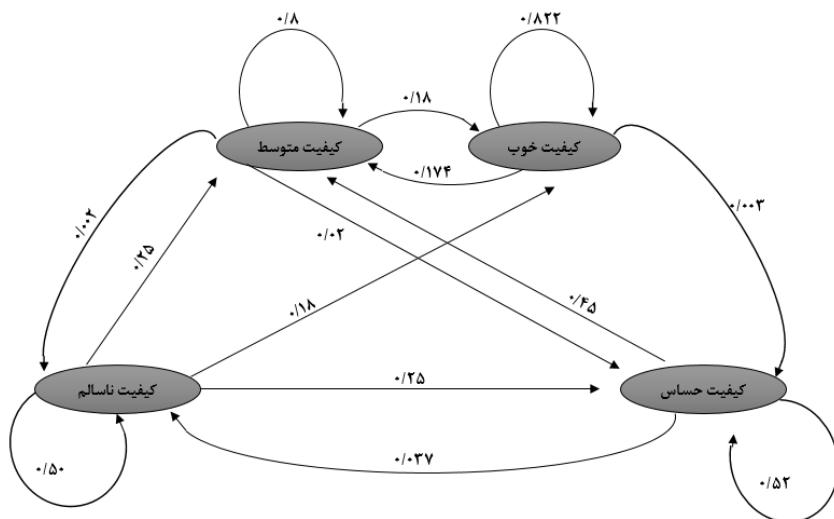
$$P_{(4 \times 4)} = \begin{bmatrix} g & m & s & u \\ g & 0.822 & 0.174 & 0.003 & 0 \\ m & 0.18 & 0.8 & 0.02 & 0.002 \\ s & 0 & 0.45 & 0.52 & 0.037 \\ u & 0 & 0.25 & 0.25 & 0.5 \end{bmatrix} \quad \text{رابطه (۲۵)}$$

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 ۱/۰ صحت و دقت قابل قبولی دارد. بنابراین می‌توان نتیجه گرفت که احتمال رخداد آلودگی PM₁₀ در زمان‌های مختلف با استفاده از این روش قابل پیش‌بینی است.

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

حالات مختلف انتقال وضعیت آلودگی								
mu	ms	mm	mg	gu	gs	gm	gg	
۱	۱۰	۴۶۶	۱۰۵	۰	۲	۱۰۴	۴۹۰	تعداد رخداد
۰/۰۰۲	۰/۰۲	۰/۸	۰/۱۸	۰	۰/۰۰۳	۰/۱۷۴	۰/۸۲۲	احتمال
۰	۲	۴۳	۹	۱	۱	۱۰	۵۲	تعداد رخداد
۰	۰/۰۳۷	۰/۷۹۶	۰/۱۶۶	۰/۰۱۵	۰/۰۱۵	۰/۱۵۶	۰/۸۱۲	احتمال
۰/۰۰۲	۱/۱۵	۰/۰۰۵	۰/۰۷	۰/۰۱	۳/۶	۰/۱	۰/۰۱	سنجدی
								خطا (%)

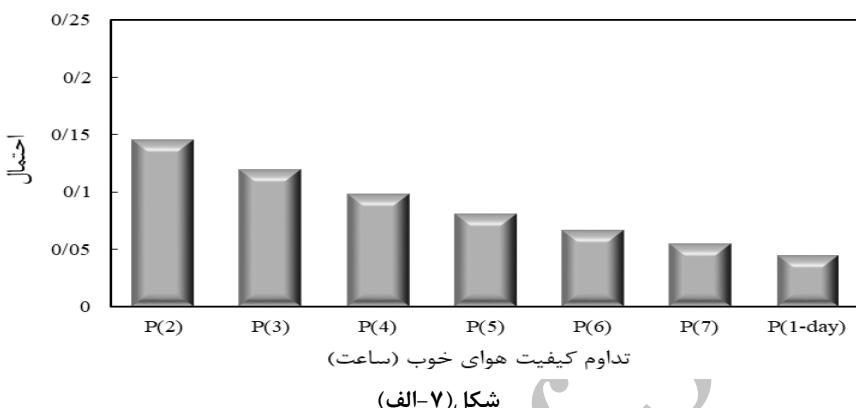
حالات مختلف انتقال وضعیت آلودگی								
uu	us	um	ug	su	ss	sm	sg	
۲	۱	۱	۰	۱	۱۴	۱۲	۰	تعداد رخداد
۰/۵	۰/۲۵	۰/۲۵	۰	۰/۰۳۷	۰/۵۲	۰/۴۵	۰	احتمال
۱	۱	۱	۰	۰	۴	۴	۰	تعداد رخداد
۰/۳۳	۰/۳۳	۰/۳۳	۰	۰	۰/۵	۰/۵	۰	احتمال
۰/۳۳	۰/۳۳	۰/۳۳	۰	۰/۰۳۷	۰/۰۳۵	۰/۱۲۵	۰	سنجدی
								خطا (%)



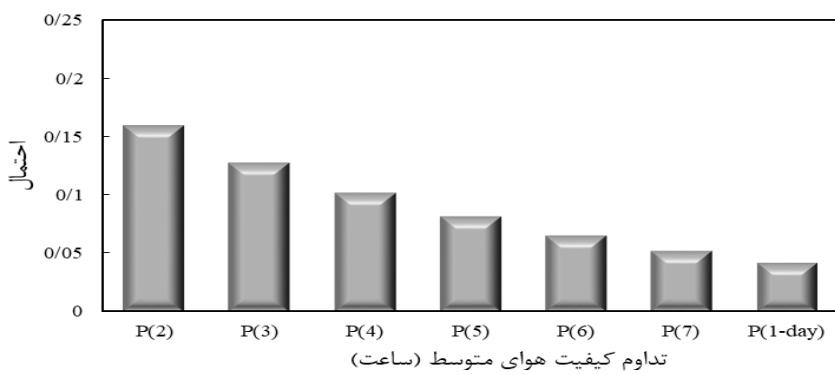
شکل (۶). نمایش تصویری احتمالات انتقال وضعیت

شکل (۷) وضعیت احتمال تداوم n ساعته برای ۲ ساعت تا ۱ روز هر یک از حالات کیفیت هوای را نشان می‌دهند. 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 متواالی تداوم داشته باشد و پس از آن وضعیت تغییر یابد. با توجه به شکل (۷-د) بالا بودن احتمال تداوم دوساعته حالت ناسالم (25%) وضعیت نامناسب آلاینده PM_{10} را نشان می‌دهد. ولی از احتمال تداوم این وضعیت در ساعت‌های چهارم و پنجم کاسته شده و خط قابل توجهی برای تداوم بیش از حد آلودگی وجود ندارد. در ساعت‌های سوم و بعد از آن با احتمال زیاد وضعیت هوای ناسالم به حساس و پس از آن به متوسط تغییر حالت

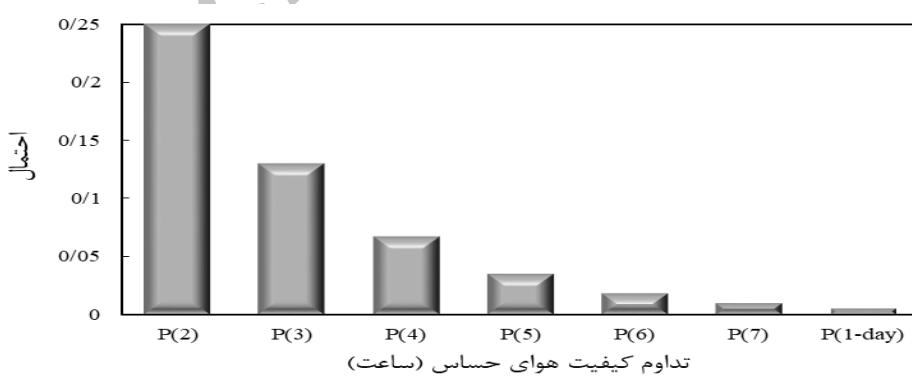
می‌دهد. وضعیت برای کیفیت هوای حساس نیز به همین ترتیب می‌باشد. به این ترتیب پس از وقوع یک ساعت آلوده یا حساس از نظر ذرات معلق در شهر مشهد، باید تا ۲ الی ۳ ساعت بعد بهدلیل احتمال بالای تداوم وضعیت احتیاط لازم را درنظر گرفت، ولی پس از آن از شدت آلودگی کاسته شده و درصد احتمالی پایینی برای رخ دادن وضعیت ناسالم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



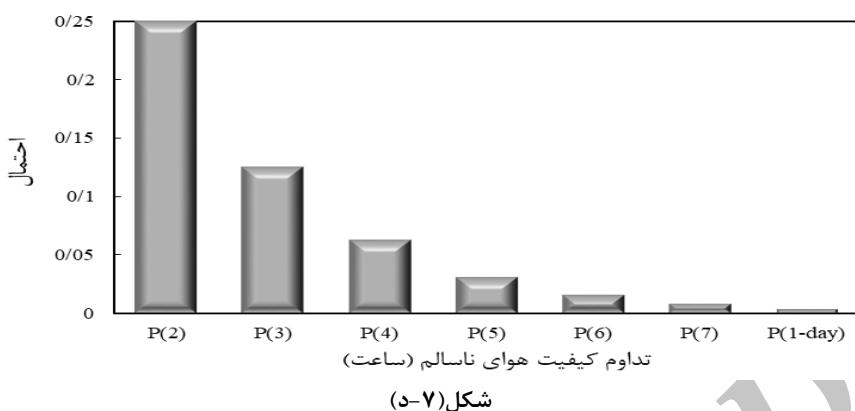
شکل(۷-الف)



شکل(۷-ب)



شکل(۷-ج)



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-سنجدی با ضریب همبستگی 0.88 ، شاخص تطابق 0.91 ، میانگین بایاس خطای 0.874 و جذر میانگین مربعات خطای 2.26 گردید. با توجه به اثبات صحت عملکرد شبکه‌های عصبی مصنوعی در این تحقیق می-توان 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 می‌پابد. 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 45 درصد به هوای متوسط که در محدوده غیرخطوناک آلودگی واقع است تبدیل خواهد شد. در صورتیکه کیفیت هوا در محدوده خوب باشد 82 درصد احتمال دارد که در ساعت بعدی نیز این وضعیت تکرار گردد. مقایسه احتمالات محاسبه شده 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 جامع تر و با دقت بیشتری دست یابند. همچنین این قابلیت وجود دارد با بررسی چگونگی پخش آلاینده‌ها از منابع آلاینده ثابت و متحرک، راه حل‌های مدیریتی حل این معضل بررسی و تجزیه و تحلیل گردد.

منابع

- اکبری، مهری، محمدی، حسین، شمسی‌پور، 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 برآبودگی هوا (مطالعه موردی آبودگی 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) پنهانه‌بندی آسیب‌پذیری آب‌های زیرزمینی با کمک الگوریتم‌های فازی عصبی (مطالعه موردی: استان زنجان)، مجله سنجش از راه دور و GIS ایران، سال سوم شماره اول.
- کاویانی، مجیدرضا، علیجانی، بهلول. (۱۳۹۰) مبانی آب و هواشناسی، انتشارات سازمان مطالعه و تدوین کتب علوم انسانی دانشگاهها (سمت).

- Asadollahfardi, G.R., Zangooei, 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). **PM2.5-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 offline 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 PM2.5 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 NO₂ and PM₁₀ 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 NO₂, CO, SO₂, and O₃ 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 PM10 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., Jervis, 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 offine 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). **PM10 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 PM2.5concentrations 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 PM10 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 PM10and PM2.5concentrations 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.
- Zangooei, 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., Niranjani, M. (2002). **Comparison of four machine learning methods for predicting PM10 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).