دانشگاه آزاد اسلامی واحد اهر
فصلنامه‌ی علمی-پژوهشی فضای جغرافیایی

سال شانزدهم، شماره‌ی ۵۵
پاییز ۱۳۹۵، صفحات ۱۷۶-۱۵۵

شادی اوسطی[۱]
جمیل امان‌اللهی[۲]
بختیار محمدی[۳]

ارزیابی دقت مدل های رگرسیون چندگانه، ARIMA وGRNN در پیش‌بینی غلظت ذرات معلق PM2.5 در شهر سنندج

تاریخ دریافت: ۱۳۹۳/۰۳/۱۶ تاریخ پذیرش: ۱۳۹۳/۱۲/۰۹

چکیده

وجود مشکلات و بحران‌های زیست‌محیطی در جهان باعث شده است تا طی نیم قرن گذشته اهمیت بحث در مورد محیط‌زیست و مسایل زیست‌محیطی بیش‌تر شود. در این میان آلودگی هوا به‌عنوان یکی از معضلات زیست‌محیطی ده‌های اخیر در ردیف یکی از زیان‌بارترین بلایای طبیعی قرار گرفته است. با توجه به اثرگذاری زیان‌بار ذرات معلق بر روی سلامت انسان‌ها، پیش‌بینی مقدار غلظت این ذرات در روزهای آینده می‌تواند سبب کاهش این اثرات شود. لذا در این مطالعه به منظور افزایش صحت پیش‌بینی ذرات معلق $PM_{2.5}$ در شهر سنندج دقت مدل‌های خطی شامل رگرسیون خطی چندگانه (MLR) و خود رگرسیون میانگین متحرک انباشته (ARIMA) و مدل غیرخطی شبکه عصبی رگرسیون عمومی (GRNN) مورد آزمون قرار گرفت. داده‌های مربوط به کیفیت هوا شامل PM_{10}، SO_2، NO_2، CO، O_3 و داده‌های مربوط به هواشناسی شامل میانگین حداقل دما (MinT)، میانگین حداکثر دما (MaxT) میانگین فشار جوی (AP)، بارش کل روزانه (PR)، رطوبت نسبی روزانه سطح هوا (RH) و سرعت باد روزانه (WS)

۱- دانشجوی کارشناسی ارشد محیط‌زیست، دانشگاه کردستان، سنندج، ایران.
۲- استادیار گروه محیط‌زیست، دانشگاه کردستان، سنندج، ایران. E-mail: j.amanollahi@uok.ac.ir
۳- استادیار گروه آب‌وهوا شناسی، دانشگاه کردستان، سنندج، ایران.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

مربوط به سال ۱۳۹۳ به‌عنوان متغیرهای مستقل و میزان غلظت ذرات معلق $PM_{2.5}$ به‌عنوان متغیر وابسته در نظر گرفته شدند. نتایج نشان داد که مدل شبکه عصبی رگرسیون عمومی با مقدار $R^{2=}$ ۰/۸۱ و RMSE= ٦/٩٤٦٨ و MAE=٥ در مرحله آموزش و مقدار R^2=٧٤ و RMSE= ۰/۰۷۲۵ و MAE= ۳/٤٨٧٤ در مرحله آزمون بهترین عملکرد را نسبت به مدل‌های خطی در پیش‌بینی ذرات معلق $PM_{2.5}$ در شهر سنندج داشته است.

کلید واژه‌ها: ذرات معلق $PM_{2.5}$، آلودگی هوا، سنندج، رگرسیون خطی چندگانه، خود رگرسیون میانگین متحرک انباشته، شبکه عصبی رگرسیون عمومی.

مقدمه

افزایش مشکلات و بحران‌های زیست‌محیطی در جهان از یک طرف و درک پیامدهای بلندمدت موضوعات زیست‌محیطی در زندگی انسان‌ها از سوی دیگر، باعث شده است تا طی نیم قرن گذشته اهمیت بحث در مورد محیط‌زیست و مسایل زیست‌محیطی افزایش یابد (صالحی و قائمی‌اصل، ۱۳۹۲: ٦٨). بی‌شک زندگی انسان از روزهای آغازین تا کنون همواره با خطرات ناشی از عوامل طبیعی همراه بوده است، که یکی از این خطرات، آلودگی هوا می‌باشد که در ردیف یکی از زیان‌بارترین بلایای طبیعی قرار گرفته است و مشکلات محیطی عدیده‌ای را به‌وجود آورده است. هوا نیز مانند سایر منابع محیط‌زیست دارای ظرفیت محدود می‌باشد و تحمل تخلیه مواد زاید و سمی مختلف را در حدی که امروزه بشر به آن تحمیل کرده است ندارد (نصراللهی و غفاری[4]، ۲۰۱۰: ۳۷۷). آلودگی هوا عبارت است از حضور یک یا بیش از یک آلاینده در هوای آزاد به مقدار کافی، با خواص مشخص و تداوم کافی که می‌تواند حیات انسان، گیاه یا جانوران و یا اموال انسانی را به مخاطره اندازد (قوامی، ۱۳۹۲: ۱۱). یکی از شاخص‌های مهم در بحث کیفیت هوا غلظت ذرات معلق (PM)[5] می‌باشد (بالداسنو و جیمنز[6]، ۲۰۰۳: ١٤٣). ذرات معلق موجود در هوا می‌تواند منشأ طبیعی یا انسانی داشته باشند. منابع طبیعی تشکیل دهنده ذرات معلق، شامل ذرات جامد ناشی از فعالیت آتشفشان (تیمرک و همکاران[7]، ۲۰۰۹: ۱)، ذرات نمک برخاسته از اقیانوس‌ها و گردوغبار حمل شده توسط باد از مناطق بیابانی (کافمن و همکاران[8]، ۲۰۰۲: ٢١٦) و منابع انسانی آن شامل ذرات تولید شده توسط دودکش کارخانجات، سوزاندن زباله، وسایل گرمایشی منازل و آتش‌سوزی‌های عمدی

4- Nasrollhi and Ghaffari
5- Particulate matter
6- Baldasano and Jiménez
7- Timmreck et al
8- Kaufman et al

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

و غیر عمدی هستند (پستوسکا و همکاران[9]، ۲۰۱۰: ٦١٤). ذرات معلقی که در مجاورت جاده‌ها یا صنایع مولد غبار یافت می‌شوند و قطرشان بزرگتر از ۲/۵ میکرون و کوچک‌تر از ۱۰ میکرون است را PM_{10} می‌نامند و ذرات معلقی که در دود و مه‌دود یافت می‌شود و قطرشان ۲/۵ میکرون و یا کم‌تر است را $PM_{2.5}$ می‌نامند. مضر بودن این ذرات برای سلامتی انسان‌ها توسط محققان زیادی ثابت شده است (ادامسون و همکاران[10]، ۱۹۹۹: ٤٣) که باعث بیماری‌های آسم، ذات‌الریه و عفونت‌های مجاری تنفسی می‌شود (سندستروم[11]، ۲۰۰۸: ۸۰۸). ذرات معلق علاوه بر ایجاد مشکلات سلامتی برای انسان‌ها باعث تأثیر بر روی مقدار تابش خورشید به زمین و تغییر سیستم زمین و جو، تأثیر روی الگوهای جریان جوی، تغییر دمای سطحی زمین و بارش و کاهش دید نیز می‌شوند (گوپتا و ساندر[12]، ۲۰۰۸: ٦٤٦٦). تحقیقی که توسط WHO[13] در برلین، کپنهاک و رم صورت گرفت، نشان داد PM در غلظت‌های طولانی مدت، باعث افزایش ٦٪ مرگ‌ومیر و افزایش هر $\mu g/m^3$ ۱۰ در غلظت $PM_{2.5}$، افزایش ۱۲٪ بیماری‌های قلبی عروقی و ١٤٪ سرطان ریه را در پی دارد (عزیزی‌فر و همکاران، ۱۳۹۰: ٦٠). با توجه به اثرات زیان‌بار این ذرات بر سلامتی انسان‌ها، توانایی پیش‌بینی میزان غلظت آن‌ها و صدور اخطار از رسانه‌های عمومی می‌تواند سبب بالا رفتن سلامت عمومی جامعه گردد. اخیرا روش‌های متعددی برای پیش‌بینی غلظت $PM_{2.5}$ ارائه شده است. مدل رگرسیون خطی چندگانه (MLR) روشی است که برای ارتباط خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل مورد استفاده قرار می‌گیرد (کازمانوسکی و آلکسوسکا[14]، ۲۰۰۳: ١٦٩). مدل‌های رگرسیون چندگانه به دلیل صحت تفسیرشان (ژو و همکاران[15]، ٢٠١٤: ٢٦٥)، به طور گسترده‌ای در زمینه‌ی پیش‌بینی $PM_{2.5}$ مورد استفاده قرار می‌گیرند (کوبورن[16]، ۲۰۱۰: ۳۰۱۷). یکی دیگر از روش‌های پیش‌بینی که در علوم جوی کاربرد زیادی دارد روش شبکه‌های عصبی مصنوعی[17](ANN) است که به صورت پیشرونده و موفق برای سیستم‌های غیرخطی در زمینه‌های علمی و مهندسی به‌کار می‌رود. پیش‌بینی سری‌های زمانی با استفاده از مدل‌های تجزیه و تحلیل از دیرباز در منابع علمی جهان در حال انجام است (حسن[18]، ٢٠١٤: ٤٢٢) که در این رابطه می‌توان به مطالعات زیر اشاره کرد. پرزو همکاران[19] (۲۰۰۰) مدل شبکه عصبی مصنوعی را برای پیش‌بینی $PM_{2.5}$ در سانتیاگو به‌کار بردند و از غلظت $PM_{2.5}$،

9- Pastuszka et al
10- Adamson et al
11- Sandstrom
12- Gupta and Sundar
13- Word health organization
14- Kuzmanovski and Aleksovska
15- Zhou et al
16- Cobourn
17- Artificial Neural Network
18- Hassan
19- Pérez et al

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

سرعت باد و جهت باد به‌عنوان متغیرهای پیش‌بینی کننده استفاده کردند. آن‌ها نتایج را با مدل رگرسیون خطی مقایسه کردند و به این نتیجه رسیدند که شبکه عصبی نتایجی دقیق‌تری را ارائه می‌دهد. الکامل و همکاران[20] (۲۰۰۱) سطوح ازن را با استفاده از شبکه عصبی مصنوعی پیش‌بینی کردند. به همین منظور اطلاعات مربوط به هواشناسی (سرعت و جهت باد، رطوبت نسبی و درجه حرارت خورشید) و غلظت آلاینده‌های متان، منوکسیدکربن، دی‌اکسیدکربن و گردوغبار در یک منطقه صنعتی در کویت جمع‌آوری شد و عملکرد شبکه عصبی با مدل‌های رگرسیون خطی و غیرخطی مقایسه گردید. نتایج نشان داد که شبکه‌های عصبی پیش‌بینی بهتری را ارائه می‌دهد. چالولاکو و همکاران[21](۲۰۰۳) مدل شبکه عصبی و MLR را برای پیش‌بینی غلظت PM_{10} در آتن پیشنهاد دادند. به همین منظور متغیرهای هواشناسی طی یک دوره‌ی دو ساله به عنوان ورودی‌های شبکه عصبی و MLR مورد بررسی قرار گرفتند. نتایج نشان داد اگر شبکه عصبی مصنوعی به درستی اجرا شود می‌تواند گزینه مناسبی برای پیش‌بینی این آلاینده باشد. در مطالعه‌ای صدرموسوی و رحیمی (۱۳۸۸) از مدل MLR و شبکه عصبی مصنوعی به منظور پیش‌بینی کوتاه‌مدت غلظت ازن برای شهر تبریز استفاده کردند. داده‌های مورد نیاز شامل داده‌های هواشناسی (سرعت باد، رطوبت نسبی، جهت باد، درجه حرارت، بارندگی، فشار هوا، مقدار تابش و مقدار تبخیر) و داده‌های آلودگی هوا (غلظت ازن) است. نتایج به‌دست آمده نشان می‌دهد که مدل شبکه‌های عصبی توانایی‌های بیش‌تری نسبت به روش‌های رگرسیونی خطی داشته است. به‌طوری که ضریب همبستگی در مدل رگرسیون چندگانه ۰/٤٥ در حالی که ضریب همبستگی در شبکه‌های عصبی ۰/۹۱ بوده است. کای و همکاران[22](۲۰۰۹) غلظت آلاینده‌های نزدیک جاده‌های شهری را با استفاده از شبکه عصبی مصنوعی محاسبه کردند. به‌این منظور غلظت منوکسیدکربن، نیتروژن‌دی‌اکسید و ازن را اندازه‌گیری کردند و نتایج نشان داد که این مدل قادر به پیش‌بینی دقیق آلاینده‌ها تا ۱۰ ساعت قبل از آن می‌باشد. بوداقپور و چرخستانی (۱۳۹۰) برای پیش‌بینی میزان غلظت آلاینده‌های شهر تهران از شبکه عصبی مصنوعی استفاده کردند. برای این منظور از آمار غلظت آلاینده هوای ثبت شده توسط حسگرهای نصب شده در سال‌های ۱۳۸۱ تا ۱۳۸٦ استفاده کردند (گاز NO_X). همچنین این پیش‌بینی با استفاده از رگرسیون غیرخطی انجام گرفته و خطای جذر میانگین مربعات مدل شبکه عصبی با معادلات رگرسیون مقایسه شده و مشاهده می‌شود که خطای مدل شبکه عصبی کم‌تر از روش رگرسیون است. منصوری و همکاران (۱۳۹۲) به پیش‌بینی و بررسی وضع آلاینده‌های هوای شهر کرمان با استفاده از مدل خود رگرسیون میانگین متحرک انباشته (ARIMA) پرداختند. نتایج نشان می‌دهد که آلاینده‌ها در هوای کرمان روند تقریبا ثابتی داشتند به جز منواکسیدکربن که به طور

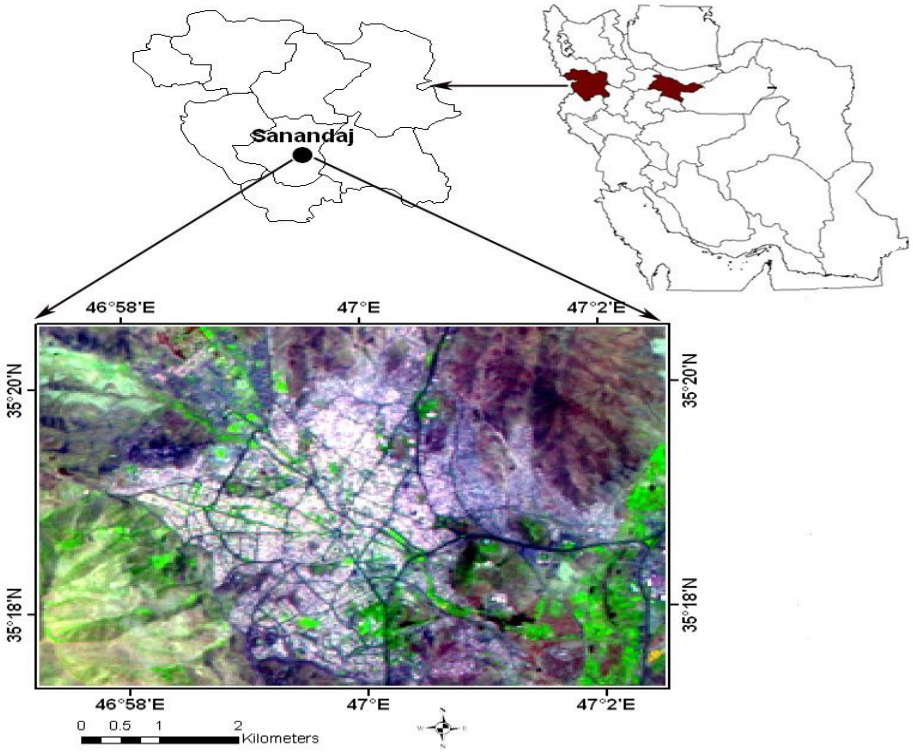
20- Elkamel et al
21- Chaloulakou et al
22- Cai et al

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

معنی‌داری در حال کاهش و گردوغبار که روند افزایشی داشت همه آلاینده‌ها الگوی فصلی داشتند. از آنجایی که سنندج به‌عنوان یکی از شهرهای آلوده‌ی کشور به حساب می‌آید، پیش‌بینی انواع آلودگی‌های آن به‌ویژه پیش‌بینی ذرات معلق $PM_{2.5}$ که عامل بسیاری از بیماری‌ها می‌باشد، می‌تواند در اعلام به موقع و قبل از افزایش میزان $PM_{2.5}$ کمک شایانی به سلامت جامعه کند. از این رو برای افزایش دقت پیش‌بینی مدل‌های خطی شامل MLR، ARIMA و مدل غیر خطی شبکه عصبی رگرسیون عمومی (GRNN) استفاده شدند و در نهایت دقیق‌ترین مدل از میان این مدل‌ها برای پیش‌بینی ذرات معلق $PM_{2.5}$ معرفی گردید.

منطقه مورد مطالعه

شهرستان سنندج با مساحت ۲۹۰۶ کیلومتر مربع مرکز استان کردستان با ۳۵ درجه و ۲۰ دقیقه عرض شمالی و ٤٧ درجه طولی شرقی از نصف‌النهار گرینویچ و در ارتفاع ۱۵۳۸ متری از سطح دریا قرار دارد (شکل ۱).



شکل ۱: موقعیت جغرافیایی شهر سنندج در کشور

مواد و روش‌ها

در این مطالعه از داده‌های مربوط به کیفیت هوای شهر سنندج شامل $PM_{2.5}$، PM_{10}، SO_2، NO_2، CO و O_3 و داده‌های مربوط به هواشناسی شامل میانگین حداقل دما (MinT)، میانگین حداکثر دما (MaxT)، میانگین فشار جوی

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

(AP)، بارش کل روزانه (PR) و سرعت باد روزانه (WS) مربوط به سال ۱۳۹۳ برای پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ شهر سنندج استفاده شد (جدول ۱).

جدول ۱- میانگین و انحراف معیار پارامترهای مورد استفاده شده

	میانگین	انحراف معیار
SO_2	۲۱/۸۷	۷/۷۸
NO_2	۱۷/٤	٦/٤٨
PM_{10}	٦٨/٥٥	۳۰/۰۹
$PM_{2.5}$	۳۱/۰۲	۱٥/۳۱
CO	۱/۲٤	۱/۳۷
O_3	۱۲/۲٦	۸/۳۷
MinT	۹/۲٦	۷/۲۰
MaxT	۲۷/۲٥	۱۰/۱۱
AP	۱۰۱۰/۰۸	۹/۰۷
PR	۰/۷	۲/۸۲
WS	٥/۹۲	۲/۳٦

(جدول ۱) میانگین و انحراف معیار پارامترهای استفاده شده در شهر سنندج در سال ۱۳۹۳ را نشان می‌دهد. PM_{10} و $PM_{2.5}$ دارای میانگین غلظت بالایی نسبت به دیگر آلاینده‌ها می‌باشند. در این سال میانگین بارش باران خیلی کم و در حدود ۰/۷ میلی‌متر برای هر روز است.

پیش‌بینی ذرات معلق $PM_{2.5}$ شهر سنندج

مدل رگرسیون خطی چندگانه(MLR)[۲۳]

در مدل MLR مقادیر یک متغیر وابسته از روی مقادیر دو یا چند متغیر مستقل دیگر برآورد می‌شود. مدل‌های MLR در زمینه کیفیت هوا توسط محققین زیادی مورد استفاده قرار گرفته شده است (بارسناس و همکاران[۲٤]، ۲۰۰٥: ۱٥۱؛ باسورکو و همکاران[۲٥]، ۲۰۰٦: ٤۳۲). در این پژوهش آنالیز خطی دادها با استفاده از نرم‌افزار SPSS ورژن ۲۰ انجام شد. در مدل خطی، متغیر وابسته، میزان غلظت ذرات معلق $PM_{2.5}$ و متغیرهای مستقل، $PM_{2.5}$ روز قبل، PM_{10}، SO_2، NO_2، CO، O_3، MinT، MaxT، AP، PR و WS در نظر گرفته شد (ژو و همکاران، ۲۰۱٤: ۲٦٦).

23- Multiple linear regression
24- Barcenas et al
25- Basurko et al

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

فرمول کلی مدل MLR به شکل زیر است (تیریاکی و همکاران[۲۶]، ۲۰۱٤: ۳۱):

$$Y = \beta_0 + \beta_1 X_1 + \cdots + \beta_n X_n + \varepsilon$$

که در آن Y متغیر وابسته، X_1 ... متغیرهای مستقل، β_0، ...β_n ثابت‌های معلوم و ε مقدار باقی‌مانده می‌باشد. در مدل MLR از روش گام‌به‌گام[۲۷] استفاده شده است که براساس آن متغیرهای مستقل تک تک وارد معادله می‌شوند و اگر نقش معنی‌داری در رگرسیون نداشته باشند از آن خارج می‌شوند.

مدل خود رگرسیون میانگین متحرک انباشته (ARIMA)[۲۸]

یک سری زمانی مجموعه مشاهداتی است که بر حسب زمان مرتب شده‌اند. پیش‌بینی سری‌های زمانی یکی از مهم‌ترین زمینه‌های پیش‌بینی است که در آن مشاهدات گذشته یک متغیر جمع‌آوری و به منظور به‌دست آوردن روابط اساسی بین مشاهدات و تعیین یک مدل توصیفی، مورد تجزیه‌وتحلیل قرار می‌گیرد (خاشعی و بیجاری، ۱۳۸۷: ۸٤). یکی از مهم‌ترین و پرکاربردترین مدل‌های سری‌های زمانی، مدل ARIMA می‌باشد. این مدل به الگوی باکس–جنکینز نیز معروف است و در نرم‌افزار MINITAB قابل بررسی است. مدل‌های پیش‌بینی باکس-جنکینز با سری‌های زمانی ایستا سروکار دارند. سری‌های زمانی به دو دسته کلی ایستا و غیرایستا تقسیم‌بندی می‌شوند. در سری‌های ایستا میانگین و پراکندگی در طول زمان ثابت می‌باشد، در غیر این صورت سری را غیرایستا می‌نامند. ناایستایی در واریانس را با استفاده از تبدیل توانی باکس و کاکس[۲۹]و ناایستایی در میانگین را با استفاده از تفاضلی کردن می‌توان برطرف کرد (احمدی و همکاران، ۱۳۸٦: ۲۲). فرمول کلی آریما به شرح زیر است:

$$y_t = \sum_{i=1}^{p} f_i\, y_{t-1} + \sum_{i=1}^{q} \theta_i e_{t-j} + \varepsilon_t$$

در این رابطه y_t مقادیر مشاهده شده در زمان t، f_i پارامتر اتورگرسیو، θ_i پارامتر میانگین متحرک و ε_t خطا در زمان t است (کهنسال و پرمه، ۱۳۹۱: ۵۱). برای ساختن یک مدل آریما از یک روش سه مرحله‌ای تکراری استفاده می‌شود. به این ترتیب که ابتدا یک مدل آزمایشی از طریق تجزیه وتحلیل داده‌های تاریخی مشخص می‌شود. سپس پارامترهای نامعلوم مدل تخمین زده می‌شود. در نهایت آزمون خطا اجرا می‌شود تا شایستگی مدل را تعیین کند. چنانچه مدل مورد تایید قرار گرفت می‌توان آن را مبنای پیش‌بینی رفتار آینده سری قرار داد (خرمی و بزرگ‌نیا، ۱۳۸٦: ۲۲). مدل آریما دارای سه پارامتر به صورت ARIMA (p ,d ,q) می‌باشد. پارامتر d مربوط به مرتبه

26- Tiryaki et al
27- Stepwise
28- Autoregressive Integrated moving average
29- Box- Cox

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

تفاضل‌گیری برای تبدیل سری ناایستا به ایستا، پارامتر p مربوط به مرتبه جمله خودرگرسیون و q مرتبه جمله میانگین متحرک می‌باشد (زراءنژاد و همکاران، ۱۳۹۲: ۳۸).

مدل‌های شبکه عصبی

روش شبکه عصبی برای اولین بار توسط مک کلاچ و پیتز در سال ۱۹۴۳ معرفی گردید. شبکه عصبی مصنوعی یک روش شبیه‌سازی بوده که از سیستم مغز و شبکه عصبی موجودات زنده الهام گرفته و از متداول‌ترین روش‌های پیش‌بینی در علوم مختلف است (سرمدیان و همکاران، ۱۳۸۹: ۲۱٤). شبکه عصبی متشکل از سه لایه است، لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان مسئول پردازش داده‌ها و لایه خروجی که نتایج را به ازای ورودی‌های مشخص استخراج می‌کند. انواع مختلفی از شبکه‌های عصبی مصنوعی وجود دارند که به منظور پیش‌بینی مورد استفاده قرار می‌گیرند که از آن جمله می‌توان به شبکه‌های عصبی چند لایه پیشخور (FFNN)، شبکه‌های عصبی شعاعی محور (RBF)، شبکه‌های عصبی احتمالی (PNN) و شبکه‌های عصبی رگرسیون عمومی (GRNN) اشاره کرد (خاشعی و همکاران، ۱۳۹۲: ٤). برای پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ شهر سنندج، از مدل GRNN استفاده گردید. مدل GRNN در این مطالعه برای اولین بار است که برای پیش‌بینی آلودگی اتمسفر در ایران استفاده می‌شود.

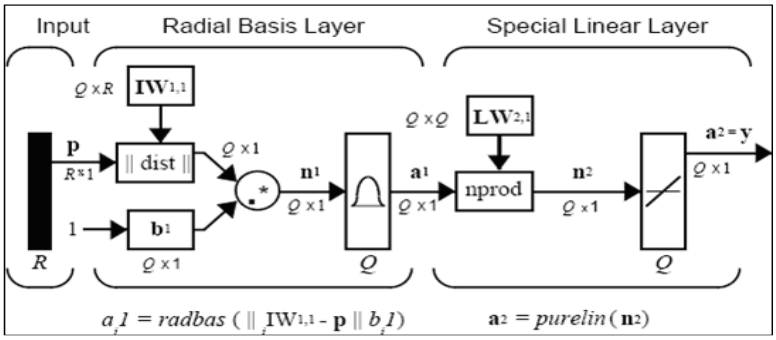
مدل شبکه عصبی رگرسیون عمومی (GRNN)[۳۰]

به منظور تخمین روابط رگرسیونی سری‌های زمانی، نوع خاصی از شبکه‌های عصبی به نام GRNN مطرح شدند که قادرند با دقت بالایی پارامترهای روابط رگرسیونی حاکم بر سری‌های زمانی را تخمین زنند. GRNN توسط اسپچت[۳۱]برای شناسایی و مدل‌سازی ارائه شد (اسپچت، ۱۹۹۱: ٥٦۹). شبکه‌های عصبی رگرسیون عمومی می‌توانند هر تابع را با در اختیار داشتن داده‌های گذشته ورودی و خروجی تقریب بزنند (له آنگ و همکاران[۳۲]، ۲۰۰۰: ۱۷٦). از ویژگی‌های بارز آن زمان آموزش سریع و مدل‌سازی توابع غیرخطی است. این شبکه دارای فاکتور هموارساز[۳۳] است که مقدار بهینه آن در طی چندین اجرا با توجه به میانگین مربعات خطا به‌دست می‌آید (مرادزاده و همکاران، ۱۳۹۰: ۵۷) (شکل ۲).

توپولوژی GRNN به شرح زیر است:

30- General Regression Neural Network
31- Specht
32- L- eung et al
33- Smooth Factor

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]



شکل۲: ساختار GRNN (دمیوت و بیل[۳۴]، ۲۰۰۲)

مدل GRNN دارای چهار لایه است:

لایه ورودی: این لایه وظیفه ورود اطلاعات به شبکه را بر عهده دارد. تعداد نرون‌های ورودی در یک GRNN برابر با تعداد متغیرهای موجود در بردار ورودی است.

لایه الگو: نرون‌های موجود در این لایه نرون‌های الگو نام دارند. این نرون‌ها با ترکیب و پردازش داده‌های ورودی آن‌ها را تنظیم می‌کنند. تعداد نرون‌های الگو در این لایه برابر با تعداد دسته‌های آموزشی خواهد بود. خروجی نرون الگوی iام از تابع زیر محاسبه می‌شود:

$$P_i = \exp\left(\frac{(X-Xi)^T(X-Xi)}{2\sigma^2}\right)$$

در این رابطه σ پارامتر هموارسازی، X متغیر ورودی و Xi نمونه آموزشی برای نرون iام در لایه الگو است.

لایه جمع: خروجی نرون‌های الگو به لایه سوم یعنی نرون‌های جمع‌کننده وارد می‌شوند. دو نوع جمع Ss و Sw دراین لایه محاسبه می‌شود:

$$S_S = \sum_{i=1}^{n} P_i$$

$$S_W = \sum_{i=1}^{n} W_I P_i$$

در این رابطه wi وزن نورون iام در لایه الگو است که به لایه جمع وصل شده است.

لایه خروجی: حاصل‌جمع‌های محاسبه شده در لایه جمع، به لایه خروجی فرستاده می‌شوند و نرون‌های این لایه خروجی را مطابق رابطه زیر محاسبه می‌نمایند:

$$y = {}^{S_W}/_{S_S}$$

34- Demuth and Beale

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

ارزیابی مدل‌ها

یکی از معیارهای مورد بررسی اعتبار نتایج به‌دست آمده از مدل‌ها، آماره R^2 می‌باشد. آماره R^2 به‌عنوان یک شاخص برای بیان دقت خط رگرسیون به‌کار رفته و مقدار آن بین صفر و یک تغییر می‌کند و مقادیر نزدیک به یک تطابق بهتر داده‌های مشاهده‌ای و برآورده شده را نشان می‌دهد. ولی با توجه به این مسئله که مقدار R^2 تحت تأثیر داده‌های پرت است باید علاوه بر آن از پارامترهای دیگر استفاده کرد (لگاتس و مک کیب[۳۵]، ۱۹۹۹: ۲۳۵). به همین دلیل از دیگر پارامترها نظیر ریشه متوسط مربعات خطا (RMSE[۳۶]) و میانگین مطلق خطا (MAE[۳۷]) نیز برای بررسی اعتبار نتایج استفاده می‌شود (نوری و همکاران، ۱۳۸۷: ۱٤۰) (جدول ۲). ریشه متوسط مربعات خطا و میانگین مطلق خطا طبق زیر محاسبه می‌شود:

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(Y_{da} - Y_{dp})^2}$$

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n}\left|Y_{da} - Y_{dp}\right|$$

در این رابطه‌ها Y_{da} مقدار واقعی، Y_{dp} مقدار پیش‌بینی شده و n تعداد داده‌های موجود است.

نتایج پیش‌بینی ذرات معلق $PM_{2.5}$ شهر سنندج

نتایج مرحله آموزش مدل MLR در پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ برای شهر سنندج

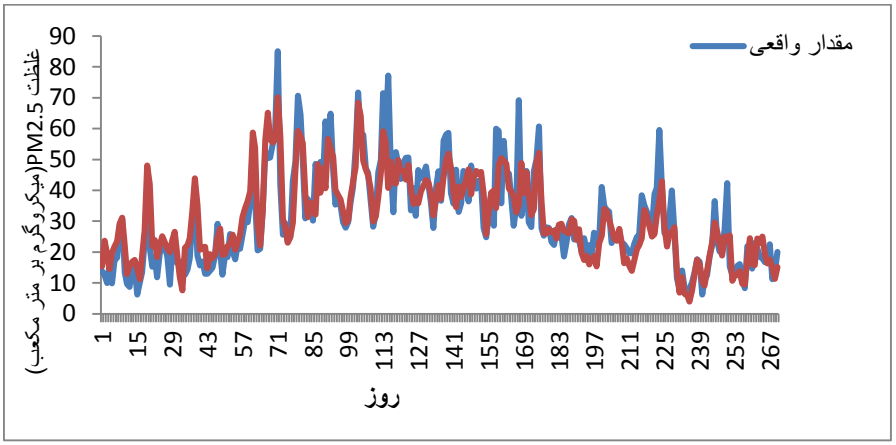
نتایج آموزش کاربرد مدل MLR در پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ در شهر سنندج در (شکل ۳) نشان داده شده است و معادله به‌دست آمده به شکل زیر است:

$$PM_{2،5F} = 3.403 - 0.353SO_2 + 0.25PM_{10} + 0.452PM_{2.5P} + 0.122O_3 + 0.244MAX - 0.67WS$$

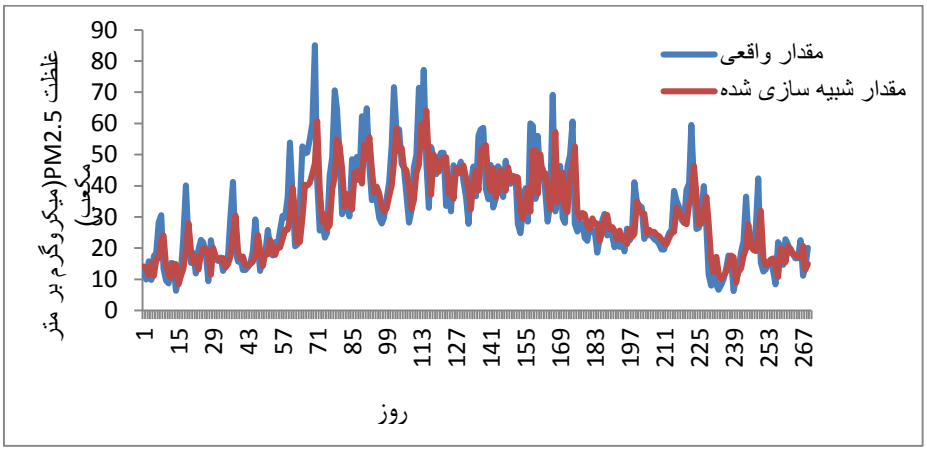
در این بخش مقدار R^2=۰/۷٦ , RMSE=۷/۳۵۳۹ و MAE=۲۵۵۵/۵ بود.

35- Legatesand McCabe
36- Root mean square error
37- Mean absolute error

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]



شکل ۳: نتایج مدل MLR در مرحله آموزش مدل



شکل ٤: نتایج مدل ARIMA درمرحله آموزش

- نتایج مرحله آموزش مدل ARIMA انباشته در پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ برای شهر سنندج مدل استفاده شده برای تجزیه سری زمانی $PM_{2.5}$ مدل ARIMA (1, 1, 1) می‌باشد. معادله به‌دست آمده در این قسمت به صورت زیر است:

$$y_t = 0.572y_{t-1} - 0.9148e_{t-j} + \epsilon_t$$

نتایج آموزش مدل ARIMA در پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ در شهر سنندج در (شکل ٤) نشان داده شده است.

در این قسمت مقدار R^2= ۰/٦۳ , RMSE=۹/٤۱۳۷ و MAE=٦/۷٦۷ بود.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

جدول ۲- مقادیر ضرایب همبستگی و جذر میانگین مربعات خطا با فاکتورهای هموارساز متفاوت

فاکتور هموارساز	آموزش R	آزمون R	آموزش RMSE	آزمون RMSE
۰/۰۵	۰/۹۹۹۹	۰/٦٨۰۳٥	۰/۲۲۰۹	۷/۳۷۱۷
۰/۰۹	۰/۹۹٥۱۲	۰/۷۲۰۹	۱/٥۲٥۲	٦/۷٥٥۸
۰/۱۲	۰/۹۸۲٥	۰/۷۷۹۳	۲/۸٦۸	٥/۹۱٤
۰/۱٦	۰/۹٦٤٤	۰/۸۱۹۹	٤/۰۸۳٦	٥/۳٦۰۹
۰/۲	۰/۹٤۷٦	۰/۸۳۸٤	٤/۹٥۸	٥/۱۲۸۸
۰/۲٤	۰/۹۳۲۲	۰/۸٤۹۲	٥/٦٤۳٤	٥/۰۲۳٤
۰/۲۸	۰/۹۱۸۹	۰/۸٥۳٤	٦/۱۸۷۸	٥/۰٤۳۲
۰/۳	۰/۹۱۳۱	۰/۸٥٤۲	٦/٤۲۲۲	٥/۰٤۳۲
۰/۳٥	۰/۹۰۰۱	۰/۸٥۹	۰/۹٤٦٥	٥/۰۷۲٥

- نتایج مرحله آموزش مدل GRNN در پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ برای شهر سنندج

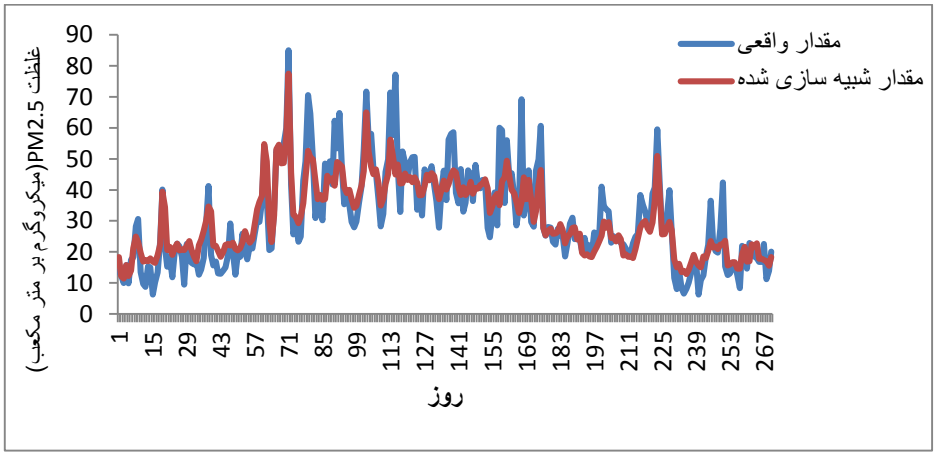
ورودی‌های این مدل، خروجی مدل MLR می‌باشد. یعنی از متغیرهای مستقلی برای آموزش استفاده می‌کند که بر روی غلظت متغیر وابسته ($PM_{2.5}$) تأثیر داشته باشد. آموزش شبکه برای برآورد خروجی با فاکتورهای متفاوت هموارساز صورت گرفت. مقدار فاکتور هموارساز بین ۰ و ۱ می‌باشد (قیاس و اسمیت[۳۸]، ۲۰۰۹). با افزایش فاکتور هموارساز مقدار ضریب همبستگی در داده‌های آموزش به آرامی کاهش ولی برای داده‌های آزمون به آرامی افزایش می‌یابد (مرادزاده و همکاران، ۱۳۹۰: ۵۸). طبق (جدول ۲) مقدار فاکتور هموارساز بهینه با توجه به مقدار ضریب همبستگی و میزان خطای مناسب در مرحله آموزش و مرحله آزمون، مقدار ۰/۳۵ انتخاب گردید.

نتایج آموزش مدل GRNN در پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ در شهر سنندج در (شکل ۵) نشان داده شده است.

در این بخش در قسمت آموزش مقدار R^2=۰/۸۱ , RMSE=٦/۹٤٦۸ و MAE=٥/۷۲٥ بود.

38- Gheyas and Smith

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

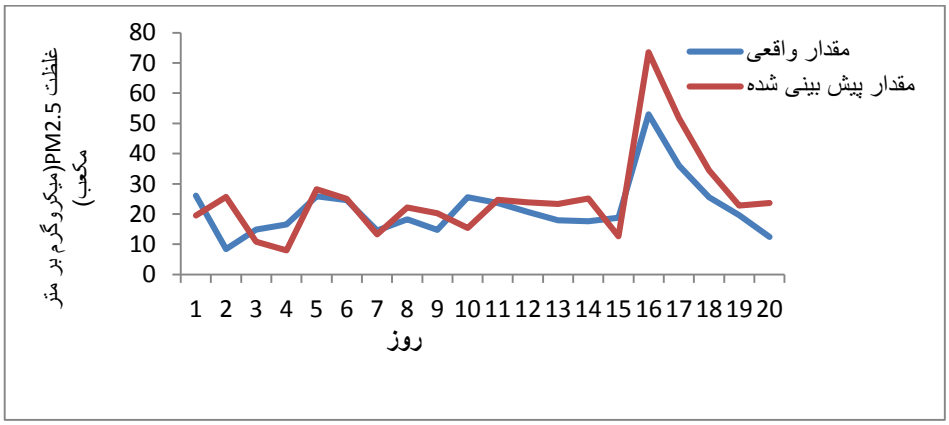


شکل ۵: نتایج مدل GRNN در مرحله آموزش

میزان RMSE در مدل ARIMA با ۹/٤۱۳۷ بیش‌ترین و در GRNN با مقدار ٦/۹٤٦۸ کم‌ترین مقدار، MAE در ARIMA با ٦/۷٦۷ بیش‌ترین و در GRNN با مقدار ۵/۰۷۲۵ کم‌ترین را دارد. R^2 در مدل ARIMA کم‌ترین و در GRNN بیش‌ترین مقدار (۰/٦۳ و ۰/۸۱ به‌ترتیب) را داراست.

- نتایج مرحله آزمون مدل MLR در پیش‌بینی ذرات معلق $PM_{2.5}$ برای شهر سنندج

(شکل ٦) نتایج حاصل از مرحله آزمون مدل MLR را نشان می‌دهد. در این مرحله مقدار R^2= ۰/۷۰ , RMSE= ۸/۹٦۰۹ و MAE= ۷/۱۳۸۵ می‌باشد.

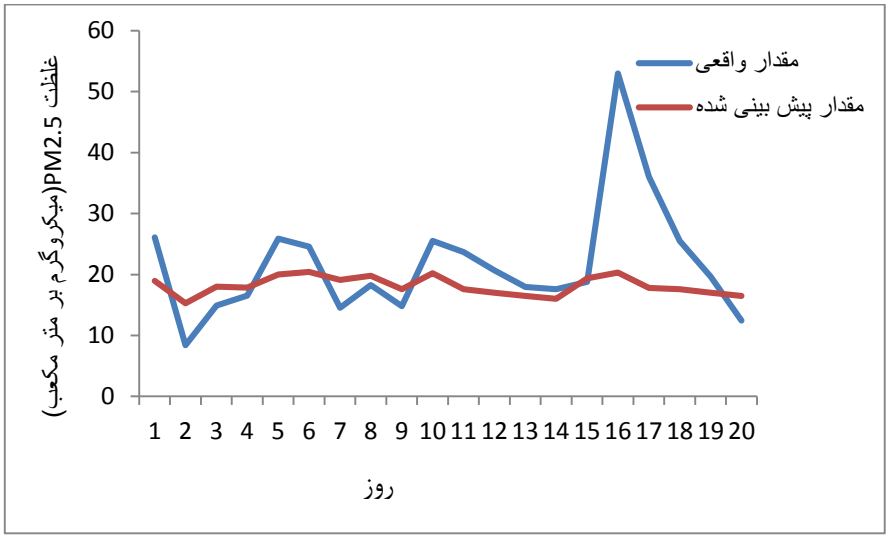


شکل ٦: نتایج مدل MLR در مرحله آزمون

- نتایج مرحله آزمون مدل ARIMA در پیش‌بینی ذرات معلق $PM_{2.5}$ برای شهر سنندج

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

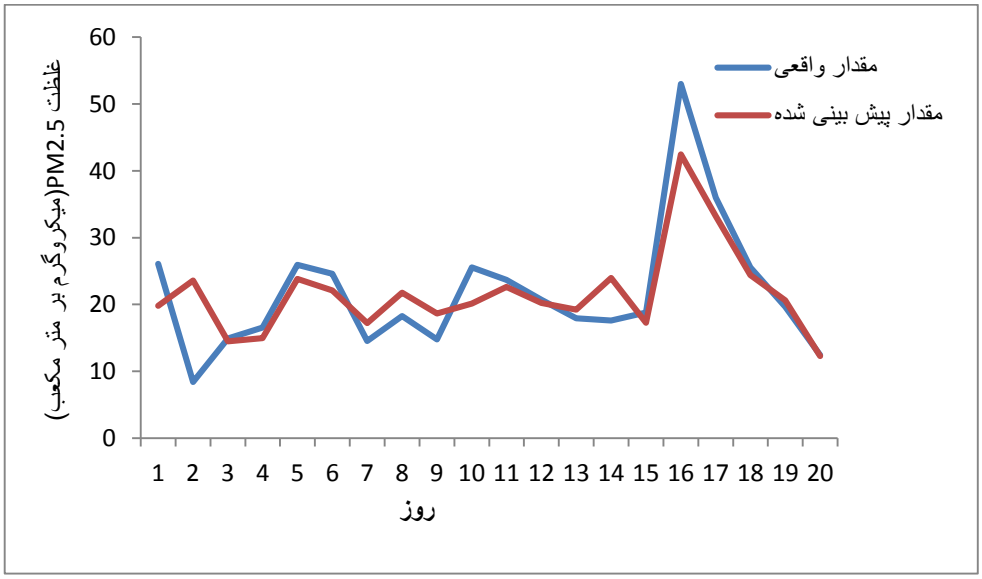
(شکل ۷) نتایج حاصل از مرحله آزمون مدل ARIMA را نشان می‌دهد. در این مرحله مقدار R^2=۰/۳۰ و RMSE=۱۱/۳۹۲۵ و MAE=۹/۰۸۶۳ می‌باشد.



شکل۷: نتایج مدل ARIMA در مرحله آزمون مدل

- نتایج مرحله آزمون مدل GRNN در پیش‌بینی ذرات معلق $PM_{2.5}$ برای شهر

(شکل ۸) نتایج حاصل از مرحله آزمون مدل GRNN را نشان می‌دهد. در این مرحله مقدار R^2= ۰/۷٤ و ۵/۰۷۲۵ =RMSE و ۳/٤۸۷٤ =MAE می‌باشد.



شکل۸: نتایج GRNN در مرحله آزمون مدل

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

مدل ARIMA بیش‌ترین مقدار خطا (RMSE=۱۱/۳۹۲۵، MAE=۹/۰۸۶۳) و GRNN کم‌ترین مقدار خطا (RMSE=۵/۰۷۲۵، MAE=۳/٤۸۷٤) را دارد. مقدار R^2 در ARIMA کم‌ترین مقدار (۰/۳۰) و در GRNN بیش‌ترین مقدار (۰/۷٤) می‌باشد.

یافته‌ها و بحث

مدل رگرسیون چندگانه خطی (MLR)

مدل اول استفاده شده، رگرسیون چندگانه خطی (MLR) است که کاربرد زیادی در پیش‌بینی داشته و در مطالعات زیادی از آن استفاده شده است (فرناندز و همکاران[39]، ۲۰۱۲: ۳۵۲۸). در MLR از روش گام به گام استفاده گردید. بنابراین از متغیرهایی که دارای اثر معنی‌داری بر متغیر وابسته بود استفاده شد. از میان متغیرهای مستقل وارد شده در مدل، متغیرهای SO_2، PM_{10}، $PM_{2.5}$ روز قبل، O_3، MAXT و WS در مدل باقی‌مانده و در نتیجه میزان غلظت این متغیرها بر میزان غلظت $PM_{2.5}$ شهر سنندج مؤثر بوده است. طبق معادله به‌دست آمده در MLR پارامترهای PM_{10}، $PM_{2.5}$ روز قبل، O_3 و MAXT با ذرات معلق $PM_{2.5}$ شهر سنندج رابطه مثبت و پارامترهای SO_2 و WS با ذرات معلق $PM_{2.5}$ شهر سنندج رابطه منفی دارند. این مدل در مقایسه با مدل غیرخطی شبکه عصبی کارایی کم‌تری دارد به طوری که میزان ضریب تعیین (R^2) آن در مرحله آموزش ۰/۷٦ و میزان RMSE و MAE (۷/۳۵۳۹، ۵/۲۵۵۵) به‌ترتیب کم‌تر و بیش‌تر از مدل غیرخطی می‌باشند. این نتیجه با نتایج تیریاکیو همکاران (۲۰۱٤) و ولی و همکاران در سال ۱۳۹۰ همخوانی دارد. ولی و همکاران به مقایسه کارایی مدل‌های غیر خطی نظیر شبکه عصبی و MLR برای پیش‌بینی پرداختند. نتایج نشان داد که مدل غیرخطی با ضریب تعیین ۰/۸٦ و مجذور میانگین مربعات خطای ۱/۸۱۵ بهتر از مدل خطی چندگانه با ضریب تعیین ۰/۸۱ با معیار خطای معادل ۲/۱٤۲ است. استفاده از مدل MLR فرض‌های زیادی دارد که استفاده از آن در مسائل علمی مشکل است به طوری که در بسیاری از تحقیقات صورت گرفته، به دلیل این که، این فرض‌ها مباحث آماری پیچیده‌ای‌اند، از دید محققان مخفی مانده و به آن توجهی نشده است. در نتیجه مدل ارائه شده‌ی آن‌ها دارای دقت لازم نیست (نوری و همکاران، ۱۳۸۷: ۱۵۰).

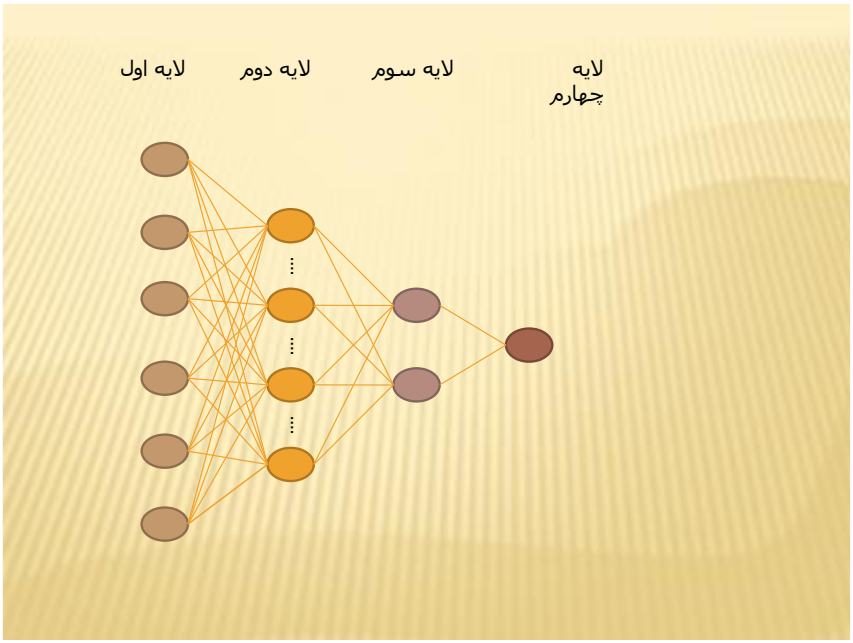
- خود رگرسیون میانگین متحرک انباشته (ARIMA)

نتایج مدل ARIMA در پیش‌بینی ذرات معلق $PM_{2.5}$ در مقایسه با نتایج مدل‌های دیگر به‌کار برده شده ضعیف‌تر است و در رتبه آخر قرار دارد که به نظر می‌رسد پایین بودن میزان همبستگی به دلیل عدم رعایت ترتیب مشاهدات

39- Fernandez et al

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

می‌باشد. ARIMA با استفاده از داده‌های قبلی مقادیر آینده را پیش‌بینی می‌کند در حالی که در دیگر روش‌های مدل‌سازی اغلب با استفاده از متغیرهای مستقل دیگر به پیش‌بینی متغیر مورد نظر پرداخته می‌شود. معمولا قدرت این مدل‌ها در پیش‌بینی کم‌تر است، اما به دلیل این‌که به اطلاعات جانبی کم‌تری نیاز دارد تمایل استفاده از آن زیاد است. طبیعت ذاتی یک سری زمانی، وابسته یا هم‌بسته بودن مشاهدات آن است و بنابراین ترتیب مشاهدات دارای اهمیت است. اگر داده‌ها مستقل و تصادفی باشند برای پیش‌بینی مناسب نخواهند بود و مقادیر گذشته تأثیری روی مقادیر حال و آینده نخواهد داشت. در سری زمانی غلظت$PM_{2.5}$ مورد مطالعه، فقدان داده وجود داشت و به همین دلیل ترتیب مشاهدات رعایت نشده و ARIMA نتوانسته در پیش‌بینی عملکرد خوبی داشته باشد. این نتایج با نتایج سینگ و میشرا[40] همخوانی دارد. سینگ و میشرا در سال ۲۰۱۵ از مدل‌های شبکه عصبی و ARIMA برای پیش‌بینی سری‌های زمانی مالی استفاده کردند، مدل ARIMA به دلیل بی‌نظمی داده‌ها نتایج ضعیف‌تری در پیش‌بینی سری‌های زمانی مالی نسبت به شبکه عصبی داشته است.



شکل ۹: ساختار GRNN استفاده شده

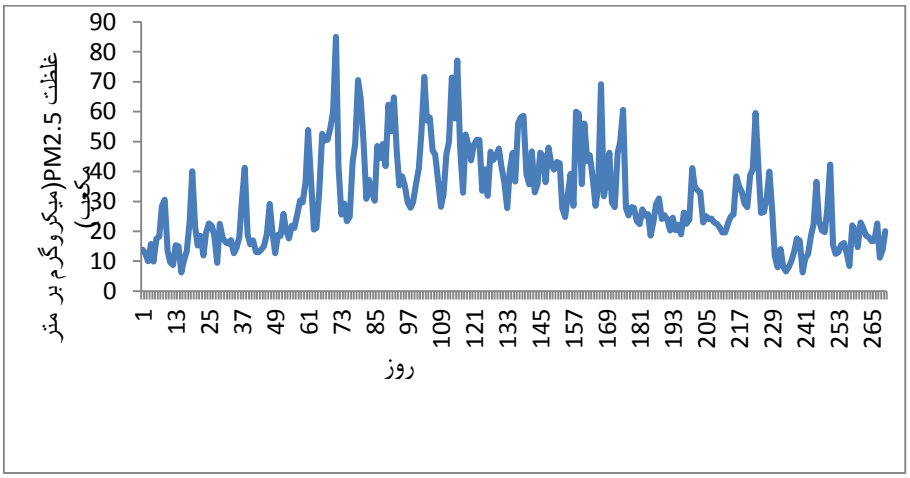
- شبکه عصبی رگرسیون عمومی (GRNN)

مدل GRNN مورد استفاده شده برای برآورد میزان ذرات معلق $PM_{2.5}$ شهر سنندج در مقایسه با دیگر مدل‌ها در رتبه اول قرار دارد. این شبکه دارای یک لایه ورودی با شش نرون، یک لایه پنهان با ۲۷۰ نرون و تابع محرک شعاعی و یک لایه خروجی با یک نرون و تابع محرک خطی در آن است (شکل ۹). مزیت GRNN آموزش سریع و عملکرد

40- Singh and Mishra

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

مناسب برای تعداد داده‌های کم است. با تغییر مقدار فاکتور هموارساز در GRNN مقدار خروجی تغییر کرده که می‌توان با آزمون و خطا بهترین مدل با مناسب‌ترین بازدهی را به‌دست آورد. مقدار فاکتور هموارساز با توجه به مقدار ضریب همبستگی و میزان خطای مناسب در هر دو مرحله آموزش و آزمون ۰/۳۵ انتخاب گردید. این شبکه در مقایسه با مدل‌های خطی عملکرد بهتری داشته و این چنین برمی‌آید که مدل GRNN در پیش‌بینی ذرات معلق $PM_{2.5}$ شهر سنندج مناسب می‌باشد.



شکل ۱۰: غلظت سری زمانی $PM_{2.5}$

شبکه‌های عصبی برخلاف روش‌های خطی، دارای پیش فرض‌های بسیار کمی است و به عبارتی دیگر به‌صورت مدل آزاد هستند. این شبکه‌ها از مثال‌ها درس می‌آموزند و روابط تبعی میان داده‌ها را در صورت ناشناخته بودن روابط یا دشوار بودن توصیف آن‌ها کشف می‌کنند. از این رو در صورتی که داده‌های کافی وجود نداشته باشد این شبکه ابزار بسیار مفیدی است. شبکه‌های عصبی قابلیت تعمیم بسیار بالایی دارند و اگر داده‌ها دارای نویز باشند نسبت به دیگر مدل‌ها بهتر عمل می‌کنند (روبلس و همکاران[41]، ۲۰۰۸: ۸۳۳۲) و طبق نظر اسچاپ و همکاران[42] در سال ۱۹۹۸ در طراحی شبکه‌های عصبی نوعی خاص از معادلات لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد. برتری دیگر شبکه‌عصبی در مقایسه با مدل‌های خطی حساس نبودن آن به وجود تعداد محدودی خطا در داده‌های آماری است. تنها محدودیت این شبکه‌ها در غیر قابل تفسیر بودن نتایج حاصل از مدل‌سازی از نظر میزان تأثیر هر متغیر ورودی بر خروجی مورد نظر است (نورانی و سیاح فرد، ۱۳۹۲: ۹۷). برتری شبکه عصبی نسبت به MLR و ARIMA توسط محققان زیادی ثابت شده است.

41- Robles et al
42- Schaap et al

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

تقوی و همکاران (۱۳۹۱) به مقایسه کارایی شبکه عصبی و MLR در پیش‌بینی غلظت روزانه منواکسیدکربن پرداختند. نتایج حاصل از اجرای این دو مدل نشان داد که مدل شبکه عصبی مصنوعی توانایی بیش‌تری نسبت به روش MLR در پیش‌بینی غلظت روزانه منواکسیدکربن دارد. به‌طوری که ضریب همبستگی و میانگین مجموع مربعات خطا در شبکه عصبی به‌ترتیب برابر با ۰/۸۱ و ۰/۰۶۹ و برای مدل رگرسیونی به‌ترتیب ۰/۶۱ و ۰/۱ به‌دست آمد. به نظر می‌رسد با توجه به سری زمانی غلظت $PM_{2.5}$ (شکل ۱۰) که دارای نوسانات زیادی است، مدل‌های خطی توانایی ارائه مدلی که بتواند این نوسانات را در نظر بگیرد ندارد و در این موارد استفاده از شبکه عصبی که قادر به پیش‌بینی روابط غیرخطی بین ورودی‌ها و خروجی‌ها باشد راه حل مناسبی برای جایگزین مدل‌های خطی می‌باشد.

نتیجه‌گیری

از آنجایی که سنندج به‌عنوان یکی از شهرهای آلوده‌ی کشور به‌حساب می‌آید، پیش‌بینی انواع آلودگی‌های آن به‌ویژه پیش‌بینی ذرات معلق $PM_{2.5}$ که عامل بسیاری از بیماری‌ها می‌باشد، می‌تواند در اعلام به موقع و قبل از افزایش میزان $PM_{2.5}$ کمک شایانی به سلامت جامعه کند. در ابتدا به بررسی رابطه بین تغییرات غلظت PM_{10}, SO_2, NO_2, CO, O_3، MinT، MaxT، AP، PR، RH، WS و $PM_{2.5}$ روز قبل موجود در هوای شهر سنندج بر روی میزان غلظت $PM_{2.5}$ در شهر سنندج پرداخته شد. با توجه به روش گام‌به‌گام مورد استفاده تنها متغیرهای SO_2، PM_{10}، $PM_{2.5}$ روز قبل، O_3، MaxT و WS در مدل باقی‌مانده و در نتیجه میزان غلظت این متغیرها بر میزان غلظت $PM_{2.5}$ شهر سنندج مؤثر بوده است. سپس به ارزیابی دقت مدل‌های MLR، ARIMA و GRNN در پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ شهر سنندج پرداخته شد. در MLR مقادیر یک متغیر وابسته از روی مقادیر دو یا چند متغیر مستقل دیگر برآورد می‌شود. در ARIMA مشاهدات گذشته یک متغیر جمع‌آوری و به منظور به‌دست آوردن روابط اساسی بین مشاهدات و تعیین یک مدل توصیفی، مورد تجزیه و تحلیل قرار می‌گیرد. به منظور تخمین روابط رگرسیونی سری‌های زمانی، نوع خاصی از شبکه‌های عصبی به نام GRNN مطرح شدند که قادرند با دقت بالایی پارامترهای روابط رگرسیونی حاکم بر سری‌های زمانی را تخمین زنند. نتایج نشان داد که مدل GRNN با مقدار R^2=۰/۸۱ و ۶/۹۴۶ =RMSE و ۵/۰۷۲۵ =MAE در مرحله آموزش و مقدار R^2= ۰/۷۴ و ۵/۰۷۵ =RMSE و ۳/۴۸۷۴ =MAE در مرحله آزمون بهترین عملکرد را نسبت به مدل‌های خطی در پیش‌بینی ذرات معلق $PM_{2.5}$ در شهر سنندج داشته است.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

منابع

- احمدی، ف؛ قهرمان، ب؛ داوری، ک؛ نیرومند، ح.ع (۱۳۸٦)، «کاربرد مدل سری‌های زمانی در پیش‌بینی بارندگی ماهیانه و سالانه مشهد»، ***مجله علوم و صنایع کشاورزی ویژه خاک، آب‌وهوا***، شماره ۲، صص ۳۳- ۲۱.

- بوداقپور، س؛ چرخستانی، ا (۱۳۹۰)، «پیش‌بینی میزان غلظت آلاینده‌های هوای تهران با استفاده از شبکه عصبی مصنوعی»، ***علوم و تکنولوژی محیط‌زیست***، شماره ۱، صص ۱۰- ۱.

- تقوی، ه؛ دانش، ش؛ مساعدی، ا (۱۳۹۱)، «مقایسه کارایی مدل‌های شبکه عصبی مصنوعی و رگرسیون خطی در پیش‌بینی غلظت روزانه منواکسیدکربن براساس پارامترهای هواشناسی»، همایش ملی جریان و آلودگی هوا، ۲۵-۱٤ آبان ۱۳۸۹، دانشگاه تهران، ایران.

- خاشعی، م؛ بیجاری، م (۱۳۸۷)، «بهبود عملکرد پیش‌بینی‌های مالی با ترکیب مدل‌های خطی و غیرخطی خودرگرسیون میانگین متحرک انباشته و شبکه‌های عصبی مصنوعی»، ***فصلنامه پژوهش‌های اقتصادی***، شماره ۸، صص ۱۰۰- ۸۳.

- خاشعی، م؛ بیجاری، م؛ مخاطب رفیعی، ف (۱۳۹۲)، «پیش‌بینی نرخ ارز با به‌کارگیری مدل‌های ترکیبی پرسپترون‌های چند لایه (MLPs) و طبقه‌بندی کننده‌های عصبی احتمالی (PNNs)»، ***روش‌های عددی در مهندسی***، شماره ۳۲، صص ۱٤-۱.

- خرمی، م؛ بزرگ‌نیا، ا (۱۳۸٦)، «تجزیه و تحلیل سری‌های زمانی با نرم‌افزار MINITAB 14»، تهران، انتشارات سخن گستر.

- زراءنژاد، م؛ خداپناه، م؛ کیانی، پ؛ ابراهیمی، ص (۱۳۹۲)، «ارزیابی و مقایسه عملکرد مدل رگرسیون خودبازگشتی میانگین متحرک انباشته فازی و شبکه عصبی فازی در پیش‌بینی رشد اقتصادی ایران»، ***فصلنامه مطالعات اقتصادی کاربردی ایران***، شماره ۸، صص ۵۱- ۳۳.

- سرمدیان، ف؛ تقی‌زاده، ر؛ مهرجردی، ح؛ عسگری، م؛ اکبرزاده، ع (۱۳۸۹)، «مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چندمتغیره در پیش‌بینی برخی خصوصیات خاک (مطالعه موردی: استان گلستان)»، ***مجله تحقیقات آب و خاک ایران***، شماره ٤۱، صص ۲۲۰-۲۱۱.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

- صالحی، ص؛ قائمی‌اصل، ز (۱۳۹۲)، «بررسی رابطه آموزش زیست‌محیطی و رفتارهای حفاظت از محیط‌زیست (مورد مطالعه: دانش‌آمزان دبیرستان‌های دخترانه شهر بابل)»، ***فصلنامه آموزش محیط‌زیست و توسعه پایدار***، شماره ۳، صص ۷۹-٦۷.

- صدرموسوی، م؛ رحیمی، ا (۱۳۸۸)، «مقایسه نتایج شبکه‌های عصبی پرسپترون چند لایه با رگرسیون چندگانه در پیش‌بینی غلظت ازن در شهر تبریز»، ***پژوهش‌های جغرافیایی طبیعی***، شماره ۷۱، صص ۷۲-٦۵.

- عزیزی‌فر، م؛ ندافی، ک؛ محمدیان، م؛ صفدری، م؛ خزایی، م (۱۳۹۰)، «بررسی شاخص کیفیت هوا و غلظت ذرات معلق با قطر آئرودینامیکی در هوای شهر قم»، ***مجله دانشگاه علوم پزشکی قم***، شماره ۲، صص ٦۳-۵۹.

-قوامی، س (۱۳۹۲)، «پیش‌بینی وقوع پدیده‌های گردوغبار شهر سنندج»، پایان‌نامه کارشناسی ارشد، دانشکده منابع‌طبیعی، دانشگاه کردستان.

-کهنسال، م. ر؛ پرمه، ز (۱۳۹۱)، «پیش‌بینی قیمت تخم‌مرغ با استفاده از ARIMA، شبکه عصبی مصنوعی و هموارسازی هالت-وینترز»، ***فصلنامه پژوهشنامه بازرگانی***، شماره ٦۲، صفحات ۷۲-٤۹.

- مرادزاده، ع؛ دولتی‌اردەجانی، ف؛ روکی، ر؛ رحیمی، م (۱۳۹۰)، «برآورد نفوذپذیری میدان گازی پارس‌جنوبی با استفاده از شبکه عصبی رگرسیون عمومی»، ***مجله فیزیک زمین و فضا***، شماره ۳۷، صص ٦۵-۵۱.

- منصوری، ف؛ خانجانی، ن؛ راننده‌کلانکش، ل؛ پورموسی، ر (۱۳۹۲)، «بررسی و پیش‌بینی وضع آلاینده‌های هوای شهر کرمان با مدل سری‌های زمانی»، ***مجله دانشکده بهداشت و انستیتو تحقیقات بهداشتی***، شماره ۱۱، صص ۸٦-۷۵.

-نورانی، و؛ سیاح‌فرد، م (۱۳۹۲)، «آنالیز حساسیت داه‌های ورودی به شبکه عصبی مصنوعی به منظور برآورد مقدار تبخیر روزانه»، ***مجله آب و فاضلاب***، شماره ۳، صص ۱۰۰-۸۰.

- نوری، ر. ا؛ اشرفی، خ؛ اژدرپور، ا (۱۳۸۷)، «مقایسه کاربرد روش‌های شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره براساس تحلیل مولفه‌های اصلی برای پیش‌بینی غلظت میانگین کربن‌منواکسید: بررسی موردی: شهر تهران»، ***مجله فیزیک زمین و فضا***، شماره ۳٤، صص ۱۵۲-۱۳۵.

-ولی، ع. ع؛ رامشت، م. ح؛ سیف، ع؛ قضاوی، ر (۱۳۹۰)، «مقایسه کارایی مدل‌های شبکه عصبی مصنوعی و رگرسیون برای پیش‌بینی بار رسوب جریان مطالعه موردی حوضه آبخیز سمندگان»، ***مجله جغرافیا و برنامه‌ریزی محیطی***، شماره ٤٤، صفحات ۳٤- ۱۹.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

- Adamson, I., Prieditis, H., Vincent, R., (1999),"Pulmonary toxicity of an atmospheric particulate sample is due to the soluble fraction",***Toxicology and Applied Pharmacology***, 157: 43–50.

-Baldasano, V. E., Jiménez, P., (2003), "Air quality data from large cities", ***Sci Total Environ***, 307: 141-65.

- Barcenas, O., Olivas, E., Guerrero, J. D., Valls, G., Rodriguez, C., Tascon, S., (2005),"Unbiased sensitivity analysis and pruning techniques in neural networks for surface ozone modeling", ***Ecol Model***, 182: 149–58.

- Basurko, E., Berastegi, G., Madariaga, I., (2006),"Regression and multilayer perceptron-based models to forecast hourly O_3 and NO_2 levels in the Bilbao area", ***Environ Model Softw***, 21: 430–46.

- Cai, M., Yin, Y., Xie, M., (2009),"Prediction of hourly air pollutant concentrations near urban arterials using artificial neural network approach",***Transportation Research Part D***, 14: 32-4.

- Cobourn, W. G., (2010),"An enhanced $PM_{2.5}$ air quality forecast model based on nonlinear regression and back-trajectory concentrations", ***Atmos Environ***, 44: 3015–3023.

- Chaloulakou, A., Grivas, G., Spyrellis, N., (2003),"Neural network and multiple regression model for PM_{10} prediction in Athens: A comparative assessment", ***Journal of the Air & Waste Management Association***, 53 (10): 1183-1190.

- Demuth, H., Beale, M., (2002),"Neural network toolbox for use with matlab", users guide version 4. [online]: https://www.mathworks.com/help/pdf_doc/nnet/ nnet_ug.pdf

- Elkamel, A., Abdul-Wahab, S., Bouhamra, W., Alper, E., (2001),"Measurement and prediction of ozone levels around a heavily industrialized area: A neural network approach", ***Advances in Environmental Research***, 5: 47–59.

- Fernandez, F. G., Palacios, P., Esteban, L. G., Garcia-Iruela, A., Rodrigo, B. G., Menasalvas, E., (2012),"Prediction of MOR and MOE of structural plywood board using an artificial neural network and comparison with a multivariate regression model", ***Composites Part B***, 43: 3528– 3533.

- Gheyas, I. A., Smith, L. S., (2009),"A neural network approach to time deries forecasting", proceeding of the world congress on engineering, July 1-3, London, U.K. pp 1-5.

- Gupta, P., Sundar, C. A., (2008),"An evaluation of Terra-MODIS sampling for monthly and annual particulate matter air quality assessment over the Southeastern United States", ***Atmospheric Environment***, 42: 6465-6471.

- Hassan. J., (2014),"ARIMA and regression models for prediction of daily and monthly clearness index", ***Renewable Energy***, 68: 421- 427.

- Kaufman, Y. J., Tanre, D., Boucher, O., (2002),"A satellite view of aerosols in climate systems", ***Nature***, 419: 215–223.

- Kuzmanovski, I., Aleksovska, S., (2003),"Optimization of artificial neural networks for prediction of the unit cell parameters in orthorhombic perovskites; Comparison with multiple linear regression", ***Chemometrics and Intelligent Laboratory Systems***, 67: 167– 174.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

- Legates, D. R., McCabe, G. J., (1999),"Evaluating the use of "Goodness-of-fit" Measures in hydrologic and hydroclimatic model validation", ***Water Resour. Res***, 35: 233-241.
- Leung, M. T., Daock, H., Chen, A., (2000),"Acomparison of classification and level estimation models", ***International Journal of Forecasting***, 16: 173-190.
- Nasrollhi, Z., Ghaffari Goolak, M., (2010), "Air pollution and its effective factors", ***Faslnameh Pazhoohesh Eghtesadi***, 3: 375-395.
- Pastuszka, J. S., Kozlowska, W. R., Zubek, E, Z., (2010),"Characteriazation of PM_{10} and $PM_{2.5}$ and associated heavy metals at the crossroads and urban background site in Zabrze, upper Silesia, Poland, during the smog episodes",***Environmrntal Monitoring and Assessment***, 168: 613- 627.
- Pérez, P., Trier, A., Reyes, J., (2000),"Prediction of $PM_{2.5}$ concentrations several hours in advance using neural networks in Santiago, Chile", ***Atmos Environ***, 34: 1189–96.
- Robles, L. A., Ortega, J. C., Fu, J. S., Reed, G. D., Chow, J. C., Watson, J. G., Herrera, J. A., (2008),"A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco, Chile", ***Atmospheric Environment***, 42: 8331- 8340.
- Sandstrom, T.FB., (2008),"Desert dust, an unrecognized source of dangerous air pollution", ***Epidemiology***, 19: 808-9.
- Schaap, M. G., (1998),"Using neural network to predict soil water retention and soil hydraulic conductivity", ***Soil and Till Research***, 47: 37- 42.
- Singh, A., Mishra, G. C., (2015),"Application of box- jenkins method and artificial neural network procedure for time series forecasting of prices", ***Statistics in Transition new series***, 16 (1): 83- 96.
- Specht, D. F., (1991),"A general regression neural network", ***IEEE TransnNeural Networks***, 2: 568–76.
- Timmreck, C., Lorenz, M. P., Crowley, T. J., Kinne, S., Raddatz, T. J., Thomas, M., A., (2009),"Limited tempreature response to the very large AD 1258 volcanic eruption",***Geographical Research Letters***, 36: 14-29.
-Tiryaki, S., Özşahin, Ş., Yıldırım, I., (2014),"Comparison ofartificial neural network and multiple linear regression models to predict optimum bonding strength of heat treated woods", ***International Journal of Adhesion and Adhesives***, 55: 29- 36.
- Zhou, Q., Jiang, H., Wang, J., Zhou, J., (2014),"A hybridmodel for $PM_{2.5}$ forecasting based on ensemble empirical mode decomposition and a general regression neural nrtwork", ***Science of the Total Environment***, 496: 264-274.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]