

## مقایسه پراکنش خطا در شبکه‌های عصبی مصنوعی بازگشتی Elman و Jordan در تخمین غلظت ذرات معلق اتمسفر (PM10) با استفاده از تصاویر ماهواره‌ای MODIS (مورد مطالعاتی: شهر اهواز)

دریافت مقاله: ۹۶/۷/۲۹ پذیرش نهایی: ۹۶/۱۰/۲۱

صفحات: ۱۶۹-۱۵۵

جواد سدیدی: استادیار گروه سنجش از دور دانشگاه خوارزمی تهران<sup>۱</sup>.

jsadidi@gmail.com

هانی رضائیان: استادیار گروه سنجش از دور دانشگاه خوارزمی تهران.

Hani.Rezayan@gmail.com

محمدرضا برشان: دانشجوی کارشناس ارشد سنجش از دور دانشگاه خوارزمی تهران.

reza540101@gmail.com

### چکیده

بواسطه پیچیدگی عملکردی پدیده آلودگی هوا، از روش‌های هوش مصنوعی بالاخص شبکه عصبی برای مدل سازی آلودگی هوا استفاده می‌شود. هدف از این پژوهش دو مدل شبکه عصبی بازگشتی Elman و Jordan در زمینه پراکنش خطا و اعتبارسنجی آنها، به منظور تخمین غلظت ذرات معلق موجود در اتمسفر در شهر اهواز می‌باشد. پارامترهای مورد استفاده شامل رطوبت، فشار هوا، دما و عمق نوری آتروسول می‌بوده که مقادیر آن از تصاویر ماهواره‌ای MODIS و داده‌های ایستگاه‌های هواشناسی تهیه شده است. نتایج نشان می‌داد که مدل Jordan با مقدار RMSE معادل ۲۲۸/۵ دقت برازش بهتری داشته است. مدل Jordan نسبت به مدل Elman با مقدار RMSE معادل ۲۲۸/۵ دقت برازش بهتری داشته است. مدل Jordan به دلیل استفاده از حلقه‌های درونی سبب به‌روز رسانی مقادیر زمینه شده و این امر موجب افزایش صحت مدل می‌شود. مقدار شاخص  $R^2$ ، که نماینده میزان رابطه خطی بین مقادیر پیش‌بینی شده با مقادیر واقعی است، برای مدل Jordan معادل ۰/۵ بدست آمده است که درصد تخمین صحیح ۵۰ درصد داده‌ها را نشان می‌داد. در نهایت با استفاده از داده‌های مربوط به غلظت PM10 برای روز ۱۶۲ که بالاترین میزان غلظت را داشت با روش درونیابی IDW نقشه توزیع مکانی آن تولید شد. با توجه به گران بودن ایستگاه‌های آلودگی سنجی پیشنهاد شد از منابع کمکی دیگر مانند اطلاعات داوطلبانه با استفاده از سنسورهای ارزان قیمت موبایل به عنوان ایستگاه کمکی متحرک و کم هزینه جهت افزایش تراکم و پراکنش مناسب ایستگاه‌ها جهت مدلسازی دقیق تر آلودگی هوا استفاده شود.

کلیدواژگان: آلودگی هوا، ذرات معلق، شبکه عصبی مصنوعی، Elman, Jordan, MODIS.

## مقدمه

تکنیک‌های یکپارچه برای بازیابی غلظت ذرات معلق (Particulate Matters) هوای سطح زمین توسط ماهواره-های سنجش از دور و مدل‌های پیش‌بینی کننده به طور فعال در طول دهه گذشته مورد بررسی قرار گرفته است. بازیابی غلظت PM هوای سطح زمین با استفاده از داده‌های سنجش از راه دور ماهواره‌ای و رابطه ذرات معلق با عمق نوری آئروسول (Aerosol Optical Depth) را می‌توان به دو دسته عمده طبقه‌بندی کرد: روش‌های مبتنی بر مشاهدات تجربی و روش‌های مبتنی بر شبیه‌سازی. مدل‌های مبتنی بر مشاهدات تجربی بر مبنای محاسبه رگرسیون‌های آماری بین AOD و PM عمل می‌کنند. (۸) این مشاهدات یا با استفاده از مدل‌های رگرسیون خطی چندگانه و با پارامترهای بیشتر (به عنوان مثال AOD، ارتفاع لایه مرزی، دما، رطوبت نسبی و باد (۲۹،۲۰) یا مدل‌های غیر خطی (۲۷،۲۳) و یا با استفاده از مدل‌های ترکیبی و پیچیده انجام می‌شوند. (۱۸) مدل‌های نیمه تجربی مبتنی بر مشاهدات با ترکیب کردن پارامترهای هواشناسی (ارتفاع لایه مرزی و فاکتور رشد نم پذیری) بر اساس درک فیزیکی صورت می‌گیرد. تحلیل و پیش‌بینی گرد و غبار علاوه بر نقشه‌های اطلاعات سطح زمین به اطلاعات ارتفاع بالای جو نیز نیاز دارد و با بررسی یک نقشه جوی نمی‌توان به نتیجه-گیری دقیق و مناسب دست یافت. (۳)

نتایج مطالعات انگل کاکس و همکاران (۱۰) نشان می‌دهد که رابطه PM-AOD چندان معین نیست و متغیر-های تأثیر گذار ناشناخته بسیاری در این میان وجود دارند. بعلاوه AOD یک اندازه‌گیری ستونی است در حالی است PM مشاهده سطحی است. از این رو AOD استخراج شده از تصاویر ماهواره‌ای به تنهایی نمی‌تواند برای برآورد غلظت PM، که نشان دهنده توده PM خشک در نزدیکی سطح زمین است، مورد استفاده قرار گیرد. پارامترهای هواشناسی مانند ارتفاع لایه مرزی سیاره‌ای (Planetary Boundary Layer) درجه حرارت (Temperature)، رطوبت نسبی (Relative humidity)، سرعت باد (Wind speed)، و جهت باد (Wind direction)، که در فضا و زمان بسیار متغیر می‌باشند، می‌توانند برای اصلاح رابطه بین AOD و غلظت PM مورد استفاده قرار گیرد. (۲۸،۲۵،۲۲،۱۹) به منظور کاهش عدم قطعیت‌ها در هنگام استفاده از رگرسیون‌های خطی ساده و یا غیر خطی، استفاده از شبکه‌های عصبی مصنوعی برای برآورد PM سطح، با استفاده از داده‌های AOD و با در نظر گرفتن عوامل اقلیمی ذکر شده در بالا در سال‌های اخیر مورد توجه محققان قرار گرفته است. در تحقیق انجام شده از سویگوپتا و همکاران (۱۱) چند مدل مبتنی بر شبکه‌های عصبی مصنوعی به منظور برآورد PM<sub>2.5</sub> نزدیک سطح زمین با استفاده از داده‌های ماهواره‌ای و هواشناسی در فصول و مناطق مختلف بر روی جنوب شرقی ایالات متحده توسعه داده شده است. پارامترهای ورودی مورد استفاده در تحقیق مزبور شامل عرض جغرافیایی، طول جغرافیایی، ماه، AOT، سرعت باد (WS) رطوبت نسبی (RH)، ارتفاع لایه مرز سیاره‌ای (PBL) و دمای سطح (TMP) بود. نتایج حاصل از بکارگیری شبکه عصبی مصنوعی در این تحقیق نشان دهنده همبستگی معادل ۰/۷۴ بین PM<sub>2.5</sub> تخمین زده شده و پارامترهای ورودی است که در مقایسه با نتایج همبستگی ساده (R=0.6) یا رگرسیون چند گانه (R=0.64)، بیانگر برتری شبکه عصبی مصنوعی برای کنترل عملیاتی کیفیت هوا است. در مطالعه‌ای دیگر، وئو و همکاران (۲۹) یک شبکه عصبی مصنوعی پس انتشار (Back Propagation) آموزش دیده با روش (Bayesian) را با استفاده از مشاهدات ماهواره‌ای و زمینی به منظور برآورد PM در شرق چین توسعه دادند. ورودی شبکه مزبور شامل هفت پارامتر ماه، AOT، سرعت باد

(WS)، جهت باد (WD) رطوبت نسبی (RH)، ارتفاع لایه مرزی سیاره‌ای (PBL) و دمای سطح (TMP) است. تعداد نرون‌های لایه پنهان بین ۶ تا ۱۵ نرون متغیر با تابع فعال‌سازی لجستیک  $\logistic$  لحاظ شد. نتایج تحقیق نشان داد که نتایج همبستگی حدود ۰/۷۵ حاصل شده است. علاوه بر این، نتایج نشان دهنده تغییرات فصلی قابل توجهی با حداکثر مقدار R معادل ۰/۸ در طول دوره پاییز را نشان می‌دهد.

باری و همکاران (۷) تعدادی از روش‌های شبکه عصبی را برای پیش‌بینی کیفیت هوا، از جمله مدل شبکه بازگشتی (Recurrent Network Model)، مدل تشخیص تغییر نقطه Change Point detection Model با RNM، مدل ساختار شبکه پی در پی Sequential Network Construction Model و خود سازمانده و ویژگی‌های نقشه Self-Organizing Feature Maps پیش‌بینی‌های کوتاه مدت (روزانه) و بلندمدت (سالانه) بود، نتایج نشان داد مدل‌ها به طور کلی می‌تواند الگوهای کیفیت هوا را با دقت متوسط پیش‌بینی کنند. با این حال، مدل SOFM در مقایسه با سایر مدل‌های برای پیش‌بینی دراز مدت (سالانه) داده‌ها و همچنین کوتاه مدت (روزانه) مناسب بود.

گلایی و همکاران (۴) دو مدل شبکه عصبی Multi layer Perceptron و Radial Basis Function را با تغییر در تعداد نرون‌ها، لایه‌های میانی و الگوریتم‌های آموزشی برای پیش‌بینی بارش‌های فصلی بکار گرفتند، نتایج نشان داد که برای ایستگاه اهواز و آبادان، شبکه RBF و برای ایستگاه دزفول شبکه MLP بیشترین همبستگی را داشتند. در تحقیق انجام شده از سوی پرز و ریس (۲۶) یک مدل شبکه عصبی مصنوعی پیش‌خور ۳ لایه شامل لایه مخفی دارای ۴ نرون و تابع فعال‌سازی سیگموید (Sigmoid) را برای پیش‌بینی حداکثر میانگین ۲۴ ساعته غلظت PM10 توسعه دادند که در پنج ایستگاه مانیتورینگ در شهر سانتیاگو، شیلی اعمال شد. ورودی مدل این-تحقیق غلظت PM10 تا ۷ بعد از ظهر در پنج ایستگاه اندازه‌گیری و متغیرهای هواشناسی بوده است. در این-تحقیق کیفیت برازش با استفاده از مدل عصبی در مقایسه با نتایج به دست آمده از برازش با یک مدل خطی با متغیرهای ورودی مشابه نشان داده شده است. بعلاوه تأکید شده است که انتخاب صحیح متغیرهای ورودی و ساختار شبکه عصبی نقش مهمی در نتیجه حاصله دارد. اردیز و همکاران (۲۴) متوسط روزانه PM2.5 در El Paso (ایالات متحده آمریکا) و Ciudad Juarez (مکزیک) با استفاده از سه نوع مختلف از شبکه‌های عصبی شامل پرسپترون چند لایه (MLP)، تابع دایره‌ای (RBF) و پرسپترون چند لایه مربعی (SMLP) و دو نوع از مدل‌های رگرسیون خطی نتایج حاصله نشان داد شبکه عصبی مصنوعی عملکرد بهتری نسبت به مدل‌های آماری کلاسیک مبتنی بر رگرسیون داشته است.


پراکندگی مقدار PM تحت تاثیر عوامل مختلفی است که رابطه این عوامل با پراکندگی PM لزوماً به صورت خطی نمی‌باشد و پیچیده است. بنابراین مدل‌های شبکه عصبی مصنوعی می‌تواند برای مدل کردن پراکندگی PM با استفاده از داده‌های ماهواره‌ای و پارامترهای اقلیمی مورد استفاده قرار گیرد. در کارهای قبلی از مدل‌های شبکه عصبی پیش‌خوراند برای مدل سازی پراکندگی PM استفاده شده است. در این تحقیق از مدل‌های شبکه عصبی مصنوعی بازگشتی به دلیل قابلیت بالا در کشف الگو در داده‌های زمانمند استفاده می‌شود. هدف از این تحقیق ارزیابی پتانسیل شبکه‌های عصبی مصنوعی بازگشتی Elman و Jordan جهت برآورد غلظت PM10 می‌باشد. شبکه‌های بازگشتی توانایی بالایی در تشخیص الگوها در سری‌های داده زمانمند دارا می‌باشند در حالی که آموزش آن‌ها مانند سایر انواع شبکه‌های عصبی تعریف شده و مشخص نیست. بدین منظور از

داده‌های هواشناسی و محصول AOD از سنجنده MODIS بعنوان ورودی‌های مدل در هر دو ساختار، استفاده می‌شود و در نهایت بهترین ساختار در تخمین PM10 معرفی می‌گردد.

### روش تحقیق

#### منطقه مورد مطالعه

شهر اهواز، مرکز استان خوزستان، یکی از کلانشهرهای ایران است که در منطقه‌ای جلگه‌ای با ارتفاع حدود ۱۸ متر از سطح دریا واقع شده است. بیشترین طوفان‌های گرد و غبار در آن اتفاق می‌افتد. (۵) منشا اکثر این طوفان‌های گرد و غبار کشور همسایه ایران شامل عراق و سوریه هستند و برخی نیز دارای منشا داخلی بوده‌اند. شکل (۱) منطقه مورد مطالعه به همراه موقعیت ایستگاه‌های هواشناسی و آلودگی سنجی را نشان می‌دهد.



شکل (۱). موقعیت منطقه مورد مطالعه

### داده‌های سنجنده MODIS

سنجنده‌های MODIS روی دو ماهواره Terra و Aqua قرار گرفته که به ترتیب از سال ۱۹۹۹ و ۲۰۰۲ شروع به کار کرده‌اند. این دو ماهواره با مدار قطبی در ارتفاع حدود ۷۰۰ کیلومتری خط استوا در حال گردش به دور کره زمین هستند. زمان تقریبی عبور این ماهواره‌ها از بالای هر منطقه حدود ۱۰:۳۰ و ۱۳:۳۰ دقیقه زمان محلی است. سنجنده MODIS دارای ۳۶ باند طیفی از ۰/۴۱ تا ۱۴ میکرومتر است. قدرت تفکیک مکانی این

سنجنده بین ۲۵۰ متر، ۵۰۰ متر و یک کیلومتر است. قدرت تفکیک زمانی این ماهواره در حدود یک یا دو روز می‌باشد. سنجنده MODIS دارای محصولات زمینی، اتمسفری و اقیانوسی متنوع می‌باشد که بصورت رایگان در اختیار متقاضیان قرار می‌گیرد. داده‌های MODIS به دلیل پوشش وسیع مکانی و زمانی گزینه مناسب برای مطالعه و تحقیق در زمینه پدیده‌هایی همچون گرد و غبار که منطقه وسیعی را تحت تاثیر خود قرار می‌دهند، می‌باشند. بیات و همکاران (۱) از تصاویر MODIS و داده‌های ایستگاه هواشناسی اهواز جهت بررسی ارتباط تغییرات پوشش تالاب شادگان با طوفان‌های گرد و غبار استفاده کردند. نتایج کاهش ۷/۳۶ درصدی سطح پوشش گیاهی منطقه را از ۲۰۰۰ تا ۲۰۱۱ نشان داد. همچنین پورهاشمی و همکاران (۲) از تصاویر MODIS در ترکیب با داده‌های سینوپتیک ایستگاه‌های خراسان رضوی جهت پهنه‌بندی روزهای گرد و غبار استفاده کردند. پهنه‌بندی با روش کریجینگ معمولی انجام شد و نتایج حاکی از ارتباط تعداد وقوع گرد و غبار با واکنش گیاهی بود. در این تحقیق محصول MOD04 که AOD را در بر دارد برای ۵۰ روز در سال ۱۳۹۲ که طوفان گرد و غبار گزارش شده است، استفاده شده است جدول (۱).

جدول (۱). مشخصات مربوط به محصول ماهواره‌ای MOD04 ماهواره‌ای

محصول	پارامتر	قدرت تفکیک	توضیحات
MOD04	AOD	10km	تخمین AOD در طول موج‌های ۴۶۵،۴۶۹،۵۵۵ و ۲۱۰۰ نانومتر

### داده‌های ایستگاه‌های هواشناسی

داده‌های ایستگاه‌های هواشناسی که شامل رطوبت نسبی (RH)، سرعت باد (WS)، جهت باد (WD)، میانگین دما (T) و فشار سطح زمین (SP) از ایستگاه‌های هواشناسی منطقه جمع‌آوری شده‌اند. تعداد ایستگاه‌های مزبور ۱۳ ایستگاه می‌باشد.

روش کار در این تحقیق شامل ۳ مرحله است شکل (۲):

۱. محصول MOD04 ماهواره MODIS که داده‌های AOD را در بر دارد تهیه شده است.
۲. داده‌های ایستگاه‌های آلودگی سنجی در زمان گذر ماهواره مشخص شده‌اند.
۳. داده‌های هواشناسی نظیر نقاط آلودگی سنجی با استفاده از شبکه‌های عصبی بازگشتی Elman و Jordan جهت برآورد غلظت PM10 مدل‌سازی شد.



شکل (۲). نمودار مراحل مربوط به روند کلی مراحل انجام پژوهش

کافمن و تانر (۱۷) به منظور پیش‌بینی غلظت PM10 با استفاده از مدل‌های شبکه عصبی بازگشتی (Elman, Jordan) در ابتدا AOD از MOD04 تهیه می‌شود. محصول سطح دو، نسخه C004 ماهواره MODIS برای مطالعات اتمسفری، AOD را در باندهای به مرکز ۰/۴۷، ۰/۶۶ و ۲/۱۲ میکرومتر ارائه می‌دهد. برای محاسبه AOD در این محصول از الگوریتم پوشش گیاهی تیره با تراکم زیاد (Dense Dark Vegetation) استفاده شده است. این الگوریتم میزان AOD را برای سطح زمین با قدرت تفکیک ۱۰×۱۰ کیلومتر مربع در نقطه نادیر ارائه می‌کند. به منظور استخراج داده‌های MODIS در ابتدا داده‌های ایستگاه‌های سنجش آلودگی در زمان گذر ماهواره مشخص شده‌اند. پس از اخذ داده‌های ماهواره‌ای MODIS از وب سایت مربوطه با استفاده از نرم‌افزار ENVI و افزونه MCTK این داده‌ها به تصاویر با پسوند TIFF و قابل گشودن در نرم‌افزار ArcGIS تبدیل شده‌اند. سپس نقاط متناظر ایستگاه‌های زمینی در تصاویر با استفاده از ابزار Extract Point Value استخراج شده است.

عوامل اقلیمی به دو دسته تاثیرگذار بر PM تقسیم می‌شوند (۱) عواملی که به طور مستقیم بر ذرات تاثیرگذار هستند. سرعت و جهت جریان هوا، لایه بندی دمای هوای اتمسفر نزدیک سطح زمین، بارش و (۲) عواملی که به طور غیر مستقیم بر آنها تاثیرگذار هستند از جمله دمای هوا، رطوبت هوا، فرم ابرها و فشار هوا (۱۵) در برخی از مطالعات مشخص شده است که میزان غلظت آئروسول‌ها در دوره‌های گرم سال بیشتر از سایر فصل‌ها است و همچنین روزهای هفته نیز با آخر هفته میزان PM متفاوتی دارند (۱۴) بین سرعت باد و مقادیر PM10 نیز رابطه منفی وجود دارد. همچنین افزایش رطوبت هوا موجب کاهش میزان PM10 در اتمسفر می‌شود. زیرا رطوبت نسبی معمولاً توسط وقوع بارندگی تحت تاثیر قرار می‌گیرد و این بارندگی موجب می‌شود که آلودگی‌های موجود در هوا کاهش پیدا کنند. (۶)

برای استفاده از داده‌های مربوط به ایستگاه‌های هواشناسی برای هر ایستگاه هواشناسی یک بافر ۱۰ کیلومتری منظور شده است. سپس از داده‌های مربوط به ایستگاه هواشناسی مربوطه برای ایستگاه‌های آلودگی سنجی موجود در بافر مربوطه استفاده شده است. داده‌های هواشناسی شامل رطوبت نسبی (SRH)، سرعت باد

(SWS)، جهت باد (SWD)، میانگین دما (T) و فشار سطح زمین (SLP) که از ایستگاه‌های هواشناسی منطقه جمع‌آوری شده اند به همراه AOD بدست آمده از تصاویر ماهواره‌ای به عنوان ورودی مدل های شبکه عصبی بازگشتی استفاده شده است. این داده ها به صورت تصادفی به میزان ۶۰ درصد برای آموزش شبکه، ۲۰ درصد برای اعتبار سنجی و ۲۰ درصد برای آزمایش (نمونه های جدا نگه داشته شده) مورد استفاده قرار گرفت. به منظور افزایش سرعت محاسبات و افزایش دقت تخمین در مدل شبکه عصبی، داده‌های ورودی با استفاده از رابطه (۱) استانداردسازی شده است:


$$SC = \frac{\bar{X} - \text{mean}}{S} \quad \text{رابطه (۱)}$$

که در آن، SC، نمره استاندارد، X متغیر مورد نظر، mean میانگین و S انحراف معیار است.

### شبکه‌های عصبی بازگشتی


کار بنیادی اولیه درباره شبکه‌های بازگشتی در ۱۹۸۰ صورت گرفت. در سال ۱۹۸۲، هاپفیلد یک خانواده از شبکه‌های عصبی بازگشتی را معرفی کرد. (۱۳) برخی از شبکه‌های هاپفیلد قابلیت تشخیص الگوها را دارند اما روش مشخصی برای آموزش نظارت شده این شبکه‌ها پیشنهاد نمی‌دهد. یادگیری با شبکه‌های عصبی بازگشتی، همانند تمام شبکه‌های عصبی، بهینه ساز NP-hard دشوار است. اما یادگیری در شبکه‌های بازگشتی می‌تواند با توجه به مشکلات یادگیری دراز مدت، دشوارتر شود. (۱۲) مشکلات شناخته شده محو شدگی و متلاشی شدن که موجب انتشار خطاهای موجود می‌شود در بسیاری از مراحل زمانی، رخ می‌دهد. در این نوع شبکه‌ها، یک الگو با تنظیم کردن ارزش های گره‌ها در شبکه قرار داده می‌شود. شبکه پس از آن برای برخی از زمان‌ها اجرا می‌شود با توجه به آن قوانین به روز رسانی شده، و در نهایت یک الگو کشف می‌شود.

شبکه‌های Jordan شکل (۳)، توسط مایکل Jordan در سال ۱۹۸۶ معرفی شده است، این شبکه‌ها در حال حاضر معماری اولیه برای یادگیری نظارت شده توالی‌ها می‌باشند. (۱۶) شبکه Jordan شبیه یک شبکه پیشخور Feed Forward با یک لایه پنهان می‌باشد، با این تفاوت که بوسیله واحدهای زمینه context units توسعه یافته است شکل (۳). خروجی‌ها به داخل واحدهای زمینه فرستاده می‌شوند و پس از آن به داخل لایه‌های پنهان فرستاده می‌شوند. علاوه بر این، واحدهای زمینه، لبه‌های خود اتصال دارند که امکان ارسال اطلاعات در سراسر مراحل زمانی مختلف، بدون آشفتگی در خروجی را به شبکه های Jordan می‌دهند. بدین ترتیب واحدهای زمینه به شبکه اجازه می‌دهند که اقدامات صورت گرفته (خروجی) در مراحل زمانی گذشته را بیاد بیاورد.



شکل (۳). شبکه‌های عصبی بازگشتی پیشنهاد شده توسط Jordan (۱۹۸۶).


شبکه Elman معرفی شده توسط Elman (۹) ساختار ساده شده شبکه Jordan می‌باشد. در این شبکه هر گره پنهان دارای یک لبه برگشتی خود اتصال است. شکل (۴).



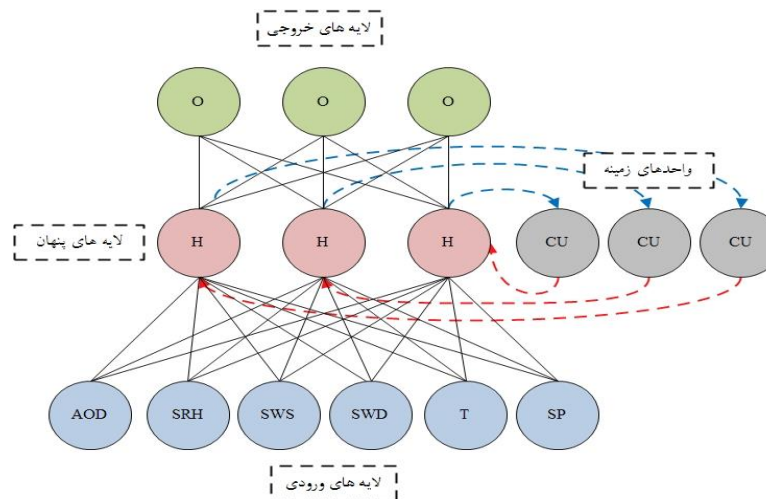
شکل (۴). شبکه‌های عصبی بازگشتی پیشنهاد شده توسط Elman (۱۹۹۰).

نمای شماتیک شبکه‌های عصبی بازگشتی Jordan و Elman استفاده شده در این تحقیق به منظور پیش‌بینی غلظت PM10 در اشکال (۵ و ۶) نمایش داده شده است. چنانکه مشاهده می‌شود شبکه‌های مزبور شامل ۶ ورودی، یک لایه مخفی شامل ۳ نرون و ۳ نرون خروجی می‌باشند.





شکل (۵). نمای شماتیک شبکه عصبی بازگشتی Jordan ایجاد شده به منظور پیش بینی غلظت PM10



شکل (۶). نمای شماتیک شبکه عصبی بازگشتی Elman ایجاد شده به منظور پیش‌بینی غلظت PM10

### ۲-۳-۲- اعتبارسنجی مدل‌ها

به منظور اعتبارسنجی مدل نهایی از دو روش، ریشه توان دوم خطا (Root-Mean-Square Error) رابطه (۲) و میانگین خطای مطلق (Mean Absolute Error) رابطه (۳) استفاده شده است و مدل‌های مختلف بر اساس این دو پارامتر آماری با یکدیگر مقایسه شده‌اند. مقدار RMSE معادل ریشه توان دوم خطاها به منظور محاسبه میزان تفاوت بین مقادیر واقعی و مقادیر پیش‌بینی شده در مدل استفاده شده است. مقدار MAE معادل میانگین خطاهای مطلق یکی از پر استفاده‌ترین شاخص‌ها برای نشان دادن میانگین خطاها است.


$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Predict - Ground)^2} \quad \text{رابطه (۲)}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Predict - Ground| \quad \text{رابطه (۳)}$$


که در آن‌ها،  $n$  برابر با تعداد کل داده‌ها، Predict برابر با مقدار پیش‌بینی شده توسط مدل و Ground برابر با مقدار داده‌های زمینی است. این شاخص هر چقدر کمتر باشد نشان‌دهنده صحت بهتر مدل نهایی است. بعلاوه این شاخص هم به خطاهای تصادفی و هم به خطاهای سیستماتیک حساسیت دارد.

### نتایج

پس از اجرای روشهای Elman و Jordan خطای حاصل از پیش‌بینی به روشهای ذکر شده محاسبه و مورد مقایسه قرار گرفته است. نمودار مقایسه برآزش مدل‌های شبکه عصبی بازگشتی Elman و Jordan بر داده‌های واقعی غلظت PM10 در اشکال (۷ و ۸) نشان داده شده است.




شکل (۷). نمودار مقایسه نتایج مدل Elman با داده‌های واقعی




شکل (۸). نمودار مقایسه نتایج مدل Jordan با داده‌های واقعی

همچنین در ادامه اشکال (۹ و ۱۰) برآزش خطی بر نتایج مقادیر PM10 پیش‌بینی شده توسط مدل‌های Elman و Jordan با مقادیر مشاهده شده توسط ایستگاه‌های زمینی را نشان می‌دهد. بر این اساس نتایج

پیش‌بینی شده توسط مدل Jordan همبستگی بالاتری ( $R^2 = 0.501$ ) نسبت به مدل Elman ( $R^2 = 0.4776$ ) دارند.



شکل (۹). نمودار پراکنش خروجی مدل Jordan با داده‌های واقعی




شکل (۱۰). نمودار پراکنش خروجی مدل Elman با داده‌های واقعی

به منظور مقایسه بین مدل‌های ارائه شده و انتخاب جداول مدل برای تخمین مقادیر PM10، دو معیار RMSE و MAE برای مدل‌های مزبور محاسبه شده و نتایج آن در جدول (۲ و ۳) آورده شده است. با توجه به نتایج، هر دو مقدار RMSE و MAE در مدل Jordan کمتر از مدل Elman است. بنابراین مدل Jordan توانسته است پیش‌بینی‌های بهتری از غلظت PM10 نسبت به مدل Elman داشته باشد.

جدول (۲). میزان **RMSE** و **MAE** محاسبه شده برای مدل‌های مورد استفاده در تحقیق

ردیف	مدل	RMSE	MAE
۱	Jordan	۲۱۹/۹	۴۸۳۵۷/۹۵
۲	Elman	۲۲۸/۵	۵۲۲۱۴/۰۸

پس از محاسبه مدل‌های شبکه عصبی در محیط MATLAB در ادامه به منظور بصری سازی نتایج خروجی هر مدل در روز ۱۶۲ که دارای بیشترین غلظت PM10 بوده است، با استفاده از مدل IDW در محیط ARCMAP برای مناطق دارای ایستگاه آلودگی سنجی (اهواز، حمیدیه و سوسنگرد) درونیایی شده است. شکل (۱۱) توزیع مکانی غلظت PM10 بدست آمده از مدل‌های Elman و Jordan را در این مناطق را جهت مقایسه نشان میدهد.



شکل (۱۱). نقشه توزیع مکانی غلظت PM10 بدست آمده از مدل Elman و Jordan در ۲۳ خرداد ۱۳۹۲

### نتیجه گیری

دو مدل شبکه عصبی بازگشتی Elman و Jordan به منظور مدل‌سازی داده‌های غلظت PM10 در استان خوزستان اجرا شده‌اند. نتایج حاصله نشان می‌دهند که مدل بازگشتی Jordan نتایج بهتری نسبت به مدل

Elman می‌دهد. با در نظر گرفتن مقادیر RMSE بدست آمده در مرحله صحت‌سنجی نیز مشخص می‌شود که مدل Jordan با داشتن مقدار  $RMSE=219$  میلی گرم بر متر مکعب دارای نتایج بهینه‌تری نسبت به مدل Elman با  $RMSE=228$  میلی گرم بر متر مکعب است. مدل Jordan در روند محاسبات خود دارای حلقه‌های درونی بر روی مقادیر زمینه خود است. این حلقه‌ها موجب می‌شود مقادیر زمینه خود را به روز رسانی کرده و همین امر موجب افزایش صحت مدل ذکر شده می‌شود. مدل Elman پیش‌بینی‌های با مقادیر نسبتاً بالاتری از مقادیر مشاهده شده غلظت  $PM_{10}$  دارد.

هر دو مدل Elman و Jordan دارای قدرت تخمین پایین در حدود ۵۰ درصد هستند. این امر می‌تواند به علت‌های مختلف باشد. از جمله این موارد اندازه پیکسل‌های مورد استفاده برای استخراج AOD هستند که در هر گذر ماهواره، سطح زمین تنها توسط تعداد کمی از این پیکسل‌ها پوشیده می‌شود. در نتیجه برای ایستگاه‌های آلودگی سنجی با ابعادی که نسبت به سلول‌های ماهواره MODIS بسیار کوچک است و (هر پیکسل نماینده یک کیلومتر مربع می‌باشد) و تنها در شعاع محدودی از اطراف خود قابل استناد هستند. در بسیاری از مواقع مقایسه داده‌های زمینی با اطلاعات بدست آمده از ماهواره واز این طریق، دارای صحت کافی نمی‌باشند. پراکندگی نامناسب و عدم کالیبره بودن ایستگاه‌های آلودگی سنجی زمینی نیز موجب افزایش عدم قطعیت در نتایج می‌شود. به همین جهت برای اعتبارسنجی اطلاعات بدست‌آمده از ماهواره، باید از اطلاعات ایستگاه‌های زمینی پایش آلودگی هوا، بهره برد. به منظور مدل‌سازی برای پیش‌بینی میزان غلظت،  $PM$  همانگونه که در مطالعات گذشته نیز انجام شده است افزودن پارامترهای هواشناسی موجب افزایش میزان همبستگی بین نتایج مدل و داده‌های ایستگاه‌های آلودگی سنجی زمینی می‌شود. از جمله این عوامل را می‌توان به رطوبت نسبی، میانگین دمای هوا، سرعت و جهت باد اشاره کرد. از بین این عوامل رطوبت نسبی تاثیر بیشتری در مدل‌های پیش‌بینی دارد. در نهایت جهت افزایش داده‌های زمینی پیشنهاد می‌شود از اطلاعات داوطلبانه جغرافیایی با نصب سنسورهای ارزان قیمت سنجش آلودگی بر روی موبایل کاربران استفاده گردد. این روش می‌تواند حجم زیادی از داده‌های آلودگی را با پراکنش سراسری و تعداد نامحدود کاربران داوطلب که به عنوان سنسورهای متحرک در زمان و مکان هستند را فراهم کند. و نهایتاً باعث افزایش دقت پیش‌بینی‌ها شود.

## منابع

- بیات، ر.، س. جعفری، ب. قرمزچشمه و ا.ح. چرخایی. (۱۳۹۵). مطالعه تأثیر ریزگردها بر تغییرات پوشش گیاهی (مطالعه موردی: تالاب شادگان، خوزستان). نشریه سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی. ۱۷-۳۲.
- پورهایمی، س.، م. بروغنی، م. ع. زنگنه اسدی و ا. امیراحمدی. (۱۳۹۴). تحلیل ارتباط پوشش گیاهی بر وقوع تعداد گرد و غبار استان خراسان رضوی با استفاده از سیستم اطلاعات جغرافیایی و سنجش از دور. نشریه سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی. ۳۳-۴۵.
- فلاح ززولی، م.، ع. وفایی‌نژاد، م.م. خیرخواه زرکش و ف. احمدی دهکاء. (۱۳۹۳). منشاء یابی گرد و غبار غرب و جنوب غرب ایران و تحلیل سینوپتیکی آن با استفاده از سنجش از دور و سیستم اطلاعات جغرافیایی. نشریه سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی. ۴۵-۷۸.

گلایی، م.م. ع. آخوندعلی و ف. رادمنش. (۲۰۱۳). مقایسه عملکرد الگوریتم های مختلف شبکه عصبی مصنوعی در مدل سازی بارندگی فصلی مطالعه موردی؛ ایستگاه های منتخب استان خوزستان. نشریه تحقیقات کاربردی علوم جغرافیایی. ۱۳ (۳۰) ۱۶۹-۱۵۱.

محیط زیست خوزستان. گزارش مربوط به تاریخ و منشا طوفان های گرد و غبار در استان خوزستان در سال ۱۳۹۲، خوزستان، ۱۳۹۳.

Afzali, A., Rashid, M., Sabariah, B., & Ramli, M. (2014). **PM10 Pollution: Its Prediction and Meteorological Influence in PasirGudang, Johor**. In IOP Conference Series: Earth and Environmental Science (Vol. 18, No. 1, p. 012100). IOP Publishing.

Barai, S. V., Dikshit, A. K., & Sharma, S. (2007). **Neural network models for air quality prediction: a comparative study**. In Soft Computing in Industrial Applications (pp. 290-305). Springer Berlin Heidelberg.

Benas, N., Beloconi, A., & Chrysoulakis, N. (2013). **Estimation of urban PM10 concentration, based on MODIS and MERIS/AATSR synergistic observations**. Atmospheric Environment, 79, 448-454.

Elman, J. L. (1990). **Finding structure in time**. Cognitive science, 14(2), 179-211.

Engel-Cox, J. A., Holloman, C. H., Coutant, B. W., & Hoff, R. M. (2004). **Qualitative and quantitative evaluation of MODIS satellite sensor data for regional and urban scale air quality**. Atmospheric Environment, 38(16), 2495-2509.

Gupta, P., & Christopher, S. A. (2009). **Particulate matter air quality assessment using integrated surface, satellite, and meteorological products: 2. A neural network approach**. Journal of Geophysical Research: Atmospheres (1984–2012), 114(D20). Chicago.

Hochreiter, S., & Schmidhuber, J. (1997). **Long short-term memory**. Neural computation, 9(8), 1735-1780.

Hopfield, J. J. (1982). **Neural networks and physical systems with emergent collective computational abilities**. Proceedings of the national academy of sciences, 79(8), 2554-2558.

Hörmann, S., Pfeiler, B., & Stadlober, E. (2005). **Analysis and prediction of particulate matter PM10 for the winter season in Graz**. Austrian Journal of Statistics, 34(4), 307-326.

Hrdličková, Z., Michalek, J., Kolář, M., & Veselý, V. (2008). **Identification of factors affecting air pollution by dust aerosol PM 10 in Brno City, Czech Republic**. Atmospheric Environment, 42(37), 8661-8673.

Jordan, M. I. (1997). **Serial order: A parallel distributed processing approach**. Advances in psychology, 121, 471-495.

Kaufman, Y. J., & Tanre, D. (1994). **Direct and indirect methods for correcting the aerosol effect on remote sensing**.

Kloog, I., Koutrakis, P., Coull, B. A., Lee, H. J., & Schwartz, J. (2011). **Assessing temporally and spatially resolved PM<sub>2.5</sub> exposures for epidemiological studies using satellite aerosol optical depth measurements**. Atmospheric Environment, 45(35), 6267-6275.

Koelmeijer, R. B. A., Homan, C. D., & Matthijsen, J. (2006). **Comparison of spatial and temporal variations of aerosol optical thickness and particulate matter over Europe**. Atmospheric Environment, 40(27), 5304-5315.

- Li, C., Hsu, N. C., & Tsay, S. C. (2011). **A study on the potential applications of satellite data in air quality monitoring and forecasting.** *Atmospheric Environment*, 45(22), 3663-3675.
- Liu, Y., Franklin, M., Kahn, R., & Koutrakis, P. (2007). **Using aerosol optical thickness to predict ground-level PM 2.5 concentrations in the St. Louis area: a comparison between MISR and MODIS.** *Remote sensing of Environment*, 107(1), 33-44.
- Liu, Y., Sarnat, J. A., Kilaru, V., Jacob, D. J., & Koutrakis, P. (2005). **Estimating ground-level PM<sub>2.5</sub> in the eastern United States using satellite remote sensing.** *Environmental science & technology*, 39(9), 3269-3278.
- Liu, Y., Schichtel, B. A., & Koutrakis, P. (2009). **Estimating particle sulfate concentrations using MISR retrieved aerosol properties. Selected Topics in Applied Earth Observations and Remote Sensing.** *IEEE Journal of*, 2(3), 176-184.
- Ordieres, J. B., Vergara, E. P., Capuz, R. S., & Salazar, R. E. (2005). **Neural network prediction model for fine particulate matter (PM 2.5) on the US–Mexico border in El Paso (Texas) and Ciudad Juárez (Chihuahua).** *Environmental Modeling & Software*, 20(5), 547-559.
- Pelletier, B., Santer, R., & Vidot, J. (2007). **Retrieving of particulate matter from optical measurements: a semiparametric approach.** *Journal of Geophysical Research: Atmospheres*, 112(D6).
- Pérez, P., Trier, A., & Reyes, J. (2000). **Prediction of PM 2.5 concentrations several hours in advance using neural networks in Santiago, Chile.** *Atmospheric Environment*, 34(8), 1189-1196.
- Tian, J., & Chen, D. (2010). **A semi-empirical model for predicting hourly ground-level fine particulate matter (PM<sub>2.5</sub>) concentration in southern Ontario from satellite remote sensing and ground-based meteorological measurements.** *Remote Sensing of Environment*, 114(2), 221-229.
- Van Donkelaar, A., Martin, R. V., & Park, R. J. (2006). **Estimating ground-level PM<sub>2.5</sub> using aerosol optical depth determined from satellite remote sensing.** *Journal of Geophysical Research: Atmospheres*, 111(D21).
- Wu, Y., Guo, J., Zhang, X., Tian, X., Zhang, J., Wang, Y., ... & Li, X. (2012). **Synergy of satellite and ground based observations in estimation of particulate matter in eastern China.** *Science of the Total Environment*, 433, 20-30