

## بررسی توانایی دو روش شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان در پیش‌بینی طوفان‌های گرد و خاک شهر زابل

محمد رضا جمالیزاده تاج‌آبادی<sup>\*</sup>، علیرضا مقدم نیا<sup>\*\*</sup> و جمشید پیری<sup>\*\*\*</sup>

<sup>\*</sup>دانشجوی کارشناسی ارشد رشته‌ی بیابان‌زدایی

<sup>\*\*</sup>استادیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه زابل

<sup>\*\*\*</sup>کارشناس ارشد اداره‌ی جهاد کشاورزی شهرستان زابل

### چکیده:

استفاده از روش‌های مختلف هوش مصنوعی<sup>۱</sup> مدتی است که در شاخه‌های گوناگون علوم مورد توجه قرار گرفته است. دلیل این امر را می‌توان توانایی بالای این روش‌ها در یادگیری روند موجود در فرآیندهای مختلف ذکر کرد. با استفاده از این روش‌ها می‌توان فرآیندهایی را که وقوع آن‌ها از یک رابطه‌ی خطی و معین تبعیت نمی‌کند شبیه‌سازی و نیز پیش‌بینی کرد. در این مطالعه به پیش‌بینی طوفان‌های گرد و خاک در شهر زابل با استفاده از دو روش هوش مصنوعی پرداخته شده است. قدرت روش شبکه‌های عصبی مصنوعی و روش ماشین‌های بردار پشتیبان و نیز روش رگرسیون گام‌به‌گام در پیش‌بینی این طوفان‌ها مورد مطالعه قرار گرفته است. واژگان کلیدی: شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان، طوفان گرد و خاک، پیش‌بینی، زابل.

### مقدمه:

طوفان‌های گرد و خاک یکی از پدیده‌های جوی هستند که در بسیاری از عرصه‌های بیابانی و مناطق خشک دنیا گسترش دارند و در سال‌های اخیر توجه فزاینده‌ای را به خود معطوف داشته‌اند [۳۸]. به خصوص توانایی ردیابی و یافتن محل طوفان‌ها و ایجاد گرد و خاک و ابرهای غباری در مقیاس زمانی کوتاه و به صورت لحظه‌ای به طور فزاینده‌ای توسط دانشمندان و دولت‌ها برای ایجاد سامانه‌ی هشدار، پیگیری می‌شود [۲۷]. در ایران نیز مناطق مختلفی وجود دارند که از این مشکل رنج می‌برند. از جمله منطقه‌ی سیستان در استان سیستان و بلوچستان، قسمتی در شمال شرق کشور و حوالی سرخس در استان خراسان، مناطقی در جنوب غرب کشور، در استان خوزستان و نیز برخی از قسمت‌های حوزه‌ی مرکزی از جمله دشت یزد - اردکان در استان یزد و همچنین بم در استان کرمان. این طوفان‌ها می‌توانند موجب بروز خسارات و تلفات گوناگون جانی و مالی شوند [۹]. از این رو شناخت و پیش‌بینی این طوفان‌ها می‌تواند در برنامه‌ریزی برای کاهش اثرات سوء آن‌ها و نیز اثرات مفید احتمالی مثلاً در راهکارهای جنگی و نظامی آن‌ها نقش بسزایی داشته باشد.

یکی از مناطقی که همواره در معرض این طوفان‌ها بوده و هرساله خساراتی را در این بعد متحمل می‌شود، منطقه‌ی سیستان و شهر زابل است (روزنامه‌ی ایران، ۱۸ خرداد ۱۳۸۲، روزنامه‌ی شرق، ۱۷ مرداد ۱۳۸۳). با گرم شدن هوای منطقه و ایجاد یک توده‌ی هوای کم فشار روی قسمت جنوب شرقی کشور و نیز قسمتی از جنوب غرب افغانستان و همچنین شمال شرق پاکستان، هوا از سمت شمال این مناطق و در اثر ایجاد توده‌ی هوای پرفشار موجود در قسمت آسیای میانه، سیبری و شمال شرق ایران، به سمت این نواحی جاری شده و وزش بادهای نسبتاً شدید همراه با ذرات گرد و خاک و نیز شن را به همراه دارد [۸]. بررسی‌ها نشان می‌دهد که عمده مناطق برداشت این غبارها و

<sup>۱</sup> . Artificial Intelligence

ذرات ریز شن، بستر خشک دریاچه‌ی هامون می باشد [۱] و مطالعات انجام شده روی تصاویر ماهواره‌ای نیز نشان می‌دهد چندین کانال مجزا برای عبور این طوفان‌ها در منطقه وجود دارد [۲].


#### روش‌های هوش مصنوعی:

تاکنون تعریف جامعی که مورد پذیرش همه باشد، از هوش مصنوعی ارائه نشده است. اما در تمامی تعاریف ارائه شده مصنوعی بودن و الگوبرداری از طرز کار مغز حیوانات، ویژگی بارز این تعاریف است [۲۱، ۲۹، ۳۱، ۳۹]. در سالیان اخیر علاقه‌ی فزاینده‌ای برای استفاده از روش‌های مختلف هوش مصنوعی در زمینه‌های مختلف علوم، در بین محققان به وجود آمده است. این روش‌ها اغلب به صورت روش‌های تشخیص الگو، روش‌های طبقه بندی و روش‌های رگرسیون طبقه بندی می شوند. در این بین چهار روش عمده که بیشتر از آن‌ها استفاده می‌شود عبارتند از: روش سیستم خبره، روش فازی، روش شبکه‌های عصبی مصنوعی و روش ماشین‌های بردار پشتیبان [۱۵]. البته از ترکیب این روش‌ها نیز روش‌های جدیدی ایجاد شده و به فراوانی مورد استفاده قرار گرفته‌اند، از جمله روش‌های فازی-عصبی و همچنین ترکیب این روش‌ها با روش‌های موجود در هر زمینه و از جمله روش‌های آماری. در این مقاله از بین این روش‌ها از دو روش شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان استفاده شده است.

#### شبکه‌های عصبی مصنوعی:

روش شبکه‌های عصبی مصنوعی (ANN)، اولین بار در سال ۱۹۴۳ میلادی توسط مک کلاچ و پیترز معرفی گردید و علی‌رغم به کارگیری یک ساختمان ساده، سرعت و قدرت محاسباتی آن به شدت مورد توجه قرار گرفت [۵]. شبکه‌های عصبی مصنوعی بر اساس ارتباطات داخلی بسیار گسترده، همانند سیستم عصبی و مغز انسان بنا نهاده شده‌اند. این شبکه‌ها جزء سیستم‌های دینامیکی می‌باشند که با پردازش روی داده‌های تجربی، قانون نهفته در ورای این اطلاعات را به ساختار شبکه منتقل می‌کنند. به همین دلیل آن‌ها را سامانه‌های هوشمند می‌نامند، زیرا بر اساس انجام محاسبات روی داده‌های عددی و یا مثال‌ها، قوانین کلی را فرا می‌گیرند [۲۸].

یک شبکه عصبی از نرون‌های مصنوعی تشکیل شده است. نرون یا گره کوچکترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد [۷]. هر یک از نرون‌ها، ورودی‌ها را دریافت نموده و پس از پردازش روی آنها، یک سیگنال خروجی تولید می‌نمایند. لذا هر نرون در شبکه به عنوان مرکز پردازش و توزیع اطلاعات عمل می‌کند و ورودی و خروجی مخصوص به خود را دارد [۵]. شکل ۱ نمایش ساختار یک نرون تک ورودی می‌باشد، که در آن علامت‌های  $p$  و  $a$ ، به ترتیب ورودی و خروجی نرون هستند.



شکل ۱: ساختار نرون تک ورودی (اقتباس از منهاج، ۱۳۷۷).

میزان تاثیر  $p$  روی  $a$  به وسیله‌ی مقدار عددی  $w$  تعیین می‌شود. ورودی دیگر مقدار ثابت است که در جمله‌ی اریب  $b$  ضرب شده و سپس با  $wp$  جمع می‌شود. این حاصل جمع ورودی خالص  $n$ ، برای تابع تبدیل یا فعال سازی (محرک)  $f$ ، است. بدین ترتیب خروجی نرون به صورت معادله زیر تعریف می‌شود:

$$a = f(wp + b)$$

پارامترهای  $w$  و  $b$  قابل تنظیم می‌باشند و تابع محرک  $f$  نیز توسط طراح انتخاب می‌شود. بر اساس انتخاب  $f$  و نوع خوارزمیک یادگیری، پارامترهای  $w$  و  $b$  تنظیم می‌گردند. در حقیقت یادگیری به این معنی است که  $w$  و  $b$  طوری تغییر کنند که رابطه‌ی ورودی و خروجی نرون با هدف خاصی مطابقت نماید [۳].

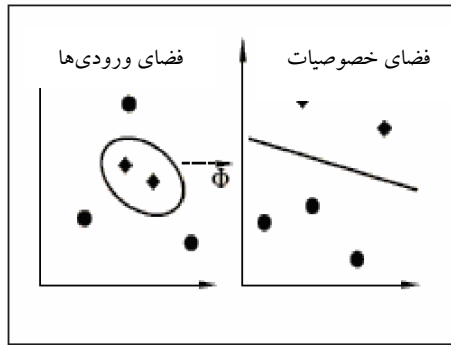
در مورد نحوه‌ی کار نرون‌ها سه نکته‌ی مهم وجود دارد. اول آن‌که نرون‌ها تنها به اطلاعات محلی نیاز دارند. در واقع تمام اطلاعات مورد نیاز یک نرون برای تولید یک مقدار خروجی، در ورودی و خود نرون موجود است و هیچ اطلاعاتی در مورد سایر قسمت‌های شبکه مورد نیاز نیست. دوم آن‌که نرون تنها یک مقدار خروجی تولید می‌کند، که این مقدار خروجی از طریق ارتباطات، به عنوان ورودی به نرون دیگر وارد شده و یا به عنوان خروجی شبکه در نظر گرفته می‌شود. سوم آن‌که هر نرون به صورت مستقل عمل می‌نماید. یعنی خروجی هر نرون تنها وابسته به ورودی آن نرون است [۴].

تابع محرک که به آن تابع فعال‌سازی یا تابع تبدیل نیز گفته می‌شود، ورودی خالص را به خروجی تبدیل می‌کند و بر اساس نیاز خاص مساله‌ای که قرار است به وسیله‌ی شبکه‌ی عصبی حل شود، می‌تواند خطی یا غیرخطی انتخاب شود. در حقیقت تابع محرک ارتباط بین ورودی و خروجی گره‌ها و شبکه را برآورد می‌نماید. تعدادی زیادی تابع محرک می‌تواند وجود داشته باشد اما در عمل تعداد محدودی از توابع محرک مورد استفاده قرار می‌گیرند [۷]. از جمله می‌توان به توابع سیگموئیدی، تانژانت هیپربولیک، سینوسی، کسینوسی و خطی اشاره نمود [۳۶]. در هر صورت، پژوهشگران شبکه‌ی عصبی ترجیح می‌دهند از توابع محرک غیرخطی استفاده کنند. در این میان تابع سیگموئیدی بیش از سایر توابع کاربرد دارد [۵].

#### ماشین‌های بردار حمایتی (SVMs):

یکی از روش‌های هوش مصنوعی که از اواخر دهه‌ی ۱۹۷۰ میلادی توسط Vapnik معرفی شد و پس از آن به علت موارد جذابی که دارند و نتایج عملی امیدبخشی که داشته‌اند، مورد استقبال قرار گرفته‌اند [۲۳]. ماشین‌های بردار حمایتی (svm) ماشین‌های یادگیری هستند که بر مبنای نظریه‌ی یادگیری آماری کار کرده و برای حل مسائل طبقه‌بندی و رگرسیون به کار می‌روند [۱۰]. در طبقه‌بندی دودویی، خوارزمیک ماشین بردار حمایتی یک ابرصفحه می‌سازد که دسته‌ای از بردارهای یادگیری را به دو طبقه تقسیم می‌کند. در مسائل غیرخطی، svmها بردار ورودی  $X$  را با استفاده از روش ترسیم غیرخطی  $\Phi$  به یک فضای خصوصیات چند بعدی تبدیل می‌کند و یک فوق صفحه-ی مطلوب ایجاد می‌کند [۳۵]. هدف svm، بیشینه‌کردن حاشیه‌ی جداسازی و کمینه‌کردن خطای طبقه‌بندی نادرست می‌باشد.

شکل ۲ ایده‌ی عمومی ماشین بردار پشتیبان را نشان می‌دهد که ترسیم داده‌های اولیه در فضای ویژه  $F$  است که " فضای خصوصیات " نامیده می‌شود.



شکل ۲: ایده‌ی کلی ماشین‌های بردار پشتیبان (اقتباس از Hearst, ۲۰۰۶).

این کار از طریق یک معادله‌ی غیر خطی انجام می‌شود:

$$\Phi: RN \rightarrow F,$$

خوارزمیک خطی بالا را در فضای  $F$  اجرا می‌کند. این کار فقط احتیاج به ارزیابی داده‌های اولیه دارد.

$$k(x, y) := (\Phi(x) \cdot \Phi(y)).$$

واضح است که اگر  $F$  چند بعدی باشد، محاسبه‌ی طرف راست معادله‌ی بالا فوق العاده سخت می‌شود. در بعضی موارد یک "هسته‌ی  $K$ " وجود دارد که می‌توان آن را به دست آورد. مثلاً "هسته‌ی چند جمله‌ای" را می‌توان برای ترسیم  $\Phi$  به یک فضای گسترده شامل تمام داده‌های چند بعدی ( $d$  بعدی) متعلق به  $\mathbf{R}^n$  استفاده نمود. مثلاً برای  $d=2$  و  $x, y$  داریم [۲۶]:

$$(x \cdot y)^2 = \left( \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right)^2 = \left( \begin{pmatrix} \sqrt{x_1^2} \\ \sqrt{2x_1x_2} \\ \sqrt{x_2^2} \end{pmatrix} \cdot \begin{pmatrix} \sqrt{y_1^2} \\ \sqrt{2y_1y_2} \\ \sqrt{y_2^2} \end{pmatrix} \right) = (\Phi(x) \cdot \Phi(y)),$$

با در نظر داشتن این که:

$$\Phi(x) = (x_1^2, \sqrt{2}x_1x_2, x_2^2)$$

فرمول SVM را می‌توان بدین صورت نیز بیان نمود:

$$\min \phi(w, \xi) = \frac{1}{2} \|w\|^2 + c \left( \sum_{i=1}^l \xi_i \right)$$

با در نظر گرفتن این که:

$$y_i (< w \cdot x_i > + b) \geq 1 - \xi_i, \xi_i \geq 0, i = 1, \dots, l$$

که در این جا:

$w$ : وزن بردار عمود بر ابر صفحه.

$b$ : پیش‌قدر ابر صفحه‌ی جدا کننده.

$\xi_i$ : متغیر دور افتادگی.

$c$ : آماره‌ای که توسط کاربر مشخص می‌شود و جابجایی‌های لازم بین کلی‌سازی و طبقه‌بندی نادرست را نمایندگی می‌کند [۲۶].

در مسائل غیرخطی، SVMها بردار خروجی  $X$  را به یک صفحه‌ی چند بعدی (ابرفضا) در میان تعدادی روند غیرخطی  $\Phi$  ترسیم کرده و یک فوق صفحه‌ی جدا کننده می‌سازد [۳۵].

در مسائل بهینه‌سازی مربوط به SVM، تابع تصمیم‌گیری به این شکل نشان داده می‌شود:

$$g(x) = \text{sign}(f(x)), \rightarrow f(x) = w^T x + b$$

از تابع تصمیم‌گیری فوق می‌توان دید که نتیجه‌ی روش SVM یک مقدار نشان‌دهنده‌ی احتمال نیست. طبق نظر پلت، می‌توان خروجی‌های SVM را با استفاده از یک تابع سیگموئید به احتمالات تبدیل کرد. احتمال به دست آمده با استفاده از تابع سیگموئید با پارامتر A و B را می‌توان بدین صورت نوشت [۳۳]:

$$p(y = 1|f) = \frac{1}{1 + \exp(Af + B)}$$

در SVM انتخاب C و پارامترهای تابع هسته که تعمیم‌پذیری خوبی داشته باشند یک مسئله‌ی مهم است که می‌توان این کار را با سعی و خطا انجام داد. همچنین می‌توان گفت SVM ابزاری برای فشرده کردن داده‌ها ساختن در مدلی از یک سامانه است [۱۱].

توابع کرنل مورد استفاده عبارتند از: ۱- چند جمله‌ای، ۲- پایه شعاعی گوسی، ۳- پایه شعاعی نمایی، ۴- پرسپترون چند لایه، ۵- سری‌های فوریر، ۶- نواری، ۷- نواری نوع B، ۸- هسته‌های افزایشی، ۹- بسط تنسور. چند نوع رایج ماشین‌های بردار پشتیبان نیز عبارتند از: ۱- c-SVC، ۲- f-SVC و ۳- SVM یک‌کلاسه، برای مسائل طبقه‌بندی، ۴- SVI و ۵- f-SVI برای مسائل رگرسیون.

SVM در مسائل بسیاری به کار گرفته شده است، از جمله در مسائل تشخیص الگو مثل دست‌نوشته [۱۸،۳۵]. تشخیص اشیاء [۱۳] و تشخیص چهره [۳۲]. در مورد تخمین رگرسیون در موارد زیادی استفاده شده است، در مورد داده‌های مصنوعی در مسئله‌ی وارونگی عامل PET [۳۵]. چنانچه ذکر شده است در تمامی این موارد قدرت تعمیم‌پذیری SVM نسبت به سایر روش‌ها بیشتر بود. اما با وجود این تعمیم‌پذیری می‌تواند در موقع اجرا بسیار کند باشد [۱۴،۲۲،۳۲]. به‌طور کلی برای یک امر یادگیری فرضی با یک سری داده‌های آموزشی محدود، در صورتی می‌توان به بهترین تعمیم‌پذیری رسید که تعادل مناسبی بین صحت آن دسته از داده‌های آموزشی و ظرفیت ماشین، که توانایی ماشین برای یادگیری بدون اشتباه هرگونه داده‌ی آموزشی می‌باشد، برقرار گردد [۱۷].

این روش در عرصه‌های مربوط به اقلیم نیز در مواردی به کار رفته است از جمله برای مسیریابی و مکان‌یابی تورنادو [۱۰]، تغییرات بارندگی در سناریوهای تغییر اقلیم [۳۴]، طبقه‌بندی خاک [۱۲]، پیش‌بینی طوفان گرد و خاک [۴۱]، پیش‌بینی سری‌های زمانی هیدرولوژیکی [۴۰]، پیش‌بینی سرعت روزانه‌ی باد [۳۰] و نیز در بسیاری کارهای علوم زیستی به کار گرفته شده است.

روش‌های قبلی شبکه‌های عصبی مصنوعی از مشکلات متعددی در هنگام تعمیم‌پذیری رنج می‌برند که نتیجه‌ی آن ایجاد مدل‌هایی است که بیش از حد بر اساس داده‌های موجود برازش یافته‌اند. این امر در نتیجه‌ی استفاده از خوارزمیک‌های تعمیم‌پذیری است که برای انتخاب عوامل و روش‌های آماری مورد استفاده در انتخاب بهترین مدل از آن‌ها بهره گرفته می‌شود [۲۳].

## روش تحقیق:

### داده‌ها و منطقه‌ی مورد مطالعه:

استان سیستان و بلوچستان در جنوب‌خاوری ایران و در مختصات جغرافیایی ۲۵° ۳' تا ۲۸° ۳۱' عرض شمالی و ۴۷° ۵۸' تا ۶۳° ۱۹' طول شرقی واقع شده است. ناحیه‌ی سیستان ۱۵۱۹۷ کیلومتر مربع وسعت دارد و در

قسمت شمالی استان واقع شده است. این ناحیه حوزه مسطح و مسدودی است که از آبرفت های دلتای قدیمی و فعلی رود هیرمند تشکیل شده است. شهر زابل دارای اقلیم بیابانی گرم و خشک می باشد. میانگین بارش سالانه در این شهرستان ۵۹/۶ میلی متر و متوسط دمای آن در سال ۱۳۸۲ از ۴۹ الی ۹/۵- درجه سانتی گراد در تغییر است [۳].

### انتخاب پارامترهای ورودی:

در روش های هوش مصنوعی هر قدر تعداد پارامترهای مرتبط بیشتر باشد می توان انتظار داشت که به جواب های بهتر رسید. با این حال افزایش حجم داده ها می تواند در سرعت همگرایی شبکه تأثیر گذاشته و باعث شود تا سرعت پردازش اطلاعات کند شده و محاسبات سنگین تر توسط رایانه رسیدن به جواب را به تأخیر می اندازد. برای همین بایستی سعی کرد تا با روشی بهترین و مناسب ترین پارامترها را برای معرفی به عنوان ورودی به این روش ها انتخاب کرد. در این مطالعه از روش تحلیل مؤلفه ای اول استفاده شده است.

برای استفاده از تکنیک تحلیل مؤلفه ای اول، راه معمول استفاده از نرم افزارهای آماری موجود از قبیل Minitab، SPSS و XLSTAT و سایر نرم افزارهای موجود است. به دلیل قابلیت های بالای نرم افزار MATLAB، در این مطالعه با استفاده از کدنویسی، کد مربوط به این نوع تحلیل در محیط نرم افزار مذکور نوشته شده و سپس با ورودی های متعدد اقدام به تحلیل مؤلفه ای اول و انتخاب بهترین و مناسب ترین پارامترها، شد.

پارامترهای ورودی به نرم افزار برای انجام تحلیل مؤلفه ای اول، عبارت بودند از: حداکثر سرعت باد، جهت وزش سریع ترین باد، ساعت وزش سریع ترین باد، میزان بارش، میزان فشار ایستگاه، دمای نقطه ی شبنم، و وقوع طوفان گرد و خاک نیز به عنوان پارامتر خروجی در نظر گرفته شد. در هنگام ثبت داده ها در ایستگاه های هواشناسی سینوپتیک، هوایی که غبار داشته یا طوفان شن یا گرد و خاک رخ داده باشد به چند دسته تقسیم می شود که مبنای این تقسیم بندی نیز بیشتر مقدار دید افقی است [۳۷] و البته برگرداندن این اصطلاحات به فارسی نیز چندان آسان نیست. ما در این تحقیق به پیش بینی مواردی از این طوفان ها پرداخته ایم که دید افقی در آن ها به کمتر از ۱۰۰۰ متر می رسد و طوفان گرد و خاک (Dust storm) نامیده می شوند [۲۰]. اما از آن جا که مدل در اجراهای اولیه نتایج خوبی نشان نداد، کدهای مربوط به طوفان از داده ها استخراج شده و دید افقی به عنوان یک پارامتر به مدل svm معرفی گردید.

از آن جا که در تمام روش های هوش مصنوعی برای آموزش شبکه احتیاج به مقداری داده های قبلی است، در این تحقیق نیز با استفاده از داده های ۲۰ ساله ی هواشناسی اقدام به آموزش، آزمون و اعتبارسنجی شبکه شد. برای این منظور داده های آماری از سال ۱۹۸۰ تا ۲۰۰۵ میلادی به سه قسمت: ۷۰ درصد برای آموزش، ۱۵ درصد برای آزمون و ۱۵ درصد باقیمانده برای اعتبارسنجی مدل، تقسیم شدند. از آن جا که مشکل بیش برآزش در این دو روش از هوش مصنوعی پیش می آید [۲۴]، داده های بخش اعتبارسنجی برای جلوگیری از به وجود آمدن مشکل بیش برآزش در نظر گرفته شده اند [۶].

در پایان نتایج حاصل از مدل ها (خروجی ها) و رخداد های واقعی طوفان با همدیگر مقایسه شده و از معیارهای میانگین مربعات خطا (MSE)، متوسط قدر مطلق خطا (MAE) که نشان دهنده ی میزان خطای مدل با بعد متغیر ها می باشد، و ضریب همبستگی ( $R^2$ )، برای نشان دادن عملکرد مدل ها استفاده شده است. این سه معیار به صورت زیر محاسبه می شوند:

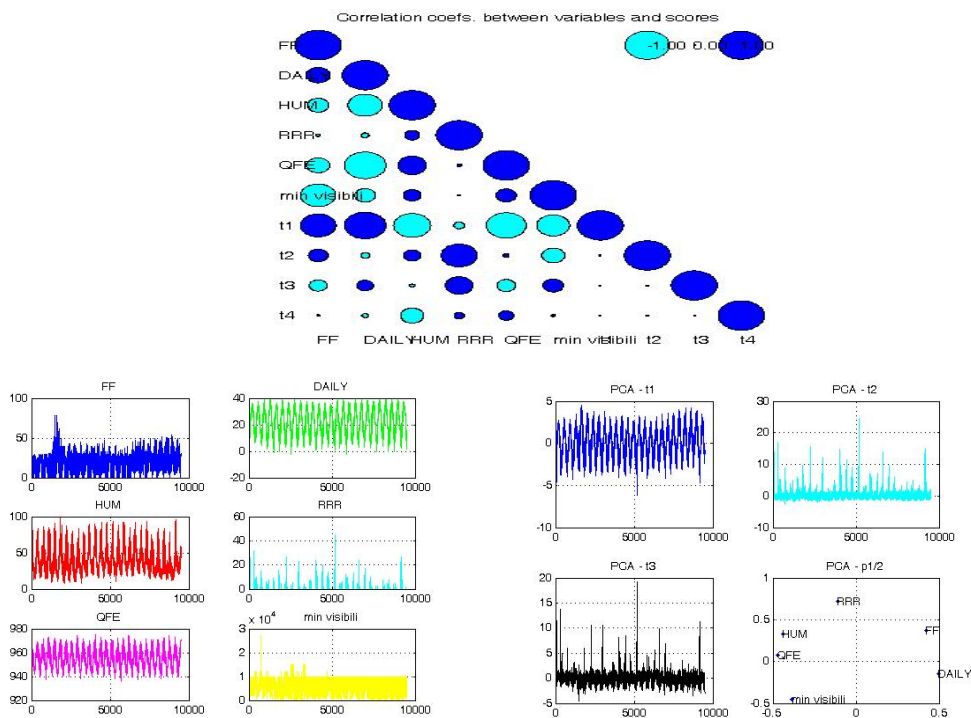
$$MAE = \frac{\sum_{k=1}^k |X_k - Y_k|}{K}, \quad RMSE = \sqrt{\frac{\sum_{k=1}^k (X_k - Y_k)^2}{K}}, \quad R^2 = \frac{\sum_{k=1}^k X_k Y_k}{\sqrt{\sum_{k=1}^k X_k^2 \sum_{k=1}^k Y_k^2}}$$

که در این روابط  $X_k$  مقدار مشاهداتی،  $Y_k$  مقدار برآورد شده و  $K$  تعداد داده‌ها می‌باشد.

### نتایج:

در این قسمت با ارائه‌ی نمودارهای به دست آمده و مقادیر محاسبه شده، عملکرد هر مدل در شبیه‌سازی و پیش‌بینی ۲۴ ساعته‌ی طوفان گرد و خاک (دید افقی زیر ۱۰۰ متر) و نیز حداقل دید افقی روزانه که می‌تواند نماینده‌ی وقوع طوفان باشد، مورد ارزیابی قرار می‌گیرد. برای این کار از داده‌های تابستان ۲۰۰۴ (ماه‌های ژوئن تا آگوست) استفاده شد که یک از طوفانی‌ترین تابستان‌های چند سال اخیر بوده است.

ابتدا با استفاده از تکنیک PCA و نیز نرم‌افزار SPSS نسبت به انتخاب بهترین ورودی‌ها به شبکه اقدام گردید. آن‌جا که در این روش‌ها انتخاب تعداد زیاد عوامل باعث کند شدن روند کار می‌گردد و از طرفی عوامل که همبستگی زیادی بین آن‌ها وجود داشته باشد نمی‌تواند تأثیر چندانی در بهبود عملکرد مدل داشته باشند، نیاز به این نوع تحلیل آماری احساس می‌شود. نتایج نشان می‌دهند سرعت باد مهمترین عامل است. اما دو عامل دیگر یعنی دمای میانگین روزانه و رطوبت نسبی نیز منظور گردیده‌اند که در رتبه‌های بعدی قرار دارند.




شکل شماری ۳: نتایج آنالیز تحلیل مؤلفه‌ی اول که نشان می‌دهد عوامل سرعت باد حداکثر، دمای میانگین روزانه و رطوبت نسبی هوا بیشترین اهمیت را در انتخاب پارامترها دارند.


### بحث:

نتایج به دست آمده نشان می‌دهد با داده‌های موجود و با روشی که در پیش گرفته شد، روش ماشین بردار پشتیبان نتایج بهتری نشان می‌دهد. هرچند که این نتایج در قسمت پیش‌بینی چندان نسبت به نتایج به دست آمده از روش


شبکه‌های عصبی مصنوعی، جواب‌های بهتری ارائه نمی‌دهند اما می‌توان با تحقیقات بیشتر و یافتن راه‌های مناسب- تر ساختن مدل‌های بر پایه‌ی این روش، امیدوار به گرفتن نتایج بهتر بود.



شکل شماره ۴: نتایج شبیه‌سازی (سمت راست) و پیش‌بینی ۲۴ ساعته (سمت چپ) برای رخداد های طوفان گرد و خاک (دید افقی زیر ۱۰۰۰ متر) با استفاده از روش ماشین بردار پشتیبان.




شکل شماره ۵: نتایج شبیه‌سازی (سمت راست) و پیش‌بینی ۲۴ ساعته (سمت چپ) برای حداقل دید افقی با استفاده از روش ماشین بردار پشتیبان.



شکل شماره ۶: نتایج پیش‌بینی ۲۴ ساعته با روش شبکه‌ی عصبی مصنوعی برای رخداد طوفان گرد و خاک (دید افقی زیر ۱۰۰۰ متر).





شکل شماره ۷: نتایج پیش‌بینی ۲۴ ساعته با روش شبکه‌ی عصبی مصنوعی برای حداقل دید افقی.

از آن‌جا که استفاده از نوع  $f$ -SVR و تابع کرنل پایه شعاعی (RBF) بهترین جواب‌ها را داده است، توصیه می‌شود در مطالعات دیگر نیز قابلیت‌های این موارد مورد بررسی قرار گیرد. استفاده از روش شبکه‌های عصبی مصنوعی، استفاده از خوارزمیک یادگیری لونیبرگ-مارکوادرات باعث بهبود چشمگیری در نتایج شد بنابراین توصیه می‌شود در اینگونه مطالعات از این خوارزمیک استفاده شود. در انتخاب نوع شبکه معمولاً از شبکه‌های پیشخور، المان-جردن و بازگشتی استفاده می‌شود. در این مطالعه ضمن استفاده از شبکه-ی پیشخور از شبکه‌ی پایه شعاعی هم استفاده شد که این نوع شبکه نتایج بهتری نشان داده و موثرتر نشان داد.

#### منابع:

- ۱- انواری، م. ۱۳۸۶. منشاء یابی رسوبات بادی دشت سیستان، مطالعه‌ی موردی: جزینک. پایان‌نامه‌ی کارشناسی ارشد، دانشگاه زابل، زابل.
- ۲- ایرانمنش، ف.، م. عرب‌خداری و م. اکرم. ۱۳۸۴. بررسی مناطق برداشت ذرات گرد و غبار و ویژگی‌های انتشار آن‌ها در طوفان‌های منطقه‌ی سیستان با استفاده از پردازش تصاویر ماهواره‌ای. مجله‌ی پژوهش و سازندگی رد منابع طبیعی: ۶۷، صص ۲۵-۳۳.
- ۳- پیری، ج. ۱۳۸۵. پایان‌نامه‌ی کارشناسی ارشد رشته‌ی زهکشی، دانشگاه شیراز، شیراز.
- ۴- تمدن، س. ۱۳۸۱. کاربرد هوش مصنوعی در مهندسی صنایع، پایان‌نامه کارشناسی ارشد رشته‌ی صنایع، دانشگاه امیرکبیر، تهران.
- ۵- دلاوری، م. ۱۳۸۴. بررسی تغییرات تراز آب دریاچه‌ی ارومیه. پایان‌نامه‌ی کارشناسی ارشد رشته‌ی آبیاری، دانشگاه تربیت مدرس، تهران.
- ۶- رضایی، ع. ۱۳۸۳. مدل‌سازی منطقه‌ای دبی‌های اوج زیرحوزه‌های آبخیز سد سفیدرود با استفاده از شبکه‌های عصبی مصنوعی. پایان‌نامه‌ی دکتری آبخیزداری. دانشگاه تهران. تهران.
- ۷- منهای، م. ۱۳۷۷. مبانی شبکه‌های عصبی (هوش محاسباتی)، نشر دکتر حسابی، تهران.
- ۸- مهندسین مشاور جامع ایران. ۱۳۸۲. مطالعات جامع اراضی سیستان. بخش اقلیم.

۹- میری، ع. ۱۳۸۴. بررسی تأثیر فرسایش بادی بر شهر زابل. پایان‌نامه‌ی کارشناسی ارشد رشته‌ی مدیریت مناطق بیابانی، دانشگاه تهران، تهران.

- 10- Adrianto, I. 2006. Support vector machine: an introduction. School of industrial engineering. University of uklamoma.
- 11- Asli, C. and I.B. Turksen. 2007. Fuzzy functions with support vector machines. *Journal of Information science*: 177, 5163-5177.
- 12- Bhattacharya, B., D.P. Solomatine. 2006. Machine learning in soil classification. *Journal of Neural Networks*: 19, 186-195.
- 13- Blanz, V., B. Scholkopf, H. Bulthoff, C. Burges, V. Vapnik, and T. Vetter. 1996. Comparison of view-based object recognition algorithms using realistic 3D models. *Artificial Neural Networks* : 96, 251 - 256.
- 14- Burges, C.J.C. 1996. Simplified support vector decision rules. *International Conference on Machine Learning*. Bari, Italy. 71-77pp.
- 15- Cerda-Villafana, G. 2005. *Artificial Intelligence Techniques in Flood Forecasting*. University of Bristol. 240 p.
- 16- Chin K. K. 1998. *Support Vector Machines applied to Speech Pattern Classification*. Engineering Department. Cambridge University. England.
- 17- Christopher j. c. burges. 1998. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2, 121-167. Kluwer Academic Publishers, Boston.
- 18- Cortes, C. and V. Vapnik. 1995. Support vector networks. *Machine Learning*, 20:273 - 297.
- 19- Dierckx, P. 1993. *Curve and Surface Fitting with Splines*. Monographs on Numerical Analysis. Clarendon Press, Oxford.
- 20- Engelstaedter, S. 2001. *Dust Storm Frequencies and Their Relationship to Land Surface Conditions*. Friedrich-Schiller University. Berlin.
- 21- Ginsberg, M. L. (1993) *Essentials of Artificial Intelligence*. Morgan Kaufmann Publishers, Inc., San Francisco, first edition.
- 22- Girosi, F. 1997. An equivalence between sparse approximation and Support Vector Machines. A.I. Memo 1606, MIT Artificial Intelligence Laboratory.
- 23- Gunn, S.R. 1998. *Support Vector Machines for Classification and Regression*. University of Southampton. 66p.
- 24- Han, D. 2007. Flood Forecasting Using Support Vector Machines. *Journal of Hydroinformatics*: 9, 267-276.
- 25- Haykin, S. 1999. *Neural Networks: A Comprehensive Foundation*. 2nd ed. Prentice Hall, New Jersey.
- 26- Hearst, M.A. 2006. *Support Vector Machines*. University of California. Berkeley.
- 27- Hsu, N. 2004. *Near Real Time Detection and Monitoring of Dust Events by Satellite (Sea-WiFS, MODIS and TOMS)*. University of Maryland.
- 28- Jain, S.K. Das, A. and Srivastava, D.K. 1999. Application of ANN for reservoir inflow prediction and operation, *Journal of Water Resources Planning and Management*: 125(5), 263 - 271.
- 29- Luger, G. F. 1998. *Artificial Intelligence. Structures and Strategies for Complex Problem Solving*. Addison-Wesley, Reading, MA, third edition.
- 30- Mohandes, M.A., T. O. Halawani, S. Rehman, A.H. Ahmed. 2004. Support vector machines for wind speed Prediction. *Journal of Renewable Energy*: 29, 939-947.
- 31- Nilsson, N. J. 1998. *Artificial Intelligence: a new synthesis*. Morgan Kaufmann Publishers, Inc., San Francisco, first edition.

- 32- Osuna, E. and F.Girosi. 1998. Reducing the run-time complexity of support vector machines. In International Conference on Pattern Recognition (submitted).
- 33- Platt, J. C. 1999. Probabilistic outputs for support vector machines and comparisons to Regularized likelihood methods. MIT Press. 61-74 pp.
- 34- Tripathi, S., V.V. Srinivas, Ravi S. Nanjundiah . 2006. Downscaling of precipitation for climate change scenarios: A support vector machine approach. Journal of Hydrology: 330, 621– 640.
- 35- Vapnik, V. N. 1998. Statistical Learning Theory. Springer Verlag. New York.
- 36- Vemuri, V. 1998. artificial neural networks, theoretical concepts. Washington, dc: IEEE computer society press.
- 37- Westwell, I. 1999. Fact finder Guide Weather. PRC Publishing. Pp57-58.
- 38- Wetphal, D.L. 2006. Status and Future of Dust Storm Forecasting. Available in naval research laboratory.
- 39- Winston, P. H. 1992. Artificial Intelligence. Addison-Wesley, third edition.
- 40- Xinying Yu, Shie-Yui Liong. 2007. Forecasting of hydrologic time series with ridge regression in feature space. Journal of Hydrology: 332, 290– 302.
- 41- ZHI-YING L., Z. QI-MENG, Z. ZHI-CHAO. 2006. SVM in the sand-dust storm forecasting. Proceedings of the Fifth International Conference on Machine Learning and Cybernetics, Dalian, 13-16 August 2006.