



## مقایسه دقت روش‌های رگرسیونی و هوش مصنوعی در برآورد سرعت روزانه باد در منطقه سیستان

افروز آبتین<sup>۱</sup>، حسین پیری صحراگرد<sup>۲\*</sup>، احمد پهلوانروی<sup>۳</sup>، جمشید پیری<sup>۴</sup>

- ۱- دانش آموخته کارشناسی ارشد بیابان‌زدایی دانشکده آب و خاک، گروه مرتع و آبخیزداری، دانشگاه زابل
- ۲- استادیار گروه مرتع و آبخیزداری، دانشکده آب و خاک، دانشگاه زابل
- ۳- دانشیار گروه مرتع و آبخیزداری، دانشکده آب و خاک دانشگاه زابل
- ۴- عضو هیئت علمی گروه مهندسی آب، دانشکده آب و خاک، دانشگاه زابل

\* نویسنده مسئول: [hopyry@uoz.ac.ir](mailto:hopyry@uoz.ac.ir)

تاریخ دریافت: ۱۳۹۴/۰۵/۲۸ تاریخ پذیرش: ۱۳۹۵/۰۵/۰۵

### چکیده

پژوهش حاضر با هدف مقایسه دقت پیش‌بینی روش‌های رگرسیونی، شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی در برآورد سرعت باد در منطقه سیستان انجام شد. برای این منظور از داده‌های روزانه ایستگاه‌های هواشناسی سینوپتیک زابل و زهک طی یک دوره پنج ساله (۲۰۱۵-۲۰۱۰) استفاده شد. برای مدل‌سازی به روش شبکه عصبی مصنوعی و سیستم استنتاج فازی از نرم‌افزار MATLAB و برای مدل‌سازی با روش‌های رگرسیونی از نرم‌افزار DATA FIT استفاده شد. دقت روش‌ها با استفاده از آماره‌های جذر میانگین مربعات خطا، شاخص تطابق و میانگین قدر مطلق خطا مورد ارزیابی قرار گرفت. براساس تحلیل حساسیت انجام‌شده، متغیرهای متوسط درجه حرارت روزانه، متوسط رطوبت نسبی، ساعت آفتابی و میزان تبخیر از تشتک به‌عنوان متغیرهای ورودی مدل‌های رگرسیونی و هوش مصنوعی در نظر گرفته شد و متغیر سرعت باد نیز به‌عنوان خروجی در نظر گرفته شد. بر اساس نتایج، متوسط درجه حرارت روزانه و متوسط رطوبت نسبی به‌ترتیب، بیش‌ترین و کمترین تأثیر را بر سرعت باد در منطقه سیستان دارند (به‌ترتیب ضریب همبستگی ۰/۴۲ و ۰/۲۵). علاوه بر این، نتایج بیانگر آن است که در بین روش‌های مورد استفاده روش نروفازی با تابع عملگر گوسین در برآورد سرعت باد دارای عملکرد دقیق‌تری است (جذر میانگین مربعات خطا، ۲/۵۶). درحالی‌که مجذور میانگین مربعات خطا برای مدل رگرسیون ۴/۴۴ می‌باشد. همچنین ضریب تشخیص روابط رگرسیون (۰/۵۱ و ۰/۴۵) نیز در مقایسه با مدل پرسترون چندلایه و مدل نروفازی (۰/۵۲ و ۰/۵۱) در هر دو ایستگاه کمتر است. بر این اساس پیشنهاد می‌گردد جهت تخمین و پیش‌بینی دقیق‌تر سرعت باد در منطقه سیستان از روش نروفازی استفاده شود تا با برآورد دقیق این مؤلفه، علاوه بر برنامه‌ریزی جهت کاهش خسارات ناشی از وزش بادهای شدید، امکان بهره‌برداری بهینه از این منبع انرژی نیز فراهم شود.

**واژگان کلیدی:** تحلیل حساسیت؛ میانگین مربعات خطا؛ روش نروفازی؛ ضریب تشخیص

## ■ مقدمه

باد یکی از عناصر اصلی در اقلیم هر منطقه محسوب می‌شود و تغییرات و اثرات آن می‌تواند بر پدیده‌های مختلفی مانند طوفان‌های گردوغبار و شدت تبخیر و تعرق تأثیرگذار باشد (۸، ۲۸). از سوی دیگر، سرعت باد یکی از مؤلفه‌های مهم در معادلات برآورد تبخیر و تعرق می‌باشد و بروز هرگونه تغییر در سرعت باد بر میزان نیاز آبی گیاهان نیز مؤثر خواهد بود (۱۰) به‌همین دلیل اندازه‌گیری سرعت باد در مناطق مختلف بسیار حائز اهمیت است. از مزایای تخمین پارامترهای باد، محاسبه تبخیر و تعرق، پیش‌بینی سرعت پراکندگی گرد و غبار و توانایی کنترل و تنظیم توربین‌های بادی در یک منطقه است (۹). همچنین اندازه‌گیری سرعت باد، به‌عنوان یک منبع تجدیدپذیر دارای اهمیت ویژه‌ای است (۱).

از سوی دیگر، باد از جمله پارامترهای آب‌وهوایی است که به‌عنوان عامل اصلی فرسایش بادی و زمینه‌ساز افزایش خشکی در مناطق بیابانی از آن یاد می‌شود. از این جهت بررسی آن می‌تواند به‌عنوان یک عامل اقلیمی در تشدید یا تضعیف شرایط بیابان‌زایی مؤثر باشد زیرا وقوع بادهایی با سرعت بیش از سرعت آستانه فرسایش خاک سبب تشدید فرایند بیابان‌زایی می‌گردد (۲۰). تغییرات سرعت باد از جنبه‌های مختلفی دارای اهمیت است، زیرا این تغییرات می‌تواند منجر به کاهش سرعت باد، کاهش انتقال گرما و افزایش درجه حررات شود. علاوه بر این افزایش ناگهانی سرعت باد، سبب وقوع تندبادها، گردبادها و ایجاد خسارت در منطقه وقوع خواهد شد علاوه بر این، پیش‌بینی سرعت باد به‌دلیل تأثیر در افزایش یا کاهش آلودگی و همچنین پیش‌بینی افزایش یا کاهش تولید انرژی بادی از اهمیت قابل ملاحظه‌ای برخوردار است (۲۵).

با توجه به اهمیت موضوع، مطالعات متعددی در مورد برآورد سرعت باد با روش‌های مختلف انجام شده است که به‌اختصار به برخی از این پژوهش‌ها اشاره می‌شود. تخمین سرعت باد از دو روش شبکه عصبی مصنوعی و روش آماری میانگین متحرک اتو رگرسیونی نشان داد که روش شبکه عصبی مصنوعی در پیش‌بینی سرعت باد نسبت به روش دیگر مورد استفاده دارای دقت بالاتری است (۵).

همچنین پیش‌بینی سرعت باد با استفاده از شبکه عصبی مصنوعی به‌منظور ایجاد نیروگاه بادی نشان داد که از این روش می‌توان به‌عنوان یک ابزار قدرتمند در پیش‌بینی سرعت باد استفاده کرد (۱۴). علاوه بر این، گزارش شده است که مدل‌های شبکه عصبی مصنوعی به‌منظور برآورد سرعت باد و تعیین تعداد مطلوب توربین‌های بادی از دقت قابل قبولی برخوردار هستند (۶). بررسی امکان پیش‌بینی سرعت باد با استفاده از مدل‌های هیبرید شبکه‌های عصبی، شبکه‌های فازی-عصبی و تئوری موجک در منطقه یزد نیز نشان داد که شبکه‌های عصبی موجکی و فازی-عصبی موجکی نسبت به مدل‌های شبکه عصبی و فازی-عصبی از نظر عملکرد دارای برتری هستند (۱).

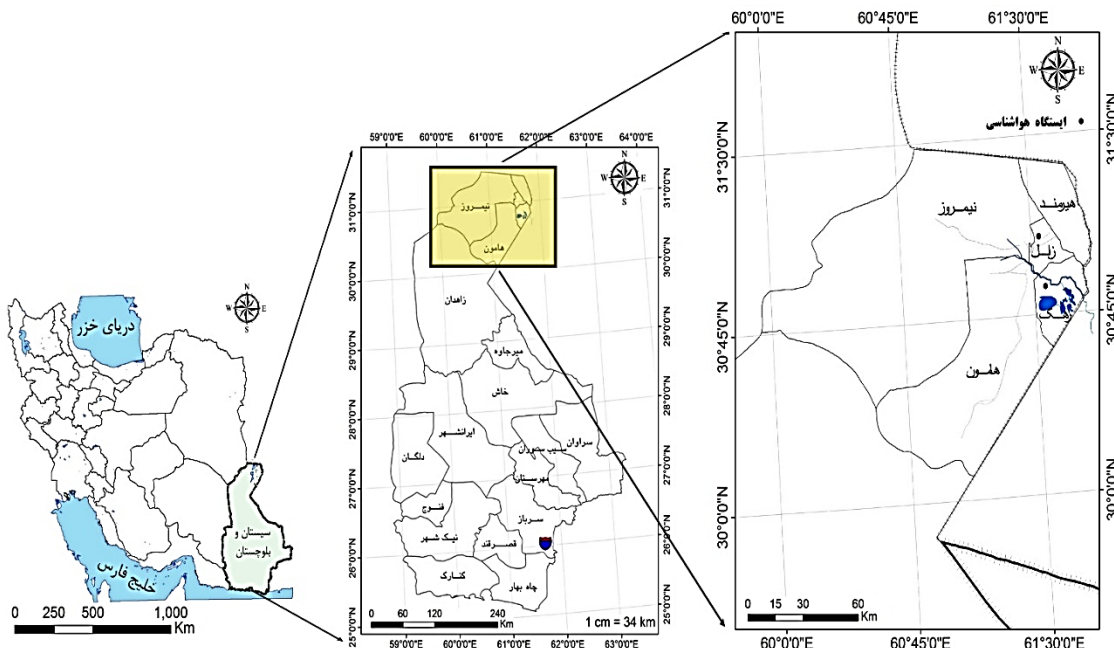
منطقه سیستان یکی از مهم‌ترین کانون‌های تحت تأثیر عامل‌های باد است و هر ساله افزایش ناگهانی سرعت باد سبب وقوع خسارات زیادی در بخش‌های مختلف می‌گردد و تأثیر غیر قابل انکاری بر تمامی جنبه‌های اکولوژیکی، اقتصادی و اجتماعی آن گذاشته و باعث می‌شود شرایط زیست‌محیطی بحرانی در منطقه حاکم گردد (۱۵). در اثر وقوع طوفان‌های شدید گردوغبار و جابجایی توده‌های عظیم شن توسط این طوفان‌ها، پل‌ها، راه‌های ارتباطی، اماکن و تأسیسات زیربنایی سیستان در آستانه نابودی قرار گرفته است. بنابراین با مطالعه تغییرات سرعت باد با استفاده از روش‌های مختلف، شناخت عوامل مؤثر در سرعت باد و دستیابی به نتایج دقیق‌تر می‌توان گامی مؤثر در جهت کنترل کانون‌های برداشت ذرات گردوغبار در منطقه برداشت و راهکارهایی علمی جهت کاهش تبعات منفی این پدیده در هر منطقه ارائه کرد (۱۳). با عنایت به موارد ذکر شده و وزش بادهای ۱۲۰ روزه در منطقه سیستان که مشکلات متعددی مانند فرسایش خاک، خسارت به جاده‌ها و کانال‌های آبرسانی و تأسیسات، افزایش دما و کاهش رطوبت موجود در محیط، خسارت به محصولات کشاورزی و افزایش شیوع بیماری‌های تنفسی، گوارشی و چشمی را به‌همراه دارد، مطالعه سرعت باد و تغییرات زمانی آن به‌منظور مقابله با اثرات منفی ناشی از این پدیده و برنامه‌ریزی جهت اتخاذ تدابیر پیشگیرانه و نهایتاً استفاده از آن به‌عنوان یک منبع

## ■ مواد و روش‌ها

### معرفی منطقه مورد مطالعه

منطقه سیستان با وسعت ۱۵۱۹۷ کیلومتر مربع (معادل ۸/۱ مساحت استان) در جنوب شرق ایران و قسمت شمالی استان سیستان و بلوچستان واقع شده است. موقعیت منطقه مورد مطالعه در شکل (۱) نشان داده شده است. این سرزمین شامل جلگه‌ای پست و هموار در منتهی‌الیه مرز شرقی کشور ایران بین ۳۰ درجه و ۵ دقیقه تا ۳۱ درجه و ۲۸ دقیقه عرض جغرافیایی و ۶۰ درجه و ۱۵ دقیقه تا ۶۱ درجه و ۵۰ دقیقه طول جغرافیایی در جنوب شرقی ایران و شمالی‌ترین قسمت استان سیستان و بلوچستان قرار دارد. سیستان سرزمینی خشک با نزولات جوی بسیار کم است و با بارندگی کمتر از ۷۰ میلی‌متر یکی از نواحی خشک کشور به حساب می‌آید. یکی دیگر از مهم‌ترین ویژگی‌های سیستان وزش بادهای ۱۲۰ روزه است که معمولاً از اوایل خرداد شروع و تا پایان شهریورماه ادامه می‌یابد (۱۳).

انرژی تجدیدپذیر از ضروریات اجتناب‌ناپذیر است. از سوی دیگر، با توجه به اهمیت موضوع و وجود روش‌های مختلف برای برآورد سرعت باد ضروری است دقت هر یک از این روش‌ها و ملزومات آنها مورد بررسی قرار گیرد و روش‌های دقیق‌تر جهت برآورد سرعت باد انتخاب گردد تا بتوان با آگاهی از سرعت باد و تغییرات آن، علاوه بر کاهش خطرات احتمالی، برنامه‌ریزی‌های علمی و دقیقی را جهت تبدیل این تهدید به فرصت در منطقه سیستان انجام داد. با عنایت به این نکات مهم، پژوهش حاضر با هدف شناخت تأثیرگذارترین عوامل اقلیمی بر تغییرات سرعت باد در منطقه سیستان و مقایسه دقت روش‌های رگرسیون (خطی و غیرخطی)، روش‌های شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی در برآورد این مؤلفه (سرعت باد) در منطقه سیستان انجام شد.



شکل ۱- موقعیت مکانی ایستگاه‌های مورد بررسی در منطقه تحقیق

سینوپتیک زابل و زهک) طی یک دوره آماری پنج ساله آماری (۲۰۱۵-۲۰۱۰) استفاده شد. مشخصات این ایستگاه‌ها در جدول (۱) آمده‌است. در این پژوهش،

### جمع‌آوری و تجزیه و تحلیل داده‌ها

در پژوهش حاضر به منظور تخمین سرعت باد در منطقه سیستان از داده‌های روزانه ایستگاه‌های هواشناسی

خطی و غیرخطی تخمین زده‌شد و مقدار سرعت باد برآورد شد. قبل از انجام تحلیل رگرسیون، پیش فرض‌های تحلیل رگرسیون (مستقل بودن مشاهدات، نرمال بودن توزیع داده‌ها و...) بررسی شد.

متغیرهای متوسط درجه حرارت روزانه، متوسط رطوبت نسبی، ساعت آفتابی و میزان تبخیر از تشتک به‌عنوان متغیرهای وابسته و سرعت باد نیز به‌عنوان متغیر مستقل در نظر گرفته شد. به‌منظور مقایسه دقت برآورد روش‌های مورد استفاده، ابتدا با استفاده از تحلیل رگرسیون چندمتغیره در نرم‌افزار DATA FIT ضرایب رگرسیون

جدول ۱- مشخصات ایستگاه‌های هواشناسی سینوپتیک زابل و زهک

ردیف	نام ایستگاه	نوع ایستگاه	عرض جغرافیایی	طول جغرافیایی	ارتفاع (m)	میانگین دما (°C)	میانگین بارندگی (mm)	نوع اقلیم
۱	زابل	فرودگاهی	۰۲° ۳۱'	۰۲۹° ۶۱'	۴۸۹	۲۲/۲	۵۵/۴	خشک و گرم
۲	زهک	کشاورزی	۵۴° ۳۰'	۴۱° ۶۱'	۸۹۵	۲۲/۹	۴۵/۸	خشک و گرم

برای تعیین معماری مدل شبکه عصبی پرسپترون چندلایه<sup>۱</sup>، تعداد زیادی شبکه با ساختار مختلف و با تغییر پارامترهای قابل تنظیم (تابع انتقال، قانون یادگیری، تعداد لایه میانی، تعداد نرون لایه میانی) با استفاده از نرم‌افزار MATLAB R2008a ساخته و اجرا شدند و شبکه بهینه با استفاده از آماره‌های جذر میانگین مربعات خطا<sup>۲</sup>، شاخص تطابق<sup>۳</sup>، میانگین قدر مطلق خطا<sup>۴</sup> و ضریب تبیین تعیین شد (روابط ۲، ۳ و ۴). معیار میانگین مربعات خطا، دقت مدل را بر اساس تفاضل بین مقادیر واقعی و مقادیر برآورد شده ارزیابی می‌کند و هر چه مقدار آن کمتر و به صفر نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است. شاخص تطابق نیز بیانگر عملکرد مدل بوده و مقدار آن بین صفر و یک است که هر چه به یک نزدیک‌تر باشد بهتر است. میانگین قدر مطلق خطا بیانگر مقدار متوسط خطا بوده و هر چه کمتر باشد، نشان‌دهنده دقت بیشتر است (۱۶). همچنین ضریب تبیین میزان همبستگی بین مقادیر برآورد شده توسط مدل و مقادیر واقعی می‌باشد. مقدار این ضریب بین صفر و یک قرار داشته و هر چه

کل داده‌های مورد استفاده برای طراحی مدل‌های هوش مصنوعی ۲۰۷۲ داده بود (داده‌های مربوط به متغیرهای مستقل و متغیر وابسته) که از این تعداد ۱۰۰۰ داده (مربوط به متغیر وابسته) از کل داده‌ها برای آموزش شبکه و ۶۰۰ داده برای آزمایش کارایی مدل‌ها مورد استفاده قرار گرفت. علاوه بر این، ۲۰ درصد از کل داده‌ها (۴۷۲ داده) از قبل به‌منظور اعتبارسنجی مدل‌های حاصل کنار گذاشته شده بودند و وارد مدل نشدند. به‌منظور افزایش دقت و سرعت در آموزش شبکه ابتدا داده‌ها با استفاده از رابطه (۱) استاندارد شد به‌طوری‌که تمامی داده‌ها بین صفر و یک قرار گرفتند. در این رابطه Z داده استاندارد شده،  $X_i$  داده مورد استفاده و  $X_{max}$  و  $X_{min}$  به ترتیب بیشترین و کمترین داده در هر یک از متغیرهاست (۴).

$$Z = \frac{(X_i - X_{min})}{X_{max} - X_{min}} \quad (1)$$

- 1 - Multi Layer Perceptron =MLP  
 2- Root Mean Square Error  
 3- Index of operation  
 4- Mean Absolute Error

در این رابطه  $\bar{y} =$  میانگین مقادیر مشاهده شده و  $N =$  تعداد نمونه‌ها می‌باشد.  $\hat{y}_i =$  داده مشاهده شده و  $y_i =$  داده پیش‌بینی شده است.  $p'_i =$  داده پیش‌بینی شده است و  $o'_i =$  داده مشاهده شده است.

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - P_i| \quad (۴)$$

در این رابطه  $\hat{y}_i =$  داده مشاهده شده و  $y_i =$  داده پیش‌بینی شده است.

### ■ نتایج

#### تحلیل حساسیت داده‌ها

به منظور بررسی تأثیر ترکیب‌های مختلف از متغیرهای ورودی بر مقدار خطا، با اجرای تحلیل حساسیت، برای هر مدل شبکه عصبی، داده‌های ورودی غیرمرتبط شناسایی شد. با انجام این تحلیل داده‌های ورودی که مدل حساسیت کمتری به آنها داشت، شناسایی و از تحلیل کنار گذاشته شد. لازم به ذکر است که حذف این داده‌ها علاوه بر افزایش دقت مدل‌ها، هزینه جمع‌آوری داده‌ها را نیز کاهش می‌دهد (۷). نتایج حاصل از تحلیل حساسیت داده‌ها نشان داد که ترکیب ورودی متغیرهای متوسط درجه حرارت روزانه، متوسط رطوبت نسبی، ساعت آفتابی و میزان تبخیر از تشستک منجر به کمترین میزان خطا (جذر میانگین مربعات خطا و میانگین قدر مطلق خطا به ترتیب ۲/۵۶۰ و ۲/۳۸۸) و در نتیجه دقیق‌ترین برآورد سرعت باد شد (جدول ۲). به عبارت دیگر افزایش تعداد متغیرها در تحلیل شبکه عصبی، کاهش مقدار خطا و افزایش در مقدار ضریب تشخیص را به همراه داشته است (ضریب تشخیص ۰/۵۲).

مقدار آن به یک نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است (۳۰).

بر این اساس تعداد لایه‌های مخفی ۴ و تعداد نرون لایه میانی ۱۲ نرون تعیین شد. همچنین برای نرون‌های لایه خروجی از توابع گوسی، زنگوله‌ای و سیگموئید به منظور تابع محرک استفاده شد و روش آموزش شبکه نیز روش پس‌انتشار خطا و الگوریتم آموزش لونیبرگ-مارکوات بود. این الگوریتم برای اکثر کاربردها نتایج دقیق و سریعی نسبت به سایر قانون‌های روش انتشار به عقب خطا ارائه می‌دهد و به شدت سرعت همگرایی را افزایش داده و به نتیجه‌گیری سرعت می‌بخشد (۱۱، ۲۹). علاوه بر این، برای انجام پیش‌بینی با استفاده از سیستم استنتاج فازی-عصبی تطبیقی<sup>۱</sup> که از ترکیب مدل‌های منطق فازی و شبکه عصبی مصنوعی به وجود آمده است، بر اساس آزمون و خطا، از ۴ لایه پنهان و ۸ نرون برای سیستم استنتاج فازی-عصبی تطبیقی استفاده شد. توابع مورداستفاده نیز همان توابع گوسی، زنگوله‌ای و سیگموئیدی و الگوریتم آموزشی مورداستفاده نیز لونیبرگ-مارکوات بود.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2} \quad (۲)$$

در این رابطه  $\hat{y}_i =$  داده مشاهده شده و  $y_i =$  داده پیش‌بینی شده است.

$$d = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (|p'_i| + |o'_i|)^2} \quad (۳)$$

$$p'_i = \hat{y}_i - \bar{y} \quad o'_i = y_i - \bar{y}$$

<sup>۱</sup> Adaptive neuro-fuzzy inference system (ANFIS)

جدول ۲- نتایج حاصل از آنالیز حساسیت داده‌های مورد استفاده در مدل‌های پیش‌بینی

متغیر	علامت اختصاری	d	RMSE	MAE	R <sup>2</sup>
دما	T	۰/۹۴	۲/۹۲۸	۲/۵۱۲	۰/۴۲
دما و رطوبت نسبی	Rh, T,	۰/۹۱	۳/۳۵۶	۲/۷۱۳	۰/۳۷
دما، رطوبت نسبی، تبخیر	Rh, Eva T,	۰/۹۳	۳/۱۳۴	۲/۶۱۱	۰/۳۹
دما، رطوبت نسبی، تبخیر، ساعات آفتابی	Eva, Hs Rh, T,	۰/۹۹	۲/۵۶۰	۲/۳۸۸	۰/۵۱
رطوبت نسبی، تبخیر، ساعات آفتابی	Rh, Eva, Hs	۰/۷۹	۴/۳۴۵	۳/۷۱۵	۰/۳۳
رطوبت نسبی	Rh	۰/۷۵	۵/۸۲۵	۴/۰۱۲	۰/۲۵

مدل معنی‌دار رگرسیونی در ایستگاه‌های زابل و زهک، به ترتیب ۰/۵۲ و ۰/۴۹ درصد از تغییرات سرعت باد توسط چهار متغیر (متوسط درجه حرارت روزانه، متوسط رطوبت نسبی، ساعت آفتابی و میزان تبخیر) توجیه می‌شود (جدول ۳). به عبارت دیگر می‌توان گفت که بین متغیر وابسته (سرعت باد) و متغیرهای مستقل رابطه معنی‌دار وجود دارد.

### مقایسه عملکرد روش‌های رگرسیون خطی و غیرخطی در برآورد سرعت روزانه باد

نتایج حاصل از تخمین سرعت باد با استفاده از روش‌های رگرسیون خطی و غیرخطی نشان می‌دهد که مدل‌های رگرسیون غیرخطی نسبت به مدل‌های رگرسیون خطی، با توجه به مقادیر معیارهای ارزیابی، از کارایی بیشتری در برآورد سرعت برخوردار است (جدول ۳). بر اساس ضریب تبیین به دست آمده برای دقیق‌ترین

جدول ۳- نتایج حاصل از ارزیابی عملکرد رگرسیون غیرخطی در برآورد سرعت باد در ایستگاه‌های زابل و زهک

نام ایستگاه	مدل پیش‌بینی	RMSE	MAE	d	R <sup>2</sup>	Sig
زابل	$V = \exp(13/52 + 0/577T - 0/126Rh - 2/058Eva - 0/361Hs)$	۴/۴۴۰	۳/۵۰۰	۰/۹۷	۰/۵۲	۰/۰۰۱
زهک	$V = \exp(4/326 + 0/292T - 0/068Rh - 1/129Eva - 0/251Hs)$	۴/۶۸۰	۳/۷۵۰	۰/۹۳	۰/۴۹	۰/۰۲۲

اعتبار سنجی نیز نشان می‌دهد که میزان همبستگی بین این مقادیر در ایستگاه‌های زابل و زهک تا حدودی از یکدیگر متفاوت است و مقدار این معیار در ایستگاه زابل بیشتر از ایستگاه زهک می‌باشد (به ترتیب ۰/۵۲ و ۰/۴۵). به عبارت دیگر مدل‌های هوش مصنوعی حاصل از داده‌های ایستگاه زابل در برآورد سرعت باد دقیق‌تر عمل کرده‌است و همبستگی بیشتری را بین مقادیر واقعی و برآوردی نشان می‌دهد (شکل ۲ و ۳). همچنین نتایج به دست آمده از پیش‌بینی سرعت باد با استفاده از سیستم استنتاج تطبیقی عصبی-فازی نشان می‌دهد که مدل نروفازی با

### ارزیابی نتایج حاصل از مدل‌های هوش مصنوعی در برآورد سرعت روزانه باد



ارزیابی نتایج حاصل از مدل شبکه عصبی پرسپترون چندلایه در برآورد سرعت باد نشان می‌دهد که با توجه به مقادیر آماره‌های خطا، مدل شبکه عصبی پرسپترون چندلایه با تابع گوسی در مرحله اعتبارسنجی در هر دو ایستگاه زابل و زهک در برآورد سرعت باد از دقت قابل قبولی برخوردار است (جدول ۴). بررسی ضرایب همبستگی بین مقادیر واقعی و مقادیر برآورد شده توسط مدل‌های پرسپترون چندلایه و مدل نروفازی در مرحله

مدل های رگرسیون خطی و غیرخطی در پیش بینی سرعت باد در منطقه سیستان است. علاوه بر این، بر اساس معیارهای ارزیابی مورد استفاده، از میان روش های هوش مصنوعی نیز سیستم استنتاج تطبیقی عصبی-فازی با تابع گوسی دقیق ترین برآوردها را از سرعت باد ارائه داده است. همچنین بعد از مدل های هوش مصنوعی مدل رگرسیون غیرخطی برآورد دقیق تری از سرعت باد داشته است. ساختار مدل های هوش مصنوعی به همراه نتایج آماری اجرای آن در جدول (۳) ارائه شده است.



تابع گوسی نیز عملکرد دقیقی در برآورد میزان سرعت باد دارد. به طوری که کمترین میزان خطا در برآورد سرعت باد مربوط به مدل نروفازی در ایستگاه زابل است (جذر میانگین مربعات خطا، ۲/۵۶). علاوه بر این، مقایسه نتایج حاصل از مدل پرسپترون چندلایه و مدل نروفازی در برآورد سرعت باد نشان از برتری سیستم نروفازی نسبت به شبکه عصبی پرسپترون چندلایه دارد. به طور کلی مقایسه دقت روش های مورد استفاده در برآورد سرعت باد نشان دهنده برتری مدل های هوش مصنوعی (شبکه عصبی پرسپترون چندلایه و شبکه نروفازی) نسبت به

جدول ۴- نتیجه ارزیابی مدل های هوش مصنوعی در برآورد میزان سرعت باد در مرحله اعتبارسنجی (ایستگاه زابل و زهک)

نام	نوع مدل	معماری	تعداد لایه	تابع انتقال	d	RMSE	MAE	R <sup>2</sup>
زابل	MLP	۴:۱۲:۱	۴	Gaussian	۰/۹۶۴	۲/۶۰۳	۲/۴۷۸	۰/۵۲۵
زهک	MLP	۴:۱۲:۱	۴	Gaussian	۰/۹۷۸	۲/۸۶۴	۲/۲۵۷	۰/۴۵۱
زابل	ANFIS	۴:۸:۱	۴	Mfgauss	۰/۹۹۸	۲/۵۶۰	۲/۳۸۸	۰/۵۱۴
زهک	ANFIS	۴:۸:۱	۴	Mfgauss	۰/۹۸۷	۲/۶۲۴	۲/۲۱۷	۰/۳۹۱



شکل ۲- مقایسه مقادیر واقعی سرعت باد با مقادیر برآورد شده با استفاده از مدل پرسپترون چندلایه در مرحله اعتبارسنجی در ایستگاه های زابل (چپ) و زهک (راست)



شکل ۳- مقایسه مقادیر واقعی سرعت باد با مقادیر برآورد شده با استفاده از مدل نروفازی در مرحله اعتبارسنجی در ایستگاه‌های زابل (چپ) و زهک (راست)

#### ■ بحث و نتیجه‌گیری

باد در رتبه‌های بعدی قرار گرفتند. علاوه بر این، نتایج حاصل از تحلیل حساسیت داده‌ها نشان داد که ترکیب ورودی متغیرها شامل متوسط درجه حرارت روزانه، متوسط رطوبت نسبی، ساعت آفتابی و میزان تبخیر از تشتک منجر به کمترین میزان خطا ( جذر میانگین مربعات خطا و میانگین قدر مطلق خطا به ترتیب ۲/۵۶۰ و ۲/۳۸۸) و در نتیجه دقیق‌ترین برآورد سرعت باد شد و دو عامل متوسط درجه حرارت روزانه و متوسط رطوبت نسبی به ترتیب، بیش‌ترین و کمترین تأثیر را بر سرعت باد در منطقه سیستان دارند (به ترتیب ضریب همبستگی ۰/۴۲ و ۰/۲۵). مطالعات نشان داده‌است که متغیرهای کم‌اهمیت در مدل‌سازی، تأثیر چندانی بر افزایش دقت مدل‌سازی نسبت به حالتی که این متغیرها در مدل‌سازی موجود هستند، ندارد. از سوی دیگر حذف این داده‌ها، هزینه جمع‌آوری داده‌ها را کاهش و در اغلب موارد دقت مدل را افزایش می‌دهد (۷). علاوه بر این موارد، همان‌طور که اشاره شد برای آموزش شبکه از الگوریتم لونیگ-مارکوات استفاده شد که تحقیقات نشان داده‌است که این الگوریتم برای اکثر کاربردها نتایج دقیق و سریعی نسبت به سایر قانون‌های روش آموزش انتشار به عقب خطا ارائه می‌دهد (۱۱، ۲۹).

یکی از ویژگی‌های مهم مدل‌های هوش مصنوعی این است که به اغتشاش در مجموعه داده‌های آموزشی مقاوم است، از این‌رو برای مطالعه پاسخ‌های غیرخطی متغیرها

ارزیابی عملکرد روش‌های مورد استفاده برای برآورد سرعت باد در این پژوهش نشان می‌دهد که میزان دقت مدل‌های حاصل از این روش‌ها در برآورد سرعت روزانه باد در منطقه مورد مطالعه از یکدیگر متفاوت است که این موضوع منجر به بروز تفاوت معنی‌دار بین عملکرد روش‌های مورد استفاده شد. براساس مقادیر مربوط به آماره‌های ارزیابی مدل، از بین روش‌های مورد استفاده، مدل‌های حاصل از روش‌های هوش مصنوعی توانست در مقایسه با روش‌های رگرسیونی خطی و غیرخطی سرعت باد را با دقت بیشتری برآورد کند و این روش‌ها در برآورد سرعت باد عملکرد بهتری از خود نشان داد. علاوه بر این، در بین روش‌های هوش مصنوعی نیز برآورد انجام‌شده با استفاده از روش سیستم استنتاج تطبیقی عصبی-فازی با معماری ۸ نرون و ۴ لایه پنهان بر اساس مقادیر آماره‌های ارزیابی در هر دو ایستگاه مورد بررسی دارای کمترین میزان خطا و بالاترین دقت بود (ریشه میانگین مربعات خطا، شاخص تطابق و میانگین قدرمطلق خطا به ترتیب برابر با ۲/۵۶، ۰/۵۱ و ۲/۳۸) (جدول ۴). در حالی که مقادیر این آماره‌ها در مدل‌های رگرسیونی حاصل به ترتیب برابر با ۴/۴۴، ۰/۹۷ و ۳/۵ بود (جدول ۳).

بر اساس نتایج، بعد از روش‌های هوش مصنوعی، روش رگرسیونی غیرخطی و خطی به ترتیب در تخمین سرعت



روش‌های شبکه عصبی مصنوعی و رگرسیون آماری برای پیش‌بینی سرعت باد نیز نشان داد که شبکه‌های عصبی قادر است نسبت به روش رگرسیون آماری، با دقت بالاتری سرعت باد را برآورد کند (۱۸). محققین دیگری نیز برای تخمین عوامل اقلیمی از روش‌های رگرسیونی استفاده کرده‌اند و به نتایج مشابهی در مورد عدم برتری روش‌های رگرسیونی نسبت به روش‌های هوش مصنوعی دست‌یافته‌اند (۲۳، ۲۶، ۲۷).

باد یکی از عوامل اساسی و تعیین‌کننده هواشناسی است و تأثیر بسزایی در اقلیم هر منطقه دارد و تغییرات و اثرات آن می‌تواند روی پدیده‌های مختلفی تأثیرگذار باشد، از این‌رو شناخت متغیرهای اقلیمی تأثیرگذار در سرعت باد از اهمیت ویژه‌ای برخوردار است (۸). در پژوهش حاضر نتایج حاصل از آنالیز حساسیت داده‌ها که با هدف تعیین متغیرهای دارای تأثیر بیشتر در سرعت باد انجام شد، نشان داد که عامل اقلیمی متوسط درجه حرارت روزانه و متوسط رطوبت نسبی با توجه به معیارهای ارزیابی به ترتیب بیش‌ترین و کمترین تأثیر را بر خروجی یعنی سرعت باد در منطقه سیستان دارند. در تأیید یافته این پژوهش، تحلیل همبستگی سرعت باد نشان داد که با افزایش دما سرعت باد افزایش می‌یابد و رابطه معناداری بین سرعت باد و رطوبت وجود ندارد (۱۴).

با توجه به نتایج این پژوهش می‌توان بیان داشت که به‌منظور اتخاذ تصمیمات منطبق با شرایط منطقه و همچنین اتخاذ تدابیر پیشگیرانه جهت کاستن از تبعات منفی این پدیده، که نیازمند اطلاعات دقیق و موثق از سرعت باد و تغییرات آن در منطقه است، از روش سیستم استنتاج تطبیقی عصبی-فازی جهت شبیه‌سازی سرعت باد در منطقه سیستان استفاده کرد. علاوه بر این، با توجه به اینکه این پژوهش تنها در منطقه سیستان انجام شده است، ضروری است به‌منظور حصول اطمینان از قابلیت روش‌های مورد استفاده، علاوه بر استفاده از سایر مدل‌های هوش مصنوعی همچون الگوریتم ژنتیک، برای شبیه‌سازی سرعت باد، این روش‌ها در مقیاس‌های زمانی و مکانی مختلف مورد استفاده قرار گیرد و سپس در مورد دقت این روش‌ها در برآورد پدیده‌های اقلیمی قضاوت کرد. علاوه بر موارد ذکر شده، پیشنهاد می‌شود در پژوهش‌های

به پیش‌بینی‌کننده‌ها مناسب است (۲۱). به عبارت دیگر، توانایی پیش‌بینی فرایندهای مبهم با حداقل متغیرهای اندازه‌گیری‌شده با دقت قابل قبول از مزیت‌های این روش‌ها است. سیستم استنتاج فازی-عصبی تطبیقی با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه عصبی، موفقیت‌های بسیاری را در مدل‌سازی و کنترل سیستم‌های پیچیده داشته است. به همین دلایل امروزه سیستم‌های فازی بر پایه شبکه عصبی تطبیقی یکی از روش‌های کارآمد در زمینه پیش‌بینی و مدل‌سازی است (۲۴). به‌طور خاص، کارایی بالای شبکه عصبی در برآورد سرعت باد نسبت به روش رگرسیونی را می‌توان به عدم وابستگی شبکه عصبی به فرض‌های اولیه در مورد داده‌ها نسبت داد زیرا ممکن است بین متغیرها رابطه‌ای غیرخطی وجود داشته باشد که رگرسیون قادر به پیش‌بینی آن نبوده است (۴). هم‌سو با یافته این پژوهش گزارش شده است که می‌توان از شبکه عصبی مصنوعی به‌عنوان یک ابزار قدرتمند در پیش‌بینی سرعت باد در یک ایستگاه هدف با توجه به ورودی‌های موردنظر استفاده کرد (۱۴). علاوه بر این، تخمین سرعت باد به‌وسیله شبکه عصبی نشان داد که می‌توان از شبکه‌های عصبی برای بازسازی داده‌ها استفاده کرد (۳). محققین دیگری نیز برای تخمین سرعت باد از روش‌های هوش مصنوعی استفاده کرده‌اند و به نتایج مشابهی در مورد قابلیت‌های این روش‌ها دست‌یافته‌اند (۲، ۵، ۶، ۱۲).

نتایج حاصل از تخمین سرعت باد با استفاده از روش‌های رگرسیون خطی و غیرخطی نیز حاکی نشان دهنده آن است که مدل‌های رگرسیون خطی و غیرخطی نتوانستند در پیش‌بینی سرعت باد بر مدل‌های هوش مصنوعی برتری یابند. مدل رگرسیونی از مدل‌های قدیمی برای برآورد عوامل اقلیمی محسوب می‌شود و به دلیل سینوسی بودن داده‌ها، نسبت به روش هوش مصنوعی عملکرد پایین‌تری در پیش‌بینی عوامل مختلف، نشان می‌دهد. هم‌سو با یافته این پژوهش، پیش‌بینی سرعت باد با استفاده از روش شبکه‌های عصبی مصنوعی و روش‌های رگرسیونی نشان داد که روش‌های رگرسیونی عملکرد ضعیف‌تری نسبت به روش‌های هوش مصنوعی در پیش‌بینی سرعت باد دارد (۱۹). همچنین مقایسه دقت

آینده از داده‌های مربوط به متغیرهای دیگر در برآورد  
سرعت باد در منطقه مورد مطالعه استفاده شود تا بتوان با  
مقایسه نتایج حاصل با نتایج این پژوهش، یک راه حل  
علمی و دقیق برای برآورد سرعت باد در منطقه ارائه داد.

## ■ References

1. Afkhami, H., Talebi, A., Mohammadi, M., & Fotouhi, F. 2015. Investigation of the Feasibility of Wind Speed Prediction Using Hybrid Model of Neural Networks, Neural -Fuzzy Networks and Wavelet (Case Study: Station of Yazd), Iran-Watershed Management Science & Engineering, 9 (30): 31-40, (in Farsi).
2. Akinci, T. C. (2011). Short term wind speed forecast with ANN in Batman, Turkey. in: proceeding of Electronics and Electrical Engineering Conference, Oct. 28- Nov, 2 Shanghai china, 1(107): 41-45
3. Barati, H., & Haroonabadi, H. (2013). Wind speed forecasting in south coasts of Iran: an application of artificial neural networks (ANNS) for Electricity Generation using Renewable Energy. Bulletin of Environment, Pharmacology and Life Sciences, 6: 30-37.
4. Bayati, H., & Njafi, A. 2013. Performance Comparison Artificial Neural Networks with Regression Analysis in Trees Trunk Volume Estimation, Forest and Wood Products, 66 (2): 177- 191. (in Farsi).
5. Cadenas, E., & Rivera, W. (2010). Wind speed forecasting in three different regions of Mexico, using hybrid ARIMA- ANN model. Renewable Energy, 35: 2732-2738.
6. Ekonomou, L., Iazarou, S., & Chatzarakis, G.E. (2012). Estimation of wind turbines optimal number and produced power in a wind farm using an artificial neural network model. Simulation Modelling Practice and Theory, 21(1): 21-25.
7. Faghhi H. 2010. Evaluating Artificial Neural Network and its Optimization Using Genetic Algorithm in Estimation of Monthly Precipitation Data (Case Study: Kurdistan Region). Journal of Water and Soil Science, 14 (51) :27-44, (in Farsi).
8. Ghasemi, A., & Seyed, F. 2015. Simulation and prediction of wind speed variations in Iran, Quarterly Journal of Geographic Information, 94: 95-105, (in Farsi).
9. Ghiasi, M. S., & Kalantar, M. (2009). New method for predicting wind speeds in Wind power plants, In: Proceedings of 24th International Power System conference, 16-18 Nov. Tehran.
10. Gong, D., S. Glenn, R. Chant, J. Wilkin, and J. Kohut. (2006). NJ Turnpike–Dynamics of the Hudson Shelf Valley, Eos Trans. AGU, 87(36), Ocean Sci. Meet. Suppl., Abstract OS34I-05.
11. Hagan, M. T., & Menhaj, M. B. (1994). Training feed forward networks with the Marquardt algorithm. IEEE Trans on Neural Networks, 5: 989-993.
12. Huang, M., Peng, G., Zhang, J., & Zhang, S. (2006). Application of artificial neural networks to the prediction of dust storms in Northwest China. Journal of Global and Planetary Change, 52: 216-224.
13. Jamalizadeh Tajabadi, M.R., Moghaddamnia, A.R., Piri, J., & Ekhtesasi, M.R. 2010. Application of artificial neural networks in dust storm prediction (case study: Zabol city), Iranian journal of Range and Desert Research, 17 (2): 205-220, (in Farsi).
14. Khalaji Asadi, M., Noorollahi, Y., & Safaei, Sh. 2014. Forecasting of the wind speed using neural networks In order to install a wind power plant. 1st National conference on clean and renewable energy. Hamedan, 9 p, (in Farsi).
15. Khosravi, M. 2010. Evaluation of vertical distribution of dust induced storm and middle east using NAAPS model, Proceedings of the 4th International Congress of the Islamic World Geographers, 14-16 April, Zahedan, University of Sistan & Baluchestan, 22p, (in Farsi).
16. Kisi, O. (2006). Daily pan evaporation modelling using a neuro-fuzzy computing technique. Journal of Hydrology, 329: 636-646.

17. Kisi, O., & Sanikhani, H. (2015). Modeling long-term monthly temperatures by several data-driven methods using geographical inputs. *Journal of Climate*, 35: 3834-3846.
18. Kulkarni, A., Patil, S., Rama, G.V., & Sen, P.N. (2008). Wind speed prediction using statistical regression and neural network: *Journal of Earth System Science*, 117, 457.
19. Maqsood, I., Khan, M. R., & Abraham, A. (2004). An ensemble neural networks for weather forecasting. *Journal Neural Computing and Applications*, 13(2): 112-122.
20. Negaresh, H., Fallahian Firouzabad, H., & Khosravi, M. 2011. The Analysis of Climatological Abnormalities Influencing on Desertification Process in Khezer Abad Region of Yazd, *Geography and environmental planning*, 22(43): 69-94, (in Farsi).
21. Pearson, R., Dawson, T. P., & Liu, C. (2004). Modelling species distributions in Britain: a hierarchical integration of climate and land-cover data. *Ecography*, 27: 285-298.
22. Piri Sahragard, H., & Zare Chahouki, M.A. (2015). An evaluation of predictive habitat models performance of plant species in Hoze sultan rangelands of Qom province. *Ecological Modelling*, 309-310: 64-71.
23. Piri Sahragard, H., Zare Chahouki, M.A., & Azarnivand, H. 2015. Modelling of Plant Species Distribution In Arid Regions Using Artificial Neural Networks (ANN) (Case Study: Hozeh Soltan Rangelands of Qom Province), *Desert Management*, 5: 27-40, (in Farsi).
24. Piri, J., & Kisi, O. (2015). Modelling solar radiation reached to the Earth using ANFIS, NNARX, and empirical models (Case studies: Zahedan and Bojnurd stations). *Journal of Atmospheric and Solar-Terrestrial Physics*. 123:39-47.
25. Rahim Zadeh, F., & Pedram, M. 2010. Reducing of the wind energy amount in the long-term effects of wind speed in Isfahan province, *Neyvar scientific and technical journals*, 7: 53-62, (in Farsi).
26. Selcuk Nogay, H., Cetin Akinci, T., & Eidukeviciute, M. (2012). Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey: *Journal of Energy in Southern Africa*, 23(4): 2-7.
27. Shafie, A., Mazoghi, H., Shehata, A., & Taha, M. (2011). Artificial neural network technique for rainfall forecasting applied to Alexandria Egypt. *International Journal of the Physical Sciences*, 6: 1306-1316.
28. Song, Z., (2004). A numerical simulation of dust storms in China. *Journal of Environmental Modelling & Software*, 19: 141-151.
29. Tan, Y., & Van C.A. (1999). Neural-Network-Based d-step-ahead predictors for nonlinear systems with time delay. *Engineering Applications of Artificial Intelligence Journal*, 12: 21-25.
30. Yadav, D., & Veena Sharma, N. (2010). Artificial neural network based hydroelectric generation modelling“, *International Journal of Applied Engineering Research*, 1(3): 343-359.

## **Comparing the accuracy of regression and artificial intelligence methods in estimating daily wind speed in the Sistan region**

**H. Piri Sahragard<sup>1\*</sup>, A. Pahlavanravi<sup>2</sup>, J. Piri<sup>3</sup>, A. Abtin<sup>4</sup>**

1. Assistant Professor, College of Soil and Water, University of Zabol, Zabol, Iran

2. Associate Professor, College of Soil and Water, University of Zabol, Zabol, Iran

3. Faculty member, College of Soil and Water, University of Zabol, Zabol, Iran

4. MSc Graduate, College of Soil and Water, University of Zabol, Zabol, Iran

\* Corresponding Author: hopiry@uoz.ac.ir

Received date: 19/08/2015

Accepted date: 26/07/2016

### **Abstract**

This paper aims at comparing the accuracy of regression, artificial intelligence, and adaptive neuro-fuzzy (ANFIS) interpretation methods in estimating wind speed in the Sistan region. To this end, we used the daily weather information obtained from Zabol synoptic stations during a five-year period (2010-2015). MATLAB software was used for modeling based on artificial neural network. On the other hand, DATA FIT software was used for modeling based on regression methods. The methods' accuracies were estimated using mean square error statistics, comparison indexes, and mean error. Based on sensitivity analysis results; variables such as daily temperature mean, mean relative humidity, sunshine hours, and evaporation from pan were regarded as input variables of regression and artificial intelligence methods. Wind speed was considered as output variable. Based on the results, mean daily temperature and mean relative humidity had the most and the least effect on wind speed in Sistan (0.42 and 0.25 respectively). Neuro-fuzzy method with Gaussian function was the most accurate method in estimating wind speed (error squares mean of 2.56). The same statistic for regression method is 4.44. The correlation of regression method (0.45 and 0.51) is less than those of multilayer perceptron method and Neuro-fuzzy method (0.51 and 0.52). So, it is suggested that Neuro-fuzzy method can be used for more accurate estimating wind speed in Sistan region. With accurate estimation of this variable, we can hinder the devastative effects of wind and use it as an effective source of energy.

**Keywords:** Sensitivity analysis; Mean square error, Neuro-fuzzy method; Coefficient of determination