

استفاده از رویکرد شبکه عصبی مصنوعی جهت پیش‌بینی کوتاه‌مدت سرعت باد (مطالعه موردی: ایستگاه هواشناسی جیرفت)

بهرام بختیاری^{*}، نوذر قهرمان^۲، اسحاق رحیمی^۳

۱. استادیار دانشکده کشاورزی دانشگاه شهید باهنر کرمان

۲. استادیار دانشگاه تهران، پردیس کشاورزی و منابع طبیعی کرج

۳. دانش آموخته کارشناسی ارشد دانشکده کشاورزی دانشگاه شهید باهنر کرمان

(تاریخ دریافت: ۱۳۹۰/۱۱/۱۸ – تاریخ تصویب: ۱۳۹۱/۱۱/۲۹)

چکیده

سرعت باد یکی از متغیرهای بسیار مهم هواشناسی در تعیین تبخیر تعرق و نیاز آبی گیاهان است. مدل‌ها و روش‌های متعددی برای پیش‌بینی این عامل وجود دارد. در سال‌های اخیر، با شناخته شدن ابزار محاسبات نرم، به مثابه روشی نوین در ایجاد سیستم‌های هوشمند، این روش‌ها جایگاهی ویژه در علوم هواشناسی کشاورزی پیدا کردند. به کاربردن رویکرد شبکه عصبی مصنوعی یکی از این روش‌های است. با توجه به وجود ایستگاه هواشناسی کشاورزی جیرفت و در دسترس بودن داده‌های ساعتی سرعت باد در این شهر، از اطلاعات این ایستگاه استفاده شد. سری زمانی استفاده شده در این تحقیق اطلاعات سرعت باد در بازه زمانی ساعتی شش ماه (آوریل تا سپتامبر) سال ۲۰۱۰ بود که سرعت باد نسبت به سایر ماه‌های سال بیشتر بود. در این تحقیق از سه مدل با نورون‌های متفاوت با چهار لایه استفاده شد. نتایج نشان داد که مرحله آزمون مدل با ۲۰ نورون در هر لایه، به طور متوسط ۱۳۴ ثانیه طول کشیده است. لذا این مدل در مقایسه با دیگر مدل‌ها، در مدت زمانی کوتاه‌تر مقادیر خروجی را به دست داد و سرعت اجرای بالاتری داشت. با توجه به مقایسه پارامترهای آماری در مرحله آزمون، متوسط RMSE و MSE و EF (ضریب کارایی مدل)، به ترتیب، ۰/۶۹۴۷ و ۱/۱۸۲۷ و ۰/۹۲۴۶ به دست آمد. مدل به کاررفته، نسبت به دو مدل دیگر، دقت بیشتر و کارایی بهتری در پیش‌بینی سرعت باد دارد و با دنیای واقعی مطابقت می‌کند.

کلیدواژگان

پیش‌بینی، داده‌های ساعتی، سرعت باد، شبکه عصبی مصنوعی.

مقدمه

تحقیق انتخاب روز نمونه برای هر ماه جهت پیش‌بینی سرعت باد است. Singh et al. (2006) در تحقیقی با استفاده از یک شبکه عصبی پرسپترون چندلایه سرعت باد را به کمک فاکتورهای مؤثر در تولید انرژی پیش‌بینی کردند. نتایج نشان داد ارتفاعات منطقه آکلاهوما پتانسیل بالایی در تولید انرژی دارد. Yao Lee et al. (2009)، با استفاده از هیبرید شبكه عصبی و^۱ Particle swarm optimization سرعت باد را جهت تولید انرژی در نیروگاههای بادی پیش‌بینی کردند. نتایج نشان داد این روش نسبت به شبکه عصبی پاسخ‌های مناسبتری دارد. Cadenas and Rivera (2010) با استفاده از هیبرید ARIMA-ANN سرعت باد را در سه منطقه مکزیک پیش‌بینی و نتایج این روش را با روش‌های ANN و ARIMA مقایسه کردند. نتایج نشان داد هیبرید این دو روش خروجی‌های بهتری دارد. Akincei (2011) با استفاده از شبکه عصبی مصنوعی سرعت باد را در مناطقی از ترکیه پیش‌بینی کرد و به این نتیجه رسید که شبکه عصبی با سه لایه و ۴۰ نورون، نسبت به دیگر مدل‌های ارائه شده، پاسخ بهتری دارد. در این مطالعه از شبکه عصبی چندلایه، با استفاده از سه مدل چهار لایه‌ای، که تفاوت آن‌ها در تعداد نورون‌های لایه اول است، در پیش‌بینی کوتاه‌مدت سرعت باد در ایستگاه جیرفت استفاده شد.

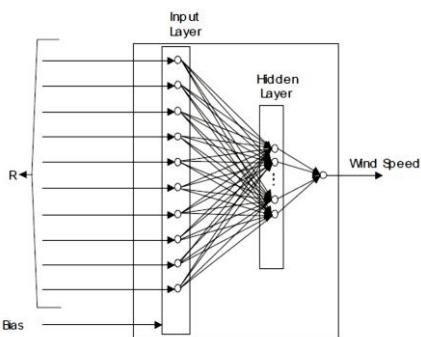
مواد و روش‌ها

داده‌ها و منطقه مورد مطالعه

شبکه‌های عصبی مصنوعی، جهت طراحی و آموزش، به یک سری داده‌های ورودی و خروجی نیاز دارند. با تجزیه و تحلیل منطقی این داده‌ها، به منزله نمونه، می‌توان روابط غیر خطی بین زوج داده‌های ورودی و خروجی را استخراج کرد و برای موارد احتمالی مشابه شبیه‌سازی انجام داد. در این مطالعه از آمار ساعتی سرعت باد ایستگاه هواشناسی جیرفت با طول و عرض

محاسبه و پیش‌بینی سرعت باد در محاسبه تبخیرتعرق و تعیین نیاز آبی گیاهان از فاکتورهای اصلی و مهم است. این عامل در روش‌های محاسبه تبخیرتعرق، از جمله پنمن مانتیث، تأثیری بسزا دارد. سرعت باد در هر منطقه تحت تأثیر عوامل متعددی است. از این پارامترها می‌توان به فشار هوا، رطوبت نسبی، دمای هوا، و دمای خاک اشاره کرد. با توجه به متغیربودن رفتار روزانه و فصلی باد و پیش‌بینی ناپذیری پارامترهای آن، در برآورد سرعت این متغیر هواشناسی عدم قطعیت مشاهده می‌شود. دو پارامتر مؤثر باد، در روابط به کاررفته در مباحث هواشناسی کشاورزی، سرعت و جهت وزش آن است. بنابراین، هر گونه تلاش برای پیش‌بینی و محاسبه این دو عامل به آگاهی از این دو متغیر نیاز دارد. از مزایای تخمین پارامترهای باد محاسبه تبخیرتعرق، پیش‌بینی سرعت پراکندگی گردوغبار و آلودگی، و توانایی کنترل و تنظیم توربین‌های بادی در یک منطقه است (Akbarpour and Tafreshi, 2010; Ghiasi and Kalantar, 2009). مدل‌های متفاوتی در تخمین سرعت باد ارائه شده است. محاسبات نرم، که ابزاری جدید در پیش‌بینی سرعت باد در دوره‌های زمانی متفاوت است، یکی از این روش‌های است. در سال‌های اخیر بسیاری از محققان، با استفاده از روش‌های محاسبات نرم، از جمله شبکه عصبی و فازی و عصبی- فازی تطبیقی^۲، سرعت باد را پیش‌بینی کرده‌اند. در مطالعه‌ای، پیش‌بینی سرعت باد با استفاده از روش مثلثاتی واریاگرام‌های تجمعی انجام گرفت و این روش با شبکه عصبی مصنوعی مقایسه شد. نتایج نشان داد روش مذکور در بیشتر ماههای سال به شبکه عصبی مصنوعی بسیار نزدیک است (Oztopal, 2006) (Monfared et al., 2006) از روش آماری جدیدی جهت برآورد و پیش‌بینی مقادیر سرعت و جهت باد استفاده کردند. هدف اصلی در این

مجموعه‌ای از توابع غیر خطی با فضای خروجی مرتبط می‌سازند. کاربردی‌ترین نوع شبکه‌های عصبی شبکه پرسپترون چندلایه^۱ و شبکه‌های توابع شعاعی^۲ هستند (Salehi et al, 1998). در این تحقیق، برای شبیه‌سازی سرعت باد، با استفاده از شبکه MLP، از دو لایه پنهان با تعداد نورون‌های متفاوت و توابع محرك کراندار تابع سیگموئید و از میان روش‌های مختلف آموزش روش پسانشوار خطأ با الگوریتم لورنبرگ_مارکوارت، به دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد (Ghabaei Sough et al, 2009). اساس روش پسانشوار خطأ بر پایه قانون یادگیری اصلاح خطاست که از دو مسیر اصلی رفت‌وبرگشت تشکیل می‌شود. در مسیر رفت، بردار ورودی به شبکه اعمال می‌شود و تأثیرات آن از طریق لایه‌های میانی به لایه خروجی انتشار می‌یابد و بردار خروجی پاسخ واقعی شبکه را تولید می‌کند. شکل ۱ ساختار شبکه چندلایه پسانشوار خطأ را نشان می‌دهد (Kouchakzadeh and Bahmani, 2005).



شکل ۱. ساختار یک شبکه عصبی مصنوعی چندلایه

طراحی مدل

تعداد لایه و تعداد نورون‌های هر لایه در به‌دست‌آوردن ساختار شبکه عصبی بسیار مهم است. انتخاب پارامترهای شبکه‌ای با توپولوژی پسانشوار خطأ به تجربه طراح این شبکه بستگی دارد. هیچ ساختار

جغرافیایی، به ترتیب، ۵۷ درجه و ۴۸ دقیقه، ۲۸ درجه و ۳۵ دقیقه، و ۶۰۱ متر ارتفاع از سطح دریا استفاده شد. داده‌های استفاده شده در این تحقیق مربوط به شش ماه اول سال میلادی است که باد نسبت به سایر ماه‌های سال سرعت قابل توجهی داشت. داده‌های ماه‌های آوریل، می، جون، جولای، آگوست، و سپتامبر ۲۰۱۰ ماه‌های استفاده شده در این مدل‌اند. متغیرهای ورودی فشار هوا، رطوبت نسبی، دمای هوا، و دمای خاک بود و سرعت باد، حسب متر بر ثانیه، یگانه متغیر خروجی در نظر گرفته شد. حداقل سرعت باد در این منطقه در طول سری زمانی ۶/۸ متر بر ثانیه ثبت شد.

روش پژوهش

شبکه عصبی مصنوعی (ANN)

آغاز نظریه شبکه عصبی مصنوعی تقریباً به دهه ۴۰ میلادی بر می‌گردد؛ زمانی که مک کلاچ، روان‌شناس معروف، والتر پیتز، ریاضی‌دان، در سال ۱۹۴۳ آن را بنیان نهادند. این روش، با الگو قراردادن فعالیت‌های مغز انسان و براساس روابط منطقی مشابه، با دریافت یک سری اطلاعات، نتایجی منطقی عرضه می‌کند و به کاربر ارائه می‌دهد. شبکه عصبی مصنوعی، با تجزیه و تحلیل داده‌های ورودی و نتایج نظیر آن‌ها، ارتباطی منطقی بین داده‌ها برقرار می‌کند که ممکن است غیر خطی و نامشخص باشد. سپس، با استفاده از این ارتباط منطقی، کار شبیه‌سازی را برای موارد احتمالی مشابه انجام می‌دهد. این شبکه‌ها، بر مبنای مقایسه خروجی شبکه و هدف، تعديل می‌شوند و تا زمانی که خروجی شبکه با خروجی هدف تطبیق پیدا کند این کار ادامه می‌یابد. شبکه‌های آموزش‌یافته را می‌توان به صورت رویه‌ای از جعبه سیاه برای برآوردهای غیر خطی، با نام نگاشته‌های غیر خطی قابل تنظیم، معرفی کرد؛ زیرا فضای بردار ورودی را به‌وسیله

$$MSE = \frac{1}{n} \sum (\mathbf{Y}_t - \mathbf{F}_t)^2 \quad (1)$$

$$RMSE = \sqrt{\frac{\sum (\mathbf{Y}_t - \mathbf{F}_t)^2}{n}} \quad (2)$$

$$EF = 1 - \left| \frac{\sum (\mathbf{Y}_t - \mathbf{F}_t)^2}{\sum (\bar{\mathbf{Y}}_t - \bar{\mathbf{F}}_t)^2} \right| \quad (3)$$

که در آن \mathbf{Y}_t و \mathbf{F}_t ، بهترتبی، خروجی محاسباتی و خروجی مشاهداتی و n تعداد داده‌ها در دوره زمانی را نشان می‌دهد و در رابطه ضریب کارایی $\bar{\mathbf{Y}}$ و $\bar{\mathbf{F}}$ ، بهترتبی، میانگین مقادیر خروجی محاسباتی و خروجی‌اند.

یافته‌ها و بحث

در پیش‌بینی کوتاه‌مدت سرعت باد در ایستگاه هواشناسی جیرفت از سه مدل 4L-20N (مدل ۱) و 4L-30N (مدل ۲) و 4L-40N (مدل ۳) استفاده شد. به منظور شبیه‌سازی، دو نوع تابع محرک به کار رفت که در لایه اول و دوم و سوم از تابع سیگموئید و در لایه آخر از تابع خطی بهره گرفته شد. در این تحقیق از یک شبکه چهار لایه با نورون‌های برابر در لایه اول و دوم و سوم و دو لایه مخفی و یک نورون در لایه آخر استفاده شد. در شبیه‌سازی این مدل‌ها تعداد تکرار دویست شرط پایان اجرای هر مدل در نظر گرفته شد. جهت مقایسه عملکرد این مدل‌ها معیارهای خطای RMSE، EF، EMS و پارامتر انحراف به کار رفت. همچنین زمان رسیدن به تعداد تکرار دویست نیز مورد توجه قرار گرفت. الگوریتم Levenberg-Marquardt است. جدول‌های ۱ تا ۶ نتایج اجرای این سه مدل را در مراحل آموزش^۱ و ارزیابی^۲ و آزمون^۳ نشان می‌دهد. از کل داده‌های موجود در هر ماه ۷۰

مشخصی جهت به دست آوردن بهتر این جواب در لایه خروجی شبکه وجود ندارد. فقط یک سری قوانین کلی، که در حل مسائل مهندسی از آن استفاده می‌شود، وجود دارد. مثلاً در صورتی که پیچیدگی بین داده‌های ورودی و خروجی زیاد باشد تعداد المان‌ها در لایه پنهان افزایش می‌یابد. برای هر شبیه‌سازی در شبکه عصبی باید تعداد نورون‌های هر لایه و نوع تابع محرک هر لایه و سرعت آموزش تعیین شود. در این مطالعه، برای پیش‌بینی کوتاه‌مدت سرعت باد، از سه مدل استفاده شد.

مدل ۱. سه لایه، ۲۰ نورون در لایه اول، ۲۰ نورون در لایه دوم، ۲۰ نورون در لایه سوم، ۱ نورون در لایه آخر (4L-20N)؛

مدل ۲. سه لایه، ۳۰ نورون در لایه اول، ۳۰ نورون در لایه دوم، ۳۰ نورون در لایه سوم، ۱ نورون در لایه آخر (4L-30N)؛

مدل ۳. سه لایه، ۴۰ نورون در لایه اول، ۴۰ نورون در لایه دوم، ۴۰ نورون در لایه سوم، ۱ نورون در لایه آخر (4L-40N).

معیارهای ارزیابی

در این تحقیق، برای ارزیابی نتایج به دست آمده با داده‌های واقعی، معیارهای گوناگونی وجود دارد که کاربرد هر یک به ماهیت مورد مطالعاتی بستگی دارد. در بیشتر مطالعات پیش‌بینی سرعت باد از شاخص‌های آماری ضریب همبستگی (R) و شاخص میانگین مربعات خطای^۱ استفاده می‌شود (Erasmo and Wilfrido, 2009). در این مطالعه، علاوه بر معیارهای مذکور، از معیارهای مجذور میانگین مربعات خطای (RMSE)، معیار کارایی مدل (EF)، و پارامتر انحراف Nash and Sutcliffe, (Bias) نیز استفاده شد (1970).

2. Train

3. Validation

4. Test

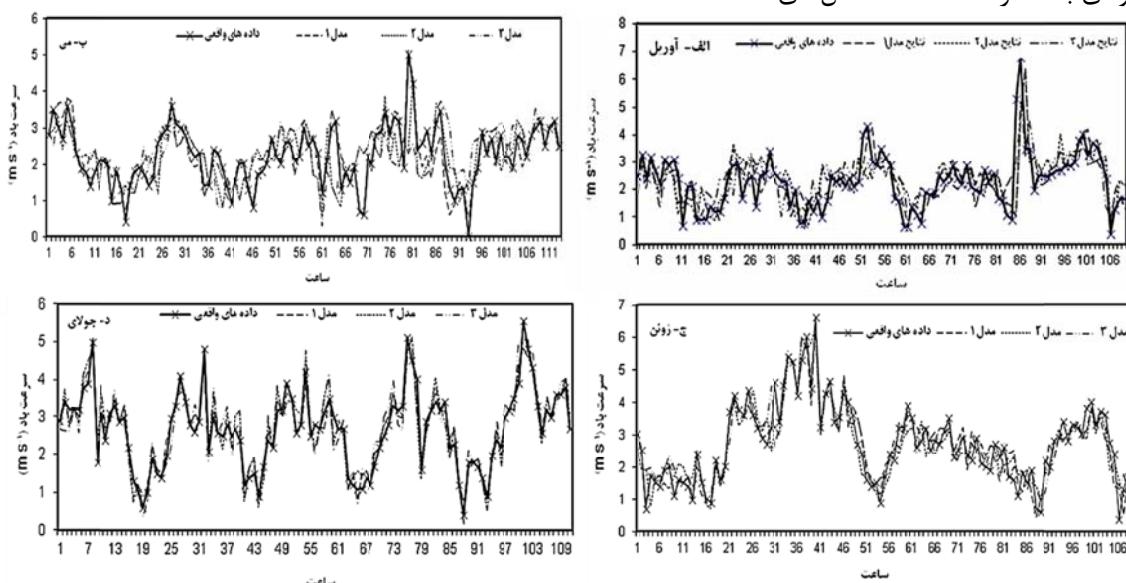
1. Mean Squared Error

مرحله برای ماههای متفاوت نشان می‌دهد با افزایش تعداد نورون‌ها در لایه اول مقادیر این پارامترها افزایش می‌یابد. با توجه به مقایسه عملکرد هر یک از این سه مدل، براساس این دو آماره، بهترین پیش‌بینی مربوط به مدل ۱ است. در جدول ۷ میانگین زمان اجرا در مدل‌های ۱ و ۲ و ۳، در مرحله آزمون، به ترتیب، ۱۳۴ و ۲۴۶ و ۳۹۵ ثانیه است و مشاهده می‌شود مدل ۱ در زمانی کمتر سرعت باد را پیش‌بینی می‌کند. با توجه به نتایج بدست‌آمده، بیشترین زمان در مراحل اجرای برنامه مرحله آموزش از ماه می در هر سه مدل و در همین مرحله کمترین زمان مربوط به ماه آوریل از سال ۲۰۱۰ در این ایستگاه است. همان‌طور که جدول‌ها نشان می‌دهند بیشترین زمان اجرای برنامه مربوط به مدل ۳ برای کلیه ماههای مورد مطالعه است. درواقع، با افزایش می‌یابد. به‌طور کلی، از زمان اجرای مدل افزایش می‌یابد. مقدار متابله می‌باشد که مدل ۱ است. یکی دیگر از معیارهای مقایسه کارایی هر یک از این سه مدل، در پیش‌بینی کوتاه‌مدت سرعت باد، ضریب کارایی مدل EF است. به‌طور کلی، هر مدلی که مقدار نزدیک به ۱ داشته باشد عملکرد بهتری دارد. با توجه به نتایج هر یک از این مدل‌ها در ماههای متفاوت میانگین این پارامتر در مدل ۱، در مرحله آزمون، برابر ۰/۹۲۶۶ است. به دست آمد که بیشترین مقدار را نسبت به سایر مدل‌ها دارد. این در حالی است که در مدل‌های ۲ و ۳، این پارامتر به ترتیب، ۰/۹۰۲ و ۰/۹۱۲۵ به دست آمد. مشاهده می‌شود که مدل ۱ مقدار بهتری در مقایسه با دو مدل دیگر به دست می‌دهد. مقدار ضریب کارایی مدل در مرحله آموزش برای همه ماههای سال نسبت به دو مرحله دیگر بیشتر است. مقایسه مقدار این ضریب بین ماههای متفاوت برای مدل ۱ در مرحله آزمون نشان می‌دهد بیشترین و کمترین مقدار این ضریب، به ترتیب، مربوط به ماه آوریل و سپتامبر است. یکی دیگر از معیارهای به‌کاررفته در این تحقیق پارامتر انحراف است. مقادیر

درصد در مرحله آموزش، ۱۵ درصد در مرحله ارزیابی، و ۱۵ درصد در مرحله آزمون استفاده شد. با توجه به جداول هر ماه، مقدار R در مرحله آموزش در هر سه مدل برای کلیه ماههای سال یکسان است. مقدار R در مراحل ارزیابی و آزمون در هر سه مدل در ماههای می و جون و جولای یکسان، اما مقدار این آماره برای هر ۴L- (20N) معنی‌دارتر از دو مدل دیگر است. از بین ماههای مورد مطالعه، بهترین مقدار R در مراحل آزمون مربوط به ماههای آوریل و آگوست و کمترین مقدار مربوط به ماه سپتامبر است. البته در این ماهها نیز مقدار این ضریب در مدل ۱ بهتر از دو مدل دیگر به دست آمد. مقایسه مقادیر معیارهای خطای MSE و RMSE این سه مدل نشان می‌دهد کمترین مقادیر این دو آماره در هر سه مرحله مربوط به مدل ۱ (4L-20N) است. جدول ۷ میانگین نتایج اجرای هر سه مدل را در شش ماه سال ۲۰۱۰ نشان می‌دهد. با توجه به جدول ۷، مقادیر میانگین آماره RMSE برای مدل ۱ و ۲ و ۳ در مرحله آزمون، به ترتیب، ۱/۱۸۲۷ و ۱/۴۲۳۹ و ۱/۵۸۸۲ به دست آمد که کمترین مقدار مربوط به مدل ۱ است. همچنان، با توجه به جدول‌های ۱ تا ۶، مقدار این آماره در مراحل آموزش و ارزیابی در مدل ۱ مقدار مناسب‌تری در مقایسه با دو مدل دیگر داشت. با توجه به جدول ۷، میانگین آماره MSE در مرحله آزمون برای هر سه مدل ۱ و ۲ و ۳، به ترتیب، ۰/۹۳۸۰ و ۰/۹۵۶۹ و ۰/۱۰۰۲۸ به دست آمد. همان‌گونه که مشاهده می‌شود، در این آماره نیز کمترین مقدار مربوط به مدل ۱ است. به‌طور کلی، از مقایسه ماههای متفاوت، کمترین مقدار دو آماره MSE و RMSE در مرحله آزمون مربوط به ماه ژوئن، به ترتیب، ۰/۹۷۲۸ و ۰/۷۷۶۸ است و مدل ۱ در این ماه بهترین پیش‌بینی کوتاه‌مدت سرعت باد را دارد. این در حالی است که بیشترین مقدار این دو آماره در مرحله آزمون ماه سپتامبر، به ترتیب، ۱/۳۷۷۱ و ۱/۳۰۴۱ به دست آمد. مقایسه مقادیر آماره MSE و RMSE در هر سه

مقایسه نتایج این سه مدل را در مرحله آزمون نشان می‌دهد. در هر یک از این اشکال نتایج حاصل از هر سه مدل با داده‌های واقعی مقایسه شد. اجرای هر سه مدل و همچنین شکل ۲ نشان می‌دهد این روش در محاسبه کوتاه‌مدت سرعت باد نتایج مطلوبی به دست می‌دهد. از مقایسه شکل‌های هر سه مدل، مدل ۱ با داده‌های واقعی مطابقت بسیار خوبی دارد.

پارامتر انحراف است. مقادیر این ضریب در مرحله آموزش برای هر سه مدل مثبت بود و این موضوع بیش برآورد را نشان می‌دهد. مقدار متوسط این ضریب در مدل‌های ۱ و ۲ و ۳، به ترتیب، 0.043 و 0.013 و 0.017 به دست آمد. با توجه به جدول‌های ۱ تا ۶، کمترین مقدار این ضریب در مدل ۱ مربوط به ماه می با مقدار 0.020 و بیشترین مقدار آن مربوط به ماه جولای با مقدار 0.070 است. شکل‌های ۲-الف تا ۲-د



شکل ۲. مقایسه مقادیر سرعت باد (متر بر ثانیه) مشاهداتی و محاسباتی با استفاده از سه مدل مختلف در مرحله آزمون مدل در چهار ماه نمونه

جدول ۱. نتایج حاصل از اجرای سه مدل برای ماه آوریل

Train						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	0.982	-0.952	-0.05	-0.968	0.962	197
4L-30N	1.223	-0.951	-0.15	-0.963	0.753	421
4L-40N	1.534	-0.951	-0.21	-0.958	0.975	749
Validation						
4L-20N	1.242	-0.979	---	-0.966	0.892	176
4L-30N	1.050	-0.979	---	-0.962	0.753	324
4L-40N	1.761	-0.978	---	-0.954	0.975	547
Test						
4L-20N	1.351	-0.999	---	-0.963	0.933	183
4L-30N	1.741	-0.999	---	-0.959	0.932	324
4L-40N	1.961	-0.999	---	-0.951	0.934	548

جدول ۲. نتایج حاصل از اجرای سه مدل برای ماه می

Train						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۷۲	۰/۹۹۹	۰/۰۲	۰/۹۹۸	۰/۶۵۲	۴۲۵
4L-30N	۱/۰۳۳	۰/۹۹۹	۰/۱۱	۰/۹۵۵	۰/۸۲۲	۷۳۶
4L-40N	۱/۳۲۱	۰/۹۹۹	۰/۱۷	۰/۹۲۲	۰/۸۳۵	۱۴۲۷
Validation						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۱/۲۸۲	۰/۹۷۶	---	۰/۹۵۶	۰/۵۳۲	۷۵
4L-30N	۱/۷۳۰	۰/۹۷۵	---	۰/۹۳۳	۰/۶۲۳	۱۰۷
4L-40N	۱/۸۱۰	۰/۹۷۵	---	۰/۹۲۲	۰/۶۰۲	۳۶۶
Test						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۱/۳۶۲	۰/۹۴۲	---	۰/۹۵۱	۰/۹۹۲	۷۷
4L-30N	۱/۴۱۲	۰/۹۴۲	---	۰/۹۳۸	۱/۰۲۱	۱۰۳
4L-40N	۱/۵۲۱	۰/۹۴۲	---	۰/۹۱۲	۱/۱۶۵	۳۶۹

جدول ۳. نتایج حاصل از اجرای سه مدل برای ماه ژوئن

Train						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۷۷۳	۰/۹۹۹	۰/۰۳	۰/۹۵۵	۰/۷۰۴	۲۴۱
4L-30N	۰/۸۶۰	۰/۹۹۹	۰/۱۳	۰/۹۴۰	۰/۷۰۲	۴۷۲
4L-40N	۰/۹۹۳	۰/۹۹۹	۰/۱۶	۰/۹۳۵	۰/۷۵۲	۱۳۷۳
Validation						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۶۳	۰/۹۵۸	---	۰/۹۷۳	۰/۷۳۷	۱۶۷
4L-30N	۰/۹۷۲	۰/۹۵۸	---	۰/۹۶۳	۰/۸۴۲	۲۴۹
4L-40N	۱/۱۱۰	۰/۹۵۸	---	۰/۹۴۱	۰/۸۴۸	۴۲۳
Test						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۷۲	۰/۹۴۹	---	۰/۹۴۲	۰/۷۷۷	۱۶۵
4L-30N	۱/۳۱۲	۰/۹۴۹	---	۰/۹۴۰	۰/۸۳۴	۲۴۹
4L-40N	۱/۵۱۰	۰/۹۴۹	---	۰/۹۳۹	۰/۸۹۵	۴۲۳

جدول ۴. نتایج حاصل از اجرای سه مدل برای ماه جولای

Train						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۷۶	۰/۹۹۹	۰/۰۷	۰/۹۹۲	۰/۵۵۱	۲۰۳
4L-30N	۱/۱۱۱	۰/۹۹۹	۰/۱۱	۰/۹۷۳	۰/۶۲۳	۷۱۰
4L-40N	۱/۱۳۳	۰/۹۹۹	۰/۱۷	۰/۹۶۱	۰/۶۲۱	۱۳۹۱
Validation						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۸۳	۰/۹۶۵	---	۰/۹۸۲	۰/۷۷۷	۹۹
4L-30N	۰/۹۹۲	۰/۹۶۵	---	۰/۹۷۷	۰/۷۸۱	۱۳۰
4L-40N	۱/۰۱۲	۰/۹۶۵	---	۰/۹۶۲	۰/۸۵۱	۲۶۷
Test						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۹۸	۰/۹۴۱	---	۰/۹۱۲	۰/۸۱۰	۱۰۱
4L-30N	۱/۳۲۲	۰/۹۴۱	---	۰/۹۱۰	۰/۸۰۳	۱۳۰
4L-40N	۱/۴۱۲	۰/۹۴۱	---	۰/۹۰۲	۰/۸۵۲	۲۶۸

جدول ۵. نتایج حاصل از اجرای سه مدل برای ماه آگوست

Train						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۸۱۸	۰/۹۹۹	۰/۰۴	۰/۹۶۷	۰/۶۷۲	۲۱۳
4L-30N	۰/۹۳۲	۰/۹۹۹	۰/۱۳	۰/۹۵۲	۰/۶۵۲	۶۳۲
4L-40N	۰/۹۹۲	۰/۹۹۹	۰/۱۵	۰/۹۴۷	۰/۶۸۳	۹۲۳
Validation						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۳۳	۰/۹۶۳	---	۰/۹۵۵	۰/۷۵۳	۱۲۵
4L-30N	۰/۹۹۶	۰/۹۶۲	---	۰/۹۳۳	۰/۷۶۱	۲۹۷
4L-40N	۱/۱۷۲	۰/۹۶۲	---	۰/۹۳۱	۰/۷۷۱	۳۴۷
Test						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۱/۳۰۵	۰/۹۵۹	---	۰/۹۵۳	۰/۸۱۲	۱۲۳
4L-30N	۱/۳۱۳	۰/۹۵۹	---	۰/۹۴۲	۰/۸۴۰	۲۹۹
4L-40N	۱/۴۱۳	۰/۹۵۹	---	۰/۹۴۲	۰/۸۵۱	۳۵۱

جدول ۶. نتایج حاصل از اجرای سه مدل برای ماه سپتامبر

Train						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۸۸	۰/۹۹۹	۰/۰۵	۰/۹۴۴	۰/۷۳۲	۳۰۲
4L-30N	۰/۹۹۱	۰/۹۹۹	۰/۱۶	۰/۹۴۳	۰/۷۷۹	۶۲۱
4L-40N	۰/۹۹۹	۰/۹۹۹	۰/۱۶	۰/۹۴۲	۰/۸۳۳	۹۷۶
Validation						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۱/۱۱۳	۰/۹۴۹	---	۰/۸۴۸	۰/۹۷۵	۱۵۸
4L-30N	۱/۳۲۵	۰/۹۴۲	---	۰/۸۱۴	۰/۹۸۲	۳۷۰
4L-40N	۱/۴۱۳	۰/۹۴۳	---	۰/۸۳۱	۰/۹۳۰	۴۰۲
Test						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۱/۳۷۷	۰/۹۳۸	---	۰/۸۳۸	۱/۳۰۴	۱۹۵
4L-30N	۱/۴۴۲	۰/۹۳۶	---	۰/۸۳۲	۱/۳۱۲	۳۷۶
4L-40N	۱/۷۴۲	۰/۹۳۲	---	۰/۸۲۹	۱/۳۲۰	۴۱۱

جدول ۷. میانگین نتایج حاصل از اجرای سه مدل

Train						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۰/۹۱۸	۰/۹۹۹	۰/۰۴	۰/۹۷۱	۰/۶۵۹	۲۳۳
4L-30N	۱/۰۲۷	۰/۹۹۹	۰/۱۳	۰/۹۵۴	۰/۷۱۷	۵۹۹
4L-40N	۱/۱۶۲	۰/۹۹۹	۰/۱۷	۰/۹۴۳	۰/۷۴۳	۹۷۷
Validation						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۱/۰۸۶	۰/۹۶۸	---	۰/۹۴۷	۰/۷۴۴	۱۳۳
4L-30N	۱/۲۵۸	۰/۹۶۷	---	۰/۹۳۰	۰/۷۹۰	۲۴۶
4L-40N	۱/۳۷۹	۰/۹۶۷	---	۰/۹۲۴	۰/۸۲۹	۳۹۲
Test						
مدل	RMSE	R	Bias	EF	MSE	Time
4L-20N	۱/۱۸۳	۰/۹۴۷	---	۰/۹۲۷	۰/۹۳۸	۱۳۴
4L-30N	۱/۴۲۴	۰/۹۴۶	---	۰/۹۲۰	۰/۹۵۷	۲۴۶
4L-40N	۱/۵۸۸	۰/۹۴۵	---	۰/۹۱۲	۱/۰۰۳	۳۹۵

نتیجه گیری

یکی از راههای هدررفت آب در مناطق مختلف اقلیمی تبخیر تعرق است. این پدیده در مناطق جنوبی کشور در اثر عوامل مختلف اقلیمی شدت می‌یابد. یکی از متغیرهای بسیار تأثیرگذار سرعت باد است که در مناطق تحت فرارفت گرمایی بالا تأثیر آن بیشتر می‌شود. در این مطالعه، با استفاده از رویکرد شبکه عصبی مصنوعی، سرعت باد در شهرستان جیرفت به صورت کوتاه‌مدت پیش‌بینی شد. در اجرای این برنامه toolbox متلب ۲۰۱۰ به کار رفت. از مقایسه نتایج اجرای مدل‌های متفاوت، بهترین نتیجه از نظر مقایسه شاخص‌های آماری مورد استفاده، مربوط به شبکه چهار لایه با ۲۰ نورون در لایه اول و لایه‌های پنهان و ۱ نورون در لایه آخر است. مقدار متوسط ضریب R و سرعت اجرا در مرحله آموزش در این مدل برای کل

REFERENCES

- Akbarpour, M. and Tafreshi, M. M. (2010). Optimal operation of a hybrid systems wind power plant-pumped storage, In: Proceedings of 25th International Power System conference, Tehran. (In Farsi).
- Akinci, T. C. (2011). Short term wind speed forecasting with ANN in Batman, Turkey, In: Proceedings of Electronics and Electrical Engineering Conference, OCT. 28- Nov, 2 Shanghai, China, No. 1, (107).
- Cadenas, E. and Rivera, W. (2010). Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA-ANN model, *Renewable Energy*, 35, 2732-2738.
- Erasmo, C. and Wilfrido, R. (2009). Short term wind speed forecasting in La Venta, Oaxaca, Mexico, using Artificial Neural Networks, *Renewable Energy*, 34(12), 274–278.
- Ghabaei Sough, M. Mosaedi, A. Hesam, M. and Hezarjaribi, A. (2010). Evaluation effect of input parameters preprocessing in Artificial Neural Networks (ANNs) by using stepwise regression and gamma test techniques for fast estimation of daily evapotranspiration, *Journal of Water and Soil*, 24 (3), 610-624. (In Farsi).
- Ghiasi, M. S. and 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. (In Farsi).
- Kouchakzadeh, M. and Bahmani, A. (2005). Assessment of Artificial Neural Networks revenue in reducing required parameters for estimation of reference evapotranspiration, *Journal of Agricultural Sciences*, 11(4), 87-97. (In Farsi).
- Monfared, M. Rategar, H. and Sadeghian, A. (2006). New Statistical Model for Predicted changes in wind speed and direction, In: Proceedings of 21th International Power System conference, Tehran. (In Farsi).

- Nash, J. E. and Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I - A discussion of principles, *Journal of Hydrology*, 10 (3), 282–290.
- Oztopal, A. (2006). Artificial neural network approach to spatial estimation of wind velocity data, *Energy Conversion and Management*, 47, 395-406.
- Salehi, F. Lacroix, R. and Wade, K. M. (1998). Effects of learning parameters and data presentation on the performance of back propagation networks for milk yield prediction, *Transaction of ASAE*, 41(1), 253-259.
- Singh, S. Bhatti, T. S. and Kothari, D. P. (2006). A Review of wind-resource-assessment technology, *Journal of Energy Engineering*, 132, 1(8), 8-14.
- Yao Lee, C. Shen, Y. X. Cheng Cheng, J. Li, Y. and Wen Chang, C. (2009). Neural networks and particle swarm optimization based MPPT for Small wind power generator, *World Academy of Science, Engineering & Technology*, 60, 17-23.