

واژه‌های کلیدی: پیش‌بینی، سرعت باد، موجک، شبکه عصبی موجکی، شبکه‌های فازی - عصبی موجکی

مقدمه

امروزه کم‌آبی یکی از بزرگترین معضلات در بسیاری از نقاط جهان و از جمله ایران محسوب می‌گردد. کمبود بارش در مناطق مرکزی و عدم نفوذپذیری سریع آب در خاک منجر می‌شود که بیش از ۷۰ درصد بارش دریافتی تبخیر گردد. یکی از عوامل مهم و موثر در افزایش میزان تبخیر، سرعت باد می‌باشد. به همین دلیل اندازه‌گیری سرعت و جهت باد در مناطق مختلف بسیار حائز اهمیت می‌باشد. علاوه بر این اندازه‌گیری سرعت و جهت باد از جمله مسائل مهم و مورد توجه در احداث سازه‌های آبی و حوضچه‌ها نیز می‌باشد. از دیگر موارد اهمیت اندازه‌گیری سرعت باد، مقدار انرژی باد به عنوان یک منبع تجدیدپذیر می‌باشد که بیشترین رشد را در میان بخش‌های مختلف تولید انرژی در جهان طی سال‌های ۲۰۰۰ تا ۲۰۰۴ میلادی به خود اختصاص داده است [۲۲]. مطابق با بسیاری از پیش‌بینی‌ها، استفاده از انرژی باد، بیشترین پیشرفت را در بین تمامی منابع انرژی خواهد داشت [۲]. غیر قابل پیش‌بینی بودن پارامترهای باد، بزرگترین ضعف آن در بسیاری از موارد گزارش شده است. در بیشتر زمینه‌های، مهمترین مؤلفه‌های مؤثر پارامتر باد، سرعت و جهت وزش باد می‌باشد. در نتیجه با توجه به اهمیت برآورد مؤلفه‌های باد، توانایی پیش‌بینی سرعت و جهت وزش باد، الزامی به نظر می‌رسد [۷].

در دهه‌های اخیر تلاش‌های فراوانی جهت پیش‌بینی پارامترهای باد در بازه‌های زمانی کوتاه مدت و تا حدودی میان مدت، انجام گرفته است که این تلاش‌ها به دو دسته اصلی تقسیم می‌شوند؛ دسته اول، بر پایه تکنیک‌های آماری استوارند و شامل روش‌های پیش‌بینی هواشناسی عددی (NWP) می‌باشند. این روش که مدل سری زمانی نیز نامیده می‌شود، ساده‌ترین روشی است که مورد استفاده قرار می‌گیرد. فرض اصلی در این روش، آن است که اندازه سرعت باد در گام بعدی، از روی داده‌های سرعت باد قبلی، با استفاده از روش‌های آماری همچون حداقل سازی میانگین مجذور خطا، برآورد می‌گردد و فراگیرترین آنها میانگین متحرک اتورگرسیون (ARMA)^۵

بررسی امکان پیش‌بینی سرعت باد با استفاده از مدل‌های هیبرید شبکه‌های عصبی، شبکه‌های فازی-عصبی و تئوری موجک (مطالعه موردی: ایستگاه سینوپتیک یزد)

ه. افخمی^۱، علی طالبی^۲، مژده محمدی^۳، فرزانه فتوحی^۴
تاریخ دریافت: تاریخ پذیرش:



چکیده

پیش‌بینی مؤلفه‌های باد از جمله سرعت باد یکی از عوامل مهم به خصوص در بحث تبخیر در یک حوزه آبخیز محسوب می‌گردد. در این مقاله سعی گردید، جهت افزایش کارایی مدل‌های هوش مصنوعی، در پیش‌بینی سرعت باد، دو مدل شبکه عصبی و فازی-عصبی با تئوری موجک ترکیب شده و دو مدل هیبرید جدید ارائه گردید. در این تحقیق با استفاده از برخی پارامترهای اقلیمی ایستگاه همدیدی یزد از جمله سرعت باد، دمای متوسط، دمای بیشینه، رطوبت نسبی و تبخیر، سرعت باد در مقیاس ماهانه برآورد گردید و سپس کارایی دو مدل‌های هیبرید شبکه عصبی موجکی و شبکه فازی-عصبی موجکی با مدل‌های شبکه عصبی و فازی-عصبی در پیش‌بینی سرعت باد ۱۲ ماه آینده مورد مقایسه قرار گرفت. در نهایت جهت تأیید کارایی بهترین مدل، با استفاده از پارامترهای اقلیمی مؤثر سال ۱۳۸۳ سرعت باد در سال ۱۳۸۴ پیش‌بینی گردید. نتایج بدست آمده در مرحله ارزیابی مدل‌ها، تفاوت قابل ملاحظه عملکرد بهتر شبکه‌های عصبی موجکی و فازی-عصبی موجکی را نسبت به مدل‌های شبکه عصبی و فازی-عصبی نشان دادند. شایان ذکر است در مرحله ارزیابی، کارایی بالای شبکه‌های فازی-عصبی موجکی، برتری این مدل را نسبت به سایر مدل‌ها به اثبات رسانید.

۱- نویسنده مسئول، دانشجوی دکتری، علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد، hamide.afkhani@gmail.com

۲- دانشیار دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد، talebisf@yazd.ac.ir

۳- دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد، mohammadi.mojdeh@gmail.com

۴- دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد، farzaneh.fotouhi@gmail.com

5 - Numerical Weather Prediction

6 - Mean Square Error

7 - Auto Regressive Moving Average

روز از شبکه عصبی مصنوعی استفاده نمود. کادناس و ریورا [۳] جهت پیش‌بینی سرعت باد از دو روش شبکه‌های عصبی مصنوعی و روش آماری (ARIMA)° استفاده کردند، نتایج برتری شبکه عصبی مصنوعی را در پیش‌بینی سرعت باد نسبت به روش دیگر نشان داد. اکونومو و همکاران [۱۰] از مدل‌های شبکه عصبی جهت تعیین تعداد مطلوب توربین‌های بادی و کل نیروی تولید شده در مزارع بادی استفاده کردند. نتایج حاصل از مدل شبکه عصبی در این تحقیق رضایت‌بخش گزارش شد. کینگ و همکاران [۲۳] جهت پیش‌بینی سرعت باد از مدل‌های ARIMA چند متغیره و مدل‌های شبکه عصبی برگشتی^۱ استفاده کردند. نتایج نشان دادند مدل‌های چند متغیره نسبت به مدل‌های تک متغیره و شبکه عصبی برگشتی کارایی بهتری را نشان می‌دهد. لیو و همکاران [۱۷] جهت پیش‌بینی سرعت باد از دو مدل هیبرید استفاده کردند. در مدل هیبرید اول، شبکه‌های عصبی با مدل ARIMA ترکیب شد و در مدل هیبرید دوم، مدل ARIMA با مدل کالمن فیلتر^۲ ترکیب گردید. نتایج عملکرد دو مدل هیبریدی را خوب برآورد نمود. لیو و همکاران [۱۶] در تحقیق دیگری پیش‌بینی سرعت باد را با استفاده از یک مدل هیبریدی که ترکیبی از مدل شبکه عصبی و مدل تجربی تجزیه^۳ می‌باشد، انجام دادند و نتایج بدست آمده را با مدل شبکه عصبی و ARIMA مقایسه کردند. نتایج برتری مدل هیبریدی را نسبت به دو مدل دیگر نشان دادند. فیلیپولوس و همکاران [۲۱]، سرعت باد در ساعات آینده را در محیط‌های ساحلی با توپوگرافی پیچیده با استفاده از دو نوع شبکه عصبی پیش‌تغذیه پیش‌بینی کردند.

همچنین در زمینه استفاده از تئوری موجک می‌توان به تحقیق لو و ونگ [۱۵] اشاره کرد. تورنسی و کامپو [۲۶] نیز کاربردهای عملی این روش را در هواشناسی و اقلیم با مثال‌هایی از سری‌های زمانی نوسانات جنوبی النینو^۴ بیان، و مفاهیم سطوح اطمینان در تحلیل موجک را با جزئیات کامل تشریح کردند. دادسنکو و همکاران [۸] با استفاده از این روش به بررسی و تحلیل داده‌های بارش شهر ماتسویاما^۱ پرداخته و نتایج قابل توجهی در ارتباط با تغییرپذیری بارش در مقیاس‌های متفاوت به دست آوردند. کیم و والدس [۱۳] از مدل پیوسته بر پایه تبدیل موجک دو تایی^{۱۱} و شبکه عصبی مصنوعی برای پیش‌بینی خشکسالی در رودخانه کنچز^{۱۲} در مکزیک استفاده کردند. این محققین برای پیش‌بینی سیگنال‌های زیرین^{۱۳} حاصل از تجزیه موجک و نیز بازسازی سیگنال اصلی از سیگنال‌های زیرین، از شبکه عصبی مصنوعی استفاده کردند. در این تحقیق از

می‌باشد [۲۵، ۲۹، ۳۰]. پیش‌بینی‌ها با استفاده از حجم وسیع داده‌های اندازه‌گیری شده در ایستگاه‌های هواشناسی و مدل‌های بسیار بزرگ و پیچیده کامپیوتری که برای تغییرات اتمسفریک و آب و هوایی بدست آمده‌اند، صورت می‌پذیرد. این مدل‌ها، توسط سازمان‌های هواشناسی ملی، مورد استفاده قرار می‌گیرند. NWPها علاوه بر سرعت، قادر به پیش‌بینی جهت باد نیز می‌باشند. به سبب حجم داده‌های ورودی مورد نیاز بسیار زیاد و حجم بالای پردازش‌ها، استفاده از این مدل‌ها برای پیش‌بینی‌های کوتاه مدت میسر نیست [۳۰]. دسته دوم، مبتنی بر روش‌های هوش مصنوعی^۱ می‌باشند. امروزه روش‌های پیش‌بینی متعددی با استفاده از شبکه‌های عصبی مصنوعی^۲ و منطق فازی^۳ برای مدل کردن سرعت باد، بعنوان یک پدیده فیزیکی کاملاً غیرخطی، مورد استفاده قرار گرفته‌اند تا مقدار سرعت باد در چند گام زمانی بعدی را پیش‌بینی کنند که بعضی نیز به نتایج مناسب‌تری نسبت به روش‌های قبلی دست یافته‌اند [۱۹، ۲۹، ۱۱]. در کلیه روش‌های تشریح شده، خطای پیش‌بینی‌ها، با بزرگ شدن بازه زمانی پیش‌بینی، افزایش یافته و به سرعت از واقعیت فاصله می‌گیرند. این در صورتی است که پیش‌بینی بلند مدت پارامترهای باد، از جنبه‌های گوناگون حائز اهمیت است. یکی از روش‌های موفق در زمینه پیش‌بینی غیر خطی سری‌های زمانی استفاده از تحلیل موجک^۴ می‌باشد که به عنوان روشی نوین و بسیار موثر در زمینه آنالیز سیگنال‌ها و سری‌های زمانی موثر واقع شده است. تلفیق موجک با شبکه‌های عصبی مصنوعی و فازی-عصبی منجر به توسعه مدل‌های جدیدی به نام شبکه‌های عصبی موجکی و فازی-عصبی موجکی شده است. این مدل‌ها، هر دو قابلیت‌های سودمند مدل‌های عصبی و فازی-عصبی به همراه تحلیل موجک را دارا می‌باشند، به همین دلیل توانایی بالایی را در پیش‌بینی‌های سری زمانی دارند. تاکنون مطالعات و تحقیقات زیادی در زمینه پیش‌بینی سرعت باد با روش‌های مختلف صورت گرفته است. همچنین تحقیقات گسترده‌ای در مورد پیش‌بینی پارامترهای اقلیمی و سری‌های زمانی با استفاده از روش موجک و یا تلفیق آن با هوش مصنوعی صورت گرفته است. از جمله تحقیقاتی که در زمینه پیش‌بینی سرعت باد صورت گرفته می‌توان به کار الکسیدیس و همکاران [۱] اشاره کرد. در این تحقیق پیش‌بینی سرعت باد متوسط، برای گام‌های زمانی ۱۰ دقیقه و یک ساعت با به کارگیری شبکه‌های عصبی انجام گرفت و از پارامترهای سرعت باد و جهت باد به عنوان ورودی به شبکه‌های عصبی استفاده گردید. پوتر و نگویسکی [۲۲] یک سیستم استنتاجی فازی را برای پیش‌بینی بسیار کوتاه مدت باد بکار بردند. از توپال [۲۰] برای پیش‌بینی باد از داده‌های جمع‌آوری شده از چند منطقه با فواصل مشخص استفاده کرد و سپس برای یافتن ضرایب وزنی مربوط به هر یک، در پیش‌بینی نهایی، برای هر

5- Auto Regressive Integrated Moving Average

6-Time lag recurrent network

7- Kalman Filter (KF)

8- Empirical Mode Decomposition

9- Alnino

10-Matsuyama

11- Dyadic wavelet

12- Conches

13- sub-signals

1- Artificial Intelligent

2- Artificial Neural Network

3-Active Neuro-Fuzzy Inference System

4- Wavlet

ایستگاه‌های موجود در استان می‌باشد. اساس انتخاب این ایستگاه نیز وجود طول دوره مشترک آمار بلند مدت پارامترهای اقلیمی می‌باشد. جهت پیش‌بینی سرعت باد در این ایستگاه ابتدا همبستگی پارامترهای اقلیمی با سرعت باد اندازه‌گیری و سپس برخی از پارامترها انتخاب گردیدند. این پارامترها، شامل دمای متوسط T_{ave} با همبستگی ۰/۳۷ درصد، دمای بیشینه T_{max} با همبستگی ۰/۳۵ درصد، رطوبت نسبی R_H با همبستگی ۰/۴۰ درصد، تبخیر ماهانه E_R با همبستگی ۰/۳۹ درصد و سرعت باد W_s در بازه زمانی سال‌های ۱۳۵۴-۱۳۸۴ می‌باشد.

بر این اساس با مجموع ۲۸ سال داده‌های ماهانه سال ۱۳۵۴ تا ۱۳۸۲ به عنوان ورودی و خروجی، در مرحله آموزش و آزمایش مدل مورد استفاده قرار گرفت و در نهایت به منظور تأیید مدل تنها با معرفی داده‌های ورودی سال ۱۳۸۳ مقادیر سرعت باد سال ۱۳۸۴ پیش‌بینی گردید. این مقادیر خارج از مدل با مقادیر واقعی سال ۱۳۸۴ مقایسه گردید و نتایج ارائه شد. به این منظور ابتدا داده‌ها مطابق با رابطه یک استاندارد شدند و سپس با ترکیبات مختلف پارامترهای ورودی مورد آموزش^۸ و در ادامه آزمایش^۹ قرار گرفتند. لازم به ذکر است ۷۰ درصد داده‌ها به صورت تصادفی به عنوان داده‌های آموزشی و ۳۰ درصد داده‌ها به عنوان داده‌های آزمایشی انتخاب گردید (داده‌های سالهای ۱۳۵۴-۱۳۸۲)

$$X_n = \frac{X_o - X_{min}}{X_{max} - X_{min}} \quad (1)$$

در رابطه (۱) X_n داده‌های نرمال شده، X_o داده‌های واقعی، X_{max} بیشینه داده‌ها و X_{min} کمینه داده‌ها می‌باشد.

در مرحله بعد پیش‌بینی سرعت باد با استفاده از چهار روش شبکه عصبی، شبکه فازی عصبی، شبکه عصبی موجکی و شبکه فازی-عصبی موجکی انجام و در هر مرحله نتایج مورد ارزیابی قرار گرفتند. پس از اخذ بهترین نتایج، جهت تأیید^{۱۰} نتایج بدست آمده با مدلی که بالاترین ضریب کارایی و کمترین میزان خطا را به همراه داشت، داده‌های سال ۱۳۸۳، به عنوان ورودی به مدل معرفی شد و سپس سرعت باد سال ۱۳۸۴ به عنوان خروجی پیش‌بینی گردید. (۱۲ ماه بعد) و نتایج این پیش‌بینی با مقادیر واقعی سال ۱۳۸۴ مورد مقایسه قرار گرفت. (لازم به ذکر است آمار سال ۱۳۸۳ در هیچکدام از مراحل آموزش و آزمایش مدل‌ها مورد استفاده قرار نگرفتند و تنها جهت تأیید مدل به کار گرفته شدند.)

شبکه عصبی موجکی

ترکیب تئوری موجک و شبکه عصبی منجر به توسعه شبکه‌های عصبی موجکی می‌شود [۲۲]. این شبکه‌ها طبقه‌ای از شبکه‌های پیشرو هستند که توابع فعال نرون‌های لایه مخفی از توابع موجک

الگوریتم آتروس^۱ برای تبدیل موجک دوتایی گسسته^۲ همراه با سه لایه پیش‌خور^۳ شبکه عصبی به منظور پیشگویی سری‌های زمانی هیدرولوژیکی استفاده گردید و جهت شناسایی سیگنال‌های اقلیمی، تئوری تحلیل موجک به کار گرفته شد. کاننس و همکاران [۴] بر روی اثر پردازش مقدماتی داده‌ها در کاربرد مدل شبکه عصبی مصنوعی با استفاده از تبدیل موجکی پیوسته و گسسته تحقیق کردند. نتایج آنها نشان داد که آموزش شبکه با پردازش مقدماتی داده‌ها اجرای بهتری از آموزش شبکه تجزیه‌ناپذیر سیگنال‌های نارس آشفته^۴ دارد. توشیکایانو و سانسی گولو [۲۷] براساس تحلیل موجک به بررسی تغییرات دهه و سالانه دما و بارش در جنوب برزیل^۵ پرداختند. کائو و همکاران [۱۴] نیز تغییرپذیری و قابلیت پیش‌بینی بارش را در تایوان با کمک این روش بررسی کردند و پس از به دست آوردن مدل‌های غالب بارش فصلی، با استفاده از شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک، مدلی را برای شبیه‌سازی بارش در تایوان^۶ معرفی کردند. هانگ [۱۲] کاهش ابعاد سری‌های هیدرولوژیکی را با استفاده از تبدیل موجک گسسته انجام داد. در این تحقیق خوشه‌بندی سری‌ها با استفاده از خوشه‌بندی لایه‌ای انجام گرفت. وانگ و همکاران [۲۸] جهت اصلاح داده‌های دستی سرعت باد به صورت ساعتی از روی داده‌های اتوماتیک، از شبکه‌های عصبی موجکی استفاده کردند. نتایج بدست آمده با استفاده از این مدل رضایت‌بخش گزارش گردید.

با توجه به نتایج بررسی‌های انجام شده انتظار می‌رود که استفاده از آنالیز موجک در تلفیق با مدل‌های هوش مصنوعی منجر به افزایش کارایی آن نسبت به استفاده از این مدل‌ها به صورت مفرد گردد. لذا در این تحقیق سعی شده است تا با بکارگیری چهار روش شبکه عصبی پرسپترون چند لایه^۷، سیستم عصبی-فازی-عصبی، شبکه‌های عصبی موجکی و شبکه‌های فازی-عصبی موجکی، تأثیر تلفیق مدل موجک با مدل‌های هوش محاسباتی در حالت منفرد و ترکیبی جهت پیش‌بینی سرعت متوسط باد ماهانه تا یک سال بعد در ایستگاه همدیدی یزد بررسی گردد. مدل‌های هیبریدی جدید می‌تواند در افزایش دقت پیش‌بینی سرعت باد نسبت به روش‌های شبکه عصبی و فازی-عصبی بسیار موثر واقع گردد.


مواد و روش‌ها

منطقه مورد مطالعه و آماده‌سازی داده‌ها:

ایستگاه همدیدی یزد با موقعیت ۵۴ درجه و ۱۷ دقیقه طول شرقی و ۳۱ درجه و ۵۳ دقیقه عرض شمالی و ارتفاع ۱۲۳۰ متر از سطح دریا دارای آمار اقلیمی کامل و طولانی مدت، نسبت به سایر

- 1 - a trous
- 2 - discrete dyadic wavelet transform
- 3 - feed forward
- 4 - Noisy
- 5 - Brazil
- 6 - Tyvan
- 7 - Multilayer Perceptron

- 8 - Calibration
- 9 - Evaluation
- 10 - verification



شکل ۱- طرح کلی از یک نمونه شبکه عصبی موجکی
Figure1- A schematic of a typical wavelet neural network

پیوسته معکوس^۶ از رابطه زیر بدست می آید:

$$f(t) = \frac{1}{C_f} \int_R \frac{1}{a^2} w_f(a, b) h^*\left(\frac{t-b}{a}\right) da db \quad (۴)$$

که $C_f = \frac{1}{2\pi} \int_R \frac{h(\omega)^2}{|\omega|^2} d\omega < \infty$ مقدار ثابتی هست که به تابع $h(t)$ بستگی دارد.

بر اساس تحلیل موجک، تبدیل موجک توانایی بالایی در استخراج انواع خصوصیات پارامترها از داده‌های آزمایشی با معادل‌سازی پارامترهای a و b دارد و چنانچه داده‌ها به اندازه کافی وجود داشته باشد با عملیات تبدیل معکوس موجکی داده‌ها به صورت دست نخورده ایجاد می‌گردند [۶، ۲۴].

شبکه‌های فازی- عصبی موجکی

شبکه‌های فازی- عصبی موجکی ترکیبی از سیستمی مبتنی بر شبکه‌های عصبی مصنوعی و فازی- عصبی و موجک می‌باشد به طوری که این شبکه‌ها با استفاده از قابلیت یادگیری شبکه‌های عصبی مصنوعی، رابطه ورودی- خروجی که از تئوری موجک (مطابق آنچه در بالا گفته شد) تبعیت می‌کند را به دست آورده و با استفاده از استدلال منطق فازی نتایج را ارائه می‌کند. در این شبکه‌ها سیگنال‌های ورودی و خروجی مطابق با یکی از توابع موجک مادر شکسته شده و خصوصیات پارامترها به صورت ضرائب جزئی‌تر به شبکه‌های فازی- عصبی معرفی می‌گردد. سپس این پارامترها در مدل‌های فازی- عصبی مطابق با الگوریتم آموزشی شبکه‌های عصبی مانند الگوریتم کاهش شیب نزولی^۷ آموزش دیده و نتایج به صورت فازی ارائه می‌گردد. بعد از ارائه ضرایب پیش‌بینی شده در مدل‌های

پیوسته تبعیت می‌کند [۳۱]. توابع موجک به دلیل اینکه از فاصله‌های زمانی طولانی مدت برای اطلاعات دارای فرکانس پایین و تناوب‌های کوتاه‌تر برای اطلاعات دارای فرکانس بالا استفاده می‌کند، در نتیجه توانایی شبکه‌های عصبی موجکی در تحلیل توابع غیر خطی می‌تواند بسیار بالا برآورد گردد [۵]. با توجه به آنچه بیان شد، این مدل می‌تواند در بسیاری از جنبه‌های مهندسی از جمله طبقه‌بندی و شناسایی سری‌های زمانی غیر خطی موثر واقع گردد. ساختار کلی شبکه‌های عصبی موجکی در شکل یک نشان داده شده است که اساس آن وجود لایه موجکی در لایه میانی می‌باشد.

چنانچه $h(t)$ موجک مادر باشد موجک $\{h_{a,b}\}$ می‌تواند از فرایند تاخیر^۱ و انتقال^۲ مشتق شده باشد [۹].

$$h_{a,b} = \frac{1}{\sqrt{|a|}} h\left(\frac{t-b}{a}\right) \quad b \in R, a \in R - \{0\} \quad (۲)$$

که پارامترهای a و b به ترتیب پارامترهای مقیاس^۳ و وضعیت^۴ در دامنه اعداد حقیقی R هستند. نظریه اساسی که پشت نظریه موجک می‌باشد با استفاده از علامت اختصاری $f(t)$ بیان می‌شود که این تابع به عنوان موجک مادر شناخته می‌شود. تبدیل موجک مادر از $f(t)$ مطابق با رابطه سه بیان می‌شود:

$$w_f(a, b) = \langle f, h_{a,b} \rangle = \frac{1}{\sqrt{|a|}} \int_R f(t) h^*\left(\frac{t-b}{a}\right) dt \quad (۳)$$

که علامت $\langle f, h_{a,b} \rangle$ نتیجه درونی $f(t)$ و $h_{a,b}$ را نشان می‌دهد. علامت * نشان‌دهنده مزدوج مختلط^۵ می‌باشد. فرایند تبدیل موجک

- 1- dilation
- 2- translation
- 3- scale
- 4- position
- 5- conjugate

6- inverse continuous wavelet
7- gradient descent

$$\delta_{a_t} = \frac{\partial E}{\partial a_t} = - \sum_{i=1}^l \sum_{n=1}^N (V_n^T(i) - V_n(i)W_{ti}) \frac{\partial h}{\partial a_t} \quad (10)$$

$$\delta_{b_t} = \frac{\partial E}{\partial b_t} = - \sum_{i=1}^l \sum_{n=1}^N (V_n^T(i) - V_n(i)W_{ti}) \frac{\partial h}{\partial b_t} \quad (11)$$

$$\delta_{u_{ti}} = \frac{\partial E}{\partial u_{ti}} = - \sum_{i=1}^l \sum_{n=1}^N (V_n^T(i) - V_n(i)W_{ti}) \frac{\partial h}{\partial \sum_{i=1}^s U_{ti} x_n(i)} x_n(i) \quad (12)$$

η فاکتور نرخ یادگیری⁴ در مدل فازی-عصبی موجکی می‌باشد. مقادیر بالای این فاکتور منجر به پایداری مدل و مقادیر کم منجر به کندشدن یادگیری می‌شود. نرخ یادگیری متناسب با تعداد دور⁵ یادگیری متفاوت است. α نیز فاکتور مومنتم⁶ بوده که برای جلوگیری از قرار گرفتن در کمینه‌های محلی⁷ استفاده می‌شود [28].

گام پنجم: میزان خطا (MSE)⁸ در این مرحله مطابق با رابطه 13 محاسبه می‌شود چنانچه خطا بیش از مقدار قابل قبول باشد این مرحله به مرحله سوم باز گردانده می‌شود.

$$MSE = \frac{1}{2} \sum_{i=1}^L \sum_{n=1}^N (V_n^T(i) - V_n(i))^2 \quad (13)$$

در این مقاله از شبکه‌های عصبی سه لایه موجکی و شبکه‌های فازی-عصبی موجکی استفاده گردیده است و جهت ارزیابی مقادیر پیش‌بینی شده با مقادیر واقعی پس از عملیات معکوس موجکی در این مدل‌ها، ضریب همبستگی مطابق با معادله 14 در دو مدل محاسبه گردید. علاوه بر این میزان خطا نیز مطابق با معادلات 15 و 16 و 17 با سه آماره ریشه میانگین مربعات خطا⁹ و میانگین مطلق خطا¹⁰ و میانگین مطلق درصد خطا¹¹ برآورد گردید و نتایج بر اساس بالاترین ضریب همبستگی و کمترین خطا مورد ارزیابی قرار گرفتند.

$$r = \sqrt{1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2}} \quad (14)$$

$$RMSE = \sqrt{\left(\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \right)} \quad (15)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad (16)$$

- 4- learning rate
- 5- Epoch
- 6- Momentum
- 7-Local minimum
- 8- Mean squar Error
- 9-Root Mean Squar Error
- 10- Mean Absolute Error
- 11- mean absolute percentage error

فازی-عصبی، مطابق با عملیات معکوس موجکی که در بالا نیز به آن اشاره گردید سیگنال‌های اصلی پیش‌بینی شده (خروجی‌ها) تولید می‌گردد.

فرایند آموزش در شبکه‌های عصبی موجکی و فازی-موجکی

همان‌گونه که بیان گردید اساس کار شبکه‌های عصبی موجکی و فازی-عصبی موجکی بر پایه شناخت خصوصیات جزئی هر سیگنال ورودی می‌باشد. زمانی که تعداد داده‌ها به اندازه کافی موجود باشد این مدل‌ها قادرند انواع مختلفی از الگوها را شبیه‌سازی نمایند. مدل‌های عصبی موجکی و فازی-عصبی موجکی بر اساس توابع مختلف موجکی و همچنین الگوریتم‌های مختلف، آموزش می‌بینند در این تحقیق از الگوریتم آموزشی لورنبرگ مارکوات¹ در شبکه‌های عصبی موجکی و الگوریتم پس انتشار خطا² در مدل فازی-عصبی موجکی استفاده شده است و تابع موجک مادر دابشیز³ در سطح سه، به عنوان تابع اساسی موجکی به کار رفته است. به طور کلی پنج گام آموزشی در فرایند آموزش دو مدل وجود دارد [6].

گام اول: فرایند مقداردهی به پارامترهای مدل‌های عصبی موجکی و فازی-عصبی موجکی. تعداد نرون‌های ورودی و خروجی به موجک به ترتیب با S و I بیان می‌گردد و تعداد نرون‌های موجک با T نمایش داده می‌شود. پارامتر مقیاس a_t ، پارامتر انتقال b_t ، وزن‌های گره‌های اتصال با U_{ii} و W_{ii} برخی مقادیر تصادفی می‌باشد. با این روش پارامترها طبق یک فرایند یکسان وزن می‌گیرند.

گام دوم: نمونه‌های ورودی آموزشی $X_{(n)}(s)$ و $V_{(n)}^T(I)$ مقادیر خروجی می‌باشد که S تعداد گره‌های ورودی و n هست n امین نمونه آموزش دیده و T سطح خروجی هدف می‌باشد.

گام سوم: خروجی از نمونه‌های $V_{(n)}(I)$ مطابق با پارامترهای صحیح مدل‌های عصبی موجکی و فازی-عصبی موجکی محاسبه می‌شود.

گام چهارم: قضاوت در مورد پارامترهای خروجی بر اساس قوانین آموزشی. برای مثال در شبکه‌های فازی-عصبی موجکی مطابق با الگوریتم پس انتشار خطا به این گونه عمل می‌شود:

$$U_{ti} = U_{ti} - \eta \delta_{v_{ti}} + \alpha \Delta U_{ti} \quad (5)$$

$$W_{ti} = W_{ti} - \eta \delta_{w_{ti}} + \alpha \Delta W_{ti} \quad (6)$$

$$a_t = a_t - \eta \delta_{a_t} + \alpha \Delta a_t \quad (7)$$

$$b_t = b_t - \eta \delta_{b_t} + \alpha \Delta b_t \quad (8)$$

$$\delta_{w_{ti}(j)} = \frac{\partial E}{\partial w_{ti}} = - \sum_{i=1}^l \sum_{n=1}^N (V_n^T(i) - V_n(i)h(\frac{\sum_{i=1}^s U_{ti} x_n(i) - b_t}{a_t})) \quad (9)$$

$$V_n(i)h(\frac{\sum_{i=1}^s U_{ti} x_n(i) - b_t}{a_t})$$

- 1- Levenberg-Marquardt
- 2- Back propagation
- 3- Daubechies

۱۳۸۳ انجام گرفت و با مقادیر واقعی آن سال مقایسه گردید. جدول یک نتایج حاصل از سه ترکیب مختلف مورد استفاده در شبکه‌های چند لایه پرسپترون و عصبی فازی-عصبی را نمایش می‌دهد. در اغلب موارد شبکه‌های فازی-عصبی، با تابع عضویت زنگوله‌ای و مدل فزایی تاکاگی و در مدل‌های پرسپترون، تابع فعال سیگموئید در لایه میانی و خروجی عملکرد بهتری داشتند. همچنین نمودارهای یک و دو نتایج داده‌های مشاهده‌ای و پیش‌بینی شده سرعت باد را در ترکیب شماره دو شبکه‌های فازی-عصبی و ترکیب شش شبکه‌های پرسپترون را در مرحله آزمایش نشان می‌دهند.

با توجه به نتایج جدول یک واضح است که در میان سه ترکیب متفاوت پارامترها، که در دو مدل مورد استفاده قرار گرفته است، در مدل فازی-عصبی ترکیب شماره دو با ضریب همبستگی ۰/۷۴ و بهترین MAE, RMSE, MAPE به ترتیب ۰/۰۱، ۰/۷۵ و ۰/۹۷ بهترین کارایی را نشان می‌دهد. در حالی که در مدل پرسپترون چند لایه

$$MAEP = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - P_i}{O_i} \right| \quad (17)$$

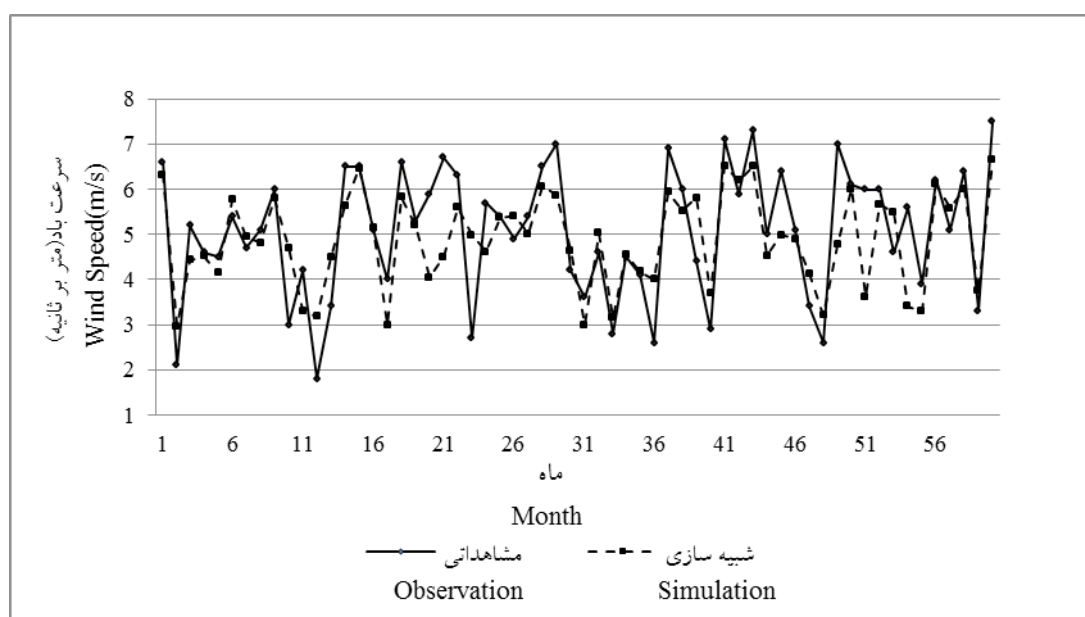
در روابط بالا O_i داده‌های مشاهده‌ای، P_i داده‌های شبیه‌سازی شده و n تعداد داده‌ها است. شایان ذکر است جهت انجام این پژوهش از نرم‌افزار مطلب استفاده شده است.

نتایج


در این تحقیق جهت پیش‌بینی سرعت باد ماهانه از چهار روش شبکه‌های پرسپترون چند لایه، شبکه‌های فازی-عصبی، شبکه‌های عصبی موجکی و شبکه‌های فازی-عصبی موجکی استفاده گردید و کارایی مدل‌ها مورد بررسی قرار گرفت. براین اساس از ترکیبات مختلف پارامترهای ورودی استفاده گردید و در ادامه جهت تأیید نتایج بهترین مدل، که دارای بالاترین ضریب کارایی و کمترین خطا بود فرایند پیش‌بینی سرعت باد سال ۱۳۸۴ با استفاده پارامترهای سال

جدول ۱- نتایج حاصل از پیش‌بینی سرعت باد با دو مدل شبکه عصبی پرسپترون و مدل فازی-عصبی در مرحله آزمایش
Table 1-The result of prediction wind speed by ANN and ANFIS in the testing phase

MAE	RMSE	MAPE	r	مدل	ترکیب ورودی	شماره ترکیب
				Model	Combine input	No. combine
0.81	0.97	0.11	0.74	ANFIS	$T_{ave} - T_{max} - W_s$	1
0.75	0.97	0.01	0.74	ANFIS	$T_{ave} - T_{max} - H - W_s$	2
0.86	1.05	0.17	0.73	ANFIS	$T_{ave} - T_{max} - H - E - W_s$	3
0.82	1.00	0.02	0.65	MLP	$T_{ave} - T_{max} - W_s$	4
0.83	1.05	0.10	0.74	MLP	$T_{ave} - T_{max} - H - W_s$	5
0.81	1.01	0.04	0.73	MLP	$T_{ave} - T_{max} - H - E - W_s$	6



نمودار ۱- مقایسه مقادیر واقعی و پیش‌بینی شده سرعت باد در ترکیب دو شبکه‌های فازی-عصبی
Graph 1-Comparison between observed and simulated wead speed in combination (2) ANFIS



نمودار ۲- مقایسه مقادیر مشاهداتی و شبیه سازی شده سرعت باد در ترکیب شش شبکه های عصبی پرسپترون
Graph ۲-Comparison between observed and simulated wead speed in combination (۶) ANN

جدول ۲- نتایج حاصل از پیش بینی سرعت باد با دو مدل شبکه عصبی موجکی و مدل فازی- عصبی موجکی

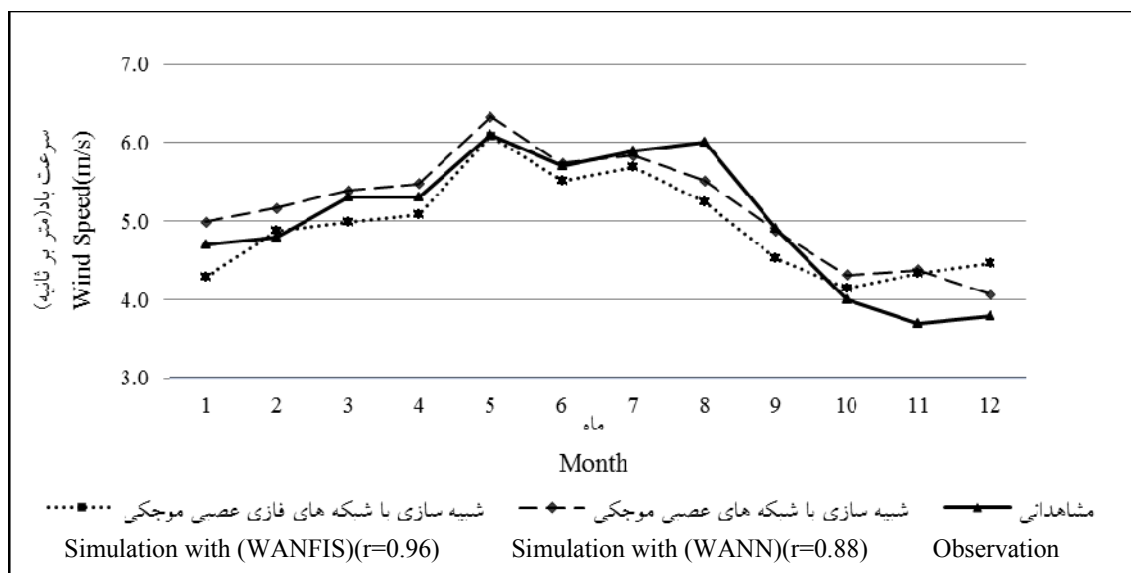
Table 1-The result of prediction wind speed by WANN and WANFIS

MAE	RMSE	MAPE	r	مدل	ترکیب ورودی	شماره ترکیب
				Model	Combine input	No. combine
0.45	0.52	0.08	0.96	WANFIS	$T_{ave} - T_{max} - W_s$	۱
0.24	0.31	0.02	0.96	WANFIS	$T_{ave} - T_{max} - H - W_s$	۲
0.33	0.41	0.03	0.97	WANFIS	$T_{ave} - T_{max} - H - E - W_s$	۳
0.50	0.61	0.01	0.98	WNN	$T_{ave} - T_{max} - W_s$	۴
0.50	0.60	0.10	0.98	WNN	$T_{ave} - T_{max} - H - W_s$	۵
0.33	0.40	0.02	0.98	WNN	$T_{ave} - T_{max} - H - E - W_s$	۶

بهترین کارایی و کمترین خطا را با ضریب کارایی ۰/۹۶ و RMSE مدل عصبی موجکی نیز همانند مدل شبکه عصبی ترکیب شماره شش کارایی بالاتری را با ضریب کارایی ۰/۹۸ و MAE، RMSE، MAPE به ترتیب ۰/۰۲، ۰/۲۴ و ۰/۳۱ داشته است و در مدل عصبی موجکی در همین سال مقایسه گردید و سرعت باد پیش بینی شده با سرعت باد واقعی در این سال مقایسه گردید. شایان ذکر است تفاوت این مرحله با مرحله آزمایش در این است که در این مرحله تنها ورودی به مدل داده شده است و مدل، خروجی را پیش بینی کرده است در صورتی که در مرحله آزمایش ورودی و خروجی هر دو به مدل داده می شود. همچنین داده های این مرحله در مرحله

بالاترین کارایی در ترکیب شماره شش با ضریب کارایی ۰/۷۳ و MAPE، MAE، RMSE به ترتیب ۰/۰۴، ۰/۸۱ و ۱/۰۱ مشاهده می شود. مقایسه بالاترین کارایی در دو مدل نشان می دهد که شبکه های فازی- عصبی با ضریب کارایی بالاتر و میزان خطای کمتر عملکرد بهتری را نسبت به شبکه عصبی پرسپترون نشان می دهد. همچنین نتایج حاصل از دو مدل شبکه عصبی موجکی و شبکه های فازی- عصبی موجکی در جدول شماره دو آورده شده است.

با توجه به نتایج حاصل از پیش بینی سرعت باد تفاوت قابل ملاحظه ای در عملکرد دو مدل عصبی موجکی و فازی- عصبی موجکی، در مقایسه با دو مدل شبکه های پرسپترون و فازی- عصبی ملاحظه می شود. نکته قابل ملاحظه ای که با مقایسه نتایج جدول شماره یک و دو مشاهده می گردد این است که در مدل فازی- عصبی موجکی نیز همانند مدل فازی- عصبی ترکیب شماره دو



نمودار ۳- مقایسه مقادیر مشاهداتی و شبیه سازی شده با دو مدل عصبی موجکی و فازی-عصبی موجکی سال ۱۳۸۴
Graph 3- Comparison between observed and simulated data by WANN and WANFIS in 1995

ضریب همبستگی به ۰/۹۶، و MAPE, MAE, RMSE به ترتیب ۰/۰۲، ۰/۲۴ و ۰/۳۱ ارتقا پیدا کرده است. همچنین نتایج بهترین کارایی شبکه عصبی پرسپترون نیز در شرایط بدون تلفیق با موجک از ۰/۷۳= و MAPE, MAE, RMSE به ترتیب ۰/۰۴، ۰/۸۱ و ۱/۰۱ به ۰/۹۸= و MAPE, MAE, RMSE به ترتیب ۰/۰۲، ۰/۳۳ و ۰/۴۰ در شرایط تلفیق با موجک بهبود یافت. در این تحقیق همچنین نتایج عملکرد شبکه‌های فازی-عصبی موجکی نسبت به شبکه‌های عصبی موجکی با خطای کمتری همراه بوده و در مجموع عملکرد برتر این مدل در میان چهار مدل مورد استفاده، به اثبات رسید. نتایج این تحقیق با نتایج حاصل از مطالعه وانگ و همکاران [۲۸] مقایسه گردید. مطالعه وانگ نیز توانایی مدل شبکه عصبی موجکی را جهت اصلاح داده‌های سرعت باد دستی با توجه به سرعت باد اتوماتیک به ثبت رسانید. نتایج مطالعه حاضر نیز در راستای مطالعه انجام شده توسط وانگ می‌باشد بطوریکه توانایی بالای مدل‌های تلفیقی شبکه عصبی موجکی و بخصوص مدل فازی-عصبی موجکی در پیش‌بینی ماهانه سرعت باد تأیید گردید.

منابع

- Alexiadis, M. C. Dokopoulos, P. S. and Sahsamanoğlu, H. S. 1998. Short-term forecasting of wind speed and related electrical power. *Solar Energy*. 63(1): 61-68, 1998.
- Burton, T. Sharpe, D. Jenkins, N. and Bossanyi, E. 2001. *Wind energy handbook*. Chichester: John Wiley and Sons.
- Cadenas, E. and Rivera, W. 2007. Wind speed forecasting in the south coast of Oaxaca, Mexico.

آموزش و آزمون مورد استفاده قرار نگرفته است. نمودار شماره سه مقایسه نتایج بدست آمده از پیش‌بینی سرعت باد با داده‌های واقعی در مرحله تأیید مدل در سال ۱۳۸۵ را نشان می‌دهد. با توجه به نمودار سه، ضریب کارایی بین ۱۲ داده پیش‌بینی شده با مدل‌های فازی-عصبی موجکی در مقایسه با داده‌های واقعی برابر ۰/۹۶ و با استفاده از مدل عصبی موجکی ۰/۸۶ برآورد گردید. نتایج در مرحله تأیید دو مدل، نشان می‌دهد در مجموع علی‌رغم نتایج رضایت‌بخش دو مدل عصبی موجکی و فازی-عصبی موجکی، مدل فازی-عصبی موجکی کارایی بالاتری را از خود نشان داده است.

بحث و نتیجه‌گیری

در تحقیق حاضر که به منظور پیش‌بینی سرعت ماهانه باد در ایستگاه سینوپتیک یزد انجام گرفت، دو مدل هیبرید عصبی موجکی و فازی-عصبی موجکی ارائه گردید. در این راستا به منظور افزایش عملکرد شبکه‌های عصبی و فازی-عصبی این دو مدل با آنالیز موجک ترکیب گردید، بدیهی است مدل‌های هیبرید ایجاد شده از توانایی بالای شبکه‌های عصبی و فازی عصبی و همچنین موجک، هر دو بهره می‌برد. در این راستا مقادیر خروجی موجک به عنوان مقادیر ورودی شبکه‌های عصبی و فازی-عصبی به کار گرفته شد. به منظور تأثیر عملکرد موجک در مدل‌های هیبریدی، نتایج بدست آمده از دو مدل هیبرید با نتایج حاصل از دو مدل شبکه عصبی و شبکه فازی-عصبی در شرایط منفرد و بدون تلفیق موجک با دو مدل نامبرده منجر به افزایش چشمگیری در بهبود کارایی آنها شده است، به طوری که ضریب همبستگی شبکه‌های فازی-عصبی در شرایط بدون تلفیق با موجک ۰/۷۴ و MAPE, MAE, RMSE به ترتیب ۰/۰۱، ۰/۷۵ و ۰/۹۷ برآورد گردیده است در حالی که در شرایط تلفیق با موجک

Wavelet analysis on the variability, teleconnectivity, and predictability of the seasonal rainfall of Taiwan: *Monthly Weather Review*. 138(1):162-175.

15- Lau, K. M. and Weng, H. Y. 1995. Climate signal detection using wavelet transform, How to make a time series sing. *Bulletin of the American Meteorological Society*. 76(12): 2391-2402.

16- Liu, H. Chen, C. Tian, H. and Li, Y. 2012. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks. *Renewable Energy*. 48,545-556.

17- Liu, H. Tian, H. and Li, Y. 2012. Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. *Applied Energy*. 98, 415-424.

18- Mellit, A. Benghanem, M. and Kalogirou, Sa. 2006. An adaptive wavelet-network model for forecasting daily total solar-radiation. *Applied Energy*. 83 (7):705-722.

19- Negnevitsky, M. and Potter, C. W. 2006. Innovative short-term wind generation prediction techniques. *Power Systems Conference and Exposition. PSCE'06. IEEE PES*. 60-65.

20- Oztopal, A. 2006. Artificial neural network approach to spatial estimation of wind velocity data. *Energy Conversion and Management*. 47(4):395-406.

21- Philippopoulos, K. and Deligiorgi, D. 2012. Application of artificial neural networks for the spatial estimation of wind speed in a coastal region with complex topography. *Renewable Energy*. 38(1): 75-82.

22- Potter, C. W. and Negnevitsky, M. 2006. Very short-term wind forecasting for Tasmanian power generation. *IEEE Transaction on power systems*. 21(2):965-972.

23- Qing, C. Ewing, B. T. and Thompson, M. A. 2012. Forecasting wind speed with recurrent neural networks. *European Journal of Operational Research*. Volume 221(1) : 148-154.

24- Rioul, O. Vetterli, M. 1991. Wavelets and signal processing. *IEEE Signal Processing Magazine*. 8(4):14-38.

25- Soder, L. Simulation of wind speed forecast

Renewable Energy. 32 (12) 2116-2128.

4- Cannas, B. Fanni, A. See, L. and Sias, G. 2006. Data preprocessing for river flow forecasting using neural network: wavelet transforms and data partitioning. *Physics and Chemistry of the Earth* 31(18): 1164-1171.

5- Cao, J. C. and Lin. X. C. Application of the diagonal recurrent wavelet neural network to solar irradiation forecast assisted with fuzzy technique. *Engineering Applications of Artificial Intelligence*. 21, 1255-1263.

6- Cui, W. Z. Zhu, C. C. Zhao, H. P. 2005. Prediction of thin film thickness of field emission using wavelet neural networks. *Thin Solid Films* 437(2): 224-229.

7- Damousis, I. G. and Dokopoulos, P. A. 2001. fuzzy expert system for the forecasting of wind speed and power generation in wind farms. In *Proceedings of the IE IEEE International Conference on Power Industry Computer Applications PICA 01*. 63-69 p.

8- Datsenko, N. M. Shabalova, M. V. and Sonechkin, D. M. 2001. Seasonality of multidecadal and centennial variability in European temperatures. The wavelet approach. *Geophy Research*. 106(D12): 12449-12461.

9- Daubechies, I. 1990. The wavelet transform, time-frequency localization and signal analysis. *Information Theory IEEE Transactions*. 36(5): 961-1005

10- Ekonomou, L. Lazarou, S. and 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.

11- Guangdian, G.W. and Zhijie, D. 1994. Wind pattern recognition in neural fuzzy wind turbine control system. *NAFIPS/IFIS/NASA The Industrial Fuzzy and Intelligent Systems Conference and the NASA Joint Technology*. 381-5 p.

12- Hong, W. 2012. Clustering of Hydrological Time Series Based on Discrete Wavelet Transform. *Physics Procedia*. 25, 1966-1972.

13- Kim, T. and Valdes, J. B. 2003. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Hydrologic Engineering ASCE* 8(6): 319-328.

14- Kuo, C. C. Gan, T. Y. and Yu, P. S. 2010.

28- Wang, X. Sideratos, G. Hatzigryriou, N. and Tsoukalas, L.H. 2004. Wind speed forecasting for power system operational planning. 8th International conference on probabilistic methods applied to power systems. Iowa state university. Iowa. 470-74p.

29- Watson, S. J. Landberg, L. and Halliday, J.A. 1994. Application of wind speed forecasting to the integration of wind energy in to a large scale power system. In: IEE Proceedings of Generation, Transmission and Distribution, vol. 141(4): 357-362.

30- Zhang, Q. and Benveniste, A. 1992. Wavelet networks. IEEE Transactions on Neural Networks. 3(6): 889-898.

errors for operation planning of multi-area power systems. 2004. 8th International conference on probabilistic methods applied to power systems. Iowa state university. Iowa. 23-28p.

26- Torrence, C. H. and Compo, G. P. 1998. A practical guide to wavelet analysis: Bulletin of the American Meteorological Society. 79(1):61-78.

Toshie Kayano, M. and Sansigolo, C. 2009. interannual to decadal variations of precipitation and daily maximum and daily minimum temperatures in southern Brazil: Theoretical Applied Climatology. 97(1-2):81-90.

27- Wang, J. J. Zhang, W.Y. Liu, X. and Wang, C.Y. 2012. Modifying Wind Speed Data Observed from Manual Observation System to Automatic Observation System Using Wavelet Neural Network. Physics Procedia. 25, 1980 – 1987