



دانشگاه گوارز و منابع طبیعی

نشریه پژوهش‌های حفاظت آب و خاک

جلد بیست و دوم، شماره ششم، ۱۳۹۴

<http://jwsc.gau.ac.ir>

پیش‌بینی بارش ماهانه ایستگاه سینوپتیک کرمانشاه با استفاده از مدل ترکیبی شبکه عصبی و موجک

* غلامعلی مظفری^۱، شهاب شفیعی^۲ و حمیدرضا همتی^۳

^۱دانشیار گروه جغرافیا، دانشگاه یزد، ^۲دانشجوی دکتری گروه جغرافیا، دانشگاه یزد،

^۳دانشجوی کارشناسی ارشد گروه کامپیوتر، دانشگاه یزد

تاریخ دریافت: ۹۳/۸/۲۹؛ تاریخ پذیرش: ۹۴/۳/۱۰

چکیده

سابقه و هدف: بارش به‌عنوان یکی از عناصر مهم هواشناسی، مطرح می‌باشد که شناخت لازم از میزان این عنصر، تغییرات و پیش‌بینی آن، از یک‌سو به جهت داشتن برنامه‌ریزی دقیق‌تر در مدیریت بخش‌های کشاورزی، اقتصادی و اجتماعی ضروری می‌نماید و به همین دلیل مورد توجه هیدرولوژیست‌ها و اقلیم‌شناسان می‌باشد. با توجه به اهمیت پیش‌بینی بارش در برنامه‌ریزی‌ها و مدیریت بحران هدف این مطالعه اجرای یه مدل ترکیبی شبکه عصبی و تبدیل موجک برای پیش‌بینی بارش ماهانه در ایستگاه سینوپتیک کرمانشاه است.

مواد و روش‌ها: در این مطالعه برای پیش‌بینی سری زمانی بارش ماهانه ایستگاه سینوپتیک کرمانشاه، از داده‌های پنج پارامتر اقلیمی، میانگین بارش ماهانه، میانگین رطوبت نسبی، میانگین حداکثر دما، میانگین حداقل دما و میانگین سرعت باد در دوره آماری ۴۰ سال (۱۹۷۰-۲۰۱۰) استفاده شد. جهت کنترل کیفیت آمار و اطلاعات موجود از آزمون توالی استفاده شده است. نتایج نشان داد که داده‌های مزبور از همگنی لازم برخوردار می‌باشند و سپس با توجه به ویژگی‌های غیرخطی مقیاس‌های زمانی چندگانه، برای پیش‌بینی بارش، از مدل شبکه عصبی و موجک استفاده شد.

یافته‌ها: برای پیش‌بینی بارش از چهار پارامتر: میانگین رطوبت نسبی، میانگین حداکثر دما، میانگین حداقل دما و میانگین سرعت باد استفاده و به‌وسیله تبدیل موجکی به ۸ زیرسری زمانی چند فرکانسی تجزیه شد و سپس برای پیش‌بینی بارش ماهانه آینده، این سری‌ها به‌عنوان داده‌های ورودی به مدل شبکه عصبی مصنوعی وارد شد. ضرایب همبستگی ($R=0/874$) در پیش‌بینی ۱ ماه بعد نشان‌دهنده اجرای نسبتاً پایین شبکه عصبی در مدل‌سازی می‌باشد. در حالی که ضریب همبستگی مدل شبکه عصبی- موجکی ۰/۹۴ است. همچنین دقت پیش‌بینی در هر دو مدل با افزایش تعداد تأخیرها در نرون خروجی کاهش می‌یابد. لازم به ذکر است که در پیش‌بینی توسط شبکه عصبی موجکی از موجک میر استفاده شد که نتایج شبیه‌سازی توسط موجک میر از میزان دقت بالایی برخوردار است، با توجه به آماره F تحلیل واریانس شاخص‌های همگنی و ناهمگنی بارش مشاهده‌شده و بارش پیش‌بینی‌شده توسط مدل در سطح اطمینان ۹۹٪ ($P<0/008$) همگن می‌باشد.

* مسئول مکاتبه: yazdmozafari@gmail.com

نتیجه‌گیری: نتایج به‌دست آمده از تبدیل موجک- شبکه عصبی با نتایج حاصل از کاربرد شبکه عصبی، مقایسه شده و ملاحظه گردید که روش موجک- شبکه عصبی نسبت به روش شبکه عصبی دقت پیش‌بینی بالاتری دارد و همچنین دقت پیش‌بینی در هر دو مدل با افزایش تعداد تأخیرها در نرون خروجی کاهش می‌یابد. لازم به ذکر است که در پیش‌بینی توسط شبکه عصبی موجکی از موجک میر استفاده شد که نتایج شبیه‌سازی توسط موجک میر از میزان دقت بالایی برخوردار است.

واژه‌های کلیدی: پیش‌بینی بارش، مدل ترکیبی شبکه عصبی و موجک، ایستگاه سینوپتیک کرمانشاه، موجک میر

مقدمه

آن‌ها استفاده از الگوریتم‌ها، معادلات غیرخطی و نظریه‌های جدید ریاضی ضروری به‌نظر می‌رسد. استفاده از شبیه‌سازها، مدل‌های فیزیکی، مدل‌های ریاضی، توزیع‌های آماری و برنامه‌های رایانه‌ای مربوطه از مواردی است که برای پیش‌بینی پدیده‌ها استفاده می‌گردد. تاکنون مدل‌های اقلیم‌شناسی مختلفی جهت مدلسازی بارندگی پیشنهاد شده‌اند، اما با توجه به ماهیت غیرخطی، عدم قطعیت و عدم صراحت زیاد و ویژگی‌های متغیر زمانی و مکانی در سیستم گردش آبی، هیچ‌یک از مدل‌های آماری و مفهومی پیشنهاد شده به‌منظور الگوسازی دقیق بارش نتوانسته‌اند به‌عنوان یک مدل برتر و توانا شناخته شوند و این مسأله همواره از پیچیدگی‌های ویژه‌ای برخوردار است، در حالت کلی برای تشخیص اطلاعاتی که در سیگنال مخفی می‌باشد باید از تبدیل‌کننده‌های ریاضی استفاده نمود که فوریه یکی از تبدیل‌کننده‌ها می‌باشد (14). تبدیل موجکی تابعی است که نسخه بهبودیافته تبدیل فوریه را تداعی می‌نماید. تبدیل فوریه در آنالیز سیگنال‌های نایستا به شکست منجر می‌شود. در حالی که تبدیل موجکی اجازه می‌دهد که سیگنال‌های نایستا به‌خوبی آنالیز شوند (17). شبکه‌های عصبی مصنوعی یکی از دستاوردهایی می‌باشد که با الگوبرداری از مغز انسان، می‌تواند پدیده‌های پیچیده و ناشناخته را به‌خوبی بررسی نماید (11). ازدیاد تعداد متغیرها در شبکه عصبی می‌تواند سبب پیچیدگی

بارش از مهم‌ترین عناصر اقلیمی می‌باشد که در تعیین و پراکندگی دیگر عناصر اقلیمی نیز مؤثر است (2). به‌عبارتی بارش به‌عنوان یکی از عناصر مهم هواشناسی، مطرح می‌باشد که شناخت لازم از میزان این عنصر، تغییرات و پیش‌بینی آن، از یک‌سو به جهت داشتن برنامه‌ریزی دقیق‌تر در مدیریت بخش‌های کشاورزی، اقتصادی و اجتماعی ضروری می‌نماید (13). و به همین دلیل مورد توجه هیدرولوژیست‌ها و اقلیم‌شناسان می‌باشد. پیش‌بینی هر واقعه‌ای، اساس مدیریت بحران آن را تشکیل می‌دهد و این امکان، زمانی حاصل می‌شود که بتوان مدل‌های پیش‌بینی مناسب را در اختیار داشت. روش‌های مختلفی برای پیش‌بینی عناصر اقلیمی (از جمله بارندگی) به‌کار می‌روند. نتایج حاصل از به‌کارگیری هر یک از این روش‌ها همواره با مقداری خطا همراه می‌باشد. پیش‌بینی درست در سیگنال‌های هیدرولوژیکی نظیر بارندگی می‌تواند اطلاعات مفیدی را به‌منظور پیش‌بینی مقدار بارندگی و مدیریت منابع آب و خاک در یک حوضه ارائه دهد. علاوه بر این، پیش‌بینی درست در پارامترهای اقلیم‌شناسی نقش مهمی را در کاهش اثرات خشکسالی بر سیستم‌های منابع آب ایفا می‌کند. بیش‌تر سیگنال‌های هیدرولوژیکی مخصوصاً فصلی و ماهانه دارای مشخصات غیرایستا، پرش، روند و تغییرات ناگهانی در بسامد هستند که برای مدل‌سازی

سری زمانی نوسانات جنوبی النینو بیان و مفاهیم سطوح اطمینان در تحلیل موجک را با جزئیات کامل تشریح کردند (23). سانتوس و همکاران (2001) با استفاده از تحلیل موجک به بررسی و تحلیل داده‌های بارش شهر ماتسویاما پرداخته و نتایج قابل توجهی در ارتباط با تغییرپذیری بارش در مقیاس‌های متفاوت به دست آوردند (15). تقوی و همکاران (2011) مطالعه‌ای تحت عنوان کاربرد تحلیل موجک در شناسایی رفتار بارش در مناطق غربی ایران انجام داده‌اند و نتیجه گرفتند که تحلیل موجک در برآورد روند و تغییرپذیری بارش میزان دقت بالایی برخوردار است (20). طوفانی و همکاران (2011) با استفاده مستقیم از نظریه موجک بارندگی ایستگاه زرنگیل استان گلستان را پیش‌بینی کرده‌اند و نتیجه گرفتند که تجزیه سیگنال با موجک منجر به ساده‌شدن سیگنال بارندگی می‌شود (22). شفائی و همکاران (2013) جریان روزانه رودخانه را در ایستگاه هیدرومتری و نیار در حوضه آبریز آجی‌چای با استفاده از مدل هیبرید موجک و شبکه عصبی پیش‌بینی کرده‌اند (16). با توجه به اهمیت پیش‌بینی بارش در برنامه‌ریزی‌ها و مدیریت بحران، هدف این مطالعه اجرای مدل ترکیبی شبکه عصبی و تبدیل موجک برای پیش‌بینی بارش ماهانه در ایستگاه سینوپتیک کرمانشاه است.


مواد و روش‌ها

معرفی منطقه مورد مطالعه: ایستگاه سینوپتیک کرمانشاه دارای بلندترین طول دوره آماری در بین ایستگاه‌های استان کرمانشاه می‌باشد. داده‌های مورد استفاده در این پژوهش مربوط به آمار ماهیانه بارندگی، رطوبت نسبی، دمای حداقل، دمای حداکثر و سرعت باد در دوره آماری (۲۰۱۰-۱۹۷۱) در یک دوره ۴۰ ساله در ایستگاه سینوپتیک کرمانشاه می‌باشد که از سازمان هواشناسی کشور تهیه شد. جهت کنترل

ساختار شبکه عصبی و ناپایداری آن می‌گردد که یکی از دلایل آن افزایش تعداد وزن‌ها نسبت به ورودی‌ها می‌باشد (9). از طرفی در مواردی متغیرها از همبستگی بالایی برخوردار هستند که استفاده از همه آن‌ها نوعی ورود اطلاعات تکراری را به همراه دارد (24). که این موارد می‌توانند از یافتن مدل‌های بهینه جلوگیری کنند (4). روش‌های متفاوتی برای رفع این مشکل پیشنهاد شده‌اند، مثلاً الگوریتم ژنتیک و دیگر روش‌های بهینه‌سازی (3). ولی در این روش‌ها نیز برخی متغیرها به‌طور مستقیم حذف می‌گردند و اثر آن‌ها در نظر گرفته نمی‌شود. روش‌های دیگری نیز به‌عنوان پیش‌پردازش روی داده‌های ورودی شبکه‌های عصبی در نظر گرفته شده‌اند که از این دسته می‌توان تبدیل موجکی را نام برد. با وجود قابلیت انعطاف مناسب ANN در مدل‌سازی سری‌های زمانی هیدرولوژیکی مثل رواناب (9)، گه‌گاه هنگامی که نوسانات سیگنال تا حد زیادی ناپیدا باشند و فرایندهای هیدرولوژیکی فیزیکی در دامنه بزرگی از مقیاس‌های ۱ ماهه تا چندماهه عمل می‌کنند کمبودی در ANN احساس می‌شود و در صورتی که پیش‌پردازش روی داده‌های ANN انجام نشود، شبکه‌های عصبی مصنوعی در مقابل داده‌های ناپیدا توانایی نخواهد داشت (5). کاربرد موجک در شبکه عصبی موجکی به‌عنوان تابع آموزش، اخیراً به‌عنوان یک روش جایگزین، در شبکه‌های عصبی، به‌کار برده می‌شود. ترکیب تئوری موجکی و شبکه‌های عصبی منجر به گسترش شبکه‌های عصبی-موجکی شده است. در شبکه‌های عصبی-موجکی، موقعیت و مقیاس موجک‌ها علاوه بر وزن‌ها بهینه‌سازی می‌شوند. در اصل شبکه عصبی موجکی به شبکه عصبی با استفاده از موجک اشاره دارد (21) تورنسی و کامپو (1998) نیز کاربرد عملی تحلیل موجک را در هواشناسی و اقلیم با مثال‌هایی از

استفاده شده است. جدول ۱ و شکل ۱ موقعیت و مشخصات ایستگاه سینوپتیک کرمانشاه را نشان می‌دهد.

کیفیت آمار و اطلاعات موجود از آزمون توالی استفاده شده است. نتایج نشان داد که داده‌های مزبور از همگنی لازم برخوردار می‌باشند و سپس از نرم‌افزار متلب جهت اجرای مدل‌های شبکه عصبی و موجک



شکل ۱- موقعیت جغرافیایی ایستگاه سینوپتیک کرمانشاه.

Figure 1. Geographical location of Kermanshah synoptic station.

جدول ۱- مشخصات ایستگاه سینوپتیک کرمانشاه.

Table 1. Specification of Kermanshah synoptic station.

طول جغرافیایی	عرض جغرافیایی	ارتفاع	دوره آماری	ایستگاه
Longitude	latitude	Height	Period	station
47° 9'	34° 21'	1318.6	1971-2010	کرمانشاه

فعال می‌شود که مجموع سیگنال‌های رسیده به بدنه آن از حد آستانه مشخصی تجاوز نماید. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسأله مورد بررسی مشخص می‌شود، حال آن‌که تعداد نرون‌های موجود در لایه‌های پنهانی و همچنین تعداد این لایه‌ها با سعی و خطا در جهت کاهش مقدار خطا توسط طراح ارائه می‌شود (7). اتصال‌هایی که بین نرون‌ها وجود دارد، دارای وزن

روش پژوهش

شبکه عصبی مصنوعی: ساختار کلی ANN از سه لایه متفاوت تشکیل شده است. لایه ورودی که پخش داده در شبکه و لایه میانی که فرآیند پردازش داده را به عهده دارد. لایه خروجی نیز افزون بر پردازش داده‌ها، به‌ازای بردار ورودی شبکه، خروجی و عملکرد آن را نشان می‌دهد (19) نرون، کوچک‌ترین یکان پردازشگر شبکه است. در شبکه عصبی مصنوعی هر نرون زمانی

می‌کند. به‌طور نمونه این شبکه ورودی جمع وزنی شده ورودی‌های یک نرون می‌باشد، یعنی خروجی گره‌های قبلی که در وزن‌های ماتریسی (W) ضرب شده است (6).

$$\text{Net}(t) = W \cdot O(t) \quad (2)$$

قانون فعالسازی اغلب تابع محرک نامیده می‌شود. و مقدار فعالسازی یک نرون بر مبنای شبکه ورودی تعیین می‌گردد.

تابع F با گرفتن $a(t)$ و بردارهای $\text{Net}(t)$ برای هر نوع اتصال مختلف، یک حالت جدید فعالسازی را تولید می‌کند. تابع محرک سیگموئیدی تانژانت هیپربولیک در زیر نشان داده شده است:

$$a(t+1) = F(\text{net}(t)) = \tanh(\text{net}(t)) \quad (3)$$

پارامترهای داخلی (وزن‌ها و بایاس‌ها) بهینه را به‌وسیله مقایسه تخمین‌های پردازشی شبکه عصبی و مقدارهای مشاهداتی به‌دست آورده و در نتیجه مقدارهای تخمین زده شده را می‌تواند به مقدار حقیقی نزدیک‌تر کند. مقایسه فوق‌الذکر مبتنی بر یک ارزیابی با استفاده از تابع اجرایی می‌باشد. در اینجا از این تابع به‌عنوان تابع خطا نام برده شده است. یک الگوریتم را بایستی برای بهینه‌سازی پارامترهای داخلی و به‌منظور تولید بردار Y (بردار تخمینی) تعیین نمود به‌طوری‌که این بردار تا حد امکان به بردار t (بردار مشاهداتی) نزدیک باشد و تعیین این الگو سبب تولید تابع خطای مینیمم می‌باشد. این تابع به شکل زیر تعریف خواهد شد (8).


$$E = \sum_{n=1}^{\infty} (t_n - y_n)^2 \quad (4)$$

تعداد داده‌ها n می‌باشد.

هستند. این وزن‌ها در هنگام عبور داده‌ها از آن اتصال، در داده عبوری تأثیر می‌گذارند (18). با وجود بسیاری از قوانین به‌منظر می‌رسد که شبکه عصبی از یک مجموعه از مثال‌ها می‌تواند یاد بگیرد. این یکی از مزیت‌های شبکه عصبی نسبت به روش‌های سنتی می‌باشد. به‌منظور فهمیدن یا طراحی فرآیند یادگیری، ابتدا باید مدل محیطی را که شبکه عصبی در آن اجرا می‌شود را در اختیار داشت، یعنی این‌که چه اطلاعاتی برای فرآیند یادگیری در دسترس است. به این مدل به‌عنوان مدل یادگیری اشاره شده است. دوم این‌که، باید چگونگی بروز شدن وزن‌ها را درک نمود یعنی قوانین یادگیری که فرآیند بروز شدن را کنترل می‌کنند را باید فهمید. الگوریتم یادگیری به روشی که قوانین یادگیری برای تعدیل وزن‌ها در شبکه استفاده می‌شوند اشاره می‌کند (9). حالت سیستم در یک نقطه و در زمان معین به‌وسیله اصطلاح فعالسازی تعداد نرون‌ها باشد، N نرون‌های شبکه بیان می‌شود. اگر معین شود که حالت $a(t)$ حالت سیستم می‌تواند با بردار فعالسازی نرون‌ها در شبکه را معین می‌کند (6). هر نرون دارای یک تابع خروجی می‌باشد به‌طوری‌که حالت جاری فعالسازی را به سیگنال خروجی نگاشت می‌کند خروجی با $oi(t)$ نمایش داده می‌شوند.

$$a(t+1) = F(\text{net}(t)) = \tanh(\text{net}(t)) \quad (1)$$

تابع خروجی اغلب وابسته به مقداری به نام بایاس می‌باشد. در موقعیتی که تابع خروجی برابر با تابع همانی می‌باشد، هیچ بایاسی برای نرون استفاده نشده است. برای مثال یک بایاس $0/5$ به این معنی است که یک تابع آستانه‌ای که به‌عنوان تابع خروجی استفاده می‌شود فقط در صورتی که مقدار ورودی از $0/5$ تجاوز کند از سیگنال عبور داده می‌شود. قانون انتشار یک شبکه، روش محاسبه شبکه ورودی $\text{Net}(t)$ یک نرون از چندین خروجی نرون همسایه را توصیف



شکل ۲- عملیات شبکه عصبی (مأخذ: جعبه ابزار نرم‌افزار متلب).

Figure 2. Neural network operation (reference: Mat lab software toolbox).

در طول سیگنال مورد تحلیل، تغییر اندازه و تغییر محل می‌یابند و (b) ضرایب موجک در هر نقطه از سیگنال و (a) ضرایب موجک برای هر مقدار از سیگنال است.

تبدیل‌های موجکی به دو دسته موجک پیوسته و گسسته تقسیم می‌شوند. برای کاربردهای عملی، هواشناسان، اقلیم‌شناسان و هیدرولوژیست‌ها اغلب سیگنال‌های زمانی پیوسته در اختیار ندارند، بلکه بیشتر سیگنال‌های زمانی گسسته در اختیار آن‌هاست. اگر انتخاب‌های مقیاس و موقعیت مبنی بر مزیت‌های هر دو (مقیاس‌ها و موقعیت‌های دوتایی) باشد.

تحلیل‌ها دقیق خواهد بود. تبدیل موجک گسسته از بانک‌های فیلتر برای بازسازی سطح چند تفکیکی زمان-فرکانس بهره می‌برد (12). این تبدیل، تبدیل موجک گسسته نامیده می‌شود و به شکل زیر تعریف می‌شود:

(۷)

$$W_f(a,b) = |a|^{-\frac{1}{2}} \sum_{n=1}^N f(k\Delta t) \psi^*\left(\frac{k\Delta t - b}{a}\right)$$

$\psi^*(t)$ تابع مختلط و مرکب $\psi(t)$ است. $W_f(a,b)$ ضریب موجک است که تحت سطوح تجزیه و زمان‌های مختلف به دست آمده است. N تعداد گام زمانی گسسته و t فواصل زمانی نمونه است. $W_f(a,b)$ می‌تواند ویژگی‌های سری زمانی اصلی را در زمان b و دامنه فرکانس a، در زمان یکسان

تبدیل موجک: تبدیل موجکی تبدیلی است که سیگنال را به یک مجموعه از توابع اساسی سیگنال تجزیه می‌کند و در حقیقت یک مجموعه تابع اساسی از تأخیر و تغییر در مقیاس موجک مادر به دست می‌آید. تبدیل موجکی سیگنال به صورت همبستگی سیگنال و موجک تبدیل یافته توضیح داده شده است. که این تعریف را از بطن فرمول ضریب موجکی می‌توان دریافت کرد. مزیت مهم تبدیل موجکی این است که اطلاعات زمان و فرکانس را به طور مؤثری از سیگنال متغیر در زمان استخراج می‌کند (17). تابع موجک $\psi(t)$ ، موجک مادر نامیده می‌شود. که دارای ویژگی‌های شوک بوده و به سرعت می‌تواند به صفر کاهش پیدا کند. تابع موجک $\psi(t)$ به شکل ریاضی زیر تعریف می‌شود.

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (5)$$

توابع موجکی که برای آنالیز سیگنال استفاده می‌شوند، عبارتند از: موجک هار، مرلت، دابچیز، میر و غیره.

$\psi_{(a,b)}(t)$ با استفاده از تأخیر و تغییر مقیاس

موجک مادر از فرمول زیر حاصل می‌گردد.

$$\psi_{(a,b)}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (6)$$

$$A \in \mathbb{R}, b \in \mathbb{R}, a \neq 0$$

$\psi(t)$ تابع موجک مادر است که توابع مورد استفاده در تحلیل، با دو عمل ریاضی انتقال و مقیاس

$$S = \sum_{j \in Z} D_j \quad (9)$$

در تجزیه موجکی دو دسته D_j حاصل می‌شود که دسته اول دارای مقیاس $a=2^j$ که $|j| \leq J$ می‌باشند و به D_j های زیر معروف‌اند و دسته دوم دارای $a=2^j$ که $|j| > J$ هستند و D_j خشن نام دارند. J سطح تجزیه موجکی است.

$$D_J = \sum_{j>J} D_j \quad (10)$$


$$S = A_J + \sum_{j<J} D_j \quad (11)$$

که در آن، A_J زیر سری تقریبی در سطح J است (21).

منعکس کند. انتخاب تابع موجکی و مقیاس موجکی دو موضوع مهم در تبدیل موجکی هستند (23). در مرحله تجزیه تبدیل موجک گسسته سیگنال را به یک مجموعه از فرکانس‌های بالا و پایین تجزیه می‌کند. تجزیه موجک به یک سلسله فرکانس‌های بالا و پایین اولین بار توسط مالات پیشنهاد شده است. در سطح تجزیه J ، D_j که نشانگر زیر سری جزئی است به صورت زیر تعریف می‌شود:


$$D_j(t) = \sum_{k \in Z} w_f(a, b) \psi_{(a,b)}(t) \quad (8)$$

که در آن، $w_f(a, b)$ ضریب موجکی در مقیاس a و زمان b بوده $\psi_{(a,b)}(t)$ موجک مادر تبدیل یافته در مقیاس a و b می‌باشد. که سیگنال اصلی از حاصل جمع همه D_j قابل حصول است.



شکل ۳- یک موجک مادر (مأخذ: جعبه ابزار نرم‌افزار متلب).

Figure 3. A parent wavelet (reference: Mat lab software toolbox).



شکل ۴- عملیات فیلتر نمودن یک سیگنال (مأخذ: جعبه ابزار نرم‌افزار متلب).

Figure 4. A signal filtering process (reference: Mat lab software toolbox).

پیش‌بینی متغیر هدف صورت گرفته است. متغیرهای مستقل مورد استفاده در این پژوهش و علائم اختصاری آن‌ها در جدول ۲ نمایش داده شده است.

عناصر مورد استفاده در شبیه‌سازی: در شبیه‌سازی با استفاده از مدل شبکه عصبی- موجکی و موجک از عناصر مختلفی استفاده شده است. این عناصر به‌عنوان متغیر مستقل به مدل معرفی و شبیه‌سازی‌ها برای

جدول ۲- معرفی عناصر ورودی مدل (دوره آماری ۱۹۷۱ تا ۲۰۱۰).

Table 2. Input elements of model (1971-2010).

Parameters پارامترها	عناصر ورودی Input	حداکثر max	حداقل min	میانگین mean
P	بارش (میلی‌متر) Precipitation (mm)	153	0	31.7
T _{mean}	دمای متوسط (درجه سانتی‌گراد) Average Temperature (C°)	26	-1.7	14.4
T _{max}	دمای حداکثر (درجه سانتی‌گراد) Maximum Temperature (C°)	22.6	-1.2	22.6
H	رطوبت نسبی (درصد)	77	18	46
W _s	سرعت باد غالب (متر بر ثانیه) wind speed	6.5	1.9	3.7

تجزیه می‌شود و دقت کار افزایش می‌یابد، اما از مرحله‌ای به بعد مقادیر بسامدها تقریباً ثابت باقی می‌ماند (22). از آنجا که هدف تجزیه موجکی، ساده‌سازی سیگنال تا حد امکان است با استفاده از کد برنامه نوشته شده در متلب مشاهده شد که در سطح ۸ زیرسری تقریبی به مرحله‌ای می‌رسند که در آن‌ها بسامدی مشاهده نمی‌گردد. موج‌های تجزیه شده در این سطح به ساده‌ترین شکل ممکن هستند. $d(t)_1, d(t)_2, \dots, d(t)_7, d(t)_8$ زیر سری‌های جزئی هستند. بعد از نرمالایزه شدن توسط فرمول زیر به‌عنوان ورودی شبکه عصبی در زمان t در نظر گرفته می‌شوند.

$$X_n = \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}} \quad (12)$$

در این مطالعه در مرحله اول از شبکه عصبی- موجکی برای پیش‌بینی بارش ماهیانه ایستگاه سینوپتیک کرمانشاه استفاده شده است، به این منظور ابتدا سری‌های زمانی اصلی داده‌های ماهیانه میانگین رطوبت نسبی، سرعت باد، میانگین حداکثر دما، میانگین حداقل دما و بارش ایستگاه سینوپتیک کرمانشاه و با استفاده از کد برنامه‌ای که در نرم‌افزار متلب نوشته شد و با به‌کارگیری موجک میر و توسط تبدیل موجک گسسته داده‌های میانگین رطوبت نسبی، میانگین حداکثر دما، میانگین حداقل دما و میانگین سرعت باد، چون از مرحله ۸ به بعد مقادیر بسامدها تقریباً ثابت باقی می‌مانند به ۸ زیرسری معین $d(t)_1, d(t)_2, \dots, d(t)_7, d(t)_8$ تجزیه می‌شوند. هرچه تعداد مراحل منتخب برای تجزیه بیش‌تر باشد، سیگنال به همان تعداد به بسامدهای بالاگذر و پایین‌گذر

که آموزش شبکه را با هدف کارایی ۴-۱۰ برآورده می‌سازد و از تابع محرک تانژانت هیپربولیک و قانون یادگیری مومتم استفاده شد. همان‌طور که گفته شد طول سری زمانی متغیرهای ورودی داده‌های میانگین ماهیانه رطوبت نسبی، میانگین سرعت باد، میانگین حداکثر دما و میانگین حداقل دما ۱۹۲۰ ماه است که ۶۰ درصد داده‌ها برای آموزش و ۲۵ درصد برای تست و ۱۵ درصد برای اعتبارسنجی در نظر گرفته شد. برای ارزیابی مقدار کارایی و دقت این مدل از ضریب همبستگی و ریشه مربعات خطاها و میانگین قدرمطلق خطاها بین بارش مشاهداتی و محاسباتی استفاده شده است و ضمن پیش‌بینی بارش، کارایی دو تا روش شبکه عصبی و موجک مورد ارزیابی و مقایسه قرار گرفتند.

نتایج و بحث

ابتدا بدون هیچ‌گونه پیش‌پردازشی شبکه پیش‌خور پرسپترون چند لایه مدل ANN برای مدل‌سازی بارش ماهیانه استفاده می‌شود. در این پژوهش مدل‌سازی بارش ۱، ۲، ۳ و ۴ ماه بعد مد نظر قرار گرفته است. نتایج حاصل از آزمایش تعداد نرون‌های بالاتر از ۱۰ در لایه پنهان نشان داد که این افزایش نرون سبب کارایی بهتر نمی‌شود و دقت آن هم‌چنان ثابت می‌ماند، که این نتیجه توسط پژوهشگران دیگر نیز اثبات شد (1). هنگامی که خطا در مرحله اعتبارسنجی بالا می‌رود آموزش متوقف می‌شود، که این امر برآزش نیافتن بیش از اندازه داده‌های مجموعه آموزش را در شبکه عصبی تأیید می‌کند و پس از آن آموزش در شبکه عصبی متوقف شده و شروع به پیش‌بینی و تعمیم مجموعه داده‌های تست می‌کند.

که در آن، X_0 و X_n به ترتیب داده‌های نرمال شده و داده‌های اولیه را نشان می‌دهد و X_{min} و X_{max} به ترتیب مینیمم و ماکزیمم داده‌های اولیه را نشان می‌دهد.

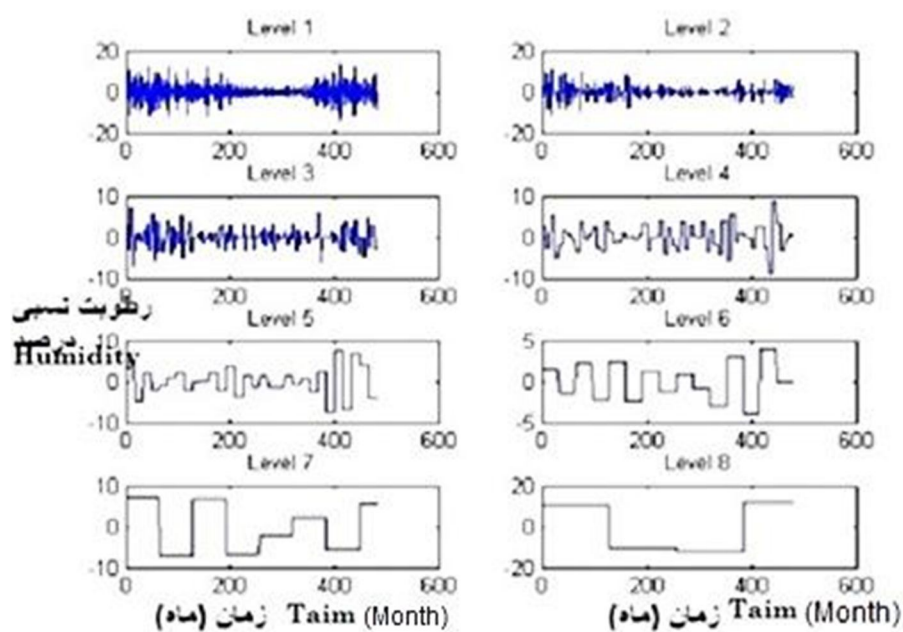
به‌منظور آموزش شبکه سری زمانی نرمال داده‌ها در زمان $T+t$ به‌عنوان خروجی ANN در نظر گرفته می‌شود T طول زمان پیش‌بینی می‌باشد. به‌طوری‌که در اینجا جمعاً ۸ نرون ورودی وارد شبکه عصبی شده و لازم به ذکر است که دلیل استفاده از موجک میر شباهت بسیار زیاد این موجک به سیگنال با داده‌های بارش می‌باشد. ثابت شده است که پرسپترون‌های چندلایه پس از آموزش با یکی از رایج‌ترین الگوریتم‌های یادگیری به نام الگوریتم پس‌انتشار خطا به‌طور رضایت‌بخشی در حل برخی مسایل پیچیده به‌کار رفته‌اند. این الگوریتم بر اساس قانون آموزش سعی و خطا می‌باشد و همچنین ساختار شبکه، که بیانگر نحوه اتصالات بین نرون‌های شبکه و الگوریتم آموزش می‌باشد در اینجا به‌صورت پیش‌خور است. سپس سیگنال داده‌های ماهیانه را به‌وسیله تبدیل موجکی گسسته موجک میر تجزیه و نتایج پیش‌بینی ارائه شد. نرون‌های لایه مخفی به‌وسیله صحیح و خطا تعیین می‌گردد. که در اینجا بین ۳ تا ۱۰ نرون در نظر گرفته شد و در نهایت نرونی که باعث حداقل خطا گردید به‌عنوان تعداد نرون‌های مخفی برای ساختمان برای شبکه عصبی انتخاب شد. انتخاب نرون‌های مخفی و تعداد تکرارهای آموزش دو موضوع مهم در مدل‌سازی توسط ANN می‌باشند که باید مورد توجه قرار گیرد. به‌طوری‌که انتخاب مناسب این دو پارامتر سبب پیشرفت مدل‌سازی در مرحله آموزش و تأیید می‌شود. در این مطالعه تعداد نرون مخفی با صحیح و خطا محاسبه گردید و تعداد تکرارها نیز ۲۰۰ انتخاب شد

جدول ۳- نتایج ضریب همبستگی و خطاهای حاصل از پیش‌بینی مدل شبکه عصبی.
 Table 3. Results of correlation coefficient and the neural network model prediction errors.

تعداد تاخیر Delays Number	آموزش Learning						اعتبارسنجی Validation						امتحان Test					
	R همبستگی	R ² ضریب تعیین	RMSE کم‌ترین مربعات خطا	MAE میانگین خطای مطلق	R همبستگی	R ² ضریب تعیین	RMSE کم‌ترین مربعات خطا	MAE میانگین خطای مطلق	R همبستگی	R ² ضریب تعیین	RMSE کم‌ترین مربعات خطا	MAE میانگین خطای مطلق	R همبستگی	R ² ضریب تعیین	RMSE کم‌ترین مربعات خطا	MAE میانگین خطای مطلق		
1	0.874	0.76	0.0021	0.014	0.73	0.53	0.00054	0.006	0.88	0.77	0.001	0.0007	0.88	0.77	0.001	0.0007		
2	0.887	0.77	0.0021	0.0112	0.73	0.53	0.0004	0.0062	0.88	0.77	0.001	0.0073	0.88	0.77	0.001	0.0073		
3	0.851	0.72	0.002	0.0132	0.71	0.50	0.0005	0.0061	0.83	0.69	0.00	0.0078	0.83	0.69	0.00	0.0078		
4	0.845	0.70	0.0017	0.0164	0.70	0.49	0.0005	0.0063	0.84	0.70	0.00	0.0075	0.84	0.70	0.00	0.0075		

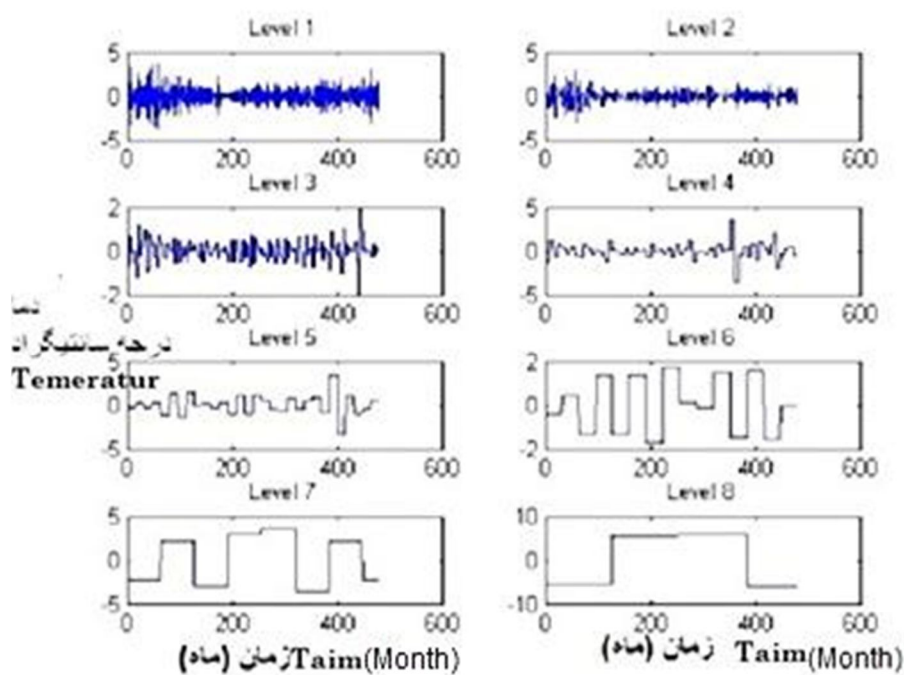
شده است. دلیل استفاده از سطح ۸ در تجزیه موجکی رسیدن به روند کامل در این سطح می‌باشد. به‌طوری‌که همه جزئیات سیگنال در زیرسری‌های جزئی آن و هویتش در زیرسری تقریبی نشان داده شده است. هنگامی‌که زیر سری‌ها به‌عنوان ورودی به شبکه عصبی وارد می‌شوند، شبکه عصبی به هر کدام از زیرسری‌های تجزیه‌ای وزن خاصی اختصاص می‌دهد به‌طوری‌که وزن‌های بالا به سطوح با ارزش سیگنال اختصاص می‌یابند. مثلاً در سطح تجزیه ۸ شبکه عصبی وزن بالاتر را به d_8 نسبت خواهد داد. چرا که نسبت d_8 به زیرسیگنال‌های دیگر بیش‌ترین وابستگی را به سیگنال اصلی داده‌ها دارد و مدت دوره کوتاه بوده و در ضمن نقش معنی‌داری در پیش‌بینی بارش به عهده دارد. نتایج این پیش‌بینی در جدول ۴ نمایش داده شده است. همان‌طور که در جدول ۴ مشاهده می‌شود کارایی و دقت مدل‌های حاصل از تجزیه با موجک میر به‌علت شباهت به سیگنال بارش و پیچیدگی‌اش، موجب بالا رفتن کارایی مدل شبکه عصبی - موجک گردیده است دقت بالای مدل شبکه عصبی - موجکی نه تنها به‌خاطر پیش‌پردازش و پارتیشن‌بندی موجک به زیرسیگنال‌های مختلف است بلکه علت آن می‌تواند به‌خاطر توجه به تأثیر هر زیرسیگنال تجزیه‌ای به‌وسیله بزرگنمایی نسبی وزن آن زیرسیگنال باشد.

ضریب همبستگی ($R=0.874$) در پیش‌بینی ۱ ماه بعد نشان‌دهنده اجرای نسبتاً پایین شبکه عصبی در مدل‌سازی می‌باشد. که علت آن احتمالاً به‌خاطر معنی‌دار بودن نوسانات داده‌ها حول میانگین می‌باشد، به‌طوری‌که رگرسیون کوتاه‌مدت بین داده‌ها کاهش می‌یابد. البته این کارایی در پیش‌بینی ماه‌های بعدی کم‌تر نیز می‌شود. نتایج پیش‌بینی ماه‌های بعدی در شبکه عصبی، کاهش دقت مدل‌سازی این ماه‌ها را نشان می‌دهد. که کاهش ضریب همبستگی و افزایش خطاها این را تأیید می‌نمایند. که این پدیده به‌خاطر کاهش بارش در اثر افزایش تأخیرها در سیگنال خروجی می‌باشند. جدول ۱ دقت پیش‌بینی‌ها را در ۱، ۲، ۳ و ۴ ماه بعد نشان می‌دهد. در مرحله بعد به‌منظور افزایش دقت مدل، داده‌های پیش‌پردازش شده توسط تبدیل موجکی گسسته و با به‌کارگیری موجک میر به‌عنوان ورودی‌های شبکه عصبی در نظر گرفته می‌شوند و به این ترتیب تمامی ویژگی‌های ریز و درشت سیگنال نمایان می‌شوند که این خود باعث افزایش دقت مدل می‌گردد. یکی از اهداف پژوهشگران، مطالعه روی تأثیر نوع موجک میر، روی مدل‌سازی می‌باشد. ۸ سطح $d(t)_1, d(t)_2, \dots, d(t)_7, d(t)_8$ داده‌های میانگین رطوبت نسبی، میانگین دمای حداکثر، دمای حداقل و میانگین سرعت باد توسط موجک میر محاسبه شد و برای پیش‌بینی وارد شبکه شدند. این ۸ زیرسری از داده‌ها در شکل‌های ۴ تا ۷ نمایش داده



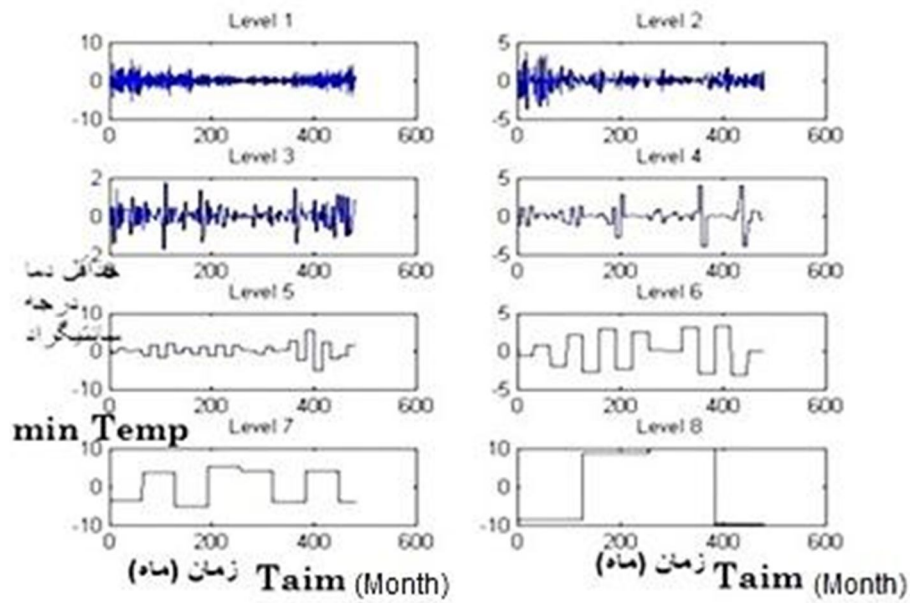
شکل ۵- زیرسری جزئی و تقریبی d_1 تا d_8 حاصل تجزیه موجکی میانگین رطوبت نسبی.

Figure 5. d_1 to d_8 sub-series derived from average relative humidity wavelet conversion.



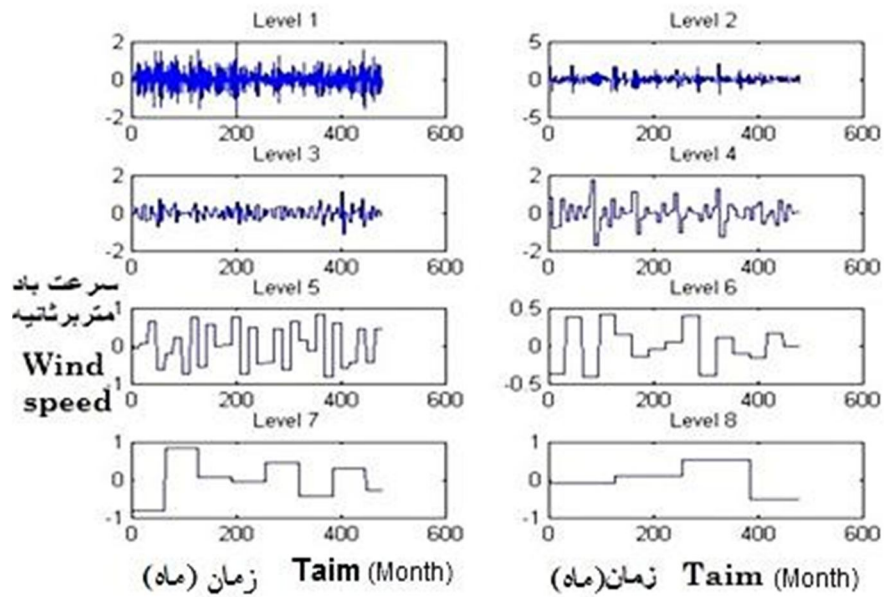
شکل ۶- زیرسری جزئی و تقریبی d_1 تا d_8 حاصل تجزیه موجکی میانگین حداکثر دما.

Figure 6. d_1 to d_8 sub-series derived from average maximum temperature wavelet conversion.



شکل ۷- زیرسری جزئی و تقریبی d_1 تا d_8 حاصل تجزیه موجکی میانگین حداقل دما.

Figure 7. d_1 to d_8 sub-series derived from average minimum temperature wavelet conversion.



شکل ۸- زیرسری جزئی و تقریبی d_1 تا d_8 حاصل تجزیه موجکی میانگین سرعت باد.

Figure 8. d_1 to d_8 sub-series derived from average wind speed wavelet conversion.


جدول ۴- نتایج ضریب همبستگی و خطاهای حاصل از پیش‌بینی مدل شبکه عصبی- موجکی با به‌کار بردن موجک میر.

Table 4. Results of correlation coefficient and driven errors by neural network-wavelet model using Meyer wavelet.

تعداد تاخیر Delays Number	آموزش Learning				اعتبارسنجی Validation				امتحان Test			
	R	R ²	RMSE	MAE	R	R ²	RMSE	MAE	R	R ²	RMSE	MAE
	همبستگی	ضریب تعیین	کم‌ترین مربعات خطا	میانگین خطای مطلق	همبستگی	ضریب تعیین	کم‌ترین مربعات خطا	میانگین خطای مطلق	همبستگی	ضریب تعیین	کم‌ترین مربعات خطا	میانگین خطای مطلق
1	0.94	0.88	0.003	0.006	0.93	0.86	0.0002	0.003	0.96	0.92	0.001	0.0023
2	0.92	0.84	0.0004	0.01	0.85	0.72	0.003	0.006	0.935	0.87	0.001	0.004
3	0.93	0.86	0.0005	0.02	0.82	0.67	0.002	0.005	0.92	0.84	0.004	0.062
4	0.92	0.84	0.0006	0.01	0.87	0.75	0.0003	0.006	0.91	0.82	0.003	0.0075


همان‌طور که شکل نشان می‌دهد این مدل قادر به یافتن الگوی ماهانه سری زمانی بارش بوده و به خوبی توانایی شبیه‌سازی را دارا می‌باشد.

پیش‌بینی بارش ماهیانه با این مدل، دقت پیش‌بینی را نسبت به روش‌های آماری و ANN بالا می‌برد. در شکل ۹ برازش مدل شبکه عصبی- موجکی روی سری زمانی بارش در مرحله آموزش مشاهده می‌شود.




شکل ۹- تطابق مقادیر بارش ماهیانه و بارش محاسباتی به‌وسیله روش موجک- شبکه عصبی با موجک میر در مرحله آموزش.

Figure 9. Monthly and calculating precipitation matching by wavelet-neural network using Meyer wavelet in learning process.



شکل ۱۰- خط برازش رگرسیونی مقادیر بارش ماهیانه و بارش محاسباتی به وسیله روش موجک- شبکه عصبی با موجک میر در مرحله تست.

Figure 10. Monthly and calculating precipitation regression fitness line by wavelet-neural network using Meyer wavelet in test process.



شکل ۱۱- تطابق مقادیر بارش ماهیانه و بارش محاسباتی به وسیله روش موجک- شبکه عصبی با موجک میر در مرحله تست.

Figure 11. Monthly and calculating precipitation matching by wavelet-neural network using Meyer wavelet in test process.

رضایت بخش این روش در پیش بینی می باشد. با توجه به آماره F تحلیل واریانس شاخص های همگنی و ناهمگنی بارش مشاهده شده و بارش پیش بینی شده توسط مدل در سطح اطمینان ۹۹٪ ($P < 0.008$) همگن می باشند. نکته قابل توجه در این نمودار تطابق مقادیر

شکل ۱۰ مقادیر محاسباتی و مشاهده‌ای را در مرحله تست نشان می دهد. همچنین تطابق بارش پیش بینی شده و مشاهده شده را در شکل ۱۱ به صورت واضح تر می توان مشاهده نمود، که همپوشانی این نمودار بر روی نیمساز بیانگر دقت بسیار

بر نایستایی سیگنال نمی‌باشد. در حالی‌که تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پایین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل‌توجهی بالا می‌برد. همچنین در مدل هیبریدی دقت پیش‌بینی بارش اوج که مهم‌ترین قسمت مدل‌سازی بارش می‌باشد بالا می‌رود. و سومین نتیجه‌ای که از این پژوهش گرفته می‌شود، این است که با افزایش تأخیر در سیگنال خروجی دقت پیش‌بینی در هر دو مدل (شبکه عصبی و شبکه عصبی- موجکی) کاهش می‌یابد. نتیجه چهارم این‌که استفاده از موجک میر دقت پیش‌بینی مدل موجکی را افزایش می‌دهد. با توجه به انجام آماره F تحلیل واریانس شاخص‌های همگنی و ناهمگنی بارش مشاهده‌شده و بارش پیش‌بینی‌شده توسط مدل در سطح اطمینان ۹۹٪ ($P < 0.008$) همگن می‌باشد و هر دو به یک جامعه آماری تعلق دارند. که بیانگر دقت بسیار رضایت‌بخش این روش در پیش‌بینی می‌باشد. این نیز به‌دلیل پیچیدگی موج شکل موجک میر می‌باشد.

مشاهداتی و محاسباتی در بارش‌های اوج می‌باشد. که در شکل این برآزش را به خوبی دیده می‌شود.

نتیجه‌گیری کلی

در این مطالعه شبیه‌سازی مدل شبکه عصبی مصنوعی با شبکه عصبی موجکی برای پیش‌بینی ماهیانه بارش ایستگاه سینوپتیک کرمانشاه مقایسه گردید و اولین نتیجه‌ای که از این مقایسه گرفته شد که ضریب همبستگی شبکه عصبی در پیش‌بینی ماه اول ۰/۸۷۴ و ضریب همبستگی مدل شبکه عصبی- موجکی ۰/۹۴ می‌باشد که بیانگر برتری کامل مدل پیش‌بینی شبکه عصبی- موجکی نسبت به مدل شبکه عصبی در پیش‌بینی بارش ماهیانه می‌باشد. با این‌که به‌خاطر در اختیار داشتن کرنل غیرخطی ANN مدل توانایی مدل‌سازی رفتارهای غیرخطی را داراست، ولی با توجه به ویژگی‌های نایستایی و غیرخطی بودن سری زمانی بارش، به‌منظور پیش‌بینی و شبیه‌سازی دقیق ملزم به استفاده از شبکه عصبی- موجکی می‌باشیم. چرا که شبکه عصبی به تنهایی قادر به غلبه

منابع

1. Abrahart, R.J., and See, L. 2000. Comparing neural network (NN) and Auto Regressive Moving Average (ARMA) techniques for the provision of continuous river flow forecasts in two contrasting catchment. *Hydrol. Process.* 14: 2157-2172.
2. Asakereh, H. 2007. Linear regression analysis of annual rainfall in Tabriz. *J. Geograph. Res.* 22: 87. 3-26.
3. Bowden, G.J., Dandy, G.C., and Maier, H.R. 2005. Input determination for neural network models in water resources applications. Part 1. background and methodology. *J. Hydrol.* 301: 75-92.
4. Broadhurst, D., Goodacre, R., Jones, A., Rowland, J.J., and Kell, D.B. 1997. Genetic algorithms as a method for variable selection in multiple linear regression and partial least squares regression, with applications to pyrolysis mass spectrometry. *Anal Chim. Acta.* 348: 1-3. 71-86.
5. Cannas, B., Fanni, A., See, L., and Sias, G. 2006. Data preprocessing for river flow forecasting using neural networks: wavelet transforms and data partitioning. *Phys. Chem. Earth.* 31: 18. 1164-1171.
6. Devos, N.J. 2003. Rainfall-Runoff Modelling Using Artificial Neural Networks. M.Sc. Thesis Report. Civil Engineering Informatics Group and Section of Hydrology & Ecology.
7. 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. *J. Wate. Soil.* 24: 3. 610-624.

8. Govindaraju, Rao S. 2000. Artificial neural networks in hydrology II: hydrologic applications. *J. Hydrol. Engin.* 5: 2. 124-137.
9. Haykin, S. 1999. *Neural networks: a comprehensive foundation*, 2nd Ed., Prentice Hall., New Jersey, USA.
10. Khodashenas, S., Khalili, N., Davari, K., and Musavi Bayagi, M. 2006. Monthly Precipitation Prediction by Artificial Neural Networks (Case study: Mashhad synoptic station). *J. Water Soil.* 22: 1. 89-99.
11. Menhaj, M.B. 2002. *Foundations of Neural Networks*. Amirkabir University Publication Center. 1. 715.
12. Merry, R.J.E. 2005. *Wavelet Theory and Applications. A literature study*. Eindhoven University of Technology Department of Mechanical Engineering Control Systems Technology Group.
13. Orfanian, M., Ansari, H., and Alizadeh, A. 2013. The average monthly precipitation and temperature prediction models using artificial neural networks to link distance (Case study: Mashhad station). *J. Geograph. Res. Arid Zone.* 3: 14. 53-73.
14. Polikar, R. 1996. *Fundamental Concept and An Overview Of The Wavelet Theory Wavelet Tutorial*. Second edition. Rowan University. College of engineering web Servers. Glassboro. N.J.08028.
15. Santos, C., Calvao, C., Suzuki, K., and Trigo, R. 2001. Matsuyama city rainfall data Analysis using wavelet transform. *J. Hydr. Engin. JSCE.* 45: 211-216.
16. Shafaei, M., Fakhei Fard, A., Darbandi, S., and Ghorbani, M.A. 2013. Prediction Daily Flow of Vanyar Station Using ANN and Wavelet Hybrid Procedure. *J. Irrig. Water Engin.* 4: 14. 113-128.
17. Sifuzzaman, M., Islam, M.R., and Ali, M.Z. 2009. Application of Wavelet Transform and its Advantages Compared to Fourier Transform. *J. Phys. Sci.* 13: 121-134.
18. Silverman, D., and Dracup, J.A. 2000. Artificial neural network and long range precipitation prediction in California. *J. Appl. Meteorol.* 39: 1. 57-66.
19. Soltani, S. 2002. Comparison formally models with artificial neural networks to simulate rainfall runoff. Master Thesis. Modares University.
20. Taghavi, F., Neyestani, N., Mohammadi, M., and Rostami Jalilian, Sh. 2011. Application of wavelet analysis to investigate precipitation variability at western region of Iran. *J. Geo Phys. Iran.* 4: 13-30.
21. Thuillard, M. 2000. A review of wavelet networks, wavelets, fuzzy wavelets and their application. ESIT. in: Presented in Conference. 14-15 September.
22. Toufani, P., Mosaedi, A., and Fakheri Fard, A. 2011. Prediction of Precipitation Applying Wavelet Network Model (Case study: Zarringol station, Golestan province, Iran). *J. Water Soil.* 25: 5. 1217-1226.
23. Torrence, C.H., and Compo, G.P. 1998. A practical guide to wavelet analysis: *Bull. Am. Meteor. Soc.* 79: 61-78.
24. Zhang, Y.X. 2007. Artificial neural networks based on principal component analysis input selection for clinical pattern recognition analysis. *Talanta.* 73: 1. 68-75.

Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 22(6), 2016
<http://jwsc.gau.ac.ir>

Predicting monthly precipitation of Kermanshah synoptic station using the hybrid model of neural network and wavelet

*Gh.A. Mozafari¹, Sh. Shafie² and H.R. Hemati³

¹Associate Prof., Dept. of Geography, University of Yazd, ²Ph.D. Student, Dept. of Geography,
University of Yazd, ³M.Sc. Student, Dept. of Computer, University of Yazd

Received: 11/20/2014; Accepted: 05/31/2015

Abstract

Background and Objectives: Precipitation is one of the most important meteorology elements and recognition of its amount, its variation and prediction, are necessary to have an actual planning in agricultural, economic and social management. So the hydrologists and climatologists are paying attention to it. Due to precipitation importance in planning and crisis management, the goal of this research leads to the implementation of neural network and wavelet conversion hybrid model to monthly precipitation prediction of Kermanshah synoptic station.

Materials and Methods: In this research to predict monthly precipitation time series of Kermanshah's synoptic station, five parameters namely: monthly precipitation average, relative humidity average, Maximum temperature average, minimum temperature average and wind speed average, were used within the forty years period (1970-2010). In order to quality control of given statistic and information, sequencing test is used. The results showed that given information is significantly homogeneous and according to nonlinear specifications of multiple time scales, neural network and wavelet model is used to precipitation prediction.

Results: In order to precipitation prediction, four parameters of relative humidity average, maximum temperature average, minimum temperature average and wind speed average, were used and using wavelet alternation decomposed into 8 sub-series and then these series were used to future monthly precipitation prediction as the entrance neural network model data. The correlation coefficient ($R=0.874$) of next month prediction denoted the relatively low efficiency of the neural network while the wavelet-neural network model correlation coefficient is 0.94. Also, both model prediction precision decreases by increasing the number of output neurons delays. It should be noted that Meyer wavelet is used to wavelet- neurotic network prediction which has a high precision. Regarding the F statistic, variance analysis of homogeneity and heterogeneity indices of observed and predicted precipitation, is homogeneous in the confidence level of %99 ($P<0.008$).

Conclusion: The comparison between the driven results from wavelet conversion-neural network and driven results from a neural network application, showed that wavelet-neural network method had higher predicting precision than neural network and also predicting precision in both models decreases through increasing the number of delays of exit neurons. It is noteworthy that Meyer wavelet was used to neural network predicting which its simulated results had high precision.

Keywords: Precipitation prediction, Hybrid neural network-wavelet model, Kermanshah synoptic station, Meyer wavelet

* Corresponding Author; Email: yazdmozafari@gmail.com