

مدل سازی چندگامه پدیده‌های هیدروکلیماتولوژیکی با استفاده از مدل فصلانه موجک - شبکه عصبی

حسام نجفی^{۱،۲}، وحید نورانی^{۳*}، الناز شرقی^۴، علیرضا بابائیان امینی^۵

^۱ فارغ‌التحصیل دکتری مهندسی و مدیریت منابع آب، دانشگاه تبریز

^۲ استاد مدعو دانشکده مهندسی عمران، دانشگاه بناب

^۳ استاد دانشکده مهندسی عمران، دانشگاه تبریز

^۴ استادیار دانشکده مهندسی عمران، دانشگاه تبریز

^۵ استادیار دانشکده مهندسی عمران، دانشگاه بناب

(دریافت: ۹۵/۸/۱۸، پذیرش: ۹۹/۹/۲۹، نشر آنلاین: ۹۹/۹/۲۹)

چکیده

با توجه به این که سری‌های زمانی هیدروکلیماتولوژیکی دارای سه جزء اصلی خودهمبسته، فصلانه و تصادفی می‌باشند و رفتار مدل‌هایی که تاکنون ارائه شده‌اند، نسبت به این اجزاء متفاوت بوده است، در این مقاله از داده‌های ماهانه بارش و رواناب حوضه Murrumbidgee استرالیا و داده‌های کمینه دمای ماهانه شهر تبریز برای ایجاد و ارزیابی مدل ترکیبی موجک- شبکه عصبی استفاده شده است. با توجه به این که توانایی مدل غیرخطی و خودهمبسته شبکه عصبی مصنوعی (ANN) (Artificial Neural Network) در مدل‌سازی یک گام بعد فرآیندهای هیدروکلیماتولوژیکی (Hydro-Climatological) اثبات شده است، در این مقاله توانایی مدل ANN با انتشار برگشتی خطا و همچنین ترکیب مدل ANN و تبدیل موجک (WANN) در مدل‌سازی فصلانه فرآیندهای هیدروکلیماتولوژیکی برای پیش‌بینی چندگام بعد با به‌کارگیری کم‌ترین ورودی بررسی شده است. به‌همین منظور ابتدا از مدل ANN و سپس از مدل WANN برای پیش‌بینی یک تا دوازده گام بعد استفاده شده است. در انتها کارایی همه مدل‌ها با استفاده از معیارهای ارزیابی بررسی شده و مدل‌ها با یکدیگر مقایسه شده‌اند. نتایج مدل‌سازی بیانگر این است که استفاده از تبدیل موجک به‌عنوان پیش‌پردازش داده‌ها موجب شده با کم‌ترین ورودی، دقت نتایج مدل‌سازی در همه گام‌های پیش‌بینی به‌صورت مطلوبی افزایش یابد. برای سری زمانی رواناب مورد مطالعه به‌دلیل ویژگی خودهمبسته ضعیف و حالت فصلانه چندتناوبه قابل توجه، مدل ANN نتایج ضعیفی را ارائه داد ولی استفاده از تبدیل موجک به‌عنوان پیش‌پردازش داده‌ها باعث بهبود نتایج در همه گام‌های پیش‌بینی نسبت به مدل ANN شد (تا ۷۴٪) و همچنین با افزایش مقیاس زمانی تجزیه به‌دلیل افزایش زیر سری‌ها و کنترل بهتر حالت فصلانه نتایج مناسب‌تری برای همه گام‌های پیش‌بینی حاصل شد. برای سری زمانی دما به‌دلیل ویژگی خودهمبسته قوی و حالت فصلانه تک‌تناوبه قابل توجه، مدل ANN نتایج نسبتاً مناسبی را ارائه داد ولی استفاده از تبدیل موجک به‌عنوان پیش‌پردازش داده‌ها باعث بهبود نتایج در همه گام‌های پیش‌بینی نسبت به مدل ANN شد (تا ۱۸٪) ولی عملاً تغییر مقیاس تجزیه، تفاوت چندانی را ایجاد نکرد.

کلیدواژه‌ها: مدل‌سازی فصلانه چندگامه، ANN، WANN، رواناب حوضه Murrumbidgee، کمینه دمای تبریز.

۱- مقدمه

هیدروکلیماتولوژیکی دارای یک سیستم غیرخطی و پیچیده می‌باشند و از این‌رو پیش‌بینی حالت دقیق آن‌ها غیرممکن خواهد بود. ویژگی تصادفی بودن پدیده‌های هیدروکلیماتولوژیکی سبب شده هیدرولوژیست‌ها^۱ از مفاهیم متغیرهای تصادفی و سری‌های زمانی در مدل‌سازی و پیش‌بینی فرآیندهای

فرآیندهای هیدروکلیماتولوژیکی در یک حوضه به‌علت وابسته بودن به متغیرهای زمانی و مکانی، الگوهای مختلف اقلیمی و تعداد پارامترهایی که در این فرآیندها اثر می‌گذارند، جزو پیچیده‌ترین روابط در علوم مهندسی می‌باشند. فرآیندهای

1. Hydrologists

* نویسنده مسئول؛ شماره تماس: ۹۸۹۱۴۴۰۳۰۲۳۳۲

مصنوعی می‌باشند که حالت خودهمبسته دارند و به‌صورت غیرخطی توانایی کنترل جزء خودهمبسته سری زمانی را دارند. یکی از دغدغه‌های مربوط به شبکه عصبی مصنوعی ظرفیت و توانایی آن در پیش‌بینی چند گام بعد می‌باشد. ظرفیت و توانایی بالای شبکه عصبی مصنوعی در پیش‌بینی یک گام بعد در بسیاری از زمینه‌ها اثبات شده است و در بسیاری از تحقیقات منتشر شده در مورد ANN از پیش‌بینی یک گام بعد استفاده شده و مقالات متعددی از کاربرد موفق ANN در مدل‌سازی فرآیندهای هیدروکلیماتولوژیکی برای یک گام بعد ارائه شده است (به‌عنوان مثال: Kim و Valdés، ۲۰۰۳؛ Antar و همکاران، ۲۰۰۶؛ Dinu و همکاران، ۲۰۱۷). همچنین Abrahart و همکاران (۲۰۱۲) یک مرور جامع بر روی کاربرد ANN در مدل‌سازی‌های هیدروکلیماتولوژیکی انجام داده‌اند. درحالی‌که پیش‌بینی چند گام بعد نیز در بسیاری از زمینه‌ها نظیر شناسایی سیستم‌ها و مدل‌سازی زیست‌محیطی برای مواردی چون کاهش خطرات سیلاب کاربرد دارد (Xie و همکاران، ۲۰۰۶). بنابراین تاکنون چندین تحقیق در زمینه کاربرد پیش‌بینی چند گام بعد صورت گرفته است (به‌عنوان مثال: Tsai و Chang، ۲۰۱۶؛ Yang و همکاران، ۲۰۱۳).

یکی از راه‌های مناسب برای کنترل جزء فصلانه سری‌های زمانی به کمک ابزارهای هوش مصنوعی، استفاده از تبدیل موجک می‌باشد. تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال می‌باشد چراکه این تبدیل توانایی بیان اطلاعات فرکانسی و زمانی را به‌صورت هم‌زمان برای یک سیگنال دارا می‌باشد. بنابراین با تبدیل موجک می‌توان یک سری زمانی را به زیرسری‌هایی در حوزه فرکانس و حوزه زمانی تجزیه نمود که این عملکرد توانایی کنترل حالت فصلانه چندگانه در رفتار یک سری زمانی را دارا می‌باشد و با داشتن اطلاعات در سطوح مختلف فرکانسی کمک شایانی را در مدل‌سازی می‌نماید. مدل ترکیبی WANN^۵ که از ترکیب تبدیل موجک و شبکه عصبی به‌دست آمده است.

Nourani و همکاران (۲۰۱۴) مروری جامع بر کاربردهای ترکیب موجک با مدل‌های هوش مصنوعی در هیدرولوژی انجام داده‌اند. هدف این مقاله پیش‌بینی ۱ تا ۱۲ گام بعد (در مقیاس ماهانه) سری‌های زمانی فصلانه دما و رواناب می‌باشد، به‌همین منظور در گام اول از مدل ANN با ترکیب‌های ورودی مختلف برای مدل‌سازی بارش- رواناب و دما استفاده شده و سپس در گام دوم به‌دلیل پیچیدگی سری زمانی بارش- رواناب، توسط مدل WANN برای پیش‌بینی رواناب ماهانه یک گام بعد، آنالیز حساسیت صورت گرفته و بهترین ترکیب ورودی و تبدیل موجک

هیدروکلیماتولوژیکی کمک بگی‌رند. در نتیجه برای مدل‌سازی فرآیندهای هیدروکلیماتولوژیکی در این چند دهه اخیر، انواع مدل‌ها ارائه شده است.

سری‌های زمانی هیدروکلیماتولوژیکی عموماً دارای سه جزء اساسی خودهمبسته، فصلانه و تصادفی می‌باشند که توانایی انواع مدل‌هایی که تاکنون ارائه شده، در کنترل این اجزاء متفاوت بوده است. ارائه مدلی متأثر از تمام عوامل مؤثر در پدیده‌های هیدروکلیماتولوژیکی به دلیل تعدد آن‌ها و همچنین وابستگی آن‌ها به شرایط مکانی و زمانی امکان‌پذیر نیست، به همین دلیل برحسب استفاده از روش‌های گوناگون برای ساده‌سازی، انواع مدل‌ها توسعه می‌یابند. در این راستا از مدل‌های جعبه سیاه که با دریافت ورودی و انجام یک سری عملیات ریاضی، خروجی موردنظر را می‌دهند، استفاده می‌شود. فرآیند بارش- رواناب از مهم‌ترین و پیچیده‌ترین فرآیندهای هیدرولوژیکی است. این فرآیند شامل حرکت قطرات باران در حالت‌های مختلف و در نهایت تشکیل رواناب در کانال‌های طبیعی یا مصنوعی می‌باشد. از طرف دیگر دما از عمده‌ترین عناصری است که در تعیین نقش و پراکندگی دیگر عناصر اقلیم تأثیر اساسی داشته و یکی از شاخص‌های اصلی در پهنه‌بندی و طبقه‌بندی اقلیمی بشمار می‌رود (حسن‌زاده و آقاخانی افشار، ۱۳۹۸). برنامه‌ریزی‌های مبتنی بر روند دما می‌تواند راهگشای بسیاری از مسائل زیست‌محیطی از جمله شهرسازی، روستایی و کشاورزی باشد لذا باتوجه به اجزاء اصلی سری زمانی فرآیندهای هیدروکلیماتولوژیکی و در نتیجه فرآیند بارش- رواناب و دما به- عنوان نمونه‌های مهم از این فرآیندها، در سال‌های اولیه، مدل‌هایی خطی از جمله مدل خودهمبسته ARIMA^۲ برای کنترل جزء خودهمبسته و همچنین مدل فصلانه ARIMA یعنی SARIMA^۳ برای کنترل جزء فصلانه و همچنین جزء خودهمبسته ارائه شدند (Tankersley و همکاران، ۱۹۹۳؛ نورانی و همکاران، ۱۳۹۴). ولی به هر حال این مدل‌ها اساساً خطی‌اند و توانایی کمی در مقابله با ناپستیایی و غیرخطی بودن داده‌ها دارند (Sharghi و همکاران، ۲۰۱۸).

در سال‌های اخیر روش‌های هوش مصنوعی AI^۴ توانایی قابل‌ملاحظه‌ای در مدل‌سازی و پیش‌بینی سری‌های زمانی هیدروکلیماتولوژیکی از خود نشان داده‌اند. این روش‌ها چون مبتنی بر داده هستند، به دانش اولیه نسبت به پدیده مورد مطالعه نیاز ندارند. مدل‌های مبتنی بر AI، ابزاری کارآمد برای کار کردن بر روی تعداد وسیعی از داده‌های دینامیکی و غیرخطی می‌باشند به‌خصوص اگر روابط بین عوامل فیزیکی دخیل در پدیده به‌صورت کامل مشخص نباشد. مدل‌های ANN^۵ از جمله روش‌های هوش

5. Artificial Neural Network

6. Wavelet Artificial Neural Network

2. Autoregressive integrated moving average

3. Seasonal autoregressive integrated moving average

4. Artificial Intelligence

هستند.

در اکثر کاربردهای عملی فرآیندهای هیدرولوژیکی سری زمانی دارای حالت گسسته می‌باشد که در این حالت موجک گسسته به صورت رابطه (۱) بیان می‌شود (Adison, ۲۰۰۲):

$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} g\left(\frac{t-nb_0a_0^m}{a_0^m}\right) \quad (1)$$

در رابطه فوق، m و n اعداد صحیحی هستند که به ترتیب میزان مقیاس و انتقال موجک را کنترل می‌نمایند. همچنین a_0 گام مقیاس کوچک ویژه برای پارامتر انتقال ($a_0 > 1$) و b_0 پارامتر انتقال موقعیت ($b_0 > 0$) می‌باشند. معمولی‌ترین حالت برای پارامترهای رابطه (۱) مقادیر $a_0 = 2$ و $b_0 = 1$ هستند که این مقیاس لگاریتمی با توان دو برای انتقال و مقیاس تحت عنوان آرایش شبکه دوتایی^۷ نامیده می‌شود. زیرسری جزئیات خواص با دامنه کوتاه مدت سری زمانی را بیان می‌کنند در حالی که زیرسری تقریب بیانگر اطلاعات کلی و تقریبی از سری اولیه است. به بیان دیگر هر یک از زیرسری-ها، یک دوره تناوب از سری را شامل می‌شوند که خواص همان دوره تناوب را بیان می‌کنند. از این رو در انتخاب تعداد زیرسری‌ها و یا به عبارتی درجه تجزیه یک سری بایستی تعداد الگوهای تناوب موجود و یا محتمل در سری زمانی را ملاک انتخاب قرار داد. در این مقاله برای مدل سازی سری های هیدرولوژیکی از موجک مادر db4 استفاده شده است. این موجک بسته به شکل خود دارای قابلیت‌ها و کاربردهای متفاوتی می‌باشد.

۲-۳- مدل شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی دسته‌ای از سیستم‌های دینامیکی هستند که با پردازش روی داده‌های تجربی دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کند، به همین خاطر به این سیستم‌ها هوشمند گویند. ساختار سه لایه شبکه عصبی پیشرو با الگوریتم انتشار برگشتی^۸ FFNNs در اکثر مدل سازی‌های سری‌های زمانی مورد استفاده قرار می‌گیرد و یک الگوی کلی برای نگاشت غیرخطی میان متغیرهای ورودی و خروجی است. برای پیش‌بینی چند گام بعد، از روش مستقیم استفاده شده است.

مناسب انتخاب شده و برای پیش‌بینی رواناب ۱ تا ۱۲ گام بعد استفاده شده است. در گام سوم توسط مدل WANN برای پیش‌بینی ۱۲ گامه سری زمانی دمای ماهانه مدل سازی صورت گرفته است. در نهایت نتایج حالات مختلف با هم مقایسه و کارایی مدل‌های ارائه شده ارزیابی شده است.

۲- مواد و روش‌ها

در این مقاله برای مدل کردن هم‌زمان خاصیت خودهمبستگی و فصلانه سری‌های زمانی دما و رواناب (در مقیاس ماهانه) به منظور پیش‌بینی چندگامه، از مدل ترکیبی WANN استفاده شده و به منظور ارزیابی و مقایسه نتایج از مدل ANN نیز استفاده شده است. مدل سازی به کمک مدل WANN شامل چندین مرحله است که مرحله نخست شامل انتخاب داده‌های ورودی به مدل و پردازش کلی داده‌ها از نظر صحت و کیفیت داده‌ها می‌باشد. مرحله دوم شامل نرمال سازی و بدون بعد کردن داده‌ها می‌باشد تا همه داده‌ها در بازه صفر و یک قرار بگیرند. در مرحله سوم نیز به وسیله تبدیل موجک، سری زمانی ورودی به زیر سری‌هایی با دقت و مقیاس‌های متفاوت تجزیه می‌گردد و در نهایت به کمک مدل ANN مدل سازی صورت گرفته و سری‌های نهایی پیش‌بینی برای گام‌های مختلف، به عنوان خروجی به وجود می‌آیند.

۲-۱- مدل ترکیبی ارائه شده

مدل ترکیبی WANN برای ترکیب هم‌زمان توانایی‌های مدل هوش مصنوعی (ANN) و آنالیز موجک در یک ساختار واحد برای مدل سازی بارش- رواناب و دما طراحی گردیده است. در این مدل، پیش‌پردازش داده‌ها توسط تبدیل موجک انجام گرفته و سپس نتایج این پردازش به عنوان ورودی در شبکه عصبی مصنوعی استفاده می‌گردد. در این نوع مدل سازی، تبدیل موجک گسسته این امکان را فراهم می‌آورد که مقیاس‌های مختلف زمانی به صورت جداگانه مورد ارزیابی و بررسی قرار گیرند. به این گونه که ابتدا سری زمانی مورد نظر را توسط تبدیل موجک گسسته در مقیاس-های زمانی مختلف تجزیه کرده و سپس ترکیب‌های مختلف به-عنوان ورودی به ANN داده می‌شود.

۲-۲- تبدیل موجک

موجک برای اولین بار در سال ۱۹۸۴ معرفی گردید و در مدت زمان کوتاهی توجه پژوهشگران سراسر دنیا را به خود جلب کرد. این موفقیت دلایل متعددی دارد: از یک طرف مفهوم موجک ترکیبی از نظریه‌های موجود در علوم مهندسی، ریاضی و فیزیک می‌باشد و از طرف دیگر این توابع ابزارهای ساده‌ای در ریاضیات

۵۱۵۸ کیلومترمربع را شامل می‌شود که در اطراف رودخانه Murrumbidgee River below Lobbs Hole Creek حدوداً ۲۴۲ کیلومتر متمرکز شده است. برای مدل‌سازی دما نیز از داده‌های کمینه دمای ماهانه شهر تبریز برای محدوده زمانی سال‌های ۱۹۷۵ تا ۲۰۱۴ که از سازمان هواشناسی کشور تهیه شده، استفاده شده است (جدول (۳)). تبریز در غرب استان آذربایجان شرقی و در منتهی‌الیه مشرق و جنوب‌شرق جلگه تبریز قرار گرفته است.

جدول ۱- مشخصات آماری رواناب ماهانه حوضه آبریز

Murrumbidgee				
سری زمانی رواناب (ML/month)				
Standard Deviation	Mean	Min	Max	داده‌های
۵۹۶۱۳/۵۴	۳۱۷۲۲/۷۵	۱۳۴/۶	۴۴۵۴۲۳	آموزش
Standard Deviation	Mean	Min	Max	داده‌های
۳۰۴۷۶/۳۹	۱۵۵۰۷/۹۸	۷/۳۹	۳۳۱۳۴۰	صحت‌سنجی


جدول ۲- مشخصات آماری بارش ماهانه حوضه آبریز

Murrumbidgee				
سری زمانی بارش (mm)				
Standard Deviation	Mean	Min	Max	داده‌های آموزش
۴۰/۷	۵۴/۶۵	۰/۴	۲۲۱/۴	
Standard Deviation	Mean	Min	Max	داده‌های
۳۹/۲۹	۵۰/۵۶	۰/۴	۲۴۹/۲	صحت‌سنجی

جدول ۳- مشخصات آماری داده‌های کمینه دمای ماهانه شهر

تبریز				
سری زمانی دما (°C)				
Standard Deviation	Mean	Min	Max	مجموعه داده‌های آموزش
۹/۹	۱/۵۰	-۲۱/۶	۱۸/۸	
Standard Deviation	Mean	Min	Max	مجموعه داده‌های صحت‌سنجی
۱۰	۲/۰۲	-۱۸	۱۸/۸	

آب‌وهوای تبریز با تابستان‌های گرم و خشک و زمستان‌های سرد است. سرمای زمستانی، تأثیر پذیرفته از ارتفاع بالا و توپوگرافی کوهستانی منطقه است. با توجه به این‌که هدف این مقاله بررسی توانایی مدل‌های ANN و WANN در مدل‌سازی سری‌های زمانی با ویژگی اصلی فصلانه می‌باشد به همین دلیل برای این مقاله داده‌های بارش-رواناب ایستگاه‌های شرقی حوضه Murrumbidgee که منطقه کوهستانی و نزدیک به ساحل است،

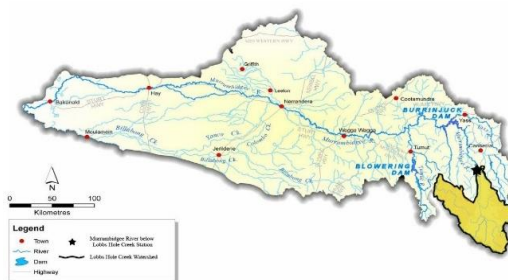


شکل ۱- پیش‌بینی با روش مستقیم

در روش مستقیم در لایه خروجی به جای یک گام، همه گام‌های مدنظر به عنوان خروجی قرار داده می‌شوند و ورودی‌ها نیز همگی از گام‌های زمانی قبل انتخاب می‌شوند (شکل (۱)). در این روش می‌توان در هر مرحله فقط از یک نرون^۹ خروجی استفاده کرد ولی با توجه به این‌که در این مقاله از نرم‌افزار متلب برای مدل‌سازی استفاده شده است برای افزایش سرعت مدل‌سازی کدهای مدل به‌گونه‌ای تنظیم شده‌اند که همه گام‌های مدنظر به عنوان خروجی قرار گیرند.

۲-۴- داده‌های مورد استفاده

در این مقاله برای مدل‌سازی بارش-رواناب از داده‌های ماهانه ایستگاه‌های (Murrumbidgee River below Lobbs Hole Creek) برای رواناب و (AinslieTyson St) برای بارش استفاده شده که در پایتخت استرالیا (کانبرا) و قسمت شرقی حوضه آبریز Murrumbidgee قرار دارند (شکل (۲)).



شکل ۲- حوضه آبریز Murrumbidgee

این داده‌ها به طول ۳۹ سال (۲۰۱۴-۱۹۷۵) می‌باشند که ۲۵ سال اول برای آموزش و ۱۴ سال بعدی برای صحت‌سنجی مدل‌ها استفاده می‌گردند (جدول (۱) و (۲)).

حوضه آبریز Murrumbidgee مساحتی بالغ بر ۸۴۰۰۰ کیلومترمربع از ایالت ولز جنوبی جدید (واقع در جنوب شرقی استرالیا) را شامل می‌شود. این حوضه در اطراف رودخانه Murrumbidgee به طول حدوداً ۱۶۰۰ کیلومتر متمرکز شده است (شکل (۲)). زیرحوضه مورد مطالعه نیز، مساحتی بالغ بر

که در این روابط O_i بیانگر داده‌های مشاهداتی، \bar{O} میانگین داده‌های مشاهداتی، C_i داده‌های محاسباتی و N تعداد کل داده‌های موجود می‌باشد.

۳- نتایج و بحث

جهت مدل‌سازی چندگامه ابتدا از مدل ANN بدون پیش‌پردازش داده‌ها استفاده شده و در ادامه از مدل WANN، با پیش‌پردازش داده‌ها توسط تبدیل موجک که توانایی لحاظ کردن خصوصیات فصلی و تناوبی یک فرآیند را دارا می‌باشد استفاده شده است. ترکیب‌های ورودی مدل‌های چندمتغیره ANN و WANN نیز به کمک معیار Correlation خطی (CC) و معیار تابع اطلاعات مشترک (MI) انتخاب شده‌اند، به گونه‌ای که ارتباط خطی و غیرخطی ورودی با خروجی مدل توسط معیار CC و MI بررسی شده و سپس توسط صحیح و خطا بهترین ترکیب ورودی انتخاب شده است (Sharghi و همکاران، ۲۰۱۸). با توجه به این که هدف این مقاله پیش‌بینی تا ۱۲ گام بعد می‌باشد، چالش‌های زیر مطرح می‌شود:

الف) با توجه به ACF سری زمانی رواناب مورد استفاده که دارای ویژگی خودهمبسته ضعیف و ویژگی فصلانه ضعیف (البته فصلانه تک‌تناوبه) می‌باشد، رسیدن به یک مدل مناسب با سختی مواجه است.

ب) با توجه به این که هر مدل با یک ترکیب ورودی با ۱۲ نوع خروجی سروکار دارد، انتخاب ترکیب ورودی‌ای که بتواند برای همه خروجی‌ها نتایج مناسبی داشته باشد، جزء چالش‌های اصلی می‌باشد.


ت) همچنین بررسی تعداد گام‌های مناسب برای پیش‌بینی، از چالش‌های این مقاله می‌باشد.

۳-۱- مدل ANN


با توجه به ACF سری زمانی رواناب (شکل (۳)) که رواناب دارای رابطه خطی ضعیفی با گذشته می‌باشد و همچنین رابطه خطی ضعیف رواناب با بارش، با توجه به Correlation خطی ضعیف بین آن‌ها، همچنین تعداد خروجی متعدد (۱۲ تا)، انتخاب ورودی مناسب دشوار می‌باشد، در نتیجه برای مدل‌سازی بارش- رواناب از ترکیب‌های مختلف ورودی استفاده شده است؛ ولی با توجه به ACF سری زمانی دما (شکل (۴)) که دما دارای رابطه خطی قوی با گذشته می‌باشد، فقط یک نوع ترکیب ورودی استفاده شده است.

برای مدل‌سازی چندگامه (تا ۱۲ گام بعد) بارش- رواناب با

انتخاب شده‌اند که همبستگی بین هر رواناب ماه با ماه‌های گذشته با توجه به ACF^{۱۰} رواناب، کم می‌باشد (شکل (۳)).



شکل ۳- ACF سری رواناب حوضه آبریز Murrumbidgee



شکل ۴- ACF سری زمانی کمینه دمای ماهانه شهر تبریز

همچنین از داده‌های کمینه دمای ماهانه شهر تبریز که هم‌زمان دارای ویژگی خودهمبستگی و فصلانه قوی می‌باشد، استفاده شده است (شکل (۴)).

۲-۵- معیارهای ارزیابی

صحت‌سنجی مدل‌های پیش‌بینی به منظور سنجش دقت مدل‌ها در انجام پیش‌بینی صورت می‌گیرد. برای این منظور آماره‌های مختلفی تدوین شده و مورد استفاده قرار می‌گیرند. از پرکاربردترین آن‌ها در مدل‌سازی هیدروکلیماتولوژیکی، معیار Nash-Sutcliffe (E) و جذر میانگین مربعات خطا (RMSE) می‌باشند که با توجه به روابط (۲) و (۳) باید مقادیر آن‌ها در هر دو مرحله آموزش و صحت‌سنجی در محدوده مطلوب قرار گیرند.

$$E = 1 - \frac{\sum_{i=1}^N (O_i - C_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - C_i)^2}{N}} \quad (3)$$

ANN، از روش مستقیم که شامل ۳ نوع ترکیب ورودی می‌باشد، استفاده شده که با توجه به تعداد ورودی، تا ۴۰ نرون میانی با ۱۵۰ تکرار در نظر گرفته شده و بهترین نتایج با تعداد نرون میانی و تکرار در جدول (۴) ذکر شده است. همان‌طور که در جدول (۴) مشاهده می‌شود برای تعداد ۳ و ۱۰ متغیر ورودی نتایج مدل‌سازی برای همه گام‌های موردنظر ضعیف می‌باشد و برای ۴ متغیر ورودی با ترکیب ذکرشده فقط برای گام اول پیش‌بینی نتایج نسبتاً بهتر می‌باشد و در کل با افزایش گام پیش‌بینی نتایج مدل‌سازی با مدل خودهمبسته ANN به دلیل ویژگی ضعیف خودهمبستگی سری زمانی رواناب رضایت‌بخش نمی‌باشد.

برای مدل‌سازی چندگامه (تا ۱۲ گام بعد) سری زمانی دما با ANN، نیز از روش مستقیم که شامل ۱ نوع ترکیب ورودی می‌باشد استفاده شده که با توجه به تعداد ورودی، تا ۸ نرون میانی با ۱۵۰ تکرار در نظر گرفته شده و بهترین نتایج با تعداد نرون میانی و تکرار در جدول (۵) ذکر شده است. همان‌طور که در جدول (۵) مشاهده می‌شود، با توجه به ویژگی خودهمبستگی قوی سری زمانی دما، نتایج مدل‌سازی نسبت به مدل‌سازی بارش - رواناب بهتر می‌باشد و حتی افزایش گام‌های پیش‌بینی نیز باعث کاهش دقت مدل‌سازی نمی‌شود و حتی نتایج گام ۱۲ و ۱۱ بهتر از بقیه می‌باشد. با توجه به نتایج ضعیف پیش‌بینی چندگامه رواناب ماهانه توسط مدل خودهمبسته ANN و همچنین بررسی پیش‌بینی چندگامه دمای ماهانه، در ادامه برای پیش‌بینی از مدل فصلانه چندتناوبه WANN استفاده شده است.

۳-۲- مدل WANN

دومین مدل استفاده‌شده در این تحقیق، مدل ترکیبی WANN می‌باشد که برای استفاده هم‌زمان از ظرفیت‌های ANN و تبدیل موجک طراحی شده است. به این صورت که داده‌های پیش‌پردازش شده با تبدیل موجک به‌عنوان ورودی به ANN اعمال می‌شوند. به‌منظور این هدف با توجه به کارهای گذشته صورت گرفته (به عنوان مثال، Morlet و Grossmann، ۱۹۸۴؛ Nourani و همکاران، ۲۰۱۱؛ Khanghah و همکاران، ۲۰۱۲) از تبدیل موجک گسسته با موجک مادر db4 و مقیاس‌های تجزیه ۲، ۳ و ۴ استفاده شده و بهترین نتایج ذکر شده است.

برای مدل‌سازی رواناب با توجه به نتایج ضعیف ANN و در نظر گرفتن این‌که رواناب دارای رابطه خطی ضعیفی با رواناب و بارش گذشته می‌باشد، به‌منظور انتخاب ورودی مناسب مدل WANN آنالیز حساسیت ضروری به‌نظر می‌رسد تا بتوان از

افزایش تعداد ورودی‌ها جلوگیری کرد و بهترین ترکیب ورودی را انتخاب کرد. به‌منظور آنالیز حساسیت برای پیش‌بینی یک گام بعد (هدف $Q(t+1)$)، سری‌های زمانی $Q(t)$ و $I(t)$ توسط موجک مادر db4 در مقیاس‌های ۳ و ۴ تجزیه شدند و به‌عنوان ورودی به شبکه عصبی اعمال شدند. همان‌طور که در جدول (۶) قابل‌مشاهده است، در هر دو مقیاس زمانی تجزیه شده، استفاده از سری زمانی بارش ماه قبل به‌عنوان ورودی باعث کاهش دقت مدل شده است، در نتیجه برای ورودی مدل WANN فقط از سری زمانی رواناب یک ماه قبل و دو ماه قبل استفاده شده است. با توجه به ویژگی آنالیز چندمقیاسه مدل WANN، عملاً نیازی به استفاده از تعداد ورودی زیاد نمی‌باشد و همچنین با توجه به نتایج جدول (۶) (مربوط به آنالیز حساسیت)، برای پیش‌بینی چندگامه رواناب ماهانه توسط مدل WANN، از تبدیل موجک db4 و ترکیب ورودی $Q(t)$ و $Q(t-1)$ با مقیاس‌های تجزیه ۲، ۳ و ۴ استفاده شده است و بهترین نتایج که شامل تجزیه با موجک مادر db4 و مقیاس زمانی ۴ می‌باشد، در جدول (۷) ذکر شده است. همان‌طور که در جدول (۷) مشاهده می‌شود، استفاده از تبدیل موجک به‌دلیل آنالیز چندمقیاسه سری زمانی رواناب، باعث بهبود قابل‌توجه دقت مدل نسبت به ANN در همه ۱۲ گام پیش‌بینی رواناب ماهانه شده است ولی همان‌طور که مشاهده می‌شود با افزایش گام پیش‌بینی، به‌دلیل خاصیت خودهمبستگی ضعیف سری زمانی رواناب، دقت مدل‌سازی کاهش پیدا کرده است. همان‌طور که در جدول (۷) مشاهده می‌شود استفاده از تبدیل موجک به‌دلیل آنالیز چندمقیاسه سری زمانی رواناب، باعث بهبود قابل‌توجه دقت مدل نسبت به ANN در همه ۱۲ گام پیش‌بینی رواناب ماهانه شده است ولی همان‌طور که مشاهده می‌شود با افزایش گام پیش‌بینی، به‌دلیل خاصیت خودهمبستگی ضعیف سری زمانی رواناب، دقت مدل‌سازی کاهش پیدا کرده است.

برای پیش‌بینی سری زمانی ماهانه دما نیز، به‌منظور تشخیص ویژگی‌ها و الگوهای زمانی موجود و حالت فصلانه از پیش‌پردازش زمانی داده‌ها توسط تبدیل گسسته موجک db4 در مقیاس‌های تجزیه ۲، ۳ و ۴ استفاده شد و بهترین نتایج که شامل مقیاس تجزیه ۳ می‌باشد، در جدول (۸) ذکر شده است.

همان‌طور که در جدول (۸) مشاهده می‌شود، در پیش‌بینی دمای ماهانه نیز، استفاده از تبدیل موجک باعث بهبود دقت مدل نسبت به ANN در همه ۱۲ گام پیش‌بینی دمای ماهانه شده است و به‌دلیل خاصیت خودهمبستگی بالای سری زمانی دما، حتی با افزایش گام پیش‌بینی، دقت مدل تغییر چندانی پیدا نکرده است.

جدول ۴- نتایج و ساختار مدل سازی بارش- رواناب با مدل ANN

RMSE (نرمال شده)		E		ساختار	هدف	گام	متغیرهای ورودی
صحت سنجی	آموزش	صحت سنجی	آموزش				
۰/۱۱۹	۰/۰۶۶	۰/۰۴۵	۰/۲۴۰	۳--۳--۱	Q(t+1)	۱	Q(t) Q(t-1) I(t)
۰/۱۲۲	۰/۰۷۱	-۰/۰۱۹	۰/۰۵۹	۳--۷--۱	Q(t+2)	۲	
۰/۱۱۶	۰/۰۷۵	-۰/۰۴۸	۰/۱۱۲	۳--۸--۱	Q(t+3)	۳	
۰/۱۲۱	۰/۰۷۸	-۰/۱۳۶	۰/۰۳۶	۳--۷--۱	Q(t+4)	۴	
۰/۱۱۲	۰/۰۷۱	-۰/۱۰۲	۰/۱۶۴	۳--۳--۱	Q(t+5)	۵	
۰/۱۳۱	۰/۰۷۲	-۰/۱۴۶	-۰/۱۳۵	۳--۷--۱	Q(t+6)	۶	
۰/۱۲۱	۰/۰۷۳	-۰/۱۵۷	۰/۰۲۳	۳--۸--۱	Q(t+7)	۷	
۰/۱۲۲	۰/۰۷۲	-۰/۱۰۴	۰/۰۰۹	۳--۳--۱	Q(t+8)	۸	
۰/۱۲۱	۰/۰۷۱	-۰/۰۸۵	۰/۰۱۵	۳--۸--۱	Q(t+9)	۹	
۰/۱۱۷	۰/۰۷۱	-۰/۰۶۲	۰/۰۸۶	۳--۷--۱	Q(t+10)	۱۰	
۰/۱۱۹	۰/۰۶۸	۰/۰۰۳	۰/۰۵۹	۳--۸--۱	Q(t+11)	۱۱	
۰/۱۱۹	۰/۰۶۷	۰/۰۳۶	۰/۰۵۰	۳--۴--۱	Q(t+12)	۱۲	
۰/۱۰۵	۰/۰۴۷	۰/۵۱۲	۰/۶۷۰	۴--۱۵--۱	Q(t+1)	۱	Q(t) Q(t-1) Q(t-2) I(t)
۰/۱۲۲	۰/۰۶۷	۰/۱۱۹	۰/۱۵۲	۴--۴--۱	Q(t+2)	۲	
۰/۱۱۴	۰/۰۶۹	۰/۱۱۶	۰/۱۴۶	۴--۵--۱	Q(t+3)	۳	
۰/۱۲۹	۰/۰۷۲	-۰/۱۱۲	-۰/۱۰۴	۴--۱۲--۱	Q(t+4)	۴	
۰/۱۰۰	۰/۰۷۱	-۰/۰۹۲	۰/۳۳۹	۴--۱۱--۱	Q(t+5)	۵	
۰/۱۲۲	۰/۰۷۱	-۰/۰۷۹	۰/۰۰۴	۴--۹--۱	Q(t+6)	۶	
۰/۱۲۳	۰/۰۷۳	-۰/۱۴۷	-۰/۰۰۶	۴--۱--۱	Q(t+7)	۷	
۰/۱۲۳	۰/۰۷۰	-۰/۰۵۲	-۰/۰۰۷	۴--۸--۱	Q(t+8)	۸	
۰/۱۲۲	۰/۰۶۹	-۰/۰۲۰	۰/۰۰۲	۴--۶--۱	Q(t+9)	۹	
۰/۱۲۱	۰/۰۶۹	۰/۱۲۰	۰/۱۲۵	۴--۶--۱	Q(t+10)	۱۰	
۰/۱۰۴	۰/۰۶۹	۰/۱۷۱	۰/۲۷۱	۴--۶--۱	Q(t+11)	۱۱	
۰/۱۲۱	۰/۰۶۹	۰/۱۲	۰/۱۷۰	۴--۶--۱	Q(t+12)	۱۲	
۰/۱۰۲	۰/۰۶۳	۰/۱۳۵	۰/۴۳۹	۱۰--۳--۱	Q(t+1)	۱	Q(t) Q(t-1) Q(t-2) Q(t-3) Q(t-4) I(t) I(t-1) I(t-2) I(t-3) I(t-4)
۰/۱۱۷	۰/۰۶۷	۰/۰۱۷	۰/۱۳۸	۱۰--۷--۱	Q(t+2)	۲	
۰/۱۰۵	۰/۰۶۹	-۰/۰۴۰	۰/۲۷۵	۱۰--۱۴--۱	Q(t+3)	۳	
۰/۰۶۳	۰/۰۵۸	۰/۲۸۴	۰/۷۳۴	۱۰--۲۷--۱	Q(t+4)	۴	
۰/۱۱۷	۰/۰۷۳	-۰/۱۶۲	۰/۱۰۱	۱۰--۲--۱	Q(t+5)	۵	
۰/۱۲۲	۰/۰۶۹	-۰/۰۱۹	۰/۰۱۷	۱۰--۱۸--۱	Q(t+6)	۶	
۰/۱۲۲	۰/۰۶۹	-۰/۰۴۲	۰/۰۰۲	۱۰--۵--۱	Q(t+7)	۷	
۰/۱۲۲	۰/۰۶۹	-۰/۰۳۰	۰/۰۱۳	۱۰--۵--۱	Q(t+8)	۸	
۰/۱۳۹	۰/۰۶۹	-۰/۲۸۱	-۰/۰۲۵	۱۰--۳۳--۱	Q(t+9)	۹	
۰/۱۱۸	۰/۰۷۰	-۰/۰۵۴	۰/۰۶۵	۱۰--۹--۱	Q(t+10)	۱۰	
۰/۱۱۶	۰/۰۶۶	۰/۰۶۸	۰/۰۹۹	۱۰--۹--۱	Q(t+11)	۱۱	
۰/۱۳۸	۰/۰۵۵	-۰/۲۷۷	۰/۳۶۰	۱۰--۳۲--۱	Q(t+12)	۱۲	

جدول ۵- نتایج و ساختار مدل سازی دما با مدل ANN

RMSE (نرمال شده)		E		ساختار	هدف	گام	متغیرهای ورودی
صحت سنجی	آموزش	صحت سنجی	آموزش				
۰/۱۰۷	۰/۰۹۶	۰/۸۰۹	۰/۸۴۹	۲--۷--۱	T(t+1)	۱	T(t), T(t-1)
۰/۱۱۹	۰/۱۱۱	۰/۷۶۳	۰/۸۰۰	۲--۸--۱	T(t+2)	۲	
۰/۱۲۳	۰/۱۱۷	۰/۷۴۹	۰/۷۷۸	۲--۸--۱	T(t+3)	۳	
۰/۱۱۰	۰/۱۰۶	۰/۷۹۷	۰/۸۱۷	۲--۷--۱	T(t+4)	۴	
۰/۰۹۲	۰/۰۸۹	۰/۸۶۰	۰/۸۷۰	۲--۸--۱	T(t+5)	۵	
۰/۰۹۳	۰/۰۹۰	۰/۸۵۶	۰/۸۶۸	۲--۵--۱	T(t+6)	۶	
۰/۱۱۲	۰/۱۰۶	۰/۷۹۲	۰/۸۱۸	۲--۸--۱	T(t+7)	۷	
۰/۱۲۷	۰/۱۲۱	۰/۷۳۳	۰/۷۶۳	۲--۷--۱	T(t+8)	۸	
۰/۱۲۹	۰/۱۲۰	۰/۷۲۵	۰/۷۶۵	۲--۸--۱	T(t+9)	۹	
۰/۱۱۴	۰/۱۰۰	۰/۷۸۴	۰/۸۳۷	۲--۸--۱	T(t+10)	۱۰	
۰/۰۹۲	۰/۰۸۱	۰/۸۵۷	۰/۸۹۳	۲--۷--۱	T(t+11)	۱۱	
۰/۰۹۰	۰/۰۸۶	۰/۸۶۴	۰/۸۷۹	۲--۸--۱	T(t+12)	۱۲	

جدول ۶- نتایج و ساختار مربوط به آنالیز حساسیت مدل WANN با موجک مادر db4

ردیف	ورودی	مقیاس	ساختار شبکه عصبی	E		RMSE (نرمال شده)
				آموزش	صحت‌سنجی	
۳	$\frac{Q(t)}{I(t)}$	۳	۸-۹-۱	۰/۹۸	۰/۶۲	۰/۰۴
۴	$\frac{Q(t)}{Q(t-1)}$	۳	۸-۱۷-۱	۰/۹۳۸	۰/۸۷۳	۰/۰۳۴
۵	$\frac{Q(t)}{I(t)}$	۴	۱۰-۲۸-۱	۰/۹۹	۰/۵۵	۰/۰۵
۶	$\frac{Q(t)}{Q(t-1)}$	۴	۱۰-۱۵-۱	۰/۹۴۷	۰/۸۶۳	۰/۰۳۲

جدول ۷- نتایج و ساختار مدل WANN با موجک مادر db4 و مقیاس تجزیه ۴ در پیش‌بینی رواناب ماهانه

ورودی	هدف	گام	ساختار	E		RMSE (نرمال شده)
				آموزش	صحت‌سنجی	
Q(t) Q(t-1)	Q(t+1)	۱	۲-۱۵-۱	۰/۹۴۷	۰/۸۶۳	۰/۰۳۲
	Q(t+2)	۲	۲-۱۸-۱	۰/۹۰۰	۰/۷۸۶	۰/۰۴۰
	Q(t+3)	۳	۲-۲۰-۱	۰/۷۸۶	۰/۷۲۷	۰/۰۵۷
	Q(t+4)	۴	۲-۲۰-۱	۰/۸۲۰	۰/۴۷۰	۰/۰۵۲
	Q(t+5)	۵	۲-۲۵-۱	۰/۸۶۵	۰/۵۹۷	۰/۰۴۵
	Q(t+6)	۶	۲-۱۹-۱	۰/۸۵۰	۰/۴۸۳	۰/۰۴۹
	Q(t+7)	۷	۲-۱۲-۱	۰/۷۷۳	۰/۴۱۰	۰/۰۵۸
	Q(t+8)	۸	۲-۳۶-۱	۰/۷۸۷	۰/۲۷۱	۰/۰۵۶
	Q(t+9)	۹	۲-۹-۱	۰/۶۸۰	۰/۱۱۲	۰/۰۶۹
	Q(t+10)	۱۰	۲-۳-۱	۰/۳۳۶	۰/۱۶۱	۰/۱۰۰
	Q(t+11)	۱۱	۲-۸-۱	۰/۶۰۷	۰/۳۶۴	۰/۰۷۷
	Q(t+12)	۱۲	۲-۴-۱	۰/۴۲۲	۰/۴۵۳	۰/۰۹۳

جدول ۸- نتایج و ساختار مدل WANN با موجک مادر db4 و مقیاس تجزیه ۳ در پیش‌بینی دما ماهانه

ورودی	هدف	گام	ساختار	E		RMSE (نرمال شده)
				آموزش	صحت‌سنجی	
T(t) T(t-1)	T(t+1)	۱	۲-۱۴-۱	۰/۹۷۲	۰/۹۶۹	۰/۰۴۳
	T(t+2)	۲	۲-۱۱-۱	۰/۹۴۰	۰/۹۳۷	۰/۰۶۲
	T(t+3)	۳	۲-۲۹-۱	۰/۹۴۲	۰/۹۱۶	۰/۰۷۲
	T(t+4)	۴	۲-۱۲-۱	۰/۹۲۱	۰/۹۱۰	۰/۰۷۴
	T(t+5)	۵	۲-۲۵-۱	۰/۹۳۷	۰/۹۰۲	۰/۰۷۸
	T(t+6)	۶	۲-۱۰-۱	۰/۹۱۲	۰/۹۰۰	۰/۰۷۹
	T(t+7)	۷	۲-۱۰-۱	۰/۹۰۸	۰/۹۰۵	۰/۰۷۶
	T(t+8)	۸	۲-۱۱-۱	۰/۹۱۲	۰/۸۹۹	۰/۰۷۸
	T(t+9)	۹	۲-۱۵-۱	۰/۹۱۲	۰/۹۰۶	۰/۰۷۵
	T(t+10)	۱۰	۲-۱۸-۱	۰/۹۰۹	۰/۹۰۵	۰/۰۷۶
	T(t+11)	۱۱	۲-۱۰-۱	۰/۹۱۲	۰/۹۰۴	۰/۰۷۶
	T(t+12)	۱۲	۲-۱۳-۱	۰/۹۱۳	۰/۹۱۱	۰/۰۷۴

۳-۳- مقایسه مدل‌ها

به منظور ارزیابی کیفیت مدل‌سازی، نتایج مدل‌سازی‌های مختلف ناشی از مدل‌های ANN، WANN براساس معیار

Nash-Sutcliffe در مرحله صحت‌سنجی هرکدام از سری‌های زمانی مطالعاتی ماهانه (رواناب و دما) با یکدیگر مقایسه شده‌اند. به همین منظور برای سری زمانی رواناب و دمای ماهانه، بهترین

در جدول (۹) نتایج بهترین مدل مربوطه یعنی مدل WANN با موجک مادر db4 و مقیاس تجزیه ۴ در مرحله صحت‌سنجی با سایر مدل‌ها مقایسه شده است و درصد افزایش دقت آن نسبت به سایر مدل‌ها نشان داده شده است که نشان‌دهنده این است که تقریباً در همه گام‌های پیش‌بینی استفاده از تبدیل موجک و افزایش مقیاس تجزیه باعث افزایش چشمگیر دقت مدل‌سازی شده است. برای سری زمانی دما که دارای ویژگی خودهمبسته قوی و حالت فصلانه تک‌تناوبه قابل توجه می‌باشد، مدل ANN نیز نتایج مناسبی را شامل شد ولی استفاده از تبدیل موجک به‌عنوان پیش‌پردازش داده‌ها باعث بهبود نتایج در همه گام‌های پیش‌بینی نسبت به مدل ANN شد، ولی عملاً تغییر مقیاس تجزیه، تفاوت چندانی را ایجاد نکرده است زیرا به دلیل نوع سری زمانی ورودی و خاصیت فصلانه تک‌تناوبه سری زمانی دمای ماهانه مورد استفاده، افزایش زیاد مقیاس تجزیه فقط باعث افزایش ورودی مدل و در نتیجه خطای بیشتر در مدل‌سازی شده است. در جدول (۱۰) نتایج بهترین مدل مربوطه یعنی مدل WANN با موجک مادر db4 و مقیاس تجزیه ۳ در مرحله صحت‌سنجی با سایر مدل‌ها مقایسه شده است و درصد افزایش آن نسبت به سایر مدل‌ها نشان داده شده است که نشان‌دهنده این است که تقریباً در همه گام‌های پیش‌بینی استفاده از تبدیل موجک باعث افزایش چشمگیر دقت مدل‌سازی شده است ولی افزایش مقیاس تجزیه تغییر چندانی در دقت مدل‌سازی ایجاد نکرده است.

جدول ۱۰- مقایسه درصد تغییر دقت مدل در مرحله

صحت‌سنجی برای سری زمانی دمای ماهانه در همه گام‌های

پیش‌بینی

مدل‌های مورد مقایسه*			گام
WANN		ANN	
db4 level 4	db4 level 2		
۰	۰	۱۴	۱
۰	۰	۱۷	۲
۰	۰	۱۸	۳
-۱	۰	۱۱	۴
۰	۱	۴	۵
۰	۱	۴	۶
۱	۱	۱۱	۷
۱	۰	۱۸	۸
۱	۰	۱۸	۹
۲	۰	۸	۱۰
۱	۰	۱	۱۱
۰	۱	۴	۱۲

*علامت + نشان‌دهنده افزایش دقت مدل WANN با موجک مادر db4 و مقیاس تجزیه ۳ نسبت به مدل مورد مقایسه و علامت - نشان‌دهنده کاهش دقت مدل می‌باشد.

ساختارهای مدل ANN با مدل ترکیبی WANN با تبدیل موجک db4 و مقیاس‌های تجزیه ۴، ۳، ۲ مقایسه شده است (جدول (۹) و (۱۰)). پوشش گیاهی غالب حوضه آبریز Murrumbidgee درخت (۸۸ درصد) و چمن‌زار (۱۲ درصد) می‌باشد و منطقه اطراف رودخانه نیز دارای جمعیت بسیار کوچک با ۴ نفر در هر ۲km بوده و حوضه آن چنان تحت تأثیر تأثیرات انسانی قرار نمی‌گیرد. شرایط اقلیمی بسیار متنوع حوضه آبریز، سطح تراز متغیر منطقه (از ۲۲۰۰ متر تا کم‌تر از ۵۰ متر) و میانگین بارش سالانه متغیر (از ۱۷۰۰ میلی‌متر در نواحی مرتفع تا ۳۵۰ میلی‌متر در نواحی پست) باعث شده سری زمانی رواناب حوضه آبریز Murrumbidgee رفتار غیرخطی از خود نشان دهد و همبستگی ضعیفی با رواناب ماه‌های گذشته داشته باشد (شکل (۳)). در نتیجه با توجه به نوع سری زمانی رواناب مورد مطالعه که دارای ویژگی خودهمبسته ضعیف و حالت فصلانه چندتناوبه قابل توجه می‌باشد، مدل ANN نتایج ضعیفی را شامل شد ولی استفاده از تبدیل موجک به‌عنوان پیش‌پردازش داده‌ها باعث بهبود نتایج پیش‌بینی در همه گام‌های پیش‌بینی شد و همچنین با افزایش مقیاس زمانی تجزیه به دلیل افزایش زیر سری‌ها و کنترل بهتر حالت فصلانه نتایج مناسب‌تری برای همه گام‌های پیش‌بینی حاصل شد.

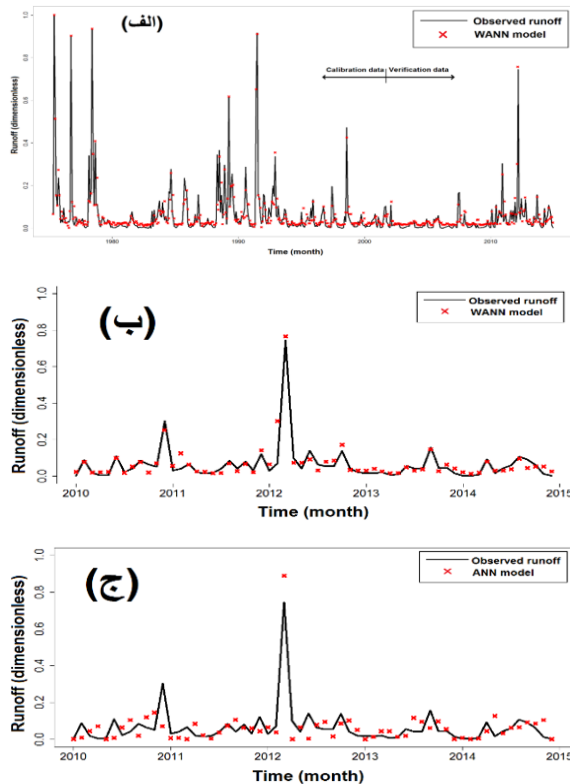
جدول ۹- مقایسه درصد تغییر دقت مدل در مرحله صحت-

سنجی برای سری زمانی رواناب نسبت به مدل WANN با

موجک مادر db4 و مقیاس تجزیه ۴

مدل‌های مورد مقایسه*			گام
WANN		ANN	
db4 level 3	db4 level 2		
-۱	۰	۶۹	۱
۱۸	۷۶	۵۶۱	۲
۱	۶۹	۵۲۷	۳
-۱۵	۸۵۸	۵۲۰	۴
۵۸	۵۵۹	۷۴۹	۵
۲۲۶	۴۸۳	۷۱۱	۶
۵۸۳	۳۹۵	۳۷۹	۷
۳۵۸	۴۳۹	۶۲۱	۸
۸۴۷	۲۳۵	۶۶۰	۹
۴۵۸	۲۹۶	۳۴	۱۰
۳۸۷	۵۷۳	۱۱۳	۱۱
۵۴۴	۴۳۸	۲۷۸	۱۲

*علامت + نشان‌دهنده افزایش دقت مدل WANN با موجک مادر db4 و مقیاس تجزیه ۴ نسبت به مدل مورد مقایسه و علامت - نشان‌دهنده کاهش دقت مدل می‌باشد.

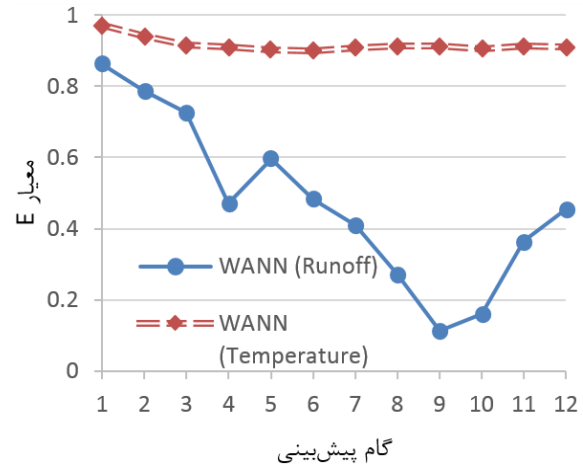


شکل ۶- سری زمانی مشاهداتی رواناب در مقایسه با سری های زمانی محاسباتی ANN و ANN (الف: کل سری زمانی، ب و ج) سری زمانی جزئیات از سال ۲۰۱۰ تا ۲۰۱۵

۴- نتیجه گیری

ویژگی های اصلی سری زمانی مطالعاتی از قبیل خودهمبستگی و حالت فصلانه، مهم ترین نقش را در انتخاب مدل برای شبیه سازی ایفا می کنند. مدل ANN مدلی خودهمبسته است و در مقابله با سری های زمانی که ویژگی خودهمبسته ضعیفی دارند، نتایج مناسبی را ارائه نمی دهد. ولی مدل WANN به دلیل پیش پردازش زمانی داده ها و خاصیت تبدیل موجک، که توانایی کنترل حالت فصلانه چند تناوبه را دارد (با تجزیه سری زمانی به زیر سری هایی که هر کدام بیانگر یک مقیاس فصلانه مخصوص می باشند)، در مقابله با سری های زمانی که ویژگی خودهمبسته ضعیف ولی خاصیت فصلانه (تک تناوبه یا چند تناوبه) قابل توجه دارند، نتایج مناسبی را ارائه می دهد لذا برای انتخاب مدل مناسب توجه به نوع فرآیند و خصوصیات آن و همچنین مقیاس زمانی مورد مطالعه ضروری می باشد.

ارزیابی نتایج مدل سازی نشان داد که برای سری زمانی رواناب به دلیل ویژگی خودهمبسته ضعیف و حالت فصلانه چندتناوبه قابل توجه، مدل ANN نتایج ضعیفی را ارائه داد ($E > 0.52$) ولی استفاده از تبدیل موجک با موجک مادر db4 و مقیاس تجزیه ۴ به عنوان پیش پردازش داده ها باعث بهبود نتایج در همه گام های



شکل ۵- مقایسه نتایج بهترین مدل های رواناب و دمای ماهانه در مرحله صحت سنجی

همان طور که در شکل (۵) مشاهده می شود به دلیل ویژگی خودهمبسته ضعیف و حالت فصلانه چندتناوبه، پیش بینی تا ۱۲ گام بعد رواناب نتایج مناسبی را شامل نشده است و عملاً پیش بینی بیشتر از ۳ تا ۴ گام نتایج ضعیفی را شامل شده است که البته با نزدیک شدن به تناوب ۱۲ ماهه، دوباره دقت مدل افزایش یافته است. اما به دلیل خاصیت خودهمبستگی بالا و تک تناوبه بودن سری زمانی دما، پیش بینی تا ۱۲ گام بعد، نتایج مناسبی را شامل شده است.

ارزیابی نتایج مدل سازی نشان داد که در هر ۱۲ گام بعد پیش بینی شده، مدل WANN عملکرد بهتری نسبت به مدل ANN در پیش بینی نقاط پیک داشته است، به طوری که در پیش بینی یک گام بعد سری زمانی رواناب توسط بهترین مدل WANN در مرحله صحت سنجی E_{peak} برابر 0.87 بود در حالی که برای مدل ANN معیار E_{peak} برابر 0.60 بود. در پیش بینی یک گام بعد سری زمانی دما توسط بهترین مدل WANN نیز در مرحله صحت سنجی E_{peak} برابر 0.95 بود در حالی که برای مدل ANN معیار E_{peak} برابر 0.78 بود. در شکل (۶) سری زمانی رواناب مشاهداتی (یک گام بعد) در مقایسه با سری های زمانی محاسباتی (بهترین مدل های WANN و ANN) رسم شده است. همان طور که از قسمت های شکل (۶-ب) و (۶-ج) مشخص است، مدل WANN عملکرد بهتری نسبت به مدل ANN داشته (مخصوصاً در پیش بینی نقاط پیک) چراکه علاوه بر جزء خودهمبسته، توانایی کنترل جزء فصلانه سری زمانی را دارد.

مقیاس تحت اثر تغییر اقلیم"، نشریه مهندسی عمران و محیط زیست دانشگاه تبریز، ۱۳۹۸، ۹۴، ۵۹-۴۷.

نورانی و، رنجبر س، توتونچی ف، "بررسی تغییرات فرآیندهای هیدرولوژیکی با استفاده از معیاره موجک- آنتروپی مطالعه موردی: دریاچه ارومیه"، نشریه مهندسی عمران و محیط زیست دانشگاه تبریز، ۱۳۹۴، ۸۰، ۸۶-۷۵.

Abrahart RJ, Anctil F, Coulibaly P, Dawson Ch, Mount NJ, See L, Shamseldin A, Solomatine D, Toth E, Wilby LR, "Two decades of anarchy? Emerging themes and outstanding challenges for neural network river forecasting", *Progress in Physical Geography*, 2012, 36, 480-513.

Addison PS, "The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance", CRC Press, 2002.

Antar MA, Ellassiouti I, Alam MN, "Rainfall-runoff modeling using artificial neural networks technique: a Blue Nile catchment case study", *Hydrological Processes*, 2006, 20, 1201-1216.

Chang FJ, Tsai MJ, "A nonlinear spatio-temporal lumping of radar rainfall for modeling multi-step-ahead inflow forecasts by data-driven techniques", *Journal of Hydrology*, 2016, 535, 256-269.

Dinu C, Drobot R, Pricop C, Blidaru TV, "Flash-flood modelling with artificial neural networks using radar rainfall estimates", *Mathematical Modelling in Civil Engineering*, 2017, 13, 10-20.

Grossmann A, Morlet J, "Decomposition of hardy function into square integrable wavelets of constant shape", *Journal on Mathematical Analysis*, 1984, 154, 723-736

Khanghah TR, Nourani V, Parhizkar M, Sharghi E, "Application of information content to extract wavelet-based feature of rainfall-runoff process", In *Proceedings of the 12th WSEAS International Conference on Applied Computer Science*, WSEAS, Greece, 2012, 148-153.

Kim T, Valdes JB, "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks", *Journal of Hydrologic Engineering*, 2003, 8, 319-328.

Nourani V, Hosseini Baghanam A, Adamowski J, Kisi O, "Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review", *Journal of Hydrology*, 2014, 514, 358-377.

Nourani V, Kisi Ö, Komasi M, "Two hybrid Artificial Intelligence approaches for modelling rainfall-runoff process", *Journal of Hydrology*, 2011, 402, 41-59.

Sharghi E, Nourani V, Najafi H, Molajou A, "Emotional ANN (EANN) and wavelet-ANN (WANN) approaches for Markovian and seasonal based modeling of rainfall-runoff process", *Water Resources Management*, 2018, 32, 3441-56.

Tankersley C, Graham W, Hatfield K, "Comparison of univariate and transfer function models of groundwater fluctuations", *Water Resources Research*, 1993, 29, 3517-3533.

Xie JX, Cheng CT, Chau KW, Pei YZ, "A hybrid adaptive time-delay neural network model for multi-step-

پیش‌بینی نسبت به مدل ANN شد (تا ۰/۷۴۹) و همچنین با افزایش مقیاس زمانی تجزیه (از مقیاس تجزیه ۲ به ۴) به دلیل افزایش زیر سری‌ها و کنترل بهتر حالت فصلانه نتایج مناسب‌تری برای همه گام‌های پیش‌بینی حاصل شد. اما برای سری زمانی دما به دلیل ویژگی خودهمبسته قوی و حالت فصلانه تک‌تناوبه، مدل ANN نیز نتایج نسبتاً مناسبی را ارائه داد ($E < 0/72$) ولی استفاده از تبدیل موجک با موجک مادر db4 و مقیاس تجزیه ۳ به‌عنوان پیش‌پردازش داده‌ها باعث بهبود نتایج در همه گام‌های پیش‌بینی نسبت به مدل ANN شد (تا ۰/۱۸) ولی عملاً تغییر مقیاس تجزیه، تفاوت چندانی را ایجاد نکرد، زیرا به دلیل نوع سری زمانی ورودی و خاصیت فصلانه تک‌تناوبه سری زمانی دمای ماهانه مورد مطالعه، افزایش زیاد مقیاس تجزیه فقط باعث افزایش ورودی مدل و در نتیجه خطای بیشتر در مدل‌سازی شده است.

با توجه به این‌که هدف این مقاله بررسی پیش‌بینی تا ۱۲ گام بعد سری زمانی ماهانه رواناب و دما بود، انتخاب ترکیب ورودی که بتواند برای همه گام‌های پیش‌بینی نتایج مناسبی را ارائه دهد، اهمیت ویژه‌ای داشت. لذا استفاده از تبدیل موجک به دلیل تجزیه سری زمانی به چند زیر سری و بررسی هم‌زمان اطلاعات طیفی و زمانی سری زمانی، باعث شد برای هر دو سری زمانی رواناب و دما، فقط سری دو زمان قبل به‌عنوان ورودی مورد استفاده قرار گیرد و نتایج مطلوبی حاصل گردد.

از نظر پیش‌بینی چندگام بعد، بررسی نوع فرآیند مورد مطالعه و خصوصیات آن (مانند میزان خودهمبستگی و تناوب‌های فصلانه) ضروری می‌باشد، چراکه با توجه به نتایج این مقاله در مواجهه با سری‌های زمانی که دارای ویژگی خودهمبستگی ضعیفی هستند (مانند سری زمانی رواناب ماهانه مورد مطالعه در این مقاله) عملاً پیش‌بینی گام‌های زیاد نتایج مناسبی را ارائه نمی‌دهد (به دلیل ماهیت مدل‌های استفاده‌شده) و حداکثر باید ۳ تا ۴ گام را مورد پیش‌بینی قرارداد ولی در مورد سری‌های زمانی با ویژگی خودهمبسته قوی و فصلانه تک‌تناوبه مشخص (مانند سری زمانی دمای ماهانه مورد مطالعه در این مقاله) می‌توان گام‌های متعددی را مورد پیش‌بینی قرار داد.

با توجه به وجود مدل‌های متنوع و جدید دیگر، در راستای افزایش دقت مدل‌سازی، می‌توان توانایی مدل‌های دیگری چون ANFIS و SVM در ترکیب با تبدیل موجک را در کنترل اجزاء اصلی سری زمانی و پیش‌بینی چندگام بعد مورد بررسی قرار داد. همچنین توصیه می‌شود برای ارزیابی بیشتر توانایی مدل WANN در مدل‌سازی چندگامه از معیارهای ارزیابی متنوعی استفاده شود.

۵- مراجع

حسن‌زاده ی، آقاخانی افشار ا ح، "استفاده از مدل-ESM MIROC در بررسی شرایط هیدرو- اقلیمی حوضه آبخیز کوچک

ahead prediction of sunspot activity”, International Journal of Environment and Pollution, 2006, 28, 364-381.

Yang JS, Yu SP, Liu GM, “Multi-step-ahead predictor design for effective long-term forecast of hydrological signals using a novel wavelet neural network hybrid model”, Hydrology and Earth System Sciences, 2013, 17, 4981-4993.

EXTENDED ABSTRACT

Multistep Modeling of Hydroclimatic Phenomena Using Wavelet-Neural Network Seasonal Model

Hessam Najafi^{a,b}, Vahid Nourani^{a,*}, Elnaz Sharghi^a, Alireza Babaeian Amini^b

^a Faculty of Civil Engineering, University of Tabriz, Tabriz 5166616471, Iran

^b Faculty of Civil Engineering, University of Bonab, Bonab 5157938531, Iran

Received: 09 November 2016; **Accepted:** 20 December 2020

Keywords:

Seasonal multistep modeling, ANN, WANN, Murrumbidgee catchment runoff, Tabriz minimum temperature.

1. Introduction

In the present paper, the ability of the Artificial Neural Network (ANN) and combined wavelet-neural network (WANN) model were investigated for multistep modeling of hydroclimatic processes with the least input. For this purpose, the ANN model and then the WANN model were used to predict one to twelve steps in advance. Finally, the efficiencies of all models were examined using the evaluation criteria, and all models were compared with each other.

2. Methodology

2.1. WANN model

WANN combined model was designed for combining the capabilities of the ANN model and wavelet transform in a single structure for rainfall-runoff and temperature modeling. In this model, the data preprocessing is carried out by the wavelet transform and the results of this processing are used as inputs in ANN. In this type of modeling, discrete wavelet transform provides opportunities for different time scales that are assessed and evaluated separately. In that case, the input time series in different time scales are decomposed by discrete wavelet transform, and then its various combinations are used as inputs in the ANN model (Grossmann and Morlet, 1984; Addison, 2002; Nourani et al, 2011; Nourani et al, 2014).

2.2. Case study

The monthly rainfall-runoff data in this paper are from the Murrumbidgee catchment for 39 years (1975-2014), located in Australia. Also, the 39 years (1975-2014) data of Tabriz temperature were used for monthly minimum temperature modeling.

2.3. Efficiency criteria

Validation of predictive models is done for assessing the performance of the predictions. For this purpose Nash-Sutcliffe (E) and Root Mean Square Error (RMSE) criterion have been used.

* Corresponding Author

E-mail addresses: hessamnajafi71@gmail.com (Hessam Najafi), vnourani@yahoo.com (Vahid Nourani), elnaz_sharghi@yahoo.com (Elnaz Sharghi), a_babaeian@ubonab.ac.ir (Alireza Babaeian Amini).

3. Results and discussion

For multistep modeling, at first, the ANN model was used without any data preprocessing, and then the WANN model with the capability of considering the seasonal and periodic properties of time series was used. The input combinations of ANN and WANN as multivariate models were selected by linear correlation (CC) and mutual information (MI). To this end, the linear and nonlinear properties of inputs were examined by MI and CC criteria, and then the best input combinations were selected by trial and error (Sharghi et al, 2018; Khanghah et al, 2012).

3.1. Comparison of models

To assess the performance of the used models, for each studied monthly time series (runoff and temperature), the results of ANN and WANN models were compared with each other according to the Nash-Sutcliffe efficiency in the validation phase. Therefore in Figs. 1 and 2 the best structure of each model were compared.




Fig. 1. Comparison of different monthly runoff modeling results in the validation phase

As can be seen in Fig. 1, using wavelet transform caused a considerable increase in the accuracy of models in all steps of monthly runoff modeling. Also by increasing the wavelet transform decomposition level, accuracy increased in all time steps. But because of the weak autoregressive component of the monthly runoff time series, by increasing the time step, the accuracy of models decreased and the prediction of more than three steps included weak results.

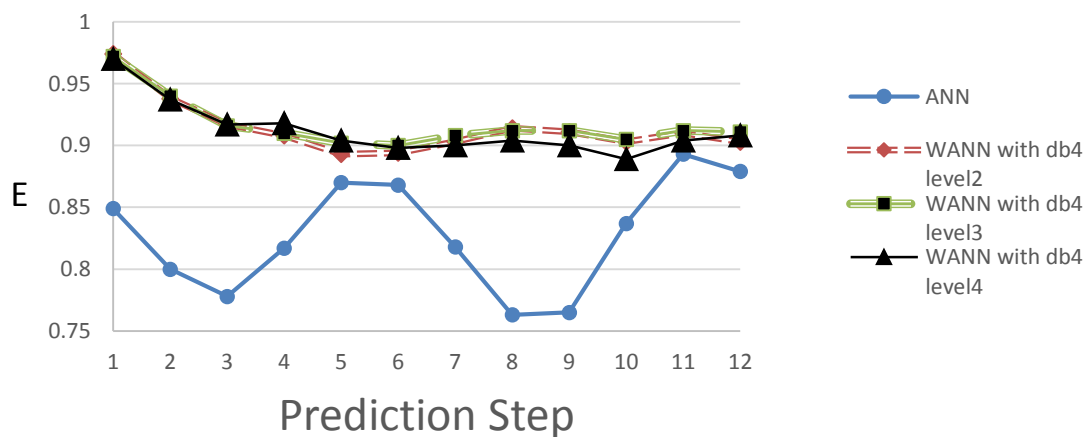


Fig. 2. Comparison of different monthly temperature modeling results in the validation phase

As can be seen in Fig. 2, using wavelet transform caused a considerable increase in accuracy of all time steps of monthly temperature modeling and because of the strong autoregressive component of monthly temperature time series, all 12 steps in advance included good results. But with increasing the wavelet transform decomposition level, the accuracy of models has not considerably increased because of the strong autoregressive and single frequency properties of monthly temperature time series, decomposition level increasing does not give new useful information to the model.

4. Conclusions

Hydroclimatic time series components such as autoregressive, seasonality and stochastic, play the most important role in the selection of models. ANN is an autoregressive model and in dealing with time series that have weak autoregressive properties did not include proper results. But WANN model because of time series preprocessing and its ability to handle seasonal multi-frequency mode, included good results. Therefore for the selection of appropriate models, it is necessary to pay attention to the type of time series components and time scales of time series.

In terms of multistep modeling, it is necessary to pay attention to the type, components and time scales of time series. Because the results of this paper indicated that in dealing with time series which have a weak autoregressive component, by increasing time steps, the accuracy of results was decreased. In order to complete the current study, it is recommended to use the presented methodology with replacement ANFIS and SVM models instead of ANN.

5. References

- Addison PS, "The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance", CRC Press, 2002.
- Grossmann A, Morlet J, "Decomposition of hardy function into square integrable wavelets of constant shape", *Journal on Mathematical Analysis*, 1984, 154, 723-736.
- Khanghah TR, Nourani V, Parhizkar M, Sharghi E, "Application of information content to extract wavelet-based feature of rainfall- runoff process", In *Proceedings of the 12th WSEAS International Conference on Applied Computer Science*, WSEAS, Greece, 2012, 148-153.
- Nourani V, Hosseini Baghanam A, Adamowski J, Kisi O, "Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review", *Journal of Hydrology*, 2014, 514, 358-377.
- Nourani V, Kisi Ö, Komasi M, "Two hybrid Artificial Intelligence approaches for modelling rainfall-runoff process", *Journal of Hydrology*, 2011, 402, 41-59.
- Sharghi E, Nourani V, Najafi H, Molajou A, "Emotional ANN (EANN) and wavelet-ANN (WANN) approaches for Markovian and seasonal based modeling of rainfall-runoff process", *Water Resources Management*, 2018, 32, 3441-56.