

آزمون حافظه سیگنال سری زمانی و شبیه‌سازی فرایند بارش-رواناب با استفاده از مدل‌های شبکه عصبی و ترکیب موجک-عصبی

سعید فرزین^{۱*}، حمید میرهاشمی^۲، حامد عباسی^۳، زهره مریانجی^۴ و پیام خسروی‌نیا^۵

^۱ استادیار، دانشکده مهندسی عمران، دانشگاه سمنان، ^۲ استادیار، گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه لرستان، ^۴ استادیار آب و هواشناسی، دانشکده علوم انسانی و اسلامی، دانشگاه سید جمال الدین اسدآبادی، ^۵ استادیار، دانشکده کشاورزی، دانشگاه کردستان

تاریخ پذیرش: ۱۳۹۷/۰۵/۰۶

تاریخ دریافت: ۱۳۹۶/۰۹/۱۶

چکیده

در پژوهش حاضر، حافظه بلندمدت و رفتار دینامیکی سیگنال سری زمانی جریان روزانه رودخانه خرم‌آباد که حوزه آبخیز آن کوهستانی و دارای کاربری شهری است، با استفاده از نمایه هرست بررسی شده است. مقدار نمایه هرست سیگنال رواناب رودخانه خرم‌آباد در بازه زمانی سال‌های ۱۳۷۰ تا ۱۳۹۳ برابر با ۰/۸ به‌دست آمد. این مقدار نشان از حافظه بلندمدت و دینامیک غیر خطی سیگنال رواناب این رودخانه دارد. در ادامه، با به‌کارگیری مدل‌های شبکه عصبی و تبدیلات موجک، سری زمانی بارش-رواناب این رودخانه شبیه‌سازی شده است. در این راستا، با اتخاذ سری‌های زمانی بارش و بارش-رواناب به‌عنوان ورودی در دو الگوریتم شبکه عصبی و ترکیب موجک-عصبی، چهار مدل شامل (۱) بارش، عصبی، (۲) بارش-رواناب، عصبی، (۳) بارش، موجک-عصبی و (۴) بارش-رواناب، موجک-عصبی تولید شده است. در مدل‌های ترکیبی موجک-عصبی، سری زمانی بارش و رواناب به زیرسیگنال‌های فرکانس بالا و پایین تجزیه شده‌اند. نتایج حاصل از ارزیابی میزان دقت و کارایی چهار مدل حاکی از آن است که مدل بارش-رواناب، موجک-عصبی با بهترین کارایی در سطح اطمینان ۹۹ درصد، دقت بالایی در شبیه‌سازی رفتار رواناب دارد. به‌طوری که مقایسه نتایج مدل موجک-عصبی با مدل عصبی با استفاده از آزمون مرگان-گرنجر-نیوبلد، نشان از برتری معنی‌دار مدل نخست دارد. همچنین، نتایج ارزیابی سیگنال خطای چهار مدل اجرا شده با استفاده از دو آزمون نسبت وان‌نیومن و بویشاند نشان داد که یک نقطه جابه‌جایی معنی‌دار در سیگنال خطای مدل عصبی و سیگنال بارش-رواناب وجود دارد. بنابراین، وجود نوسان‌های بسیار متفاوت ماهانه و دوره‌ای شامل دو دوره ۱۳۷۷-۱۳۷۰ و ۱۳۹۳-۱۳۷۸ در رفتار بارش-رواناب منجر به کاهش کارایی و ضریب دقت مدل شبکه عصبی شده است. در صورتی که در مدل ترکیبی موجک-عصبی با اختصاص وزن نسبی به هر زیرسیگنال، تأثیر نوسان‌های کوتاه مدت، متوسط و بلند مدت در ایجاد خطای مدل‌سازی به‌نحو مؤثری کاهش یافته است.

واژه‌های کلیدی: آزمون وان‌نیومن، حافظه بلند مدت، حوضه خرم‌آباد، شبکه عصبی مصنوعی، نمایه هرست

مقدمه

به‌منظور طراحی و برنامه‌ریزی منابع آب ضرورت دارد (Kisi, 2008). چنین پیش‌بینی‌هایی از جریان رودخانه با فراهم کردن هشدارهای لازم در مورد رخداد سیل و

الگوی رواناب یا جریان رودخانه‌ای از یک دینامیک پیچیده غیر خطی پیروی می‌کند که پیش‌بینی آن

چندی صورت گرفته است. Cannas و همکاران (۲۰۰۶)، با تجزیه سیگنال سری زمانی رواناب حوضه تیرسو (واقع در ساردینا، ایتالیا) با استفاده از تبدیلات موجک و پیش‌پردازش این سیگنال برای ورود به مدل‌سازی شبکه عصبی مصنوعی، نتیجه گرفتند که تجزیه با استفاده از موجک گسسته، رفتار هیدرولوژیکی جریان رودخانه را دقیق‌تر پیش‌بینی می‌کند. Panda و Pramanik (۲۰۰۹)، با اتخاذ پنج الگو با زمان‌های تاخیر متفاوت از رودخانه ماهندی در هندوستان به‌عنوان ورودی روش‌های شبکه عصبی و نروفازی دریافتند که رواناب شبیه‌سازی شده به‌وسیله مدل نروفازی دارای تطابق بهتری با رواناب مشاهداتی نسبت به شبکه عصبی است. Wu و Chau (۲۰۱۰)، با مدل‌سازی جریان ماهانه چندین رودخانه در کشور چین نشان دادند که روش K-نزدیک‌ترین همسایه در پیش‌بینی جریان رودخانه از کارایی مناسب‌تری نسبت به روش آریمای و شبکه عصبی برخوردار است. Adamowski و Prasher (۲۰۱۲)، با در نظرگیری ماهیت پیچیده و داده‌های محدود جریان رودخانه‌های حوضه‌های کوهستانی به مقایسه میزان کارایی دو روش رگرسیون ماشین بردار پشتیبان و ترکیب شبکه عصبی مصنوعی-آنالیز موجک در پیش‌بینی جریان حوضه کوهستانی سیانجی در منطقه هیمالیا هندوستان پرداختند. نتایج نشان داد که هر دو مدل قادرند رواناب روزانه حوضه کوهستانی را به‌طور دقیقی پیش‌بینی کنند. Sudhishri و همکاران (۲۰۱۶)، با اتخاذ سه مدل به‌نام مدل دینامیک غیر خطی، شبکه عصبی مصنوعی و مدل ترکیبی موجک-شبکه عصبی مصنوعی به ایجاد مدل پیش‌بینی رواناب و تولید رسوب با استفاده از داده‌های روزانه بارش، رواناب و مقدار رسوب در حوضه بینو در هندوستان پرداختند. نتایج این مطالعه نشان داد که با اتخاذ دو ورودی بارش-رواناب، مدل‌های شبکه عصبی و موجک شبکه عصبی در مقایسه با مدل دینامیک غیر خطی ساده دقیق‌تر هستند.

Shafaei و همکاران (۲۰۱۳)، مدل پیش‌بینی موجک-شبکه عصبی را برای سری زمانی جریان روزانه ایستگاه ونیار رودخانه آجی‌چای بنا نهادند. ایشان بیان داشتند که تابع موج مادر میر دارای قابلیت بهتری در تجزیه سیگنال سری زمانی بوده است. همچنین، مدل

کمک به تنظیم جریان خروجی منابع آب در هنگام پایین بودن تراز جریان رودخانه، به مدیریت منابع آب کمک می‌کند (Akhtar و همکاران، ۲۰۰۹؛ Besaw و همکاران، ۲۰۱۰). با توجه به اهمیت پیش‌بینی جریان آب رودخانه از نقطه نظرهای مختلف، یافتن روشی مناسب در این خصوص حائز اهمیت است (Montaseri و Zamanzad Ghavidel، ۲۰۱۴). از دیرباز، مدل‌های اتورگرسیون، آرما و آریمای به‌طور گسترده‌ای به‌منظور مدل‌سازی سری‌های زمانی هیدرولوژیکی با پیروی از پیش‌فرض خطی به‌کار گرفته شده‌اند (Zounemat- Kermani و Teshnelab، ۲۰۰۸). این مدل‌ها برای تحلیل فرایندهای غیر خطی دقت پایینی دارند. در سال‌های اخیر مدل‌های شبکه‌های عصبی مصنوعی به‌طور موفقیت آمیزی برای مدل‌سازی فرایندهای پیچیده هیدرولوژیکی مانند مدل بارش-رواناب استفاده شده‌اند (Karunanithi و همکاران، ۱۹۹۴؛ Kumar و همکاران، ۲۰۱۶؛ Machado و همکاران، ۲۰۱۱؛ Wang و Ding، ۲۰۰۳). علت استقبال از مدل‌های شبکه عصبی را می‌توان قدرت شبیه‌سازی و پیش‌بینی مدل در فرایندهای پیچیده که تعریف دقیق و درک خاصی از آن‌ها وجود ندارد و حساسیت کمتر آن نسبت به وجود خطا در ورودی‌ها دانست (Hassanzadeh و همکاران، ۲۰۱۴).

با این حال، مشخص شده که این روش‌های هوش مصنوعی و سایر روش‌های خطی و غیر خطی در برخورد با سری‌های زمانی ناپایست^۱ ضعیف عمل می‌کنند (Adamowski، ۲۰۰۸؛ Cannas و همکاران، ۲۰۰۶) و چنان‌که پیش‌پردازش‌هایی بر داده‌های ورودی اعمال نشود، مدل حاوی خطاهای قابل توجهی خواهد بود. در این راستا، تحلیل موجک روشی مناسب برای پیش‌پردازش داده‌های ورودی شبکه عصبی محسوب می‌شود (Kisi، ۲۰۰۸؛ Nourani و همکاران، ۲۰۰۹). بدین ترتیب که موجک‌ها با تجزیه سیگنال در محدوده‌های زمان و فرکانس، به‌عنوان رویکردی بهینه برای تجزیه و تحلیل سری‌های زمانی ناپایستا به شمار می‌روند (Lotfollahi Yaghin، ۲۰۱۰).

با توجه به اهمیت موضوع، تا کنون پژوهش‌های

¹ Non-stationary

دینامیکی سیگنال رواناب با استفاده از نمایه هرست^۱ و سپس مدل‌سازی بارش-رواناب با اتکای بر روش‌های شبکه عصبی مصنوعی و ترکیب موجک شبکه عصبی است. به این ترتیب که با در نظرگیری سیگنال‌های ورودی متفاوت، چندین مدل بارش-رواناب با استفاده از روش‌های یاد شده ارائه می‌شود تا با ارزیابی خروجی این مدل‌ها بتوان به دیدگاه مناسبی در مورد چگونگی رفتار زمانی بارش و رواناب دست پیدا کرد. سرانجام، هدف نهایی این مطالعه مبتنی بر ارائه مدلی است که به‌طور معنی‌داری شبیه‌سازی‌های دقیق‌تری نسبت به سایر مدل‌های مورد استفاده ارائه دهد و فاقد سوگیری قابل اعتنایی باشد.

مواد و روش‌ها

منطقه مورد پژوهش: حوزه آبخیز خرم‌آباد با مساحت ۱۶۴۰ کیلومتر مربع با موقعیت جغرافیایی $33^{\circ} 26' 76''$ عرض شمالی و $48^{\circ} 14' 77''$ طول شرقی در استان لرستان واقع شده است. این حوضه حدود ۱۶ درصد وسعت حوضه کشکان را در بر گرفته و دارای شیب متوسط ۲۴/۳۶ درصد بوده که نسبت به شیب متوسط کشکان کمتر است. بیشینه و کمینه ارتفاع این حوضه به ترتیب ۲۸۷۶ متر و ۱۱۱۳ متر است (به نقل از Haghizadeh و همکاران، ۲۰۱۵). رودخانه خرم‌آباد با طول آبراهه اصلی حدود ۴۴/۵ کیلومتر از تلاقی شاخه‌های رباط، کرگانه، کاکاشرف، چشمه‌های کیو، گلستان مطهری، دارابی، گرداب سنگی و چنگایی تشکیل می‌شود (Khorshiddoust و همکاران، ۲۰۱۵). این رودخانه پس از عبور از شهر خرم‌آباد و دشت جنوبی آن، در نهایت به رودخانه کشکان می‌ریزد.

در این پژوهش، به‌عنوان مطالعه موردی، مدل بارش-رواناب رودخانه خرم‌آباد به‌عنوان یکی از مهمترین زیرحوضه‌های رودخانه کشکان در نظر گرفته شده است. بدین منظور، از داده‌های بارش ایستگاه خرم‌آباد و رواناب ایستگاه دبی‌سنجی چمنجیر (واقع در پایاب رودخانه) در بازه زمانی سال‌های ۱۳۷۰ تا ۱۳۹۳ در مقیاس روزانه استفاده شد. پایگاه این داده‌ها، سازمان هواشناسی و سازمان آب منطقه‌ای خرم‌آباد می‌باشد. با توجه به

ترکیبی موجک-عصبی نسبت به مدل شبکه عصبی از دقت بالاتری برخوردار است. Abdollahi و همکاران (۲۰۱۴)، به‌منظور ارائه مدل پیش‌بینی رواناب روزانه رودخانه حوزه آبخیز بهشت‌آباد، از سه روش موجک متقاطع، شبکه عصبی مصنوعی و موجک-شبکه عصبی استفاده کردند. مقایسه نتایج حاکی از دقت مدل ترکیبی موجک-عصبی در قیاس با دو مدل دیگر بود. Zamanzad Ghavidel و Montaseri (۲۰۱۴)، با بررسی جریان رودخانه خرخره‌چای حوزه آبخیز زرینه‌رود، مدل‌های خروجی حاصل از اجرای دو روش هوشمند فازی-شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن را مورد ارزیابی قرار دادند. مقایسه نتایج حاکی از دقت بیشتر مدل برنامه‌ریزی بیان ژن در مقایسه با مدل فازی-عصبی بود.

Yarahmadi و Mirhashemi (۲۰۱۸)، از شبکه عصبی مصنوعی (ANN)، K- نزدیک‌ترین همسایه (K-NN) و ترکیب تحلیل موجک، برای پیش‌بینی سری زمانی جریان رودخانه کشکان استفاده کردند. نتایج این مطالعه نشان داد که مدل K-NN با خطای ۴/۶ درصد، از عملکرد مناسب‌تری نسبت به مدل ANN برخوردار بوده است. در صورتی که با ترکیب تحلیل موجک، عملکرد ANN در شبیه‌سازی سیگنال جریان رودخانه نسبت به K-NN بهتر شده است.

شایان توجه است که وجود حافظه بلندمدت در هر سری زمانی، به‌عنوان پیش‌شرط برای انجام فرایند پیش‌بینی محسوب می‌شود. زیرا یک سری زمانی در صورتی از قابلیت پیش‌بینی برخوردار است که دارای حافظه بلندمدت باشد. از سوی دیگر، در مقایسه بین نتایج چند مدل ضرورت دارد که از آزمون‌های معتبر آماری برای ارزیابی معنی‌داری اختلاف نتایج مدل‌های متفاوت استفاده شود. چرا که معیارهایی نظیر ریشه میانگین مربعات خطا و ضریب همبستگی از قابلیت سنجش معنی‌داری تفاوت بین نتایج دو روش آماری متفاوت برخوردار نیستند. در صورتی که این شاخص‌ها صرفاً برای ارزیابی نتایج خروجی از یک مدل مناسب هستند. این نیز موضوعی است که در اهم تحقیقات صورت گرفته مغفول واقع شده است. بنابراین، هدف از مطالعه حاضر، در ابتدا، ارزیابی حافظه و ماهیت

¹ Hurst exponent

در مرحله بعد سری زمانی تجمعی رواناب محاسبه می‌شود (رابطه ۳).

$$Y_i = \sum_{k=1}^i Z_k \quad j=1,2,\dots,n \quad (3)$$

نظر به این‌که میانگین Z صفر است، آخرین مقدار Y یعنی Y_n همواره صفر خواهد بود. بنابراین، دامنه تعدیل‌شده برابر خواهد بود با:

$$R_n = \max(Y_1, \dots, Y_n) - \min(Y_1, \dots, Y_n) \quad (4)$$

از آنجایی که میانگین Y صفر است، بیشینه آن همواره بزرگ‌تر یا مساوی صفر و کمینه آن کوچک‌تر یا مساوی صفر خواهد بود. بنابراین، دامنه تعدیل‌شده همیشه غیر منفی است. هرست با استفاده از قاعده نصف در آمار رابطه (۵) را تعریف کرد.

$$\log\left(\frac{R}{S}\right) = \log a + H \log(n) \quad (5)$$

که در آن، R دامنه تغییرات، S انحراف معیار سری زمانی، a عدد ثابت، n تعداد مشاهده‌ها و H نمای هرست است. با رسم ترم سمت چپ رابطه (۵) در مقابل $\log(n)$ ، نمای هرست برآورد شد. برحسب یافته‌های هرست، اگر مقدار نمای هرست برابر با 0.5 شود، بر یک فرایند مستقل نرمال دلالت دارد. اگر بین 0.5 و یک قرار گیرد، بر یک سری زمانی دوام‌دار با حافظه بلندمدت دلالت دارد که این به‌نوبه خود نشان‌دهنده ساختار غیر خطی سری زمانی نیز است. در نهایت، اگر نمای هرست مثبت و کمتر از 0.5 شود، نشان از بی‌دوام بودن سری زمانی دارد.

مدل‌سازی بارش-رواناب با شبکه عصبی مصنوعی چندلایه: با استفاده از شبکه عصبی مصنوعی، پدیده‌هایی مدل می‌شوند که اطلاعات چندانی در مورد آن‌ها در دسترس نیست (Lee و همکاران، ۲۰۰۶؛ Mark و همکاران، ۲۰۱۶).

پس از تنظیم یا همان آموزش شبکه عصبی، اعمال یک ورودی خاص به آن منجر به دریافت پاسخ خاص می‌شود، شبکه بر مبنای تطابق و هم‌سنجی بین ورودی و هدف سازگار می‌شود تا اینکه خروجی شبکه و هدف بر هم منطبق شوند. عموماً تعداد زیادی از این زوج‌های ورودی و خروجی به‌کار گرفته می‌شوند تا در این روند که از آن تحت عنوان یادگیری نظارت‌شده یاد می‌شود، شبکه آموزش داده شود (Kia، ۲۰۱۰). لازم به ذکر

این‌که سری زمانی بارش و رواناب هم‌معیار نیستند و همچنین، جهت بهبود آهنگ یادگیری تابع فعال‌سازی آموزش در شبکه عصبی، نخست با استفاده از تابع لجستیک (رابطه ۱)، سری زمانی بارش و رواناب هم‌معیار و در بازه عملکرد تابع فعال‌سازی سیگموئید قرار گرفتند.

$$x_i = \frac{1}{1 + \exp\left(-\left(\frac{x_i - \bar{x}}{\sigma}\right)\right)} \quad (1)$$

که در آن، x_i مقدار نرمال شده متغیر x_i ، \bar{x} مقدار هر متغیر، σ به‌ترتیب میانگین و واریانس سری زمانی هستند. سپس، با استناد به این‌که دبی در زمان $t+1$ به بارش و دبی در زمان‌های t ، $t-1$ ، $t-2$ و $t-3$ وابسته است، سری‌های زمانی بارش-رواناب با تأخیرهای زمانی یک، دو و سه روز به‌عنوان ورودی و دبی با تأخیر زمانی سه روز بعد، به‌عنوان خروجی مدل‌ها در نظر گرفته شدند.

بررسی حافظه بلندمدت سری زمانی با استفاده از نمایه هرست: یک سری زمانی در صورتی از قابلیت پیش‌بینی برخوردار است که دارای حافظه بلندمدت باشد. این تفکر مبتنی بر آن است که آیا در سری زمانی در دسترس، تمامی پدیده‌های حدی قابل‌انتظار رخ داده‌اند یا نه (Karamouz و همکاران، ۲۰۱۳). در سری‌های زمانی هیدرولوژیکی مثل رواناب، حافظه بلندمدت موجب وابستگی مقدار رواناب با مقادیر قبلی در گذشته شده که این نشان‌دهنده وجود پارامتری قابل پیش‌بینی در سری زمانی است.

Hurst (۱۹۵۱)، با مطالعه تراز آبی رودخانه نیل، آزمونی را برای بررسی حافظه بلندمدت ارائه داد که اینک به‌عنوان نمایه هرست نامیده می‌شود. این آزمون در مطالعه حاضر به‌عنوان ابزاری جهت بررسی حافظه بلندمدت سری زمانی رواناب رودخانه خرم‌آباد مورد استفاده قرار گرفته است و مراحل آن به شرح ذیل است. با اتخاذ یک سری زمانی رواناب با $x = x_1, x_2, \dots, x_n$ ابتدا مقیاس داده‌ها با استفاده از رابطه (۲) نرمال می‌شود.

$$z_k = (x_k - x_m) \quad (2)$$

که در آن، x_k مقدار رواناب روزانه، x_m میانگین سری زمانی رواناب و z_k مقدار رواناب نرمال شده است.

رابطه (۷) به دست می‌آیند.

$$DWT_s^{\nu}(t) \sum s(t) \psi_{k,j}(t) dt \quad (7)$$

در تبدیل موجک گسسته، سیگنال از یک سری فیلترهای پایین‌گذر و بالاگذر عبور داده می‌شود که بخش به دست آمده از فیلتر بالاگذر حاوی اطلاعات فرکانس بالا است که جزئیات نامیده می‌شود. از سویی، بخش حاصل از فیلتر پایین‌گذر حاوی اطلاعات فرکانس پایین و دربردارنده ویژگی‌های اصلی سیگنال است که کلیات نامیده می‌شود. در ادامه، به سبب شباهت موجک مادر میر (موجک پیچیده) به سیگنال سری زمانی بارش-رواناب، تجزیه این سیگنال‌ها با استفاده از تابع موجک میر انجام گرفت. بر حسب رابطه ارائه شده توسط Ding و Wang (۲۰۰۳) (رابطه ۸) تعداد سطح تجزیه مناسب به مقدار چهار سطح به دست آمد. بنابراین، سیگنال بارش و رواناب هرکدام به پنج زیرسیگنال شامل چهار سیگنال فرکانس بالا و یک سیگنال فرکانس پایین تجزیه شدند که این سری‌های زمانی به عنوان ورودی شبکه عصبی در نظر گرفته شدند.

$$L = INT[\log(N)] \quad (8)$$

که در آن، L درجه تجزیه، INT تابع گردکننده و N تعداد داده‌های سری زمانی است.

صحت‌سنجی مدل‌های شبیه‌سازی بارش-رواناب:

به منظور ارزیابی، مقایسه و گزینش دقیق‌ترین ساختار مدل بارش-رواناب از شاخص‌های آماری ضریب همبستگی (R)، ضریب نش-ساتکلیف (NCE)، جذر میانگین مربعات خطا (RMSE) و ضریب مجموع باقی‌مانده‌ها (CRM) استفاده شد (روابط ۹ تا ۱۲).

$$R = \frac{\sum_{i=1}^n [(P_i - \bar{P})(O_i - \bar{O})]}{\sqrt{\sum_{i=1}^n [(P_i - \bar{P})^2 (O_i - \bar{O})^2]}} \quad (9)$$

$$RMSE = \left[n^{-1} \sum_{i=1}^n (O_i - P_i)^2 \right]^{0.5} \quad (10)$$

$$NCE = \left(1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \right) \times 100 \quad (11)$$

$$CRM = \frac{\sum_{i=1}^n O_i - \sum_{i=1}^n P_i}{\sum_{i=1}^n P_i} \quad (12)$$

است که شبکه عصبی پرسپترون یکی از معروف‌ترین شبکه‌های عصبی است که در مدل چند لایه (MLP) دارای سه لایه شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی بوده که لایه پنهان خود می‌تواند بیش از یک لایه باشد و همچنین، تعداد نرون‌های موجود در هر لایه متفاوت بوده و بر اساس ماهیت مسئله مورد بررسی با سعی و خطا تعیین می‌شود (Menhaj, ۲۰۰۲). بنابراین، با استفاده از مدل شبکه عصبی چند لایه با روش پس‌انتشار خطا (BP) با الگوریتم لوبنبرگ-مارکوئٹ و تابع محرک تان‌سیگموئید، مدل‌سازی بارش-رواناب رودخانه خرم‌آباد انجام گرفته است. به این ترتیب که با اتخاذ تاخیرهای زمانی سیگنال بارش و بارش-رواناب به‌طور جداگانه به عنوان نرون‌های ورودی این رویکرد مدل‌سازی بارش-رواناب با دامنه‌ای از دو تا ۲۰ نرون برای لایه پنهان با تابع محرک‌سازی تان‌سیگموئید انجام شده است.

پیش‌پردازش و تجزیه سیگنال اصلی سری زمانی

با استفاده از تحلیل موجک: به منظور بهره‌گیری از کلیه اطلاعات سیگنال اصلی سری زمانی که از داده‌های خام در دسترس نیستند و همچنین، برای افزایش دقت مدل پیش‌بینی، از تحلیل موجک برای پیش‌پردازش و تجزیه سیگنال اصلی سری زمانی استفاده می‌شود. تحلیل موجک قادر است، بسیاری از منظرهای پنهان داده‌هایی که دیگر روش‌های تحلیل سیگنال در شناسایی آن‌ها ناتوان هستند را شناسایی کند (Daubechies, ۱۹۹۲). تبدیل گسسته موجکی برای پیش‌پردازش و تحلیل سری‌های زمانی مناسب‌تر از تبدیل پیوسته موجکی است. زیرا، داده‌های تبدیل یافته با DWT^1 اجزای اضافی نداشته و بنابراین، تبدیل معکوس را می‌توان برای هر دسته از داده‌های زمان-بسامد به کار برد (Hassanzadeh و همکاران، ۲۰۱۳). بنابراین، در این پژوهش، از تبدیلات موجک گسسته برای تجزیه سیگنال اصلی سری‌های زمانی بارش و رواناب استفاده شد. تابع موجک گسسته به صورت رابطه (۶) تعریف شده است

$$\psi_{k,j}(t) = s_0^{-j/2} \psi(s_0^{-j}t - k\tau_0) \quad (6)$$

با کاربرد رابطه (۶)، ضرایب گسسته موجک طبق

انحراف معیار بر دامنه تغییرات هر یک از این گام‌های زمانی (۱۰ روز) در مقابل لگاریتم بر مبنای ۱۰ طول دوره آماری، نمایه هرست به مقدار ۰/۸ به‌دست آمد (شکل ۱). این مقدار از نمایه هرست، نشان می‌دهد که سری زمان جریان رودخانه خرم‌آباد دارای دینامیک غیر خطی بوده و از حافظه بلندمدت برخوردار است. همچنین، بیان می‌دارد که مقادیر جریان این رودخانه مستقل از گذشته خود نیستند، بنابراین، سیگنال سری زمانی رواناب رودخانه خرم‌آباد از کفایت لازم برای مدل‌سازی برخوردار است. یعنی اینکه می‌توان از تأخیرهای زمانی جریان این رودخانه به‌عنوان سیگنال‌های ورودی مدل استفاده کرد. بر این اساس، معماری شبکه عصبی و موجک شبکه عصبی بدین طریق شکل گرفت که مقدار رواناب $Q(t+1)$ مطابق رابطه (۱۴) تابعی از مقدار بارش و رواناب است.

$$Q(t+1) = f \left(\begin{matrix} P(t), P(t-1), P(t-2) \\ Q(t), Q(t-1), Q(t-2) \end{matrix} \right) \quad (14)$$

مدل بارش، شبکه عصبی: در این مدل، تنها سیگنال بارش به‌عنوان ورودی شبکه عصبی در نظر گرفته شد. به این ترتیب که سه نرون بارش $p(t), p(t-1), p(t-2)$ به‌عنوان ورودی و مقدار رواناب $Q(t+1)$ به‌عنوان نرون خروجی یا هدف، این مدل شبکه عصبی در نظر گرفته شدند. ارزیابی معیارهای کارایی و ضریب دقت مدل حاکی از عملکرد ضعیف این مدل است (جدول ۱). چنان‌که، بر حسب معیار نش-ساتکلیف، مدل توانسته تنها در حدود ۲۰ درصد از موارد، رواناب را به‌درستی شبیه‌سازی کند و در حدود ۸۰ درصد دیگر موارد، شبیه‌سازی توأم با خطا بوده است. در این خصوص، برازش مقادیر مشاهداتی در مقابل مقادیر محاسباتی نیز به روشنی نشان از خطای نسبتاً بالای مدل دارند (شکل ۲). این مورد بر حسب جذر میانگین مربعات خطا به‌مقدار ۰/۱۳ نیز تأیید می‌شود. با توجه به شاخص ضریب باقی‌مانده‌ها (CRM)، مدل در هر دو مرحله آموزش و آزمون، متحمل بیش‌برازش اندکی شده است، یعنی اینکه مدل سوگیری قابل‌اعتنایی را نشان نمی‌دهد.

که در آن‌ها، O_t و \bar{O} به‌ترتیب داده‌ها و میانگین داده‌های مشاهداتی، P_t و \bar{P} به‌ترتیب داده‌ها و میانگین داده‌های محاسباتی است. در رابطه (۱۲) مقادیر مثبت ضریب CRM مبین گرایش مدل برای تخمین مقادیر کمتر از مقادیر مشاهداتی، مقدار منفی آن بیانگر گرایش مدل برای تخمین مقادیر بیشتر از مقادیر مشاهداتی و مقدار ایده‌آل در این مدل، ضریب صفر است.

هر چند معیارهای یاد شده از جمله معیارهای مفید در زمینه بررسی قدرت پیش‌بینی روش‌های مختلف به شمار می‌روند، اما هیچ‌کدام قادر نیستند، برتری یک روش را به‌صورت آماری ارزیابی کنند. بنابراین، برای اینکه از نظر آماری نیز فرضیه برابری صحت پیش‌بینی‌ها در مدل‌های مختلف مورد مقایسه قرار گیرند، از آزمون مرگان-گرنجر-نیوبلد^۱ (MGN) استفاده شد (رابطه ۱۳).

$$\begin{aligned} e_{1,t} &= O - P & e_{2,t} &= O - P_2 \\ S_t &= e_{1,t} + e_{2,t} & D_t &= e_{1,t} - e_{2,t} \end{aligned} \quad (13)$$


$$MGN = \frac{\rho_{sd}}{\sqrt{\frac{1 - \rho_{sd}^2}{N - 1}}}$$

که در آن، MGN آماره آزمون مرگان-گرنجر-نیوبلد، $e_{1,t}$ و $e_{2,t}$ به‌ترتیب خطای پیش‌بینی مدل اول و دوم، ρ_{sd} ضریب همبستگی بین مجموع خطای پیش‌بینی (S_t) و تفاضل خطای پیش‌بینی (D_t) دو مدل است. همچنین، مقدار محاسبه شده MGN از توزیع t_{N-1} پیروی می‌کند. این آزمون قادر است، معنی‌دار بودن تفاوت روش‌های مختلف را نیز بررسی کند (Diebold و Mariano, ۱۹۹۵).

نتایج و بحث

ارزیابی حافظه و دینامیک سری زمانی رواناب: به‌منظور اطمینان از وجود حافظه بلندمدت سری زمانی رواناب رودخانه خرم‌آباد، از نمایه هرست استفاده شد. به این ترتیب که ابتدا با در نظرگیری پایه میانه ۴۲۰۰ روز و فاصله زمانی ۱۰ روز در هرگام، میانگین، انحراف معیار و دامنه تغییرات هر یک از این فاصله‌های زمانی محاسبه شد. در گام بعدی، با برازش لگاریتم در مبنای ۱۰

^۱ Morgan-Granger-Newbold (MGN)



شکل ۱- نمودار هرست سری زمانی رواناب رودخانه خرم‌آباد ۱۳۷۰-۱۳۹۳


است (شکل ۴).

در نتیجه، به نظر می‌رسد، جابه‌جایی بسیار شدیدی در سیگنال خطا با تأثیرپذیری از سیگنال‌های ورودی وجود دارد که مدل شبکه عصبی قادر به عملکرد مناسب در مقابل این جابه‌جایی‌های محلی نیست. به طوری که ارزیابی سیگنال خطا که به‌عنوان توزیع زمانی خطا به شمار می‌رود، حاوی نکات مهمی همچون وجود نوسان‌های ماهانه، سالانه و دوره‌ای در روند خطا است (شکل ۵). از لحاظ دوره‌ای، سیگنال خطا، از سال ۱۳۷۰-۱۳۷۷ (دوره اول) رفتار نسبتاً منظمی را بر حسب ماه‌های معینی طی می‌کند. در صورتی که در دوره ۱۳۷۸-۱۳۹۳ (دوره دوم) به استثنای سال ۱۳۸۵، این سیگنال رفتاری متفاوت نسبت به دوره پیشین نشان می‌دهد. بدین ترتیب که در ماه‌های فروردین، اردیبهشت، خرداد و تیرماه دوره اول، همواره نوسانات مثبت و بعضاً بسیار شدیدی در این سیگنال مشاهده می‌شود. در صورتی که نوسانات منفی به‌ندرت و در حدود چند مورد اتفاق می‌افتد. در دوره دوم، وضعیت معکوس می‌شود.


لازم به ذکر است که این شاخص در هر یک از این دو مرحله، علامت متفاوتی را نشان می‌دهد. به این مفهوم که مدل در مرحله آموزش از سوگیری مثبت و در مرحله آزمون از سوگیری منفی برخوردار است. بنابراین، این مدل در مجموع، مقادیر رواناب شبیه‌سازی شده را در مرحله آموزش کمتر از مقادیر مشاهداتی و در مرحله آزمون بیشتر از مقادیر مشاهداتی تخمین زده است. از سویی، چون شاخص چولگی می‌تواند ارزیابی مناسبی از چگونگی توزیع فراوانی یک مجموع داده در اختیار قرار دهد، به این منظور، برای درک بهتر عملکرد مدل، توزیع فراوانی مقادیر خطا مورد ارزیابی قرار گرفت. چنان‌که از شکل ۳ پیداست، توزیع فراوانی مقادیر خطای کل داده‌ها به سمت راست چوله شده که چنین آرایشی در توزیع فراوانی خطا در مرحله آموزش و آزمون نیز قابل مشاهده است. لذا، مدل در حالت کلی (با فراوانی بیشتر) مقادیر رواناب را با خطای کمتری، بیشتر از رواناب مشاهداتی شبیه‌سازی می‌کند. ولی در برخی موارد (با فراوانی کمتر) مقادیر رواناب را با خطای بسیار زیادی، کمتر از مقادیر مشاهداتی تخمین زده

جدول ۱- نتایج عملکرد مدل بارش، شبکه عصبی در مدل‌سازی بارش-رواناب


| CRM | | R | | RMSE | | NCE | |
|--------|---------|-------|-------|-------|-------|-------|-------|
| آزمون | آموزش | آزمون | آموزش | آزمون | آموزش | آزمون | آموزش |
| ۰/۰۰۳۳ | -۰/۰۰۳۵ | ۰/۴۵ | ۰/۴۴ | ۰/۱۳ | ۰/۱۳۱ | ۲۰ | ۱۹/۶ |




شکل ۳- توزیع فراوانی مقدار خطا



شکل ۲- نمودار همبستگی رواناب مشاهداتی و محاسباتی



شکل ۵- توزیع زمانی سیگنال مقدار خطا



شکل ۴- نمودار برازش رواناب مشاهداتی و محاسباتی

عصبی مصنوعی مقدار رواناب ثابتی را به عنوان دبی پایه برای کل فرایند مدل سازی در نظر می گیرند، لذا همواره مقدار رواناب پیش بینی شده مدل با فرض نبود روز بارشی، در دوره اول و دوم به ترتیب کمتر و بیشتر از مقدار قابل انتظار است. چنین رویکردی به عنوان یکی از مهمترین عوامل افزایش خطای مدل سازی بارش-رواناب به وسیله شبکه عصبی قابل ذکر است.

مقایسه رواناب ماهانه این دو دوره (۱۳۷۷-۱۳۷۰ و ۱۳۹۳-۱۳۷۸) نشان می دهد که میانگین رواناب تیرماه و خردادماه دوره اول به ترتیب بیش از مقدار رواناب اردیبهشت و فروردین ماه دوره دوم است. نکته قابل توجه آن که در تیرماه دوره اول، بارشی ثبت نشده است، در صورتی که در اردیبهشت دوره دوم، میانگین بارش روزانه بیش از یک میلی متر در روز بوده است. بنابراین، ممکن است، فرایندهای دیگری همچون ذوب برف، نوسان دما و میزان تبخیر متأثر از توسعه و تغییر بافت شهر خرم آباد (زیرا این رودخانه از داخل شهر عبور می کند) افزایش فعالیت های اقتصادی-کشاورزی همچون دایر شدن سیستم شالی کاری در بخش پایین دست حوضه یا

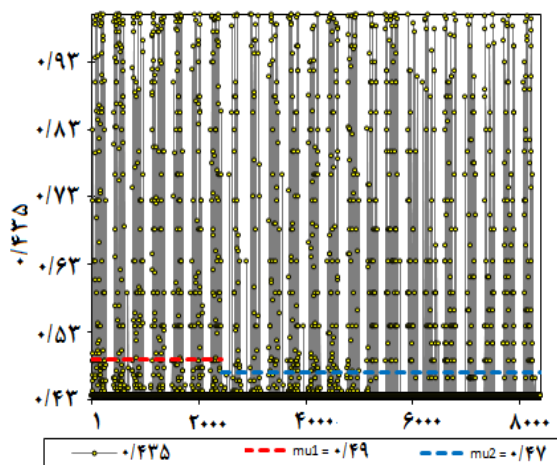
چنان که ذکر شد، سیگنال ورودی شبکه عصبی دارای نقاط تغییر و جابه جایی است که این جابه جایی در فرایند مدل سازی، در سیگنال خطا نیز انعکاس پیدا کرده است. در این خصوص، برای ارزیابی و آزمون معنی داری چنین فرایندی، معنی داری این جابه جایی های رخ داده در سیگنال های خطا و بارش با استفاده از دو آزمون نسبت وان نیومن^۱ و آزمون بویشاند^۲ در سطح اعتمادپذیری ۹۵ درصد مورد سنجش قرار گرفت. نتایج این آزمون ها حاکی از معنی دار بودن این جابه جایی ها و وجود دو میانگین متفاوت هم در سیگنال خطا و هم بارش است. چنانکه در شکل های ۶ و ۷ نیز مشخص است، این سیگنال ها دارای دو دوره متفاوت و منطبق برهم هستند. بنابراین، جابه جایی سیگنال خطا و بارش در مدل بارش-رواناب شبکه عصبی مصنوعی از دیدگاه آماری نیز معنی دار و قابل تأیید است.

با توجه به شکل ۷، میانگین بارش در دوره اول بیشتر از دوره دوم بوده است. بنابراین، از آنجا که شبکه

¹ Von neumann

² Buishand


زیادی روبه‌رو می‌کند. با توجه به این خصیصه (مستقل نبودن میانگین بارش و رواناب در طی زمان) و وجود دامنه‌های نسبتاً بزرگ در مقدار بارش-رواناب رودخانه حوزه آبخیز خرم‌آباد، چنانکه Cannas و همکاران (۲۰۰۶) اشاره می‌کنند، شبکه عصبی در مدل‌سازی چنین سیگنال‌های ناپیوسته‌ای از کارایی لازم برخوردار نیست.



شکل ۷- نمودار جابه‌جایی سیگنال بارش

به ترتیب در حدود ۸۵ و ۳۵ درصد افزایش داشته است. همچنین، میزان خطای آن بر حسب جذر میانگین مربعات خطا، ۱۸ درصد نسب به مدل قبلی کاهش یافته است. از سویی، مقادیر محاسبه شده شاخص CRM به مقدار $0.01-$ نشان می‌دهند که این مدل بر خلاف مدل پیشین دارای سوگیری یکسانی در کلیه مراحل مدل‌سازی بوده و چولگی مقادیر خطا نیز کاهش پیدا کرده است. به‌منظور آزمون معنی‌داری کاهش خطای مدل بارش-رواناب در نتیجه ترکیب شبکه عصبی با تحلیل موجک، سیگنال‌های خطای این مدل با مدل شبکه عصبی با استفاده از آزمون مرگان-گرنجر-نیوبلد مورد مقایسه قرار گرفت. آماره این آزمون در مرحله آزمون، آموزش و کل داده‌ها به ترتیب به مقدار $5/8$ ، $13/7$ و $24/4$ به‌دست آمد. بنابراین، با قرار نگرفتن این آماره‌ها در ناحیه بحرانی جدول t ، اطمینان حاصل می‌شود که ترکیب موجک با شبکه عصبی منجر به افزایش معنی‌دار دقت شبیه‌سازی بارش-رواناب نسبت به مدل شبکه عصبی می‌شود.

نوسانات آب و هوایی منطقه‌ای قابل توجهی در دوره دوم نسبت به دوره اول اتفاق افتاده باشند که مدل شبکه عصبی قادر به شناسایی و وزن‌دهی مناسب به آن‌ها نیست. به‌طور کلی، بر حسب متغیرهای آب و هواشناختی همچون نوع بارش، دما، تبخیر و زمان ذوب برف، جابه‌جایی زمانی در فصول سال اتفاق افتاده یا به نوعی یک ناپیوستگی در پارامترهای آب و هوایی پدید آمده که همین عامل پیش‌بینی رواناب را با خطاهای



شکل ۸- نمودار جابه‌جایی سیگنال خطا

مدل بارش، ترکیبی موجک-عصبی: نتایج مدل پیشین نشان داد که وجود جابه‌جایی زمانی در سیگنال بارش، موجب نامناسب شدن عملکرد مدل شبکه عصبی شده و این مدل قادر به استفاده از کلیه اطلاعات سیگنال نیست. لذا، در رویکردی که در ادامه نتایج آن ارائه خواهد شد، مدل شبکه عصبی با تحلیل موجک ترکیب شده است. به این ترتیب که ابتدا با استفاده از تابع موجک میر، سیگنال بارش در چهار سطح تجزیه و آنگاه با محاسبه سه زمان تاخیر چهار سیگنال فرکانس بالا و چهارمین سیگنال فرکانس پایین، در مجموع ۱۵ سیگنال به‌دست آمد. این ۱۵ سیگنال به‌عنوان نرون‌های ورودی و سیگنال رواناب به‌عنوان نرون خروجی مدل ترکیبی موجک-شبکه عصبی محسوب شدند.

نتایج حاصل از اجرای این مدل ترکیبی، حاکی از بهبود فرایند مدل‌سازی بارش-رواناب نسبت به مدل شبکه عصبی است. چنان‌که از جدول ۲ مشاهده می‌شود، عملکرد مدل ترکیبی نسبت به مدل قبلی، بر پایه معیارهای نش-ساتکلیف و ضریب همبستگی،

جدول ۲- نتایج عملکرد مدل بارش، ترکیبی موجک-عصبی در مدل‌سازی بارش-رواناب

| CRM | | R | | RMSE | | NCE | |
|-------|--------|-------|-------|-------|-------|-------|-------|
| آموزش | آزمون | آموزش | آزمون | آموزش | آزمون | آموزش | آزمون |
| ۰/۰۱- | ۰/۰۰۴- | ۰/۶۳ | ۰/۶۲ | ۰/۱۱۵ | ۰/۱۱۳ | ۳۸ | ۴۰ |

رویکردی دیگر، با محاسبه سه سیگنال تاخیر زمانی رواناب به همراه سه سیگنال بارش، در مجموع شش نرون به‌عنوان ورودی شبکه عصبی مصنوعی برای مدل‌سازی بارش-رواناب رودخانه خرم‌آباد در نظر گرفته شدند.

محاسبه شاخص‌های آماری حاصل از این مدل‌سازی نشان می‌دهد که ساختار ۶-۸-۱ با خطای محاسباتی ۰/۰۴۲ به‌عنوان بهترین ساختار این مدل به شمار می‌رود. مقادیر شاخص‌های آماری این ساختار در جدول شماره ۳ ارائه شده است. بر حسب معیار نش-ساتکلیف، کارایی مدل به مقدار ۹۰ درصد محاسبه شد. به این معنی که مدل توانایی آن را دارد که در ۹۰ درصد از موارد، رواناب را به‌درستی شبیه‌سازی کند. نکته حائز اهمیت، کاهش قابل توجه مقدار خطای مدل نسبت به مدل‌های قبلی است. همچنین، به‌رغم اینکه، سوگیری مدل بسیار ناچیز و قابل اغماض بوده، اما با استناد به شاخص CMR، مدل در مجموع مقدار رواناب را کمتر از مقادیر مشاهداتی شبیه‌سازی کرده است. با این حال، مقدار چولگی خطا ضمن چوله‌شدن به سمت راست (شکل ۸)، مقدار بیشینه‌ای را نسبت به دو مدل قبل نشان می‌دهد که این حاکی از قابل انعطاف نبودن مدل نسبت به نوساناتی است که قبلاً در مورد آن‌ها بحث شد. مقادیر آماره مرگان-گرنجر-نیوبلد حاصل از مقایسه نتایج خروجی این مدل با مدل ترکیبی موجک-شبکه عصبی به‌ترتیب در بخش آموزش به مقدار ۸۸، آزمون ۴۵ و کل داده‌ها به مقدار ۱۰۶ محاسبه شد. این مقادیر، نشان از معنی‌داری دقت نتایج مدل شبکه عصبی با ورودی سیگنال بارش-رواناب نسب به مدل ترکیبی موجک-شبکه عصبی با ورودی بارش دارد. بنابراین، با دخیل کردن سیگنال‌های تاخیری رواناب، دقت و صحت مدل‌سازی افزایش پیدا کرد.

از سویی، چنان‌که ذکر شد، چولگی خطا در این مدل افزایش قابل توجهی پیدا کرده است. بنابراین، در این مدل نیز برای دستیابی به این نکته که آیا سیگنال خطای این مدل متحمل جابه‌جایی شده است، از دو

مدل شبکه عصبی-موجکی با جداسازی سیگنال‌های فرکانس بالا و پایین، مانند مدل شبکه عصبی بدون پیش‌پردازش، وزن یکسانی برای کل سیگنال بارش در نظر نمی‌گیرد. بلکه با تجزیه سیگنال اصلی به زیرسیگنال‌های با فرکانس بالا و پایین، توجه خود را به وزن نسبی هر زیرسیگنال که معرف نوسانات روزانه، ماهانه و سالانه هستند، معطوف می‌دارد. به‌عبارتی، تأثیر تبدیل موجک در فرایند مدل‌سازی رواناب به سبب توجه به تأثیر هر زیرسیگنال تجزیه‌ای به‌وسیله بزرگ‌نمایی نسبی وزن آن زیر سیگنال است (Shafaei و همکاران، ۲۰۱۳). بنابراین، مشکلی که در مورد جابه‌جایی و ناپیوستایی سیگنال بارش رودخانه خرم‌آباد وجود داشت، با اتخاذ این روش ترکیبی تا حدی مرتفع شد.

شایان ذکر است که در ایستگاه‌های هواشناسی و باران‌سنجی حوضه خرم‌آباد تفکیکی در مورد نوع بارش صورت نمی‌گیرد. معمولاً داده‌های بارش ممکن است، شامل برف یا باران باشند که این خود سبب رفتار متفاوت حوضه نسبت به بارش در طی زمان‌های مختلف می‌شود (رفتار متفاوت رواناب نسبت به بارش بهاره و زمستانه). از سویی، پارامترهای دیگری چون دما، قدرت تبخیر جو، پوشش گیاهی و بافت حوزه آبخیز در پیچیدگی دینامیک رواناب مؤثر هستند. بر این اساس، سری زمانی خود رواناب به‌عنوان مهمترین متغیری به شمار می‌رود که از پتانسیل بالای برای افزایش قدرت پیش‌بینی مدل برخوردار است، چرا که اثر ترکیبی تمامی متغیرهای مؤثر در مقدار رواناب، در سیگنال آن نهفته هست. البته با توجه به اینکه سری زمانی یادشده دارای حافظه بلندمدت باشد.

مدل بارش-رواناب، شبکه عصبی: چنان‌که پیشتر مشخص شد، سیگنال رواناب رودخانه خرم‌آباد دارای حافظه بلندمدت و رفتاری دینامیکی بوده یعنی اینکه حالت کنونی آن وابسته به گذشته آن است. بنابراین، این سیگنال قابلیت آن را دارد که بر پایه زمانی‌های تأخیر متفاوت شبیه‌سازی شود. بر این اساس، در


وجود، هنوز کاستی‌هایی در مدل بارش-رواناب وجود دارد و آن هم مربوط به وزن‌دهی مناسب به سیگنال‌های فرکانس بالا (روزانه و غیره)، و فرکانس پایین (سالانه، دوره‌ای و غیره)، بارش و رواناب است. چرا که در بخش قبلی مشخص شد که بارش و رواناب علاوه بر دارا بودن تغییرات روزانه و ماهانه، از تغییرات دوره‌ای نیز برخوردارند. به‌علاوه، به‌رغم کاهش میزان خطای مدل، هنوز توزیع زمانی خطا دارای اریب و چولگی شدیدی است. یعنی در برخی موارد، مدل‌سازی دچار خطاهای بسیار شدیدی می‌شود. بنابراین، می‌توان بیان کرد که بخشی از اطلاعات در سیگنال بارش-رواناب نهفته هستند که شبکه عصبی قادر به کشف آن‌ها نیست و عملاً بخشی از اطلاعات در فرایند مدل‌سازی حضور ندارند.

آزمون نسبت وان نیومن و بویشاند بهره برده شد که نتایج آن در شکل ۹ ارائه شده است. همان‌طور که مشاهده می‌شود، در این مدل نیز سیگنال خطا یک نقطه جابه‌جایی معنی‌دار دارد. این نقطه جابه‌جایی، بسیار نزدیک به نقطه جابه‌جایی مدل شبکه عصبی است. در مجموع، چنین استنباط می‌شود که سیگنال رواناب نیز مانند سیگنال بارش از نقطه جابه‌جایی مهمی برخوردار است که جا دارد، این سیگنال نیز مورد آزمون جابه‌جایی قرار گیرد.


بر پایه دستاوردهای فوق، از آنجا که گذشته رواناب حاوی کلیه نکاتی است که سیگنال آن از تغییرات متغیرهای مؤثر در آن پذیرفته است، بنابراین، در این رویکرد با دخالت دادن رواناب، به نوعی برآیند و یا نتیجه برهم کنش متغیرهای مؤثر در رواناب به‌طور غیر مستقیم در فرایند مدل‌سازی دخالت داده شده‌اند. با این

جدول ۳- نتایج عملکرد مدل بارش-رواناب، شبکه عصبی در مدل‌سازی بارش-رواناب

| CRM | | R | | RMSE | | NCE | |
|--------|--------|-------|-------|-------|-------|-------|-------|
| آموزش | آزمون | آموزش | آزمون | آموزش | آزمون | آموزش | آزمون |
| ۰/۰۰۱۳ | ۰/۰۰۱۵ | ۰/۹۵ | ۰/۹۶ | ۰/۰۴۴ | ۰/۰۴۲ | ۹۰ | ۹۲ |



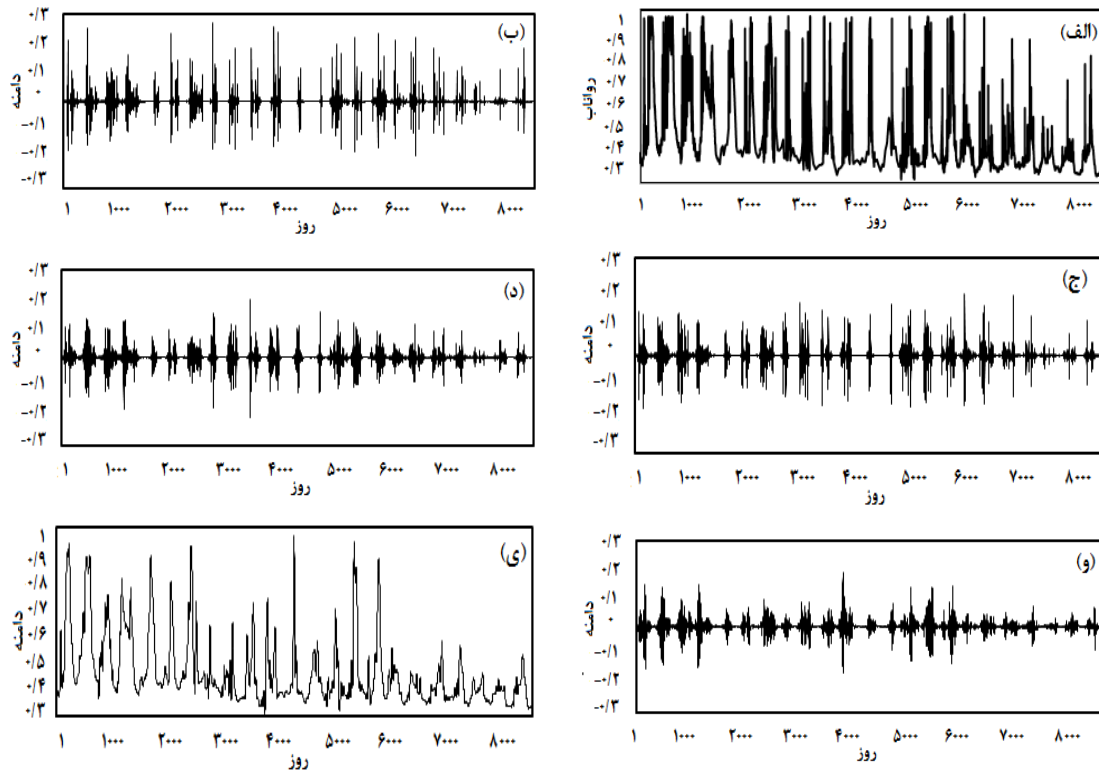
شکل ۹- نمودار آزمون جابه‌جایی سیگنال خطا



شکل ۸- نمودار توزیع فراوانی مقدار خطا

یک سیگنال فرکانس پایین (شکل ۱۰- ی) تجزیه شد. به این ترتیب، با محاسبه سه تاخیر زمانی برای هرکدام از این سیگنال‌ها، مجموعاً ۳۰ سیگنال ورودی حاصل شد که این ۳۰ سیگنال به‌عنوان نرون‌های ورودی مدل ترکیبی موجک - شبکه عصبی در نظر گرفته شدند.

مدل بارش-رواناب، ترکیبی عصبی-موجک: برای دخالت دادن تمامی اطلاعات سیگنال بارش و رواناب، سیگنال رواناب (شکل ۱۰- الف) نیز همانند سیگنال بارش با استفاده از تابع تبدیل موجک میر به چهار سیگنال فرکانس بالا (شکل‌های ۱۰- ب، ج، د و و) و



شکل ۱۰- الف) سیگنال اصلی نرمال شده سری زمانی رواناب، ب) سیگنال فرکانس بالا سطح ۱، ج) سیگنال فرکانس بالا سطح ۲، د) سیگنال فرکانس بالا سطح ۳، و) سیگنال فرکانس بالا سطح ۴ رواناب و ی) سیگنال فرکانس پایین سطح ۴

پیش‌بینی کند (جدول ۴). همچنین، مقادیر سایر شاخص‌ها اعم از ریشه میانگین مربعات خطا و ضریب همبستگی به مقدار مناسبی بهبود پیدا کردند. چنان‌که ترسیم پراکنش و توزیع زمانی مقادیر رواناب شبیه‌سازی شده در مقابل رواناب مشاهداتی به ترتیب در قالب شکل‌های ۱۱ و ۱۲ حاکی از پراکنش مناسب و همبستگی بسیار بالای این دو پارامتر است.

با اتخاذ این سیگنال‌ها (بارش-رواناب) به‌عنوان نرون‌های ورودی شبکه عصبی، مدل بارش-رواناب پیاده‌سازی شد که با ارزیابی معیارهای صحت‌سنجی مدل، ساختار ۳۰-۸-۱ به‌عنوان بهترین ساختار شناسایی شد. به‌طوری که میزان کارایی عملکرد این مدل بر اساس معیار نش-ساتکلیف به مقدار ۹۹ درصد به‌دست آمد. بدین‌مفهوم که مدل ایجاد شده قادر است، در ۹۹ درصد موارد، مقدار رواناب را به‌درستی شبیه‌سازی یا

جدول ۴- نتایج عملکرد مدل بارش-رواناب ترکیبی موجک-عصبی در مدل‌سازی بارش-رواناب


| CRM | | R | | RMSE | | NCE | |
|---------|---------|-------|-------|-------|-------|-------|-------|
| آموزش | آزمون | آموزش | آزمون | آموزش | آزمون | آموزش | آزمون |
| -۰/۰۰۷۵ | -۰/۰۰۶۸ | ۰/۹۹۷ | ۰/۹۸۸ | ۰/۰۱۱ | ۰/۰۱ | ۹۹/۴ | ۹۹/۵ |

قابل اعتماد دقت و صحت مدل بارش-رواناب با ورودی سیگنال بارش و رواناب نسبت به مدل شبکه عصبی با ورودی سیگنال بارش و رواناب می‌شود. علاوه بر کاهش مقدار خطای این مدل ترکیبی نسبت به مدل‌های پیشین، دستاورد مهم این مدل کاهش شدید نوسانات زمانی سیگنال خطای مدل است (شکل ۱۳). بدین‌ترتیب که نوسانات توزیع زمانی خطاها و چولگی

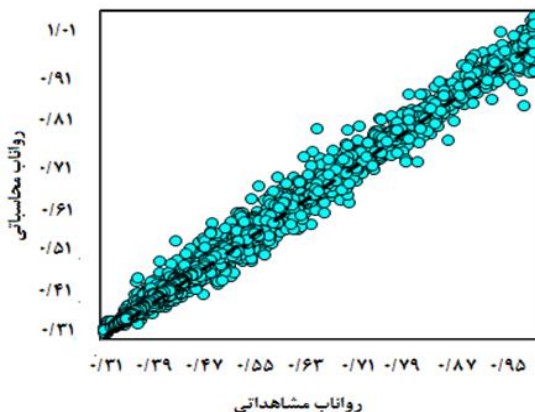
نتایج خروجی مدل ترکیبی موجک-عصبی با مدل شبکه عصبی با ورودی بارش-رواناب با تکیه بر آماره مرگان-گرنجر-نیوبلد برای بخش‌های آزمون، آموزش و کل داده‌ها به‌ترتیب به مقدار ۸۱، ۱۵۹ و ۱۹۳ محاسبه شد. با توجه به جدول توزیع t ، این مقادیر در ناحیه بحرانی قرار نمی‌گیرند و معنی‌داری آن‌ها تأیید می‌شود. بنابراین، ترکیب موجک با شبکه عصبی موجب افزایش

آزمون نسبت وان نیومن و بویشاند نقطه جابه‌جایی معنی‌داری را نشان نمی‌دهند (شکل ۱۵).


این سیگنال به‌طور چشم‌گیری کاهش یافته و سیگنال خطا از روند تقریباً نرمالی برخوردار شده است (شکل ۱۴). به‌طوری که آزمون سیگنال خطا با استفاده از دو




شکل ۱۲- نمودار برازش رواناب مشاهداتی و محاسباتی




شکل ۱۱- نمودار پراکنش رواناب مشاهداتی و محاسباتی




شکل ۱۴- نمودار توزیع فراوانی خطا



شکل ۱۳- نمودار سیگنال زمانی خطا



شکل ۱۶- نمودار جابه‌جایی سیگنال رواناب



شکل ۱۵- نمودار آزمون جابه‌جایی سیگنال خطا

بودند، با کاربرد و تجزیه سیگنال‌های بارش-رواناب به‌وسیله تحلیل موجک مرتفع شد. لازم به‌ذکر است که بر اساس نتایج دو آزمون، سیگنال رواناب نیز مانند

بنابراین، مسله‌ای که مدل‌های پیشین به‌رغم ارائه شبیه‌سازی‌های با درجه خطا قابل‌قبول اما سوگیری نسبتاً شدید در مقابل نوسانات محلی گریبان‌گیر آن

پاسخ یکسان درون دوره‌ای و پاسخ متفاوت برون دوره‌ای نسبت به مقدار بارش بوده است. این جابه‌جایی در سیگنال بارش موجب شده بود که قدرت تعمیم‌دهی مدل، کاهش و خطای محاسباتی افزایش پیدا کند.

در ادامه، با تجزیه سیگنال بارش در چهار سطح تجزیه، فرکانس‌های بالا و پایین بارش، در دسترس قرار گرفتند. نتایج این مدل ترکیبی بارش-رواناب نشان داد که میزان سوگیری مدل، کاهش معنی‌داری پیدا کرده است. چنان‌که مقایسه نتایج این مدل ترکیبی با مدل شبکه عصبی بر اساس آزمون مرگان-گرنجر-نیوبلد، نشان داد که در کلیه مراحل مدل‌سازی، نتایج مدل ترکیبی به‌طور معنی‌داری نسبت به مدل شبکه عصبی در سطح اعتماد ۹۵ درصد افزایش پیدا کرده است. با این وجود، هنوز میزان همبستگی مدل و خطای محاسباتی آن در حد قابل‌قبولی به‌عنوان یک مدل شبیه‌ساز مناسب قرار نداشت. بنابراین، در رویکردی دیگر، سیگنال رواناب به همراه سیگنال بارش نیز به‌عنوان نرون ورودی شبکه عصبی در نظر گرفته شدند. نتایج حاصل از اجرای این مدل نشان داد که اگرچه دخالت سیگنال رواناب منجر به افزایش معنی‌دار و قابل‌توجه صحت نتایج می‌شود، اما میزان سوگیری مدل نیز به‌طور قابل‌توجهی افزایش پیدا کرده است. از سویی آزمون سیگنال خطا و رواناب این مدل با استفاده از دو آزمون نسبت وان‌نیومن و بوشاند نیز نشان داد که همانند سیگنال بارش، یک نقطه جابه‌جایی در سیگنال رواناب نیز وجود دارد که در ترکیب با نقطه جابه‌جایی بارش، سوگیری شدید مدل و چولگی شدید سیگنال خطا را موجب شده‌اند.

سرانجام با تجزیه سیگنال رواناب، مدل بارش-رواناب با استفاده از ترکیب عصبی-موجک اجرا شد. آماره آزمون آزمون مرگان-گرنجر-نیوبلد حاصل از مقایسه نتایج این مدل ترکیبی با مدل شبکه عصبی (ورودی بارش رواناب) در بخش آموزش، آزمون و کل داده‌ها به‌ترتیب به مقدار ۸۱، ۱۵۹ و ۱۹۳ به‌دست آمد که نشان از افزایش معنی‌دار صحت نتایج مدل‌سازی داشت. به‌طور کلی، نتایج نشان دادند که مدل ترکیبی موجک عصبی، با کمترین مقدار سوگیری و کاهش شدید چولگی سیگنال خطا قادر است در ۹۹ درصد موارد فرایند بارش-رواناب را به‌درستی شبیه‌سازی کند.

سیگنال بارش دارای یک نقطه جابه‌جایی بسیار قوی است (شکل ۱۶).

در نهایت، بایستی بیان نمود که مدل ترکیبی موجک-عصبی با اختصاص وزن مناسب به نوسانات فرکانس بالا و پایین و بهره‌گیری از کلیه اطلاعات سیگنال‌های بارش رواناب، توانسته است، دینامیک غیر خطی رواناب رودخانه خرم‌آباد را به‌درستی شبیه‌سازی کند. در صورتی‌که در مدل قبلی با وجود دارا بودن ضریب همبستگی و میزان کارایی بالا، توزیع زمانی خطاها دارای چولگی مثبت بسیار شدیدی بود. مدل ارائه شده کلیه اجزای نوسانات سری زمانی رواناب رودخانه یادشده را به‌درستی پیش‌بینی می‌کند و قابلیت برخورد و وزن‌دهی مناسب شبکه عصبی را با نوسانات محلی بهبود می‌بخشد.

نتیجه‌گیری

با توجه به این‌که بخش نسبتاً وسیعی از حوزه آبخیز رودخانه خرم‌آباد در محدوده کاربری شهری قرار دارد، در مطالعه حاضر ابتدا با استفاده از نمایه هرست، حافظه بلندمدت و رفتار دینامیکی سیگنال رواناب این رودخانه طی بازه زمانی ۱۳۹۳-۱۳۷۰ مورد آزمون قرار گرفت. نمایه هرست برابر ۰/۸ به‌دست آمد که این مقدار نشان از وجود حافظه بلندمدت و رفتار دینامیکی و غیر خطی این سیگنال داشت. بر این اساس، برای شبیه‌سازی و پیش‌بینی رواناب این رودخانه ضرورت دارد که از روش‌هایی مانند شبکه عصبی مصنوعی و ترکیب موجک عصبی که قادر به کشف رفتارهای غیر خطی و پیچیده هستند استفاده شود.

در پژوهش حاضر، چهار مدل شامل (۱) بارش، عصبی، (۲) بارش-رواناب، عصبی، (۳) بارش، موجک-عصبی و (۴) بارش-رواناب، موجک-عصبی، با سه زمان تأخیر اجرا شد. نتایج حاصل از ارزیابی اجرای اولین مدل با استفاده از شبکه عصبی نشان داد که یک جابه‌جایی زمانی معنی‌دار در سیگنال خطا وجود دارد که منجر به اجرای متفاوت مدل در بخش‌های آموزش و آزمون شده است. بدین‌ترتیب، مشخص شد که در حوضه مورد مطالعه، بارش و رواناب دارای یک نقطه جابه‌جایی و چرخه‌های ماهانه و دوره‌ای شامل دوره ۱۳۷۷-۱۳۷۰ و ۱۳۷۸-۱۳۹۳ هست. در این دوره‌ها، مقدار رواناب دارای

چنان‌که آزمون سیگنال خطای این مدل ترکیبی با اتخاذ دو آزمون نسبت وان‌نیومن و بویشانده، هیچ‌گونه نقطه جابه‌جایی را در این سیگنال تشخیص ندادند. به واقع، این نشان از عملکرد مناسب و قابل اعتماد مدل دارد. بنابراین، این مدل با بزرگ‌نمایی نسبی وزن هر

زیرسیگنال توانسته که نوسان‌های روزانه، ماهانه، دوره‌ای و ...، که در سیگنال‌های بارش-رواناب وجود داشتند را شناسایی و ضمن کاهش سوگیری مدل، رواناب را به‌درستی با خطای ۰/۰۱۱ شبیه‌سازی و پیش‌بینی کند.

منابع مورد استفاده

1. Abdollahi Asadabadi, S., Y. Dinpashoh and R. Mirabbasi. 2014. Forecasting of mean daily runoff discharge of behesht-abad River using wave let analysis. *Water and Soil*, 28: 534-545 (in Persian).
2. Adamowski, J. and S.O. Prasher. 2012. Comparison of machine learning methods for runoff forecasting in mountainous watersheds with limited data. *Journal of Water and Land Development*, 17: 89-97.
3. Adamowski, J. 2008. Development of a short-term river flood forecasting method for snowmelt driven and cross-wavelet analysis floods based on wavelet. *Journal of Hydrology*, 3-4: 247-266.
4. Akhtar, M.K., G.A. Corzo, S.J. Van Andel and A. Jonoski. 2009. River flow forecasting with artificial neural networks using satellite observed precipitation pre-processed with flow length and travel time information, case study of the Ganges River Basin. *Hydrology and Earth System Sciences*, 9: 1607-1618.
5. Besaw L.E., D.M. Rizzo, P.R. Bierman and W.R. Hackett. 2010. Advances in ungauged streamflow prediction using artificial neural networks. *Journal of Hydrology*, 1-4: 27-37.
6. Cannas, B., A. Fanni, L. See and G. Sias. 2006. Data preprocessing for river flow forecasting using neural networks. *Wavelet transforms and data partitioning. Physics and Chemistry of the Earth*, 18: 1164-1171.
7. Daubechies, I. 1992. Ten lectures on wavelets. *Society for Industrial Mathematics*, 350 pages.
8. Diebold, F.X. and R.S. Mariano. 1995. Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 13: 253-263.
9. Haghizadeh, A., M. Mohammadlou and F. Noori. 2015. Simulation of rainfall-runoff process using multilayer perceptron and adaptive neuro-fuzzy interface system and multiple regressions, case study: Khorram-abd Watershed. *Iranian Journal of Ecohydrology*, 21: 233-243 (in Persian).
10. Hassanzadeh, Y., A. Abdi Kordani, M. Shafieinajd and S. Khoshtinat. 2014. Daily stream flow forecasting of Nooranchay River using the hybrid model of artificial neural networks-principal component analysis. *Water and Soil*, 3: 53-63 (in Persian).
11. Hassanzadeh, Y., M.A. Lotfollahi, S. Shahverdi, S. Farzin and N. Farzin. 2013. De-noising and prediction of time series based on the wavelet algorithm and chaos theory, case study: SPI drought monitoring index of Tabriz City. *Iran-Water Resources*, 3: 1-13 (in Persian).
12. Hurst, H.E. 1951. Long-term storage capacity of reservoirs (with discussion). *Transactions of the American Society of Civil Engineers*, 116: 770-808.
13. Karamouz, M., S. Nazif and M. Falahi 2013. *Hydrology and hydroclimatology principles and applications*. John Wiley and Sons Inc., New York, 703 pages.
14. Karunanithi, N., W.J. Grenney, D. Whitley and K. Bovee. 1994. Neural networks for river flow prediction. *Journal of Computing in Civil Engineering*, 2: 201-220.
15. Khorshiddoust, A.M., M. Rezaei Banafsheh, H. Mirhashemi and Y. Kakolvand. 2015. Studying the trend of changes in precipitation-discharge the Karkhe Rive Sub-Basin using non-parametric methods, case study: Kashkan Basin. *Journal of Irrigation Science and Engineering*, 38: 177-188 (in Persian).
16. Kia, M. 2010. *Neural networks in matlab*. Qian Academic Publishing, 408 pages (in Persian).
17. Kisi, O. 2008. Stream flow forecasting using neuro-wavelet technique. *Journal of Hydrological Process*, 22: 4142-4152.
18. Kumar, P.S., T.V. Praveen and M.A Prasad. 2016. Artificial neural network model for rainfall-runoff a case study. *International Journal of Hybrid Information Technology*, 3: 263-272.
19. Lee, S., J.H. Ryu, M. Lee and J.S. Won. 2006. The application of artificial neural networks to landslide susceptibility mapping at Janghung, Korea. *Mathematical Geosciences*, 38: 199-220.
20. Lotfollahi-Yaghin, M.A., S. Shahverd and R. Tarinejad. 2010. Damage detection in jacket type offshore platforms using wavelet packet transform. *The 5th Civil Engineering Conference in the Asian Region and Australasian Structural Engineering Conference*.

21. Machado, F., M. Mine, E. Kaviski and H. Fil. 2011. Monthly rainfall-runoff modelling using artificial neural networks. *Journal of Hydrological Science*, 56: 349-361.
22. Mark, H.B., T.H. Martin and B.D. Haward. 2016. *Neural network toolbox TM getting started guide*. The Math Works, 446 pages.
23. Menhaj, M. 2002. *Neural networks and artificial intelligent basic*. First edition, Amir Kabir University Press, 716 pages (in Persian).
24. Montaseri, M. and S. Zamanzad Ghavidel. 2014. River flow forecasting using soft computing. *Water and Soil*, 2: 394-405 (in Persian).
25. Nourani, V., M. Komasi and A. Mano. 2009. A multivariate ANN-Wavelet approach for rainfall-runoff modeling. *Water Resources Management*, 23(14): 2877-2894.
26. Pramanik, N. and R.K. Panda. 2009. Application of neural network and adaptive neuro-fuzzy inference systems for river flow prediction. *Hydrological Sciences*, 54: 247-260.
27. Shafaei, M., A. Fakheifard, S. Darbandi and M.A. Ghorbani. 2013. Prediction daily flow of Vanyar Station using ANN and wavelet hybrid procedure. *Irrigation and Water*, 14: 144-128 (in Persian).
28. Sudhishri, S., A. Kumar and J.K. Singh. 2016. Comparative evaluation of neural network and regression based models to simulate runoff and sediment yield in an outer Himalayan Watershed. *Journal of Agricultural Science and Technology*, 3: 681-694.
29. Wang, W. and S. Ding. 2003. Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, 1: 67-71.
30. Wu, C.L. and K.W. Chau. 2010. Data-driven models for monthly streamflow time series prediction. *Engineering Applications of Artificial Intelligence*, 8: 1350-1367.
31. Yarahmadi, D. and H. Mirhashemi. 2018. Forecasting Kashkan River flow using a combination of artificial neural network, Wavelet Analysis and K-Nearest Neighbor. *Water and Soil*, 6: 1561-1574 (in Persian).
32. Zounemat-Kermani, M. and M. Teshnelab. 2008. Using adaptive neuro-fuzzy inference system for hydrological time series prediction. *Applied Soft Computing*, 8: 928-936.