

استفاده ترکیبی از تبدیل موجک و مدل‌های هوشمند در شبیه‌سازی جریان رودخانه (مطالعه موردی: رودخانه‌های کاکارضا و سراب صیدعلی)

امیر پورحقی^۱، ابادر سلگی^۲، فریدون رادمنش^۳، مهرانوش شهینی دارابی^۴.

تاریخ ارسال: ۱۳۹۵/۰۱/۱۶

تاریخ پذیرش: ۱۳۹۶/۱۱/۰۸

چکیده

بی‌شک اولین قدم برای مدیریت منابع آب پیش‌بینی و برآورد جریان رودخانه‌ها است. در این مطالعه به منظور پیش‌بینی سری زمانی جریان روزانه و ماهانه ایستگاه‌های کاکارضا و سراب صیدعلی، مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج فازی عصبی تطبیقی استفاده شده است. به منظور بهبود نتایج شبیه‌سازی از آنالیز موجک به عنوان مدل ترکیبی استفاده شد. برای این هدف، سری زمانی جریان و بارش به مدت ۱۲ سال (۱۳۸۰-۱۳۹۲) به وسیله تبدیل موجک به زیرسری‌های فرکانسی تجزیه شد، سپس این زیرسری‌ها به عنوان داده‌های ورودی به مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج فازی عصبی تطبیقی وارد شد. نتایج بدست آمده حاکی از آن بود که سیستم استنتاج فازی عصبی تطبیقی با میزان خطای کمتر و ضریب همبستگی بیشتر نسبت به روش شبکه عصبی مصنوعی از دقت بالاتری برخوردار است و اعمال تبدیل موجک روی داده‌های اصلی جریان و بارش باعث بهبود چشمگیر نتایج پیش‌بینی شد.

کلیدواژه: شبکه عصبی مصنوعی، سیستم استنتاج فازی عصبی تطبیقی، تبدیل موجک، بارش-رواناب.

* ایمیل نویسنده مسئول: freidon_radmanesh@yahoo.com

۱- امیر پورحقی - آدرس: خرم آباد، شهرک پارسیلون، انتهای بلوار فروردین، سمت چپ نبش خیابان مهاباد، دانشجوی دکتری مهندسی منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز. اهواز: Pourhaghiamir@yahoo.com

۲- ابادر سلگی - آدرس: نهبوند - شهر فیروزان - بلوار انقلاب، دانشجوی دکتری مهندسی منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز. اهواز: A-solgi@phdstu.scu.ac.ir

۳- فریدون رادمنش، آدرس: اهواز، دانشیار گروه هیدرولوژی و منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز. freidon_radmanesh@yahoo.com

۴- مهرانوش شهینی دارابی - آدرس: اهواز-گلستان -خیابان اصفهان بین آذر و دی -ساختمان نگین، دانشجوی دکتری مهندسی منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز و کارشناس کنترل کیفیت شرکت آب غدیر خوزستان.

shahnidarabi.mehrnoush@gmail.com

مقدمه

مدل‌سازی فرایندهای هیدرولوژیکی همچون بارش-رواناب می‌تواند نقش مهمی در کاهش خشکسالی‌ها، کنترل سیلاب‌ها و مدیریت منابع آب ایفا کند (Nourani and et al. 2011). امروزه مدل‌های متعددی به منظور شبیه‌سازی فرایندهای پیچیده هیدرولوژیکی توسعه پیدا کرده است. مدل‌های هوشمند همچون شبکه عصبی مصنوعی^۱ و سیستم استنتاج فازی عصبی تطبیقی^۲ توانایی نسبتاً خوبی در مدل‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی غیرخطی نشان داده‌اند (Nourani and et al. 2009). به عنوان مثال، آلتون کایناک (۲۰۰۷) نشان داد که شبکه‌های عصبی مصنوعی به خوبی می‌توانند رابطه بین بارندگی و سطح آب را مدل‌سازی کنند. مساعدی و قبادی سوق (۱۳۹۰)، با استفاده از سیستم استنتاج تطبیقی عصبی-فازی به برآورد تبخیر روزانه در ایستگاه سینوپتیک شیراز پرداختند و نشان دادند این مدل توانایی خوبی در برآورد تبخیر دارد. همچنین محققین مختلفی در سراسر جهان باروش‌های مختلف اقدام به پیش‌بینی جریان رودخانه‌ها در مقیاس‌های زمانی ساعتی، روزانه و ماهانه نموده‌اند. نایاک و همکاران (۲۰۰۵) در پیش‌بینی دبی رودخانه بایتارانی در ایالت اوراسیای هند، به این نتیجه رسیدند که روش ANFIS عملکرد بهتری نسبت به شبکه عصبی مصنوعی و مدل آرما^۳ داشته است. در ایران نیز کارهای خوبی در این زمینه صورت گرفته است (سلگی و همکاران، ۱۳۹۴، نیک منش، ۱۳۹۴). عراقی‌نژاد و کارآموز (۱۳۸۴) از شبکه عصبی مصنوعی و سیستم استنتاج فازی (FIS) برای پیش‌بینی بلندمدت حجم جریان رودخانه زاینده‌رود استفاده

نمودند. نتایج آن‌ها نشان داد که این دو مدل به خصوص هنگامی که در ترکیب با هم به کار رفتند، از دقت مناسبی برای پیش‌بینی رواناب به صورت بلند مدت برخوردار بودند. نورانی و کماسی (۲۰۱۳)، از مدل ANFIS جهت شبیه‌سازی فرآیند بارش-رواناب رودخانه ال در کالیفرنیا استفاده نمودند. شجاع رستگاری و بارانی (۲۰۱۱)، از دو مدل ANN، ANFIS و رگرسیون جهت پیش‌بینی رواناب ماهانه حوضه زیارت گرگان استفاده نمودند. نتایج نشان داد که شبکه عصبی فازی تطبیقی نسبت به شبکه عصبی مصنوعی و رگرسیون برتری دارد. غفاری و وفاخواه (۱۳۹۲)، در مطالعه‌ای به شبیه‌سازی بارش-رواناب به صورت روزانه با استفاده از شبکه‌های عصبی مصنوعی و شبکه فازی-عصبی تطبیقی پرداختند. نتایج آنها نشان داد که مدل ANFIS نسبت به مدل ANN فرآیند بارش-رواناب را با دقت بالاتری پیش‌بینی می‌نماید. عبدالله پور آزاد و ستاری (۱۳۹۴) با بهره‌گیری از شبکه‌های عصبی مصنوعی (ANN) و سیستم استنتاج فازی عصبی تطبیقی اقدام به پیش‌بینی دبی جریان روزانه رودخانه اهرچای واقع در استان آذربایجان شرقی کردند. نتایج نشان داد که سیستم استنتاج فازی با دقت بالاتری نسبت به شبکه‌های عصبی مصنوعی می‌تواند جریان روزانه رودخانه اهرچای را پیش‌بینی کند. همانطور که ذکر شد مدل‌های هیدرولوژیکی مختلفی جهت شبیه‌سازی فرآیند بارش-رواناب در سال‌های اخیر مورد استفاده قرار گرفته است. هر چند که از این مدل‌ها به طور گسترده استفاده شده است ولی هنگامی که رفتار دینامیک سیستم هیدرولوژیکی با گذشت زمان تغییر می‌کند مدل‌های یاد شده برای پیش‌بینی پارامترهای منابع آب توانایی کافی نداشته و مدل‌های

^۱ Artificial Neural Network (ANN)

^۲ Adaptive Network-Based Fuzzy Inference System (ANFIS)

^۳ Autoregressive Moving Average Model

کوتاه مدت (پیش‌بینی ۱ ماه بعد) و بلندمدت (پیش-بینی بیش از یک ماه) به علت استفاده سری‌های زمانی چند مقیاسی از لایه ورودی شبکه عصبی مصنوعی به خوبی به انجام برساند. سلگی (۱۳۹۳)، در تحقیقی از ترکیب مدل موجک با مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج فازی عصبی تطبیقی برای پیش‌بینی جریان روزانه رودخانه گاماسیاب - نپاوند استفاده کرد. نتایج نشان داد که آنالیز موجک می‌تواند باعث بهبود چشمگیر نتایج پیش‌بینی شود. سلگی و همکاران (۲۰۱۴)، در مطالعه‌ای دیگر برای پیش‌بینی بارش در ایستگاه وراینه نپاوند از مدل ترکیبی شبکه عصبی - موجک استفاده کرده‌اند. با توجه به اهمیت پیش‌بینی‌های کوتاه مدت در مهندسی منابع آب، و ویژگی غیرخطی و ناپایداری سری زمانی جریان روزانه و ماهانه، هدف این مطالعه مقایسه مدل‌های ANN و ANFIS و مدل‌های هیبریدی Wavelet-ANN و Wavelet-ANFIS به منظور پیش‌بینی جریان روزانه و ماهانه در ایستگاه‌های کاکارضا و سراب صیدعلی است.

مواد و روشها

منطقه مورد مطالعه

در این مطالعه، از داده‌های ایستگاه‌های هیدرومتری کاکارضا و سراب صیدعلی به ترتیب روی رودخانه‌های هرود و دوآب واقع در شمال استان لرستان استفاده شده است. این رودخانه‌ها از سرشاخه‌های اصلی رودخانه کشکان به شمار می‌آیند که به سد کرخه می‌ریزد. حوضه کاکارضا با مساحت ۱۱۵۰ کیلومتر مربع در شمال استان لرستان و در محدوده جغرافیایی $48^{\circ}15'$ تا $48^{\circ}55'$ شمالی و $33^{\circ}43'$ و $33^{\circ}53'$ شرقی قرار دارد. طول آبراهه اصلی این حوضه ۸۰ کیلومتر بوده و حداکثر و حداقل ارتفاع این حوضه به ترتیب ۱۰۱۵ و ۳۰۴۵ متر از سطح آزاد دریا می‌باشد. حوضه سراب صیدعلی در شمال غرب حوضه کاکارضا با مساحت ۷۹۷ کیلومتر

مناسبی نیستند (Bierkens, 1988). سری‌های زمانی هیدرولوژیکی دارای مشخصات غیرایستا، پرش، روند و تغییرات ناگهانی در بسامد هستند که برای مدل‌سازی آن‌ها استفاده از الگوریتم‌ها، معادلات غیرخطی و نظریه‌های جدید ریاضی ضروری به نظر می‌رسد (Shafaei and et al. 2014). در حالت کلی برای آنالیز مشخصات مخفی در سری‌های زمانی باید از تبدیل‌کننده‌های ریاضی استفاده نمود (Polikar, 1996). تبدیل موجک تابعی است که نسخه بهبود یافته تبدیل فوریه را تداعی می‌نماید. تبدیل فوریه در آنالیز سیگنال‌های ناپایستا به شکست منجر می‌شود. در حالیکه تبدیل موجک اجازه می‌دهد که سیگنال‌های ناپایستا نیز بخوبی آنالیز شوند (Sifuzzaman and et al. 2009). ترکیب موجک با مدل‌های هیبریدی اخیراً به عنوان یک روش جایگزین در شبیه‌سازی فرآیند بارش-رواناب به کار برده می‌شود. در این مدل‌ها، علاوه بر وزن‌ها، موقعیت و مقیاس موجک‌ها نیز بهینه‌سازی می‌شوند (Thuillard, 2000). شفائی و همکاران (۱۳۹۲)، در مطالعه‌ای از مدل ترکیبی موجک-شبکه عصبی به پیش‌بینی جریان روزانه ایستگاه ونیاز در حوضه آبریز آجی‌چای پرداختند و نشان دادند موجک میر از موجک هار به مراتب بهتر عمل می‌کند. پارتال و کایزی (۲۰۰۷) یک روش ترکیبی را مبنی بر ترکیب موجک-فازی عصبی برای پیش‌بینی بارندگی پیشنهاد دادند و مشاهده کردند که مدل هیبریدی حاصل، همپوشانی و تطابق خوبی را با داده‌های مشاهده شده فراهم می‌آورد. نورانی و همکاران (۲۰۰۹)، برای پیش‌بینی بارش یک ماه بعد حوضه آبریز ليقوان‌چای واقع در آذربایجان شرقی از شبکه عصبی-موجکی استفاده کردند. نتایج نشان داد که مدل شبکه عصبی-موجکی می‌تواند پیش‌بینی بارندگی را در هر دو دوره

Trend

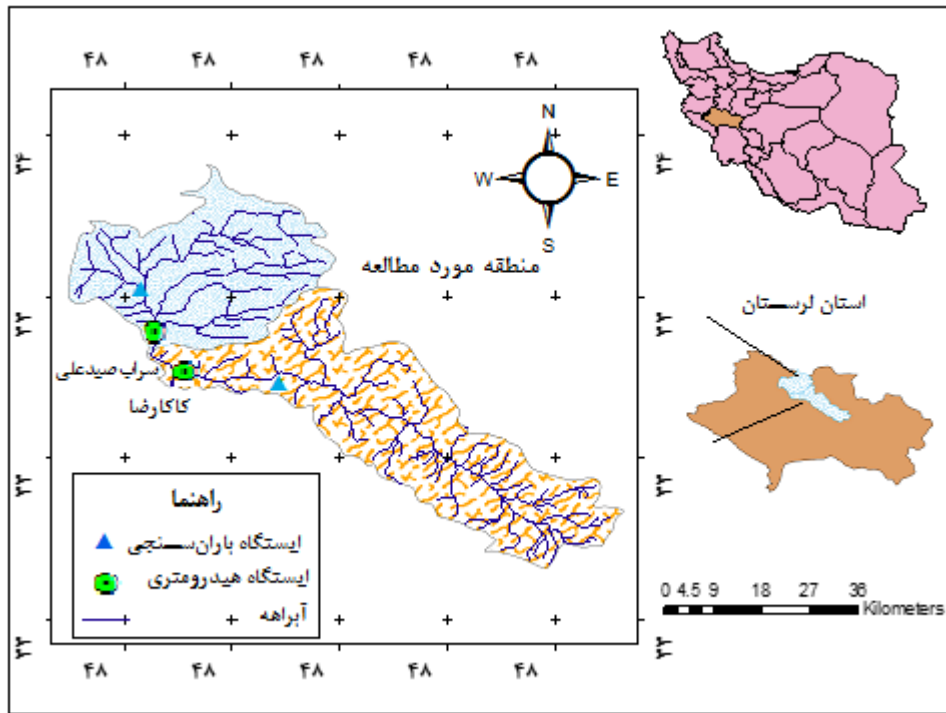
Wavelet

Non Stationary

Drift

مدل‌سازی استفاده شد (۸ سال برای آموزش و ۴ سال برای صحت‌سنجی) که خصوصیات آماری بارندگی و رواناب در مقیاس روزانه و ماهانه برای این حوضه‌ها در جدول ۱ نشان داده شده است (۹).

مربع و در محدوده جغرافیایی $10^{\circ}48'$ و $30^{\circ}48'$ شمالی و $43^{\circ}33'$ و $58^{\circ}33'$ شرقی قرار دارد. طول آبراهه اصلی این حوضه ۳۸ کیلومتر بوده و حداکثر و حداقل ارتفاع این حوضه به ترتیب ۹۶۸ و ۲۹۰۵ متر از سطح آزاد دریا می‌باشد (شکل ۱). در این تحقیق، از سری زمانی ۱۲ ساله (۱۳۸۰-۱۳۹۲) برای فرآیند



شکل (۱): منطقه مورد مطالعه.


جدول (۱): مشخصات آماری داده‌های بارندگی و رواناب در منطقه مورد مطالعه

رواناب (مترمکعب بر ثانیه)				بارندگی (میلی‌متر)			مقیاس زمانی	منطقه مورد مطالعه
انحراف از معیار	میانگین	حداقل	حداکثر	انحراف از معیار	میانگین	حداقل	حداکثر	
داده‌های آموزش								
۴/۸۶	۶/۴۷	۱	۵۳	۵/۶۸	۱/۳۸	۰	۶۱	روزانه سراب صیدعلی
۲/۸۲	۴/۶۸	۱	۱۵	۴۸/۵۱	۴۰/۹۸	۰	۲۱۹	ماهانه
۱۵/۷۶	۱۰	۰/۷	۲۵۰	۵/۶۵	۱/۴۲	۰	۶۲	روزانه کاکارضا
۱۱/۷۰	۹/۳۳	۰/۶۷	۶۳/۲۸	۵۷/۹۴	۴۲/۵۲	۰	۲۵۷	ماهانه
داده‌های صحت‌سنجی								
۳/۴۴	۵/۷۵	۰/۷	۲۵	۵/۲	۱/۳۱	۰	۷۳	روزانه سراب صیدعلی
۲/۱	۴	۰/۷	۸/۵۱	۴۷/۴۵	۳۸/۱۴	۰	۱۸۵	ماهانه
۸/۸	۷/۲۸	۰/۴۵	۶۶	۵/۷	۱/۶۷	۰	۸۳	روزانه کاکارضا
۷/۱۶	۷/۴۴	۰/۷۰	۳۲/۴۲	۵۴	۴۷/۸۴	۰	۲۰۴	ماهانه

شبکه عصبی مصنوعی

and et al. 2009). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است (شکل ۲).

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (Nourani



شکل (۲): شبکه عصبی پیش خور سه لایه با الگوریتم آموزش پس انتشار خطا (سلگی، ۱۳۹۳).

متعارف مستلزم به کارگیری راه حل های بسیار طولانی و زمان بر می باشد. یکی از قابلیت های مهم سامانه استنتاج تطبیقی عصبی-فازی درک رفتار غیرخطی یک سیستم می باشد. این روش در سال های اخیر در مسایل مختلف مدیریت منابع آب و خاک مورد استفاده قرار گرفته است (احمدی و همکاران، ۱۳۹۴؛ Nahvinia and et al. 2010). برای مطالعه بیشتر در این بخش به منابع (۱، ۱۴، ۱۸، ۲۳) مراجعه شود.

تبدیل موجک

به هر کمیت متغیر در زمان یا مکان که قابل اندازه گیری باشد، سیگنال گویند. برای تحلیل سیگنال ها، مبدل های ریاضی مورد استفاده قرار می گیرد تا بتوان اطلاعاتی را که از سیگنال های خام به آسانی قابل دسترس نیست، به دست آورد. تبدیل موجک یکی از تبدیل های ریاضی کارآمد در زمینه پردازش سیگنال است. تبدیل موجک تبدیلی است که سیگنال را به یک مجموعه از توابع اساسی سیگنال تجزیه می کند و در حقیقت یک مجموعه تابع اساسی از تأخیر و تغییر در مقیاس موجک مادر بدست می آید (شفاعی و همکاران،

لایه ورودی یک لایه انتقال دهنده و وسیله ای برای تهیه کردن داده ها، لایه خروجی شامل مقادیر پیش بینی شده توسط شبکه و لایه میانی یا مخفی که از گره های پردازشگر تشکیل شده اند، محل پردازش داده ها است. به منظور مطالعه بیشتر در این بخش به منبع (۱۹) مراجعه شود. شبکه هایی که در این پژوهش به منظور الگوبندی دبی روزانه و ماهانه حوضه کرخه در محل ایستگاه های کاکارضا و سراب صیدعلی استفاده شدند از نوع شبکه های پرسپترون^۲ چند لایه است. در این شبکه ها ثابت شده است که از میان الگوریتم های یادگیری، الگوریتم پس انتشار خطا^۳ با ساختار شبکه پیش خور^۴ تعداد سه لایه بطور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه سازی و پیش بینی سری های زمانی هیدرولوژیکی کاربرد دارد (۱۵، Hornik, 1998).

سیستم استنتاج فازی عصبی تطبیقی

سیستم استنتاج فازی عصبی تطبیقی، یک روش نوین در حل مسایل پیچیده ای است که یا الگوریتم مشخصی برای حل آن ها وجود ندارد و یا استفاده از روش های

Back Propagation(BP)

Feed Forward

Node

^۲Perceptron

۱۳۹۲). مزیت مهم تبدیل موجکی این است که اطلاعات زمان و فرکانس را بطور موثری از سیگنال متغیر در زمان استخراج می‌کند. تابع موجک $\psi(t)$ موجک مادر نامیده می‌شود که دارای سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر است (این سه ویژگی شرط لازم برای این است که تابعی بتواند به عنوان تبدیل موجکی عمل کند) که شرط مقبولیت نامیده می‌شود. تابع موجک $\psi(t)$ به شکل ریاضی زیر تعریف می‌شود (Mallat, 1998).

$$\int_{-\infty}^{+\infty} \psi(t) d(t) = 0 \quad (1)$$

از انواع موجک‌های مادر که برای آنالیز سیگنال استفاده می‌شوند می‌توان به موجک سیملت^۱، هار^۲، مرلت^۳، دابچیز^۴، میره^۵ و غیره ... اشاره کرد. $\psi_{(a,b)}(t)$ با استفاده از تأخیر و تغییر مقیاس موجک مادر از فرمول زیر حاصل می‌گردد.

$$\psi_{(a,b)}(t) = |a|^{-0.5} \psi\left(\frac{t-b}{a}\right), \quad a \in R, b \in R, a \neq 0 \quad (2)$$

تبدیل‌های موجکی به دو دسته پیوسته و گسسته تقسیم می‌شوند. هیدرولوژیست‌ها برای کاربردهای عملی، 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. در این مطالعه از موجک‌های مادر haar و db4 استفاده شد. برای این کار ابتدا سری‌های زمانی بارندگی و رواناب در چند مرحله (تا جایی که بسامد سری داده‌ها از بین برود) به چند زیر

سری تجزیه و بعد به عنوان ورودی مدل در نظر گرفته شد. هر چه تعداد مراحل منتخب برای تجزیه بیشتر باشد، سیگنال به همان تعداد به بسامدهای بالا گذرو پایین گذر تجزیه می‌شود و دقت کار افزایش می‌یابد، اما از مرحله‌ای به بعد مقادیر بسامدها تقریباً ثابت باقی می‌ماند (Wang and Ding, 2003). زیر سری‌های جزئی تولید شده بعد از نرمالیزه شدن توسط فرمول زیر به عنوان ورودی‌های شبکه عصبی در زمان t در نظر گرفته می‌شوند.

$$I_i = \frac{(X_i - X_{min})}{(X_{max} - X_{min})} \quad (3)$$

X_i سری زمانی جریان روزانه و X_{max} , X_{min} به ترتیب مینیمم و ماکزیمم جریان روزانه می‌باشند.

عیارهای ارزیابی مدل

در این پژوهش، برای ارزیابی مدل‌های مورد نظر از نمایه‌های ضریب همبستگی و جذر میانگین مربعات خطا استفاده شده است. در روابط زیر، Q_i مقدار مشاهده شده در گام i ام، \hat{Q} مقدار محاسبه شده در همان زمان، n تعداد داده‌ها و \bar{Q} میانگین مقادیر مشاهداتی می‌باشد (روابط ۴ و ۵). هرچه مقدار ضریب همبستگی بالاتر و RMSE کمتر باشد، نتایج دقیق‌تر و قابل اعتمادتر هستند.

$$R = \left(1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2}\right)^{0.5} \quad (4)$$

$$RMSE = \left(\frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{n}\right)^{0.5} \quad (5)$$

نتایج و بحث

نتایج حاصل از مدل ANN و WANN

به منظور مدل‌سازی فرآیند بارش-رواناب حوضه از مدل پرسپترون چندلایه (MLP) با ساختار شبکه پیش‌خور استفاده شد. این نوع مدل شبکه عصبی همراه با الگوریتم پس انتشار خطا در مدل‌سازی پارامترهای

Daubechies (db)

Meyer

Multi-Layer Perceptron

'Sym

Haar

Morlet

هیدرولوژیکی کاربرد وسیعی دارد (۱۵). در این مطالعه، ۴ الگوی ورودی (جدول ۲) برای مدل شبکه عصبی استفاده شد که نتایج آن در جدول ۳ آورده شده است. هر مدل MLP با ۲۰-۳ نرون مخفی در لایه پنهان و الگوریتم آموزش لورنبرگ-مارکوات آموزش دیده شد. ثابت شده است وقتی تعداد نرون‌های لایه مخفی از حد آستانه‌ای بالاتر برود، تاثیر چشمگیری روی عملکرد مدل ندارد (Abrahart and See, 2000). در این مدل سازی براساس معیارهای ارزیابی، مدل در مقیاس زمانی روزانه و ماهانه نتایج چندان خوبی از خود نشان نداد که این امر ممکن است به دلیل وجود سیگنال‌های ناپیدا در داده‌ها باشد. در مرحله بعد با ترکیب آنالیز موجک و مدل ANN، تاثیر نوع موجک مادر و سطح تجزیه بر عملکرد مدل WANN مورد بررسی قرار گرفت. مطالعات نشان می‌دهد موجک‌های مادر Haar، db-4 در مدل سازی بارش - رواناب عملکرد بهتری از خود نشان می‌دهند (Nourani and et al. 2011). بنابراین در این مطالعه سری زمانی داده‌ها با موجک‌های مادر Haar (موجک مادر ساده) و db-4 (موجک مادر پیچیده) در سطوح مختلف تجزیه شد. در ادامه، زیرسری‌های بدست آمده در سطوح مختلف به عنوان ورودی مدل ANN در نظر گرفته شد. در آخر مدل آموزش دیده شده صحت‌سنجی شد که نتایج آن در جدول ۴ آورده شده است. مطابق نتایج، موجک مادر db-4 عملکرد بهتری نسبت به موجک مادر Haar از خود نشان می‌دهد. لازم به ذکر است سطح تجزیه سری‌های زمانی بارش و رواناب یکسان در نظر گرفته شد. سطح تجزیه مناسب با توجه به طول سری داده‌ها از رابطه زیر محاسبه می‌شود (Wang and Ding, 2003):

$$L = \text{int}[\log N] \quad (۶)$$

که در آن N تعداد داده‌های سری زمانی است. این رابطه بدون در نظر گرفتن تناوب داده‌ها، تنها طول سری داده‌ها را تاثیر داده است که این خود ممکن است باعث ایجاد خطا در پیدا کردن سطح تجزیه بهینه شود. برای

رفع این مشکل سطوح مختلف نزدیک به این مقدار در نظر گرفته شد.

نتایج حاصل از مدل ANFIS و WANFIS

از جنبه‌های اولیه و مهم در استفاده از مدل ANFIS، شناخت کامل و صحیح از ساختار آن است. استفاده از ساختار نامناسب در مدل سبب محاسبات نادرست و بیش از حد می‌شود (Nourani and Komasi, 2013). به منظور تعیین ساختار مناسب مدل ANFIS پارامترهای هیدرولوژیکی بارندگی و رواناب با تأخیرهای زمانی مختلف (Q, I) به عنوان ورودی به مدل داده شد (جدول ۲). شکل ۳ نتایج ارزیابی الگوهای مختلف ورودی مدل ANFIS را نشان می‌دهد. مطابق این شکل، الگوی ورودی ۱ برای ایستگاه‌های کاکارضا و سراب صیدعلی در مقیاس روزانه مناسب نیست. از طرفی الگوی ورودی ۲ نسبت به الگوی ورودی ۳ و ۴ به ترتیب ۲ و ۴ پارامتر ورودی کمتر دارد و نتایج آن نیز رضایت بخش‌تر است. بنابراین الگوی ورودی ۲ با تابع عضویت زنگوله‌ای، به عنوان الگوی مناسب پیش‌بینی برای ایستگاه‌های کاکارضا و سراب صیدعلی در مقیاس روزانه انتخاب شد. برای مقیاس ماهانه، الگوهای ورودی ۱ و ۲ عملکرد ضعیفی در پیش‌بینی رواناب از خود نشان دادند. الگوی ورودی ۳ با تابع عضویت زنگوله‌ای با عملکرد بهتر و تعداد پارامتر کمتر نسبت به الگوی ورودی ۴ می‌تواند به عنوان الگوی مناسب جهت مدل سازی انتخاب شود. علاوه بر این، با آموزش ساختارهای مختلف مدل ANFIS با تعداد تکرارهای مختلف، نتیجه شد که تعداد ۲۰۰ تکرار برای آموزش ساختار مدل ANFIS مناسب است. ساختارهای مناسب الگوبندی جریان در مدل ANFIS برای ادامه کار با مدل WANFIS به کار گرفته شد. همان‌طور که در بالا نیز ذکر شد برای داده‌های روزانه الگوی ورودی ۲ و برای داده‌های ماهانه الگوی ورودی ۳ انتخاب شد. در ادامه، به منظور ارزیابی مدل WANFIS زیرسری‌های بدست آمده در سطوح مختلف به عنوان ورودی مدل ANFIS در نظر گرفته شد. جدول ۵ نتایج ارزیابی مدل WANFIS را نشان می‌دهد. مطابق نتایج، با افزایش سطح تجزیه تا مقدار

سرآب صیدعلی و کاکارضا، موجک مادر db-4 به ترتیب با سطح تجزیه ۵ و ۶ عملکرد بهتری دارد. برای داده‌های ماهانه نیز موجک مادر db-4 با سطح تجزیه ۳ مناسب دیده شد.

آستانه مشخصی، عملکرد مدل رو به بهبود بوده و بعد از آن کاهش پیدا می‌کند. به عنوان مثال برای داده‌های روزانه ایستگاه سرآب صیدعلی مدل تا سطح تجزیه ۵ عملکرد افزایشی دارد اما در سطوح ۶ و ۷ عملکرد مدل روند کاهشی دارد. برای داده‌های روزانه ایستگاه‌های

جدول (۲): الگوهای ورودی مورد استفاده در مقیاس زمانی روزانه و ماهانه

ردیف	الگوی ورودی مدل
الگوی ورودی ۱	$Q(t), Q(t-1), I(t), I(t-1)$
الگوی ورودی ۲	$Q(t), Q(t-1), Q(t-2), I(t), I(t-1), I(t-2)$
الگوی ورودی ۳	$Q(t), Q(t-1), Q(t-2), Q(t-3), I(t), I(t-1), I(t-2), I(t-3)$
الگوی ورودی ۴	$Q(t), Q(t-1), Q(t-2), Q(t-3), Q(t-4), I(t), I(t-1), I(t-2), I(t-3), I(t-4)$

جدول (۳): نتایج حاصل از مدل ANN در مقیاس روزانه و ماهانه

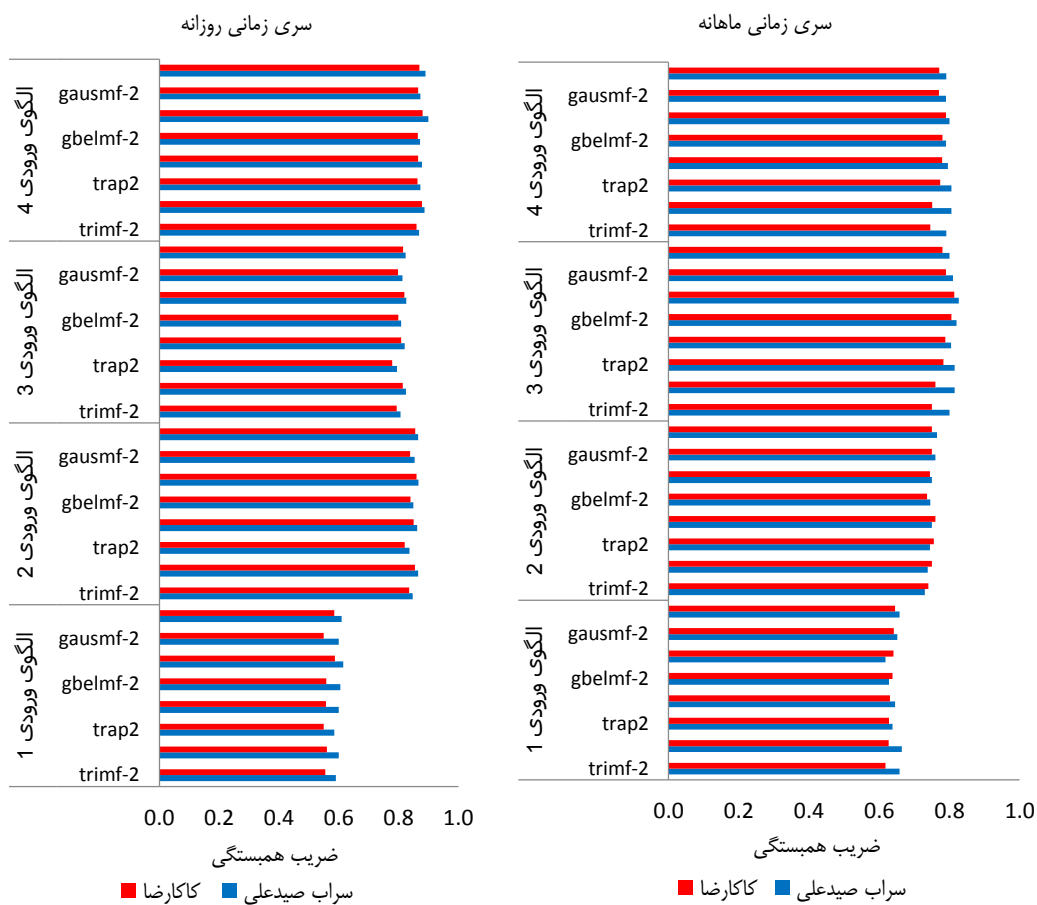
ضریب تعیین (R^2)		متغیرهای ورودی	ساختار شبکه	مقیاس زمانی مدل‌سازی	منطقه مورد مطالعه
صحت سنجی	آموزش				
۰/۷۲	۰/۷۵	$Q(t), Q(t-1)$	(۲، ۹، ۱)	روزانه	سرآب صیدعلی
۰/۶۵	۰/۷۲		(۲، ۱، ۶)	ماهانه	
۰/۷۱	۰/۸۱	$I(t), I(t-1)$	(۲، ۱۰، ۱)	روزانه	کاکارضا
۰/۶۷	۰/۷۲		(۲، ۷، ۱)	ماهانه	
۰/۷۶	۰/۸۰	$Q(t), Q(t-1), Q(t-2)$	(۴، ۱۱، ۱)	روزانه	سرآب صیدعلی
۰/۷۱	۰/۷۵		(۴، ۷، ۱)	ماهانه	
۰/۷۶	۰/۸۰	$I(t), I(t-1), I(t-2)$	(۴، ۱۲، ۱)	روزانه	کاکارضا
۰/۶۹	۰/۷۵		(۴، ۹، ۱)	ماهانه	
۰/۷۸	۰/۸۳	$Q(t), Q(t-1), Q(t-2), Q(t-3)$	(۶، ۱۴، ۱)	روزانه	سرآب صیدعلی
۰/۷۳	۰/۷۸		(۶، ۹، ۱)	ماهانه	
۰/۷۷	۰/۸۳	$I(t), I(t-1), I(t-2), I(t-3)$	(۶، ۱۳، ۱)	روزانه	کاکارضا
۰/۷۱	۰/۷۶		(۶، ۱۰، ۱)	ماهانه	
۰/۷۸	۰/۸۱	$Q(t), Q(t-1), Q(t-2), Q(t-3), Q(t-4)$	(۸، ۱۵، ۱)	روزانه	سرآب صیدعلی
۰/۷۲	۰/۷۹		(۸، ۱۱، ۱)	ماهانه	
۰/۷۵	۰/۸۳	$I(t), I(t-1), I(t-2), I(t-3), Q(t-4)$	(۸، ۱۲، ۱)	روزانه	کاکارضا
۰/۷۳	۰/۷۷		(۸، ۹، ۱)	ماهانه	

جدول (۴): نتایج حاصل از مدل WANN در مقیاس روزانه و ماهانه

ماهانه				روزانه			
صحت‌سنجی		آموزش	موجک	صحت‌سنجی		آموزش	موجک
R^2	RMSE	R^2	مادر	R^2	RMSE	R^2	مادر
			تجزیه $i=j$				تجزیه $i=j$
منطقه مورد مطالعه (۱): سرآب صیدعلی				منطقه مورد مطالعه (۱): سرآب صیدعلی			
۰/۸۴	۰/۰۷۵	۰/۸۷	۲	۰/۸۸	۰/۰۷۰	۰/۹۲	۴

۰/۸۷	۰/۰۷۱	۰/۸۹	۰/۰۶۳	۳	Db-4	۰/۸۹	۰/۰۶۵	۰/۹۴	۰/۰۵۵	۵	Db-4
۰/۸۵	۰/۰۷۴	۰/۸۸	۰/۰۶۵	۴	Db-4	۰/۸۸	۰/۰۷۰	۰/۸۸	۰/۰۶۱	۶	Db-4
۰/۸۵	۰/۰۷۳	۰/۸۸	۰/۰۶۸	۵	Db-4	۰/۸۹	۰/۰۶۷	۰/۹۴	۰/۰۵۵	۷	Db-4
۰/۸۴	۰/۰۷۷	۰/۸۶	۰/۰۶۴	۲	Haar	۰/۸۸	۰/۰۷۳	۰/۹۱	۰/۰۶۰	۴	Haar
۰/۸۶	۰/۰۷۷	۰/۸۸	۰/۰۶۶	۳	Haar	۰/۸۶	۰/۰۷۶	۰/۸۹	۰/۰۶۱	۵	Haar
۰/۸۵	۰/۰۷۶	۰/۸۸	۰/۰۶۷	۴	Haar	۰/۸۹	۰/۰۷۳	۰/۹۳	۰/۰۵۷	۶	Haar
۰/۸۷	۰/۰۷۴	۰/۸۹	۰/۰۶۵	۵	Haar	۰/۸۹	۰/۰۷۳	۰/۹۱	۰/۰۵۹	۷	Haar
منطقه مورد مطالعه (۲): کاکارضا						منطقه مورد مطالعه (۲): کاکارضا					
۰/۸۷	۰/۰۷۴	۰/۹۰	۰/۰۶۱	۲	Db-4	۰/۹۱	۰/۰۶۵	۰/۹۳	۰/۰۵۶	۴	Db-4
۰/۸۹	۰/۰۷۰	۰/۹۱	۰/۰۵۹	۳	Db-4	۰/۹۲	۰/۰۶۴	۰/۹۴	۰/۰۵۴	۵	Db-4
۰/۸۵	۰/۰۷۳	۰/۸۹	۰/۰۶۰	۴	Db-4	۰/۹۰	۰/۰۶۵	۰/۹۲	۰/۰۵۷	۶	Db-4
۰/۸۶	۰/۰۷۱	۰/۸۵	۰/۰۶۰	۵	Db-4	۰/۸۷	۰/۰۶۹	۰/۹۱	۰/۰۵۷	۷	Db-4
منطقه مورد مطالعه (۲): کاکارضا						منطقه مورد مطالعه (۲): کاکارضا					
۰/۸۳	۰/۰۸۳	۰/۸۷	۰/۰۶۴	۲	Haar	۰/۸۴	۰/۰۸۵	۰/۸۹	۰/۰۶۰	۴	Haar
۰/۸۵	۰/۰۸۰	۰/۸۷	۰/۰۶۴	۳	Haar	۰/۹۰	۰/۰۷۸	۰/۸۹	۰/۰۶۰	۵	Haar
۰/۸۶	۰/۰۷۹	۰/۸۶	۰/۰۶۶	۴	Haar	۰/۸۹	۰/۰۷۶	۰/۹۱	۰/۰۵۸	۶	Haar
۰/۸۵	۰/۰۸۰	۰/۸۸	۰/۰۶۰	۵	Haar	۰/۸۹	۰/۰۷۸	۰/۹۲	۰/۰۵۶	۷	Haar

شکل (۳): نتایج حاصل از مدل ANFIS در مقیاس های روزانه و ماهانه.



جدول (۵): نتایج حاصل از مدل WANFIS در مقیاس روزانه و ماهانه (trimf: تابع عضویت مثلثی، trap: تابع عضویت

دو زنگه‌ای، gbelmf: تابع عضویت زنگوله‌ای)

ماهانه						روزانه					
صحت‌سنجی		آموزش		سطح	موجک	صحت‌سنجی		آموزش		سطح	موجک
R ²	RMSE	R ²	RMSE	تجزیه i=j	مادر	R ²	RMSE	R ²	RMSE	تجزیه i=j	مادر
منطقه مورد مطالعه (۱): سراب صیدعلی						منطقه مورد مطالعه (۱): سراب صیدعلی					
۰/۸۷	۰/۰۶۲	۰/۹۱	۰/۰۵۰	۲	Db-4	۰/۸۸	۰/۰۵۶	۰/۹۶	۰/۰۳۷	۴	Db-4
۰/۹۰	۰/۰۵۷	۰/۹۳	۰/۰۴۶	۳	Db-4	۰/۹۳	۰/۰۴۸	۰/۹۸	۰/۰۳۲	۵	Db-4
۰/۹۰	۰/۰۵۷	۰/۹۰	۰/۰۴۸	۴	Db-4	۰/۹۲	۰/۰۵۳	۰/۹۷	۰/۰۳۴	۶	Db-4
۰/۸۵	۰/۰۶۴	۰/۸۹	۰/۰۵۰	۵	Db-4	۰/۹۰	۰/۰۵۳	۰/۹۷	۰/۰۳۵	۷	Db-4
۰/۸۸	۰/۰۶۶	۰/۸۷	۰/۰۴۹	۲	Haar	۰/۸۸	۰/۰۵۸	۰/۹۳	۰/۰۴۴	۴	Haar
۰/۸۶	۰/۰۶۹	۰/۹۱	۰/۰۴۸	۳	Haar	۰/۸۶	۰/۰۶۴	۰/۹۵	۰/۰۴۲	۵	Haar
۰/۸۲	۰/۰۷۴	۰/۹۲	۰/۰۵۰	۴	Haar	۰/۸۸	۰/۰۶۲	۰/۹۶	۰/۰۴۰	۶	Haar
۰/۸۴	۰/۰۷۱	۰/۹۰	۰/۰۵۰	۵	Haar	۰/۹۱	۰/۰۵۷	۰/۹۴	۰/۰۴۰	۷	Haar
منطقه مورد مطالعه (۲): کاکارضا						منطقه مورد مطالعه (۲): کاکارضا					
۰/۸۶	۰/۰۶۷	۰/۸۹	۰/۰۴۷	۲	Db-4	۰/۸۷	۰/۰۵۸	۰/۹۱	۰/۰۴۲	۴	Db-4
۰/۹۱	۰/۰۶۱	۰/۹۲	۰/۰۴۵	۳	Db-4	۰/۸۸	۰/۰۶۰	۰/۹۵	۰/۰۴۰	۵	Db-4
۰/۸۷	۰/۰۶۵	۰/۹۱	۰/۰۴۷	۴	Db-4	۰/۹۲	۰/۰۵۲	۰/۹۶	۰/۰۳۹	۶	Db-4
۰/۸۹	۰/۰۶۳	۰/۹۲	۰/۰۴۷	۵	Db-4	۰/۹۰	۰/۰۵۷	۰/۹۶	۰/۰۳۹	۷	Db-4
۰/۸۵	۰/۰۶۹	۰/۸۹	۰/۰۴۹	۲	Haar	۰/۹۰	۰/۰۶۱	۰/۸۹	۰/۰۴۳	۴	Haar
۰/۸۷	۰/۰۶۸	۰/۹۰	۰/۰۴۸	۳	Haar	۰/۸۳	۰/۰۷۰	۰/۹۳	۰/۰۴۲	۵	Haar
۰/۹۰	۰/۰۶۶	۰/۹۱	۰/۰۴۷	۴	Haar	۰/۸۸	۰/۰۶۳	۰/۹۴	۰/۰۳۹	۶	Haar
۰/۸۸	۰/۰۶۷	۰/۹۱	۰/۰۴۶	۵	Haar	۰/۸۷	۰/۰۶۴	۰/۹۴	۰/۰۳۹	۷	Haar

مقایسه نتایج

را تا مقدار چشمگیری افزایش دهد. این نکته نیز قابل ذکر است که تبدیل موجک روی نتایج مدل ANN تاثیر بیشتری داشته و نتایج آن را نسبت به مدل ANFIS تا حد بالاتری بهبود داده است. همچنین طبق نتایج، داده‌های ماهانه با وجود انحراف از معیار کمتر نسبت به داده‌های روزانه نتایج ضعیف‌تری را از خود نشان می‌دهد که از دلایل این مورد می‌توان به طول کمتر سری زمانی داده‌های ماهانه نسبت به داده‌های روزانه اشاره کرد. در واقع می‌توان گفت هرچه طول داده‌های مدل‌سازی بیشتر باشد آموزش مدل بهتر بوده و نتایج رضایت بخش‌تر است. در مجموع، با توجه به نتایج جدول ۶ مشاهده می‌شود برای الگوبندی‌های





جدول ۶ مقایسه شاخص‌های آماری مربوط به نتایج حاصل از کاربرد روش‌های ANN، WANN، ANFIS، و WANFIS در الگوبندی جریان روزانه و ماهانه را برای الگوهای مختلف ورودی نشان می‌دهد. نتایج حاکی از آن است که مدل شبکه عصبی مصنوعی به عنوان یک مدل غیرخطی دقت کمتری نسبت به مدل‌های هیبریدی دارد. در این مدل، با ترکیب آنالیز موجک به عنوان یک روش ترکیبی به خوبی می‌توان سیگنال سری داده‌ها را پردازش کرده و نتایج را تا سطح قابل قبولی بهبود داد. در مدل ANFIS نیز وضع همین‌گونه بوده و آنالیز موجک به خوبی توانسته نتایج

نمودارهای پراکندگی و مقادیر مشاهده‌ای و پیش‌بینی حاصل از بهترین الگوی WANFIS برای ایستگاه‌های سراب صیدعلی و کاکارضا را نشان می‌دهد.

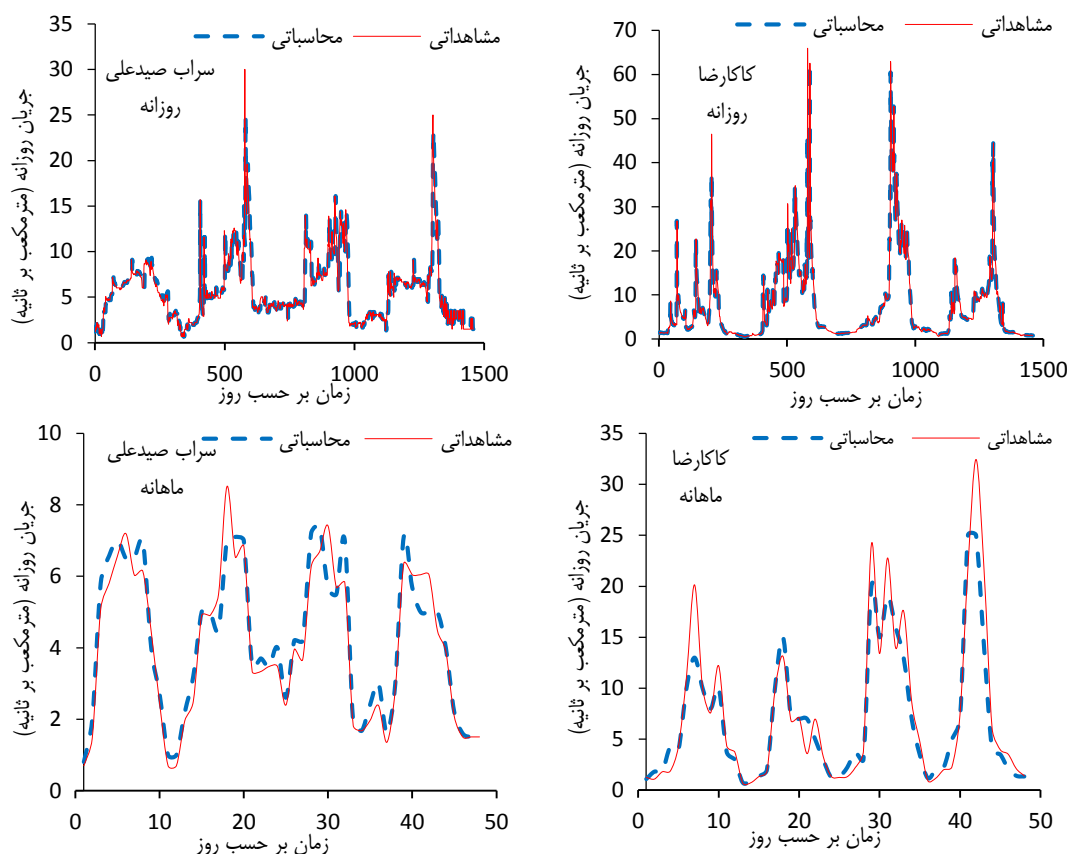
روزانه و ماهانه در هر دو ایستگاه سراب صیدعلی و کاکارضا، مدل WANFIS کمترین خطا و بیشترین دقت را داشته است، به عنوان بهترین مدل جهت مدل‌سازی انتخاب شد. شکل ۴ و ۵ به ترتیب

جدول (۶): مقایسه مدل‌های مختلف بارش-رواناب

کاکارضا		سراب صیدعلی		منطقه مورد مطالعه	
معیار ارزیابی (R ²)		معیار ارزیابی (R ²)		نوع مدل	مدل
آموزش	صحت سنجی	آموزش	صحت سنجی		
روزانه					
۰/۷۷	۰/۸۳	۰/۷۸	۰/۸۳	غیر خطی	ANN
۰/۹۲	۰/۹۴	۰/۸۹	۰/۹۴	هیبریدی	WANN
۰/۸۶	۰/۸۹	۰/۸۷	۰/۹۱	هیبریدی	ANFIS
۰/۹۲	۰/۹۶	۰/۹۳	۰/۹۸	هیبریدی	WANFIS
ماهانه					
۰/۷۲	۰/۷۶	۰/۷۳	۰/۷۸	غیر خطی	ANN
۰/۸۹	۰/۹۱	۰/۸۷	۰/۸۹	هیبریدی	WANN
۰/۸۱	۰/۸۸	۰/۸۳	۰/۸۷	هیبریدی	ANFIS
۰/۹۱	۰/۹۲	۰/۹۰	۰/۹۳	هیبریدی	WANFIS



شکل (۴): نمودار پراکندگی جریان حاصل از بهترین مدل WANFIS در مرحله صحت سنجی



شکل (۵): نمودار مقادیر مشاهداتی و پیش‌بینی شده جریان حاصل از بهترین مدل WANFIS در مرحله صحت سنجی

تقدیر و تشکر

نویسندگان بر خود ضروری می‌دانند، از سازمان آب منطقه‌ای لرستان به دلیل در اختیار گذاشتن اطلاعات این مطالعه، و از سازمان آب و برق خوزستان و شرکت بهره‌بردار، تولید و انتقال آب غدیر خوزستان به خاطر حمایت‌های لازم، کمال تشکر و قدردانی را بعمل آورند.

نتیجه‌گیری

تعیین جریان رودخانه‌ها یکی از مؤلفه‌های مهم و تأثیرگذار در مدیریت منابع آب حوضه آبریز می‌باشد. مطالعه این پدیده هیدرولوژیکی دارای کاربردهای فراوانی از جمله در زمینه پیش‌بینی سیلاب است. در این مطالعه از تبدیل موجک به منظور پردازش سیگنال‌های داده‌های بارندگی و رواناب حوضه‌های سراب صیدعلی و کاکارضا استفاده شد. برای سری زمانی روزانه بهترین عملکرد سیستم استنتاج فازی

عصبی تطبیقی-موجک با سه تأخیر زمانی در ورودی‌های مدل، تابع عضویت زنگوله‌ای و سطح تجزیه پنج بدست آمد. ضریب همبستگی و جذر میانگین مربعات خطا برای این الگو به ترتیب $0/93$ و $0/048$ برای ایستگاه سراب صیدعلی و $0/92$ و $0/052$ برای ایستگاه کاکارضا محاسبه گردید. برای داده‌های ماهانه نیز مدل سیستم استنتاج فازی عصبی تطبیقی - موجک با چهار تأخیر زمانی در ورودی‌های مدل، تابع عضویت زنگوله‌ای و سطح تجزیه سه با بهترین عملکرد انتخاب گردید. ضریب همبستگی و میانگین مربعات مجذور خطا برای این الگو به ترتیب $0/90$ و $0/058$ برای ایستگاه سراب صیدعلی و $0/91$ و $0/061$ برای ایستگاه کاکارضا بدست آمد. ارزیابی عملکرد مدل‌های مورد استفاده نشان می‌دهد که مدل‌سازی تا تأخیر و سطح تجزیه مشخصی رو به بهبود بوده و از آن به بعد کاهش می‌یابد. پیشنهاد می‌شود در پژوهش‌های آینده از دیگر الگوهای هوش مصنوعی از جمله برنامه‌ریزی ژن و ماشین بردار

پشتیبان نیز در الگوبندی جریان رودخانه در مقیاس‌های زمانی روزانه و ماهانه و سایر پارامترهای هیدرولوژیکی استفاده شود.

منابع

- احمدی، ف.س.، آیشم، ک.خلیلی، ج. بهمنش. ۱۳۹۴. کاربرد سیستم‌های استنتاج عصبی - فازی تطبیقی و برنامه‌ریزی ژنتیک برای برآورد تبخیر تعرق ماهانه در شمال غرب ایران. نشریه پژوهش آب در کشاورزی. (۲) ۲۹/۲: ۲۳۵-۲۴۷.
- نیک منش، محمدرضا. ۱۳۹۴. پیش‌بینی آبدهی متوسط ماهانه با استفاده از مدل تلفیقی شبکه عصبی مصنوعی و تبدیلات موجک (مطالعه موردی: رودخانه کر- ایستگاه پل خان). مجله پژوهش‌های حفاظت آب و خاک. (۳) ۲۲: ۲۳۹-۲۳۱.
- سلگی، اباذر. ۱۳۹۳. پیش‌بینی جریان رودخانه با مدل ترکیبی شبکه عصبی موجک و مقایسه آن با روش‌های سیستم استنتاج فازی-عصبی تطبیقی و شبکه عصبی مصنوعی (مطالعه موردی: رودخانه گاماسیاب نهاوند). پایان‌نامه کارشناسی ارشد. دانشگاه شهید چمران اهواز.
- سلگی، ا.، رادمنش، ف.، سلطانی، ک. ۱۳۹۴. مدل‌سازی هوشمند سری زمانی جریان ماهانه حوضه رودخانه شور قروه با استفاده از شبکه عصبی مصنوعی. مجله پژوهش‌های حفاظت آب و خاک. (۱) ۲۲: ۳۰۹-۳۱۸.
- شجاع رستگاری، ح.، غ. غ.، بارانی. ۱۳۹۰. بکارگیری سیستم فازی - عصبی تطبیقی در مدل‌سازی بارش - رواناب. اولین همایش منطقه ای توسعه منابع آب، ابرکوه، دانشگاه آزاد اسلامی واحد ابرکوه.
- شفائی، م.، فاخری فرد، ص.، دربندی، م. ع. قربانی. ۱۳۹۲. پیش‌بینی جریان روزانه رودخانه با استفاده از مدل هیبرید موجک و شبکه عصبی؛ مطالعه موردی ایستگاه هیدرومتری ونیار در حوضه آبریز آجی چای. فصلنامه علمی پژوهشی مهندسی آبیاری و آب. (۱۴) ۱۱۳-۱۲۸: ۴.
- طوفانی، پ. ا.، مساعدی، ا.، فاخری فرد. ۱۳۹۰. پیش‌بینی بارندگی با استفاده مستقیم از نظریه موجک (مطالعه موردی: ایستگاه باران سنجدی زرینگل استان گلستان). نشریه آب و خاک. (۵) ۲۴: ۱۲۲۶-۱۲۱۷.
- عبداله‌پور آزاد، م. ر.، م. ت. سناری. ۱۳۹۴. پیش‌بینی جریان روزانه رودخانه اهرچای با استفاده از روش‌های شبکه‌های عصبی مصنوعی (ANN) و مقایسه آن با سیستم استنتاج فازی-عصبی تطبیقی (ANFIS). نشریه پژوهش‌های حفاظت آب و خاک. (۱) ۲۲: ۲۸۷-۲۹۸.
- عراقی نژاد، ش.، م. کارآموز. ۱۳۸۴. پیش‌بینی بلند مدت رواناب با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی. نشریه تحقیقات منابع آب ایران. (۲) ۴۱-۲۹: ۱.
- غفاری، غ. ع.، م. وفاخواه. ۱۳۹۲. شبیه‌سازی فرآیند بارش- رواناب با استفاده از شبکه عصبی مصنوعی و سیستم فازی-عصبی تطبیقی (مطالعه موردی: حوزه آبخیز حاجی قوشان). پژوهش‌نامه مدیریت حوزه آبخیز. (۸) ۴: ۱۲۰-۱۳۶.
- مساعدی، ا.، م. قبائی سوق. ۱۳۹۰. برآورد تبخیر روزانه از تشت تبخیر با استفاده از سیستم استنتاج تطبیقی عصبی- فازی. مجله پژوهش آب ایران. (۸) ۵: ۱۶۱-۱۷۰.
- نحوی‌نیا، م. ج.، ع. لیاقت. م.، پارسی نژاد. ۱۳۸۹. کاربرد مدل‌های تجربی و آماری در پیش‌بینی میزان نفوذ آب در آبیاری جویچه‌ای. نشریه آب و خاک. (۴) ۷۸۰-۷۶۹: ۲۴.
- وزارت نیرو. دفتر مطالعات، گزارش هیدروژئولوژی و زمین‌شناسی. ۱۳۹۲.

Abrahart, R.J., L. See. 2000. Comparing neural network (NN) and Auto Regressive Moving Average (ARMA) techniques for the provision of continuous river flow forecasts in two contrasting catchment. *Hydrology Process*, 14:2157-2172.

Altunkaynak, A. 2007. Forecasting surface water level fluctuations of Lake Van by artificial neural networks. *Water Resource Management*, 21:399-408.

- Aqil, M., I.Kita, A. Yano, S.Nishiyama. 2007. Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool. *J. Environ. Manage*, 85:215–223.
- Govindaraju, R.S. 2000. Artificial Neural Networks in Hydrology. II: Hydrologic Applications. *J. Hydrol. Eng*, 5(2):124–137.
- Bierkens, M.F.B. 1988. Modeling water table fluctuations by means of a stochastic differential equation. *J. of Water Resources Research*, 34(10):2485–2499.
- Hornik, K. 1988. Multilayer feed-forward networks are universal approximates Neural Networks, 2(5):359–366.
- Jang, J.S.R., C.T.Sun, E. Mizutani. 1997. *Neuro-fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Third ed. Prentice-Hall, New Jersey.
- Kim, T., J.B. Valdes. 2003. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *J. Hydrol. Eng*, 8(6):319–328.
- Mallat, S.G. 1998. *A Wavelet Tour of Signal Processing*, second ed. Academic Press, San Diego.
- Nayak, P.C., K.P.Sudheer, D.M. Rangan, K.S. Ramasastri. 2005. Short-term flood forecasting with a neurofuzzy model. *Water Resources Research*, 41(4):2517-2530.
- Nourani, V., M.T. Alami, M.H. Aminfar. 2009. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, 22:466–472.
- Nourani, V., M.Komasi. 2013. A geomorphology-based ANFIS model for multi-station modeling of rainfall–runoff process. *Journal of Hydrology*, 490:41–55.
- Nourani, V., Ö. Kisi, M. Komasi. 2011. Two hybrid artificial intelligence approaches for modeling rainfall–runoff process. *Journal of Hydrology*, 402(1-2):41–59.
- Partal, T., O.Kisi. 2007. Wavelet and neruro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology*, 342:199-212.
- Polikar, R. 1996. *Fundamental Concept and an Overview of the Wavelet Theory Wavelet Tutorial*. Second Edition. Rowan University. College of Engineering Web Servers. Glassboro, NJ.08028.
- Sifuzzaman M., M.R. Islam, M.Z.Ali. 2009. Application of Wavelet Transform and its advantages Compared to Fourier Transform. *Journal of Physical Sciences*, 13:121-134.
- Solgi, A., V.Nourani, A. Pourhaghi. 2014. Forecasting Daily Precipitation Using Hybrid Model of Wavelet-Artificial Neural Network and Comparison with Adaptive Neuro-Fuzzy Inference System (Case Study: Verayneh Station, Nahavand). *Advances in Civil Engineering*, 1-12.
- Thuillard, M. 2000. A review of wavelet networks, wavelets, fuzzy wavelets and their application. ESIT.in: Presented in Conference, 14-15 September 2000.
- Wang, W., S.Ding. 2003. Wavelet network model and its application to the predication of hydrology. *Nat. Sci*, 1(1):67–71.

Hybrid Usage of the Wavelet transform and Intelligent to Simulation River Flow (Case Study: KaKa Reza and Sarab seyed Ali rivers)

Amir Pourhaghi¹, Abazar Solgi², Freidon Radmanesh^{*3}, Mehrnoush Shehni Darabi⁴.

Abstract

Undoubtedly, the first step for managing water resources is predicting river flow accurately. In This study, to predict daily and monthly time series of Kakareza and Sarab seyed ali stations, artificial neural network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS) models was used. In order to improve the simulation results, wavelet analysis was used as a hybrid model. For this purpose, the daily and Monthly time series of rainfall and runoff for 12 years (2001-2013) were decomposed into sub-signals in various resolution levels using wavelet analysis and then these sub-signals entered to the ANN and ANFIS models as input. The results showed that ANFIS model has a higher accuracy with less error rate and more correlation coefficient than ANN model and Wavelet Transform Improves simulation results.

Keyword: ANN, ANFIS, Wavelet Transform, Rainfall-Runoff.

Corresponding Author Email: freidon_radmanesh@yahoo.com.

1- Ph.D. Student, Department of Water Resources Engineering, Faculty of Water Sciences, Shahid Chamran University of Ahvaz, Iran. Pourhaghiamir@yahoo.com

2- Ph.D. Student, Department of Water Resources Engineering, Faculty of Water Sciences, Shahid Chamran University of Ahvaz, Iran. A-solgi@phdstu.scu.ac.ir.

3-Associate Professor, Department of Hydrology and Water Resources, Faculty of Water Sciences, Shahid Chamran University of Ahvaz, Iran. freidon_radmanesh@yahoo.com

4- Ph.D. Student, Department of Water Resources Engineering, Faculty of Water Sciences, Shahid Chamran University of Ahvaz and Quality Control Expert, Water Transfer and Utilization of Ghadir Company of Khuzestan, Ahvaz, Iran. shahnidarabi.mehrnoush@gmail.com