

پیش‌بینی دبی متوسط روزانه جریان رودخانه بهشت‌آباد با استفاده از آنالیز موجک

سجاد عبداللہی اسدآبادی^{۱*} - یعقوب دین‌پژوه^۲ - رسول میرعباسی نجف‌آبادی^۳

تاریخ دریافت: ۱۳۹۲/۹/۱۶

تاریخ پذیرش: ۱۳۹۳/۲/۹

چکیده

پیش‌بینی دبی رودخانه‌ها یکی از موارد کلیدی در برنامه‌ریزی و مدیریت منابع آب می‌باشد. در این مطالعه از دو روش مبتنی بر آنالیز موجک و شبکه عصبی مصنوعی (ANN) به منظور پیش‌بینی دبی جریان رودخانه بهشت‌آباد استفاده شد. بدین منظور، داده‌های دبی متوسط روزانه رودخانه مذکور و اطلاعات بارش روزانه مربوط به ۱۷ ایستگاه هواشناسی در طول دوره آماری ۲۰۰۸-۱۹۹۹ استفاده گردید. در روش اول موسوم به روش موجک متقاطع (CW)، از موجک مختلط مورلت به عنوان تابع آنالیزگر استفاده شد. تجزیه موجک برای هر یک از سری‌های زمانی مجموع بارش روزانه و دبی متوسط روزانه جریان بصورت جداگانه انجام گرفت. مدل دبی جریان به ازای افق‌های پیش‌بینی ۱ روز، ۲ روز، ۳ روز و ۷ روز جلوتر بسط داده شد. در روش دوم موسوم به روش تلفیقی موجک و شبکه عصبی (WNN)، ابتدا با استفاده از موجک گسسته میر، پردازش اولیه بر روی ماتریس ورودی اولیه انجام گرفت. سپس با نرمالسازی دریاچه‌های ماتریس ورودی اولیه، ماتریس ورودی ثانویه تشکیل گردد. ماتریس ورودی ثانویه و ماتریس هدف به یک شبکه سه لایه پیشخور با الگوریتم پس‌انتشار (FFBP) اعمال شدند. آموزش شبکه با استفاده از تابع آموزش لونیبرگ مارکوارت (LM) انجام گرفت. نهایتاً، پیش‌بینی جریان به ازای افق‌های زمانی کوتاه‌مدت انجام شد. نتایج نشان داد پیش‌بینی‌های مدل WNN در مقایسه با مدل‌های ANN و CW از دقت بالاتری برخوردار می‌باشد. در مرحله تست، در مدل CW با کاهش افق پیش‌بینی از ۷ روز به ۱ روز مقدار آماره R^2 از ۰/۵۱۱۳ به ۰/۹۳۸۸ افزایش و مقدار آماره RMSE از ۱۷/۹۱۷۱ به ۸/۳۲۲۶ مترمکعب بر ثانیه کاهش می‌یابد. در مدل ANN با کاهش افق پیش‌بینی از ۷ روز به ۱ روز مقدار آماره R^2 از ۰/۶۷۰۵ به ۰/۹۱۶۶ افزایش و مقدار آماره RMSE از ۵/۹۸۲۸ به ۲/۵۶۰۰ مترمکعب بر ثانیه کاهش یافت. در حالی که در مدل WNN با کاهش افق پیش‌بینی از ۷ روز به ۱ روز مقدار آماره R^2 از ۰/۸۴۲۴ به ۰/۹۹۲۷ افزایش و مقدار آماره RMSE از ۳/۴۶۷۸ به ۰/۸۱۴۵ مترمکعب بر ثانیه کاهش یافت.

واژه‌های کلیدی: پیش‌بینی، دبی جریان رودخانه، موجک متقاطع، شبکه عصبی مصنوعی

مقدمه

چندین ماه هم در نظر گرفته شود (۱۴). روابط ریاضی و فیزیکی برای پیش‌بینی‌های کوتاه‌مدت بیشتر مورد توجه قرار گرفته و قابلیت شبیه‌سازی بهتری دارند. در مقابل پیش‌بینی‌های بلندمدت به علل مختلف دارای خطای بالای بوده و از پیچیدگی‌های بیشتری در مدل‌سازی و شبیه‌سازی برخوردارند (۳). امروزه روش‌های پیش‌بینی، بر مبنای پایگاه داده، به علت صرفه‌جویی در زمان، حداقل اطلاعات مورد نیاز و سهولت اجرای بهنگام با رشدی سریع در حال متداول شدن می‌باشند. در میان روش‌های پیش‌بینی جریان بر مبنای پایگاه داده، مدل‌های آماری بصورت مرسوم مورد استفاده قرار گرفته‌اند. در این میان مدل‌های مبتنی بر سری‌های زمانی مانند مدل اتورگرسیو میانگین متحرک^۴ (ARMA) از جمله متداول‌ترین روش‌ها می‌باشند (۱ و ۲). در سال‌های اخیر، از روش‌های هوشمند مانند شبکه‌های عصبی

مدیریت علمی منابع آبهای سطحی نیازمند پیش‌بینی و تخمین دقیق دبی جریان رودخانه‌ها در آینده می‌باشد. پیش‌بینی دبی جریان را می‌توان در دو دسته کلی شامل پیش‌بینی کوتاه‌مدت و پیش‌بینی بلندمدت تقسیم نمود. در پیش‌بینی‌های کوتاه مدت معمولاً افق زمانی پیش‌بینی را کمتر از هفت روز در نظر می‌گیرند، در صورتی که در پیش‌بینی‌های بلندمدت این افق زمانی طولانی بوده و می‌تواند تا

۱- دانشجوی دکتری مهندسی منابع آب، دانشکده علوم آب، دانشگاه شهید چمران اهواز

*- نویسنده مسئول: (Email: sajad1998@yahoo.com)

۲- دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

۳- استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهرکرد

ریدیو^{۱۰} در کانادا در دوره آماری ۲۰۰۱-۱۹۷۰ توسعه داد. نتایج نشان داد که این مدل نسبت به ANN در مقیاس‌های زمانی کمتر از هفت روز عملکرد بهتری دارد. آداموفسکی (۶)، روش جدیدی مبتنی بر WT و CW برای تخمین جریان کوتاه‌مدت در رودخانه اسکروا پراوا واقع در لهستان استفاده نمود. در این تحقیق از داده‌های هواشناسی شامل حداکثر و حداقل دمای هوا، بارش و عمق برف موجود در ایستگاه در مقیاس روزانه استفاده شد. نتایج نشان داد که مدل مذکور (WT و CW) در پیش‌بینی‌های کوتاه مدت جریان رودخانه یک تا سه روزه عملکرد بهتری دارد. همچنین برای تخمین دبی‌های ۷ روزه مدل‌های مبتنی بر ANN نتایج دقیق‌تری را در مقایسه با مدل CW داشتند. نورانی و همکاران (۱۸)، برای پیش‌بینی بارندگی در حوضه ليقوان چای از تلفیق آنالیز موجک با مدل ANN استفاده کردند. بدین منظور، سری زمانی اولیه بوسیله تئوری موجک به سری‌های زمانی متعدد با فرکانس‌های مختلف تجزیه گردید. سپس سری‌های زمانی بدست آمده به عنوان ورودی در مدل ANN استفاده شدند تا بارندگی یک ماه بعد را پیش‌بینی کنند. نتایج بدست آمده نشان داد که مدل پیشنهاد شده بدلیل استفاده از سری‌های زمانی با مقیاس چندگانه بعنوان لایه ورودی مدل ANN، قادر به پیش‌بینی رویدادهای بارندگی طولانی مدت و کوتاه مدت می‌باشد. آداموفسکی و سان (۷)، مدلی را که تلفیقی از WT و روش‌های ANN بود، به منظور تخمین جریان چند رودخانه‌های غیردائمی واقع در حوضه‌های آبریز نیمه خشک کشور قبرس استفاده کردند. نتایج نشان داد که روش تلفیقی مذکور یک روش موثر در تخمین جریان در حوضه مورد مطالعه می‌باشد. با توجه به بررسی پیشینه پژوهش، بنظر می‌رسد در ایران مطالعه جامعی که در آن دبی جریان رودخانه با روش‌های موجک متقاطع (CW) و تلفیقی موجک شبکه عصبی (WNN) پیش‌بینی شده باشد، انجام نشده است. بنابراین، در این مطالعه، مدل‌های مذکور به منظور پیش‌بینی کوتاه مدت (۱ تا ۷ روز جلوتر) دبی متوسط روزانه جریان رودخانه بهشت‌آباد توسعه داده شدند. همچنین عملکرد روش‌های مذکور با روش شبکه عصبی (ANN) مورد مقایسه قرار گرفت.

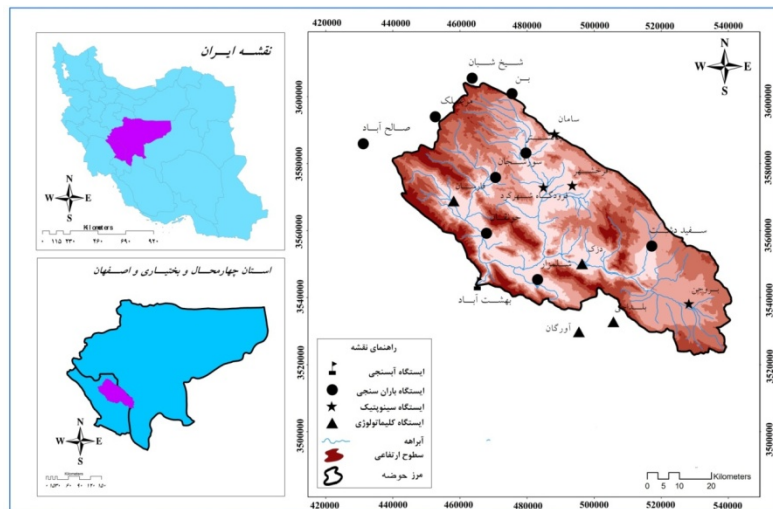
مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورد استفاده

در این مطالعه، محدوده حوضه آبریز رودخانه بهشت‌آباد به منظور توسعه مدل‌های پیش‌بینی جریان انتخاب گردید. حوضه بهشت‌آباد در محدوده جغرافیایی ۵۰ درجه و ۲۲ دقیقه تا ۵۱ درجه و ۲۵ دقیقه طول شرقی و ۳۱ درجه و ۵۰ دقیقه تا ۳۲ درجه و ۳۲ دقیقه عرض شمالی قرار گرفته است.

مصنوعی^۱ (ANNs) نیز به منظور پیش‌بینی جریان استفاده شده است (۹، ۱۳ و ۲۰). ضعف این روش‌ها و دیگر روش‌های خطی و غیرخطی در سری داده‌های ناپیستا ظاهر می‌شود (۵). تحقیقات نشان داده است که آنالیز موجک^۲ روش مناسبی در تجزیه و تحلیل سری‌های زمانی ناپیستا می‌باشد (۶). در دهه اخیر، همسو با تلاش‌های دانشمندان علوم مختلف، محققین بخش هیدرولوژی و منابع آب نیز سعی کرده‌اند از قابلیت‌های منحصر به فرد آنالیز موجک در تحقیقات علمی خود استفاده کنند. تورنس و کامپو (۲۱)، روشی جدید برای محاسبه تبدیل پیوسته موجک سری‌های زمانی گسسته ارائه کردند و با بهره‌گیری از داده‌های شاخص اقلیمی نوسان جنوبی ال نینو^۳ در خلال سال‌های ۱۹۹۷-۱۸۷۱، نحوه کاربرد عملی این روش را شرح دادند. همچنین ایشان روش نوینی را به منظور بررسی معنی‌داری طیف حاصل از تجزیه موجک معرفی نمودند و در ادامه، چند روش نوین آنالیز سری‌های زمانی از جمله آنالیز موجک متقاطع^۴ (CW) را نیز معرفی کردند. وانگ و دینگ (۲۲)، از مدل حاصل از تلفیق ANN و آنالیز موجک به منظور پیش‌بینی حداقل تراز آب زیرزمینی شهر پکن در مقیاس ماهانه و پیش‌بینی دبی جریان روزانه رودخانه یانگ تسه استفاده کردند. مقایسه نتایج پیش‌بینی‌های این مدل ترکیبی با نتایج مدل‌های دیگر از جمله ARMA و مدل خودهمبسته آستانه‌ای^۵ (TAR) نشان داد که مدل ترکیبی مذکور عملکرد بهتری دارد. کناس و همکاران (۱۰)، از یک مدل تلفیقی (ترکیبی از ANN و WT) در تخمین جریان ماهانه رودخانه تیرسو^۶ در ایتالیا در یک دوره آماری ۶۹ ساله استفاده کردند. نتایج نشان داد که پیش‌پردازش‌های صورت گرفته توسط روش‌های آنالیز موجک، بویژه در حالت گسسته، تاثیر بسزایی در افزایش دقت مدل‌های ANN دارد. کیشی (۱۴)، از تکنیک عصبی موجکی برای مدل‌سازی دبی جریان ماهانه دو ایستگاه آبسنجی واقع بر مسیر جریان رودخانه گوکسادر^۷ در ترکیه در خلال سال‌های ۱۹۹۹-۱۹۶۰ استفاده کرد. نتایج نشان داد که این مدل نسبت به روش شبکه‌های عصبی پرسپترون چند لایه^۸ (MLP)، مدل‌های اتورگرسیو (AR) و رگرسیون خطی چند متغیره^۹ (MLR) کارایی بهتری دارد. آداموفسکی (۵)، یک روش جدید مبتنی بر CW به منظور تخمین کوتاه مدت سیلاب‌های ناشی از ذوب برف در رودخانه

- 1- Artificial Neural Networks
- 2- Wavelet Analysis
- 3- El Nino-Southern Oscillation (ENSO)
- 4- Cross Wavelet
- 5- Threshold Autoregressive Model (TAR)
- 6- Tirso
- 7- Gouksudere
- 8- Multilayer Perceptron
- 9- Multiple Linear Regression



شکل ۱- موقعیت جغرافیایی حوضه آبریز رودخانه بهشت‌آباد و ایستگاه‌های هواشناسی مورد استفاده

تبدیل موجک

تبدیل موجک به عنوان یک تبدیل ریاضیاتی (مانند تبدیل فوریه) برای تشخیص اطلاعاتی که در سری زمانی یا سیگنال نهفته است، استفاده می‌شود. برای فهم بهتر تبدیل موجک می‌توان آنرا با تبدیل فوریه مقایسه کرد. تبدیل فوریه، یک سیگنال را بصورت توان‌های مختلف از امواج سینوسی تشکیل دهنده و فرکانس تفکیک کرده، بدون اینکه اشاره‌ای به موقعیت اتفاق فرکانس‌ها داشته باشد. محلی‌سازی در زمان بوسیله اعمال تبدیل فوریه در یک پنجره از زمان و جایگزین کردن آن در طول سری زمانی حاصل می‌شود. به این صورت از تبدیل فوریه، تبدیل فوریه پنجره‌ای یا زمان کوتاه^۳ اتلاق می‌گردد. با این حال طول پنجره بدون در نظر گرفتن فرکانس، ثابت در نظر گرفته شده است. بر خلاف تبدیل فوریه، تبدیل موجک طول پنجره آنالیزگر را متناسب با فرکانس تنظیم می‌کند. با افزایش فرکانس در امتداد سری زمانی، مقیاس موجک کاهش می‌یابد و برعکس، با کاهش فرکانس مقیاس موجک افزایش می‌یابد. تبدیل مذکور سری زمانی را به یک فضای سه بعدی شامل زمان، مقیاس (یا فرکانس) و بزرگی تبدیل می‌کند (۱۹). تبدیلات موجک به دو نوع پیوسته و گسسته تقسیم می‌شوند. تبدیل پیوسته موجک یک سیگنال $x(t)$ به صورت زیر می‌باشد (۱۰):

$$CWT_x^\Psi = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \Psi^* \left(\frac{t-\tau}{s} \right) dt \quad (1)$$

که در آن Ψ تابع موجک، $S(>1)$ پارامتر مقیاس یا اتساع^۴، τ

رودخانه بهشت‌آباد یکی از سرشاخه‌های دائمی رودخانه کارون بوده و مساحتی در حدود ۳۸۶۰ کیلومتر مربع را زهکشی می‌کند. در تحقیق حاضر، از داده‌های دبی متوسط روزانه جریان رودخانه مذکور در محل ایستگاه آبسنجی بهشت‌آباد و مقادیر بارش روزانه ۱۷ ایستگاه باران‌سنجی، کلیماتولوژی و سینوپتیک واقع در بالادست ایستگاه مذکور در خلال سال‌های ۲۰۰۸-۱۹۹۹ استفاده گردید. بیشتر این ایستگاهها در داخل حوضه آبریز بهشت‌آباد قرار گرفته‌اند. با این حال، تعدادی نیز در مناطق مرزی حوضه و یا در مجاورت آن قرار دارند. شکل ۱ موقعیت جغرافیایی حوضه آبریز رودخانه بهشت‌آباد را در محل ایستگاه بهشت‌آباد به همراه موقعیت ایستگاه‌های هواشناسی مورد استفاده در تحقیق نشان می‌دهد.

پیش از استفاده از داده‌های بارش، در کلیه ایستگاهها آزمون همگنی داده‌ها با روش تحلیل جرم مضاعف^۱ انجام پذیرفت و در صورت نیاز اصلاحات لازم بر روی داده‌ها انجام شد. سپس داده‌های گم شده بارش در یکایک ایستگاهها با استفاده از داده‌های مناسب-ترین ایستگاههای همسایه و روش نسبت نرمال^۲ بازسازی گردید (۳). به علت قرارگیری ایستگاه آبسنجی بهشت‌آباد در مجاورت خروجی حوضه و شرایط توپوگرافی و اقلیمی متنوع در سطح حوضه، لازم است به عنوان بخشی از ورودی مدل، میانگین منطقه‌ای بارش در نظر گرفته شود. برای این منظور، در این مطالعه میانگین منطقه‌ای بارش با استفاده از روش چند ضلعی‌های تیسن محاسبه گردید.

3- Short Time Fourier Transform (STFT)
4- Dilatation Parameter

1- Double Mass Analysis
2- Normal Ratio

تبدیل موجک متقاطع

به منظور بررسی ارتباط دو متغیر در حوزه زمان-مقیاس (فرکانس) نیاز به بسطی دو متغیره از تبدیل موجک می‌باشد. در سال ۱۹۹۳، هادگینز برای اولین بار مفهوم تبدیل موجک متقاطع^۶ را ارائه کرد. این مفهوم اولین بار در سال ۱۹۹۹ توسط لابات در تحلیل‌های هیدرولوژیکی مورد استفاده قرار گرفت (۱۶). در مطالعه حاضر، از تبدیل مذکور به منظور تعیین اختلاف فاز (تاخیر زمانی) متغیرهای بارش و جریان استفاده شد. تبدیل موجک متقاطع دو سری زمانی $x(t)$ و $y(t)$ بشرح زیر است (۱۲):

$$W_{xy}(n,s) = w_x(n,s) w_y^*(n,s) \quad (۳)$$

که در آن $w_x(n,s)$ و $w_y(n,s)$ به ترتیب ضرایب تبدیل موجک سری‌های زمانی $x(t)$ و $y(t)$ با زمان تاخیر n و مقیاس s می‌باشند. بطوریکه اشاره شد، علامت * بیانگر صورت مزدوج یک عدد مختلط می‌باشد. ضرایب حاصل از تبدیل موجک متقاطع، خود اعدادی مختلط می‌باشند که دارای بخش‌های حقیقی و موهومی بوده و یا می‌توانند بصورت مدول و اختلاف فاز توصیف شوند. با استفاده از مقادیر حاصل از تبدیل موجک متقاطع و رابطه زیر اختلاف فاز $\Delta\Phi(n,s)$ بین دو سری زمانی فوق در هر نقطه n و s در فضای زمان-مقیاس محاسبه گردید (۱۲):

$$\Delta\Phi(n,s) = \tan^{-1} \frac{\text{Im}[W_{xy}(n,s)]}{\text{Re}[W_{xy}(n,s)]} \quad (۴)$$

که در آن Re و Im به ترتیب بخش‌های موهومی و حقیقی ضریب $W_{xy}(n,s)$ می‌باشند. در این تحقیق، از مقادیر اختلاف فاز به منظور ایجاد ارتباط بین متغیرهای بارش و جریان استفاده گردید.

مدل‌سازی و پیش‌بینی جریان با روش موجک متقاطع (CW)

در این مطالعه، مدل پیش‌بینی دبی متوسط روزانه جریان با استفاده از روش موجک متقاطع به شرح زیر بسط داده شد. **گام اول:** متغیرهای هواشناسی و هیدرولوژیکی مورد استفاده در مدل انتخاب شدند. بررسی همبستگی متغیرهای مختلف هواشناسی با متغیر دبی متوسط روزانه جریان رودخانه بهشت‌آباد نشان داد که فقط متغیر بارش روزانه نقش قابل ملاحظه‌ای در تولید رواناب حوضه دارد. بنابراین، در توسعه مدل‌های پیش‌بینی جریان رودخانه مذکور، علاوه بر داده‌های مشاهداتی دبی متوسط روزانه جریان از مقادیر متوسط منطقه‌ای مجموع بارش روزانه نیز استفاده شد.

پارامتر انتقال زمان، t زمان و علامت * نشان دهنده مزدوج مختلط می‌باشد. روش CWT، سیگنال را بوسیله تعداد بیشمار و نامحدودی از پارامترهای مقیاس و انتقال تجزیه می‌کند. در این روش پارامترهای مقیاس و انتقال بصورت پیوسته تغییر می‌کنند. از اینرو محاسبه ضرایب موجک برای همه مقیاس‌های ممکن، علاوه بر تولید حجم زیادی از اطلاعات، نیاز به کوششی قابل ملاحظه دارد. آشکارا مشخص است در روش CWT مقدار زیادی اطلاعات اضافی تولید می‌شود. اما می‌توان با استفاده از زیرنمونه‌هایی CWT ویژگی‌های کلیدی تبدیل را حفظ نمود. این ایده منجر به ابداع تبدیل گسسته موجک (DWT) گردیده است (۸). شکل گسسته تابع موجک به صورت زیر می‌باشد (۱۰):

$$\Psi_{j,k}(t) = \frac{1}{\sqrt{|s_0^j|}} \Psi\left(\frac{t - k\tau_0 s_0^j}{s_0^j}\right) \quad (۲)$$

که در آن $\Psi_{j,k}$ تابع موجک به ازای مقادیر معین k و j (اعدادی صحیح)، t زمان، $S_0 (>1)$ ثابت گام اتساع، τ_0 ثابت انتقال زمان بوده و وابسته به S_0 می‌باشند (معمولاً مقدار $S_0=2$ و $\tau_0=1$ در نظر گرفته می‌شود). در روش DWT مقادیر پارامترهای مقیاس و انتقال بر اساس توان‌هایی از عدد ۲ در نظر گرفته می‌شوند. در اصطلاح به این پارامترها، پارامترهای انتقال و اتساع دوتایی^۱ می‌گویند. روش DWT علاوه بر سادگی اجرا از سرعت محاسباتی بالایی نیز برخوردار است. ضمناً می‌توان با استفاده از مقادیر حاصل از DWT، سیگنال اولیه را به خوبی بازسازی نمود. در این مطالعه، برای اجرای روش DWT از الگوریتم مالات^۲ یا روش آنالیز چند تفکیکی (MAR) استفاده شد (۱۷). در این روش سیگنال هدف از میان یکسری فیلترهای پایین‌گذر^۳ و بالا‌گذر^۴ عبور داده می‌شود. با این عمل اجزاء فرکانسی بالا و پایین سیگنال بصورت مجزا از آن جدا می‌گردد. در آنالیز گسسته موجک محتوای فرکانس پایین سیگنال تقریب^۵ و محتوای فرکانس بالای سیگنال جزئیات^۶ نامگذاری می‌شود. از این تکنیک فیلتر کردن می‌توان برای بدست آوردن نمایش زمان-مقیاس یک سیگنال استفاده نمود. برای استخراج باندهای مختلف فرکانسی سیگنال باید فرآیند بالا را تکرار کرد. این عمل تا رسیدن به سطح تجزیه مطلوب ادامه می‌یابد (۱۹).

- 1- Dyadic
- 2- Mallat Algorithm
- 3- Low-Pass Filters
- 4- High Pass Filters
- 5- Approximation
- 6- Details

$$\Phi(s, t) = \tan^{-1} \frac{\text{Im}[W_{\text{precipitation data}}(s, t)]}{\text{Re}[W_{\text{precipitation data}}(s, t)]} \quad (7)$$

در رابطه فوق $\text{Re}[W_{\text{precipitation data}}(s, t)]$ و $\text{Im}[W_{\text{precipitation data}}(s, t)]$ به ترتیب قسمت‌های حقیقی و موهومی ضریب حاصل از تجزیه موجک سری زمانی متوسط منطقه‌ای بارش روزانه در مقیاس S و زمان t و $\Phi(S, t)$ فاز متغیر بارش در مقیاس S و زمان t می باشد. در ادامه، با بهره‌گیری از مفهوم موجک متقاطع و استفاده از روابط ۳ و ۴، اختلاف فاز (تاخیر زمانی) زیرسری‌های حاصل از تجزیه موجک متغیرهای بارش و جریان در کلیه مقیاس‌ها و زمان‌ها محاسبه گردید. از مقادیر فاز اولیه و اختلاف فاز به منظور بازسازی سری‌های ساختاری مورد استفاده در توسعه مدل‌های پیش‌بینی استفاده شد.

گام هفتم: در این گام ثابت‌های واسنجی مدل محاسبه شدند. ثابت‌های واسنجی، زیرسری‌های حاصل از تجزیه متغیر بارش روزانه را به زیرسری‌های نظیر دبی جریان ارتباط می دهند. این ثابت‌ها از رابطه زیر بدست آمد (۶):

$$Z_{s,t} = \frac{[W_{s,t(\text{flow data})}]}{[W_{s,t(\text{precipitation data})}]} \quad (8)$$

که در آن $W_{s,t(\text{precipitation data})}$ و $W_{s,t(\text{flow data})}$ به ترتیب مقادیر ضرایب موجک مربوط به داده‌های بارش و جریان در مقیاس S و زمان t می باشند. با واسنجی (پیوند) اجزاء زیرسری‌های مربوط به متغیر بارش به زیرسری‌های نظیر جریان از آنها در توسعه مدل‌های پیش‌بینی جریان استفاده شد.

گام هشتم: در این گام بازسازی سری‌های ساختاری مورد استفاده در مدل پیش‌بینی بشرح زیر انجام گردید. فرض شد اولاً مقیاس‌های تبدیل موجک با پرودهای فوریه برابرند. ثانیاً ضرایب موجک با ضرایب فوریه برابرند و رابطه ای خطی بین ضرایب موجک مربوط به بارش و جریان در طول موج‌های (مقیاس) مختلف وجود دارد (۵). همزمان با در نظر گرفتن فازها، اختلاف فازها و ثابت‌های واسنجی و نهایتاً استفاده از تبدیل معکوس فوریه، ضرایب موجک مربوط به متغیر بارش روزانه در کلیه مقیاس‌ها نسبت به دبی جریان واسنجی و بشرح رابطه زیر بازسازی شد (۵).

$$X_{t,s} = Z_{t,s} \cdot Y_{t,s} \cdot W_{t,s} \cdot \cos(2\pi \frac{t}{S} + \Phi_{t,s} + \Delta\Phi_{t,s}) \quad (9)$$

که در آن $Z_{t,s}$ ثابت واسنجی در زمان t و مقیاس S ، $Y_{t,s}$ ضریب اصلاحی مربوط به اثر لبه^۳ در زمان t و مقیاس S می باشد. در این مطالعه معلوم شد که اثر ضریب مذکور ناچیز بوده و در نتیجه مقدار آن برابر ۱ در نظر گرفته شد. $W_{t,s}$ ضریب موجک مربوط به متغیر

گام دوم: در این گام مجموعه داده‌های بخش‌های آموزش^۱ و تست^۲ مدل تعیین گردید. از داده‌های موجود در بازه‌های زمانی ۲۰۰۶/۱۲/۳۰ - ۱۹۹۹/۰۱/۰۱ (حدوداً ۸۰ درصد کل داده‌ها) برای آموزش مدل و از داده‌های موجود در بازه زمانی ۲۰۰۸/۱۲/۳۰ - ۲۰۰۷/۰۱/۰۱ (حدوداً ۲۰ درصد کل داده‌ها) بمنظور تست مدل استفاده شد.

گام سوم: در این گام یک تابع موجک مناسب برای تجزیه سری داده‌های بارش و جریان انتخاب شد. انتخاب تابع موجک بر مبنای هدف و ویژگی‌های سری‌های زمانی تحت آنالیز صورت می‌گیرد. در تجزیه و تحلیل سری‌های زمانی در صورتی که به اطلاعاتی درباره ارتباط فازی بین ضرایب حاصل از تجزیه موجک دو سری نیاز باشد، باید از یک موجک مختلط استفاده کرد. از دیگر معیارهای انتخاب تابع موجک دو جنبه ظاهری، شکل و عرض تابع موجک می باشد. غالب دانشمندان از موجک مختلط مورلت به عنوان موجک آنالیزگر استفاده کرده‌اند (۵، ۶ و ۱۶). به همین دلیل در این مطالعه برای مدل‌بندی با روش موجک متقاطع از تابع موجک مختلط مورلت استفاده شد.

گام چهارم: در این گام مقیاس‌های مورد نیاز برای انجام تبدیل پیوسته موجک انتخاب شدند. برای این کار از روابط زیر استفاده شد:

$$S_j = S_0 2^{j\delta_j}, j = 1, 2, \dots, J \quad (5)$$

که در آن

$$J = \delta_j^{-1} \log_2(N\delta t / S_0) \quad (6)$$

S_0 کوچکترین مقیاس قابل تفکیک، δt گام زمانی، N تعداد نقاط سری و J تعداد مقیاس مورد استفاده در تجزیه است. در عمل مقدار $S_0 = 2\delta t$ در نظر گرفته می شود. برای موجک مختلط مورلت، $\delta_j = 0.5$ بزرگترین مقیاسی است که می توان بوسیله آن نمونه‌های کافی از مقیاس استخراج کرد. مقادیر کوچکتر δ_j تفکیک مناسب تری از سری زمانی اولیه بدست می‌دهند. در این مطالعه $\delta_j = 0.5$ در نظر گرفته شد (۲۱).

گام پنجم: در این گام با استفاده از روش تبدیل پیوسته موجک ارائه شده توسط تورنس و کامپو، سری‌های زمانی داده‌های متوسط منطقه‌ای مجموع بارش روزانه و دبی متوسط روزانه جریان، مورد استفاده در بخش آموزش مدل تجزیه شدند.

گام ششم: با استفاده از مقادیر حاصل از تجزیه سری زمانی متوسط منطقه‌ای بارش روزانه مورد استفاده در مدل، مقادیر فاز (موقعیت در حوزه فرکانس) در زمان‌ها و مقیاس‌های مختلف با استفاده از رابطه زیر محاسبه شد (۲۱):

مناسب‌ترین مدل پیش‌بینی دبی متوسط روزانه جریان استخراج شد (۶).

گام سیزدهم: در این مرحله تست مدل‌ها برای افق‌های پیش‌بینی مختلف انجام شد. بدین منظور، داده‌های ورودی مجموعه تست را به مدل‌های استخراج شده معرفی و خروجی حاصل از مدل با مشاهدات مقایسه شدند. در تحقیق حاضر این مقایسه بوسیله دو آماره ضریب تعیین (R^2) و جذر میانگین مربعات خطا (RMSE) انجام شد.

مدل‌سازی و پیش‌بینی جریان با استفاده از روش شبکه عصبی (ANN)

اولین گام در مدل‌سازی و پیش‌بینی دبی جریان با استفاده از روش ANN، انتخاب نوع شبکه است. در تحقیق حاضر در ساختار مدل پیش‌بینی ANN از یک شبکه سه لایه پیشخور با الگوریتم پس‌انتشار^۲ (FFBP) استفاده گردید. در دو لایه ورودی و میانی شبکه مذکور از تابع محرک تانژانت سیگموئید^۳ (TSTF) و در لایه خروجی از تابع خطی^۴ (LTF) استفاده شد. در گام دوم، افق‌های زمانی پیش‌بینی جریان در مقیاس روزانه بر اساس توصیه کارآموز و عراقی نژاد (۳)، شامل افق‌های ۱ روز، ۲ روز، ۳ روز و ۷ روز جلوتر انتخاب گردید. در گام سوم، به ازای هر یک از افق‌های زمانی پیش‌بینی چند الگوی ورودی برای مدل در نظر گرفته شد. به منظور یافتن بهترین الگوی ورودی از روش آزمون و خطا استفاده گردید. در این روش متناسب با افق زمانی پیش‌بینی چندین الگوی ورودی که شامل ترکیبی از مناسب‌ترین تاخیرهای متغیرهای هواشناسی و هیدرولوژیکی (پیش-بینی کننده‌ها) نسبت به مبدا زمانی پیش‌بینی می‌باشند، انتخاب شد. سپس هر یک از این الگوها به ساختارهای مختلفی از شبکه عصبی معرفی شده و با توجه به عملکرد شبکه، الگوی برتر انتخاب گردید. معمولاً برای شناسایی اولیه مناسب‌ترین تاخیرهای متغیرهای هواشناسی از جمله مجموع بارش روزانه از روش همبستگی متقاطع^۵ و برای تعیین مناسب‌ترین تاخیرهای متغیر دبی جریان روزانه از توابع خودهمبستگی^۶ (ACF) و خودهمبستگی جزئی^۷ (PACF) استفاده می‌شود. در جدول ۱ الگوهای ورودی مورد استفاده در مدل ANN ارائه شده‌اند. این الگوها شامل ۳ الگوی بارشی، ۳ الگوی جریانی و ۳ الگوی بارشی-جریانی می‌باشند. الگوهای جریانی شامل ۳ ترکیب از متوسط دبی جریان روز جاری (Q_t : مبدا زمانی پیش‌بینی) و تاخیرهای دبی جریان روزانه از ۱ تا ۲ روز قبل از مبدا زمانی پیش‌بینی (Q_{t-1} ،

بارش در زمان t و مقیاس S ، $\Phi_{t,s}$ فاز اولیه متغیر بارش در زمان t و مقیاس S ، $\Delta\Phi_{t,s}$ اختلاف فاز بین ضریب موجک داده‌های بارش و دبی جریان در زمان t و مقیاس S و $X_{t,s}$ مولفه ساختاری بازسازی شده در زمان t و مقیاس S می‌باشد. به منظور بازسازی سری‌های ساختاری مربوط به متغیر دبی جریان از رابطه زیر استفاده شد (۲۱):

$$X_{t,s} = \frac{\delta_j \delta_t^{1/2}}{C_\delta \Psi_0} \left[\frac{R \{ W_{t,s} \}}{S^{1/2}} \right] \quad (10)$$

که در آن C_δ و Ψ_0 پارامترهای ثابت بوده و مقدار آنها بر اساس نوع تابع موجک (برای موجک مختلط مورلت به ترتیب برابر با ۰/۷۷۶ و $\pi^{1/4}$ می‌باشد) تعیین گردید. پارامترهای δ_j و δ_t بسته به گام زمانی سری داده‌های اولیه و تعداد مقیاس مد نظر در تجزیه موجک تعیین شدند. لازم به یادآوری است که عبارت $R \{ W_t(S_j) \}$ بیانگر قسمت حقیقی مقدار حاصل از تجزیه موجک متغیر دبی جریان در زمان t و مقیاس S می‌باشد.

گام نهم: در این گام، میانگین مولفه‌های ساختاری بازسازی شده برای متغیرهای بارش و دبی جریان، در کلیه مقیاس‌ها و روزهای مشابه سال‌های آموزش مدل، محاسبه گردید. در این میانگین‌گیری فرض شد که هیچ گونه روند معنی‌داری در ضرایب موجک و اختلاف فاز موجود بین زیرسری‌های تجزیه شده متغیرهای بارش و جریان در روزهای مشابه مربوط به سال‌های مختلف وجود ندارد (۶).

گام دهم: در این گام انتخاب افق‌های زمانی پیش‌بینی جریان انجام گرفت. در این مطالعه از افق‌های ۱ روز، ۲ روز، ۳ روز و ۷ روز جلوتر استفاده گردید.

گام یازدهم: اختلاف میانگین مولفه‌های ساختاری، متناسب با افق زمانی پیش‌بینی دبی جریان محاسبه گردید. این عمل در کلیه مقیاس‌های تجزیه برای متغیرهای بارش و دبی جریان روزانه انجام شد. به عنوان مثال، اختلاف میانگین مولفه‌های ساختاری متغیر جریان در مقیاس X برای افق پیش‌بینی ۱ روزه از تفاضل میانگین مولفه‌های ساختاری متغیر جریان یک روز جلوتر با روز جاری (مبدا زمانی پیش‌بینی) محاسبه شد (۶).

گام دوازدهم: در این گام با استفاده از روش رگرسیون چندگانه و با انتخاب گزینه گام به گام^۱ مناسب‌ترین مقادیر اختلاف میانگین مولفه‌های ساختاری متغیرهای بارش و جریان در مقیاس‌های مختلف، متناسب با افق زمانی پیش‌بینی به دبی جریان روز جاری (مبدا زمانی پیش‌بینی) اضافه و دبی جریان در افق زمانی پیش‌بینی بدست آمد. بدین ترتیب، مطابق با جدول ۲ به ازای هر افق زمانی پیش‌بینی،

2- Feed Forward Back Propagation (FFBP)
3- Tan-Sigmoid Transfer Function (TSTF)
4- Linear Transfer Function (LTF)
5- Cross Correlation
6- Auto Correlation Function
7- Partial Auto Correlation Function

1- Step by Step Correlation

تعداد دوره‌ها یا تکرارهایی^۲ است که شبکه در حین آموزش انجام می‌دهد. در تحقیق حاضر، تعداد بهینه تکرار آموزش توسط معیارهای توقف الگوریتم آزمایشی LM تعیین شد. در گام هشتم، تست شبکه-های آموزش دیده انجام گرفت. تست مدل‌های ANN بدین صورت انجام می‌شود که داده‌های ورودی مجموعه تست را به ساختارها و الگوهای مختلف شبکه عصبی آموزش دیده معرفی کرده و خروجی شبکه را با داده‌های مشاهداتی مقایسه می‌کنیم. در مطالعه حاضر این مقایسه بوسیله دو شاخص آماری ضریب تبیین (R^2) و جذر میانگین مربعات خطا (RMSE) صورت گرفت.

مدلسازی و پیش‌بینی جریان با استفاده از روش تلفیقی موجک-شبکه عصبی (WNN)

ساختار کلی مدل WNN مشابه با مدل ANN است، تنها تفاوت این دو مدل در پیش‌پردازش صورت گرفته بر روی ماتریس ورودی مدل ANN بوسیله تبدیل موجک می‌باشد. گام‌های اول تا سوم مراحل توسعه مدل WNN مشابه مدل ANN است، لذا در تحقیق حاضر به جهت رعایت اختصار از بیان مجدد گام‌های مذکور خودداری می‌شود. در گام چهارم، هر سطر ماتریس ورودی که یکی از عوامل موثر در پدیده هدف است، توسط تبدیل موجک گسسته (یا پیوسته) تجزیه می‌گردد. مرسوم است در روش WNN از تبدیل گسسته موجک (DWT) استفاده شود. زیرا این تبدیل علاوه بر حجم محاسبات کمتر از دقت مناسبی نیز برخوردار است. قبل از تجزیه سری داده‌ها، تابع موجک مناسب انتخاب می‌شود. این انتخاب اغلب با توجه به ماهیت داده‌های اولیه و تشابه رفتاری آنها با یک تابع موجک بخصوص صورت می‌گیرد. بررسی‌ها نشان می‌دهد که موجک میر^۳، تابعی مناسب برای تجزیه سری‌های زمانی هیدرولوژیکی می‌باشد (۱۸). از اینرو در این تحقیق از تابع موجک مذکور در ساخت مدل WNN استفاده گردید. در گام پنجم، ابتدا تعداد سطح مناسب تجزیه تعیین و سپس سطرهای ماتریس ورودی به شبکه تجزیه می‌شود. در حالت کلی دو روش متداول برای تعیین تعداد سطح مناسب تجزیه در مدل‌های WNN وجود دارد. الف- سعی و خطا ب- رابطه ارائه شده توسط وانگ و دینگ به شرح زیر (۲۲):

$$L = \text{INT} [\log(N)] \quad (11)$$

در رابطه فوق L تعداد سطح تجزیه، N طول سری داده‌های اولیه و INT عملگر صحیح^۴ می‌باشد. در تحقیق حاضر از رابطه ۱۱ برای تعیین تعداد سطح تجزیه ماتریس ورودی به مدل WNN استفاده گردید. پس از تعیین تعداد سطح مناسب تجزیه، هر سطر ماتریس ورودی اولیه با استفاده از تبدیل گسسته موجک و بهره‌گیری از تابع

می‌باشند. همچنین الگوهای بارشی شامل ۳ ترکیب از بارش منطقه‌ای روز جاری (P_t) و تاخیرهای بارش منطقه‌ای روزانه از ۱ تا ۲ روز قبل از مبدا زمانی پیش‌بینی (P_{t-1}, P_{t-2}) و الگوهای بارشی-جریانی شامل ترکیبی از الگوهای بارشی و جریانی می‌باشند.

جدول ۱- الگوهای مختلف ورودی مدل ANN

ردیف	الگوی ورودی
۱	P_t
۲	P_t, P_{t-1}
۳	P_t, P_{t-1}, P_{t-2}
۴	Q_t
۵	Q_t, Q_{t-1}
۶	Q_t, Q_{t-1}, Q_{t-2}
۷	Q_t, P_t
۸	$Q_t, Q_{t-1}, P_t, P_{t-1}$
۹	$Q_t, Q_{t-1}, Q_{t-2}, P_t, P_{t-1}, P_{t-2}$

پس از تعیین الگوهای ورودی به شبکه، متناظر با هر الگوی ورودی، ماتریس داده‌های ورودی و هدف به شبکه تشکیل شد. در گام چهارم، به منظور جلوگیری از کاهش دقت و سرعت شبکه، داده‌های ماتریس‌های ورودی و هدف در دامنه $[-1+1]$ نرمال گردید. در گام پنجم، مجموعه داده‌های آموزش، صحت سنجی و تست شبکه انتخاب شد. در این تحقیق از داده‌های موجود در بازه‌های زمانی $2006/12/31 - 1999/01/01$ (حدوداً ۷۰ درصد کل داده‌ها)، $2006/01/1 - 2006/12/31$ (حدوداً ۱۰ درصد کل داده‌ها) و بازه زمانی $2008/12/31 - 2007/01/1$ (حدوداً ۲۰ درصد کل داده‌ها) به ترتیب برای آموزش، صحت سنجی و تست مدل استفاده گردید. در گام ششم، تعداد نرون‌های لایه میانی شبکه تعیین گردید. در شبکه‌های عصبی تعداد نرون‌های لایه ورودی و خروجی تابعی از نوع مسئله است یعنی با اطلاع از یک مسئله می‌توان تعداد نرون‌های ورودی و خروجی شبکه را بدست آورد. در این مطالعه، تعداد بهینه نرون‌های لایه میانی شبکه با روش آزمون و خطا تعیین شد. در گام هفتم، آموزش شبکه انجام می‌گیرد. مدل ANN با استفاده از مجموعه آموزشی، تحت آموزش قرار می‌گیرد. یعنی پارامترهای مدل، وزن‌ها و بایاس‌ها با استفاده از یک الگوریتم آموزشی محاسبه می‌گردد. در این تحقیق از تابع لونبرگ مارکوات^۱ که از جمله رایج‌ترین و کارآمدترین توابع آموزش شبکه‌های عصبی مصنوعی است به منظور آموزش و تعیین بهترین اوزان شبکه‌های توسعه داده شده استفاده گردید (۱۱). یکی از معیارهای مهم در آموزش شبکه

2- Epochs

3- Meyer

4- Integer Operator

1- Levenbreg-Marquart (LM)

پیش‌بینی‌های کوتاه مدت دبی متوسط روزانه جریان رودخانه بهشت‌آباد نشان داد با افزایش افق زمانی پیش‌بینی از دقت تخمین‌های مدل مذکور بطور قابل ملاحظه‌ای کاسته می‌شود. می‌توان نتیجه گرفت عملکرد مدل CW فقط به ازای افق پیش‌بینی ۱ روز جلوتر قابل قبول است. نتایج بدست آمده از این مطالعه با نتایج دو تحقیق آداموفسکی (۵ و ۶)، که ابداع کننده این روش می‌باشد، همخوانی دارد. علت عملکرد ضعیف مدل مذکور در پیش‌بینی دبی جریان رودخانه به ازای افق‌های پیش‌بینی بزرگتر از ۱ روز را می‌توان به دو عامل اصلی نسبت داد.

عامل اول، در مدل CW فرض شده است که رابطه‌ای خطی بین مقادیر دبی جریان و بارش وجود دارد. در صورتی که در واقعیت رابطه مذکور رابطه‌ای غیرخطی است. عامل دوم، مدل CW به خوبی نمی‌تواند تاخیر زمانی موجود بین سری‌های زمانی دبی جریان و بارش روزانه را در مدلسازی در نظر بگیرد. در دو مدل ANN و WNN بهترین الگوهای ورودی برای پیش‌بینی دبی متوسط روزانه جریان رودخانه به ازای افق‌های پیش‌بینی کوتاه مدت، الگوهای بارشی جریانی می‌باشند.

موجک میر تجزیه گردید. حاصل این تجزیه، تعداد L زیرسری جزئی و L زیرسری تقریب می‌باشد. از کلیه زیرسری‌های جزئی و آخرین زیرسری تقریب حاصل از تجزیه سطرهای ماتریس ورودی اولیه، به منظور ساخت ماتریس ورودی ثانویه استفاده می‌شود. به عنوان مثال، اگر ماتریس ورودی اولیه، ماتریسی با m سطر و n ستون باشد و تعداد سطح مناسب تجزیه ۳ سطح باشد. ماتریس ورودی ثانویه ماتریسی با $4 * m$ سطر و n ستون خواهد بود. گام‌های ششم تا یازدهم مراحل توسعه مدل WNN مشابه با گام‌های چهارم تا نهم مراحل توسعه مدل ANN می‌باشد.

نتایج و بحث

در جداول ۳، ۴ و ۵ به ترتیب عملکرد مدل‌های CW، ANN و WNN در پیش‌بینی دبی متوسط روزانه جریان رودخانه بهشت‌آباد با استفاده از دو شاخص آماری ضریب تبیین R^2 و جذر میانگین مربعات خطا RMSE ارائه شده است. در مدل CW با کاهش افق پیش‌بینی از ۷ روز به ۱ روز، مقدار آماره R^2 (مرحله تست) از ۰/۵۱۱۳ به ۰/۹۳۸۸ افزایش و مقدار آماره RMSE از ۱۷/۹۱۷۱ به ۸/۳۲۲۶ مترمکعب بر ثانیه کاهش می‌یابد. بررسی عملکرد مدل CW در

جدول ۲- مدل‌های پیش‌بینی دبی متوسط روزانه جریان رودخانه بهشت‌آباد با استفاده از روش CW

افق زمانی پیش‌بینی	مدل ریاضی [†]
۱ روز	$F(t+1) = F(t) + [F_2(t+1) - F_2(t)] + [F_5(t+1) - F_5(t)] + [F_{15}(t+1) - F_{15}(t)] + [F_{21}(t+1) - F_{21}(t)] + [F_{82}(t+1) - F_{82}(t)]$ $+ [F_{115}(t+1) - F_{115}(t)] + [F_{317}(t+1) - F_{317}(t)] + [P_5(t+1) - P_5(t)] + [P_{21}(t+1) - P_{21}(t)]$ $+ [P_{115}(t+1) - P_{115}(t)] + [P_{317}(t+1) - P_{317}(t)]$
۲ روز	$F(t+2) = F(t) + [F_2(t+2) - F_2(t)] + [F_5(t+2) - F_5(t)] + [F_{15}(t+2) - F_{15}(t)] + [F_{21}(t+2) - F_{21}(t)] + [F_{82}(t+2) - F_{82}(t)]$ $+ [F_{115}(t+2) - F_{115}(t)] + [F_{317}(t+2) - F_{317}(t)] + [P_5(t+2) - P_5(t)] + [P_{21}(t+2) - P_{21}(t)]$ $+ [P_{115}(t+2) - P_{115}(t)] + [P_{317}(t+2) - P_{317}(t)]$
۳ روز	$F(t+3) = F(t) + [F_2(t+3) - F_2(t)] + [F_5(t+3) - F_5(t)] + [F_{15}(t+3) - F_{15}(t)] + [F_{21}(t+3) - F_{21}(t)] + [F_{82}(t+3) - F_{82}(t)]$ $+ [F_{115}(t+3) - F_{115}(t)] + [F_{317}(t+3) - F_{317}(t)] + [P_5(t+3) - P_5(t)] + [P_{21}(t+3) - P_{21}(t)]$ $+ [P_{115}(t+3) - P_{115}(t)] + [P_{317}(t+3) - P_{317}(t)]$
۷ روز	$F(t+7) = F(t) + [F_{15}(t+7) - F_{15}(t)] + [F_{21}(t+7) - F_{21}(t)] + [F_{82}(t+7) - F_{82}(t)] + [F_{115}(t+7) - F_{115}(t)]$ $+ [F_{317}(t+7) - F_{317}(t)] + [P_{21}(t+7) - P_{21}(t)] + [P_{115}(t+7) - P_{115}(t)] + [P_{317}(t+7) - P_{317}(t)]$

[†] حروف F و P به ترتیب نشان دهنده دبی متوسط روزانه جریان خروجی از حوضه و مقدار بارش روزانه در سطح حوضه است. علائم t, t+1, t+2, t+3, t+7 در داخل پرانتز به ترتیب نشان دهنده روز جاری، یک روز بعد، دو روز بعد، سه روز بعد و هفت روز بعد است. به ازای افق پیش‌بینی ۱ روز جلوتر عبارت‌های $[F_2(t+1) - F_2(t)]$ ، $[F_5(t+1) - F_5(t)]$ ، ... و $[F_{317}(t+1) - F_{317}(t)]$ به ترتیب اختلاف میانگین مولفه ساختاری دبی متوسط جریان ۱ روز جلوتر با روز جاری در مقیاس ۲ روزه، اختلاف میانگین مولفه ساختاری دبی متوسط جریان ۱ روز جلوتر با روز جاری در مقیاس ۵ روزه... و اختلاف میانگین مولفه ساختاری دبی متوسط جریان ۱ روز جلوتر با روز جاری در مقیاس ۳۱۷ روزه می‌باشند. عبارت‌های $[P_2(t+1) - P_2(t)]$ ، $[P_5(t+1) - P_5(t)]$ ، ... و $[P_{317}(t+1) - P_{317}(t)]$ به ترتیب اختلاف میانگین مولفه ساختاری بارش ۱ روز جلوتر با روز جاری در مقیاس ۲ روزه، اختلاف میانگین مولفه ساختاری بارش ۱ روز جلوتر با روز جاری در مقیاس ۵ روزه... و اختلاف میانگین مولفه ساختاری بارش ۱ روز جلوتر با روز جاری در مقیاس ۳۱۷ روزه می‌باشند. مشابه با افق پیش‌بینی ۱ روز جلوتر، در ساختار مدل‌های پیش‌بینی به ازای افق‌های پیش‌بینی دیگر نیز از عبارت‌های اختلاف میانگین

جدول ۳- عملکرد مدل CW در پیش بینی دبی متوسط روزانه جریان رودخانه بهشت آباد

ردیف	افق زمانی	R ²		RMSE (m ³ /s)	
		آموزش	تست	آموزش	تست
۱	روز ۱	۰/۹۴۸۶	۰/۹۳۸۸	۳/۱۳۹۶	۸/۳۲۲۶
۲	روز ۲	۰/۷۴۵۵	۰/۷۳۹۳	۴/۶۰۴۳	۱۲/۶۰۰۶
۳	روز ۳	۰/۶۷۲۷	۰/۶۴۷۷	۵/۳۷۰۲	۱۴/۸۵۷۶
۷	روز ۷	۰/۵۲۵۱	۰/۵۱۱۳	۶/۸۴۲۱	۱۷/۹۱۷۱

جدول ۴- عملکرد مدل ANN در پیش بینی دبی متوسط روزانه جریان رودخانه بهشت آباد

افق زمانی پیش بینی	الگوی ورودی	تعداد نرون لایه پنهان	R ²			RMSE (m ³ /s)	
			آموزش	صحت سنجی	تست	آموزش	صحت سنجی
روز ۱	۷	۶	۰/۹۰۹۰	۰/۸۹۳۰	۰/۹۱۶۶	۷/۱۷۴۳	۱۴/۷۱۹۷
روز ۲	۸	۶	۰/۷۷۰۸	۰/۵۶۳۴	۰/۸۴۹۸	۱۱/۳۶۵۶	۲۹/۶۸۴۷
روز ۳	۹	۵	۰/۶۹۹۲	۰/۴۷۰۷	۰/۷۷۲۷	۱۳/۰۲۳۷	۳۲/۹۴۵
روز ۷	۹	۳	۰/۵۸۷۶	۰/۳۶۳۲	۰/۶۷۰۵	۱۵/۲۶۸۶	۳۶/۱۱۴۳

جدول ۵- عملکرد مدل WNN در پیش بینی دبی متوسط روزانه جریان رودخانه بهشت آباد

افق زمانی پیش بینی	الگوی ورودی	تعداد نرون لایه پنهان	R ²			RMSE (m ³ /s)	
			آموزش	صحت سنجی	تست	آموزش	صحت سنجی
روز ۱	۶	۵	۰/۹۹۴۴	۰/۹۶۲۷	۰/۹۹۲۷	۱/۸۰۷۴	۹/۳۶۰۵
روز ۲	۹	۴	۰/۹۹۶۸	۰/۹۲۵۳	۰/۹۷۵۵	۱/۳۴۳۰	۱۲/۳۳۱۹
روز ۳	۹	۶	۰/۹۷۶۸	۰/۹۳۸۳	۰/۹۴۶۷	۳/۶۱۸۰	۱۱/۳۸۳۴
روز ۷	۹	۵	۰/۹۷۸۷	۰/۶۹۴۳	۰/۸۴۲۴	۳/۴۷۰۶	۲۴/۹۹۹۷

رودخانه بهشت آباد به ازای افق های پیش بینی ۱ روز، ۲ روز، ۳ روز و ۷ روز از سه روش موجک متقاطع (CW)، شبکه عصبی (ANN) و تلفیقی موجک شبکه عصبی (WNN) استفاده گردید. نتایج نشان داد که عملکرد مدل ANN در افق های پیش بینی ۲، ۳ و ۷ روز از روش موجک متقاطع بهتر بوده است و فقط در افق پیش بینی ۱ روز بعد، عملکرد روش CW بهتر از ANN بود. همچنین روش WNN در مقایسه با دو روش دیگر از دقت بالاتری در مدلسازی و پیش بینی کوتاه مدت دبی متوسط روزانه جریان رودخانه، در هر ۴ افق زمانی پیش بینی، برخوردار بود. در مدل CW با کاهش افق پیش بینی از ۷ روز به ۱ روز مقدار آماره R² (مرحله تست) از ۰/۵۱۱۳ به ۰/۹۳۸۸ افزایش و مقدار آماره RMSE از ۱۷/۹۱۷۱ به ۸/۳۲۲۶ مترمکعب بر ثانیه کاهش می یابد. در مدل ANN با کاهش افق پیش بینی از ۷ روز به ۱ روز مقدار آماره R² (مرحله تست) از ۰/۶۷۰۵ به ۰/۹۱۶۶ افزایش و مقدار آماره RMSE (مرحله تست) از ۵/۹۸۲۸ به ۲/۵۶۰۰ مترمکعب بر ثانیه کاهش یافت. در حالیکه در مدل WNN با کاهش افق پیش بینی از ۷ روز به ۱ روز مقدار آماره R² (مرحله تست) از

با وجود مشابهت تقریبی بهترین الگوهای ورودی دو مدل، قابلیت مدلسازی و پیش بینی جریان توسط مدل WNN در مراحل آموزش، صحت سنجی و تست به ازای کلیه افق های پیش بینی افزایش پیدا کرده است. در مدل ANN با کاهش افق پیش بینی از ۷ روز به ۱ روز مقدار آماره R² (مرحله تست) از ۰/۶۷۰۵ به ۰/۹۱۶۶ افزایش و مقدار آماره RMSE (مرحله تست) از ۵/۹۸۲۸ به ۲/۵۶۰۰ مترمکعب بر ثانیه کاهش یافته است. در حالیکه در مدل WNN با کاهش افق پیش بینی از ۷ روز به ۱ روز مقدار آماره R² (مرحله تست) از ۰/۸۴۲۴ به ۰/۹۹۲۷ افزایش و مقدار آماره RMSE (مرحله تست) از ۳/۴۶۷۸ به ۰/۸۱۴۵ مترمکعب بر ثانیه کاهش یافته است. به نظر می رسد پیش پردازش صورت گرفته بر روی ماتریس ورودی مدل WNN توسط تبدیل موجک، توانسته قابلیت مدلسازی و پیش بینی دبی جریان را به صورت چشمگیری افزایش دهد.

نتیجه گیری

در این مطالعه، به منظور پیش بینی دبی متوسط روزانه جریان

R^2 از ۰/۳۱۹۰ به ۰/۹۲۰۵ افزایش و مقدار آماره RMSE از ۷/۴۲۹۷ به ۲/۶۲۷۱ مترمکعب بر ثانیه کاهش یافت. نتایج حاصل از مدل WNN نیز با نتایج تحقیق آداموفسکی و سان (۷) تطابق مناسبی دارد. در تحقیق نامبردگان (مرحله تست)، با کاهش افق پیش‌بینی از ۳ روز به ۱ روز مقدار آماره R^2 از ۰/۸۵۹۷ به ۰/۹۷۰۶ افزایش و مقدار آماره RMSE از ۰/۱۳۱۵ به ۰/۱۲۵۸ مترمکعب بر ثانیه کاهش یافت. با توجه به قابلیت و دقت بالای روش WNN در پیش‌بینی دبی متوسط روزانه جریان رودخانه، مطالعات مشابه در دیگر رودخانه‌های کشور توصیه می‌گردد.

۰/۸۴۲۴ به ۰/۹۹۲۷ افزایش و مقدار آماره RMSE (مرحله تست) از ۳/۴۶۷۸ به ۰/۸۱۴۵ مترمکعب بر ثانیه کاهش یافت. به نظر می‌رسد در روش WNN پیش‌پردازش الگوهای ورودی توسط تبدیل موجک، قابلیت مدل‌سازی و پیش‌بینی جریان را بصورت چشمگیری افزایش داده است. در تحقیق حاضر نتایج حاصل از مدل‌های ANN و CW با نتایج تحقیق آداموفسکی (۶) تطابق مناسبی دارد. در تحقیق ایشان (مرحله تست)، در مدل CW با کاهش افق پیش‌بینی از ۷ روز به ۱ روز مقدار آماره R^2 از ۰/۲۵۵۲ به ۰/۹۴۰۵ افزایش و مقدار آماره RMSE از ۸/۷۶۷۱ به ۲/۴۳۲۵ مترمکعب بر ثانیه کاهش یافت. در مدل ANN با کاهش افق پیش‌بینی از ۷ روز به ۱ روز مقدار آماره

منابع

- ۱- بشری م.، و وفاخواه م. ۱۳۸۹. مقایسه روش‌های مختلف تحلیل سری‌های زمانی در پیش‌بینی دبی ماهانه حوزه آبخیز کرخه. فصلنامه علمی پژوهشی مهندسی آبیاری و آب، سال اول، شماره ۲، ص ۸۶-۷۵.
- ۲- فتح آبادی ا.، سلاجقه ع.، و مهدوی م. ۱۳۸۷. پیش‌بینی دبی رودخانه با استفاده از روش‌های نوروفازی و مدل‌های سری‌های زمانی. مجله علمی پژوهشی علوم و مهندسی آبخیزداری ایران، سال دوم، شماره ۵، ص ۳۰-۲۱.
- ۳- کارآموز م.، و عراقی نژاد ش. ۱۳۸۴. هیدرولوژی پیشرفته. انتشارات دانشگاه صنعتی امیرکبیر.
- ۴- منهای م. ۱۳۸۰. مبانی شبکه‌های عصبی مصنوعی (جلد اول). انتشارات دانشگاه صنعتی امیرکبیر.
- 5- Adamowski J. 2008a. Development of a short-term river flood forecasting method for snowmelt driven and cross-wavelet analysis floods based on wavelet. *Journal of Hydrology*. 353: 247-266.
- 6- Adamowski J. 2008b. River flow forecasting using wavelet and cross-wavelet transform models. *Journal of Hydrological Process*. 22: 4877-4891.
- 7- Adamowski J., and Sun K. 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*. 390: 85-91.
- 8- Chen B.H., Wan X.Z. Yang S.H., and McGreavy C. 1999. Application of wavelets and neural Networks to diagnostic System development, 1, feature extraction. *Computers & Chemical Engineering*, 23(7): 899-906.
- 9- Coulibaly P., Anctil F., and Bobee B. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*. 230: 244-257.
- 10- Cannas B., Fanni A., See L., and Sias G. 2006. Data preprocessing for river flow forecasting using neural networks: Wavelet transforms and data partitioning. *Phys. Chem. Earth*. 31(18): 1164-1171.
- 11- Hagan M.T., and Menhaj M.B. 1994. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*. 5: 989-993.
- 12- Jury M.R., Enfield D.B., and Melice J.L. 2002. Tropical monsoons around Africa: stability of El Nino-southern oscillation associations and links with continental climate. *Journal of Geophysical Research*. 107 (C10): 3151 DOI: 10.1029/2000JC000507.
- 13- Kisi O. 2007. Streamflow forecasting using different Artificial Neural Network algorithms. *Journal of Hydrologic Engineering*. 12(5): 533-539.
- 14- Kisi O. 2008. Stream flow forecasting using neuro-wavelet technique. *Journal of Hydrological Process*. 22: 4142-4152.
- 15- Lettenmaier D.P., and Wood E.F. 1992. Hydrologic Forecasting. In: D.R Maidment (eds.). *Handbook OF Hydrology*. McGRAW-HILL, INC. 26.1-26.30.
- 16- Labat D. 2010. Cross wavelet analyses of annual continental freshwater discharge and selected climate indices. *Journal of Hydrology*. 385: 269-278.
- 17- Mallat S. 1989. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 11(7): 674-693.
- 18- Nourani V., Komasi M., and Mano A. 2009. A multivariate ANN-Wavelet approach for Rainfall-Runoff Modeling. *Water Resources Management*. 23: 2877-2894.
- 19- Polikar R. 1996. *Fundamental Concepts and Over View of Wavelet Theory*. Second Edition. Rowan University. College of Engineering Web Servers. Glassboro. NJ.08028.
- 20- Sarangi A. 2005. Comparison of Artificial Neural Network and regression models for sediment loss prediction from

Banha watershed in India. *Journal of Agriculture Water Management*. 78: 195-208.

- 21- Torrence C., and Compo G.P. 1998. A practical guide to wavelet analysis. *Bulletin of the American Meteorological Society*. 79(1): 61-78.
- 22- Wang W. and Ding J. 2003. Wavelet network model and its application to the prediction of hydrology. *Nature and Science*. 1: 67-71.

Forecasting of Mean Daily Runoff Discharge of Behesht-Abad River Using Wavelet Analysis

S. Abdollahi Asadabadi^{1*} - Y. Dinpashoh² - R. Mirabbasi³

Received: 07-12-2013

Accepted: 29-04-2014

Abstract

Forecasting of river discharge is a key aspect of efficient water resources planning and management. In this study, two models based on Wavelet Analysis and Artificial Neural networks (ANNs) were developed for forecasting discharge of Behesht-Abad River. For this purpose, mean daily discharge data of mentioned river as well as precipitation data of 17 meteorological stations were used in the period 1999-2008. In the first method, called Cross Wavelet (CW), complex Morlet wavelet was used as analyzer function. Wavelet analyzing was performed for every daily rainfall and average discharge time series, separately. The model equation derived for 1, 2, 3 and 7 days ahead forecasting horizon. In the second method, called Wavelet Neural Networks conjunction (WNN), a preprocessing was done on the initial input matrix using Meyer wavelet. Then the elements of the initial input matrix were normalized and the second input matrix was created. A three layer Feed Forward Back Propagation (FFBP) was formed based on the second input matrix and target matrix. After training the model using Levenberg-Marquardt (LM) algorithm, the river discharges were predicted for short term time horizons. The results showed that the WNN method had higher accuracy in short-term forecasting of river discharge in comparison with CW and ANN methods. In testing stage, in CW model when forecasting horizon reduced from 7-days to 1day, the R^2 value increased from 0.5113 to 0.9388, and RMSE decreased from 17.9171 to 8.3226 m^3/s . In ANN model when forecasting horizon reduced from 7-days to 1day, the R^2 value increased from 0.6705 to 0.9166, and RMSE decreased from 5.9828 to 2.5600 m^3/s . Whereas, in WNN model, when forecasting horizon reduced from 7-days to 1day, the R^2 value increased from 0.8424 to 0.9927, and RMSE decreased from 3.4678 to 0.8145 m^3/s .

Keywords: Forecasting, River Discharge, Cross Wavelet, Artificial Neural Network

1- PhD Candidate of Water Resources Engineering, Faculty of Water Sciences, Shahid Chamran University of Ahvaz (*- Corresponding Author Email: sajad1998@yahoo.com)

2- Associate Professor of Water Engineering Department, Faculty of Agriculture, University of Tabriz

3- Assistant Professor of Water Engineering Department, Faculty of Agriculture, University of Shahrekord