



Print ISSN: 2251-7480
Online ISSN: 2251-7400

Journal of
Water and Soil
Resources Conservation
(WSRCJ)

Web site:

<https://wsrcj.srbiau.ac.ir>

Email:

iawwsrj@srbiau.ac.ir
iawwsrj@gmail.com

Vol. 13
No. 4 (52)

Received:
2023-09-26

Accepted:
2023-12-22

Pages: 89-102

Evaluation of Time Series Analysis Based on Wavelet Function on River Flow Simulation

Vahed Eslamitabar¹, Ahmad Sharafati^{2*}, Farshad Ahmadi³ and Vahid Rezaverdinejad⁴

1) Phd student, Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.

2) Associate professor, Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.

3) Assistant Professor, Water Engineering Department, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

4) Professor, Department of Water Engineering, Urmia University, Urmia, Iran.

* Corresponding author email: asharafati@srbiau.ac.ir

Abstract:

Introduction: Using the values analyzed by the wavelet function can increase the accuracy of the simulations. Considering the climatic changes and the increase of extreme values in recent years, in this study, we made an effort that the effect of signal processing under the name of wavelet transformation in improving the performance of random forest model in simulating monthly river flow in Siminehrood and Mahabadchai sub-basins in the south of Lake Urmia has been discussed and investigated in the period of 1971-2019.

Materials and Methods: In this study, the accuracy of the random forest model has been investigated in two phases of training and testing. At first, the random forest model was evaluated in two phases of training and testing in rainfall-runoff simulation in the south of Lake Urmia basin. Nash-Sutcliffe statistics and root mean square error were used to evaluate the performance and error rate of the studied models, respectively. In the next step, after investigating the performance of the random forest model, the time series of rainfall and river flow in the studied basins were analyzed using the wavelet function. In this regard, two analysis levels (level 1 and 2) and two Haar and Daubechies wavelet functions were used. Finally, using the random forest model, rainfall-runoff simulation based on the wavelet theory was done under the name of W-RF model.

Results and Dissection: At First, the random forest model was investigated in two phases of training and testing, and the simulation results of the river flow values showed that the simulated values were within the 95% confidence interval, and the error rate of the river flow simulation using the RMSE statistic is 3.22 and 8.91 cubic meters per second in the test phase for Mahabadchai and Siminehrood sub-basins, respectively. In order to investigate the effect of time series analysis on the performance of the RF model, wavelet theory and Haar and Daubechies 4 wavelet functions were used in decomposition levels 1 and 2. By estimating the accuracy and performance of the hybrid W-RF model in 4 input patterns, the best pattern was selected based on the RMSE and NSE model evaluation criteria. The research results showed that for the Haar wavelet function in level 1 decomposition has better performance and error rate than level 2 type in both sub-basins. In this study, the Daubechies wavelet at level 1 in the test phase has provided the best performance and the lowest error rate in the simulation of the river flow values in the studied sub-basins and has been able to reduce the error rate in the two sub-basins of Mahabadchai and Siminehrood respectively by about 89 and 80 percent compared to the random forest model.

Conclusion: Finally, by comparing the RF and W-RF models, the simulation results of river flow in the two studied sub-basins showed that the integrated W-RF model was able to reduce the error rate in the two sub-basins of Mahabadchai and Siminehrood to reduce by 89 and 80% respectively. Considering the increase in simulation complexity with the involvement of wavelet theory, the error recovery rate and model performance are acceptable. The integrated W-RF model in this study provides reliable results for the simulation of river flow data in order to support decision-making and risk analysis in the exploitation of downstream reservoirs and the management of water resources in sub-basins. The obtained results can be used in the design of water resources systems.

Keywords: Daubechies, Haar wavelet, Random forest, Wavelet transform





ارزیابی تجزیه سری زمانی مبتنی بر تابع موجک در شبیه‌سازی دبی جریان رودخانه

واحد اسلامی تبار^۱، احمد شرافتی^{۲*}، فرشاد احمدی^۳ و وحید رضا وردی نژاد^۴

(۱) دانشجوی دکتری، گروه مدیریت ساخت و آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

(۲) دانشیار گروه مدیریت ساخت و آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

(۳) استادیار گروه هیدرولوژی و مهندسی منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز.

(۴) استاد گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه.

* ایمیل نویسنده مسئول: asharafati@srbiau.ac.ir

چکیده:

زمینه و هدف: استفاده از مقادیر تجزیه و تحلیل شده توسط تابع موجک می‌تواند دقت شبیه‌سازی‌ها را افزایش دهد. با توجه به تغییرات اقلیمی و افزایش مقادیر حدی در سال‌های اخیر، در این مطالعه سعی گردید تأثیر پردازش سیگنال تحت عنوان تبدیل موجک در بهبود عملکرد مدل جنگل تصادفی در شبیه‌سازی جریان ماهانه در زیرحوضه‌های سیمینه‌رود و مهابادچای در جنوب دریاچه ارومیه در دوره آماری ۲۰۱۹-۱۹۷۱ مورد بحث و بررسی قرار گیرد.

روش پژوهش: در این مطالعه، دقت مدل جنگل تصادفی در دو مرحله آموزش و آزمون مورد بررسی قرار گرفت. در ابتدا مدل جنگل تصادفی در دو فاز آموزش و آزمایش در شبیه‌سازی بارش-رواناب در جنوب حوضه دریاچه ارومیه مورد ارزیابی قرار گرفت. در خصوص ارزیابی عملکرد و میزان خطای مدل‌های مورد مطالعه به ترتیب از آماره‌های نش-ساتکلیف و جذر میانگین مربعات خطا استفاده شد. در گام بعدی بعد از بررسی عملکرد مدل جنگل تصادفی، اقدام به تجزیه سری‌های زمانی بارش و دبی جریان در حوضه‌های مورد مطالعه با استفاده از تابع موجک شد. در این خصوص از دو سطح تجزیه (سطح ۱ و ۲) و دو تابع موجک Haar و Daubechies استفاده شد. در نهایت با استفاده از مدل جنگل تصادفی به شبیه‌سازی بارش-رواناب مبتنی بر تئوری موجک تحت عنوان مدل W-RF پرداخته شد.

یافته‌ها و تشریح: در ابتدا مدل جنگل تصادفی در دو فاز آموزش و آزمون مورد بررسی قرار گرفته نتایج شبیه‌سازی مقادیر دبی جریان نشان داد که مقادیر شبیه‌سازی شده در محدوده اطمینان ۹۵ درصد واقع شده که میزان خطای شبیه‌سازی مقادیر دبی جریان با استفاده از آماره RMSE به ترتیب برابر با ۳/۲۲ و ۸/۹۱ مترمکعب بر ثانیه در فاز آزمایش برای زیرحوضه مهابادچای و سیمینه‌رود است. جهت بررسی تأثیر تجزیه سری زمانی بر عملکرد مدل RF، از تئوری موجک و تابع موجک‌های Haar و دابچیز ۴ در دو سطح تجزیه ۱ و ۲ استفاده شد. با برآورد دقت و عملکرد مدل تلفیقی W-RF در ۴ الگوی ورودی، بهترین الگو بر اساس معیارهای ارزیابی مدل RMSE و NSE انتخاب گردید. نتایج بررسی‌ها نشان داد که برای تابع موجک Haar، تجزیه سطح ۱ عملکرد و میزان خطای بهتری نسبت به نوع سطح ۲ در هر دو زیرحوضه دارد. در این مطالعه موجک دابچیز در سطح ۱ در فاز آزمایش بهترین عملکرد و کمترین میزان خطا را در شبیه‌سازی مقادیر دبی جریان در زیرحوضه‌های مورد مطالعه ارائه کرده و توانسته است میزان خطا را در دو زیرحوضه مهابادچای و سیمینه‌رود به ترتیب حدود ۸۹ و ۸۰ درصد نسبت به مدل جنگل تصادفی کاهش دهد.

نتایج: در نهایت با مقایسه دو مدل RF و W-RF در شبیه‌سازی مقادیر دبی جریان در دو زیرحوضه مورد مطالعه، نتایج نشان داد که مدل تلفیقی W-RF به دلیل تجزیه سری زمانی مورد مطالعه توانسته است میزان خطا را در دو زیرحوضه مهابادچای و سیمینه‌رود به ترتیب حدود ۸۹ و ۸۰ درصد کاهش دهد. با توجه به افزایش پیچیدگی شبیه‌سازی با دخالت تئوری موجک، میزان بهبودی خطا و عملکرد مدل قابل قبول می‌باشد. مدل تلفیقی W-RF در این مطالعه نتایج قابل اعتمادی را برای شبیه‌سازی داده‌های دبی جریان ارائه می‌دهد تا بتوان از تصمیم‌گیری و تحلیل ریسک در عملیات بهره‌برداری از مخزن‌های پایین دست و مدیریت منابع آب زیرحوضه‌ها پشتیبانی کند. نتایج به دست آمده به‌خوبی می‌تواند در طراحی سامانه‌های منابع آب به کار گرفته شود.

کلمات کلیدی: تبدیل موجک، جنگل تصادفی، دابچیز، شبیه‌سازی دبی جریان، موجک هار



مقدمه

برنامه‌ریزی و مدیریت دقیق و مطمئن منابع آب برای اطمینان از استفاده پایدار از منابع آبخیز بدون مدل‌های دقیق و قابل اعتماد امکان پذیر نیست. علی‌رغم ماهیت بسیار تصادفی فرآیندهای هیدرولوژیکی، توسعه مدل‌هایی که قادر به توصیف چنین پدیده‌های پیچیده‌ای هستند، حوزه تحقیقاتی رو به رشدی است. ارائه بینشی به مدل‌سازی پدیده‌های پیچیده از طریق مروری کامل بر پیشینه پژوهش، تحقیقات جاری و گسترش افق‌های تحقیقاتی می‌تواند پتانسیل مدل‌های دقیق و خوب طراحی شده را افزایش دهد. در چند دهه گذشته پیشرفت قابل توجهی در توانایی توسعه مدل‌های دقیق هیدرولوژیکی مشاهده شده است. در میان مدل‌های مختلف مفهومی و توسعه‌یافته در این دوره، مدل‌های مبتنی بر موجک ترکیبی و هوش مصنوعی^۱ (AI) از امیدوارکننده‌ترین مدل‌ها در شبیه‌سازی فرآیندهای هیدرولوژیکی بوده‌اند (Nourani et al., 2014).

رویکرد مدل‌سازی شبکه عصبی مصنوعی در دو دهه گذشته توجه قابل توجهی را به خود جلب کرده است و با موفقیت در زمینه‌های مختلف از جمله تخمین و پیش‌بینی جریان هیدرولوژیک استفاده شده است (Jain et al., 1999; Zealand et al., 1999; Hu et al., 2005; Sivakumar et al., 2002; Campolo et al., 2003; Nilsson et al., 2006; Kisi and Cigizoglu, 2007; Wei et al., 2013; Darbandi and Pourhosseini, 2018; Jimeno-Sáez et al., 2018; Meresa, 2019; Seifi and Riahi-Madvar, 2019; Noori et al., 2020; Feng and Niu, 2020; Hassanjabbar et al., 2022; Kalhori et al., 2022; Mirzaee and Sarraf, 2022; Geshnigani et al., 2023).

اخیراً، تحلیل یکپارچه موجک و شبکه عصبی مصنوعی (WNN) توجه فزاینده‌ای را به خود جلب کرده است و مزایایی را نسبت به یک مدل ANN و سایر روش‌های مدل‌سازی از نظر برآزش و دقت پیش‌بینی نشان داده است. تجزیه و تحلیل موجک (WA) به دلیل توانایی آن در آشکارسازی هم‌زمان اطلاعات طیفی و زمانی در یک سیگنال، به یک تکنیک تحلیلی محبوب تبدیل شده است. (Wei et al., 2013). استفاده از آنالیز موجک در هیدرولوژی موضوع جدیدی است و برخی از محققان استفاده از آن را آغاز کرده‌اند. ناکن^۲ (۱۹۹۹) ممکن است اولین کسی باشد که از تجزیه و تحلیل موجک برای توصیف تغییرات زمانی بارش-رواناب و روابط آن‌ها استفاده کرد. در ادامه دمیانوف^۳ و همکاران (۲۰۰۱) از تحلیل موجک و ابزارهای زمین آماری (کریجینگ) برای پیمایش تغییرات فضایی بارندگی استفاده کرد و نتایج با نتایج مدل ترکیبی شبکه عصبی مصنوعی و کریجینگ مقایسه شد.

جایاواردنا^۴ و همکاران (۲۰۰۴) همچنین از تجزیه موجک ترکیب شده با مدل مارکوف برای شبیه‌سازی بارش روزانه

حوضه چائو فرایا در تایلند استفاده کرد. کاناس^۵ و همکاران (۲۰۰۶) از تبدیل موجک پیوسته و گسسته و پارتیشن‌بندی داده‌ها برای بررسی اثرات پردازش داده برای پیش‌بینی جریان رودخانه با استفاده از شبکه‌های عصبی استفاده کردند و نشان دادند که شبکه‌های آموزش دیده با داده‌های از پیش پردازش شده بهتر از شبکه‌های آموزش دیده بر روی داده‌های سیگنال جبران نشده عمل می‌کنند. سالنو و تاتاری^۶ (۲۰۰۹) به بررسی مزایای استفاده از تحلیل موجک (WA) در زمینه آب‌های کارستی پرداختند. آن‌ها به دلیل این که روش آماری WA اخیراً در هیدروژئولوژی برای تفسیر دبی‌های چشمه و در هیدروژئولوژی برای توصیف تغییرپذیری جریان‌ها استفاده شده است، بینش‌هایی را در مورد پیوند دینامیکی آن‌ها با حالت‌های غالب تغییرپذیری آب و هوا ارائه دادند. آن‌ها بیان کردند که چگونه WA می‌تواند به‌طور بالقوه برای کمک به تعریف ماهیت و رفتار سهم کارست در جریان رودخانه اعمال شود و در نتیجه عملکرد آینده مدل‌سازی هیدرولوژیکی سطح را بهبود بخشد. یک روش مبتنی بر تبدیل موجک گسسته (DWT) و ANN، که برای پیش‌بینی جریان رودخانه فصلی در حوضه نیمه‌خشک قبرس استفاده شد، توسط آداموفسکی و سان^۷ (۲۰۱۰) ارائه شد. آن‌ها بیان کردند مدل WANN برای پیش‌بینی جریان دقیق‌تر از ANN بود. نتایج نشان تحقیق آن‌ها نشان داد که مدل‌های WANN روش‌های جدیدی را برای پیش‌بینی جریان کوتاه‌مدت در رودخانه‌های غیر چندساله در حوزه‌های آبخیز نیمه‌خشک مانند آنچه در قبرس یافت می‌شوند، امیدوار می‌کنند.

وی^۸ و همکاران (۲۰۱۱) یک رویکرد مدل‌سازی ترکیبی شبکه‌های عصبی موجک (WNN) را برای تخمین و پیش‌بینی جریان ماهانه رودخانه توسعه دادند. این رویکرد تجزیه موجک گسسته را با وضوح چندگانه و یک شبکه عصبی مصنوعی پرسپترون چند لایه (FFML) با انتشار پس انتشار (BP) ادغام می‌کند. الگوریتم لونبرگ-مارکوورت (LM) و الگوریتم تنظیم بیزین (BR) برای انجام مدل‌سازی شبکه به کار گرفته شد. داده‌های جریان ماهانه از سه دریاچه در رودخانه وی در چین برای آموزش شبکه و آزمایش برای پیش‌بینی ۴۸ ماه آینده استفاده شد. مقایسه نتایج مدل ترکیبی WNN با نتایج مدل ANN منفرد نشان داد که مدل اول قادر است دقت پیش‌بینی را به میزان قابل توجهی افزایش دهد.

داندنمه^۹ و همکاران (۲۰۱۳) پیش‌بینی‌های جریان ماهانه با استفاده از برنامه‌ریزی ژنتیکی خطی (LGP) را انجام داده و با مدل WANN مقایسه کردند. نتایج نشان داد که LGP خطی عملکرد بهتری نسبت به WANN دارد. (Asadi et al., 2013). ترکیب جدیدی از شبکه عصبی مصنوعی برای مدل‌سازی بارش-رواناب در حوضه آق چای، ایران ارائه کرد. مدل

را برآورد کند. ژو و همکاران (۲۰۲۳) به پیش‌بینی سری زمانی دبی رودخانه ماهانه در دو سایت اندازه‌گیری هیدرومتری واقع در رودخانه میسوری، ایالات متحده با استفاده از دو مدل یادگیری ماشین مبتنی بر تقویت گرادیان شدید (XGB) و K-نزدیک‌ترین همسایگان (KNN) پرداختند. آن‌ها از تجزیه موجک (W) برای توسعه رویکردهای ترکیبی W-XGB و W-KNN استفاده کردند. در مرحله آزمایش، بهترین پیش‌بینی‌ها مربوط به هیبریدی W-XGB معرفی شد.

احمدی^{۱۳} (۲۰۲۱) جهت پیش‌بینی جریان ماهانه رودخانه آب زال در دوره آماری ۱۳۵۱ تا ۱۳۹۶ از دو مدل برنامه‌ریزی بیان ژن و مدل ترکیبی برنامه‌ریزی بیان ژن و موجک استفاده کردند. نتایج کلی پژوهش آن‌ها نشان داد که مدل ترکیبی برنامه‌ریزی بیان ژن-موجک از عملکرد بسیار مطلوبی برخوردار بوده به طوری که می‌توان از آن را به‌عنوان یک روش مؤثر در پیش‌بینی جریان میان مدت رودخانه‌ها معرفی نمود.

مرور منابع نشان می‌دهد که استفاده از مقادیر تجزیه شده توسط تابع موجک می‌تواند دقت شبیه‌سازی‌ها را افزایش دهد. با توجه به تغییرات اقلیمی و افزایش مقادیر حدی در سال‌های اخیر، این مطالعه سعی دارد تا اثر تجزیه سری مشاهداتی را در شبیه‌سازی مقادیر دبی جریان مشاهداتی بررسی کند. هدف اصلی این تحقیق ارزیابی الگوریتم جنگل تصادفی در دو حالت تجزیه مقادیر مشاهداتی و عدم تجزیه مقادیر مشاهداتی بر پایه تابع موجک در دو سطح ۱ و ۲ می‌باشد. در واقع نوآوری اصلی این تحقیق بررسی اثر تجزیه سری زمانی بر دقت شبیه‌سازی-های مبتنی بر جنگل تصادفی می‌باشد.

مواد و روش‌ها

منطقه مورد مطالعه

این مطالعه در دو زیر حوضه سیمینه‌رود و مهابادچای در جنوب دریاچه ارومیه واقع در شمال غرب ایران انجام شده و از داده‌های دبی (مترمکعب بر ثانیه) و بارش (میلی‌متر) در مقیاس ماهانه در دوره آماری ۱۹۷۱ تا ۲۰۱۹ استفاده شده است. شکل ۱ منطقه مورد مطالعه و موقعیت ایستگاه‌های انتخابی را نشان می‌دهد. مشخصات آماری داده‌های مورد بررسی نیز به شرح جدول ۱ ارائه گردید. مقادیر اولیه داده‌های مورد مطالعه نیز به صورت شکل ۲ ارائه گردید.

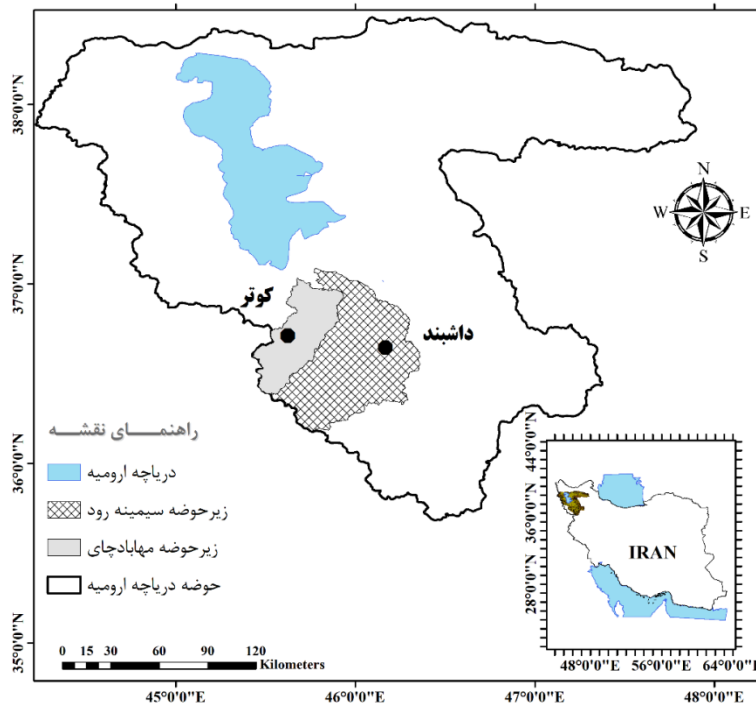
شکل ۲ نمودار تغییرات مقادیر مشاهداتی بارش و دبی جریان در زیرحوضه‌های مهابادچای (الف) و سیمینه‌رود (ب) را در طی دوره آماری مورد مطالعه نشان می‌دهد. با توجه به شکل‌های ارائه شده می‌توان تغییرات ثبت شده متغیرهای بارش و دبی جریان را مشاهده کرد.

پیشنهادی ترکیبی از روش‌های پردازش داده، الگوریتم‌های ژنتیک و الگوریتم لونبرگ-مارکوارت برای آموزش ورودی شبکه عصبی بود. نتایج نشان داد که این روش در پیش‌بینی رواناب دقیق‌تر از ANN و ANFIS است.

سولگی^{۱۱} و همکاران (۲۰۱۷) از مدل‌های رگرسیون بردار پشتیبان (SVR) و برنامه‌ریزی بیان ژن (GEP) در مقیاس روزانه و ماهانه به‌منظور شبیه‌سازی جریان رودخانه گاماسیاب در نیاوند استفاده کردند. نتایج تحقیق آن‌ها نشان داد که اگرچه عملکرد مدل‌ها در مقیاس روزانه قابل قبول و نتیجه مدل SVR کمی بهتر بود، اما عملکرد آن‌ها در مقیاس روزانه بهتر از مقیاس ماهانه بود. بنابراین از تبدیل موجک استفاده شد و سیگنال اصلی هر ورودی تجزیه شد. سپس با استفاده از روش تحلیل مؤلفه اصلی، سیگنال‌های فرعی مهم شناسایی و به‌عنوان ورودی برای مدل‌های SVR و GEP برای تولید رگرسیون بردار پشتیبان موجک (WSVR) و برنامه‌ریزی بیان موجک-ژن استفاده شد. نتایج نشان داد که عملکرد WSVR بهتر از SVR است به گونه‌ای که ترکیب SVR با موجک می‌تواند ضریب تعیین مدل را به ترتیب تا ۳ و ۱۸ درصد برای مقیاس روزانه و ماهانه بهبود بخشد. در مجموع می‌توان گفت که ترکیب موجک با SVR ابزار مناسبی برای پیش‌بینی جریان رودخانه گاماسیاب در دو مقیاس روزانه و ماهانه است.

زاخروف^{۱۱} و همکاران (۲۰۱۷) به توسعه یک مدل پیوند -تبدیل موجک، مدل‌های مبتنی بر داده و الگوریتم ژنتیک (GA) برای پیش‌بینی جریان روزانه یک رودخانه در شمال الجزایر با استفاده از سری زمانی رواناب انجام شده پرداختند. حوضه مورد بررسی آن‌ها دارای آب و هوای نیمه‌خشک و تنوع زیاد رواناب بود. سری زمانی اولیه توسط الگوریتم تبدیل موجک به سری‌های زمانی چند فرکانس تجزیه شد و به‌عنوان ورودی برای شبکه‌های عصبی مصنوعی (ANN) و مدل‌های سیستم استنتاج عصبی فازی تطبیقی (ANFIS) استفاده شد. آن‌ها بیان کردند که برای تعیین بهترین ساختار مدل باید چندین عامل بهینه شود. نتایج بررسی آن‌ها نشان داد که عملکرد مدل‌های مبتنی بر داده‌های مبتنی بر موجک (یعنی WANN و WANFIS) نسبت به مدل‌های معمولی برتر بود.





موهانتا^{۱۲} و همکاران (۲۰۲۱) دو مدل سیستم استنتاج عصبی فازی کواکتیو (CANFIS) و سیستم استنتاج عصبی فازی کواکتیو موجک (WCANFIS) را برای پیش‌بینی سری های زمانی جریان رودخانه مورد بررسی قرار دادند. آن‌ها از سری زمانی جریان رودخانه ماهانه در دوره ۲۰۱۱-۱۹۸۹ در حوضه رودخانه گانگا، هند استفاده کردند. نتایج ارزیابی مدل‌ها نشان داد که مدل WCANFIS با دقت بیشتری نسبت به مدل CANFIS توانسته است سری‌های زمانی ماهانه جریان رودخانه



شکل ۱. موقعیت زیرحوضه‌های مورد مطالعه در حوضه دریاچه ارومیه و ایران

جدول ۱. مشخصات آماری داده‌های مورد بررسی

زیرحوضه	ایستگاه	نوع ایستگاه	کمینه	بیشینه	متوسط
مهابادچای	کوثر	هیدرومتری (m^3/s)	۱/۴	۱۴/۴	۶/۴
	کوثر	هواشناسی (mm)	۱۴۹/۰	۹۲۸/۰	۴۱۳/۹
سیمینه رود	داشبند	هیدرومتری (m^3/s)	۲/۴	۳۹/۰	۱۴/۱
	داشبند	هواشناسی (mm)	۱۵۲/۳	۹۲۰/۴	۳۹۲/۵



(ب)

(الف)

شکل ۲. مقادیر اولیه بارش و دبی در دوره آماری ۱۹۷۱-۲۰۲۰ (الف: زیرحوضه مهابادچای، ب: زیرحوضه سیمینه‌رود)

تبدیل موجک

نظریه موجک روشی برگرفته از نظریه فوریه است و در قرن نوزدهم ارائه شد (Solgi et al., 2017a). مفهوم فعلی نظریه موجک توسط مورلت و تیمی در مرکز تحقیقاتی فیزیک نظری مارسل زیر نظر الکس گروسمن در فرانسه ارائه شد. تبدیل موجک یک تبدیل ریاضی کارآمد در زمینه پردازش سیگنال است. موجک‌ها توابع ریاضی هستند که شکل مقیاس زمانی سری‌های زمانی و توابع آن‌ها را برای تجزیه و تحلیل سری‌های زمانی که شامل متغیرهای نا ایستا می‌شود، ارائه می‌دهند. تجزیه و تحلیل موجک فواصل طولانی مدت برای اطلاعات با فرکانس پایین و فواصل زمانی کوتاه‌تر برای اطلاعات با بالاتر ارائه می‌دهد.

تجزیه و تحلیل موجک قادر است جنبه‌های مختلفی از داده‌ها، نقاط شکست و ناپیوستگی‌های مختلف را نشان دهد که سایر روش‌های تحلیل سیگنال ممکن است قادر به نشان دادن آن نباشند. تابع موجک دارای دو ویژگی مهم نوسان و کوتاه بودن است. $\psi(x)$ تابع موجک است اگر و تنها در صورتی که تبدیل فوریه $\psi(x)$ شرط زیر را برآورده کند (Mallat, 1989):

$$\int_{-\infty}^{+\infty} \frac{|\psi(x)|}{|\omega|^2} d\omega < +\infty \quad (1)$$

این شرط به‌عنوان شرط پذیرش موجک شناخته می‌شود. معادله فوق را می‌توان معادل رابطه زیر در نظر گرفت:

$$\int_{-\infty}^{+\infty} \psi(x) dx = 0 \quad (2)$$

این ویژگی توابع که میانگین برابر با صفر است، فیلتر سختگیرانه‌ای نیست و بسیاری از توابع را می‌توان به‌عنوان توابع موجک بر اساس آن در نظر گرفت. $\psi(x)$ تابع موجک مادر است که در تجزیه و تحلیل توسط دو روش ریاضی به نام ترجمه و مقیاس استفاده می‌کند که باعث تغییر در اندازه و مکان سیگنال تحلیل شده می‌شود.

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (3)$$

در نهایت، ضریب موجک می‌تواند در هر نقطه سیگنال (b) و برای هر مقدار مقیاس (a) با معادله زیر قابل محاسبه باشد (Mallat, 1989):

$$T(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \psi\left(\frac{t-b}{a}\right) f(t) dt \quad (4)$$

در معادله فوق، a برابر با مقیاس و b برابر با تبدیل است. برای مقدار T مقادیر مختلف a و b به دست می‌آید. هر گاه T بالاترین مقدار مثبت را داشته باشد، بیشترین تعدیل رخ می‌دهد. هیچ تعدیلی برای T برابر با صفر وجود ندارد و برای مقدار منفی T تعدیل معکوس می‌شود یا بزرگ‌ترین تفاوت رخ می‌دهد. توابع موجک انواع مختلفی دارند و بسته به کاربردشان، دقت آن‌ها متفاوت است.

توابع موجک

بسته به کاربردشان، توابع موجک انواع مختلفی با سطوح دقت متفاوت دارند. متداول‌ترین توابع موجک به‌عنوان تابع موجک هار^{۱۴} دنبال می‌شوند. تابع موجک هار ساده‌تر و یکی از اولین موجک‌ها است. تابع موجک Daubechies یکی از کارآمدترین توابع موجک در کشف ناپیوستگی‌های محلی در سیگنال‌ها است. تابع موجک Symlet خواصی شبیه به خانواده Daubechies دارد. توابع Sym6 و Sym4 تقریباً متقارن هستند و در کشف آسیب‌ها استفاده می‌شوند. موجک‌های دیگر عبارتند از Mexican, Coif, Meyer, Morlet, Gaussian, hat و Bior (Solgi et al., 2017). یکی از نکات کلیدی مهم در انتخاب موجک‌های مادر، طبیعت و نوع سری‌های زمانی است. بنابراین، الگوهای توابع موجک مادر، که می‌توانند از نظر هندسی با منحنی سری زمانی تطبیق داده شوند، انطباق بهتری انجام می‌دهند و نتایج به دست آمده بهتر خواهد بود.

مدل جنگل تصادفی

الگوریتم جنگل تصادفی توسط براین^{۱۵} (۲۰۰۱) به‌عنوان یک روش یادگیری جمعی برای مسائل مبتنی بر رگرسیون و خوشه‌بندی ارائه شده است. جنگل تصادفی ترکیبی از چندین درخت تصمیم است که در ساخت آن چندین نمونه خودسازمانده از داده‌ها شرکت دارند. فرایند تصمیم در هر گره داخلی از گره ریشه، طبق قانون درختی تکرار می‌شود تا زمانی که شرط توقف قبلی تعیین شده به دست آید (Nazeri Tahroudi et al., 2023; Bageri et al., 2023).

در روش RF بردار تصادفی X_n که مستقل از بردارهای تصادفی X_1, X_2, \dots, X_{n-1} بوده، برای درخت \ln ام، تولید می‌شود. همچنین همه بردارها از توزیع مشابهی تبعیت می‌کنند. رگرسیون درختی با استفاده از مجموعه داده‌های آموزش و X_n محاسبه شده مجموعه درخت‌هایی برابر با n را به شرح زیر تولید می‌نماید.

$$X_n = \{h_1(x), h_2(x), \dots, h_n(x)\} \quad (5)$$

$$h_n = h(x, X_n), x = \{x_1, x_2, \dots, x_p\} \quad (6)$$

بردار p بعدی فوق یک جنگل را تشکیل داده و خروجی‌ها برای هر درخت به صورت زیر ارائه می‌شود:

$$y_1 = h_1(x), y_2 = h_2(x), \dots, y_n = h_n(x) \quad (7)$$

که y_n خروجی درخت \ln ام می‌باشد. برای به دست آوردن خروجی نهایی، متوسط همه پیش‌بینی‌های درخت‌ها محاسبه می‌شود (Breiman, 2001).

معیارهای ارزیابی مدل

برای انتخاب بهترین مدل برازشی، جذر میانگین مربعات خطا (RMSE) (رابطه ۱۱) و معیار نش- ساتکلیف (رابطه ۱۲) محاسبه شد. هرکدام از مدل‌های برازشی که بیشترین مقدار معیار نش- ساتکلیف (NSE) و کمترین RMSE را داشته باشند، به‌عنوان مدل مناسب برگزیده می‌شود.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (S_i - O_i)^2}{n-1}}$$

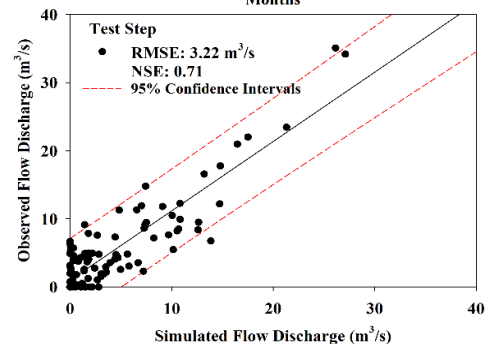
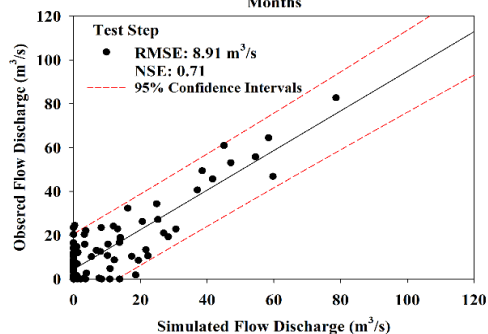
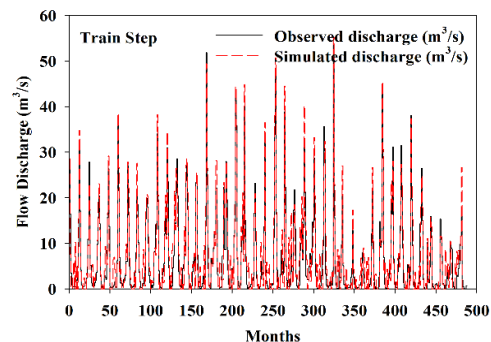
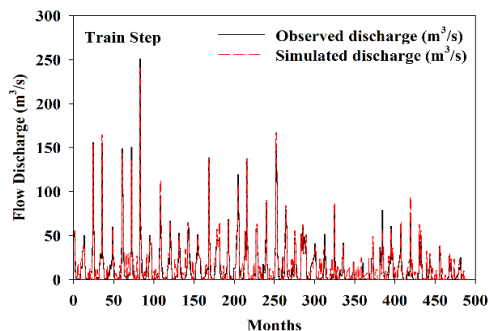
$$NSE = 1 - \frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2}$$

که در روابط فوق، n تعداد داده‌ها، مقدار نمونه مشاهداتی، \bar{O}_i میانگین مقادیر نمونه‌ها و S_i مقدار خروجی مدل مورد آزمون برای هر سری زمانی می‌باشد (Nash and Sutcliffe, 1979; Pronoos Sedighi et al., 2023).

نتایج و بحث

در این مطالعه از دو مدل جنگل تصادفی (RF) و جنگل تصادفی مبتنی بر تئوری موجک (W-RF) جهت شبیه‌سازی بارش رواناب در زیرحوضه‌های مورد مطالعه استفاده شده است. در ابتدا به شبیه‌سازی مقادیر دبی جریان با استفاده از مدل RF پرداخته شد و در نهایت با تجزیه سری زمانی توسط تئوری موجک به شبیه‌سازی بارش-رواناب با استفاده از مدل W-RF پرداخته شد.

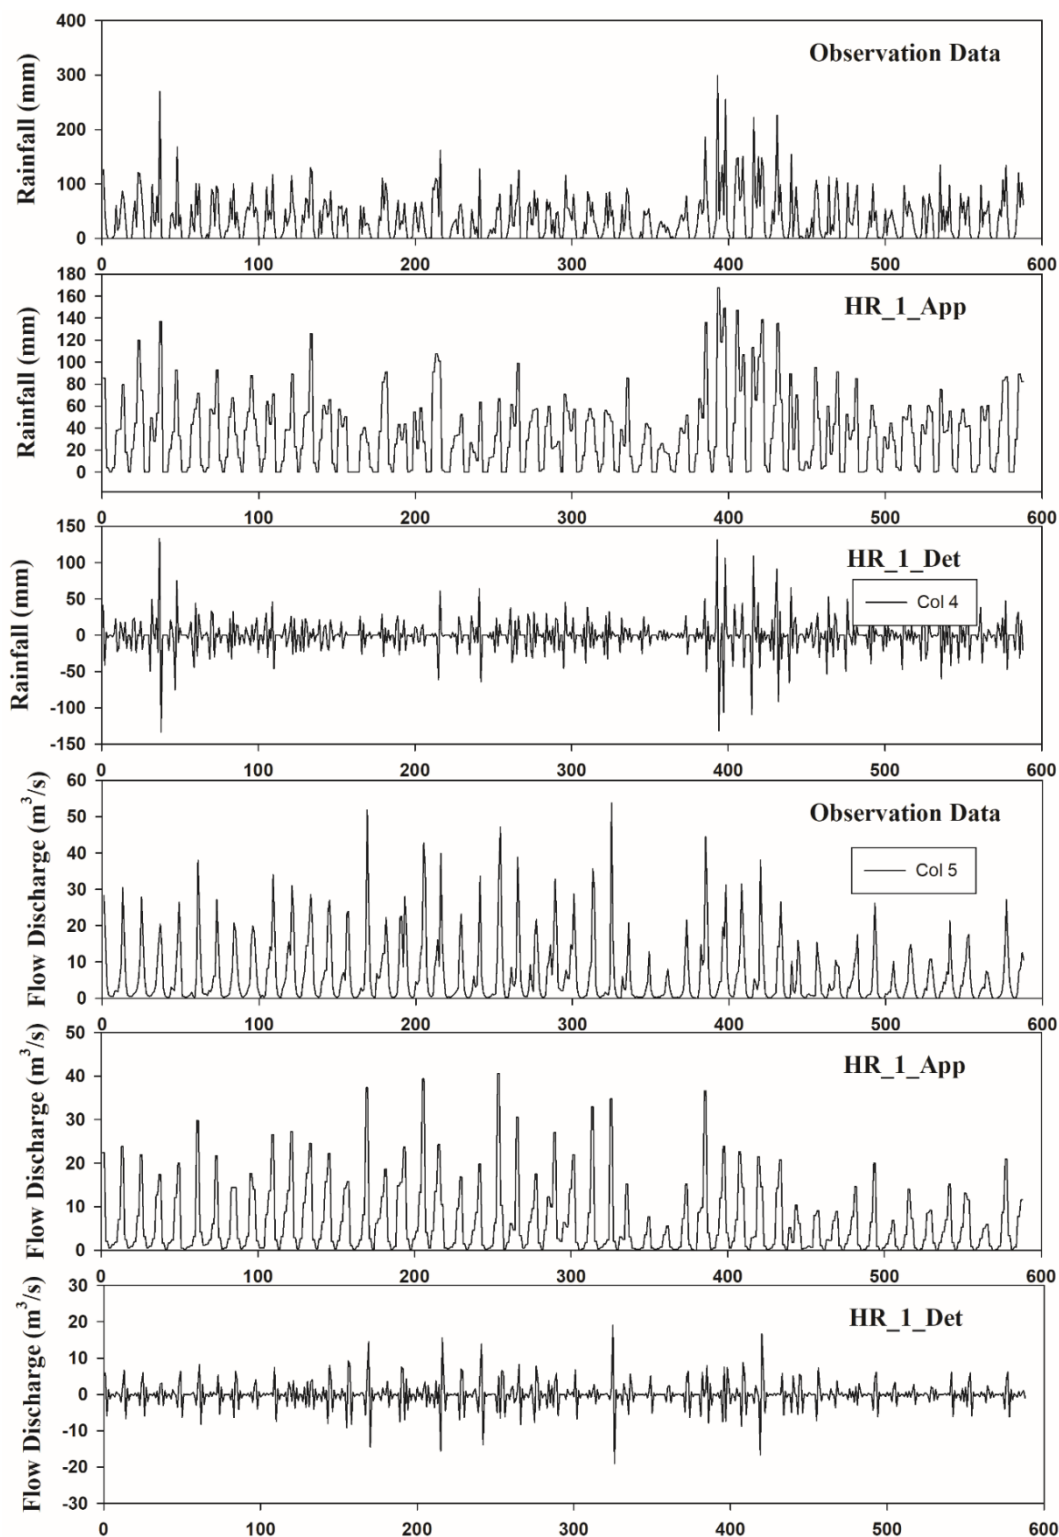
نتایج شبیه‌سازی بارش-رواناب مبتنی بر مدل جنگل تصادفی



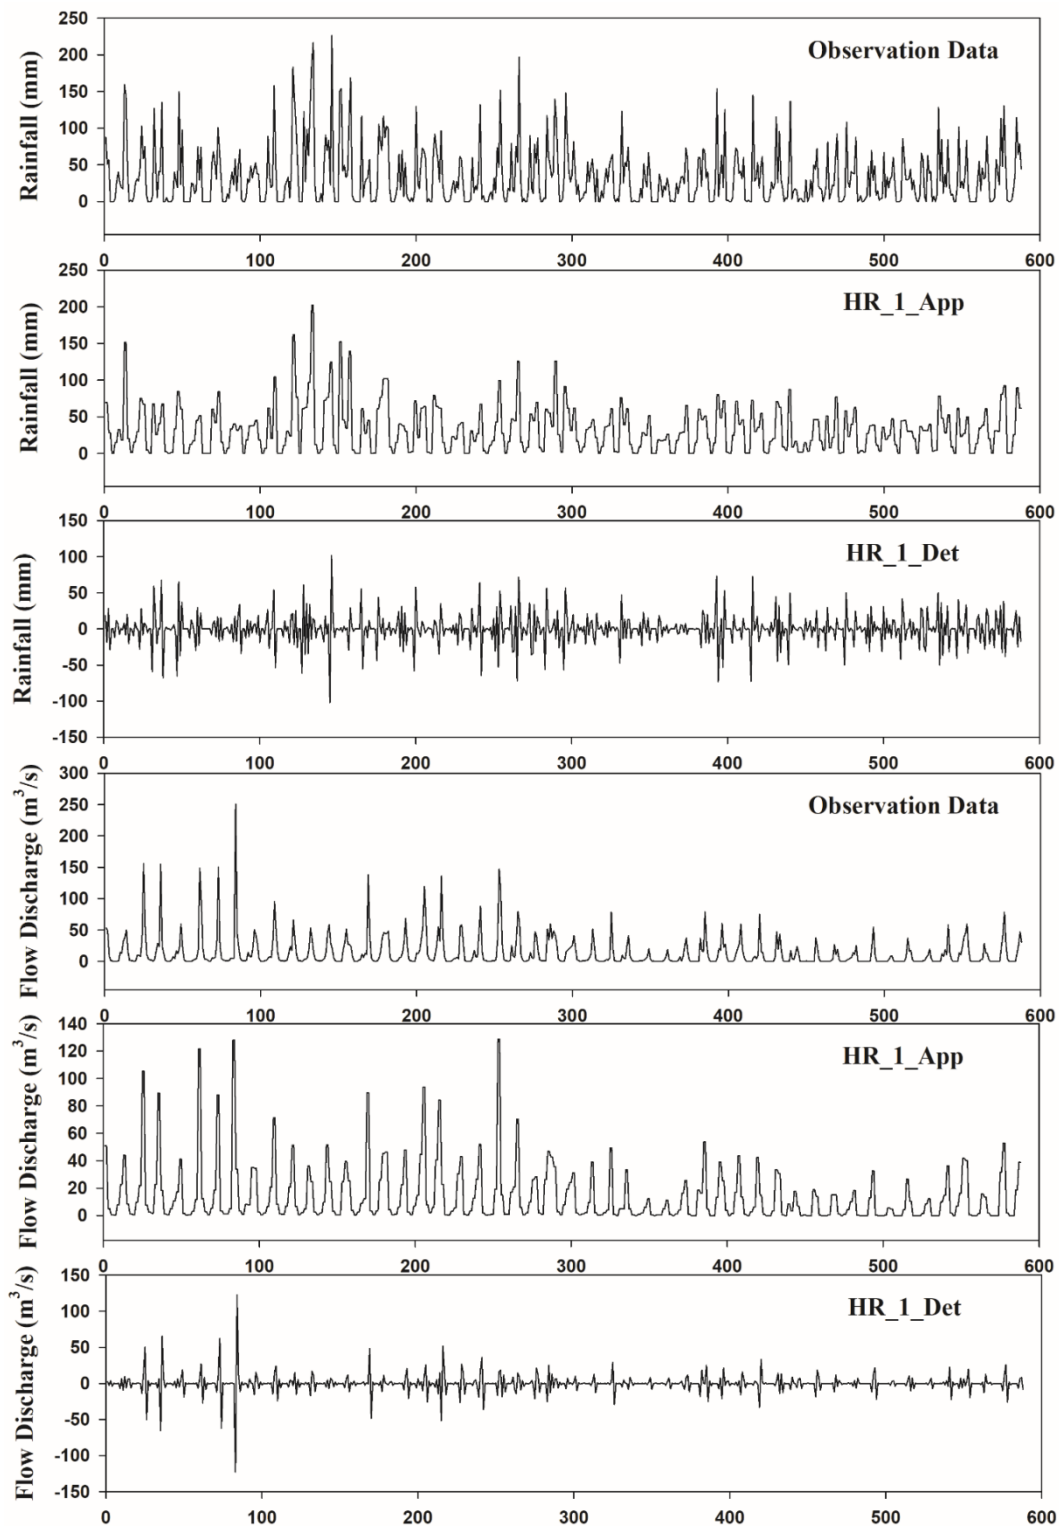
(ب)

(الف)

شکل ۳. نتایج شبیه‌سازی بارش-رواناب با استفاده از مدل جنگل تصادفی در دو مرحله آموزش و آزمایش (الف: زیرحوضه مهابادچای، ب: زیرحوضه سیمینه‌رود)



شکل ۴. نتایج تجزیه سری‌های مورد مطالعه با استفاده از تابع موجک و الگوی ورودی MI برای زیرحوضه مهابادچای



شکل ۵. نتایج تجزیه سری‌های مورد مطالعه با استفاده از تابع موجک و الگوی ورودی M1 برای زیرحوضه سیمینه‌رود

جریان تابعی از تجزیه دبی جریان و بارش در سطح ۱ و موجک Haar است که با الگوی M1 نشان داده شده است. الگوی دوم، M2، تجزیه سطح دو مقادیر دبی جریان و بارش است که توسط موجک Haar انجام شده است. الگوی سوم، تجزیه مقادیر دبی و بارش در سطح یک و توسط موجک دابچیز ۴ بوده که با M3

نتایج شبیه‌سازی بارش-رواناب مبتنی بر مدل W-RF جهت بررسی و ارزیابی مدل W-RF در شبیه‌سازی بارش-رواناب در ایستگاه‌های مورد مطالعه از تابع موجک و الگوریتم جنگل تصادفی استفاده شد. در این خصوص ۴ سناریو برای هر ایستگاه به شرح زیر در نظر گرفته شد. الگوی اول، مقادیر دبی

جدول ۲ می‌توان مشاهده کرد که در فاز آزمایش، سطح تجزیه ۱ عملکرد بهتری نسبت به سطح تجزیه ۲ دارد.

با توجه به جدول ۳ می‌توان مشاهده کرد که کارایی مدل W-RF مطابق با آماره NSE در دو فاز آموزش و آزمایش در دو زیرحوضه مورد مطالعه رضایت‌بخش بوده که بیانگر کارایی بالای مدل W-RF در شبیه‌سازی مقادیر دبی جریان تحت تأثیر تجزیه مبتنی بر موجک می‌باشد. در تمامی زیرحوضه‌های مورد مطالعه در هر دو فاز آموزش و آزمایش، کارایی مدل W-RF نسبت به مدل جنگل تصادفی بیشتر می‌باشد. مقادیر RMSE منتج از مدل W-RF نسبت به مدل جنگل تصادفی نیز در تمامی موارد کمتر می‌باشد که بهبود میزان خطا را نشان می‌دهد. با توجه به جدول ۲ می‌توان مشاهده کرد که میزان خطای مدل W-RF در شبیه‌سازی مقادیر دبی جریان در زیرحوضه مهابادچای در دو فاز آموزش و آزمایش نسبت به مدل جنگل تصادفی به ترتیب حدود ۸۲ و ۸۹ درصد بهبود یافته است. کارایی مدل W-RF نیز نسبت به مدل RF در فاز آموزش و آزمایش به ترتیب ۱۳ و ۳۹ درصد بهبود یافته است. در زیرحوضه سیمینه‌رود نیز مقادیر خطای شبیه‌سازی دبی جریان توسط مدل W-RF در دوره آماری مورد بررسی در دو فاز آموزش و آزمایش نسبت به مدل RF به ترتیب بهبود ۶۴ و ۸۰ درصدی میزان خطا را نشان می‌دهد. مدل W-RF توانست با تجزیه مقادیر بارش و دبی جریان در حالت‌های مختلف، میزان خطای شبیه‌سازی را در دو فاز آموزش و آزمایش بهبود بخشد. نتایج شبیه‌سازی مقادیر دبی جریان در زیرحوضه‌های مورد بررسی با استفاده از الگوی برتر مدل W-RF به صورت شکل ۶ ارائه شد.

با توجه به شکل ۶-الف می‌توان مشاهده کرد که در زیرحوضه مهابادچای، مدل W-RF با میزان خطای ۰/۳۷ مترمکعب بر ثانیه و کارایی ۰/۹۹ پوشش کاملی بر داده‌های مشاهده‌ای دارند، و محدوده اطمینان ۹۵ درصد شبیه‌سازی شده بر داده‌ها منطبق می‌باشد. بیش تخمینی و کم تخمینی در نتایج شبیه‌سازی مدل W-RF در زیرحوضه‌های مورد مطالعه مشاهده نشد. در زیرحوضه سیمینه‌رود نیز به غیر از چندین مورد خارج از محدوده اطمینان ۹۵ درصد، سایر موارد در

نشان داده شده است. در نهایت الگوی چهارم که با M4 نشان داده شده است، تجزیه سطح دو مقادیر دبی جریان و بارش توسط موجک دابچیز ۴ می‌باشد.

M1: $Q_t = f(\text{decomposition inputs } (Q \text{ and } R) \text{ via Haar wavelet, level } 1)$

M2: $Q_t = f(\text{decomposition inputs } (Q \text{ and } R) \text{ via Haar wavelet, level } 2)$

M3: $Q_t = f(\text{decomposition inputs } (Q \text{ and } R) \text{ via db4 wavelet, level } 1)$

M4: $Q_t = f(\text{decomposition inputs } (Q \text{ and } R) \text{ via db4 wavelet, level } 2)$

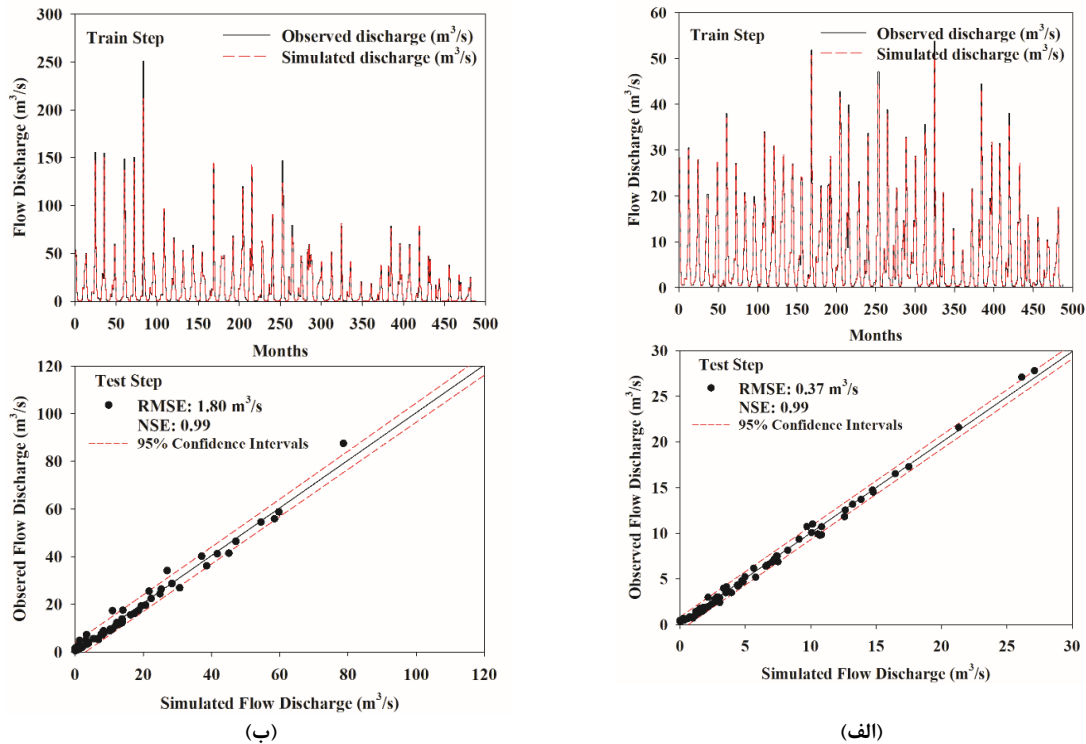
نتایج تجزیه سری‌های مورد بررسی به صورت شکل‌های ۴ و ۵ برای الگوهای M1 به ترتیب برای زیرحوضه‌های مهابادچای و سیمینه‌رود برای نمونه ارائه شد.

الگوهای مورد مطالعه با استفاده از مدل جنگل تصادفی در دو فاز آموزش و آزمایش مورد بررسی و شبیه‌سازی قرار گرفت و در نهایت مقادیر شبیه‌سازی شده به صورت تجمیعی با مقادیر مشاهداتی مقایسه شد. این مقایسه با استفاده از آماره‌های RMSE و NSE در هر ایستگاه بررسی شد.

نتایج بررسی آماره‌های خطا و کارایی مدل W-RF در شبیه‌سازی مقادیر دبی جریان در ایستگاه‌های مورد مطالعه به صورت جدول ۲ ارائه شد. مطابق جدول ۲، نتایج بررسی میزان خطا (RMSE) در شبیه‌سازی مقادیر دبی جریان در زیرحوضه مهابادچای نشان داد که در فاز آموزش کمترین میزان خطا مربوط به الگوی M1 با ۰/۴۷ مترمکعب بر ثانیه و کارایی مدل ۹۹ درصد می‌باشد. در زیرحوضه سیمینه‌رود نیز مطابق جدول ۲، کمترین میزان خطا (۲/۵۱ مترمکعب بر ثانیه) بیشترین کارایی مدل (۹۹ درصد) در فاز آموزش مربوط به الگوی M1 می‌باشد. در فاز آموزش کمترین میزان خطا در شبیه‌سازی دبی جریان مربوط در زیرحوضه‌های مهابادچای و سیمینه‌رود مربوط به الگوی M3 می‌باشد که به ترتیب میزان خطایی برابر با ۰/۳۷ و ۱/۸ مترمکعب بر ثانیه دارند. با توجه به اهمیت فاز آزمایش در شبیه‌سازی مقادیر دبی جریان، الگوی M3 به‌عنوان الگوی برتر در شبیه‌سازی بارش-رواناب در منطقه مورد مطالعه معرفی شد. این الگو بر اساس تابع موجک دابچیز ۴ و سطح تجزیه ۱ می‌باشد. با توجه به

جدول ۲. نتایج بررسی مقادیر خطا (RMSE) و کارایی مدل (NSE) در شبیه‌سازی مقادیر دبی جریان با استفاده از دو مدل RF و W-RF

مدل	سیمینه‌رود				مهابادچای			
	NSE		RMSE (m ³ /s)		NSE		RMSE (m ³ /s)	
	Test	Train	Test	Train	Test	Train	Test	Train
RF	۰/۷۱	۰/۹۰	۸/۹۱	۸/۴۷	۰/۷۱	۰/۸۸	۳/۲۲	۳/۳
M1	۰/۹۸	۰/۹۹	۲/۰۳	۲/۵۱	۰/۹۹	۰/۹۹	۰/۵۲	۰/۴۷
M2	۰/۹۲	۰/۹۹	۴/۶۲	۲/۹۷	۰/۹۶	۰/۹۹	۱/۲۵	۰/۸۶
M3	۰/۹۹	۰/۹۹	۱/۸	۳/۰۷	۰/۹۹	۰/۹۹	۰/۳۷	۰/۵۸
M4	۰/۹۶	۰/۹۸	۳/۲۴	۳/۵۶	۰/۹۹	۰/۹۹	۰/۷۱	۰/۷۲



شکل ۶ نتایج شبیه‌سازی بارش-رواناب با استفاده از مدل W-RF در دو مرحله آموزش و آزمایش (الف: زیرحوضه مهابادچای (مدل M3)، ب: زیرحوضه سیمینه‌رود (مدل M3))

بارش-رواناب در زیرحوضه‌های مهابادچای و سیمینه‌رود با استفاده از مدل جنگل تصادفی نشان داد که میزان خطای شبیه‌سازی مقادیر دبی جریان با استفاده از آماره RMSE به ترتیب برابر با ۳/۲۲ و ۸/۹۱ مترمکعب بر ثانیه در فاز آزمایش می‌باشد. همچنین نتایج بررسی کارایی مدل (NSE) نشان داد که کارایی مدل RF در فاز آزمایش در شبیه‌سازی مقادیر دبی جریان در زیرحوضه‌های مهابادچای و سیمینه‌رود ۰/۷۱ می‌باشد و اکثر موارد شبیه‌سازی شده در محدوده اطمینان ۹۵ درصد واقع شده‌اند. جهت بررسی تأثیر تجزیه سری زمانی بر عملکرد مدل RF، از تئوری موجک و تابع موجک‌های Haar و دابچیز ۴ در دو سطح تجزیه ۱ و ۲ استفاده شد. با برآورد دقت و عملکرد مدل تلفیقی W-RF در ۴ الگوی ورودی، بهترین الگو بر اساس معیارهای ارزیابی مدل RMSE و NSE انتخاب شد. نتایج بررسی‌ها نشان داد که برای تابع موجک Haar، تجزیه سطح ۱ عملکرد و میزان خطای بهتری نسبت به نوع سطح ۲ در هر دو زیرحوضه دارد. میزان خطای شبیه‌سازی شده توسط مدل W-RF در سطح ۱ در زیرحوضه‌های مهابادچای و سیمینه‌رود به ترتیب برابر با ۰/۵۲ و ۲/۰۳ مترمکعب بر ثانیه در فاز آزمایش می‌باشد که نسبت به تابع Haar در سطح ۲، میزان خطا را در فاز آزمایش حدود ۱۴۰ و ۱۲۸ درصد به ترتیب در زیرحوضه‌های مهابادچای و سیمینه‌رود کاهش داده است. در خصوص تابع موجک دابچیز ۴ نیز میزان خطای شبیه‌سازی در سطح

محدوده ۹۵ درصد شبیه‌سازی قرار دارند. با توجه به شکل‌های ارائه شده به خوبی می‌توان عملکرد بهتر مدل W-RF در شبیه‌سازی مقادیر دبی جریان ماهانه را مشاهده کرد. این مدل با تجزیه سری زمانی و افزایش بعد محاسبات توانست دقت و میزان کارایی نتایج شبیه‌سازی را افزایش دهد.

به‌طور کلی نتایج این تحقیق نشان داد که با تجزیه سری زمانی و افزایش بعد شبیه‌سازی‌ها می‌توان دقت و کارایی مدل مبتنی بر جنگل تصادفی را بهبود بخشید. همچنین نتایج نشان داد که با توجه به سطح تجزیه مورد استفاده، در هر سطح تجزیه، تابع موجک دابچیز ۴ عملکرد بهتری نسبت به تابع موجک‌ها دارد که این موضوع با مطالعات احمدی (۲۰۲۱) و نکوئیان و همکاران (۲۰۲۲) مطابقت دارد. افزایش بعد شبیه‌سازی به دلیل افزایش پارامترهای وابسته و مؤثر، رابطه بهتری در خصوص شبیه‌سازی به دست می‌آید و سبب افزایش قطعیت مدل‌ها می‌شود.

نتیجه‌گیری

در این مطالعه به منظور شبیه‌سازی دبی جریان متأثر از بارش در زیرحوضه‌های مهابادچای و سیمینه‌رود در جنوب دریاچه ارومیه از ۲ مدل جنگل تصادفی و مدل تلفیقی W-RF (جنگل تصادفی مبتنی بر تابع موجک) استفاده شد. جهت شبیه‌سازی مقادیر یاد شده، داده‌های مورد بررسی به دو فاز آموزش و آزمایش تقسیم شد. نتایج شبیه‌سازی دومتغیره

تجزیه سری زمانی مورد مطالعه توانسته است میزان خطا را در دو زیرحوضه مهابادچای و سیمینه رود به ترتیب حدود ۸۹ و ۸۰ درصد کاهش دهد. با توجه به افزایش پیچیدگی شبیه‌سازی با دخالت تئوری موجک، میزان بهبودی خطا و عملکرد مدل قابل قبول می‌باشد. مدل تلفیقی W-RF در این مطالعه نتایج قابل اعتمادی را برای شبیه‌سازی داده‌های دبی جریان ارائه می‌دهد تا بتوان از تصمیم‌گیری و تحلیل ریسک در عملیات بهره‌برداری از مخزن‌های پایین دست و مدیریت منابع آب زیرحوضه‌ها پشتیبانی کند. نتایج به دست آمده به‌خوبی می‌تواند در طراحی سامانه‌های منابع آب به کار گرفته شوند.

یک نسبت به سطح ۲ در زیرحوضه‌های مهابادچای و سیمینه-رود به ترتیب حدود ۹۲ و ۸۰ درصد کاهش یافته است. به‌طور کلی، تجزیه سطح ۱ عملکرد و میزان خطای بهتری نسبت به تجزیه سطح دو در خصوص هر دو تابع موجک ارائه کرده است. در نهایت بهترین الگو در فاز آموزش، الگوی M1 (تجزیه سطح ۱ تابع موجک Haar) و بهترین الگو در فاز آزمایش، الگوی M3 (تجزیه سطح ۱ تابع موجک db4) معرفی شد. در بین الگوهای مورد بررسی موجک دابچیز در سطح ۱ در فاز آزمایش بهترین عملکرد و کمترین میزان خطا را در شبیه‌سازی مقادیر دبی جریان در زیرحوضه‌های مورد مطالعه ارائه کرد. در نهایت با مقایسه دو مدل RF و W-RF نتایج شبیه‌سازی مقادیر دبی جریان در دو زیرحوضه مورد مطالعه نشان داد که مدل تلفیقی W-RF به دلیل

Reference:

- Adamowski, J., & 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(1-2), 85-91.
- Ahmadi, F. (2021). Evaluation of the Efficiency of Data Preprocessing Methods on Improving the Performance of Gene Expression Programming Model (Case Study: Ab Zal River). *Journal of Water and Soil*, 35(2), 153-165. [In Persian].
- Asadi, S., Shahrabi, J., Abbaszadeh, P., & Tabanmehr, S. (2013). A new hybrid artificial neural networks for rainfall-runoff process modeling. *Neurocomputing*, 121, 470-480.
- Bageri, F., Khalili, K., & Nazeri Tahrudi, M. (2023). Evaluation of Entropy Theory Based on Random Forest in Quality Monitoring of Ground Water Network. *Water and Irrigation Management*, 13(1), 123-139
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Campolo, M., Soldati, A., & Andreussi, P. (2003). Artificial neural network approach to flood forecasting in the River Arno. *Hydrological Sciences Journal*, 48(3), 381-398.
- Cannas, B., Fanni, A., See, L., & Sias, G. (2006). Data preprocessing for river flow forecasting using neural networks: wavelet transforms and data partitioning. *Physics and Chemistry of the Earth, Parts A/B/C*, 31(18), 1164-1171.
- Danandeh Mehr, A., Kahya, E., & Olyae, E. (2013). Streamflow prediction using linear genetic programming in comparison with a neurowavelet technique. *J Hydrol* 505:240-249.
- Darbandi, S., & Pourhosseini, F. A. (2018). River flow simulation using a multilayer perceptron-firefly algorithm model. *Applied Water Science*, 8(3), 1-9.
- Demyanov, V., Soltani, S., Kanevski, M., Canu, S., Maignan, M., Savelieva, E., ... & Pisarenko, V. (2001). Wavelet analysis residual kriging vs. neural network residual kriging. *Stochastic Environmental Research and Risk Assessment*, 15(1), 18-32.
- Feng, Z. K., & Niu, W. J. (2021). Hybrid artificial neural network and cooperation search algorithm for nonlinear river flow time series forecasting in humid and semi-humid regions. *Knowledge-Based Systems*, 211, 106580.
- Geshnigani, F. S., Golabi, M. R., Mirabbasi, R., & Tahroudi, M. N. (2023). Daily solar radiation estimation in Belleville station, Illinois, using ensemble artificial intelligence approaches. *Engineering Applications of Artificial Intelligence*, 120, 105839.
- Hassanjabbar, A., Nezaratian, H., & Wu, P. (2022). Climate change impacts on the flow regime and water quality indicators using an artificial neural network (ANN): a case study in Saskatchewan, Canada. *Journal of Water and Climate Change*.
- Hu, T. S., Lam, K. C., & Ng, S. T. (2005). A Modified Neural Network for Improving River Flow Prediction/Un Réseau de Neurons Modifié pour Améliorer la Prévision de L'Écoulement Fluvial. *Hydrological sciences journal*, 50(2).
- Jain, S. K., Das, A., & Srivastava, D. K. (1999). Application of ANN for reservoir inflow prediction and operation. *Journal of water resources planning and management*, 125(5), 263-271.
- Jayawardena, A. W., Xu, P., & Tsang, F. L. L. (2004, July). Rainfall predication by wavelet decomposition. In *Asia Pacific Association of Hydrology and Water Resources Conference, Singapore*.
- Jimeno-Sáez, P., Senent-Aparicio, J., Pérez-Sánchez, J., & Pulido-Velazquez, D. (2018). A comparison of SWAT and ANN models for daily runoff simulation in different climatic zones of peninsular Spain. *Water*, 10(2), 192.

- Kalhari, M., Ashofteh, P. S., Moghadam, S. H., & Singh, V. P. (2022). Investigating the effect of uncertainty of AOGCM-TAR and AOGCM-AR5 climate change models on river runoff. *Arabian Journal of Geosciences*, 15(13), 1-16.
- Kisi, O., & Kerem Cigizoglu, H. (2007). Comparison of different ANN techniques in river flow prediction. *Civil Engineering and Environmental Systems*, 24(3), 211-231.
- Mallat, S. G. (1989). Multiresolution approximations and wavelet orthonormal bases of $L^2(R)$. *Transactions of the American mathematical society*, 315(1), 69-87.
- Meresa, H. (2019). Modelling of river flow in ungauged catchment using remote sensing data: application of the empirical (SCS-CN), artificial neural network (ANN) and hydrological model (HEC-HMS). *Modeling Earth Systems and Environment*, 5(1), 257-273.
- Mirzaee, N., & Sarraf, A. (2022). Application of data fusion models in river flow simulation using signals of large-scale climate, case study: Jiroft Dam Basin. *Watershed Engineering and Management*, 13(4), 672-689.
- Mohanta, N. R., Patel, N., Beck, K., Samantaray, S., & Sahoo, A. (2021). Efficiency of river flow prediction in river using wavelet-CANFIS: a case study. In *Intelligent Data Engineering and Analytics: Frontiers in Intelligent Computing: Theory and Applications (FICTA 2020)*, Volume 2 (pp. 435-443). Springer Singapore.
- Nakken, M. (1999). Wavelet analysis of rainfall-runoff variability isolating climatic from anthropogenic patterns. *Environmental Modelling & Software*, 14(4), 283-295.
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I—A discussion of principles. *Journal of Hydrology*, 10(3), 282-290.
- Nazeri Tahroudi, M., Ahmadi, F., & Mirabbasi, R. (2023). Performance comparison of IHACRES, random forest and copula-based models in rainfall-runoff simulation. *Applied Water Science*, 13(6), 134.
- Nekoeeyan, M. A., Radmanesh, F., & Ahmadi, F. (2022). Prediction of Monthly Streamflow Using Shannon Entropy and Wavelet Theory Approaches (Case study: Maroon River). *Water and Irrigation Management*, 12(1), 15-31. doi: 10.22059/jwim.2022.335702.949. [In Persian].
- Nilsson, P., Uvo, C. B., & Berndtsson, R. (2006). Monthly runoff simulation: Comparing and combining conceptual and neural network models. *Journal of Hydrology*, 321(1-4), 344-363.
- Noori, N., Kalin, L., & Isik, S. (2020). Water quality prediction using SWAT-ANN coupled approach. *Journal of Hydrology*, 590, 125220.
- Nourani, V., Baghanam, A. H., Adamowski, J., & Kisi, O. (2014). Applications of hybrid wavelet-artificial intelligence models in hydrology: a review. *Journal of Hydrology*, 514, 358-377.
- Pronoos Sedighi, M., Ramezani, Y., Nazeri Tahroudi, M., & Taghian, M. (2023). Joint frequency analysis of river flow rate and suspended sediment load using conditional density of copula functions. *Acta Geophysica*, 71(1), 489-501.
- Salerno, F., & Tartari, G. (2009). A coupled approach of surface hydrological modelling and Wavelet Analysis for understanding the baseflow components of river discharge in karst environments. *Journal of hydrology*, 376(1-2), 295-306.
- Seifi, A., & Riahi-Madvar, H. (2019). Improving one-dimensional pollution dispersion modeling in rivers using ANFIS and ANN-based GA optimized models. *Environmental Science and Pollution Research*, 26(1), 867-885.
- Sivakumar, B., Jayawardena, A. W., & Fernando, T. M. K. G. (2002). River flow forecasting: use of phase-space reconstruction and artificial neural networks approaches. *Journal of hydrology*, 265(1-4), 225-245.
- Solgi, A., Pourhaghi, A., Bahmani, R., & Zarei, H. (2017a). Pre-processing data using wavelet transform and PCA based on support vector regression and gene expression programming for river flow simulation. *Journal of Earth System Science*, 126(5), 1-17.
- Solgi, A., Zarei, H., Nourani, V., & Bahmani, R. (2017b). A new approach to flow simulation using hybrid models. *Applied Water Science*, 7(7), 3691-3706.
- Wei, S., Yang, H., Song, J., Abbaspour, K., & Xu, Z. (2013). A wavelet-neural network hybrid modelling approach for estimating and predicting river monthly flows. *Hydrological Sciences Journal*, 58(2), 374-389.
- Zakhrouf, M., Bouchelkia, H., Stamboul, M., Kim, S., & Heddami, S. (2018). Time series forecasting of river flow using an integrated approach of wavelet multi-resolution analysis and evolutionary data-driven models. A case study: Sebaou River (Algeria). *Physical Geography*, 39(6), 506-522.
- Zealand, C. M., Burn, D. H., & Simonovic, S. P. (1999). Short term streamflow forecasting using artificial neural networks. *Journal of hydrology*, 214(1-4), 32-48.
- Zhou, J., Wang, D., Band, S. S., Jun, C., Bateni, S. M., Moslehpour, M., ... & Ameri, R. (2023). Monthly River Discharge Forecasting Using Hybrid Models Based on Extreme Gradient Boosting Coupled with Wavelet Theory and Lévy-Jaya Optimization Algorithm. *Water Resources Management*, 1-20.

- ¹ *Artificial intelligence*
- ² *Nakken*
- ³ *Demyanov*
- ⁴ *Jayawardena*
- ⁵ *Cannas*
- ⁶ *Salerno and Tartari*
- ⁷ *Adamowski and Sun*
- ⁸ *Wei*
- ⁹ *Danandeh Mehr*
- ¹⁰ *Solgi*
- ¹¹ *Zakhrouf*
- ¹² *Mohanta*
- ¹³ *Ahmadi*
- ¹⁴ *Haar*
- ¹⁵ *Breiman*