

Simulation of the Flow of the Kermanshah Razavar River Using the Extreme Learning Model and the Meta-Heuristic Optimization Algorithms of Whale and Grasshopper

Meysam Bagherifar and Maryam Hafezparast Mavaddat ^{1*} 

(Received: March 14-2025 ; Revised: July 7-2025 ; Accepted: September 29-2025)

1. Department of Water Engineering, Faculty of Agriculture, Razi University, Kermanshah, Iran.

*: Corresponding author, Email: m.hafezparast@razi.ac.ir

Abstract

The river flow prediction is a key aspect of hydrology that plays a significant role in water resources management, flood risk reduction, and agricultural planning. This study simulates the monthly flow of the Razavar River, located in western Iran, using an extreme learning machine (ELM) model enhanced by the Whale (WOA) Optimization Algorithm and Grasshopper Optimization Algorithm (GOA) metaheuristic optimization algorithms. The data used include river flow, precipitation, evaporation, and temperature, which were collected for 10 years with a monthly time step and normalized in the numerical range of zero to one. 80% of the data is used for training, and the remaining 20% for model evaluation. The performance of the models is measured with the statistical indices RMSE, NSE, and R^2 . First, the basic ELM model is developed using the trial-and-error method to adjust the weights between the hidden and output layers. Then, the WOA and GOA algorithms are used to optimize the weights. The results show that the basic ELM model performs worse than the optimized models (Train: RMSE=0.1427, NSE=0.7795, R^2 =0.7911, Test: RMSE=0.1406, NSE=0.7811, R^2 =0.7916). While the WOA-ELM and GOA-ELM models provide similar results, the WOA-ELM model shows better performance in complex conditions (Train: RMSE=0.1215, NSE=0.7869, R^2 =0.7932, Test: RMSE=0.1165, NSE=0.7872, R^2 =0.7933). The results of this research show that meta-heuristic optimization algorithms play an important role in improving the performance of river flow prediction models due to their ability to search comprehensively and avoid getting stuck in local optima. The findings of this study emphasize the importance of applying these techniques in water resources management and sustainable planning and will pave the way for future research in this area.

Keywords: River engineering, Extreme learning machine, Optimization algorithm, GOA, WOA

How to cite this article: Bagherifar, M. and Hafezparast Mavaddat, M. 2025. Simulation of the Flow of the Kermanshah Razavar River Using the Extreme Learning Model and the Meta-Heuristic Optimization Algorithms of Whale and Grasshopper. *J. Water and Soil Sci.* 29(4): 73-93. DOI: [10.47176/jwss.29.4.70281](https://doi.org/10.47176/jwss.29.4.70281)

Copyright © 2025 Bagherifar and Hafezparast. Published by Isfahan University of Technology.



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International license (<https://creativecommons.org/licenses/by-nc/4.0/>). Non-commercial uses of the work are permitted, provided the original work is properly cited.

شبیه‌سازی جریان رودخانه رازور کرمانشاه با استفاده از مدل یادگیری افراطی و الگوریتم‌های بهینه‌سازی فراابتکاری نهنگ و ملخ

میثم باقری‌فر و مریم حافظ‌پرست مودت^{*id}

(تاریخ دریافت: ۱۴۰۳/۱۲/۲۴؛ تاریخ بازنگری: ۱۴۰۴/۴/۱۶؛ تاریخ پذیرش: ۱۴۰۴/۷/۷)

۱. گروه مهندسی آب، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران.

*: مسئول مکاتبات: پست الکترونیکی: m.hafezparast@razi.ac.ir

چکیده

پیش‌بینی جریان رودخانه یکی از جنبه‌های کلیدی هیدرولوژی است که نقش بسزایی در مدیریت منابع آب، کاهش خطرات ناشی از سیل و برنامه‌ریزی کشاورزی ایفا می‌کند. هدف اصلی این مطالعه، شبیه‌سازی دقیق و پیش‌بینی جریان ماهانه رودخانه رازور در استان کرمانشاه، با توسعه و ارزیابی مدل ترکیبی ماشین یادگیری افراطی (ELM) بهینه‌سازی‌شده توسط الگوریتم‌های فراابتکاری نهنگ (WOA) و ملخ (GOA) است. برای این منظور، داده‌های ماهانه جریان رودخانه، بارندگی، تبخیر و دما برای یک بازه زمانی ۱۰ ساله با گام زمانی ماهانه جمع‌آوری و در بازه عددی صفر تا یک نرمال‌سازی شدند. ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده برای ارزیابی مدل‌ها استفاده شد. عملکرد مدل‌ها با شاخص‌های آماری NSE ، $RMSE$ و R^2 سنجیده شد. ابتدا مدل پایه ELM با استفاده از روش سعی و خطا برای تنظیم وزن‌های بین لایه‌های پنهان و خروجی توسعه یافت. سپس، الگوریتم‌های WOA و GOA برای بهینه‌سازی وزن‌ها به کار گرفته شدند. نتایج نشان داد که مدل پایه ELM نسبت به مدل‌های بهینه‌سازی‌شده عملکرد ضعیف‌تری دارد (آموزش: $RSME=0.1427$ ، $NSE=0.7795$ ، $R^2=0.7911$ ؛ تست: $RSME=0.1406$ ، $NSE=0.7811$ ، $R^2=0.7916$). مدل GOA-ELM نسبت به مدل ELM عملکرد بهتر اما نسبت به مدل WOA-ELM عملکرد ضعیف‌تری داشت (آموزش: $RSME=0.1366$ ، $NSE=0.7855$ ، $R^2=0.7922$ ؛ تست: $RSME=0.1328$ ، $NSE=0.7859$ ، $R^2=0.7925$). مدل WOA-ELM نسبت به همه مدل‌ها عملکرد بهتری دارد (آموزش: $RSME=0.1215$ ، $NSE=0.7869$ ، $R^2=0.7932$ ؛ تست: $RSME=0.1165$ ، $NSE=0.7872$ ، $R^2=0.7933$). این پژوهش نشان می‌دهد که الگوریتم‌های بهینه‌سازی فراابتکاری به دلیل توانایی جستجوی جامع و جلوگیری از گرفتار شدن در بهینه‌های محلی، نقش مهمی در بهبود عملکرد مدل‌های پیش‌بینی جریان رودخانه دارند. یافته‌های این مطالعه، بر اهمیت به‌کارگیری این تکنیک‌ها در مدیریت منابع آب و برنامه‌ریزی پایدار تأکید می‌کند و زمینه‌ساز پژوهش‌های آتی در این حوزه خواهد بود.

واژه‌های کلیدی: مهندسی رودخانه، ماشین یادگیری افراطی، الگوریتم بهینه‌سازی، WOA، GOA.

حق انتشار این مستند، متعلق به دانشگاه صنعتی اصفهان است. © ۱۴۰۴.

این مقاله تحت گواهی زیر منتشر شده و هر نوع استفاده غیرتجاری از آن مشروط به استناد صحیح به مقاله و با رعایت

شرایط مندرج در آدرس زیر مجاز است: (<https://creativecommons.org/licenses/by-nc/4.0/>)



مقدمه

رودخانه‌ها به‌عنوان یکی از منابع اصلی آب سطحی در کره زمین، نقش حیاتی در اکوسیستم‌ها، کشاورزی، تأمین آب آشامیدنی، تولید انرژی و حفظ تنوع زیستی ایفا می‌کنند. این منابع آب، علاوه بر تأمین نیازهای انسانی، در تنظیم چرخه هیدرولوژیک زمین و کنترل سیلاب‌ها نقش بسیار مهمی دارند. با توجه به تغییرات اقلیمی و افزایش فشارهای انسانی بر منابع آب، شبیه‌سازی جریان رودخانه‌ها به ابزاری حیاتی برای پیش‌بینی رفتار این منابع آبی و مدیریت بهینه آنها تبدیل شده است. در این میان، درک دقیق جریان رودخانه و پیش‌بینی تغییرات آن به‌ویژه در مناطقی که منابع آبی از این رودخانه‌ها تأمین می‌شود، امری ضروری است (۴).

یکی از مهم‌ترین کاربردهای شبیه‌سازی جریان رودخانه، پیش‌بینی و مدیریت منابع آب است. در بسیاری از مناطق جهان، رودخانه‌ها منبع اصلی تأمین آب آشامیدنی، کشاورزی و صنعتی هستند. به‌ویژه در مناطق خشک و نیمه‌خشک که منابع آبی محدودتر است، مدیریت صحیح جریان رودخانه‌ها می‌تواند به کاهش خطرات کمبود آب و بهبود بهره‌وری منابع کمک کند. در این راستا، شبیه‌سازی جریان رودخانه‌ها با استفاده از مدل‌های هیدرولوژیک دقیق می‌تواند نقش بسزایی در پیش‌بینی نیازهای آبی و تخصیص منابع آب در بخش‌های مختلف ایفا کند (۱۵).

یکی دیگر از کاربردهای مهم شبیه‌سازی جریان رودخانه، پیش‌بینی خطر سیلاب‌هاست. سیلاب‌ها به‌عنوان یکی از بلایای طبیعی با اثرهای اقتصادی، اجتماعی و زیست‌محیطی گسترده شناخته می‌شوند. پیش‌بینی صحیح سیلاب‌ها به‌ویژه در مناطق شهری و حاشیه رودخانه‌ها می‌تواند به برنامه‌ریزی برای کاهش خسارات ناشی از آنها کمک کند. شبیه‌سازی‌های دقیق جریان رودخانه و تحلیل رفتار آنها در برابر بارش‌های شدید و تغییرات اقلیمی، می‌تواند به طراحان و مسئولین مدیریت بحران این امکان را بدهد تا در زمان مناسب اقدامات پیشگیرانه را انجام دهند (۲۴).

با وجود اهمیت شبیه‌سازی جریان رودخانه‌ها، این فرایند چالش‌های متعددی را به همراه دارد. پیچیدگی‌های هیدرولوژیک، تغییرات اقلیمی و تأثیرات فعالیت‌های انسانی همچون ساخت سدها و تغییرات در کاربری اراضی، موجب می‌شود که پیش‌بینی دقیق جریان رودخانه‌ها همواره با عدم قطعیت‌هایی همراه باشد. به‌علاوه، داده‌های موردنیاز برای مدل‌سازی‌های دقیق معمولاً از کیفیت و دقت مطلوب برخوردار نیستند و در بسیاری از مناطق، ایستگاه‌های اندازه‌گیری جریان آب به‌صورت کافی در دسترس نیستند. به همین دلیل، نیاز به توسعه مدل‌های جدید و استفاده از روش‌های نوین برای بهبود دقت پیش‌بینی‌ها بیش‌ازپیش احساس می‌شود (۲).

در این راستا، استفاده از الگوریتم‌های بهینه‌سازی و یادگیری ماشینی به‌عنوان روش‌های نوین در مدل‌سازی جریان رودخانه‌ها مطرح شده است. این الگوریتم‌ها با توانایی جستجوی هوشمندانه و تنظیم پارامترهای مدل به طور خودکار، می‌توانند دقت پیش‌بینی‌ها را به طور قابل توجهی افزایش دهند. به طور خاص، الگوریتم‌های بهینه‌سازی فراابتکاری مانند الگوریتم‌های نهنگ (WOA) و ملخ (GOA) به دلیل قابلیت جستجوی گسترده و اجتناب از گیرکردن در بهینه‌های محلی، برای شبیه‌سازی دقیق جریان رودخانه‌ها بسیار مؤثر هستند. این الگوریتم‌ها به مدل‌ها کمک می‌کنند تا بهترین ترکیب از پارامترها را شبیه‌سازی کرده و خطاهای پیش‌بینی را کاهش دهند (۷).

همچنین، مدل‌سازی جریان رودخانه‌ها می‌تواند به کاهش اثرهای منفی تغییرات اقلیمی کمک کند. تغییرات دما، بارش و الگوهای تبخیر در اثر تغییرات اقلیمی، به‌ویژه در مناطق حساس، می‌تواند موجب تغییرات عمده‌ای در جریان‌های رودخانه‌ها شود. با شبیه‌سازی دقیق جریان‌ها و تحلیل تغییرات احتمالی در آینده، می‌توان به طور مؤثرتر به برنامه‌ریزی برای سازگاری با این تغییرات پرداخته و تدابیر مناسبی را برای جلوگیری از بحران‌های آبی اتخاذ کرد. این امر به‌ویژه در

مناطقى که در معرض تهدیدات ناشى از تغییرات اقلیمى هستند، بسیار حیاتی است (۲۲).

در نهایت، شبیه‌سازی جریان رودخانه‌ها نه تنها به پیش‌بینی دقیق‌تر رفتار این منابع آبی کمک می‌کند، بلکه می‌تواند به تصمیم‌گیری‌های بهینه در خصوص مدیریت منابع آب، پیشگیری از سیلاب‌ها و سازگاری با تغییرات اقلیمی منجر شود. استفاده از مدل‌های پیشرفته و روش‌های بهینه‌سازی که توانایی تحلیل داده‌های پیچیده و متعدد را دارند، می‌تواند به عنوان ابزاری کلیدی در دستیابی به مدیریت پایدار منابع آبی در قرن بیست و یکم مطرح شود. این فرایند، علاوه بر بهبود کیفیت زندگی انسانی، به حفظ اکوسیستم‌ها و منابع طبیعی برای نسل‌های آینده نیز کمک خواهد کرد (۳). تاکنون مطالعات زیادی درباره استفاده از این روش‌ها برای شبیه‌سازی جریان رودخانه انجام شده است. برای نمونه کیسی و همکاران (۲۰۲۴) با هدف بررسی رابطه مرحله - دبی، از سه روش یادگیری ماشین شامل شبکه عصبی چندلایه (MLNN)، شبکه عصبی پایه شعاعی (RBNN) و سیستم عصبی - فازی تطبیقی (ANFIS) استفاده کردند. برای این کار از داده‌های روزانه رودخانه استفاده کردند. در این مطالعه برای ارزیابی عملکرد مدل‌ها از شاخص‌هایی مانند $RMSE$ ، $MAPE$ ، R^2 و DDR کردند. بر اساس نتایج حاصل مدل MLNN بهترین عملکرد را دارد (۱۴).

ابوعلی‌گاہ و دیابت (۲۰۲۰) در مطالعه‌ای به ارزیابی عملکرد الگوریتم‌های بهینه‌سازی نهنگ (WOA) و ملخ (GOA) در کالیبراسیون پارامترهای مدل‌های هیدرولوژیک برای پیش‌بینی سطح آب زیرزمینی پرداختند. آنها نشان دادند که این الگوریتم‌ها به دلیل قابلیت جستجوی جهانی قوی، می‌توانند به طور مؤثر پارامترهای مدل را تنظیم کرده و دقت پیش‌بینی را بهبود بخشند. این پژوهش بر اهمیت استفاده از این الگوریتم‌ها در مسائل بهینه‌سازی پیچیده در حوزه منابع آب تأکید دارد (۱).

ایلهان (۲۰۲۲) جریان آب رودخانه را با استفاده از الگوریتم‌های یادگیری ماشین برای یک دوره ۹ ساله در شیلی

شبیه‌سازی کردند. آنها برای این کار از مدل‌های FCM، ANFIS، LSTM و SC استفاده کردند. بر اساس نتایج حاصل از این مطالعه، مدل ANFIS-FCM بهترین عملکرد دارد. با این حال مدل ANFIS-SC نیز عملکرد مناسبی داشت. این پژوهش نشان داد که رویکردهای FCM و SC در ANFIS ابزارهای مؤثری برای پیش‌بینی جریان رودخانه هستند (۱۳).

مطالعه چن و همکاران (۲۰۲۳) درباره بررسی هشدار زودهنگام جریان اکولوژیک برای مدیریت بهینه منابع آب حوضه رودخانه جیاوجیانگ در جنوب شرقی چین است. برای این کار ابتدا از تکنیک ترکیبی جداسازی جریان پایه و روش Tennant برای محاسبه جریان اکولوژیک استفاده شد. سپس یک مدل هشدار زودهنگام بر پایه تکنیک یادگیری ماشین LightGBM توسعه دادند. آنها در این مطالعه از روش (SHAP) برای تحلیل تأثیر عوامل هیدرومتئورولوژیک بر تغییرات جریان اکولوژیک استفاده کردند. نتایج این مطالعه نشان داد که دقت پیش‌بینی مدل هشدار جریان اکولوژیک در این ایستگاه‌ها نزدیک به ۹۰٪ است و تبخیر و شاخص جریان پایه به عنوان مهم‌ترین عوامل تأثیرگذار بر تغییرات جریان اکولوژیک هستند (۵).

تنگ و همکاران (۲۰۲۵) داده‌های بارندگی و جریان مربوط به ۹۸ سیلاب رخ داده بین سال‌های ۱۹۷۱ تا ۲۰۱۴ در زیرحوضه جینگل، یکی از شاخه‌های حوضه رودخانه زرد چین، را با استفاده از خوشه‌بندی پویا و جنگل تصادفی تحلیل کردند. هدف این تحلیل شناسایی انواع سیلاب و انتخاب پارامترهای مناسب برای مدل‌سازی آن است. بعد از توسعه مدل‌های مختلف، این مدل‌ها برای پیش‌بینی سیلاب‌های واقعی استفاده شدند. بر اساس نتایج حاصل از این مطالعه این روش‌ها امکان شناسایی سیلاب‌های شدید، طبقه‌بندی بهتر سیلاب‌ها، کاهش خطرات و استفاده بهینه از منابع آب را دارند و می‌توان از آنها به عنوان ابزاری قدرمند برای این کار استفاده کرد (۲۵). در مجموع، بررسی پیشینه پژوهش نشان می‌دهد که مدل‌های یادگیری ماشین و الگوریتم‌های بهینه‌سازی فراابتکاری، ابزارهای

قدرتمندی برای شبیه‌سازی و پیش‌بینی پدیده‌های پیچیده هیدرولوژیک از جمله جریان رودخانه هستند و مزایای قابل توجهی در دقت و کارایی ارائه می‌دهند. با این حال، با وجود این پیشرفت‌ها، بررسی‌های جامع‌تر و مقایسه‌ای دقیق‌تر میان مدل‌های هیبریدی نوین مانند ELM بهبودیافته با الگوریتم‌های بهینه‌سازی نهنگ (WOA) و ملخ (GOA) در مناطق خاص با ویژگی‌های هیدرولوژیک منحصربه‌فرد (مانند رودخانه رازاور)، همچنان نیاز به پژوهش بیشتری دارد. به طور خاص، کمتر مطالعه‌ای به تحلیل مقایسه‌ای عملکرد این مدل‌ها تحت ترکیبات ورودی متنوع و همچنین ارزیابی تأثیر متغیرهای مختلف (از طریق آنالیز حساسیت) در یک سیستم رودخانه‌ای مشخص پرداخته است. این خلأ پژوهشی، اهمیت و ضرورت مطالعه حاضر را دوچندان می‌سازد تا قابلیت‌های این مدل‌های پیشرفته در پیش‌بینی دقیق جریان رودخانه روشن‌تر گردد و راهنمایی‌های عملی برای مدیریت منابع آب ارائه شود.

مواد و روش‌ها


منطقه مورد مطالعه

رودخانه رازاور یکی از منابع آبی مهم در غرب ایران و استان کرمانشاه است که نقش مهمی در تأمین نیازهای آبی منطقه ایفا می‌کند. این رودخانه در حوزه آبریز کرمانشاه واقع شده و جریان آن از ارتفاعات اطراف کندوله و کامیاران سرچشمه می‌گیرد و در مسیر خود از مناطق مختلفی عبور می‌کند. موقعیت جغرافیایی این رودخانه باعث شده است که از جنبه‌های مختلف، از جمله هیدرولوژیک، اقلیمی و اقتصادی مورد توجه قرار گیرد. ارتفاعات اطراف رودخانه، با بارش سالانه قابل توجه، منبع اصلی تغذیه جریان آن هستند و تأثیر مهمی بر رفتار هیدرولوژیک منطقه دارند (شکل ۱).

منطقه مورد مطالعه در اقلیمی نیمه‌خشک تا مدیترانه‌ای قرار دارد که مشخصه آن بارش‌های فصلی و تغییرات دمایی قابل توجه است. بارش‌های عمدتاً زمستانه و بهاره، همراه با تابستان‌های گرم و خشک، الگوی جریان رودخانه رازاور را

به شدت تحت تأثیر قرار می‌دهد. این منطقه با متوسط بارش سالانه حدود ۴۰۰ تا ۶۰۰ میلی‌متر و دمای میانگین سالانه حدود ۱۵ درجه سانتی‌گراد، شرایطی ایده‌آل برای تحلیل رفتار هیدرولوژیک رودخانه فراهم می‌کند. تنوع اقلیمی این منطقه، آن را به محیطی مناسب برای مطالعات مرتبط با تغییرات اقلیمی و اثرهای آن بر جریان آب تبدیل کرده است (۲۳). حوزه آبریز رودخانه رازاور از تنوع کاربری زمین برخوردار است که شامل اراضی کشاورزی، مراتع و مناطق مسکونی می‌شود. کشاورزی به عنوان یکی از فعالیت‌های اصلی اقتصادی در این منطقه، به شدت وابسته به منابع آب رودخانه است. این رودخانه علاوه بر تأمین آب برای آبیاری اراضی کشاورزی، منبعی برای تأمین آب شرب و مصارف صنعتی نیز محسوب می‌شود. بهره‌برداری پایدار از این منابع آبی برای تضمین امنیت غذایی و توسعه اقتصادی منطقه از اهمیت ویژه‌ای برخوردار است (۲۸). آب این حوزه در نهایت به سیستم بزرگ‌تر حوزه آبریز خلیج فارس و دریای عمان می‌پیوندد. آب‌های سطحی و زیرزمینی منطقه رازاور از راه رودخانه‌ها و مسیرهای طبیعی جریان، به رودخانه‌هایی مانند رودخانه قره‌سو یا سایر شاخه‌های مرتبط با حوزه کرمانشاه می‌ریزند و در نهایت به آب‌های حوزه خلیج فارس تخلیه می‌شوند. در حوزه آبریز رازاور، سدهایی مانند آزادی (زمنکان) و جامیشان احداث شده‌اند که هدف اصلی از ساخت آنها تأمین آب شرب و کشاورزی، کنترل سیلاب و تغذیه سفره‌های زیرزمینی است. سد آزادیدر شهرستان دالاهو، از نوع خاکی با هسته رسی است و آب مورد نیاز کشاورزی و مدیریت سیلاب را فراهم می‌کند. سد جامیشانی نیز در نزدیکی این حوزه و در شهرستان سنقر احداث شده و علاوه بر تأمین آب شرب، در کاهش خسارات ناشی از سیلاب مؤثر است. این سدها نقش مهمی در مدیریت منابع آبی و حفظ محیط زیست منطقه دارند (جدول ۱).

رودخانه رازاور با چالش‌های متعددی روبه‌روست که شامل تغییرات اقلیمی، نوسانات بارش و فعالیت‌های انسانی مانند بهره‌برداری بیش از حد از منابع آب زیرزمینی و تغییر کاربری



شکل ۱. موقعیت منطقه مورد مطالعه

رودخانه رازاور و مراکز هواشناسی منطقه تهیه شده‌اند. برای کنترل کیفی داده‌ها ابتدا بررسی همسانی و اعتبار داده‌ها با استفاده از روش آماری انجام شد و داده‌های پرت (آبمادهای غیرمنطقی یا مقادیر غیرعادی) بر اساس روش آماری IQR (Interquartile Range) و تحلیل انحراف معیار از میانگین شناسایی شدند. داده‌های گمشده نیز که کمتر از ۴ درصد کل داده‌ها بود، با استفاده از روش درون‌یابی خطی بازسازی شدند تا از عدم انحراف در تحلیل مدل جلوگیری شود. برای جایگزینی داده‌های پرت، از روش میانگین وزنی متحرک استفاده شد که با در نظر گرفتن داده‌های قبل و بعد از مقدار پرت، جایگزینی انجام می‌شود. انتخاب این روش به دلیل حفظ روند طبیعی جریان رودخانه و جلوگیری از ایجاد خطا در مدل‌سازی صورت گرفت. این فرایندهای کنترل کیفی و بازسازی داده‌ها باعث اطمینان از صحت و دقت داده‌های اولیه و بهبود قابلیت اعتماد نتایج پژوهش می‌شود.

اراضی است. این عوامل می‌توانند منجر به کاهش دبی رودخانه، افزایش خطر خشکسالی و در مواردی، تشدید خطر سیلاب‌ها شوند (۲۷). تغییرات سریع در رفتار هیدرولوژیک رودخانه به دلیل این تهدیدات، اهمیت مطالعات پیش‌بینی جریان را برای مدیریت پایدار منابع آبی منطقه دوچندان کرده است. ویژگی‌های منحصر به فرد رودخانه رازاور و نقش حیاتی آن در تأمین منابع آبی منطقه، نیاز به انجام مطالعات دقیق هیدرولوژیک و شبیه‌سازی جریان را ضروری می‌سازد (۱۶). داده‌های به‌دست‌آمده از این مطالعات می‌توانند در مدیریت بهینه منابع آب، کاهش خسارات ناشی از سیلاب‌ها و خشکسالی‌ها و برنامه‌ریزی بلندمدت برای توسعه پایدار منطقه استفاده شوند. علاوه بر این، بررسی رفتار هیدرولوژیک رودخانه رازاور می‌تواند به بهبود درک ما از تأثیرات تغییرات اقلیمی و ارائه راهکارهای مناسب برای مقابله با این تغییرات کمک کند (۱۶).

داده‌های مورد استفاده

در این مطالعه از داده‌های هیدرولوژیک و اقلیمی شامل دبی جریان رودخانه، بارندگی، تبخیر و دما استفاده شده است. این داده‌ها برای یک دوره آماری ۱۰ ساله (۱۳۹۰ تا ۱۴۰۰) با مقیاس زمانی ماهانه از ایستگاه‌های سنجش هیدرولوژیک نزدیک

ماشین یادگیری افراطی (ELM یا Extreme Learning Machine)

ELM یکی از مدل‌های شبکه عصبی مصنوعی است که برای مسائل پیش‌بینی، طبقه‌بندی و رگرسیون استفاده می‌شود. این

جدول ۱. مشخصات آماری جریان رودخانه رازاور طی دوره ده‌ساله

نام رودخانه	نام ایستگاه	طول دوره آماری	میانگین دبی روزانه	انحراف معیار دبی	حداکثر مقدار میانگین روزانه	حداقل مقدار میانگین روزانه
رازاور	پل رازاور	۱۰	۱/۸	۱/۵	۱۰۰/۸۳	۰/۳۸


مدل در سال ۲۰۰۴ معرفی شد و به دلیل سرعت زیاد آموزش و ساختار ساده خود، مورد توجه پژوهشگران قرار گرفته است. ساختار ELM شامل یک لایه ورودی، یک لایه مخفی و یک لایه خروجی است که برخلاف مدل‌های معمول شبکه عصبی، وزن‌های بین لایه ورودی و لایه مخفی در ابتدای کار به صورت تصادفی مقداردهی شده و ثابت باقی می‌مانند (۲۶). تنظیم وزن‌ها تنها در لایه خروجی انجام می‌شود که این ویژگی باعث کاهش زمان محاسبات و افزایش کارایی مدل می‌شود (شکل ۲). مدل ELM به دلیل سادگی ساختار و عدم نیاز به الگوریتم‌های تکراری برای تنظیم وزن‌ها، سرعت بسیار زیادی در فرایند آموزش دارد. این مدل از روش‌های خطی برای تنظیم وزن‌های لایه خروجی استفاده می‌کند که باعث کاهش پیچیدگی محاسباتی و افزایش دقت در مقایسه با بسیاری از مدل‌های دیگر می‌شود (۲۶). یکی از مزایای کلیدی ELM این است که از بهینه‌سازی فراابتکاری یا الگوریتم‌های جستجوی پیچیده بی‌نیاز است و همین امر باعث می‌شود تا برای مسائل بزرگ و داده‌های حجیم نیز کارآمد باشد. با وجود مزایای فراوان، مدل ELM محدودیت‌هایی نیز دارد. یکی از چالش‌های اصلی این مدل، حساسیت به مقداردهی اولیه وزن‌های بین لایه ورودی و لایه مخفی است (۶). انتخاب تصادفی این وزن‌ها می‌تواند منجر به نتایج غیردقیق یا ناپایدار شود. همچنین، تعیین تعداد نرون‌های لایه مخفی تأثیر قابل توجهی بر عملکرد مدل دارد و نیازمند تنظیم دقیق است. علاوه بر این، اگر داده‌ها به خوبی پیش‌پردازش و نرمال‌سازی نشده باشند، عملکرد ELM ممکن است تحت تأثیر قرار گیرد. مدل ELM در حوزه‌های مختلفی از جمله پیش‌بینی سری‌های زمانی، پردازش سیگنال، شناسایی الگو و طبقه‌بندی داده‌ها استفاده می‌شود. این مدل

به‌ویژه در مسائل هیدرولوژیک مانند پیش‌بینی جریان رودخانه، تحلیل بارش و تبخیر، و مدل‌سازی کیفیت آب کاربرد دارد (۱۱). سرعت زیاد آموزش این مدل آن را به گزینه‌ای مناسب برای کاربردهایی تبدیل کرده است که نیازمند تحلیل‌های سریع و دقیق هستند. علاوه بر این، ELM در زمینه‌های پزشکی، مالی و صنعت نیز استفاده می‌شود. برای غلبه بر محدودیت‌های ELM و بهبود دقت و پایداری آن، الگوریتم‌های بهینه‌سازی فراابتکاری مانند الگوریتم نهنگ (WOA) و ملخ (GOA) به کار گرفته می‌شوند (۱۲). این الگوریتم‌ها می‌توانند وزن‌های اولیه بین لایه ورودی و لایه مخفی را به‌طور هوشمند تنظیم کنند و از تأثیرات منفی مقداردهی تصادفی جلوگیری کنند. ترکیب ELM با این روش‌های بهینه‌سازی منجر به افزایش دقت، کاهش خطا و بهبود عملکرد مدل در مسائل پیچیده می‌شود. به همین دلیل، مدل‌های ترکیبی مبتنی بر ELM به‌طور گسترده‌ای در پژوهش‌های اخیر به کار گرفته شده‌اند (۱۰). برای یک مجموع داده شامل N نمونه متمایز (x_i, t_i) ، با استفاده از L گره پنهان و یک تابع فعال‌ساز (Φ) می‌توان یک مدل ELM را برای آن توسعه داد (معادله ۱) (۱۱).

$$t_j = \sum_{i=1}^N \beta_i \cdot \Phi(u_i \cdot x_j + b_i) \quad j=1,2,3 \dots N \quad (1)$$

که در آن $(u_i = [u_{i1}, u_{i2}, u_{i3}, \dots, u_{im}]^T)$ بردار ضرایب وزنی بین گره ورودی و گره پنهان i ام است و $(\beta_i = [\beta_{i1}, \beta_{i2}, \beta_{i3}, \dots, \beta_{im}]^T)$ بردار ضرایب وزنی بین گره پنهان i ام و گره‌های خروجی است. b_i ضریب بایاس گره پنهان i ام است. $\Phi(u_i \cdot x_j + b_i)$ خروجی گره پنهان i ام با توجه به ورودی‌های x_j است. معادله ۱ را می‌توان به صورت معادله ۲ بازنویسی کرد.

$$H\beta = T \quad (2)$$



شکل ۲. ساختار مدل ELM

معرفی شد (۱۷). ملخ‌ها در طبیعت رفتارهای منحصر به فردی برای جستجوی منابع غذایی دارند و به دلیل حرکت هماهنگ در دسته‌های بزرگ، الگوریتم GOA از این رفتار برای حل مسائل پیچیده بهینه‌سازی استفاده می‌کند. این الگوریتم در دسته روش‌های متاهوریستیک قرار می‌گیرد و توانایی آن در پیدا کردن جواب‌های نزدیک به بهینه در مسائل غیرخطی و چندبعدی چشمگیر است (۱۹). الگوریتم ملخ مبتنی بر دو رفتار اصلی است: نزدیک شدن به بهترین جواب و پرهیز از به دام افتادن در نقاط بهینه محلی. ملخ‌ها در طبیعت برای جستجوی منابع غذایی، فاصله‌های کوتاه یا طولانی را طی می‌کنند و این حرکت به دو فاز تقسیم می‌شود: فاز کاوش و فاز بهره‌برداری. در فاز کاوش، ملخ‌ها به نقاط مختلف حرکت می‌کنند تا فضای جستجو را بررسی کنند؛ در حالی که در فاز بهره‌برداری تمرکز بیشتری روی نقاط امیدبخش دارند (۱). این ویژگی‌ها در الگوریتم GOA به گونه‌ای شبیه‌سازی می‌شود که تنوع پاسخ‌ها و جلوگیری از همگرایی زودرس تضمین شود. الگوریتم ملخ در مسائل متعددی از جمله بهینه‌سازی توابع پیچیده، مسائل زمان‌بندی، طراحی مهندسی و یادگیری ماشین به کار گرفته شده است. مزیت اصلی این الگوریتم در مقایسه با سایر روش‌های بهینه‌سازی، توانایی آن در مدیریت مسائل چندبعدی و غیرخطی با دقت زیاد است. علاوه بر این، GOA نسبت به بسیاری از الگوریتم‌های مشابه از همگرایی سریع‌تر و توانایی بیشتری در فرار از نقاط بهینه محلی برخوردار است. این ویژگی‌ها آن را به یک ابزار کارآمد در حوزه‌های مختلف تحقیقاتی و صنعتی تبدیل کرده است (۹). الگوریتم GOA از یک مدل ریاضی برای

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}_{N \times m} \quad Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_N^T \end{bmatrix}_{N \times m}$$

$$H(w_1 \dots w_N, b_1 \dots b_N, x_1 \dots x_N) = \begin{bmatrix} \Phi(u_1 \cdot x_1 + b_1) & \dots & \Phi(u_N \cdot x_1 + b_N) \\ \vdots & \dots & \vdots \\ \Phi(u_1 \cdot x_N + b_1) & \dots & \Phi(u_N \cdot x_N + b_N) \end{bmatrix}_{N \times N}$$

پارامترهای w_i, b_i, β_i ($i = 1, 2, 3 \dots N$) را می‌توان با استفاده از معادله ۳ محاسبه کرد (۱۰).

$$\|H(a_1, \dots, a_N, b_1, \dots, b_N)\beta - T\| = \min_{w_i, b_i, \beta} \|H(a_1, \dots, a_L, b_1, \dots, b_L)\beta - T\| \quad (3)$$

که در آن H ماتریس خروجی لایه پنهان مدل ELM است، β ماتریس وزن‌های خروجی است ($[\beta_{i1}, \beta_{i2}, \beta_{i3}, \dots, \beta_{in}]^T$) و T و ماتریس نمونه‌های شبیه‌سازی شده است ($[t_{i1}, t_{i2}, t_{i3}, \dots, t_{in}]^T$). معادله ۳ معادل است با حداقل کردن تابع هزینه زیر (معادله ۴):

$$E = \sum_{j=1}^N \left(\sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) - t_j \right)^2 \quad (4)$$

مقدار β را می‌توان عملیات ساده معکوس تعمیم‌یافته از ماتریس خروجی لایه پنهان محاسبه کرد (معادله ۵).

$$\beta^* = H^\dagger T \quad (5)$$

که در آن $H^\dagger$ تعمیم معکوس مون - پنروز از ماتریس خروجی لایه پنهان است.

الگوریتم بهینه‌سازی ملخ (GOA)

الگوریتم ملخ یکی از الگوریتم‌های بهینه‌سازی مبتنی بر رفتار جمعی است که از رفتار طبیعی ملخ‌ها الهام گرفته شده است. این الگوریتم در سال ۲۰۱۷ توسط میرجلیلی و همکاران (۲۰۲۱)

شبیه‌سازی موقعیت ملخ‌ها و تعامل بین آنها استفاده می‌کند. موقعیت هر ملخ در فضای جستجو با استفاده از معادله‌ای تعیین می‌شود که شامل سه مؤلفه اصلی است: نیروی جذبی بین ملخ‌ها، نیروی دافعی برای جلوگیری از برخورد و جاذبه نهایی به سمت هدف بهینه. این مؤلفه‌ها به صورت خطی یا غیرخطی تنظیم می‌شوند تا بالانس مناسبی بین کاوش و بهره‌برداری فراهم شود. همچنین، پارامترهایی مانند نرخ کاهش فاصله و فاکتورهای کنترلی برای تنظیم سرعت و جهت حرکت ملخ‌ها در نظر گرفته شده است. در این الگوریتم موقعیت هر ملخ در هر گام زمانی با استفاده از معادله ۶ تعیین می‌شود (۱۷).

$$X_i^d = c \left(\sum_{j=1}^N C \frac{ub_d - lb_d}{2} S(|X_j^d - X_i^d|) \frac{X_j - X_i}{d_{ij}} \right) + \hat{T}_d \quad (6)$$

S فاکتوری برای تعریف فشار اجتماعی است، ub_d و lb_d به ترتیب حد پایین و بالا در معادله مربوط به مدل‌سازی فشار اجتماعی است و $\hat{T}_d$ بهترین پاسخی که یافت شده است. d_{ij} فاصله بین ملخ i ام و j ام است. X_i و X_j موقعیت ملخ i ام و j ام است. C پارامتری خطی یا غیرخطی برای کنترل انتقال الگوریتم به مرحله کاوش یا اکتشاف است.

الگوریتم بهینه‌سازی نهنگ (WOA یا whale optimization algorithm)

الگوریتم بهینه‌سازی نهنگ یا WOA یکی از الگوریتم‌های متاهوریستیک است که در سال ۲۰۱۶ توسط میرجلیلی و لويس (۲۰۱۶) معرفی شد (۱۸). این الگوریتم از رفتار شکار نهنگ‌های گوژپشت الهام گرفته شده است (۸). این نهنگ‌ها از روش خاصی به نام شکار حباب‌زنی برای شکار طعمه استفاده می‌کنند. WOA با شبیه‌سازی این رفتار طبیعی، به یکی از ابزارهای پرکاربرد در حل مسائل پیچیده بهینه‌سازی تبدیل شده است. رفتار شکار حباب‌زنی نهنگ‌ها شامل دو مرحله اصلی است: حرکت دایره‌ای به دور طعمه و حرکت مارپیچی برای نزدیک شدن به طعمه. در الگوریتم WOA، این دو رفتار توسط معادلات ریاضی شبیه‌سازی می‌شوند. در مرحله جستجو،

الگوریتم به‌طور تصادفی فضای مسئله را کاوش می‌کند تا بهترین جواب ممکن را پیدا کند (۲۱). در مرحله بهره‌برداری، نهنگ‌ها به سمت موقعیت بهینه حرکت کرده و به‌صورت تدریجی فاصله خود را با آن کاهش می‌دهند. این ویژگی به WOA اجازه می‌دهد که به‌خوبی بین کاوش و بهره‌برداری تعادل برقرار کند (۲۰). مراحل توسعه این الگوریتم را می‌توان به سه بخش تقسیم کرد (۱۸):

۱- محاصره طعمه

در این فاز، نهنگ‌ها به موقعیت بهترین شکار شناسایی شده نزدیک می‌شوند. در فضای جستجو، موقعیت هر نهنگ با استفاده از معادلات ۷ و ۸ به‌روزرسانی می‌شود:

$$|\vec{X}(t) - \vec{X}_{best} \cdot \vec{C}| = \vec{D} \quad (7)$$

$$\vec{D} \cdot \vec{A} - \vec{X}_{best} = \vec{X}(t+1) \quad (8)$$

که در آن $\vec{X}(t)$ موقعیت فعلی نهنگ در تکرار t ام، $\vec{X}_{best}$ موقعیت بهترین شکار تاکنون، $\vec{D}$ فاصله بین نهنگ و شکار و $\vec{A}$ و $\vec{C}$ بردارهای کنترلی هستند که رفتار نهنگ را در فضای جستجو تنظیم می‌کنند.

۲- فاز بهره‌برداری

در این فاز، رفتار نهنگ‌ها هنگام شکار طعمه با استفاده از روش مارپیچی و احاطه کردن طعمه مدل‌سازی می‌شود. در روش اول فرض می‌شود نهنگ‌ها به شکل مارپیچ به سمت طعمه نزدیک می‌شوند (معادله ۹). در روش دوم، موقعیت هر نهنگ بر اساس به بهترین طعمه شناخته شده تاکنون تنظیم می‌شود.

$$\vec{X}_{best} + \cos(2\pi L) \cdot b_l \cdot \vec{D} = \vec{X}(t+1) \quad (9)$$

$\vec{D} = |\vec{X}(t) - \vec{X}_{best}|$ فاصله نهنگ از بهترین طعمه، b ضریب کنترل که شکل مارپیچ را تعیین می‌کند و L مقدار تصادفی بین -1 و $+1$ است.

۳- فاز اکتشاف

این مرحله برای کشف نواحی جدید در فضای جستجو طراحی شده است و رفتار کاوشگرانه نهنگ‌ها را مدل‌سازی می‌کند. موقعیت نهنگ‌ها در این فاز را می‌توان با استفاده از معادله ۱۰ مدل‌سازی کرد.

زمانی جاری (Q_t) است. ترکیب ۱ تنها به مقادیر قبلی جریان وابسته است (Q_{t-1}). ترکیب‌های ۲ و ۳ و ۴، بارندگی (P_t, P_{t-1}) را به ترکیب متغیرهای قبلی اضافه کرده‌اند. این ترکیب‌ها بیشتر برای مدل‌سازی رفتار دینامیکی جریان آب بدون تأثیرپذیری مستقیم از متغیرهای آب‌وهوایی طراحی شده‌اند. به ترکیب ۵ دما اضافه شده است. ترکیب ۶ تمامی متغیرها را به صورت جامع ترکیب کرده و یکی از جامع‌ترین ترکیب‌های ممکن برای مدل‌سازی جریان رودخانه است (جدول ۳).

در این مطالعه، سه مدل یادگیری ماشین شامل ELM، WOA-ELM و GOA-ELM برای پیش‌بینی جریان رودخانه رازاور مورد ارزیابی قرار گرفتند. این مدل‌ها در ده ترکیب ورودی مختلف شامل متغیرهایی مانند دبی جریان گذشته، بارش، دما و تبخیر بررسی شدند. نتایج تحلیل شاخص‌های عملکرد ($RMSE$, NSE , R^2) نشان‌دهنده تفاوت معنادار در دقت و کارایی مدل‌ها بر اساس ترکیب ورودی و نوع الگوریتم بهینه‌سازی است.

ترکیب شماره یک تنها بر اساس مقادیر تأخیری جریان رودخانه (Q_{t-1} و Q_{t-2}) طراحی شده است. نتایج نشان می‌دهد که در این سناریو، مدل WOA-ELM با بهترین عملکرد دست یافته است (آموزش: $RSME=0/1520$, $NSE=0/9837$, $R^2=0/9916$; تست: $RSME=0/1457$, $NSE=0/9840$, $R^2=0/9917$). این اعداد حاکی از توانایی فوق‌العاده WOA-ELM در شناسایی و بازتولید الگوهای ذاتی سری زمانی جریان رودخانه تنها با تکیه بر مقادیر گذشته آن است. همان‌طور که در شکل ۳ نیز به وضوح دیده می‌شود، نمودار جریان شبیه‌سازی شده توسط WOA-ELM انطباق بسیار نزدیکی با جریان مشاهده‌ای دارد و قادر به ردیابی دقیق پیک‌ها و فرورفتگی‌های جریان ماهانه است. مدل GOA-ELM نیز عملکرد بسیار خوبی نشان داد، اما به دلیل تفاوت در مکانیزم جستجوی فضای بهینه، اندکی ضعیف‌تر از WOA-ELM عمل کرد (آموزش: $RSME=0/1708$, $NSE=0/9824$, $R^2=0/9906$; تست: $RSME=0/1661$, $NSE=0/9819$, $R^2=0/9903$). در مقابل، مدل ELM پایه به دلیل عدم

$$|\bar{X}(t) - \bar{X}_{rand} \cdot \bar{C}| \cdot \bar{A} - X_{rand} = \bar{X}(t+1) \quad (10)$$

$\bar{X}_{rand}$ موقعیت یک نهنگ تصادفی در جمعیت است.

معیارهای ارزیابی مدل‌ها

برای ارزیابی کارایی مدل‌ها در این مطالعه از معیارهای ریشه میانگین مربعات خطا ($RMSE$)، شاخص نش و ساتکلیف (NSE) و ضریب تعیین (R^2) استفاده شد (معادلات ۱۱ تا ۱۳).

$$RMSE = \left[N^{-1} \sum_{i=1}^N (y_i - O_i)^2 \right]^{1/2} \quad (11)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (O_i - y_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (12)$$

$$R^2 = \left[\sum_{i=1}^N (F_i - \bar{y})(O_i - \bar{O}) \right]^2 \left[\sum_{i=1}^N (y_i - \bar{y})^2 \sum_{i=1}^N (O_i - \bar{O})^2 \right]^{-1} \quad (13)$$

در این معادله N تعداد مشاهده‌ها، y_i مقدار پیش‌بینی شده، O_i مقدار مشاهده‌ای و $\bar{y}$ و $\bar{O}$ به ترتیب متوسط مقادیر O_i و y_i هستند.

نتایج و بحث

در این مطالعه، سه مدل یادگیری ماشین شامل ELM، WOA-ELM و GOA-ELM برای پیش‌بینی جریان ماهانه رودخانه رازاور ارزیابی شدند. این مدل‌ها در شش ترکیب ورودی مختلف، شامل متغیرهایی مانند دبی جریان گذشته (Q_{t-1} , Q_{t-2} , Q_{t-3})، بارش (P_t , P_{t-1} , P_{t-2} , P_{t-3})، دما (T) و تبخیر (E) بررسی شدند (جدول ۲). نتایج تحلیل شاخص‌های عملکرد که در جدول ۲ ارائه شده‌اند، نشان‌دهنده تفاوت معنادار در دقت و کارایی مدل‌ها بر اساس ترکیب ورودی و نوع الگوریتم بهینه‌سازی است. این بخش به تفصیل به تحلیل این نتایج، مقایسه عملکرد مدل‌ها و بحث پیرامون دلایل دیده‌شده می‌پردازد.

در این ترکیبات، متغیرهای جریان رودخانه در گام‌های زمانی قبلی (Q_{t-1} , Q_{t-2})، بارندگی (P_t , P_{t-1} , P_{t-2} , P_{t-3})، دما (T_{t-1} , P_{t-3}) و تبخیر (E_t) به عنوان ورودی‌ها در نظر گرفته شده‌اند. خروجی در تمام ترکیبات، جریان رودخانه در گام

جدول ۲. ترکیب‌های مختلف برای توسعه مدل ELM

شماره ترکیب	ترکیب	خروجی
۱	Q_{t-1}, Q_{t-2}	Q_t
۲	Q_{t-1}, Q_{t-2}, P_t	
۳	$Q_{t-1}, P_{t-1}, P_{t-3}$	
۴	Q_{t-1}, P_{t-2}	
۵	$Q_{t-1}, Q_{t-2}, T_{t-1}$	
۶	$Q_{t-1}, P_{t-2}, T_{t-3}, E_t$	

استفاده از الگوریتم بهینه‌سازی فراابتکاری، در این ترکیب نیز عملکرد ضعیف‌تری نسبت به دو مدل بهینه‌سازی شده ارائه داد که بر اهمیت استفاده از تکنیک‌های بهینه‌سازی در بهبود دقت پیش‌بینی تأکید می‌کند (آموزش: $R^2=0/9890$, $NSE=0/9745$, $RSME=0/1785$, تست: $R^2=0/9895$, $NSE=0/9764$, $RSME=0/1758$).

در ترکیب شماره دو علاوه بر مقادیر قبلی جریان (Q_{t-2} و Q_{t-1}) و بارندگی (P_t) نیز به‌عنوان یک متغیر کلیدی به ورودی‌ها اضافه شد. با اضافه‌شدن بارندگی، دقت کلی مدل‌ها بهبود یافت که نشان‌دهنده نقش حیاتی بارش در دینامیک جریان رودخانه رازاور است. در این ترکیب نیز، مدل WOA-ELM با مقادیر NSE بیشتر و $RMSE$ کمتر نسبت به سایر مدل‌ها بهترین عملکرد را به خود اختصاص داد (آموزش: $R^2=0/9618$, $NSE=0/9541$, $RSME=0/1474$, تست: $R^2=0/9619$, $NSE=0/9545$, $RSME=0/1413$). این برتری، تأکید بر قابلیت WOA در تلفیق مؤثر اطلاعات هیدرولوژیک گذشته با داده‌های اقلیمی فعلی است. شکل ۴، انطباق عالی بین جریان مشاهده‌ای و پیش‌بینی‌شده توسط WOA-ELM را در این ترکیب به تصویر می‌کشد؛ به‌ویژه در دوره‌هایی که تغییرات ناگهانی جریان به دلیل بارش‌های شدید رخ می‌دهد. مدل GOA-ELM در جایگاه دوم قرار دارد (آموزش: $R^2=0/9606$).

$NSE=0/9529$, $R^2=0/9609$ ، تست: $RMSE=0/1656$, $NSE=0/9524$, $RSME=0/1611$ ، و ELM در جایگاه سوم قرار دارد (آموزش: $R^2=0/9598$, $RMSE=0/1731$, $NSE=0/9452$, تست: $R^2=0/9592$, $RMSE=0/1705$, $NSE=0/9471$). این نتایج حاکی از آن است که بارندگی تأثیر مستقیم و قابل توجهی بر جریان رودخانه دارد و افزودن آن به مدل می‌تواند منجر به پیش‌بینی‌های دقیق‌تر شود.





برای ترکیب سه اضافه کردن بارندگی در زمان تأخیری سوم (P_{t-1}) باعث شد که مدل GOA-ELM به بهترین نتایج دست یابد. این ترکیب نشان داد که افزودن داده‌های تأخیری بیشتر می‌تواند منجر به پیش‌بینی‌های دقیق‌تری شود. برای این ترکیب مدل GOA-ELM بهترین عملکرد را دارد (آموزش: $R^2=0/8726$, $NSE=0/8656$, $RMSE=0/1337$ ، تست: $R^2=0/8727$, $NSE=0/8659$, $RMSE=0/1282$) و مدل WOA-ELM در جایگاه دوم قرار داشت (آموزش: $R^2=0/8714$, $NSE=0/8640$, $RMSE=0/1502$ ، تست: $R^2=0/8714$, $NSE=0/8645$, $RMSE=0/1461$)، اما مدل ELM همچنان نسبت به دو مدل دیگر ضعیف‌تر بود (آموزش: $R^2=0/8702$, $NSE=0/8575$, $RMSE=0/1570$ ، تست: $R^2=0/8708$, $NSE=0/8592$, $RMSE=0/1547$). نتایج حاصل از این ترکیب، بیانگر نقش طولانی مدت بارندگی در الگوی

جدول ۳. مقایسه مدل‌های مختلف مبتنی بر جریان ELM در برآورد جریان رودخانه برای دوره‌های آموزشی و تست





شماره ترکیب	مدل	Train			Test		
		RMSE	NSE	R ²	RMSE	NSE	R ²
۱	WOA-ELM	۰/۱۵۲۰	۰/۹۸۳۷	۰/۹۹۱۶	۰/۱۴۵۷	۰/۹۸۴۰	۰/۹۹۱۷
	GOA-ELM	۰/۱۷۰۸	۰/۹۸۱۹	۰/۹۹۰۳	۰/۱۶۶۱	۰/۹۸۲۴	۰/۹۹۰۶
	ELM	۰/۱۷۸۵	۰/۹۷۴۵	۰/۹۸۹۰	۰/۱۷۵۸	۰/۹۷۶۴	۰/۹۸۹۵
۲	WOA-ELM	۰/۱۴۷۴	۰/۹۵۴۱	۰/۹۶۱۸	۰/۱۴۱۳	۰/۹۵۴۵	۰/۹۶۱۹
	GOA-ELM	۰/۱۶۵۶	۰/۹۵۲۴	۰/۹۶۰۶	۰/۱۶۱۱	۰/۹۵۲۹	۰/۹۶۰۹
	ELM	۰/۱۷۳۱	۰/۹۴۵۲	۰/۹۵۹۲	۰/۱۷۰۵	۰/۹۴۷۱	۰/۹۵۹۸
۳	GOA-ELM	۰/۱۳۳۷	۰/۸۶۵۶	۰/۸۷۲۶	۰/۱۲۸۲	۰/۸۶۵۹	۰/۸۷۲۷
	WOA-ELM	۰/۱۵۰۲	۰/۸۶۴۰	۰/۸۷۱۴	۰/۱۴۶۱	۰/۸۶۴۵	۰/۸۷۱۷
	ELM	۰/۱۵۷۰	۰/۸۵۷۵	۰/۸۷۰۲	۰/۱۵۴۷	۰/۸۵۹۲	۰/۸۷۰۷
۴	GOA-ELM	۰/۱۳۹۸	۰/۹۰۴۹	۰/۹۱۲۲	۰/۱۳۴۰	۰/۹۰۵۳	۰/۹۱۲۳
	WOA-ELM	۰/۱۵۷۱	۰/۹۰۳۳	۰/۹۱۱۱	۰/۱۵۲۸	۰/۹۰۳۷	۰/۹۱۱۳
	ELM	۰/۱۶۴۱	۰/۸۹۶۵	۰/۹۰۸۴	۰/۱۶۱۷	۰/۸۹۸۳	۰/۹۱۰۳
۵	WOA-ELM	۰/۱۳۰۷	۰/۸۴۵۹	۰/۸۵۲۷	۰/۱۲۵۳	۰/۸۴۶۲	۰/۸۵۲۸
	ELM	۰/۱۵۳۴	۰/۸۳۸۰	۰/۸۵۰۵	۰/۱۵۱۱	۰/۸۳۹۷	۰/۸۵۱۰
	GOA-ELM	۰/۱۴۶۸	۰/۸۴۴۴	۰/۸۵۱۶	۰/۱۴۲۸	۰/۸۴۴۸	۰/۸۵۱۹
۶	WOA-ELM	۰/۱۲۱۵	۰/۷۸۶۹	۰/۷۹۳۲	۰/۱۱۱۶	۰/۷۸۷۲	۰/۷۹۳۳
	ELM	۰/۱۴۲۷	۰/۷۷۹۵	۰/۷۹۱۱	۰/۱۴۰۶	۰/۷۸۱۱	۰/۷۹۱۶
	GOA-ELM	۰/۱۳۶۲	۰/۷۸۵۵	۰/۷۹۲۲	۰/۱۳۲۸	۰/۷۸۵۹	۰/۷۹۲۵

جریان رودخانه رازاور است. در شکل ۵ جریان رودخانه مشاهده شده و مقدار شبیه‌سازی شده به وسیله مدل GOA-ELM در مرحله آموزش و تست نشان داده شده است. ترکیب چهار از دبی جریان در گام زمانی قبل (Q_{t-1}) و بارندگی


در دو گام قبل (P_{t-2}) استفاده می‌کند. این طراحی نشان می‌دهد که ممکن است بارندگی با یک تأخیر مشخص بر جریان رودخانه اثرگذار باشد. این تأخیر می‌تواند ناشی از زمان مورد نیاز برای نفوذ یا حرکت بارش به سمت رودخانه باشد. بر اساس



شکل ۳. مقایسه جریان ماهانه مشاهده‌ای و مقدار شبیه‌سازی شده به وسیله ترکیب اول و مدل WOA-ELM



شکل ۴. مقایسه جریان ماهانه مشاهده‌ای و مقدار شبیه‌سازی شده به وسیله ترکیب دوم و مدل WOA-ELM



شکل ۵. مقایسه جریان ماهانه مشاهده‌ای و مقدار شبیه‌سازی‌شده به‌وسیله ترکیب سوم و مدل GOA-ELM

نتایج حاصل مدل GOA-ELM برای این ترکیب بهترین عملکرد را دارد (آموزش: $R^2=0.9122$, $NSE=0.9049$, $RMSE=0.1398$, تست: $R^2=0.9123$, $NSE=0.9053$, $RMSE=0.1340$). اما نسبت به مدل ELM عملکرد ضعیف‌تری دارد؛ اما نسبت به مدل ELM عملکرد دقیق‌تر دارد (آموزش: $R^2=0.9111$, $NSE=0.9033$, $RMSE=0.1571$, تست: $R^2=0.9113$, $NSE=0.9037$, $RMSE=0.1528$). مانند سایر ترکیب‌های دیگر مدل ELM بدترین عملکرد را دارد (آموزش: $R^2=0.9098$, $NSE=0.8965$, $RMSE=0.1617$, تست: $R^2=0.9103$, $NSE=0.8983$, $RMSE=0.1617$). در شکل ۶ جریان رودخانه مشاهده‌شده و مقدار شبیه‌سازی‌شده به وسیله مدل GOA-ELM در مرحله آموزش و تست نشان داده شده است.


در ترکیب شش شامل تمامی متغیرهای اقلیمی و هیدرولوژیکی بود. برای این ترکیب مدل WOA-ELM بهترین عملکرد را ارائه کرد که نشان‌دهنده اهمیت استفاده از تمامی متغیرهای موجود برای

نتایج حاصل مدل GOA-ELM برای این ترکیب بهترین عملکرد را دارد (آموزش: $R^2=0.9122$, $NSE=0.9049$, $RMSE=0.1398$, تست: $R^2=0.9123$, $NSE=0.9053$, $RMSE=0.1340$). اما نسبت به مدل ELM عملکرد ضعیف‌تری دارد؛ اما نسبت به مدل ELM عملکرد دقیق‌تر دارد (آموزش: $R^2=0.9111$, $NSE=0.9033$, $RMSE=0.1571$, تست: $R^2=0.9113$, $NSE=0.9037$, $RMSE=0.1528$). مانند سایر ترکیب‌های دیگر مدل ELM بدترین عملکرد را دارد (آموزش: $R^2=0.9098$, $NSE=0.8965$, $RMSE=0.1617$, تست: $R^2=0.9103$, $NSE=0.8983$, $RMSE=0.1617$). در شکل ۶ جریان رودخانه مشاهده‌شده و مقدار شبیه‌سازی‌شده به وسیله مدل GOA-ELM در مرحله آموزش و تست نشان داده شده است.

در ترکیب شش شامل تمامی متغیرهای اقلیمی و هیدرولوژیکی بود. برای این ترکیب مدل WOA-ELM بهترین عملکرد را ارائه کرد که نشان‌دهنده اهمیت استفاده از تمامی متغیرهای موجود برای

نتایج حاصل مدل GOA-ELM برای این ترکیب بهترین عملکرد را دارد (آموزش: $R^2=0.9122$, $NSE=0.9049$, $RMSE=0.1398$, تست: $R^2=0.9123$, $NSE=0.9053$, $RMSE=0.1340$). اما نسبت به مدل ELM عملکرد ضعیف‌تری دارد؛ اما نسبت به مدل ELM عملکرد دقیق‌تر دارد (آموزش: $R^2=0.9111$, $NSE=0.9033$, $RMSE=0.1571$, تست: $R^2=0.9113$, $NSE=0.9037$, $RMSE=0.1528$). مانند سایر ترکیب‌های دیگر مدل ELM بدترین عملکرد را دارد (آموزش: $R^2=0.9098$, $NSE=0.8965$, $RMSE=0.1617$, تست: $R^2=0.9103$, $NSE=0.8983$, $RMSE=0.1617$). در شکل ۶ جریان رودخانه مشاهده‌شده و مقدار شبیه‌سازی‌شده به وسیله مدل GOA-ELM در مرحله آموزش و تست نشان داده شده است.

در ترکیب پنج، دمای هوا (T_{i-1}) به‌عنوان یک متغیر اقلیمی به داده‌های ورودی اضافه شد. در این ترکیب مدل WOA-ELM بار دیگر با عملکرد برتری داشت (آموزش: $R^2=0.8527$,







شکل ۶. مقایسه جریان ماهانه مشاهده‌ای و مقدار شبیه‌سازی‌شده به‌وسیله ترکیب چهارم و مدل GOA-ELM





لزوم بهره‌گیری از الگوریتم‌های فراابتکاری برای بهینه‌سازی ساختار و پارامترهای مدل‌های یادگیری ماشین در مواجهه با سیستم‌های پیچیده هیدرولوژیک را تأیید می‌کند. مدل ELM به‌تنهایی، هرچند از سرعت زیاد آموزش برخوردار است؛ اما به دلیل طبیعت تصادفی انتخاب وزن‌های لایه پنهان، اغلب در بهینه‌های محلی گرفتار شده و قادر به کشف دقیق‌ترین روابط پنهان در داده‌ها نیست. در مقابل، مکانیزم‌های جستجوی هوشمندانه WOA و GOA، با ارتقا قابلیت اکتشاف (exploration) و بهره‌برداری (exploitation) در فضای راه‌حل، منجر به همگرایی به راه‌حل‌های بهینه سراسری و در نتیجه، افزایش چشمگیر دقت پیش‌بینی شده‌اند.

برتری WOA-ELM در بیشتر ترکیبات، به‌ویژه در سناریوهایی که ویژگی‌های ورودی دارای همبستگی قوی‌تر و ساختار سری زمانی مشخص‌تری هستند (مانند ترکیبات ۱ و ۲ که عمدتاً بر داده‌های گذشته جریان تکیه دارند، یا ترکیب ۵ که دما را اضافه می‌کند)، قابل تأمل است. این عملکرد برتر را می‌توان به نحوه

پیش‌بینی دقیق‌تر است (آموزش: $R^2=0.7932$ ، $NSE=0.7869$ ، $RMSE=0.1215$ ، تست: $R^2=0.7933$ ، $NSE=0.7872$ ، $RMSE=0.1165$). مدل GOA-ELM نیز عملکرد مناسبی ارائه کرد (آموزش: $R^2=0.7922$ ، $NSE=0.7855$ ، $RMSE=0.1366$ ، تست: $R^2=0.7925$ ، $NSE=0.7859$ ، $RMSE=0.1328$). مانند سایر ترکیب‌ها برای این ترکیب نیز مدل ELM ضعیف‌ترین عملکرد را دارد (آموزش: $R^2=0.7911$ ، $NSE=0.7795$ ، $RMSE=0.1427$ ، تست: $R^2=0.7916$ ، $NSE=0.7811$ ، $RMSE=0.1406$). این ترکیب بیانگر نقش جامع تمامی متغیرها در مدل‌سازی جریان رودخانه رازاور است. در شکل ۸ جریان ماهانه مشاهده‌شده و مقدار شبیه‌سازی‌شده به‌وسیله مدل WOA-ELM در مرحله آموزش و تست نشان داده شده است. نتایج حاصل از ارزیابی شش ترکیب ورودی متفاوت برای پیش‌بینی جریان رودخانه رازاور، به‌وضوح برتری قابل‌توجه مدل‌های ترکیبی WOA-ELM و GOA-ELM را نسبت به مدل پایه ELM نشان می‌دهد. این امر، صحت فرض اولیه مبنی بر



شکل ۷. مقایسه جریان ماهانه مشاهده‌ای و مقدار شبیه‌سازی‌شده به‌وسیله ترکیب پنجم و مدل WOA-ELM



شکل ۸. مقایسه جریان ماهانه مشاهده‌ای و مقدار شبیه‌سازی‌شده به‌وسیله ترکیب ششم و مدل WOA-ELM

تقلید الگوریتم WOA از رفتار شکار حباب‌زنی نهنگ‌های گوژپشت نسبت داد. این مکانیزم شامل یک فاز محاصره طعمه و یک فاز حمله مارپیچی است که امکان جستجوی دقیق در نواحی امیدبخش و همگرایی سریع به سمت بهینه را فراهم می‌آورد. این ویژگی WOA را برای جذب الگوهای نهفته و نسبتاً خطی‌تر در داده‌های هیدرولوژیک که اغلب دارای حافظه قوی هستند، بسیار کارآمد می‌سازد. به عبارت دیگر، WOA-ELM قادر است از همبستگی‌های قوی بین جریان‌های گذشته و آینده به بهترین نحو بهره‌برداری کند.

در مقابل، عملکرد برجسته GOA-ELM در برخی ترکیبات خاص، به‌ویژه آن‌هایی که شامل متغیرهای اقلیمی با تأخیرهای زمانی متفاوت یا پیچیدگی‌های غیرخطی بیشتری بودند (مانند ترکیبات ۳ و ۴ که تأثیر بارش با تأخیرهای طولانی‌تر را بررسی می‌کردند)، نشان‌دهنده توانایی‌های مکمل این الگوریتم است. الگوریتم GOA با الهام از رفتار گروهی ملخ‌ها، شامل دو نیروی جذابیت و دافعه است که در طول فرآیند بهینه‌سازی به صورت دینامیکی تغییر می‌کنند. این دینامیک به GOA امکان می‌دهد تا فضای جستجو را به شکل گسترده‌تری کاوش کند و از رکود در بهینه‌های محلی جلوگیری نماید. این قابلیت، برای مسائلی که روابط بین متغیرها کمتر خطی و بیشتر نوسانی هستند، مانند تأثیرات تأخیری بارش که می‌تواند تحت تأثیر عواملی چون نفوذ، رواناب زیرسطحی و زمان تمرکز باشد، بسیار سودمند است. اگرچه GOA ممکن است در همه موارد به پایداری و دقت WOA نرسد، اما توانایی آن در مدیریت پیچیدگی‌های خاص، آن را به گزینه‌ای ارزشمند در مدل‌سازی هیدرولوژیک تبدیل می‌کند.

یکی از مهم‌ترین پیامدهای این مطالعه، تأکید مجدد بر اهمیت انتخاب آگاهانه و بهینه متغیرهای ورودی است. تحلیل‌های انجام‌شده نشان می‌دهد که جریان رودخانه در گذشته همواره به عنوان مهم‌ترین پیش‌بینی‌کننده عمل می‌کند که این موضوع با خاصیت حافظه هیدرولوژیک سیستم رودخانه مطابقت دارد. با این حال، افزودن متغیرهای اقلیمی مانند

بارش و دما، به‌خصوص با در نظر گرفتن تأخیرهای زمانی مرتبط، به طور قابل توجهی قابلیت مدل‌ها را در ثبت دینامیک کامل سیستم افزایش می‌دهد. مشاهده شد که اضافه کردن تمامی متغیرهای اقلیمی و هیدرولوژیک در ترکیب ۶، اگرچه ممکن است منجر به کاهش جزئی در NSE شود (که می‌تواند نشانه‌ای از افزایش پیچیدگی مدل‌سازی باشد)، اما اغلب به کاهش RMSE و بهبود توانایی مدل در پیش‌بینی مقادیر شدید (پیک‌ها و فرورفتگی‌ها) منجر می‌شود. این بیانگر آن است که برای یک مدل پیش‌بینی جامع، حجم وسیعی از اطلاعات ورودی می‌تواند ارزشمند باشد؛ به شرطی که مدل توانایی لازم برای استخراج الگوها از این داده‌های پرحجم و گاه متناقض را داشته باشد که مدل‌های هیبریدی در این زمینه موفق‌تر عمل کرده‌اند.

در مجموع، این پژوهش یک چارچوب قدرتمند برای پیش‌بینی جریان رودخانه ارائه می‌دهد که تلفیق موفقیت‌آمیز مدل ELM با الگوریتم‌های فراابتکاری WOA و GOA را به اثبات می‌رساند. نتایج، علاوه بر ارائه ابزاری دقیق برای مدیریت منابع آب در رودخانه رازاور، به دانش عمومی در زمینه کاربرد هوش مصنوعی و بهینه‌سازی در هیدرولوژی نیز کمک می‌کند. یافته‌ها حاکی از آن است که برای بهبود دقت پیش‌بینی در سیستم‌های پیچیده طبیعی، نه تنها انتخاب مدل پایه مناسب، بلکه بهره‌گیری از تکنیک‌های بهینه‌سازی هوشمند و درک عمیق از ماهیت متغیرهای ورودی و روابط آنها حیاتی است. این رویکرد می‌تواند الهام‌بخش پژوهش‌های آتی در زمینه مدل‌سازی هیدرولوژیک، به‌ویژه در حوضه‌های آبریز با چالش‌های مشابه کمبود داده یا پویایی‌های غیرخطی باشد.

تحلیل حساسیت

آنالیز حساسیت در مدل‌های پیش‌بینی جریان رودخانه، به‌ویژه مدل‌هایی که از ورودی‌های چندمتغیره و الگوریتم‌های بهینه‌سازی پیشرفته مانند WOA-ELM و GOA-ELM استفاده می‌کنند، نقش حیاتی دارد. این تحلیل با ارزیابی تأثیر نسبی هر یک از متغیرهای ورودی بر خروجی مدل، اطلاعات ارزشمندی درباره مدل ارائه

جدول ۴. نتایج آنالیز حساسیت مدل‌های مختلف

شماره ترکیب	متغیر	WOA-ELM	GOA-ELM	ELM
۱	Q_{t-1}	۱	۱	۱
	Q_{t-2}	۲	۲	۲
۲	Q_{t-1}	۱	۱	۱
	Q_{t-2}	۲	۲	۲
	P_t	۳	۳	۳
۳	Q_{t-1}	۱	۱	۱
	P_{t-2}	۲	۲	۲
	P_{t-3}	۳	۳	۳
۴	Q_{t-1}	۱	۱	۱
	P_{t-2}	۲	۲	۲
۵	Q_{t-1}	۱	۱	۱
	Q_{t-2}	۲	۲	۲
	T_{t-3}	۳	۳	۳
۶	Q_{t-1}	۱	۱	۱
	P_{t-2}	۲	۲	۲
	T_{t-3}	۳	۳	۳
	E_t	۴	۴	۴

می‌دهد. اهمیت این موضوع در مدل‌های هیدرولوژیک بیشتر به دلیل پیچیدگی و تعاملات غیرخطی میان متغیرهاست که بدون تحلیل دقیق ممکن است منجر به نادیده گرفتن متغیرهای کلیدی یا در نظر گرفتن متغیرهای بی‌اهمیت شود. برای نمونه،

آنالیز حساسیت می‌تواند تعیین کند که کدام متغیرهای اقلیمی (مانند بارش، دما یا تبخیر) تأثیر بیشتری بر دقت پیش‌بینی مدل دارند. این دانش نه تنها به انتخاب ترکیب‌های بهینه ورودی کمک می‌کند، بلکه باعث می‌شود حجم محاسبات کاهش یافته

و پیچیدگی مدل به حداقل برسد. علاوه بر این، در مدل‌های بهینه‌سازی شده مانند WOA-ELM و GOA-ELM، آنالیز حساسیت می‌تواند به شناسایی نقش الگوریتم بهینه‌سازی در تنظیم ساختار مدل کمک کند و اطلاعاتی درباره توانایی این الگوریتم‌ها در مدیریت ورودی‌های مختلف فراهم آورد. بعد از توسعه مدل‌های مختلف حساسیت آنها نسبت به متغیرهای مختلف ارزیابی شد. بر اساس نتایج حاصل مدل همه مدل‌های WOA-ELM، GOA-ELM و ELM توسعه‌یافته نسبت به متغیر Q_{t-1} بیشترین حساسیت را دارند؛ اما همه آنها نسبت به یک متغیر کمترین حساسیت را ندارند. مدل‌های توسعه‌یافته برای ترکیب ۱، ۲، ۳، ۴، ۵ به ترتیب نسبت به متغیرهای Q_t ، P_t ، P_{t-3} ، P_{t-2} ، T_{t-1} و ۲ و مدل توسعه‌یافته برای ترکیب ۶ نسبت به متغیر E_t کمترین حساسیت را دارند (جدول ۴).

نتیجه‌گیری

مدل WOA-ELM در بیشتر ترکیبات ورودی نسبت به مدل‌های GOA-ELM و ELM عملکرد بهتری داشته است. این برتری به دلیل توانایی زیاد الگوریتم بهینه‌سازی نهنگ (WOA) در جستجوی گسترده در فضای پارامترها و تنظیم دقیق وزن‌های شبکه است؛ به‌طوری که مدل توانسته است خطای پیش‌بینی را به حداقل برساند. به‌ویژه، WOA با بهره‌گیری از مکانیزم‌های خاص مانند تقلید از رفتار گروهی نهنگ‌ها در یافتن غذا، قادر به بهبود همگرایی و اجتناب از گیر افتادن در

بهینه‌های محلی است. از سوی دیگر، الگوریتم GOA نیز در برخی ترکیبات مانند ترکیب ۴ عملکردی نزدیک به WOA-ELM نشان داد. این عملکرد قابل توجه ناشی از توانایی GOA در بهره‌برداری از ویژگی‌های الگوریتمی مانند پرش‌های تصادفی و تنظیم مرحله‌ای است. با این حال، GOA در ترکیبات پیچیده‌تر (مانند ترکیب‌های شامل چندین متغیر اقلیمی و زمانی) نتوانست پایداری و دقت لازم را در برابر WOA-ELM حفظ کند که نشان‌دهنده نیاز به بهبود بیشتر در مکانیزم‌های جستجوی آن است. در مقابل، مدل ساده‌تر ELM، اگرچه بهینه‌سازی خاصی روی آن اعمال نشده است، اما نشان داد که به‌تنهایی نمی‌تواند در برابر پیچیدگی روابط هیدرولوژیک عملکرد مطلوبی داشته باشد. علاوه بر این نتایج این مطالعه نشان می‌دهند که انتخاب ترکیب ورودی مناسب نقشی کلیدی در عملکرد مدل‌های پیش‌بینی جریان ایفا می‌کند. بر اساس نتایج حاصل از ارزیابی مدل‌های مختلف ترکیبات ساده‌تر (مانند ترکیب ۱) که تنها شامل داده دبی جریان در گذشته هستند، دقت نسبتاً مناسبی برای مدل‌ها ارائه می‌دهند. با این حال، ترکیباتی که از متغیرهای اقلیمی مانند بارش، دما و تبخیر استفاده کرده‌اند (مانند ترکیبات ۶ تا ۱۰)، عملکرد مدل‌ها را به‌ویژه برای مدل‌های بهینه‌شده بهبود بخشیده‌اند. این نتایج نشان می‌دهد که ترکیب داده‌های اقلیمی با داده‌های جریان می‌تواند دینامیک پیچیده‌تر رودخانه را بهتر شبیه‌سازی کند.

References

1. Abualigah, L. and A. Diabat. 2020. A comprehensive survey of the Grasshopper optimization algorithm: results, variants, and applications. *Neural Computing and Applications* 32(19): 15533-15556.
2. Abualigah, L. and A. Diabat. 2020. A comprehensive survey of the Grasshopper optimization algorithm: results, variants, and applications. *Neural Computing and Applications* 32(19): 15533-15556.
3. Badrzadeh, N., J. M. V. Samani, M. Mazaheri and A. Kuriqi. 2022. Evaluation of management practices on agricultural nonpoint source pollution discharges into the rivers under climate change effects. *Science of the Total Environment* 838: 156643.
4. Bouckaert, F. W., Y. Wei, J. Pittcock, V. Vasconcelos and R. Ison. 2022. River basin governance enabling pathways for sustainable management: A comparative study between Australia, Brazil, China and France. *Ambio* 51(8): 1871-1888.
5. Chatrabhuj, K. Meshram, U. Mishra and P. J. Omar. 2024. Integration of remote sensing data and GIS technologies in river management system. *Discover Geoscience* 2(1): 67.

6. Chen, H., S. Huang, Y.-P. Xu, R. S. Teegavarapu, Y. Guo, H. Nie, H. Xie and L. Zhang. 2023. River ecological flow early warning forecasting using baseflow separation and machine learning in the Jiaojiang River Basin, Southeast China. *Science of the Total Environment* 882: 163571.
7. Ding, S., X. Xu and R. Nie. 2014. Extreme learning machine and its applications. *Neural Computing and Applications* 25(3): 549-556.
8. Ferreira, D. M. and C. V. S. Fernandes. 2022. Integrated water quality modeling in a river-reservoir system to support watershed management. *Journal of Environmental Management* 324: 116447.
9. Gharehchopogh, F. S. and H. Gholizadeh. 2019. A comprehensive survey: Whale Optimization Algorithm and its applications. *Swarm and Evolutionary Computation* 48: 1-24.
10. Hichem, H., M. Elkamel, M. Rafik, M. T. Mesaaoud and C. Ouahiba. 2022. A new binary grasshopper optimization algorithm for feature selection problem. *Journal of King Saud University-Computer and Information Sciences* 34(2): 316-328.
11. Huang, G.-B., D. H. Wang and Y. Lan. 2011. Extreme learning machines: a survey. *International Journal of Machine Learning and Cybernetics* 2(2): 107-122.
12. Huang, G.-B., Q.Y. Zhu and C.-K. Siew. 2006. Extreme learning machine: theory and applications. *Neurocomputing* 70(1-3): 489-501.
13. Huang, G., G.-B. Huang, S. Song and K. You. 2015. Trends in extreme learning machines: A review. *Neural Networks* 61: 32-48.
14. Ilhan, A. 2022. Forecasting of river water flow rate with machine learning. *Neural Computing and Applications* 34(22): 20341-20363.
15. Kisi, O., H. M. Azamathulla, F. Cevat, C. Kullu, M. Kuhdaragh and M. Fuladipana. 2024. Enhancing river flow predictions: Comparative analysis of machine learning approaches in modeling stage-discharge relationship. *Results in Engineering* 22: 102017.
16. Lehner, B., C. R. Liermann, C. Revenga, C. Vörösmarty, B. Fekete, P. Crouzet, P. Döll, M. Endejan, K. Frenken and J. Magome. 2011. High-resolution mapping of the world's reservoirs and dams for sustainable river-flow management. *Frontiers in Ecology and the Environment* 9(9): 494-502.
17. Maleki, A., H. Hasadi and N. Pirouzinejad. 2014. Investigation of Flooding Hydrological Behavior in Razavar Watershed Using Statistical Analysis, SCS Model and Profile of the River. *Geography and Development* 12(34): 109-120 (in Farsi).
18. Mirjalili, Y., A. B. Gabis, S. Mirjalili and A. Ramdane-Cherif. 2021. Grasshopper optimization algorithm: theory, variants, and applications. *Ieee Access* 9: 50001-50024.
19. Mirjalili, S. and A. Lewis. 2016. The whale optimization algorithm. *Advances in engineering software* 95: 51-67.
20. Mirjalili, S. Z., S. Mirjalili, S. Saremi, H. Faris and I. Aljarah. 2018. Grasshopper optimization algorithm for multi-objective optimization problems. *Applied Intelligence* 48(4): 805-820.
21. Nadimi-Shahraki, M. H., H. Zamani, Z. Asghari Varzaneh and S. Mirjalili. 2023. A systematic review of the whale optimization algorithm: theoretical foundation, improvements, and hybridizations. *Archives of Computational Methods in Engineering* 30(7): 4113-4159.
22. Nasiri, J. and F. M. Khyabani. 2018. A whale optimization algorithm (WOA) approach for clustering. *Cogent Mathematics and Statistics* 5(1): 1483565.
23. Nayak, D. and A. K. Shukla. 2022. Review of state-of-the-art research on river hydrological hazards, restoration, and management, PP. 463-482. In: M. Pandey, H. Azamathulla and J. H. Pu (Eds.), *River Dynamics and Flood Hazards: Studies on Risk and Mitigation*, Springer, Singapore.
24. Panahi, R., M. M. Hoseinzadeh and S. Khaleghi. 2021. Zonation of flood hazard probability in Gamasiab river banks from Sahneh to Bisetoon - Kermanshah province. *Journal of Natural Environmental Hazards* 10(28): 53-66 (in Farsi).
25. Richter, B. D., R. Mathews, D. L. Harrison and R. Wigington. 2003. Ecologically sustainable water management: managing river flows for ecological integrity. *Ecological Applications* 13(1): 206-224.
26. Tang, Y., Y. Sun, Z. Han, Q. Wu, B. Tan and C. Hu. 2023. Flood forecasting based on machine learning pattern recognition and dynamic migration of parameters. *Journal of Hydrology: Regional Studies* 47: 101406.
27. Wang, J., S. Lu, S.-H. Wang and Y.-D. Zhang. 2022. A review on extreme learning machine. *Multimedia Tools and Applications* 81(29): 41611-41660.
28. Yousefvand, F., S. H. Golmayee, H. Qamarnia and M. K Zia Tabar Ahmadi. 2005. Evaluation of statistical methods in suspended load of Raz Avar River. In: *Third National Conference on Erosion and Sedimentation, Soil Conservation and Watershed Management Research Institute and the National Soil Conservation and Watershed Management Research Center, Tehran, Iran* (in Farsi).

29. Zoratipour, A. and M. Cheraghi. 2021. Combined Application of Multi-Criteria Decision Making Methods and Remote Sensing Systems for Flood Cellular Zoning of Abolabbas River Basin in Khuzestan Province. *Irrigation Sciences and Engineering* 44(4): 109-122 (in Farsi).