

Research Paper



Performance Comparison of Lumped Models and Machine Learning Approaches in Discharge Simulation



Zohreh Khorsandi Kouhanestani,¹ Fatemeh Taatpour²

1. Assistance Professor, Department of Nature engineering, Agricultural Sciences and natural Resources University of Khuzestan, Mollasani, Iran. khorsandi@asnrukh.ac.ir.

2. Ph.D. Candidate, Department of Rangeland and watershed management, yazd university, Yazd, Iran. f.taatpour341@gmail.com

Keywords

Discharge simulation, Machine learning, Lumped model, Kabkian watershed, Kohgiluyeh and Boyerahmad Province.

Received: 2024/09/03

Accepted: 2024/11/24

Published: 2025/04/19

ABSTRACT

Introduction

Rainfall-runoff processes are among the most complex and nonlinear phenomena in hydrology. In water resources management, runoff forecasting faces challenges in ungauged watersheds. Many models have been modified to simulate runoff using distinct input data. Recently, machine learning methods have been used for runoff simulation. However, all these methods and models do not have the same efficiency in runoff simulation. Therefore, it is important to identify the best model in terms of efficiency and accuracy. In this study, the efficiency of lumped models and machine learning methods was investigated in the Kabkian watershed.

Methodology

The Kabkian River is one of the principal branches of the Karun River. The area of the Kabkian watershed is about 835 square kilometers. In this research, some lumped hydrologic models such as AWBM, Sacramento, SIMHYD, TANK, and SMAR were used to simulate runoff. Also, some algorithms in decision trees, artificial neural networks, and support vector regression methods as machine learning methods were applied to simulate daily and monthly runoff in the Kabkian watershed. Runoff simulations were conducted using some packages of R software. Monthly and daily discharge, precipitation, and potential evapotranspiration for the period between 1972 and 2022 were used, after the time series were reconstructed and tested for homogeneity. In all methods, 70 percent of the data were used for training and 30 percent of the data for testing the models. The accuracy and efficiency of the methods were examined using R^2 , the Nash-Sutcliffe coefficient, and RMSE.

*Correspondin Author: Zohreh Khorsandi Kouhanestani, E-mail: khorsandi@asnrukh.ac.ir

How to cite this article: Khorsandi Kouhanestani, Z., Taatpour, F. (2025). Performance Comparison of Lumped Models and Machine Learning Approaches in Discharge Simulation, *Hydrogeomorphology*, 12(42): 60 – 80.

DOI: [10.22034/hyd.2024.63280.1754](https://doi.org/10.22034/hyd.2024.63280.1754)



Copyright: © by the authors

Publisher: University of Tabriz

Results and Discussion

Results showed that SMAR and AWBM, in comparison to other lumped models, have the best efficiency in the simulation of daily discharge in the Kabkian watershed. The Nash-Sutcliffe coefficients for them in the test stage are 0.79 and 0.78, respectively, showing that these models have good efficiency in daily discharge simulation. Also, the SMAR and AWBM models' Nash-Sutcliffe coefficients are 0.71 and 0.72, respectively, and the R2 for the two models is 0.79 in the monthly time series. These values show that these models have good efficiency. In machine learning methods, in the daily series, the random forest algorithm's R2 is 0.61 and has the best efficiency in comparison to other methods. Also, in the monthly series, the random forest's R2 is 0.93, which illustrates good discharge simulation efficiency.

Conclusions

The investigation of lumped models and machine learning methods efficiency in daily and monthly discharge simulation in the Kabkian watershed showed that lumped models have better results than machine learning methods. All methods couldn't simulate peaks of daily discharge correctly. Additionally, SMAR and AWBM have the best efficiency in daily simulation in this area. Among machine learning methods, the random forest algorithm performs with high accuracy in monthly series discharge simulation. AWBM has better efficiency than other lumped models, but this model has lower efficiency than the random forest algorithm.



مقاله پژوهشی



مقایسه کارایی مدل‌های یکپارچه و روش‌های یادگیری ماشین در شبیه‌سازی دبی



زهره خورسندی کوهانستانی^{۱*}، فاطمه طاعت‌پور^۲

۱- استادیار گروه مهندسی طبیعت، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاتانی، خوزستان، ایران. Kharsandi@asnrukh.ac.ir
 ۲- دانشجوی دکتری، دانشکده مهندسی مرتع و آبخیزداری، دانشگاه یزد، یزد، ایران. f.taatpour341@gmail.com

چکیده

در هیدرولوژی، فرآیند بارش - رواناب یکی از پیچیده‌ترین پدیده‌های غیرخطی است. پیش‌بینی رواناب در حوضه‌های فاقد آمار یکی از چالش‌ها در مدیریت منابع آب است. مدل‌های هیدرولوژیک و روش‌های مختلفی برای شبیه‌سازی رواناب ارائه شده‌است که با ورودی‌های محدود می‌تواند دبی را شبیه‌سازی کند، که همه آنها دقت و کارایی مشابهی در شبیه‌سازی مقادیر دبی ندارند؛ از این‌رو معرفی مدل و روش با بیشترین کارایی و دقت اهمیت دارد. در این پژوهش، کارایی مدل‌های هیدرولوژیک یکپارچه و روش‌های یادگیری ماشین در شبیه‌سازی دبی روزانه و ماهانه حوضه آبریز کبکیان، از سرشاخه‌های اصلی رودخانه کارون، بررسی شد. مدل‌های هیدرولوژیک یکپارچه AWBM، Sacramento، SIMHYD، SMAR و TANK و نیز الگوریتم‌های درخت تصمیم، شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان برای شبیه‌سازی دبی به کار گرفته شدند. سری‌های بارش، تبخیر و تعرق پتانسیل و دبی در دوره آماری ۱۳۵۰ تا ۱۴۰۱ پس از بررسی همگنی و رفع نواقص آماری به‌عنوان ورودی مدل‌ها استفاده شدند. برای ارزیابی عملکرد مدل‌ها، ضرایب کارایی R^2 ، نش-ساتکلیف (NS) و ریشه میانگین مربعات خطا (RMSE) به کار رفتند. نتایج نشان داد مدل‌های SMAR و AWBM در شبیه‌سازی دبی روزانه با ضرایب نش-ساتکلیف ۰/۷۹ و ۰/۷۸ عملکرد بسیار خوبی داشتند. در مقیاس ماهانه نیز این مدل‌ها با ضرایب نش-ساتکلیف ۰/۷۱ و ۰/۷۲ و ضریب تبیین ۰/۷۹ توانستند دقت بالایی نشان دهند. در میان روش‌های یادگیری ماشین، الگوریتم جنگل تصادفی بهترین عملکرد را برای شبیه‌سازی دبی روزانه با ضریب تبیین ۰/۶۱ داشت و در شبیه‌سازی دبی ماهانه نیز با ضریب تبیین ۰/۹۳ بسیار موفق عمل کرد. نتایج این مطالعه می‌تواند به انتخاب مدل‌های بهینه برای پیش‌بینی دقیق‌تر دبی در حوضه‌های فاقد آمار و بهبود مدیریت منابع آب، به‌ویژه در سرشاخه‌های رودخانه کارون، کمک کند.

کلیدواژه‌ها

شبیه‌سازی دبی، یادگیری ماشین، مدل یکپارچه، حوضه آبریز کبکیان، استان کهگیلویه و بویراحمد.

تاریخ دریافت: ۱۴۰۳/۰۶/۱۳

تاریخ پذیرش: ۱۴۰۳/۰۹/۰۴

تاریخ انتشار: ۱۴۰۴/۰۱/۳۰

ارجاع به این مقاله: خورسندی کوهانستانی، زهره، طلعت پور، فاطمه. (۱۴۰۴). مقایسه کارایی مدل‌های یکپارچه و روش‌های یادگیری ماشین در شبیه‌سازی دبی. هیدروژنومورفولوژی، ۱۲(۴۲): 60-80.

شناسه دیجیتال مقاله: [10.22034/hyd.2024.63280.1754](https://doi.org/10.22034/hyd.2024.63280.1754)

*نویسنده مسئول زهره خورسندی کوهانستانی
 رایانامه: Khorsandi@asnrukh.ac.ir



Copyright: ©2025 by the authors

Publisher: University of Tabriz

مقدمه

سالانه حجم زیادی از رواناب حوضه‌های آبریز کشور به دلیل عدم کنترل، از دسترس خارج شده و هدر می‌رود. بدلیل افزایش روزافزون تقاضای آب، اهمیت و حساسیت مهار آب‌های سطحی جهت برنامه‌ریزی‌های تأمین آب، بیش از پیش ضرورت می‌یابد. برآورد دقیق جریان رواناب حوضه‌ها به عنوان نخستین گام در استحصال این منابع و استفاده بهتر از پتانسیل موجود در حوضه‌های آبریز می‌باشد؛ با این حال کمبود آمار و اطلاعات آبدهی رودخانه‌ها بدلیل عدم وجود ایستگاه‌های آب‌سنجی در خروجی حوضه‌ها مشکلاتی در این زمینه ایجاد کرده‌است. علاوه بر این مواردی از قبیل کاهش یا افزایش سریع سرعت جریان، حمل مقدار زیاد رسوب، بارش‌های رگباری در اندازه‌گیری مستقیم جریان در ایستگاه‌های آب‌سنجی وجود دارد که برآورد دقیق جریان رواناب را با مشکل مواجه می‌سازد. مدل‌های بارش- رواناب یکی از ابزارهای مهم در مدیریت رواناب در حوضه‌های آبریز می‌باشند. جهت شبیه‌سازی رواناب با استفاده از مدل‌های بارش- رواناب فرآیندهای هیدرولوژیکی مختلفی از جمله نفوذ، مقادیر ذخیره خاک، جریان زیرقشری و ذخیره آب زیرزمینی در نظر گرفته می‌شوند. با توجه به اینکه امکان اندازه‌گیری تمام کمیت‌های موردنیاز جهت بررسی عکس‌العمل حوضه میسر نمی‌باشد، معرفی مدلی با کارایی مناسب، که بتواند در عین سادگی با استفاده از حداقل ورودی، پیش‌بینی قابل‌قبولی را از فرآیندهای هیدرولوژیکی ارائه کند امری ضروری به نظر می‌رسد. با توجه به تنوع مدل‌های بارش- رواناب، انتخاب یک مدل مناسب برای حوضه از جهت بهره‌وری، برنامه‌ریزی و مدیریت منابع آب اهمیت دارد. تاکنون مطالعات متعددی جهت انتخاب بهترین مدل‌های بارش رواناب در جهان صورت گرفته است. مجموعه برنامه‌های بارش رواناب ارائه شده توسط CRC برای پدیده‌های هیدرولوژیک حوضه توسعه یافته‌است که شامل مدل‌های یکپارچه‌ای مانند AWBM، SMAR، SIMHYD، Sacramento و TANK می‌باشد که داده‌های روزانه رواناب را از داده‌های روزانه بارش و تبخیر و تعرق پتانسیل تولید می‌کند (Sharifi et al., 2023; Rezaei Moghadam et al., 2024). محمدی‌وند و همکاران (۲۰۱۹) برای ارزیابی عملکرد مدل‌های AWBM، Sacramento، SIMHYD و شبیه‌سازی رواناب حوضه امامه به استفاده از بهینه‌ساز واسنجی خودکار الگوریتم ژنتیک پرداختند. نتایج آماری و گرافیکی حاصل از واسنجی و صحت‌سنجی حاکی از عملکرد بهتر مدل SIMHYD نسبت به دو مدل دیگر بوده است (Mohammadivand et al., 2019). یونسی و همکاران (۲۰۲۰) از مدل‌های مفهومی AWBM، Sacramento، SIMHYD، SMAR و TANK برای حوزه آبریز دشت سیلاخور (ایستگاه رحیم‌آباد) استفاده کردند. نتایج نشان‌دهنده توانایی نسبی مدل SIMHYD در شبیه‌سازی رواناب و کارایی کم مدل TANK در بین سایر مدل‌ها بود (Yonesi et al., 2020).

مدل‌های تجربی دارای محدودیت‌های زیادی بوده و کاربرد آنها مستلزم تصحیح ضرایب هر رابطه تجربی با صرف زمان و هزینه برای هر منطقه است. در سال‌های اخیر محققان زیادی در سراسر جهان سعی کرده‌اند از روش‌های نوین داده-کاوی برای مدل‌سازی دقیق مقدار رواناب سطحی استفاده کنند. مطالعات متعددی استفاده از روش‌های یادگیری ماشین در برآورد رواناب را استفاده نموده‌اند (Grenier et al., 2024; Asadi, et al., 2017). پاتل و جاش (۲۰۱۷) با استفاده از روش شبکه عصبی مصنوعی به مدل‌سازی ضرایب بارش رواناب در حوضه آبریز داروی در هند پرداختند. با بررسی نتایج مشاهده گردید مدل شبکه عصبی خطای بسیار پایینی داشته و برای شبیه‌سازی ضرایب بارش- رواناب در این حوضه پیشنهاد می‌شود. آنها در تحقیق خود از داده‌های بارش و رواناب به مدت ۲۹ سال استفاده نمودند که منجر به دستیابی به نتایج بسیار دقیق از جمله مقدار ۰/۹۹ برای ضریب همبستگی در این مطالعه شده‌است (Patel & Joshi, 2017). جودی حمزه آباد و همکاران (۲۰۱۷) به ارزیابی کارایی مدل‌های هیدرولوژیک ارزیابی آب و خاک و ماشین بردار پشتیبان در شبیه‌سازی رواناب رودخانه ليقوان چای پرداختند. نتایج نشان داد علی‌رغم توانایی هر دو مدل در شبیه‌سازی رواناب رودخانه ليقوان چای هیدرولوژیک ارزیابی آب و خاک دقت بیشتر و خطای کمتری نسبت به مدل ماشین بردار پشتیبان دارد (Joodi Hamzeabad et al., 2017). صمدی و همکاران (۲۰۱۹) به منظور پیش‌بینی دبی ماهانه ورودی به سد بوستان در استان گلستان از مدل‌های داده‌کاوی و

¹ Patel and Josh

² Samadi et al.

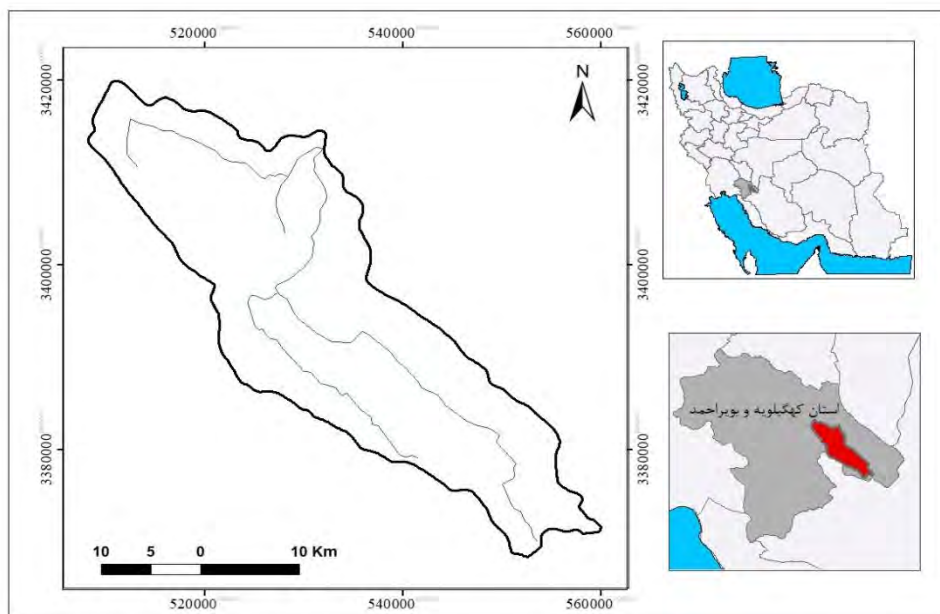
ترکیبی استفاده نمودند. برای این منظور از مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و سری‌های زمانی استفاده نمودند. یافته‌های این محققین نشان داد که مدل سری زمانی عملکرد مناسب‌تری را نسبت به بقیه مدل‌ها داشته‌است (Samadi et al., 2019). احمدی (۲۰۲۰) به بررسی ارزیابی عملکرد روش‌های ماشین بردار پشتیبان و سیستم استنتاج عصبی فازی تطبیقی در پیش‌بینی جریان ماهانه پرداخت. نتایج نشان داد که روش SVM از عملکرد بهتری نسبت به مدل ANFIS در پیش‌بینی جریان برخوردار است (Ahmadi, 2020). رستمی و همکاران (۲۰۲۱) با استفاده از مدل‌های هوش مصنوعی اقدام به شبیه‌سازی دبی سیلابی حوضه آبریز کشکان نمودند. نتایج نشان داد که این مدل‌ها می‌توانند به خوبی دبی سیلابی را شبیه‌سازی نمایند و به عنوان راهکاری مناسب و سریع در مدیریت منابع آب مطرح شوند (Roustami et al., 2022). محمدی و همکاران (۲۰۲۱) به شبیه‌سازی بارش-رواناب آبریز سد استقلال میناب با استفاده از روش‌های داده‌کاوی و مقایسه عملکرد آنها و ارائه مناسب‌ترین مدل بارش-رواناب برای این منطقه پرداختند. برای این منظور از هشت مدل داده‌کاوی شامل الگوریتم جنگل تصادفی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی، مدل الگوریتم‌های ارتقای شدید گرادیان، مدل درختی M5، مدل اسپلاین چند متغیره رگرسیون انطباقی، مدل فرایند گوسی، مدل بیزی جمعی رگرسیون درختی استفاده گردید. نتایج نشان داد که مدل اسپلاین چند متغیره رگرسیون انطباقی، بهترین عملکرد را در بین مدل‌ها برای شبیه‌سازی دبی ماهانه آبریز مورد مطالعه داشته‌است (Mohammadi et al., 2021).

بررسی منابع نشان می‌دهد، مدل‌های یکپارچه در مناطق مختلف کارایی‌های متفاوتی داشته‌اند. همچنین مدل‌های یادگیری ماشین به عنوان ابزاری نوین در شبیه‌سازی فرآیند پیچیده هیدرولوژیکی بارش-رواناب، مورد توجه قرار گرفته‌اند. با توجه به تنوع و پیچیدگی عوامل مؤثر در فرآیند بارش-رواناب و تفاوت‌های چشمگیر اقلیمی و جغرافیایی بین مناطق مختلف، انتخاب مدل مناسب برای هر منطقه، از اهمیت بالایی برخوردار است. مقایسه عملکرد مدل‌های مختلف یادگیری ماشین در پیش‌بینی رواناب می‌تواند به شناسایی مدل‌های دقیق‌تر و بهینه‌تر برای شرایط خاص منجر شود و دقت و کارایی شبیه‌سازی‌ها را بهبود بخشد. این مقایسه نه تنها به انتخاب مدل بهینه کمک می‌کند، بلکه می‌تواند به روشن شدن نقش و تأثیر هر یک از متغیرهای ورودی و نحوه پردازش آنها در مدل‌سازی نیز منجر شود، که به نوبه خود باعث مدیریت بهتر منابع آب و پیش‌بینی دقیق‌تر سیلاب‌ها و خشکسالی‌ها خواهد شد. این مطالعه با هدف ارزیابی کارایی روش‌های یادگیری ماشین و مدل‌های یکپارچه هیدرولوژیکی در برآورد دبی ماهانه و روزانه در حوضه آبریز کبکیان انجام می‌شود. در این مطالعه سعی می‌گردد میزان کارایی مدل‌های یکپارچه و یادگیری ماشین ارزیابی شود.

مواد و روش‌ها

منطقه مورد مطالعه

حوضه آبریز رودخانه کبکیان یکی از زیرحوضه‌های رودخانه کارون است. این حوضه با مساحت ۸۷۳ کیلومتر مربع در بخش جنوبی شهرستان بویراحمد در استان کهگیلویه و بویراحمد و در موقعیت ۵۱ درجه و ۳۵ دقیقه تا ۵۱ درجه و ۵۰ دقیقه طول شرقی و ۳۰ درجه و ۳۰ دقیقه تا ۳۰ درجه و ۵۵ دقیقه عرض شمالی قرار دارد. ارتفاع این حوضه بین ۱۵۳۸ تا ۲۰۸۱ متر از سطح دریا متغیر است. متوسط بارش این حوضه ۷۸۹ میلی‌متر و متوسط درجه حرارت آن ۱۳/۲ درجه سانتی‌گراد می‌باشد. زمین‌شناسی این حوضه به اواسط دوران مزوزوئیک تا عهد حاضر مربوط می‌شود و سازندهای نی‌ریز، سروک، گورپی، پابده، آسماری، گچساران، رازک، بختیاری و کواترنری در این منطقه وجود دارد. رودخانه اصلی این حوضه بعد از عبور از میان حوضه به رودخانه بشار می‌پیوندد که یکی از سرشاخه‌های مهم رودخانه کارون بزرگ است. شکل (۱) موقعیت جغرافیایی حوضه کبکیان را نشان می‌دهد.



شکل (1) موقعیت جغرافیایی حوضه آبریز کبکیان در ایران و استان کهگیلویه و بویراحمد

Figure (1): Geographical position of Kabkian watershed in Iran and Kohgiluyeh-va-boyerahmad porvince

روش کار

مدل‌های بارش - رواناب AWBM، Sacramento، SIMHYD، SMAR و TANK از نوع مدل‌های مفهومی یکپارچه می‌باشند که در بسته نرم‌افزاری RRL به همراه هشت بهینه‌ساز کالیبراسیون موجود است. به منظور انجام تحقیق حاضر ابتدا داده‌های مورد نیاز مدل‌های تجربی شامل داده‌های بارش، تبخیر و تعرق پتانسیل و دبی پایه زیرحوضه مورد مطالعه از ایستگاه‌های هواشناسی و هیدرومتری تهیه گردید. همچنین برای کاربرد روش‌های یادگیری ماشین به جز سری‌های روزانه، از سری‌های ماهانه نیز استفاده گردید. دوره آماری مورداستفاده در این مطالعه ۱۴۰۱-۱۳۵۰ در نظر گرفته شد. سپس کیفیت داده‌ها از نظر همگنی مورد بررسی قرار گرفت و داده‌های آماری با استفاده از روش ایستگاه معرف بازسازی گردید. با توجه به اینکه تعداد ایستگاه‌های باران‌سنجی و تبخیرسنجی موجود در حوضه بیش از یکی است از روش گرادیان برای بدست آوردن بارش، دما و تبخیر متوسط حوضه مورد مطالعه استفاده گردید. در جدول (۱) ویژگی‌های ایستگاه‌های مورداستفاده ارائه شده‌است.

جدول (۱) مشخصات ایستگاه‌های هواشناسی و هیدرومتری مورد استفاده
Table (1): properties of used climatological and hydrological stations

نام	نوع ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع از سطح دریا (متر)
سی سخت - بشار	باران‌سنجی	۵۱° ۲۷' ۸"	۳۰° ۵۲' ۱۱"	۲۲۵۴
شاه مختار	باران‌سنجی	۵۱° ۳۱' ۴۱"	۳۰° ۴۱' ۸"	۱۷۶۵
بطاری - کبکیان	باران‌سنجی	۵۱° ۲۰' ۳"	۳۰° ۵۱' ۴۲"	۱۵۷۰
ده کهنه	باران‌سنجی	۵۱° ۴۸' ۰"	۳۰° ۳۲' ۰"	۲۲۰۰
دشت روم	تبخیرسنجی	۵۱° ۳۵' ۰"	۳۰° ۳۴' ۰"	۲۱۰۵
یاسوج	تبخیرسنجی	۵۱° ۳۵' ۰"	۳۰° ۴۲' ۰"	۱۸۲۱

۱۵۴۰	۳۰° ۵۷' ۳۰"	۵۱° ۱۶' ۰"	تبخیر سنجی	پاتاوه
۱۵۶۰	۳۰° ۵۱' ۰"	۵۱° ۲۱' ۰"	هیدرومتری	بطاری - کبکیان

در ادامه با استفاده از مدل‌های AWBM و Sacramento، SIMHYD، TANK، SMAR از مدل‌های شبیه‌سازی بارش - رواناب حوضه کبکیان گردید. همچنین با استفاده از روش‌های یادگیری ماشین از جمله ماشین بردار پشتیبان (SVM)، شبکه عصبی پرسپترون چندلایه (MLP)، درخت تصادفی با الگوریتم‌های جنگل تصادفی (RF)، RT، ST و M5 نیز رواناب زیرحوضه‌ها شبیه‌سازی شد. برای شبیه‌سازی روش‌های یادگیری ماشین از بسته‌های نرم‌افزاری مختلف در نرم‌افزار R از جمله randomForest، e1071، neuralnet و rapt استفاده شده است.

مدل AWBM

AWBM یک مدل کامپیوتری بیلان آبی برای شبیه‌سازی بارش-رواناب است که اولین بار توسط بوقتون (۲۰۰۲) ارائه شد (Boughton, 2004). این مدل یک مدل سطوح جزئی جریان سطحی اشباع است که از بارش روزانه و ساعتی، تبخیر متوسط ماهانه و رواناب روزانه و ساعتی برای محاسبه‌ها استفاده می‌کند.

مدل AWBM بر اساس نظریه جریان از سطوح جزئی اشباع که مشابه نظریه جریان سطحی اشباع است، توسعه داده شده است. این مدل با در نظر گرفتن سه سطح ذخیره C1، C2 و C3 با مساحت‌های A1، A2 و A3 برای شبیه‌سازی ضریب رواناب استفاده می‌کند. به‌طور کلی جریان آب در هر سطح ذخیره به طور مستقل می‌شود. به نحوی که در هر مرحله بارش، با توجه به ذخیره رطوبتی در هر یک از سطوح سه‌گانه ذخیره آب (رطوبت) در خاک و با لحاظ مقدار تبخیر و تعرق، بیلان آب با استفاده از رابطه (۱) بدست می‌آید (Boughton, 2004):

$$\text{Store N} = \text{Store} + \text{Rain} - \text{Avap} \quad (1)$$

پارامترهای مدل AWBM عبارت‌اند از شاخص جریان پایه، ثابت خشکیدگی روزانه جریان و ظرفیت‌های ذخیره سطحی و سطوح متناظر با این ظرفیت‌ها. ذخیره اول در مدل نشان‌دهنده مکان‌هایی در سطح حوضه است که دارای کمترین میزان نفوذپذیری بوده و به سرعت از آب پر می‌شوند. سطح ذخیره دوم حالت بینابینی داشته و سطح ذخیره سوم که در مدل در انتها پر می‌شود نمایانگر جاهایی در سطح حوضه می‌باشد که بیشترین میزان نفوذپذیری را دارا بوده و به عبارتی در شکل‌گیری رواناب کمترین سهم را دارند.

مدل SIMHYD

SIMHYD یک مدل مفهومی ساده بارش-رواناب است که به‌صورت یکپارچه عمل نموده و در مطالعات تخمین رواناب، اثر تغییر اقلیم بر مقدار رواناب و آنالیز منطقه‌ای عملکرد موفق داشته است. در مدل SIMHYD، بارش روزانه ابتدا ذخیره برگاب را که هر روز توسط تبخیر خالی می‌شود، پر می‌کند. بارش مازاد سپس وارد تابع نفوذ شده و ظرفیت نفوذ را تعیین می‌نماید. بارش مازادی که از ظرفیت نفوذ تجاوز می‌کند به رواناب مازاد نفوذ تبدیل می‌شود. رطوبتی که نفوذ می‌کند وارد تابع رطوبت خاک می‌شود و از آنجا آب را به آبراهه، ذخیره آب زیرزمینی و ذخیره رطوبت خاک هدایت می‌کند. جریان داخلی و تغذیه آب زیرزمینی به‌عنوان یک تابع خطی از رطوبت خاک محاسبه می‌شوند و باقیمانده آب به مخزن رطوبت خاک انتقال می‌یابد. تبخیر و تعرق از مخزن رطوبت خاک در صورتی که از مقدار تبخیر و تعرق کنترل شده اتمسفری مازاد نباشد به‌عنوان یک رابطه خطی از رطوبت خاک برآورد می‌شود. مخزن رطوبت خاک ظرفیت محدودی دارد و به داخل مخزن آب زیرزمینی سرریز می‌شود. جریان پایه از مخزن آب زیرزمینی نیز به صورت افت خطی از مخزن تخمین زده می‌شود. در این مدل برای ۹ پارامتر ضریب جریان پایه، آستانه نفوذناپذیر، ضریب نفوذ، شکل نفوذ، ضریب جریان زیر قشری، کسر

نفوذپذیر، ظرفیت مخزن بارش برگاب، ضریب تغذیه و ظرفیت مخزن رطوبت خاک از مقادیر پیش‌فرض استفاده می‌شود. این مدل، تولید رواناب را از سه منبع رواناب مازاد بر میزان نفوذ، جریان داخلی و رواناب مازاد بر اشباع و جریان پایه بررسی کرده و تخمین می‌زند (Chiew, 2002).

مدل SMAR

مدل رطوبتی خاک SMAR یک مدل بارش - رواناب مفهومی یکپارچه است که در سال ۱۹۷۰ توسعه یافته است (O'Connell et al., 1970). تعدادی معادله تجربی و فرضیات برای برآورد رواناب مورد استفاده قرار می‌گیرد. این مدل از دو مدول تشکیل شده است. مدول تعادل غیر خطی آب مثل مقادیر رطوبت که از روابط پیوستگی قابل قبولی تشکیل شده است و مدول روندیابی که نزول و اثر بخشی حوضه را با استفاده از روندیابی اجزای مختلف رواناب حاصل در فواصل زمانی مختلف شبیه‌سازی می‌کند (Rezvani et al., 2023).

مدل Sacramento

Sacramento یک مدل مفهومی بارش - رواناب است که توسط NWSRFS برای پیش‌بینی سیلاب در ایالت متحده توسعه پیدا کرده است (Burnash, 1973). این مدل یکی از مدل‌های NWSRFS برای تبدیل ورودی بارش به خروجی جریان آبراه‌های است که دارای ۱۶ پارامتر مختلف است.

مدل TANK

TANK یک مدل مفهومی یکپارچه است که از چهار مخزن که در زیر سطح زمین قرار دارند تشکیل شده است. در هر مخزن یک روزنه وجود دارد که رواناب مازاد از هر مخزن از این روزنه خارج شده و مجموع این رواناب‌های مازاد از هر مخزن رواناب خروجی را شبیه‌سازی می‌کند (Basri, 2013).

روش درخت تصمیم

روش درخت تصمیم، زیر مجموعه‌ای از روش‌های یادگیری ماشین بر پایه درختی است که برای طبقه‌بندی یا پیش‌بینی بر اساس پاسخ سؤالات قبلی عمل می‌کند (Londhe & Dixit, 2012). این مدل، شکلی از یادگیری نظارت‌شده است که تابع هدف را با کمک مدل‌های رگرسیونی پیش‌بینی می‌کند. الگوریتم‌های متعددی برای ساخت درخت تصمیم وجود دارد از جمله RF، RT، M5 و ST. به عنوان نمونه الگوریتم M5 این الگوریتم درخت تصمیم را با رگرسیون خطی ترکیب می‌کند. این مدل ابتدا یک درخت می‌سازد و اطلاعات را از آن استخراج می‌کند. این الگوریتم ابتدا یک درخت معکوس به کمک داده‌های ورودی می‌سازد و از رگرسیون برای ایجاد برگ‌های این درخت استفاده می‌کند به نحوی که هر برگ دارای دامنه خاصی از داده‌های ورودی است. ساختن و هرس نمودن و هموارسازی سه گام اصلی این الگوریتم است (Mohammadi et al., 2021). الگوریتم RF (جنگل تصادفی) نیز با ساخت چندین درخت و ترکیب آنها به پیش‌بینی نتایج می‌پردازد. در این الگوریتم در ابتدا با تغییر عوامل مؤثر بر متغیر هدف تعداد زیادی درخت تصمیم‌گیری ایجاد می‌کند و سپس از ترکیب این درخت‌ها میزان واریانس را کاهش می‌دهد و دقت را افزایش می‌دهد (Breiman, 2001). در روش جنگل تصادفی تنها وجود دو پارامتر ورودی برای رسیدن به هدف و ایجاد مدل برای پیش‌بینی هدف مورد نیاز است.

شبکه عصبی پرسپترون چندلایه (MLP)

شبکه عصبی مصنوعی یک مدل داده مبنا است که می‌تواند برای پیش‌بینی از انواع توابع پیچیده خطی و غیرخطی استفاده کند. این روش با کمک شناسایی رابطه نهفته میان داده‌ها سعی در پیش‌بینی و ارائه یک تابع برای پیش‌بینی متغیر هدف دارد. در این روش سه لایه اصلی وجود دارد. لایه اول که لایه ورودی است و دارای تعدادی نرون برابر با متغیرهای ورودی است که نقش معرفی پارامترهای ورودی مدل را دارد و لایه خروجی نیز به تعداد متغیرهای خروجی نرون دارد. لایه پنهان نیز نقش پردازش داده‌ها را بر عهده دارد.

شبکه‌های عصبی از نظر ساختار و ارتباطات بین نرون‌ها به گروه‌های مختلفی تقسیم می‌شوند که یکی از رایج‌ترین آنها شبکه عصبی پرسپترون چندلایه می‌باشد که در این روش، الگوریتم مشخصی برای تعیین تعداد لایه‌های پنهان و تعداد نرون‌ها وجود ندارد و به کمک سعی و خطا تعداد لایه‌های پنهان و نرون‌ها مشخص می‌شوند. این روش به دو مرحله تقسیم شود: انتشار و به‌روزرسانی وزن‌ها. این دو مرحله تا زمانی که عملکرد مدل به اندازه کافی خوب باشد تکرار می‌شود (Haykin, 1999).

رگرسیون بردار پشتیبان

هدف ماشین‌های بردار پشتیبان یافتن یک تابع پیوسته با مقدار حقیقی است که بتواند به ازای مقادیر ورودی پیش‌بینی دقیقی از مقدار خروجی داشته باشد. روش SVM هم برای گروه‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها در رگرسیون استفاده می‌شود. روش SVR که مدل رگرسیونی SVM می‌باشد تابعی مرتبط با متغیر هدف را که خود تابعی از چند متغیر مستقل است را برآورد می‌کند. دقت پیش‌بینی یک مدل SVR متأثر از انتخاب نوع تابع کرنل است که می‌توان به تابع کرنل چندجمله‌ای، حلقوی، خطی و شعاعی اشاره کرد (Botsis et al., 2011; Chanklan et al., 2018). در این مطالعه از تابع کرنل خطی، شعاعی و چند جمله‌ای استفاده شده است.

معیارهای ارزیابی

در این مطالعه برای ارزیابی مدل‌های مورد استفاده از ضرایب کارایی Nash-Sutcliffe (NS)، ضریب تبیین (R²) و ریشه میانگین مربعات خطا (RMSE) استفاده گردید.

یکی از توابع هدف مورد استفاده برای واسنجی مدل‌های هیدرولوژیکی، ضریب کارایی Nash-Sutcliffe است که حالتی استاندارد از تابع میانگین مربعات خطاست. مقدار عددی ضریب کارایی NS بین منفی بی‌نهایت تا یک متغیر است. هر چه قدر مقدار NS به یک نزدیک‌تر باشد نشان‌دهنده تطابق بیشتر داده‌های شبیه‌سازی شده و مشاهده شده است و کارایی بهتر مدل در شبیه‌سازی پارامتر مورد نظر را تأیید می‌کند. مقدار ضریب NS کمتر از ۰/۳۵ نشان‌دهنده کارایی نامناسب، ۰/۳۶-۰/۷۵ کارایی رضایت‌بخش و بیشتر از ۰/۷۶ نتیجه شبیه‌سازی مدل را عالی ارزیابی می‌کنند (Eryani, 2022). هر شبیه‌سازی دارای مقداری خطا است که برای سنجش میزان خطا و دقت نسبی مدل‌ها، می‌توان از ریشه میانگین مربعات خطا استفاده نمود. مقدار RMSE نزدیک به صفر نشان‌دهنده خطای کمتر مدل در شبیه‌سازی داده‌های دبی است. معیار دیگر ضریب تبیین است. مقدار ضریب تبیین هر چه به یک نزدیک‌تر باشد کارایی مدل در شبیه‌سازی بالاتر است. برای محاسبه معیارهای ارزیابی از روابط زیر استفاده می‌شود (Eryani, 2022)

$$NS = 1 - \frac{\sum_{i=1}^n (Q_o - Q_s)^2}{\sum_{i=1}^n (Q_o - \bar{Q}_o)^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum (Q_o - Q_s)^2}{n-1}} \quad (3)$$

$$R^2 = \left[\frac{\sum_{i=1}^n (Q_o - \bar{Q}_o)(Q_s - \bar{Q}_s)}{\sqrt{\sum_{i=1}^n (Q_o - \bar{Q}_o)^2 \sum_{i=1}^n (Q_s - \bar{Q}_s)^2}} \right]^2 \quad (4)$$

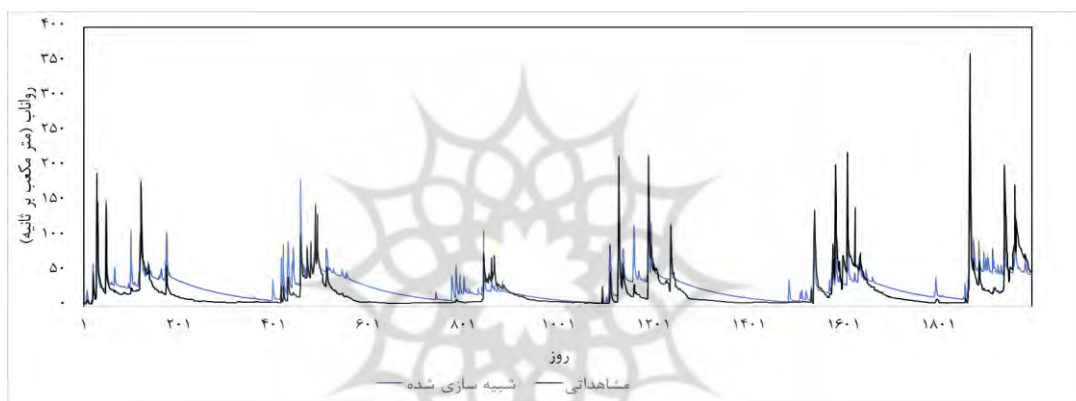
در روابط ارائه شده Q_o دبی مشاهداتی، Q_s دبی شبیه‌سازی شده (\bar{Q}_o) میانگین دبی مشاهداتی، (\bar{Q}_s) میانگین دبی شبیه‌سازی شده و n تعداد داده‌ها می‌باشد.

نتایج و بحث

بعد از آماده‌سازی داده‌های ورودی مدل‌های مورد استفاده از روش‌های بهینه‌سازی توابع هدف مدل‌ها واسنجی شدند. بعد از واسنجی مدل‌ها از داده‌هایی که برای واسنجی استفاده نشده بود برای صحت سنجی مدل‌ها در حوضه آبریز استفاده گردید.

شبیه‌سازی رواناب با مدل‌های هیدرولوژیکی

نتایج ارزیابی کارایی مدل‌های هیدرولوژیکی در مقیاس روزانه و ماهانه به ترتیب در جداول ۲ و ۳ ارائه شده است. نتایج ارزیابی کارایی مدل AWBM با استفاده از ضرایب ارزیابی کارایی، نشان داد که بالاترین کارایی برای این مدل در شبیه‌سازی دبی ماهانه در مرحله صحت‌سنجی در حوضه کبکیان با کمک روش بهینه‌سازی SCEUA و تابع هدف اولیه مجموع مربع خطا برابر $0/72$ به دست آمد. با توجه به نتایج به دست آمده مشخص گردید که این مدل کارایی رضایت‌بخشی در شبیه‌سازی داده‌های ماهانه دبی در این حوضه دارد. میزان مربعات خطا در این روش شبیه‌سازی رواناب ماهانه $22/4$ بدست آمد که در مقایسه با سایر مدل‌های یکپارچه کمتر است. در مقیاس روزانه نیز این مدل با کمک روش بهینه‌سازی الگوریتم ژنتیک و تابع هدف ضریب نش در حوضه کبکیان ضریب همبستگی مناسب $0/8$ و ضریب نش $0/78$ نشان داده است و RMSE نیز $23/81$ برآورد شد. شکل ۲ نتایج حاصل از مقایسه داده‌های رواناب روزانه مشاهداتی و شبیه‌سازی شده در دوره صحت‌سنجی و واسنجی در حوضه کبکیان را نشان می‌دهد. مدل AWBM در این حوضه نتوانسته است به صورت رضایت‌بخشی روند جریان را شبیه‌سازی نماید. اما در شبیه‌سازی داده‌های حداکثر، مقادیر به دست آمده کمتر از مقدار مشاهداتی بودند.



شکل (۲). بخشی از هیدروگراف رواناب روزانه شبیه‌سازی شده و مشاهداتی با AWBM در مرحله صحت‌سنجی

Figure (2). Apart of observed and simulate daily d hydrograph by AWBM for verification period.

جدول (۲). ضرایب ارزیابی مدل‌های مورد استفاده در مرحله واسنجی شبیه‌سازی دبی روزانه

Table (2): The evaluation coefficients of the models used in the calibration stage of daily discharge simulation

مدل	الگوریتم بهینه‌سازی - تابع هدف	پارامتر ارزیابی	مقدار
AWBM	Algorithm Genetic- Nash	Ns	$0/78$
		R^2	$0/8$
		RMSE	$23/81$
		Ns	$0/54$
Sacramento	Algorithm Genetic- Nash	R^2	$0/78$
		RMSE	$38/58$
		Ns	$0/54$
		R^2	$0/79$
Sim Hyd	Algorithm Genetic- Nash	RMSE	$23/89$

		Ns	۰/۴۵
TANK	SCEUA-Nash	R ²	۰/۵۳
		RMSE	۲۶/۵۹
		Ns	۰/۷۹
SMAR	c- SSE Algorithm Geneti	R ²	۰/۸
		RMSE	۳۱/۲۴


جدول (۳): ضرایب ارزیابی مدل‌های مورد استفاده در مرحله واسنجی شبیه‌سازی دبی ماهانه

Table (3): The evaluation coefficients of the models used in the calibration stage of monthly discharge simulation

مدل	الگوریتم بهینه‌سازی - تابع هدف	پارامتر ارزیابی	مقدار
		Ns	۰/۷۲
AWBM	SCEUA-Nash	R ²	۰/۷۹۷
		RMSE	۱۸/۴۲
		Ns	۰/۴۴
Sacramento	Algorithm Genetic- Nash	R ²	۰/۷۵۱
		RMSE	۳۶/۲
		Ns	۰/۶۲۹
SIM HYD	Algorithm Genetic- SSE	R ²	۰/۷۹۵
		RMSE	۲۲/۴
		Ns	۰/۴۹
TANK	Algorithm Genetic- SSE	R ²	۰/۶۴۳
		RMSE	۳۸/۱۶
		Ns	۰/۷۱
SMAR	SCEUA-SSE	R ²	۰/۷۹۷
		RMSE	۲۸/۸

نتایج شبیه‌سازی رواناب روزانه با مدل Sacramento در حوضه مورد مطالعه نشان داد که در حوضه کبکیان روش بهینه‌سازی الگوریتم ژنتیک و تابع هدف اولیه نش بهترین شبیه‌سازی را در مرحله واسنجی و صحت سنجی انجام داده است و در این شبیه‌سازی در مرحله واسنجی ضریب همبستگی ۰/۷۹ و ضریب نش ۰/۵۶ و در مرحله صحت سنجی به ترتیب ۰/۷۸ و ۰/۵۴ بوده است. در شبیه‌سازی ماهانه نیز در حوضه کبکیان با روش بهینه‌سازی الگوریتم ژنتیک و تابع هدف ضریب نش ضریب کارایی نش ۰/۴۴ بدست آمد که نشان‌دهنده

کارایی غیرقابل قبول این مدل است. به‌طور کلی از مقایسه دبی‌های شبیه‌سازی شده و مشاهده شده در این حوضه مشخص گردید دبی‌های حداکثر در هیچ یک از مقیاس‌های ماهانه و روزانه به‌خوبی شبیه‌سازی نشده‌است. در شکل ۳ دبی شبیه‌سازی شده و مشاهداتی در حوضه کبکیان با استفاده از مدل Sacramento ارائه شده‌است.




شکل (۳): بخشی از هیدروگراف رواناب روزانه شبیه‌سازی شده و مشاهداتی با مدل Sacramento در مرحله صحت‌سنجی

Figure (3): A part of observed and simulated daily hydrograph by Sacramento for verification period.

با توجه به نمودارها و ضرایب کارایی بدست آمده از شبیه‌سازی روزانه دبی با مدل SIMHYD در حوضه مورد مطالعه مشخص گردید که این مدل در حوضه کبکیان با روش بهینه‌سازی الگوریتم ژنتیک و تابع هدف اولیه ضریب نش، مقادیر ضریب تبیین و ضریب نش به ترتیب معادل $0/79$ و $0/54$ بدست آمد.

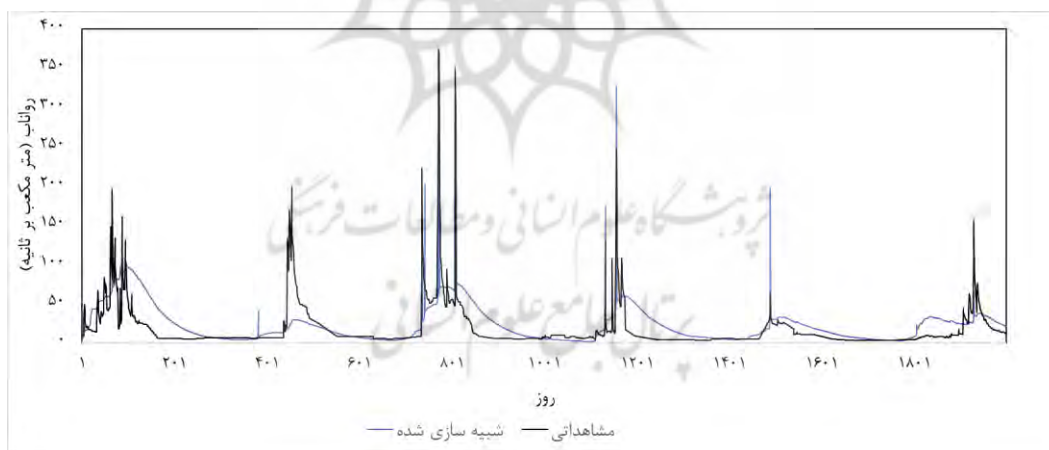
شبیه‌سازی سری ماهانه دبی در حوضه مورد مطالعه نشان داد که ضریب نش در مرحله صحت‌سنجی کبکیان با روش بهینه‌سازی الگوریتم ژنتیک، تابع هدف اولیه مجموع مربع خطا $0/62$ بود که نشان‌دهنده نتایج رضایت‌بخش این مدل در شبیه‌سازی دبی ماهانه در این حوضه بود. نمودار دبی شبیه‌سازی شده و مشاهداتی نیز حاکی از توانایی مناسب این مدل در شبیه‌سازی رواناب در حوضه کبکیان می‌باشد اما به‌طور کلی دبی‌های حداکثر به‌خوبی شبیه‌سازی نشده‌اند و دبی‌های شبیه‌سازی شده کمتر از مقدار مشاهداتی است (شکل ۴).



شکل (۴): بخشی از هیدروگراف رواناب روزانه شبیه سازی شده و مشاهداتی با مدل SYMHID در مرحله صحت سنجی

for verification period. Figure (4): Apart of observed and simulated daily hydrograph by SYMHID

همچنین در مدل TANK ضریب تبیین در مرحله صحت سنجی ۰/۷۷ و ضریب نش ۰/۴۵ بدست آمد. با روش بهینه سازی الگوریتم ژنتیک و تابع هدف مجموع مربع خطا در مقیاس ماهانه میزان ضریب نش ساتکلیف برای دوره واسنجی ۰/۴۹ و ضریب تبیین ۰/۶۴ بوده است. همچنین مقایسه رواناب ماهانه شبیه سازی شده و مشاهداتی در منطقه مورد مطالعه نشان داد که مدل قادر به شبیه سازی روند تغییرات دبی است؛ اما مقادیر حداکثر را به خوبی شبیه سازی نمی کند و در مقادیر دبی حداکثر کمتر از مقدار مشاهده شده شبیه سازی شده است. شکل ۵ بخشی از هیدروگراف رواناب شبیه سازی شده با این مدل را نشان می دهد.




شکل (۵): بخشی از هیدروگراف رواناب روزانه شبیه سازی شده و مشاهداتی با مدل TANK در مرحله صحت سنجی

Figure (5): Apart of observed and simulated daily hydrograph by TANK for verification period.

با توجه به نتایج شبیه سازی دبی روزانه با مدل SMAR در مرحله صحت سنجی با توجه به ضریب تبیین و ضریب نش که به ترتیب ۰/۷۹ و ۰/۸ در حوضه کبکیان می توان دریافت مدل قادر به شبیه سازی خوب در مقیاس روزانه است. در سری های ماهانه زیرحوضه کبکیان با روش بهینه سازی CUEA و تابع هدف مجموع مربع خطا، ضریب نش ۰/۷۱ بدست آمد. شکل ۶ نشان می دهد، مدل SMAR

بهترین نتایج را در شبیه‌سازی دبی روزانه ارائه کرده و در مقایسه با مدل‌های هیدرولوژیکی دیگر، توانسته است دبی‌های حداکثر را به خوبی شبیه‌سازی کند. این موضوع نشان‌دهنده کارایی خوب این مدل در پیش‌بینی رواناب در مقیاس روزانه است.



شکل (۶): بخشی از هیدروگراف رواناب روزانه شبیه‌سازی شده و مشاهداتی با مدل SMAR در مرحله صحت‌سنجی

Figure (6): Apart of observed and simulated daily hydrograph by TANK for verification period.

به‌طور کلی ارزیابی کارایی مدل‌های تجربی مورد استفاده نشان داد که مدل SMAR بهترین نتایج را در شبیه‌سازی دبی روزانه ارائه کرده است. در این منطقه، مدل AWBM نیز نتوانسته به خوبی مدل SMAR دبی روزانه را شبیه‌سازی کند. مدل‌های SMAR و AWBM به دلیل ساختار پارامتریک و قابل‌تنظیم، در شبیه‌سازی دبی روزانه در این حوضه کارایی مناسبی دارند و می‌توان از این مدل‌ها برای شبیه‌سازی جریان‌های دبی روزانه استفاده کرد. برای شبیه‌سازی دبی ماهانه در حوضه کبکیان نتایج مشابه شبیه‌سازی دبی روزانه است و مدل‌های SAMR و AWBM بهترین نتایج را در بین مدل‌های هیدرولوژیکی نشان داده‌اند و با توجه به پارامترهای ارزیابی کارایی مدل‌ها، کارایی این مدل‌ها در حد خوب بوده است. مطالعات مختلفی نیز کارایی خوب این مدل‌های هیدرولوژیکی را مورد تأیید قرار داده است (Gautam, 2023; Goodarzi et al., 2012; Hejazi & Loghmannia, 2023; Reddy et al., 2023; Rezie et al., 2014; Wang et al., 2011; Zarin et al., 2013). اما مشابه نتایج این مطالعه در سایر مطالعات نیز این مدل‌ها قادر نبودند به خوبی حداقل و حداکثر دبی را به خوبی شبیه‌سازی کنند (Rezvani et al., 2023). در این مطالعه، بهینه‌سازی پارامترهای مدل‌ها نیز به وسیله روش‌هایی نظیر الگوریتم ژنتیک و SCEUA انجام شد که سبب بهبود کارایی مدل‌ها گردید. این یافته‌ها نشان‌دهنده اهمیت استفاده از روش‌های بهینه‌سازی در بهبود دقت مدل‌ها و کاهش عدم قطعیت‌های ناشی از خطاهای پارامتری است، که توسط برخی پژوهش‌ها نیز مورد تأکید قرار گرفته است.

نتایج شبیه‌سازی با روش‌های یادگیری ماشین

همان‌طور که اشاره گردید از ۳ روش مبتنی بر داده و یادگیری ماشین با الگوریتم‌های مختلف در حوضه کبکیان استفاده شد. داده‌های مورد استفاده در این روش‌ها شامل بارش، تبخیر و دبی در مقیاس ماهانه و روزانه بود. در هر روش ۷۰ درصد از داده‌ها برای آموزش و ۳۰ درصد برای صحت‌سنجی مورد استفاده قرار گرفتند. در ادامه نتایج بدست آمده از هر روش ارائه خواهد شد. با توجه به مقادیر Ns ، $RMSE$ و R^2 در مراحل مختلف ارزیابی، مشخص است که هر الگوریتم ممکن است در مراحل واسنجی و صحت‌سنجی عملکرد متفاوتی داشته باشد. بنابراین، برای انتخاب بهترین الگوریتم باید نتایج ارزیابی را به دقت بررسی و تحلیل کرد.

روش درخت تصمیم

روش درخت تصمیم یکی از روش‌های مورداستفاده به‌منظور پیش‌بینی یا طبقه‌بندی متغیرهای وابسته مورد استفاده قرار می‌گیرد. در این روش از الگوریتم‌های M5، ST، RT و RF به‌منظور پیش‌بینی جریان کمک گرفته شده‌است. نتایج حاصل از این روش در جدول ۴ و ۵ برای سری‌های روزانه و ماهانه آورده شده‌است. همچنین شکل‌های ۷ و ۸ هیدروگراف‌های مشاهداتی و شبیه‌سازی شده در روش‌های مختلف را در مقیاس روزانه و ماهانه نشان می‌دهد.

جدول (۴): شاخص‌های ارزیابی الگوریتم‌های مختلف برای شبیه‌سازی دبی روزانه در مرحله واسنجی و صحت سنجی


Table (4): The evaluation coefficients of the different algorithms in the calibration and validation stage of daily discharge simulation

MLP	درخت تصمیم				SVM			شاخص ارزیابی	مرحله
	M5	ST	RT	RF	Polynomial	Linear	Radial		
۳۴/۵	۳۱/۷	۳۲/۱	۳۱/۹	۳۰/۵۵	۳۶/۹	۳۵/۶۷	۳۵/۳	RMSE	
۰/۰۰۰	۰/۲۵	۰/۲۴۸	۰/۲۵	۰/۳۱	-۰/۰۰۵	۰/۰۴۴	۰/۰۶۴	Ns	واسنجی
۰/۲۱	۰/۴۵	۰/۴۲	۰/۴۴	۰/۵۰۹	۰/۱۵۸	۰/۲۷	۰/۲۹	R ²	
۳۳/۲۸	۱۹/۱	۱۹/۳	۴۴/۹۷	۲۸/۴	۳۴/۹۸	۳۴/۱۵	۳۷/۱۳	RMSE	
۰/۲۲	۰/۲۵	۰/۲۴۸	۰/۲۵	۰/۶۵	-۰/۰۰۵	۰/۴۴	۰/۴۸	Ns	صحت سنجی
۰/۴۴	۰/۳۸	۰/۳۶	۰/۴۹	۰/۶۱۹	۰/۳۳۰	۰/۳۷	۰/۵۳	R ²	


جدول (۵): شاخص‌های ارزیابی الگوریتم‌های مختلف برای شبیه‌سازی دبی ماهانه در مرحله واسنجی و صحت سنجی

Table (5): The evaluation coefficients of the different algorithms in the calibration and validation stage of monthly discharge simulation


MLP	درخت تصمیم				SVM			شاخص ارزیابی	مرحله
	M5	ST	RT	RF	Polynomial	Linear	Radial		
۲۵/۹	۱۹/۱	۱۹/۳	۱۸/۵	۱۴/۹۸	۲۳/۵۸	۲۱/۸	۲۱/۷	RMSE	
-۰/۲۹۱	-۰/۴۶	-۰/۴۹	-۰/۶۳	-۰/۸۲	-۰/۴۸	-۰/۴۲	-۰/۴۸	Ns	واسنجی
۰/۲۶	۰/۳۸	۰/۳۶	۰/۶۸	۰/۸۱	۰/۴۷۸	۰/۵۴۱	۰/۵۴	R ²	
۲۱/۴۸	۲۲/۹	۲۲/۲	۱۹/۴۹	۱۰/۶۹	۲۳/۸	۲۲/۹۹	۲۳/۰۱	RMSE	
-۰/۳۵	-۰/۵۳	-۰/۵۵	-۰/۶۴	-۰/۷۶	-۰/۴۸	-۰/۳۶	-۰/۴۴	Ns	صحت سنجی
۰/۵۵	۰/۴۷	۰/۴۸	۰/۶۵۶	۰/۹۳	۰/۴۷	۰/۵۰۳	۰/۵۰۴	R ²	



SVR Linear




MLP

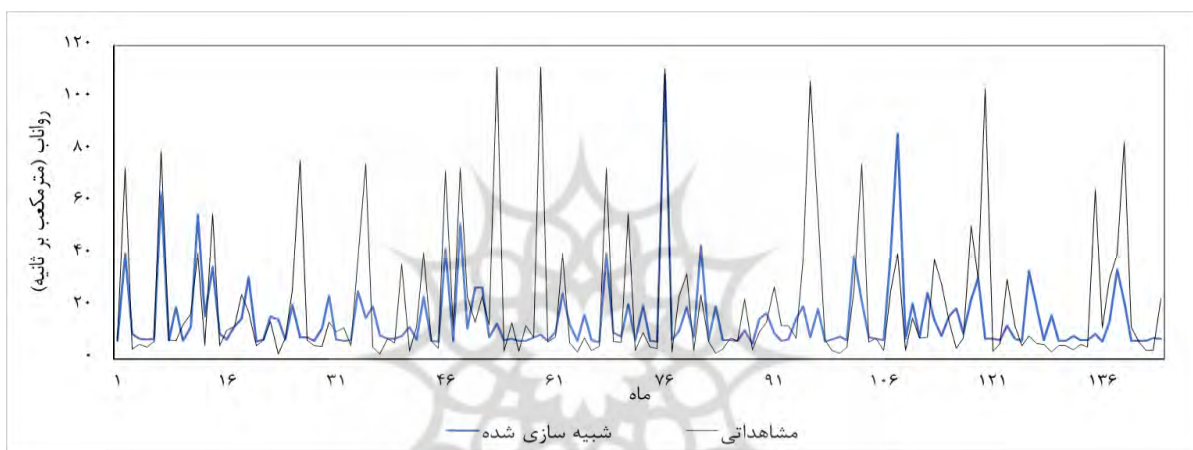


RF

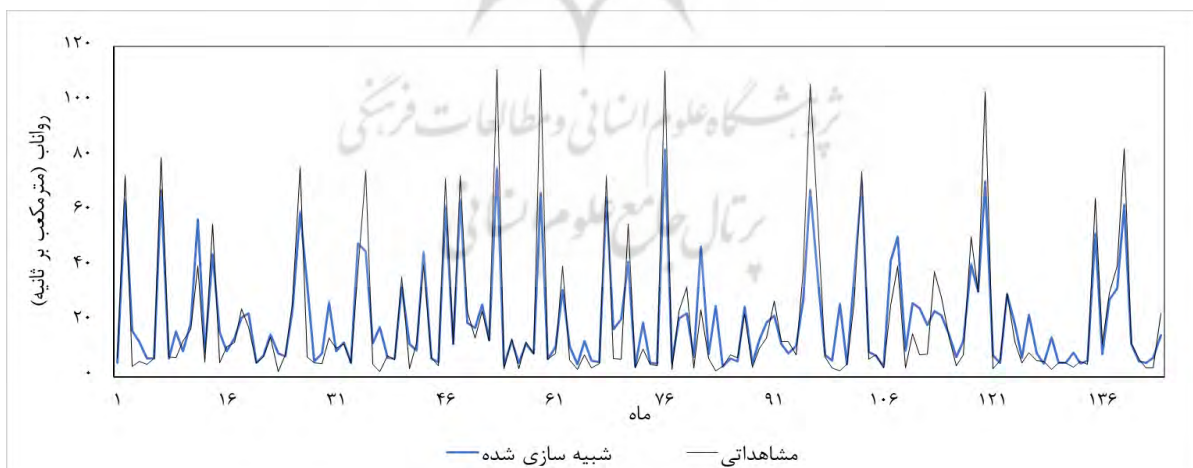
شکل (۷): بخشی از هیدروگراف رواناب روزانه شبیه‌سازی شده و مشاهداتی با روش‌های یادگیری ماشین
 Figure (7): A part of observed and simulated daily hydrographs by Machin learning method



MLP



SVR Radial



RF

شکل (۸): بخشی از هیدروگراف رواناب ماهانه شبیه سازی شده و مشاهداتی با روش های یادگیری ماشین
 Figure (8): A part of observed and simulated monthly hydrographs by Machine learning method

الگوریتم RT نیز در مقیاس روزانه نتایج قابل قبولی در حوضه مورد مطالعه ارائه نکرد، اما در شبیه‌سازی دبی ماهانه با ضریب تعیین $0/68$ و ضریب نش ساتکلیف $0/64$ نتایج قابل قبولی در مرحله واسنجی ارائه کرده است. شبیه‌سازی جریان روزانه با الگوریتم ST نیز نتایجی مشابه الگوریتم RT داشته است. در مقیاس ماهانه نیز نتایج این الگوریتم قابل قبول نبوده است. الگوریتم جنگل تصادفی (RF) نیز یکی دیگر از الگوریتم‌های مورد استفاده بود. این الگوریتم در حوضه کبکیان در شبیه‌سازی جریان روزانه در مراحل واسنجی و آموزش توانسته کارایی خوب تا بسیار خوب را ارائه کند. الگوریتم جنگل تصادفی در حوضه کبکیان جریان ماهانه را با دقت خیلی خوبی شبیه‌سازی نموده است.

روش شبکه عصبی پرسپترون چندلایه

بعد از بررسی نتایج حاصل از آموزش و واسنجی داده‌های شبیه‌سازی شده دبی روزانه مشخص شد که این روش کارایی غیرقابل قبولی در شبیه‌سازی دبی داشته است. در سری‌های ماهانه مقدار ضریب تعیین در حوضه $0/55$ است که نشان دهنده توانایی قابل قبول این روش در شبیه‌سازی داده‌های دبی ماهانه است.

روش ماشین بردار پشتیبان (SVR)

روش یادگیری ماشین بردار پشتیبان برای رگرسیون (Support Vector Regression) یک روش قوی در پیش‌بینی مقادیر پیوسته است. در SVR، هدف ایجاد یک مدل رگرسیون است که با ایجاد یک صفحه در فضای ویژگی‌ها، فاصله مطلق بین نقاط داده و خط رگرسیون به حداقل ممکن می‌رسد. در روش SVR توابع کرنل شعاعی، چندجمله‌ای و خطی استفاده شد و مقادیر پارامترهای مدل نیز با استفاده از روش بهینه‌سازی انتخاب شد. نتایج شبیه‌سازی دبی در مقیاس روزانه در این حوضه نشان داد که مدل SVR با تابع کرنل شعاعی در مرحله واسنجی میزان ضریب تبیین برابر $0/53$ و میزان RMSE معادل $37/13$ بدست آمد. در مرحله صحت سنجی نیز کمترین RMSE ($34/7$) و بیشترین میزان ضریب تبیین ($0/44$) در مدل SVR با تابع کرنل شعاعی ارائه شده است. در سری زمانی ماهانه دبی، در مرحله واسنجی میزان ضریب تبیین با تابع کرنل شعاعی، خطی و چندجمله‌ای به ترتیب $0/53$ ، $0/503$ و $0/47$ و میزان RMSE نیز $23/01$ ، $22/11$ و $23/8$ ارزیابی گردید. در مرحله صحت‌سنجی در سری ماهانه با تابع کرنل شعاعی، خطی و چندجمله‌ای نیز میزان ضریب تبیین به ترتیب $0/69$ ، $0/67$ و $0/66$ است. حداقل RMSE در این روش با تابع کرنل خطی ($20/79$) بود. با توجه به نتایج بدست آمده در مرحله صحت‌سنجی بیشترین ضریب تبیین و کمترین میزان خطا مربوط به تابع کرنل خطی و در مرحله واسنجی تابع شعاعی بیشترین ضریب تبیین را داشته؛ اما کمترین خطا مربوط به تابع کرنل خطی بوده است.

در شبیه‌سازی دبی روزانه مدل‌های یادگیری ماشین کارایی خوبی نداشته اند. روش درخت تصمیم و الگوریتم جنگل تصادفی بهترین کارایی را از بین روش‌های استفاده شده داشته است. در دبی‌های ماهانه روش درخت تصمیم و الگوریتم جنگل تصادفی و درخت تصادفی بهترین کارایی را از بین سایر روش‌های یادگیری ماشین داشته اند. نتایج بدست آمده که بر کارایی خوب و بسیار خوب روش‌های یادگیری ماشین تاکید دارد با نتایج محققان دیگر همخوانی دارد (Mohammadi et al., 2021; Najibzade et al., 2020; Taghi Sattari et al., 2013; Vyas et al., 2016). در مقایسه کارایی دو روش تجربی و یادگیری ماشین همانطور که نتایج نشان داد در شبیه‌سازی دبی روزانه روش تجربی بهترین کارایی را داشت و در شبیه‌سازی دبی ماهانه مدل‌های یادگیری ماشین (الگوریتم جنگل تصادفی) بالاترین دقت و کارایی را داشته است. مطالعات متعددی کارایی بهتر روش‌های یادگیری ماشین نسبت به مدل‌های هیدرولوژیک را مورد تأیید قرار داده اند (Hejazi & Loghmannia, 2023; Joodi Hamzeabad et al., 2017; Najibzade et al., 2020).

یکی از چالش‌های اصلی در شبیه‌سازی دبی، تخمین دقیق دبی‌های حداکثر است که هر دو نوع مدل‌های تجربی و یادگیری ماشین در این زمینه ضعف‌هایی از خود نشان دادند. نتایج این تحقیق که نشان‌دهنده عدم توانایی مطلوب مدل‌ها در شبیه‌سازی دبی‌های حدی است، با یافته‌های مشابهی در سایر مطالعات مشابهِت دارد (Mohammadi et al., 2021). عدم توانایی مدل‌ها در شبیه‌سازی دقیق

جریان‌های حدی، می‌تواند به دلیل کمبود داده‌های معتبر و مقیاس‌های زمانی کوتاه و نوسانات ناگهانی رواناب باشد، که نشان‌دهنده نیاز به استفاده از داده‌های ورودی دقیق‌تر و مدل‌های ترکیبی با دقت بیشتر است.

نتیجه‌گیری

پدیده‌های هیدرولوژیک را به دلیل پیچیدگی‌های بسیار زیاد و عدم رابطه خطی میان بارش و رواناب، به‌سختی می‌توان مدل‌سازی نمود. با توجه به این پیچیدگی‌های ذکرشده، مدل‌ها و روش‌های مختلفی برای تبدیل بارش به رواناب و پیش‌بینی جریان رودخانه‌ها به وجود آمده است. هر یک از این روش‌ها و مدل‌ها در شرایط واحد نتایج متفاوتی ارائه می‌کنند که تعیین بهترین و دقیق‌ترین رویکرد نیاز به بررسی دارد. از سوی دیگر در بسیاری از حوضه‌های آبریز به دلیل نقص و یا عدم اندازه‌گیری، داده‌های کافی برای پیش‌بینی و یا شبیه‌سازی جریان رودخانه وجود ندارد. در این تحقیق سعی شد عملکرد مدل‌های هیدرولوژیک و روش‌های یادگیری ماشین مورد ارزیابی قرار گیرد. مدل‌های هیدرولوژیک مورد استفاده حداقل داده‌های لازم که شامل بارش و تبخیر بودند را نیاز داشتند تا بتوانند دبی را شبیه‌سازی کنند و از داده‌های دبی برای کالیبراسیون و تعیین ضرایب استفاده می‌کنند. در روش‌های یادگیری ماشین نیز می‌توان تعداد زیادی از عوامل اثرگذار را وارد مدل‌سازی نمود؛ اما در این مطالعه همان داده‌هایی که در مدل‌های هیدرولوژیک استفاده شده‌است در آموزش روش‌های یادگیری ماشین نیز استفاده گردید. نتایج مقایسه کارایی دو روش استفاده شده نشان داد که در سری‌های روزانه که تغییرات داده‌ها بسیار زیاد است مدل‌های هیدرولوژیک بهتر عمل کرده‌اند؛ اما این عملکرد در حد قابل قبول بوده است. از سوی دیگر میزان بارش در تعداد زیادی از روزها صفر بوده است و این موضوع توانسته است بر روی میزان کارایی روش‌های یادگیری ماشین اثر منفی بگذارد. در شبیه‌سازی دبی ماهانه روش‌های یادگیری ماشین و به‌خصوص الگوریتم جنگل تصادفی عملکرد بسیار خوبی داشته‌است. روش‌های هیدرولوژیک نیز کارایی خوبی داشته‌اند؛ اما روش‌های هیدرولوژیک نتوانسته بود به خوبی دبی‌های حدی را شبیه‌سازی کند و علت آن می‌تواند یکپارچه بودن این مدل‌ها و عدم دخالت پارامترهایی مثل شیب، بافت خاک، پوشش گیاهی و زمین‌شناسی و غیره باشد. با توجه به نتایج بدست آمده از داده‌های محدود استفاده شده، می‌توان استفاده از مدل‌های هیدرولوژیکی و روش‌های یادگیری ماشین را برای شبیه‌سازی دبی حوضه‌های فاقد آمار پیشنهاد داد. به‌طور کلی، این تحقیق کارایی نسبی مدل‌های تجربی و یادگیری ماشین را بررسی کرد و نشان داد که هر کدام از این روش‌ها در مقیاس‌های مختلف زمانی دارای نقاط قوت و ضعف مخصوص به خود هستند. این یافته‌ها به محققان و مدیران منابع آب کمک می‌کند تا با توجه به نوع کاربرد و دقت مورد نیاز، بهترین مدل یا الگوریتم را برای شبیه‌سازی دبی در حوضه‌های فاقد آمار انتخاب نمایند.

References

- Ahmadi, F. (2020). Evaluation of support vector machine and adaptive neuro-fuzzy inference system performance in prediction of monthly river flow (case study: Nazlu chai and Sezar Rivers). *Iranian Journal of Soil and Water Research*, 51(3), 673-686 .
- Asadi, M., Fathzadeh, A., & Taghizadeh Mehrjerdi, R. (2017). The effects of the daily, monthly, and annual time scales on the suspended sediment load prediction. *Hydrogeomorphology*, 4(10), 121-143.
- Basri, H. (2013). Development of rainfall-runoff model using tank model: problems and challenges in Province of Aceh, Indonesia. *Aceh International Journal of Science and Technology*, 2(1), 26-36 .
- Botsis, D., Latinopoulos, P., & Diamantaras, K. (2011). Rainfall-runoff modeling using support vector regression and artificial neural networks. 12th International conference on environmental science and technology (CEST2011).
- Boughton, W. (2004). The Australian water balance model. *Environmental Modelling & Software*, 19(10), 943-956.
- Breiman, L. (2001). Random forests. *Machine learning*, Springer, 45, pp. 5-32 .

- Burnash, R. J. (1973). A generalized streamflow simulation system: Conceptual modeling for digital computers. US Department of Commerce, National Weather Service, and State of California .
- Chanklan, R., Kaoungku, N., Suksut, K., Kerdprasop, K., & Kerdprasop, N. (2018). Runoff prediction with a combined artificial neural network and support vector regression. *International Journal of Machine Learning and Computing*, 8(1), 39-43.
- Chiew, F. H. S., Peel, M. C. , Western, A. W. (2002). Application and testing of the simple rainfall-runoff model SIMHYD. In V. P. Singh, Frevert, D. (Ed.), *Mathematical models of small watershed hydrology and applications*, pp. 335–367.
- Eryani, I. (2022). Sensitivity analysis in parameter calibration of the WEAP Model for integrated water resources management in Unda watershed. *Civil Engineering and Architecture*, 455-469 .
- Gautam, D. K. (2023). Performance Evaluation of Rainfall-Runoff Models for Predictions of Inflows to Bhumibol Reservoir in Thailand. *Journal of Hydrology and Meteorology*, 11(1), 1-9 .
- Goodarzi, M. R., Zahabiyou, B., Massah Bavani, A. R., & Kamal, A. R. (2012). Performance comparison of three hydrological models SWAT, IHACRES and SIMHYD for the runoff simulation of Gharesou basin. *Water and Irrigation Management*, 2(1), 25-40. <https://doi.org/10.22059/jwim.2012.25090>
- Grenier, M., Boudreault, J., Raymond, S., & Boudreault, M. (2024). Projected seasonal flooding in Canada under climate change with statistical and machine learning. *Journal of Hydrology: Regional Studies*, 53, 101754 .
- Haykin, S. (1999). *Neural networks: A comprehensive foundation*. NJ. Prentice-Hall Inc. Englewood Cliffs .
- Hejazi, S. A., & Lohmannia, K. (2023). Temporal and spatial zoning of flood risk in Karganrood catchment using AWBM model and Fuzzy-ANP method. *Physical Geography Research*, 55(3), 71-88 .
- Joodi Hamzeabad, A. K., M, Akhavan, S., & Nozari, H. (2017). Evaluation of SWAT and SVM models to simulate the runoff of Lighvanchay river. *Water and Soil Science*, 26(4.1), 137-150 .
- Londhe, S. N., & Dixit, P. R. (2012). Forecasting stream flow using support vector regression and M5 model trees. *International Journal of Engineering Research and Development*, 2(5)12-15.
- Mohammadi, M., Vagharfard, H., Mahdavi Najafabadi, R., Daneshkar Arasteh, P., & Nazemosadat, M. J. (2021). Rainfall-runoff Modelling of Coastal Watersheds near Hormuz Strait Using Data Mining. *Iranian Journal of Soil and Water Research*, 52 (2), 313-327.
- Mohammadivand, M. R., Araghinejad, S., Ebrahimi, K., & Modaresi, F. (2019). Performance evaluation of AWBM, Sacramento and SimHyd models in runoff simulation of the Amameh Watershed using automatic calibration optimization method of Genetic Algorithm. *Iranian Journal of Soil and Water Research*, 50(7), 1759-1769 .
- Najibzade, N., Qaderi, K., & Ahmadi, M. M. (2020). Rainfall-runoff modelling using support vector regression and artificial neural network models (case study: SafaRoud Dam Watershed) .*Iranian Journal of Irrigation & Drainage*, 13(6), 1709-1720 .
- O'connell, P., Nash, J., & Farrell, J. (1970). River flow forecasting through conceptual models part II-The Brosna catchment at Ferbane. *Journal of hydrology*, 10(4), 317-329 .
- Patel, A. B., & Joshi, G. S. (2017). Modeling of rainfall-runoff correlations using artificial neural network-A case study of Dharoi Watershed of a Sabarmati river basin, India. *Civil Engineering Journal*, 3(2), 78-87 .
- Reddy, N. M., Saravanan, S., & Abijith, D. (2023). Streamflow simulation using conceptual and neural network models in the Hemavathi sub-watershed, India. *Geosystems and Geoenvironment*, 2(2), 100-153 .
- Rezie, H., Montaseri, M., Montaseri, M., Rezie, H., Jabari, A., & Behmanesh, J. (2014). The comparison of AWBM and SimHyd models in rainfall-runoff modeling (Case study: Nazlouchy Catchment). *Geography and Environmental Planning*, 24(4), 155-168 .
- Rezaei Moghaddam, M. H., Mokhtari, D., & skandarialni, M. (2024). Comparative evaluation of a semi-distributed hydrological model with an integrated model to simulate the runoff of Gomanab Chai basin. *Hydrogeomorphology*, 11(40), 39-22. doi: 10.22034/hyd.2024.59474.1715
- Rezvani, F. S., Ghorbani, K., Salarijazi, M., Rezaei Ghaleh, L., & Yazarloo, B. (2023). Comparative assessment of Sacramento, SMAR, and SimHyd models in long-term daily runoff simulation. *Water and Soil Management and Modelling*, 3(1), 279-297. <https://doi.org/10.22098/mmws.2022.11794.1171>

- Samadi, M., Bahremand, A., & Fathabadi, A. (2019). The Boustan Dam monthly inflow forecasting using data-driven and ensemble models in the Golestan Province. *Watershed Engineering and Management*, 11(4), 1044-1058 .
- Taghi Sattari, M., Pal, M., Apaydin, H., & Ozturk, F. (2013). M5 model tree application in daily river flow forecasting in Sohu Stream, Turkey. *Water Resources*, 40, 233-242 .
- Vyas, S. K., Mathur, Y. P., Sharma, G., & Chandwani, V. (2016). Rainfall-Runoff Modelling: Conventional regression and Artificial Neural Networks approach. 2016 International Conference on Recent Advances and Innovations in Engineering (ICRAIE) ,
- Wang, E., Zhang, Y., Luo, J., Chiew, F. H., & Wang, Q. (2011). Monthly and seasonal streamflow forecasts using rainfall runoff modeling and historical weather data. *Water Resources Research*, 47(5).
- Yonesi ,H. A., Yousefi, H., Arshia, A., & Yarahmadi, Y. (2020). Runoff Rainfall Simulation using RRL Toolkit (Case Study: Rahim Abad Station-Silakhor Plain). *Iranian Journal of Irrigation & Drainage*, 14(4), 1348-1361 .
- Zarin, H., Moghaddamnia, A., Nam, D. J., & Mosaedi, A. (2013). Simulation of outlet runoff in ungauged catchments by using AWBM Rainfall-Runoff Model. *Journal of Water and soil Conservation (Journal of Agricultural Sciences and natural Resources)*, 20(2), 195-208 .

