

Prediction of climate change impacts on the hydrological pattern and sediment load of Keshkan River basin using climate and hybrid metaheuristic models

R. Dehghani¹, E. Nohani^{2*}, H.R. Babaali³

Extended Abstract

Introduction:

Rising temperatures, altered precipitation patterns, and extreme weather events not only affect water resources and food security but can also significantly transform river dynamics, including the transport of suspended sediments. Riverine suspended sediments, as a vital indicator of watershed erosion and aquatic ecosystem health, play a crucial role in water quality, reservoir capacity, and the stability of water infrastructure. Therefore, understanding and accurately predicting future climate changes and their subsequent effects on sediment dynamics are of high importance for optimal water resource management and sustainable development planning. Climate predictions at various scales, including General Circulation Models (GCMs), provide powerful tools for simulating future climatic conditions under different greenhouse gas emission scenarios. After generating future climate scenarios, the next step is to analyze the consequences of these changes on hydrological and sediment processes, which requires more specialized and precise modeling. Considering recent research, General Circulation Models from the sixth report and Artificial Neural Networks are effective tools for estimating climatic parameters and river suspended sediments. In this study, hybrid models of Artificial Neural Network-Wavelet, Artificial Neural Network-Chicken Swarm Optimization, and Artificial Neural Network-Particle Swarm Optimization were used to estimate the suspended sediments of the Keshkan River located in Lorestan Province.

Materials and Methods:

The methodology of this research was designed and implemented in two main stages. The first stage involved collecting and refining data from a long-term statistical period including historical meteorological data (precipitation, minimum temperature, and maximum temperature), and hydrological data related to daily discharge and suspended sediment load of the Keshkan River. Subsequently, future climate data for the study area were downscaled using the output of a General Circulation Model under two representative scenarios with different levels of greenhouse gas emissions. The performance of the climate model was evaluated during the baseline period using various statistical indices. In the second stage, by combining climate and hydrological data, intelligent hybrid models were developed and applied, including Artificial Neural Network-Wavelet Transform, Artificial Neural Network-Particle Swarm Optimization, and Artificial Neural Network-Particle Swarm Optimization. The performance of these models was evaluated using error metrics, and the best model was selected for predicting suspended sediment load under climate

1- PhD in Water Sciences and Engineering, Soil Conservation and Watershed Management Research Department, Lorestan Agriculture and Natural Resources Research and Education Center, AREEO, Khorramabad, Iran

2- Assistant Professor, Department of Civil Engineering, Materials and Energy Research Center, Dez.C., Islamic Azad University, Dezful, Iran.

3- Associate Professor, Department of Civil Engineering, Islamic Azad University, Khorramabad branch, Khorramabad, Iran

* Corresponding Author: ebrahim.nohani@iau.ac.ir

Received: 2025/08/23

Accepted: 2026/01/16

change conditions. Finally, the trend of suspended sediment load changes was analyzed under different climate scenarios in the future period.

Results and Discussions:

The statistical analysis of the model's simulation for rainfall and temperature parameters during the historical period revealed that rainfall simulation error was higher than other parameters. The capability of the LARS-WG model in simulating meteorological parameters was confirmed, but the model showed less accuracy in rainfall simulation. The performance of the Sixth Assessment Report scenarios in forecasting future fluctuations compared to the baseline period indicated that both models successfully reproduced the seasonal rainfall pattern, which included a maximum in winter and early spring, and a minimum in summer. However, there were differences in absolute rainfall values between the models and scenarios. A reduction in rainfall during specific months, such as summer and early autumn, was predicted by some models in the SSP5-8.5 scenario, which could lead to the intensification of seasonal drought during these periods. The temperature graphs clearly showed a general warming trend in Pol-e Dokhtar county for the coming decades, with predicted temperatures in both the SSP5-8.5 and SSP1-2.6 scenarios significantly higher than observed values throughout the year. For modeling sediment load, a Support Vector Artificial Neural Network model was used with Wavelet, Chicken Swarm, and Particle Swarm Optimization algorithms. According to the evaluations, hybrid structures had less error compared with individual structures. Therefore, the results of the model evaluation showed that the Artificial Neural Network-Wavelet hybrid model demonstrated better performance in the validation stage, with a correlation coefficient of 0.965, the lowest root mean square error of 0.067, the lowest mean absolute error of 0.034, and the highest Nash-Sutcliffe efficiency coefficient of 0.970.

Conclusions:

Findings of this research indicated that climate change, as an influential factor, will alter the hydrological pattern of the Keshkan River basin in Lorestan Province. The results of temperature changes revealed that during the study period, the county would be affected by global warming, with temperature changes showing an increase in temperature from 2020 to 2050 in the SSP126 and SSP585 scenarios, respectively. The results from predicting rainfall and temperature fluctuations showed that the BCC-CSM2-MR model predicted much higher rainfall in the months of June to October, while the SSP585 scenario generally led to higher temperatures than SSP126. The outcomes from the performance of the hybrid models showed that the examined models in a combined structure, including all input parameters, performed better due to increased memory. The Artificial Neural Network-Wavelet model exhibited greater accuracy and less error compared with the other models investigated. The results from predicting sediment load in the coming years indicated a 23% increase in river sediment. This highlights the necessity for serious attention to comprehensive watershed management and the implementation of erosion control and desilting programs.

Keywords: Hydrological prediction, Climate change, Keshkan River Basin, General Circulation Model, Hybrid metaheuristic models.

Citation: Dehghani, R., Nohani, E., and Babaali, H.R., 2026., Prediction of climate change impacts on the hydrological pattern and sediment load of Keshkan River basin using climate and hybrid metaheuristic models. Iranian Water Research Journal, 20(60), pp. 55-76.

Copyright: © Authors, Published by Iranian Water Research Journal. This is an open-access article distributed under the CC-BY 4.0 (license <http://creativecommons.org/licenses/by/4.0/>).



پیش‌بینی تأثیر تغییر اقلیم بر الگوی هیدرولوژیکی و بار رسوبی حوضه آبریز رودخانه کشکان با استفاده از مدل‌های اقلیمی و هیبریدی فراکاوشی

رضا دهقانی^۱، ابراهیم نوحانی^{۲*}، حمیدرضا باباعلی^۳

چکیده

این پژوهش به بررسی تأثیر پدیده تغییر اقلیم بر الگوی هیدرولوژیکی و میزان بار رسوبی حوضه آبریز رودخانه کشکان در استان لرستان می‌پردازد. با استفاده از مدل پیش‌بینی کننده اقلیمی Can ESM5.0 از گزارش ششم CMIP6 و بر اساس سناریوهای SSP1-2-6 (خوش‌بینانه) و SSP5-8-5 (بدبینانه)، تغییرات پارامترهای جوی (دما و بارش) برای دوره آتی ۲۰۲۳ تا ۲۰۴۳، با در نظر گرفتن دوره پایه ۱۹۹۲ تا ۲۰۲۳، پیش‌بینی شد. سپس، با بهره‌گیری از مدل‌های هیبریدی فراکاوشی شامل شبکه عصبی مصنوعی-موجک، شبکه عصبی مصنوعی-ازدحام مرغ و شبکه عصبی مصنوعی-ازدحام ذرات، میزان رسوبات رودخانه کشکان با استفاده از پارامترهای بارش، دما و دبی جریان پیش‌بینی گردید. نتایج نشان داد که مدل Can ESM5.0 در شبیه‌سازی دمای حداکثر و حداقل دقت بالایی دارد، اما در شبیه‌سازی بارش خطای بیشتری را نشان می‌دهد. پیش‌بینی‌های دمایی حاکی از افزایش دما در هر دو سناریو SSP1-2-6 و SSP5-8-5 در دوره ۲۰۲۳ تا ۲۰۴۳ بود، با افزایش بیشتر دما در سناریوی SSP5-8-5 در پیش‌بینی بارش، تفاوت‌های قابل توجهی بین مدل‌ها مشاهده شد؛ به طوری که مدل BCC-CSM2-MR بارش بسیار بالاتری را در ماه‌های ژوئن تا اکتبر پیش‌بینی کرد. ارزیابی عملکرد مدل‌های هیبریدی نیز نشان داد که ساختارهای ترکیبی شامل کلیه پارامترهای ورودی، به دلیل افزایش حافظه، عملکرد بهتری دارند و در این میان، مدل شبکه عصبی مصنوعی-موجک با دقت بیشتر و خطای کمتر نسبت به سایر مدل‌ها اولویت دارد. نهایتاً، نتایج پیش‌بینی بار رسوبی در سال‌های آتی حاکی از افزایش ۲۳ درصدی میزان رسوبات رودخانه است که لزوم توجه جدی به مدیریت جامع حوضه آبریز و اجرای برنامه‌های کنترل فرسایش و رسوب‌زدایی را بیش‌ازپیش نمایان می‌سازد.

کلمات کلیدی: پیش‌بینی هیدرولوژیکی، تغییر اقلیم، حوضه آبریز کشکان، مدل گردش عمومی جو، مدل‌های هیبریدی فراکاوشی

ارجاع: دهقانی، ر.، نوحانی، ا.، و باباعلی، ح.ر.، ۱۴۰۵. پیش‌بینی تأثیر تغییر اقلیم بر الگوی هیدرولوژیکی و بار رسوبی حوضه آبریز رودخانه کشکان با استفاده از مدل‌های اقلیمی و هیبریدی فراکاوشی. مجله پژوهش آب ایران، ۲۰(۶۰)، صص. ۵۵-۷۶.

۱- دکترای علوم و مهندسی آب، بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان لرستان، سازمان تحقیقات، آموزش و ترویج کشاورزی، خرم‌آباد، ایران

۲- استادیار، گروه مهندسی عمران، مرکز تحقیقات مواد و انرژی، واحد دزفول، دانشگاه آزاد اسلامی، دزفول، ایران.

۳- دانشیار، گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد خرم‌آباد، خرم‌آباد، ایران.

* نویسنده مسئول: ebrahim.nohani@iau.ac.ir

تاریخ پذیرش: ۱۴۰۴/۱۰/۱۶

تاریخ دریافت: ۱۴۰۴/۰۶/۰۱

مقدمه

تغییرات اقلیمی جهانی، به عنوان یکی از چالش‌برانگیزترین مسائل قرن حاضر، تأثیرات گسترده‌ای بر سیستم‌های هیدرولوژیکی و ژئومورفولوژیکی سیاره ما دارد. افزایش دما، تغییر الگوهای بارش و رویدادهای حدی آب‌وهوایی نه تنها بر منابع آبی و امنیت غذایی تأثیر می‌گذارد، بلکه می‌تواند دینامیک رودخانه‌ها، از جمله حمل‌ونقل رسوبات معلق را به شدت دگرگون سازد (Tan et al., 2020). رسوبات معلق رودخانه‌ای، به عنوان شاخصی حیاتی از فرسایش حوضه آبخیز و سلامت اکوسیستم‌های آبی، نقش مهمی در کیفیت آب، ظرفیت مخازن سدها و پایداری زیرساخت‌های آبی ایفا می‌کنند. بنابراین، درک و پیش‌بینی دقیق تغییرات آبی اقلیم و به دنبال آن، اثرات آن بر دینامیک رسوب، برای مدیریت بهینه منابع آب و برنامه‌ریزی‌های توسعه پایدار از اهمیت بالایی برخوردار است (Shrestha et al., 2016).

حوضه آبریز کشکان در استان لرستان، به عنوان یکی از مناطق مستعد فرسایش در غرب ایران، با چالش‌های هیدرولوژیکی قابل توجهی روبروست. داده‌های تاریخی نشان می‌دهند که نرخ فرسایش منطقه‌ای اغلب از حدود ۴۵۰ تا ۶۰۰ تن در کیلومتر مربع در سال فراتر رفته و میانگین بار رسوبی سالانه رودخانه کشکان در ایستگاه‌های کلیدی، مقداری در حدود ۲/۵ تا ۳/۲ میلیون مترمکعب در سال را ثبت کرده است که این میزان به مراتب بالاتر از میانگین کشوری است. این آمار و ارقام، ضرورت توسعه ابزارهای پیش‌بینی دقیق و حساس به نوسانات اقلیمی، به ویژه برای سناریوهای شدید را بیش از پیش برجسته می‌سازد.

پیش‌بینی‌های اقلیمی در مقیاس‌های مختلف، از جمله مدل‌سازی گردش عمومی جو (GCMs)، ابزارهای قدرتمندی را برای شبیه‌سازی شرایط آبی آب‌وهوایی فراهم می‌آورند (Jaiswal et al., 2017). با این حال، استفاده از خروجی‌های GCMها برای مطالعات منطقه‌ای نیازمند تکنیک‌های ریزمقیاس‌سازی است. پس از تولید سناریوهای اقلیمی آینده، گام بعدی تحلیل پیامدهای این تغییرات بر فرآیندهای هیدرولوژیکی و رسوبی است که نیازمند مدل‌سازی‌های تخصصی است.

در این راستا، پیش‌بینی رسوبات معلق رودخانه تحت سناریوهای اقلیمی آبی، چالش‌های منحصر به فردی را به همراه دارد که رویکردهای مدل‌سازی سنتی به تنهایی قادر به حل آن نیستند. اگرچه مدل‌های فیزیکی/مکانیکی نظیر SWAT و HEC-RAS به دلیل قابلیت‌هایشان در شبیه‌سازی فرآیندهای فیزیکی ارزشمند هستند، اما کاربرد آن‌ها در پیش‌بینی‌های بلندمدت تحت سناریوهای تغییر اقلیم با محدودیت ذاتی در پارامترسازی و کالیبراسیون در شرایط غیر مشاهده شده آبی مواجه است (Neverman et al., 2023). در مقابل، نوآوری این پژوهش بر به کارگیری رویکرد هیبریدی یادگیری عمیق (WANN) متمرکز است که به جای مدل‌سازی صریح فیزیکی، بر یادگیری الگوهای آماری و غیرخطی پیچیده تمرکز دارد. این رویکرد با ترکیب Wavelet برای تجزیه سیگنال و الگوریتم‌های بهینه‌سازی PSO و CSO برای تنظیم دقیق وزن‌ها، پتانسیل بالایی در بهبود دقت پیش‌بینی‌ها نسبت به مدل‌های صرفاً فیزیکی یا مدل‌های ANN استاندارد فراهم می‌آورد. در سال‌های اخیر استفاده از مدل‌های هوش مصنوعی در پیش‌بینی میزان رسوبات معلق رودخانه‌ها با استفاده از سناریوهای اقلیمی مورد توجه محققین قرار گرفته است. به عنوان مثال

Ranjan and Mishra (2023) در پژوهشی اثر تغییر اقلیم بر تولید رسوب در حوضه آبریز رودخانه ماهانادی هند را مورد تحلیل قرار دادند. آن‌ها ابتدا داده‌های مشاهداتی دما و بارش دوره پایه را با خروجی مدل‌های گردش عمومی جو تحت سناریوهای مختلف تعدیل کردند. در گام بعدی، از یک مدل شبکه عصبی مصنوعی-الگوریتم ژنتیک برای ایجاد رابطه بین متغیرهای اقلیمی و داده‌های مشاهداتی رسوب استفاده نمودند. نتایج این تحقیق نشان داد که تغییر اقلیم منجر به تغییر در رژیم رسوب‌زایی حوضه شده و احتمال وقوع رویدادهای حدی رسوبی را افزایش می‌دهد. این پژوهش بر لزوم در نظرگیری این تغییرات در مدیریت منابع آب و سدها تأکید کرد. همچنین نتایج ایشان نشان داد که مدل هیبریدی شبکه عصبی مصنوعی دقت مدل منفرد را افزایش داده و عملکرد مطلوبی از خود نشان داده است.

در پژوهشی دیگر Zhang et al. (2023) به بررسی رابطه بین تغییر اقلیم و انتقال رسوب در رودخانه نینا نیوزیلند پرداختند.

در مجموع با توجه به پژوهش‌های انجام‌شده، مدل گردش عمومی جو گزارش ششم و مدل شبکه عصبی مصنوعی ابزاری کارآمد در برآورد پارامترهای اقلیمی و رسوبات معلق رودخانه هستند. امروزه به‌منظور افزایش کارایی و بهبود عملکرد مدل شبکه عصبی مصنوعی، از ترکیب این مدل با الگوریتم‌های فرا ابتکاری به‌عنوان راهکاری مناسب برای برآورد رسوبات معلق رودخانه‌ها استفاده می‌شود. در این پژوهش نیز از مدل‌های هیبریدی شبکه عصبی مصنوعی-موجک، شبکه عصبی مصنوعی-ازدحام مرغ و شبکه عصبی مصنوعی-ازدحام ذرات به منظور برآورد رسوبات معلق رودخانه کشکان واقع در استان لرستان استفاده شد.

رودخانه کشکان در سال‌های اخیر به‌شدت تحت تأثیر تغییرات اقلیمی و مداخلات انسانی قرار گرفته است. افزایش شدت و فراوانی پدیده‌های حدی نظیر خشکسالی و سیل، تغییر در الگوهای بارش و نوسانات دمایی ناشی از تغییر اقلیم، به همراه فعالیت‌هایی چون تغییر کاربری اراضی و فرسایش خاک در حوضه آبریز، به‌طور مستقیم بر رژیم هیدرولوژیکی و به‌ویژه دینامیک رسوبات معلق رودخانه اثرگذار است. رسوب زایی بیش‌ازحد نه‌تنها منجر به کاهش ظرفیت ذخیره سدها و تأسیسات آبی شده، بلکه با تخریب کیفیت آب و زیستگاه‌های آبریان، پایداری اکولوژیکی و اقتصادی منطقه را به چالش می‌کشد. بنابراین، درک دقیق و پیش‌بینی روندهای آبی رسوبات معلق تحت سناریوهای تغییر اقلیم، برای مدیریت پایدار منابع آب و حفاظت از محیط‌زیست در حوضه آبریز کشکان ضروری است. این تحقیق با ارائه بینش‌های علمی دقیق در مورد پاسخ رودخانه به تغییرات اقلیمی، می‌تواند مبنایی برای برنامه‌ریزی‌های استراتژیک و اتخاذ تصمیمات مدیریتی آگاهانه توسط ذینفعان و نهادهای مسئول فراهم آورد. هدف اصلی این پژوهش، توسعه و به‌کارگیری یک چارچوب مدل‌سازی یکپارچه برای پیش‌بینی دینامیک رسوبات معلق در رودخانه کشکان تحت تأثیر سناریوهای تغییر اقلیم آبی است. این مهم با ادغام خروجی مدل‌های گردش عمومی جو با یک مدل هیبریدی مبتنی بر شبکه‌های عصبی مصنوعی، موجک و الگوریتم‌های فراابتکاری (PSO/CSO) محقق شد.

در این تحقیق، از داده‌های چندین مدل گردش عمومی جو و مدل شبکه عصبی برای پیش‌بینی رسوب استفاده شد. داده‌های تاریخی شامل بارش روزانه و مقادیر رسوب اندازه‌گیری شده در ایستگاه‌های هیدرومتری بود. نتایج این مطالعه نشان داد که افزایش پیش‌بینی‌شده در سطح آب رودخانه می‌تواند باعث کاهش شیب رودخانه و کاهش توان انتقال رسوب شود که در بلندمدت منجر به تغییرات چشمگیر در مورفولوژی دلتا خواهد شد. همچنین نتایج حاصل از پیش‌بینی بار رسوبی نشان داد که مدل شبکه عصبی مصنوعی ابزاری مناسب در تخمین رسوبات معلق رودخانه است.

Kido et al. (2023) در پژوهشی به مدل‌سازی بار رسوبی در رودخانه هوکایدو در ژاپن پرداختند. در این مطالعه، از خروجی‌های مدل‌های گردش عمومی جو تحت سناریوهای انتشار متوسط و بالا استفاده شد. سپس یک مدل یادگیری ماشین از نوع شبکه عصبی پرسپترون چندلایه برای پیش‌بینی رسوب به کار گرفته شد. داده‌های مورد استفاده شامل بارش، دمای کمینه و بیشینه، دبی جریان و داده‌های ماهواره‌ای شاخص پوشش گیاهی در دوره ۲۵ ساله بود. نتایج نشان داد که کاهش پیش‌بینی‌شده در بارش سالانه، منجر به کاهش کلی بار رسوبی خواهد شد، اما شدت بارش در رویدادهای کوتاه‌مدت ممکن است افزایش یابد که خطر فرسایش لحظه‌ای را تشدید می‌کند. همچنین نتایج نشان داد مدل شبکه عصبی مصنوعی نسبت به روش آماری عملکرد بهتری در تخمین رسوبات معلق رودخانه دارد.

Zhang et al. (2024) در پژوهشی به بررسی اثرات پدیده تغییر اقلیم بر میزان بار رسوبی رودخانه لانگچان واقع در کشور چین پرداختند. در این مطالعه، از خروجی‌های چندین مدل گردش عمومی جو در چارچوب پروژه ششم مقایسه مدل‌های جفت‌شده استفاده شد. سپس، یک مدل شبکه عصبی مصنوعی برای برآورد بار رسوبی آینده به کار گرفته شد. داده‌های مورد استفاده شامل بارش، دمای کمینه و بیشینه، و دبی جریان به‌صورت ماهانه در یک دوره ۳۰ ساله (۲۰۲۰-۱۹۹۰) بود. یافته‌های پژوهش حاکی از آن بود که با وجود افزایش بارش در برخی ماه‌ها، به دلیل تغییر در الگوی بارش‌های شدید، میزان بار رسوبی سالانه در افق آینده افزایش قابل توجهی خواهد یافت.

مواد و روش‌ها

منطقه مورد مطالعه

در این مطالعه، حوضه آبریز کشکان به‌عنوان یکی از مهم‌ترین رودخانه‌های غرب ایران و به ویژه استان لرستان انتخاب شد. این رودخانه در محدوده‌ای بین طول‌های جغرافیایی ۴۷ درجه و ۳۱ دقیقه و ۳۴ ثانیه تا ۴۸ درجه و ۱۲ دقیقه و ۶ ثانیه شرقی و عرض‌های جغرافیایی ۳۳ درجه و ۴۴ دقیقه و ۴۱ ثانیه تا ۳۳ درجه و ۵ دقیقه و ۴۵ ثانیه شمالی در استان لرستان قرار گرفته است. مساحت کل حوضه

تحت پوشش این رودخانه تقریباً ۹۷/۶۶ کیلومترمربع است. شایان ذکر است که یکی از چالش‌های اصلی اکوسیستم این رودخانه، بار بالای رسوبات در بستر رودخانه است که سلامت محیط‌زیست و آبریزان را با مخاطره جدی مواجه می‌سازد. به همین دلیل، این پژوهش با هدف مدل‌سازی و پیش‌بینی دقیق میزان بار رسوبی با استفاده از رویکردهای نوین هوش مصنوعی مبتنی بر رویکرد ترکیبی (هیبریدی) توسعه داده شد. موقعیت دقیق منطقه مورد مطالعه در شکل ۱ نشان داده شده است.



شکل ۱- منطقه مورد مطالعه

روش تحقیق

در این مطالعه، داده‌های هواشناسی روزانه (دما و بارش) و داده‌های هیدرولوژیکی (دبی و رسوبات رودخانه) برای دوره پایه ۳۰ ساله (۱۹۹۲-۲۰۲۳) از شهرستان پلدختر، به ترتیب از اداره کل هواشناسی استان لرستان و شرکت آب منطقه‌ای استان لرستان گردآوری شد. این ایستگاه به‌عنوان یکی از ایستگاه‌های شاخص و معتبر استان شناخته می‌شود که داده‌های آن به‌طور مداوم و با استانداردهای کیفی سازمان هواشناسی ثبت شده است.

به‌منظور اطمینان از قابلیت اعتماد داده‌ها، فرآیند کنترل کیفیت جامعی در چهار مرحله اجرا گردید. در مرحله نخست، بازبینی اولیه برای شناسایی و حذف مقادیر نامعقول (مانند دمای غیرممکن یا بارش منفی) انجام شد. در مرحله دوم، بررسی توالی زمانی داده‌ها نشان داد که مجموعه داده‌ها فاقد هرگونه داده گمشده می‌باشد. در مرحله سوم، داده‌های پرت احتمالی با استفاده از آزمون آماری گرایس در سطح اطمینان ۹۵ درصد شناسایی و سپس با مقایسه با داده‌های ایستگاه‌های همجوار و گزارش‌های رویدادهای حدی اعتبارسنجی شدند. در نهایت، یکنواختی و همگنی سری زمانی داده‌ها با به‌کارگیری آزمون پتیت در سطح اطمینان ۹۵ درصد تأیید شد. پس از اتمام این مراحل، داده‌ها برای استفاده در مراحل بعدی تحلیل آماده شدند.

تفکیک مجموعه داده‌ها برای آموزش و ارزیابی عملکرد مدل‌ها بر اساس توالی زمانی صورت گرفت. ۸۰ درصد از کل داده‌های مشاهده‌ای برای آموزش مدل‌ها به کار رفت و ۲۰ درصد باقیمانده به‌عنوان مجموعه آزمون مستقل نگهداری شد تا قابلیت تعمیم مدل‌ها به‌طور دقیق سنجیده شود. برای اطمینان از پایداری عملکرد و جلوگیری از بیش‌برازش (Overfitting) مدل‌های توسعه‌یافته، در طول فرآیند آموزش، از روش اعتبارسنجی متقابل K-Fold با $K=5$ روی مجموعه آزمون استفاده شد تا پارامترهای داخلی بهینه‌سازی گردند. مدل نهایی بر اساس عملکرد آن در مجموعه آزمون مستقل انتخاب گردید. سپس، داده‌های اقلیمی پیش‌نگری شده از مدل (CMIP6) CanESM5.0 برای منطقه مورد مطالعه، با استفاده از نرم‌افزار LARS-WG نسخه ۸ به‌صورت آماری

ریزمقیاس نمایی گردید و صحت عملکرد مدل با داده‌های مشاهده‌ای اعتبارسنجی شد.

در مرحله بعد، سه مدل هیبریدی هوش مصنوعی شامل شبکه عصبی مصنوعی - موجک، شبکه عصبی مصنوعی - الگوریتم ازدحام مرغ و شبکه عصبی مصنوعی - الگوریتم ازدحام ذرات توسعه داده شد. این مدل‌ها با استفاده از داده‌های هواشناسی مشاهده‌ای و ریزمقیاس نمایی شده، آموزش داده و مدل بهینه با بالاترین دقت (بر اساس معیارهایی چون R^2 ، RMSE، MAE و NS) برای پیش‌بینی رسوبات رودخانه کشکان انتخاب شد.

مدل گردش عمومی جو

تغییرات اقلیمی آتی اثرات قابل توجهی بر رژیم هیدرولوژیکی حوضه و در نتیجه تولید و انتقال رسوب خواهد داشت. این امر مستلزم استفاده از خروجی‌های مدل‌های اقلیمی پیشرفته است. مدل‌های گردش عمومی (GCM) شامل مدل‌های گردش اتمسفری (AGCM)، مدل‌های گردش اقیانوسی (OGCM) و مدل‌های گردش اتمسفر-اقیانوس کوپل شده (AOGCM) هستند. در مطالعات اقلیمی، AOGCM معتبرترین ابزار برای شبیه‌سازی تغییرات اقلیمی آتی شناخته می‌شود، زیرا تعاملات پیچیده بین اتمسفر، اقیانوس، یخ کره و سطح زمین را در نظر می‌گیرد. این مدل‌ها با استفاده از سناریوهای انتشار گازهای گلخانه‌ای به‌عنوان ورودی اصلی، تغییرات آتی را پیش‌بینی می‌کنند (Irwin et al., 2012) در این پژوهش، مدل CanESM5.0 (Canadian Earth System Model version 5.0) به‌عنوان مدل اصلی برای استخراج داده‌های اقلیمی آتی انتخاب گردیده است. توجیه انتخاب این مدل بر اساس عملکرد مناسب آن در شبیه‌سازی الگوهای بارش منطقه‌ای و دمای سطح زمین در مناطق مشابه خاورمیانه و همچنین پوشش جامع و به‌روز بودن داده‌های تولیدشده تحت برنامه کپنهاگ (CMIP6) صورت پذیرفته است. این مدل به دلیل توانایی‌اش در شبیه‌سازی دقیق‌تر چرخه‌های منطقه‌ای در مقایسه با برخی مدل‌های قدیمی‌تر، ارجحیت داده شد (Pandey et al., 2022).

قبل از استفاده از خروجی‌های مدل CanESM5.0 برای سناریوهای آتی، عملکرد آن در بازتولید شرایط جاری و تاریخی (دوره پایه) ضروری است (Saha et al., 2014). برای این منظور، نتایج بارش تجمعی و میانگین دمای ماهانه

محاسبه شود. بنابراین، برای هر پارامتر در هر ماه ضریبی به دست خواهد آمد که از آن برای ایجاد سناریو در نرم افزار LARSWG و ریزمقیاس نمایی خروجی مدل‌های گزارش ششم استفاده شد.

شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (Nourani et al., 2011). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا با سناریو شبکه پیش‌خور و تعداد سه لایه به‌طور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (Nourani et al., 2009). از رایج‌ترین توابع فعال‌سازی استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک را نام برد (Hornik, 1998). در این پژوهش از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون با تعداد نورون‌های متفاوت استفاده شد. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لوبنبرگ-مارکواریت به دلیل همگرایی سریع‌تر در آموزش شبکه، انجام شد. همچنین از ترکیبات مختلف توابع محرک در لایه مخفی استفاده شد. تعداد تکرارهای لازم در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا ارزیابی می‌شود. تعداد نورون‌های موجود در لایه ورودی و خروجی با توجه به ماهیت مسئله مورد بررسی، مشخص شد؛ به طوری که تعداد نورون‌های موجود در لایه پنهان با سعی و خطا در راستای کاهش مقدار خطای

استخراج شده از مدل اقلیمی برای دوره پایه (۱۹۹۲-۲۰۲۳) با داده‌های اندازه‌گیری شده از نزدیک‌ترین ایستگاه هواشناسی معتبر (ایستگاه پلدختر) مقایسه شدند. این مقایسه برای اطمینان از صحت مدل‌سازی پارامترهای ورودی اصلی (بارش و دما) انجام شد. ارزیابی عملکرد مدل‌ها با استفاده از چهار شاخص آماری رایج ضریب همبستگی، جذر مربعات خطای نرمال شده، جذر مربعات خطا و میانگین قدر مطلق خطا صورت گرفت. که در بخش معیارهای ارزیابی تشریح می‌گردد. جدیدترین سناریوهای ارائه شده برای بررسی پارامترهای اقلیمی، سناریوهای گزارش ششم (AR6) است. در این سناریوها چگونگی مدل گردش عمومی در دوره‌های آتی بر اساس ترکیب سناریوهای انتشار (RCPs) و سناریوهای اقتصادی-اجتماعی (SSPs) بررسی می‌شود. در واقع بر اساس این گزارش، سناریوهای آینده علاوه بر توصیف اقلیم‌های متفاوت، باید جنبه‌های پیشرفت اقتصادی و اجتماعی را نیز شامل شوند (Riahi et al., 2017). در سناریوهای SSPs بر شبیه‌سازی چگونگی تغییر شرایط اقتصادی-اجتماعی مانند رشد جمعیت، رشد اقتصادی، آموزش، شهرنشینی، توسعه و تکنولوژی تأکید شده است (Jahangir et al., 2022).

همچنین در این پژوهش اطلاعات مربوط به متغیرهای بارش، دمای بیشینه، دمای کمینه و تعداد ساعات آفتابی مربوط به ایستگاه هواشناسی پلدختر در دوره ۱۹۹۲ تا ۲۰۲۳ به مدل LARSWG وارد شده و پس از اطمینان از توانایی مدل در شناخت ویژگی‌های آماری ایستگاه مذکور، از این مدل برای ریزمقیاس نمایی خروجی مدل‌های اقلیمی تحت دو سناریوی SSP1-2.6 و SSP5-8.5 استفاده خواهد شد. از آنجایی که مدل‌های گزارش ششم در نرم‌افزار LARSWG تعریف نشده‌اند بنابراین، نیاز است تا خروجی هر کدام از مدل‌ها با تعریف سناریو ریزمقیاس شود. به همین منظور ابتدا باید داده‌های بارش، دمای بیشینه و دمای کمینه مربوط به خروجی هر مدل برای دوره آتی تحت هر دو سناریوی SSP1-2.6 و SSP5-8.5 استخراج شود. سپس برای پارامتر بارش، نسبت میانگین بلندمدت ماهانه دوره آتی به دوره پایه و برای پارامترهای دمای بیشینه و دمای کمینه، اختلاف میانگین بلندمدت ماهانه دوره آتی و دوره پایه

تبدیل زمان-مقیاس است. بر همین اساس با استفاده از تبدیل موجک، در مقیاس‌های بالا سیگنال منبسط‌شده و جزئیات سیگنال قابل تجزیه و تحلیل است و در مقیاس‌های پایین سیگنال منقبض شده و کلیات سیگنال قابل بررسی می‌باشد. یک موجک به معنای موج کوچک، بخشی یا پنجره‌ای از سیگنال اصلی است که انرژی آن در زمان متمرکز شده است. با استفاده از تبدیل یا آنالیز موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد. بنابراین موجک‌ها نمونه‌های انتقال یافته و مقیاس شده‌ی سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و شدیداً میرا هستند. بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نامانا و گذرا را به صورت موضعی مورد تجزیه و تحلیل قرار داد (Shin et al., 2005). تبدیل موجک به دو صورت پیوسته و گسسته تعریف می‌شود.

تبدیل موجک پیوسته (CWT)

تبدیل موجک پیوسته تابع $f(t)$ به صورت روابط (۲) و (۳) تعریف می‌شود.


$$\begin{aligned} \text{CWT}_f^\psi(s, \tau) &= \Psi_f^\psi(s, \tau) \\ &= \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \psi^* \left(\frac{t-\tau}{s} \right) dt \\ &= \langle f(t), \psi_{s,\tau}(t) \rangle \end{aligned} \quad (2)$$

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi \left(\frac{t-\tau}{s} \right) \quad (3)$$

رابطه‌ی (۳) یک رابطه با دو متغیر s و τ است که در آن s پارامتر مقیاس (عکس فرکانس) و τ پارامتر انتقال است. علامت * نیز نشان‌دهنده‌ی مزدوج مختلط است. ψ تابع پنجره یا موجک مادر و $\frac{1}{\sqrt{|s|}} \psi \left(\frac{t-\tau}{s} \right)$ موجک‌های حاصل از انتقال و تغییر مقیاس موجک مادر است. واژه‌ی مادر به این سبب به کار می‌رود که تمامی نسخه‌های انتقال یافته و مقیاس شده (موجک‌های دختر)، همگی از این تابع به دست می‌آیند. یعنی موجک مادر یک الگو برای سایر پنجره‌هاست. علامت (...) نیز نشان‌دهنده‌ی ضرب برداری دو تابع در فضای سیگنال است. در این پژوهش از توابع مختلف موجک شامل هار، کلاه مکزیکی و مورلت استفاده

مدل مشخص می‌گردد. روند کار با تعداد نورون‌های کم آغاز می‌شود و افزودن نورون‌های اضافی تا زمانی ادامه می‌یابد، که افزایش نورون‌های بیشتر تأثیری در بهبود خطا نداشته باشد. در شکل ۲، نمونه‌ای از ساختار شبکه عصبی سه‌لایه‌ای شامل یک لایه ورودی، یک لایه مخفی و یک لایه خروجی نشان داده شده است. لازم به ذکر است در شبکه عصبی مصنوعی به دلیل ماهیت توابع فعال‌سازی باید دامنه پارامترهای مورد استفاده در محدوده توابع محرک باشند؛ بنابراین برای نرمال‌سازی از فرمول زیر استفاده شد:

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$



شکل ۲- نمای کلی یک شبکه عصبی مصنوعی سه لایه

تبدیل موجک

تبدیل موجک به‌عنوان روشی جایگزین برای تبدیل فوریه زمان کوتاه ارائه شده است و هدف از ارائه آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوریه‌ی زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه‌ی زمان کوتاه، سیگنال موردنظر به پنجره‌هایی تقسیم‌شده و تبدیل موجک روی هر کدام از این پنجره‌ها به صورت جداگانه انجام می‌گیرد (Wang et al., 2000). اما مهم‌ترین تفاوت آن‌ها در این است که در تبدیل موجک علاوه بر اینکه قدرت تفکیک فرکانس‌های یک سیگنال یا طول پنجره، متناسب با نوع فرکانس تغییر می‌کند، هم‌زمان عرض پنجره یا مقیاس فرکانس نیز متناسب با نوع فرکانس تغییر می‌کند. به عبارت دیگر، در تبدیل موجک به‌جای فرکانس، مقیاس وجود دارد. یعنی تبدیل موجک، نوعی

۴- جوجه‌ها در جستجوی غذا جفت خروس خود را دنبال می‌کنند. فرض می‌شود که مرغ‌ها به‌طور تصادفی غذای خوبی را که دیگران پیدا کرده‌اند، می‌دزدند. جوجه‌ها در اطراف مادران خود به دنبال غذا می‌گردند. خروس در رقابت برای غذا از مزیت برخوردار است.

در این الگوریتم، هر جوجه با موقعیت خود توصیف می‌شود. فرض کنید RN، HN، CN و MN به ترتیب نمایانگر تعداد خروس‌ها، مرغ‌ها، جوجه‌ها و مرغ‌های مادر باشند و معادله ریاضی، موقعیت i -امین جوجه در فضای بُعد j -ام در تکرار t -ام است، که در آن $i \in \{1, \dots, N\}$ ، $j \in \{1, \dots, D\}$ و $t \in \{1, \dots, T\}$ است. همچنین N ، D و T به ترتیب نمایانگر تعداد کل جوجه‌ها، تعداد ابعاد و حداکثر دفعات تکرار هستند. یک خروس، یک مرغ و یک جوجه دارای فرمول‌های به‌روزرسانی موقعیت خاص خود هستند. برای یک خروس، موقعیت بازگشتی آن به شرح زیر تعریف می‌شود:

$$X_{i,j}^{t+1} = X_{i,j}^t \cdot (1 + \text{Randn}(0, \sigma^2)) \quad (4)$$

$$\sigma^2 = \begin{cases} 1 & \text{if } f_i \leq f_k \\ \exp\left(\frac{f_k - f_i}{|f_i| + \varepsilon}\right) & \text{otherwise } k \in [1, \text{RN}], k \neq i \end{cases} \quad (5)$$

در اینجا، $\text{Randn}(0, \sigma^2)$ یک عدد تصادفی است که از توزیع گوسی با میانگین صفر و واریانس σ^2 پیروی می‌کند. ε یک ثابت بسیار کوچک است. k تعداد خروس دیگری است که به‌صورت تصادفی انتخاب می‌شود، و f_i و f_k به ترتیب مقادیر برازندگی خروس i -ام و خروس k -ام هستند. موقعیت بازگشتی یک مرغ به شرح زیر تعریف می‌شود:

$$X_{i,j}^{t+1} = X_{i,j}^t + C1 \cdot \text{Rand} \cdot (X_{r1,j}^t - X_{i,j}^t) + C2 \cdot \text{Rand} \cdot (X_{r2,j}^t - X_{i,j}^t) \quad (6)$$

$$C1 = \exp\left(\frac{f_k - f_i}{|f_i| + \varepsilon}\right) \quad (7)$$

$$C2 = \exp(f_{r2} - f_i) \quad (8)$$

در اینجا، $C1$ و $C2$ فاکتورهای یادگیری هستند، Rand یک عدد تصادفی است که از توزیع یکنواخت در بازه $[0, 1]$ پیروی می‌کند. $r1$ شاخص خروسی است که همسر مرغ i -ام است، $r2$ تعداد یک خروس یا یک مرغ است که به‌صورت تصادفی انتخاب می‌شود ($r1 \neq r2$).

شد. تابع مویک مورلت به دلیل آنکه مشتق دوم تابع گوسین می‌باشد از عملکرد بهتری برخوردار بود و به همین دلیل انتخاب شد. تبدیل مویک مورلت با ارائه تحلیل زمان-فرکانس دقیق، قابلیت تنظیم فرکانس مرکزی، شکل مناسب برای تحلیل سیگنال‌های ارتعاشی و امکان استخراج اطلاعات فاز، یک ابزار قدرتمند برای تحلیل سیگنال‌ها در حوزه‌های مختلف است که حتی می‌تواند نویز را از سیگنال حذف نماید. روش‌های حذف نویز مبتنی بر مویک معمولاً عملکرد بهتری نسبت به روش‌های سنتی دارند، زیرا می‌توانند نویز را بدون از دست دادن جزئیات مهم سیگنال حذف کنند.

الگوریتم ازدحام مرغ

بهینه‌سازی ازدحام مرغ (CSO)، یک الگوریتم الهام گرفته زیستی است که برای بهینه‌سازی تک هدفه مورد استفاده قرار می‌گیرد (Zouache et al., 2019). این الگوریتم توسط منگ و همکاران (Meng et al., 2014) ارائه شده است. بهینه‌سازی ازدحام مرغ از نظم سلسله مراتبی و رفتارهای یک دسته مرغ هنگام جستجوی غذا تقلید می‌کند، جایی که هر مرغ نشان‌دهنده یک راه‌حل بالقوه برای یک مسئله بهینه‌سازی است. در اصل، CSO از چهار قانون زیر برای ایده‌آل‌سازی رفتار مرغ‌ها استفاده می‌کند:

۱- دسته یا ازدحام مرغ گروه مرغ متشکل از چندین گروه است که هر گروه خروس غالب و برتر و یک جفت مرغ و جوجه دارد.

۲- در هر گروه از دسته مرغ، اعتبار و هویت مرغ (خروس، مرغ و جوجه) به ارزش و مقدار تناسب خود مرغ بستگی دارد. جوجه‌هایی که بهترین مقادیر تناسب را دارند، به‌عنوان خروس شناخته می‌شوند. هرکدام از آن‌ها در یک گروه از خروس جلوتر خواهند بود. جوجه‌هایی که از نظر آمادگی جسمانی ضعیف‌تر هستند، به‌عنوان جوجه شناخته می‌شوند و بقیه به‌عنوان مرغ‌ها در نظر گرفته خواهند شد.

۳- بعد از هر چند مرحله (G)، ترتیب سلسله مراتبی، رابطه سلطه و رابطه مادر و کودک باید کاملاً تغییر کند.

بنابراین، این الگوریتم‌ها نه تنها برای مقداردهی اولیه، بلکه برای هدایت و تنظیم دقیق وزن‌ها در تمامی تکرارهای آموزشی استفاده شدند تا از به دام افتادن در بهینه‌های محلی جلوگیری شود.

۲-۹. معیار ارزیابی

در این پژوهش برای ارزیابی مدل‌های مورد بررسی به‌منظور مدل‌سازی میزان رسوبات رودخانه از شاخص‌های ارزیابی زیر استفاده شد.

$$R^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (11)$$

$$NRMSE = \left(\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \right) \times \frac{100}{\bar{x}} \quad (12)$$

$$MAE = \frac{\sum_{i=1}^n |x_i - y_i|}{n} \quad (13)$$

$$PBIAS = \frac{\sum_{i=1}^{i=N} (y_i - x_i)}{\sum_{i=1}^{i=N} y_i} \quad (14)$$

$$PSR = \frac{RMSE}{STDEV} \quad (15)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad \infty \leq NSE \leq 1 \quad (16)$$

در روابط ۱۰ تا ۱۶، R^2 ضریب همبستگی، RMSE جذر مربعات خطا، NRMSE جذر مربعات خطای نرمال شده، MAE میانگین قدر مطلق خطا، PBIAS ضریب بایاس، ضریب PSR و NSE معیار نش-ساتکلیف می‌باشند. در این روابط x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام‌های زمانی، \bar{x} و \bar{y} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. قابل ذکر است از معیارهای ضریب همبستگی، جذر مربعات خطا، ضریب بایاس، ضریب PSR و ضریب نش ساتکلیف جهت ارزیابی مدل‌های هیبریدی استفاده شد. علاوه بر معیارهای بالا از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی-محاسباتی نسبت به زمان نیز برای مقایسه و تحلیل بیشتر استفاده شد.

موقعیت بازگشتی یک جوجه به شرح زیر تعریف می‌شود:

$$X_{i,j}^{t+1} = X_{i,j}^t + FL \cdot (X_{m,j}^t - X_{i,j}^t) \quad (9)$$

m_j نشان‌دهنده مرغ مادر جوجه‌ها است و FL یک فاکتور تصادفی در بازه $[0, 2]$ است.

الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی ازدحام ذرات یک الگوریتم فراابتکاری است که اولین بار توسط کندی و ابرهات معرفی شد (Eberhart and Kennedy., 1995). این پژوهشگران ابتدا به بررسی هوش محاسباتی بر اساس روابط اجتماعی پرداختند و سپس این مطالعات را روی گروه‌هایی از حیوانات و انسان‌ها انجام دادند و در نهایت این الگوریتم از ماهیت رفتار پرندگان و ماهی‌ها الهام گرفت. این الگوریتم نیز همانند سایر الگوریتم‌های بهینه‌ساز، از رفتار گروهی پرندگان و ماهی‌ها الهام گرفته است که مناسب‌ترین مسیر را برای رسیدن به لانه یا غذا، بدون ایجاد مانع در حرکت یکدیگر، پیدا می‌کنند. مراحل این الگوریتم در این پژوهش به‌گونه‌ای است که ابتدا جمعیت اولیه تولید شده و بردارهای سرعت ذره در ابتدا صفر و بردار مکان بصورت تصادفی انتخاب می‌شود. در مرحله بعد ارزیابی ارزش ذره صورت گرفته و سپس بهترین موقعیت فردی و سرعت ذره بروز می‌شود (Shrivatava et al., 2015).

ترکیب شبکه عصبی مصنوعی با الگوریتم بهینه‌ساز

در توسعه مدل‌های هیبریدی PSO-ANN و CSO-ANN، الگوریتم‌های PSO و CSO نقش یک بهینه‌ساز جهانی را ایفا کردند. این الگوریتم‌ها برای بهینه‌سازی هم‌زمان و تکرار شونده کلیه وزن‌ها (Weights) و بایاس‌های (Biases) لایه‌های شبکه عصبی مصنوعی، در طول فرآیند آموزش به کار گرفته شدند. به‌عبارت‌دیگر، به‌جای استفاده از روش‌های مرسوم مانند گرادیان کاهشی تصادفی (SGD) یا مشتقات آن، از PSO و CSO برای جستجوی فضای پارامتری وسیع و یافتن بهترین مجموعه از وزن‌ها و بایاس‌ها استفاده شد که کمترین مقدار تابع هزینه Loss (Function) را روی مجموعه داده آموزش به همراه داشته باشد. هر "ذره" در PSO یا هر "مرغ" در CSO، یک پیکربندی کامل از وزن‌ها و بایاس‌های شبکه عصبی را نمایش می‌دهد و معیار برازش (Fitness) آن بر اساس عملکرد شبکه تعریف شده است.

نتایج و بحث

جدول ۱- شاخص آماری ارزیابی مدل LARS-WG 8

پارامتر	R ²	RMSE	NRMSE	MAE
بارش	۰/۹۵۰	۵/۱۶	۱۱/۳۶	۰/۲۳
کمینه دما	۰/۹۷	۰/۲۱	۲/۳۱	۰/۰۴
بیشینه دما	۰/۹۷	۰/۲۷	۰/۹۵	۰/۰۵

جدول ۲ عملکرد سناریوهای گزارش ششم در پیش‌نگری میزان نوسانات دوره‌های آبی نسبت به دوره پایه را در قالب مقادیر پیش‌بینی‌شده بارش، حداکثر دما (Tmax) و حداقل دما (Tmin) برای هرماه، با استفاده از دو مدل گردش عمومی جو-اقیانوس (MPI-ESM1-2-LR AOGCM و BCC-CSM2-MR) تحت دو سناریوی مسیرهای اجتماعی-اقتصادی مشترک (SSP) (SSP5-8.5 (انتشار بالا) و SSP1-2.6 (انتشار پایین) نشان می‌دهد. این اطلاعات پایه محکمی را برای ارزیابی تأثیرات تغییرات اقلیمی و تدوین راهبردهای سازگاری در منطقه مورد مطالعه، فراهم می‌آورد.

همان‌طور که از نتایج جدول ۲ مشهود است، تفاوت‌های قابل توجهی در برآورد متغیرهای اقلیمی بین مدل‌ها وجود دارد که بازتاب‌دهنده عدم قطعیت ذاتی مدل‌سازی اقلیمی است. به‌ویژه، مدل BCC-CSM2-MR در مقایسه با مدل MPI-ESM1-2-LR، مقادیر بارش به‌مراتب بالاتری را برای ماه‌های ژوئن تا اکتبر (دوره گرم و خشک منطقه) پیش‌بینی می‌کند.

تفسیر عدم قطعیت در پیش‌بینی بارش (تمرکز بر BCC-CSM2-MR):

این تفاوت چشمگیر (بایاس مثبت بزرگ در تابستان/پاییز) در مدل BCC-CSM2-MR احتمالاً ناشی از تفاوت در پارامتر سازی فرآیندهای فیزیکی مرتبط با جابه‌جایی رطوبت و همرفت در این مدل خاص است. مدل‌های مختلف AOGCM دارای پارامتر سازی‌های متفاوتی برای پارامترهای زیر مقیاس (مانند مکانیسم‌های تولید ابر و بارش) هستند؛ مدل BCC-CSM2-MR ممکن است در بازتولید الگوی فصلی بارندگی در این منطقه، به‌ویژه در تابستان، گرایش به برآورد بیش‌ازحد (Overestimation) داشته باشد. در مقابل، مدل MPI-

ارزیابی مدل LARS-WG با استفاده از اطلاعات دوره پایه آنالیز آماری شبیه‌سازی مدل برای پارامترهای بارندگی و دما در دوره تاریخی در جدول ۱ نشان داده شده است. نتایج نشان می‌دهد مقدار ضریب تبیین در کلیه پارامترهای مورد بررسی بیشتر از ۰/۹۴۰ محاسبه گردید و میانگین خطای مطلق (MAE) برای شبیه‌سازی بارش، دمای حداقل، دمای حداکثر به ترتیب ۰/۲۴، ۰/۰۴، ۰/۰۵ به دست آمد که نشان می‌دهد خطای شبیه‌سازی بارش بیشتر از بقیه پارامترهاست. شاخص‌های RMSE و NRMSE نیز در شبیه‌سازی بارش نسبت به دیگر پارامترها به‌مراتب بیشتر بوده (به ترتیب ۵/۱۶ و ۱۱/۳۶) و خطای بیشتری را نشان می‌دهد. بنابراین توانایی مدل LARS-WG8 در شبیه‌سازی پارامترهای هواشناسی تأییدشده ولی با این حال مدل در شبیه‌سازی بارش دقت کمتری را نشان می‌دهد که با یافته‌های Hosseini et al. (2015) مطابقت دارد.

در این پژوهش، برای پیش‌نگری پارامترهای هواشناسی مانند بارش و دما در بازه زمانی ۲۰۲۳ تا ۲۰۴۳، از خروجی مدل گردش عمومی CMIP6 استفاده شد. این پیش‌نگری‌ها با در نظر گرفتن دو سناریوی اقلیمی SSP1-2.6 (سناریوی خوش‌بینانه) و SSP5-8.5 (سناریوی بدبینانه) انجام شد. در این میان، مدل اقلیمی CanESM5 به دلیل سازگاری بالا با منطقه مورد مطالعه، به‌عنوان مدل اصلی انتخاب گردید.

برای فرآیند ریزاقلیم‌سازی (downscaling)، از نرم‌افزار LARS-WG نسخه ۸ بهره گرفته شد. لازم به ذکر است که LARS-WG یک مدل ریزمقیاس کننده تصادفی (stochastic downscaling model) است. این بدان معناست که مقادیر پیش‌نگری شده برای یک دوره مشخص (مانند بازه ۲۰۲۳-۲۰۴۳) به‌صورت تصادفی در طول سال‌های این دوره توزیع می‌شوند و فاقد توالی زمانی تقویمی پیوسته هستند. به‌عبارت‌دیگر، LARS-WG به‌جای حفظ ترتیب زمانی دقیق، الگوهای آماری (مانند میانگین، واریانس و...) را از داده‌های اقلیمی با مقیاس بزرگ‌تر به مقیاس مکانی کوچک‌تر منتقل می‌کند.

تحلیل روند دما شکل ۳

نمودارهای Tmin و Tmax به‌وضوح یک‌روند گرمایش عمومی و پایدار در شهرستان پلدختر در دهه‌های آینده را تحت هر دو سناریو تأیید می‌کنند. دماهای پیش‌بینی‌شده در هر دو سناریو SSP5-8.5 و SSP1-2.6، به‌طور قابل‌ملاحظه‌ای بالاتر از مقادیر مشاهده‌شده در تمام طول سال قرار می‌گیرند. اختلاف دمایی بین سناریوی انتشار بالا و پایین، به‌ویژه در ماه‌های گرم سال (می تا اکتبر)، به حدود ۲ تا ۴ درجه سانتی‌گراد می‌رسد. این تفاوت قابل‌توجه، حساسیت بالای منطقه به میزان انتشار گازهای گلخانه‌ای را به‌وضوح نشان می‌دهد و تأکید می‌کند که انتخاب مسیرهای آتی انتشار، تأثیر مستقیمی بر شدت پدیده‌های گرمایش محلی خواهد داشت.

تحلیل یکپارچه این یافته‌ها، شهرستان پلدختر را در آینده با چالش‌های اقلیمی مهمی مواجه می‌سازد که عمدتاً شامل افزایش پایدار دما و تغییرات در الگوی بارش فصلی است. تفاوت در نتایج مدل‌های مختلف، به‌ویژه تفاوت در پیش‌بینی بارش تابستانی بین BCC-CSM2-MR و MPI-ESM1-2-LR، بر لزوم استفاده از روش‌های پس‌پردازش و مدل‌سازی ثانویه (مانند مدل‌های WANN/PSO-ANN که در بخش قبل تشریح شدند) برای کاهش عدم قطعیت و تصحیح باپاس‌های سیستماتیک مدل‌های GCM و تولید پیش‌بینی‌های محلی قابل‌اتکاتر، تأکید می‌نماید. این یافته‌ها ضرورت برنامه‌ریزی برای سازگاری با تغییر اقلیم و مدیریت پایدار منابع آب را بیش‌ازپیش آشکار می‌سازد.

ESM1-2-LR، که گرایش کمتری به نوسانات شدید در بارش تابستان نشان می‌دهد، ممکن است شبیه‌سازی دقیق‌تری از شرایط خشک منطقه ارائه دهد. این تفاوت‌ها بر ضرورت استفاده از خروجی چندین مدل و در نظرگیری دامنه‌ای از سناریوها برای دستیابی به ارزیابی‌های جامع و تعیین دامنه‌های محتمل خطا تأکید می‌کند.



شکل ۳، روند نوسانات ماهانه پارامترهای هواشناسی ایستگاه سینوپتیک پلدختر در دوره زمانی آینده را نسبت به دوره پایه نمایش می‌دهد. نمودارهای ارائه شده از مدل‌های CMIP6، پیش‌نگری‌های مربوط به تغییرات بارش و دما را تحت سناریوهای SSP5-8.5 و SSP1-2.6 به نمایش می‌گذارند.

تحلیل روند بارش شکل ۳

هر دو مدل، الگوی فصلی بارش با حداکثر در زمستان/اوایل بهار و حداقل در تابستان را حفظ می‌کنند. با این حال، تفاوت در مقادیر مطلق بارش، به‌ویژه در تابستان، همچنان برجسته است. علی‌رغم انتظار کاهش کلی بارش در سناریوی انتشار بالا (-SSP5-8.5)، مدل BCC-CSM2-MR پایداری یا حتی افزایش جزئی را در برخی از ماه‌های تابستان/پاییز نشان می‌دهد که این امر می‌تواند به تشدید خشکسالی فصلی یا افزایش نوسانات رطوبتی در آن دوره‌ها منجر شود. این نشان می‌دهد که تأثیر سناریوهای انتشار بر نوسانات محلی، به‌شدت وابسته به ویژگی‌های خاص هر مدل اقلیمی است.

جدول ۲- مقادیر سناریوهای گزارش ششم در پیش‌نگری‌های میزان نوسانات دوره آتی نسبت به دوره پایه

مشاهداتی	MPI-ESM1-2-LR model						BCC-CSM2-MR model								
	بارش	دمای ماکزیمم		بارش		دمای ماکزیمم		بارش		دمای ماکزیمم					
		SSP5-8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6				
ماه	بارش	دمای ماکزیمم	دمای مینیمم	SSP5-8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6		
Jan	۳۰/۶۷	۱۲/۱۱	۲/۱۱	۲۱/۲۳	۳۲/۰۴	۱۵/۰۱	۱۴/۹۷	۴/۷۸	۴/۵	۲۴/۴۳	۴۲/۵	۱۱/۱۷	۱۲/۱۷	۳/۸۸	۳/۸۹
Feb	۲۵/۰۹	۱۳/۷	۳/۷	۲۶/۴۱	۳۵/۷	۱۵/۷۸	۱۴/۶۱	۷/۰۱	۶/۳	۲۲/۷	۴۸/۹۲	۱۶/۳۷	۱۵/۹	۶/۶۹	۶/۷۶
Mar	۴۸/۲۸	۱۹/۵۵	۷/۱۳	۵۵/۱	۵۷/۹۶	۱۹/۶۱	۱۹/۴۵	۱۱/۴۹	۱۱/۹۵	۳۱/۳۱	۴۶/۳۶	۲۰/۳۱	۱۹/۲۹	۱۳/۵	۱۳/۱۴
Apr	۳۲/۵۷	۲۵/۴۶	۱۲/۱	۶۸/۶۵	۶۵/۸	۲۵/۵	۲۵/۷۸	۱۷/۵۸	۱۷/۳۷	۱۴/۸	۲۵/۹۵	۲۷/۳۶	۲۶/۶۵	۲۰/۲۱	۱۹/۹۱
May	۷/۵۸	۳۱/۵۸	۱۷/۴۷	۷۷/۰۵	۶۹/۷۶	۳۲/۱۵	۳۱/۵۳	۲۳/۵۳	۲۳/۴۹	۶/۷۲	۷/۱۸	۳۵/۸۱	۳۴/۲۴	۲۴/۹۸	۲۴/۹۳
Jun	۶/۴۷	۳۶/۴۷	۲۲/۲	۲۹/۳۸	۲۵/۵۸	۳۹/۴۹	۳۹/۱۱	۲۹/۸۲	۲۹/۸	۰/۵۶	۱/۲۴	۴۵/۷۴	۴۴/۴۹	۲۸/۰۵	۲۷/۵۳
Jul	۲/۱۷	۳۹/۶۷	۲۵/۴۲	۳/۴۱	۱/۹۴	۴۴/۶۴	۴۴/۶۹	۳۳/۵۵	۳۳/۵۵	۰/۱۶	۰/۲۴	۴۸/۵۶	۴۷/۸۷	۳۱/۶۴	۳۰/۹۸
Aug	۳/۷۸	۳۹/۸۳	۲۴/۹۳	۳/۵۸	۲/۶۹	۴۶/۵۲	۴۵/۸۱	۳۳/۲۵	۳۲/۸۳	۰/۸	۰/۳۲	۴۹/۶۳	۴۷/۲۶	۳۱/۹۸	۳۱/۴۳
Sep	۲/۷۷	۳۵/۹۳	۱۹/۹۴	۱۴/۰۹	۱۱/۴۲	۳۳/۴۱	۴۲/۹۷	۲۸/۰۱	۲۷/۴۶	۲/۷۶	۴/۰۶	۴۱/۸۷	۴۱/۱۸	۲۷/۵۸	۲۶/۹۹
Oct	۱۲/۱	۲۸/۵۴	۱۵/۱۴	۳۳/۱۲	۲۲/۲۴	۳۶/۴۲	۳۶/۱۳	۲۱/۵۵	۲۱/۰۸	۲۲/۷۷	۲۲/۷	۳۱/۲۵	۳۱/۶۷	۱۹/۸۳	۱۹/۳۹
Nov	۳۸/۲۹	۲۰/۳۷	۸/۳۷	۳۹/۳۵	۳۷/۳	۲۷/۵۸	۲۷/۲۱	۱۳/۹	۱۳/۲۴	۲۷/۴۷	۳/۸۸	۲۰/۸۹	۲۰/۶۱	۱۱/۵۵	۱۱/۲۲
Dec	۲۴/۱۷	۱۵/۳۳	۴/۳۳	۲۸/۱۵	۳۹/۹۲	۱۹/۱۴	۱۸/۷۷	۶/۴۸	۷/۱۵	۲۶/۹	۴۳/۰۴	۱۳/۹۵	۱۲/۷۸	۷/۲۵	۶/۸۸



شکل ۳- مقایسه روند نوسانات ماهانه پارامترهای هواشناسی ایستگاه سینوپتیک پلدختر در دوره زمانی آینده نسبت به دوره پایه

در شکل ۴ نمودار سری زمانی مقادیر مشاهداتی و محاسباتی نشان داده شده است. همان‌طور که مشاهده می‌گردد مدل شبکه عصبی مصنوعی-موجک نسبت به مدل‌های هیبریدی رگرسیون بردار پشتیبان- ازدحام مرغ و ازدحام ذرات در تخمین اکثر نقاط از جمله مینیمم، ماکزیمم و میانی دقت قابل قبولی از خود نشان داده است. همچنین مدل شبکه عصبی مصنوعی- ازدحام مرغ در تخمین اکثر مقادیر عملکرد نسبتاً مناسبی ارائه داده است. مدل شبکه عصبی مصنوعی- ازدحام ذرات نیز در تخمین مقادیر میانی عملکرد نسبتاً مطلوبی داشته و در تخمین مقادیر مینیمم و ماکزیمم ضعیف عمل نموده است. در نمودارهای سری زمانی (شکل ۴)، هم‌پوشانی داده‌های محاسباتی و مشاهداتی نشان می‌دهد که مدل‌های مختلف در بازتولید الگوی تغییرات زمانی داده‌ها عملکرد متفاوتی دارند. مدل WANN تطابق بهتری در بازه‌های اوج جریان دارد و خطاهای نسبی آن در مقادیر پیک کمتر از سایر مدل‌ها است. در مقابل، مدل‌های PSO-ANN و CSO-ANN در مقادیر پایین‌تر داده‌ها دقت مناسبی نشان می‌دهند، اما در بازسازی نوسانات تند دچار افت دقت می‌شوند. وجود هم‌پوشانی نسبی بین منحنی‌های محاسباتی و مشاهداتی در اکثر بازه‌ها نشان‌دهنده توان کلی شبکه‌های ترکیبی در یادگیری روندهای غیرخطی داده‌ها است، با این حال اختلافات موضعی در قله‌های زمانی بیانگر حساسیت مدل‌ها به نوسانات کوتاه‌مدت و تغییرات ناگهانی داده‌های ورودی است. بررسی میزان تفاضل بین داده‌های مشاهداتی و محاسباتی نشان می‌دهد که خطای مدل‌ها بیشتر در دوره‌هایی با تغییرات شدید داده رخ می‌دهد. مدل WANN کمترین میزان پراکندگی خطا را داشته و خطاهای آن عمدتاً حول محور صفر متمرکز هستند که بیانگر دقت بالا و پایداری در بازسازی الگوهای واقعی است. در مقابل، مدل CSO-ANN در برخی بازه‌ها دچار بیش برآوردی و مدل PSO-ANN در برخی نقاط دچار کم‌برآوردی می‌شود. این الگو حاکی از آن است که الگوریتم به‌کاررفته در یادگیری وزن‌ها در مدل WANN موجب همگرایی سریع‌تر و کاهش نوسانات خطا شده است.

در شکل ۵، نمودار جعبه‌ای مدل‌های موردبررسی نشان داده شده است. مدل‌های مقایسه شده شامل داده‌های

در سال‌های اخیر به دلیل آنکه در مدل شبکه عصبی مصنوعی مقادیر وزن‌ها و بایاس بصورت تصادفی انتخاب می‌گردند از الگوریتم‌های بهینه‌سازی برای افزایش دقت و کاهش خطای مدل استفاده شده است (Zeidalinejad and Dehghani., 2023). در این پژوهش نیز برای افزایش عملکرد مدل از الگوریتم‌های موجک، ازدحام مرغ و ازدحام ذرات به منظور بهینه نمودن مقادیر وزن‌ها و بایاس استفاده شد.

نتایج حاصل از ارزیابی مدل‌ها در ساختار شماره ۳ در جدول ۳ نشان داده شده است. طبق ارزیابی‌های انجام‌شده، ساختار ترکیبی شماره ۳ نسبت به ساختارهای منفرد از خطای کمتری برخوردار بود. در جدول ۴ مقادیر پارامترهای تنظیم الگوریتم‌های ازدحام مرغ و ذرات نشان داده شده است. پارامترهای الگوریتم‌های بهینه‌سازی مورد استفاده در این تحقیق، باهدف عادلانه بودن مقایسه و امکان بازتولید کامل آزمایش‌ها، بر اساس مقادیر پرکاربرد در متون علمی انتخاب شدند. اندازه جمعیت اولیه برای تمامی الگوریتم‌ها ۵۰ ذره و معیار توقف، ۱۰۰ تکرار در نظر گرفته شد. ارزیابی عملکرد الگوریتم‌های بهینه‌سازی بر اساس معیارهای زمان محاسباتی و دقت صورت گرفت. داده‌های جدول ۵ نشان می‌دهد الگوریتم CSO-ANN با میانگین خطای ۰/۰۰۱۲ و انحراف معیار ۰/۰۰۰۱، پایدارترین عملکرد را در بین الگوریتم‌های مقایسه شده دارا می‌باشد. از نظر زمان محاسباتی، این الگوریتم با ۲۴/۷ ثانیه نسبت به سایر روش‌ها زمان بیشتری نیاز دارد که این مسئله به پیچیدگی محاسباتی و ساختار سلسله‌مراتبی آن مربوط می‌شود. الگوریتم PSO-ANN با زمان ۲۰/۳ ثانیه و میانگین خطای ۰/۰۰۲۸ در جایگاه دوم قرار گرفت. الگوریتم استاندارد پس انتشار باوجود سرعت اجرای بالاتر (۸/۵ ثانیه)، از نظر دقت با میانگین خطای ۰/۰۰۵۸ عملکرد ضعیف‌تری نشان داد.

در جدول ۶، نتایج ارزیابی مدل‌ها نشان داده شده است. همان‌گونه که مشاهده می‌شود مدل هیبریدی شبکه عصبی مصنوعی-موجک در مرحله صحت‌سنجی با ضریب همبستگی ۰/۹۶۵، کمترین ریشه میانگین مربعات ۰/۰۶۷، کمترین میانگین قدر مطلق خطا ۰/۰۳۴ و بیشترین ضریب نش ساتکلیف ۰/۹۷۰ عملکرد بهتری از خود نشان داده است.

مدل‌های مبتنی بر الگوریتم‌های بهینه‌سازی (CSO و PSO) بهبودهایی نسبت به WANN پایه ایجاد کرده‌اند اما WANN در تعادل بین انحراف معیار و همبستگی به نقطه بهینه نزدیک‌تر است. نتایج این پژوهش در همسویی با مطالعات پیشین، به‌ویژه تحقیق (Shadkani et al. 2025) در زمینه پیش‌بینی رسوب رودخانه با استفاده از مدل ترکیبی Wavelet-ANN (WANN)، پتانسیل بالای این ساختار ترکیبی برای مدل‌سازی پدیده‌های پیچیده هیدرولوژیکی را تأیید می‌کند. با این حال، تفاوت کلیدی مدل پیشنهادی در این تحقیق با مطالعه مرجع، در مرحله بهینه‌سازی و پیش‌پردازش داده‌ها متمرکز است. درحالی‌که پژوهش ذکر شده عمدتاً بر مزیت تجزیه موجک برای استخراج ویژگی‌های زمانی تکیه دارد، تحقیق حاضر از یک رویکرد دوگانه بهره می‌برد: استفاده از تبدیل موجک برای تجزیه سیگنال و به‌کارگیری هم‌زمان الگوریتم‌های بهینه‌سازی ازدحام ذرات (PSO) و ازدحام مرغ (CSO) برای تنظیم دقیق پارامترهای شبکه. این لایه بهینه‌سازی اضافی، نه تنها کارایی استخراج ویژگی را افزایش می‌دهد، بلکه به مدل اجازه می‌دهد نوسانات بارش پیش‌بینی شده توسط مدل‌های اقلیمی (مانند CanESM5.0) را به شکلی کارآمدتر در ساختار شبکه جای دهد. در نتیجه، این ترکیب ساختاری (Wavelet + PSO/CSO) باعث شده است که مدل پیشنهادی ما، به‌ویژه در سناریوهای اقلیمی با عدم قطعیت بالا نظیر SSP5-8.5، پایداری عملکردی ملموسی نسبت به مدل‌های Wavelet-ANN استاندارد که فاقد لایه بهینه‌سازی قوی هستند، از خود نشان دهد و این امر، برتری روش‌شناختی تحقیق حاضر را در انجام پیش‌بینی‌های بلندمدت اقلیمی توجیه می‌نماید.

جدول ۳- ترکیب پارامترهای ورودی به مدل

شماره	ورودی	خروجی
۱	T(t)	SS(t)
۲	T(t), P(t)	SS(t)
۳	T(t), P(t), Q(t)	SS(t)

مشاهداتی به‌عنوان مرجع، و سه مدل هیبریدی بر مبنای شبکه عصبی مصنوعی هستند که با الگوریتم‌های بهینه‌سازی مختلف شامل بهینه‌سازی ازدحام ذرات، یک الگوریتم ازدحام مرغ و موجک ترکیب شده‌اند. مدل شبکه عصبی مصنوعی-موجک به‌طور واضحی بهترین عملکرد را در بین مدل‌های مقایسه شده نشان می‌دهد. این مدل دارای پایین‌ترین مقدار میانه، کوچک‌ترین محدوده بین چارکی (عرض جعبه) و کمترین پراکندگی داده‌ها (فاصله بین خطوط حداقل و حداکثر) است. این ویژگی‌ها نشان‌دهنده دقت بالا و پایداری قابل‌توجه این مدل در پیش‌بینی است. در مقابل، مدل شبکه عصبی مصنوعی-ازدحام ذرات دارای بالاترین میانه و بیشترین پراکندگی است که نشان از خطای سیستماتیک و ناپایداری دارد. مدل شبکه عصبی مصنوعی-ازدحام مرغ نیز از نظر میانه و پراکندگی در موقعیت بهتری نسبت به مدل شبکه عصبی مصنوعی-ازدحام ذرات قرار دارد. نمودار جعبه‌ای نتایج یافته‌ها را تأیید می‌کند. توزیع داده‌ها در تمامی مدل‌ها شباهت نزدیکی به داده‌های مشاهده‌ای دارد که بیانگر حفظ ساختار آماری سری‌ها است. با این حال، میانه و گستره بین چارکی (IQR) مدل WANN بیشترین نزدیکی را به داده‌های واقعی نشان می‌دهد، که دال بر دقت بالاتر در بازسازی مقادیر مرکزی و نوسانات معمول داده‌ها است. در مقایسه، مدل‌های PSO-ANN و CSO-ANN دارای دامنه پراکندگی وسیع‌تری هستند و حضور داده‌های پرت در آن‌ها بیشتر مشهود است. این امر نشان‌دهنده پایداری کمتر این دو مدل نسبت به WANN در تعمیم‌پذیری داده‌های خارج از محدوده آموزش می‌باشد. در شکل ۶ نمودار تیلور مدل‌های مورد بررسی نشان داده شده است. نمودار تیلور نشان می‌دهد که مدل WANN بهترین عملکرد را در بین سه روش (WANN، CSO-ANN، PSO-ANN) در مقایسه با داده‌های مشاهده‌شده (Observer) دارد، زیرا نزدیک‌ترین نقطه به مرجع Observer قرار گرفته است که این نزدیکی نشان‌دهنده کمترین RMSE کلی است؛ همچنین، WANN بالاترین همبستگی را با داده‌های واقعی دارد و انحراف معیار آن (محور شعاعی عمودی) به مقدار انحراف معیار داده‌های مشاهده‌شده نزدیک‌تر است، درحالی‌که مدل PSO-ANN کمترین انحراف معیار را ثبت کرده اما فاصله بیشتری از لحاظ همبستگی و RMSE با مرجع دارد که نشان می‌دهد

جدول ۴- جدول تنظیمات پارامترهای الگوریتم‌های بهینه‌سازی

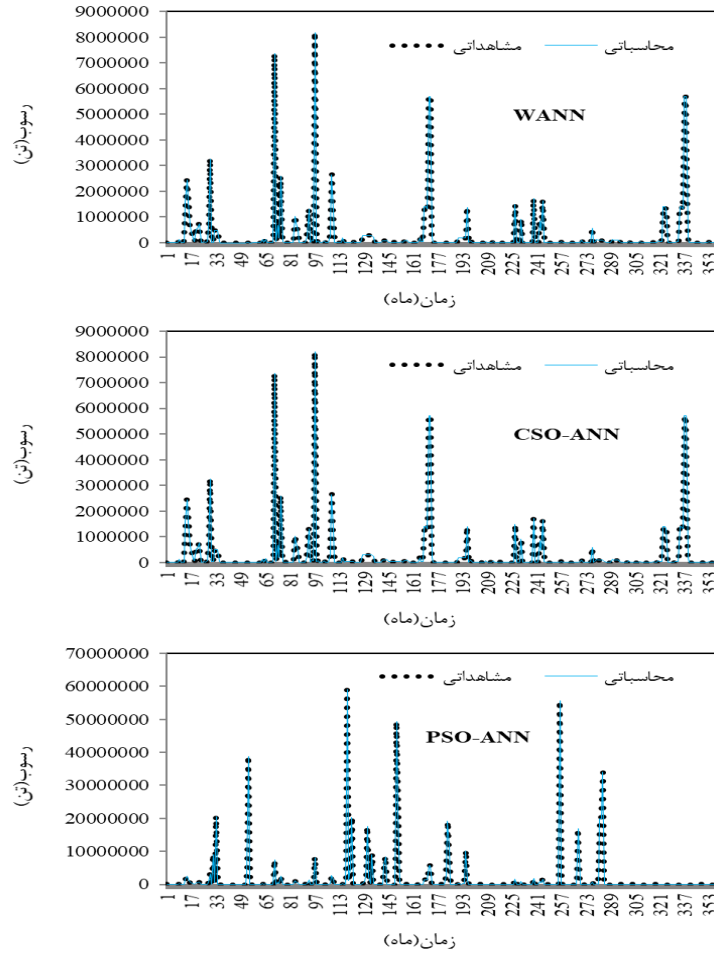
گروه پارامتر	پارامتر	الگوریتم PSO	الگوریتم CSO
پارامترهای عمومی	اندازه جمعیت	۵۰	۵۰
	تعداد تکرارها	۱۰۰	۱۰۰
	بعد مسئله	۳۰	۳۰
پارامترهای خاص الگوریتم	ضریب اینرسی (W)	۰/۷۲۹۸	-
	شتاب شناختی (c1)	۱/۴۹۶۲	-
	شتاب اجتماعی (C2)	۱/۴۹۶۲	-
	احتمال زوج شدن (p)	-	۰/۵
	فاکتور یادگیری (φ)	-	۰/۵
محدوده متغیرها	محدوده جستجو	[-۱۰۰ و ۱۰۰]	[-۱۰۰ و ۱۰۰]

جدول ۵- مقایسه عملکرد الگوریتم‌های بهینه‌سازی

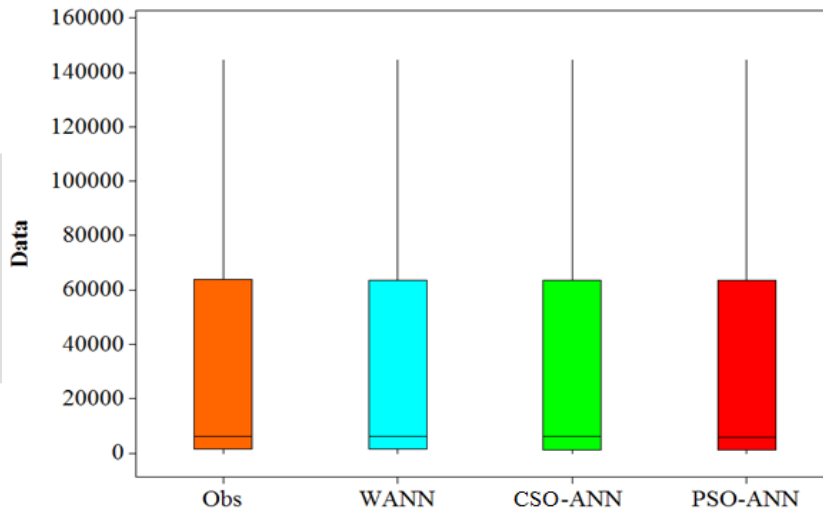
شاخص ارزیابی	الگوریتم استاندارد پس انتشار	الگوریتم PSO-ANN	الگوریتم CSO-ANN
میانگین زمان اجرا (ثانیه)	۸,۵	۲۰/۳	۲۴/۷
انحراف معیار زمان	۰/۴	۱/۱	۱/۳
بهترین MSE	۰/۰۰۴۵	۰/۰۰۲۱	۰/۰۰۰۹۵
میانگین MSE	۰/۰۰۵۸	۰/۰۰۲۸	۰/۰۰۱۲
انحراف معیار MSE	۰/۰۰۰۳	۰/۰۰۰۲	۰/۰۰۰۱

جدول ۶- نتایج مدل‌های مورد بررسی

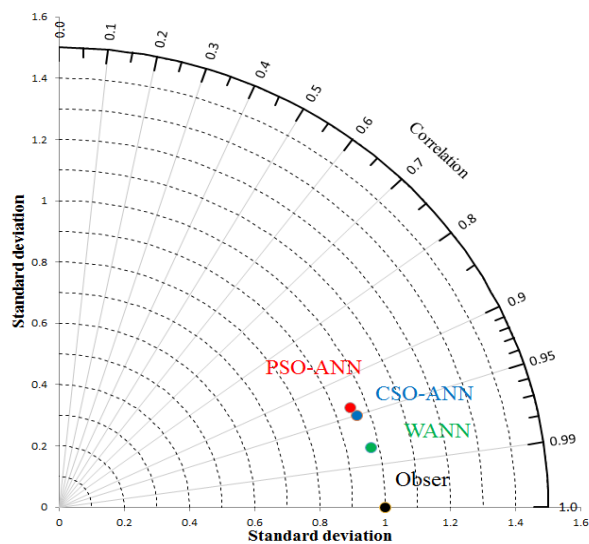
مدل	ساختار	آموزش					آزمون				
		NS	PSR	PBIAS	RMSE (ton)	R ²	NS	PSR	PBIAS	RMSE (ton)	R ²
WANN	۱	۰/۹۱۰	۰/۳۲۲	۰/۰۰۴	۰/۲۲۲	۰/۹۲۰	۰/۲۲۲	۰/۰۰۳	۰/۲۳۱	۰/۹۳۰	
	۲	۰/۹۳۰	۰/۲۹۷	۰/۰۰۳	۰/۴۴۱	۰/۹۴۰	۰/۴۴۱	۰/۰۰۲	۰/۲۱۱	۰/۹۵۰	
	۳	۰/۹۶۵	۰/۲۵۲	۰/۰۰۲	۰/۸۸۷	۰/۹۷۰	۰/۸۸۷	۰/۰۰۱	۰/۱۷۶	۰/۹۸۰	
CSO-ANN	۱	۰/۹۰۱	۰/۳۴۶	۰/۰۰۵	۰/۱۱۰	۰/۹۱۰	۰/۱۱۰	۰/۰۰۴	۰/۲۴۴	۰/۹۱۵	
	۲	۰/۹۱۵	۰/۳۰۴	۰/۰۰۴	۰/۲۲۱	۰/۹۲۰	۰/۲۲۱	۰/۰۰۳	۰/۲۲۷	۰/۹۲۵	
	۳	۰/۹۴۲	۰/۲۷۳	۰/۰۰۳	۰/۵۰۰	۰/۹۴۵	۰/۵۰۰	۰/۰۰۲	۰/۱۹۶	۰/۹۵۰	
PSO-ANN	۱	۰/۸۹۳	۰/۳۵۶	۰/۰۰۶	۰/۰۸۷	۰/۹۰۰	۰/۰۸۷	۰/۰۰۴	۰/۲۵۴	۰/۹۱۰	
	۲	۰/۹۰۴	۰/۳۱۵	۰/۰۰۴	۰/۱۱۷	۰/۹۱۰	۰/۱۱۷	۰/۰۰۳	۰/۲۳۷	۰/۹۱۸	
	۳	۰/۹۲۷	۰/۲۸۸	۰/۰۰۳	۰/۴۱۲	۰/۹۳۵	۰/۴۱۲	۰/۰۰۲	۰/۲۰۸	۰/۹۴۰	



شکل ۴- نمودار مقادیر مشاهداتی و محاسباتی مدل‌های مورد بررسی



شکل ۵- نمودار جعبه‌ای مدل‌های مورد بررسی



شکل ۶- نمودار تیلور مدل‌های مورد بررسی

بر این الگوی تاریخی، این روند صعودی را برای دوره آتی (۲۰۲۲ تا ۲۰۴۲) ادامه می‌دهد. این پیوستگی نشان می‌دهد که مدل پیش‌بینی مورد استفاده (ترکیب ANN-WAVELET) روند بلندمدت تشدید پدیده را به درستی تشخیص داده است. طبق تحلیل اختلاف میانگین درازمدت ۳۰ ساله دوره تاریخی و میانگین درازمدت ۳۰ ساله دوره پیش‌بینی شده، میزان رسوبات رودخانه کشکان حدود ۲۳ درصد افزایش می‌یابد. این افزایش بر اساس فرمول زیر محاسبه گردیده است:

$$SS\% = \frac{\overline{SS}_{t+1} - \overline{SS}_{t-1}}{\overline{SS}_{t-1}} \times 100 \quad (19)$$

در رابطه بالا، SS_{t+1} میانگین درازمدت رسوب در ۳۰ سال تاریخی، SS_{t-1} میانگین درازمدت رسوب در ۳۰ سال آینده می‌باشد. افزایش ۲۳ درصدی رسوبات، در نگاه اول ممکن است با کاهش کلی دبی آب ناشی از خشکسالی‌های ممتد در تعارض باشد؛ اما در حقیقت، این پدیده تشدید چرخه معیوب خشکسالی و تخریب محیطی را نشان می‌دهد. کاهش تدریجی بارش‌های مؤثر و تخلیه ذخایر رطوبتی منجر به کاهش قدرت انتقال رودخانه می‌گردد. کاهش ظرفیت حمل آب، منجر به ته‌نشینی مواد جامد معلق شده و در نتیجه، افزایش حجم رسوبات انباشته‌شده می‌شود. از سوی دیگر، کاهش پوشش گیاهی حوضه آبریز در اثر کم‌بارشی، فرسایش‌پذیری خاک را افزایش داده و بر حجم رسوبات ورودی به رودخانه می‌افزاید.

بررسی تغییرات پارامترهای اقلیمی نظیر دما و بارش، که به‌عنوان ورودی برای مدل‌سازی هیدرولوژیکی استفاده شده، گام اول در تحلیل تحولات ساختاری منطقه است. نتایج (جدول ۲) حاکی از روند گرمایش عمومی تحت هر دو سناریوی SSP1-2.6 و SSP5-8.5 است؛ به‌طوری‌که تفاوت دمای حداکثر و حداقل در ماه‌های گرم (می تا اکتبر) بین این دو سناریو به ۲ تا ۴ درجه سانتی‌گراد می‌رسد. این افزایش دما، به‌طور مستقیم بر افزایش تبخیر و تعرق بالقوه تأثیر می‌گذارد.

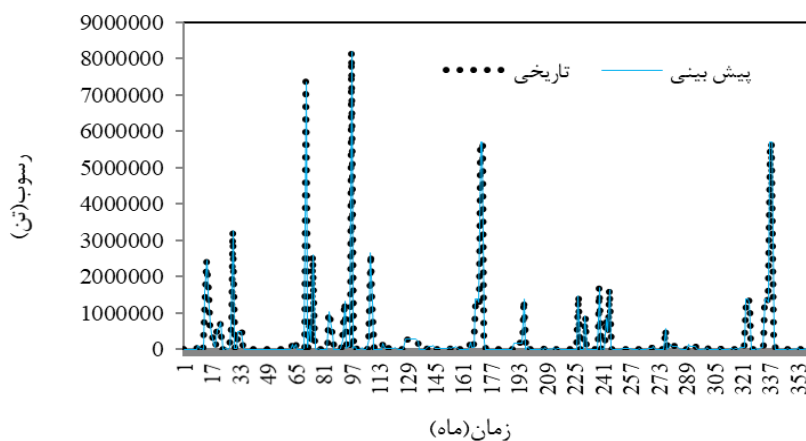
در خصوص بارش، مدل‌های اقلیمی (AOGCMs) ناهمگونی قابل‌توجهی را نشان دادند. به‌ویژه، مدل BCC-CSM2-MR بارش فصل‌های گرم (ژوئن تا اکتبر) را به‌طور قابل‌ملاحظه‌ای بیشتر از مدل MPI-ESM1-2-LR پیش‌بینی می‌کند. این اختلاف، به تفاوت در پارامترسازی فرآیندهای فیزیکی (مانند جابجایی رطوبت و همرفت) در مدل‌ها باز می‌گردد و عدم قطعیت ذاتی را در پیش‌بینی میزان بارش‌های منطقه‌ای تقویت می‌کند.

تحلیل تغییرات رسوبات رودخانه کشکان (شکل ۷) نشان‌دهنده یک تحول ساختاری اساسی در سامانه هیدرولوژیکی منطقه است که در آن اثرات خشکسالی و رسوب‌گذاری به‌طور هم‌زمان تشدید می‌شوند.

همان‌طور که در شکل ۷ مشهود است، منحنی داده‌های تاریخی نشان‌دهنده یک‌روند صعودی قوی و نوسانی در میزان رسوب در سال‌های گذشته بوده است. مدل پیش‌بینی، با تکیه

سدهابه دلیل انباشت رسوب) و تغییر مورفولوژی رودخانه را در پی خواهد داشت. این امر لزوم تدوین راهبردهای فوری برای مدیریت یکپارچه منابع آب، حفاظت از پوشش گیاهی حوضه آبریز و به‌کارگیری تکنیک‌های کاهش بایاس مدل‌های اقلیمی مانند استفاده از PSO-ANN روی خروجی‌های AOGCM را برای اطمینان از پایداری بلندمدت منابع آبی منطقه ایجاب می‌نماید.

این یافته، که افزایش رسوب در کنار تشدید خشکسالی رخ می‌دهد، یک نکته کلیدی در مدیریت حوضه‌های آبریز تحت اقلیم متغیر است. این امر با مشاهدات جهانی سازگار است. به‌عنوان مثال، مطالعاتی مانند Zhang et al. (2024) در حوضه‌هایی با شرایط مشابه، بر نقش غالب تغییر در فرکانس و شدت بارش (به‌جای میانگین بارش کلی) در کنترل نرخ فرسایش و رسوب‌گذاری تأکید دارند. تداوم این روند هشداردهنده، پیامدهای جدی (مانند کاهش ظرفیت مخازن



شکل ۷- نمودار مقایسه مقادیر پیش‌بینی‌شده و تاریخی میزان رسوبات رودخانه

نتایج بررسی خطای عملکرد مدل نشان داد که CanESM5.0 با دقت بالایی قادر به شبیه‌سازی پارامترهای دمای حداکثر و دمای حداقل است، اما در شبیه‌سازی پارامتر بارش نسبت به دو پارامتر دیگر خطای بیشتری را نشان می‌دهد. نتایج تغییرات دمایی نشان داد در دوره مورد بررسی، این شهرستان متأثر از گرمایش جهانی می‌باشد؛ نتایج نشان‌دهنده افزایش دما در دوره ۲۰۲۰ تا ۲۰۵۰ تحت هر دو سناریوی SSP1-2.6 و SSP5-8.5 است.

نتایج حاصل از پیش‌بینی نوسانات بارش و دما نشان داد مدل BCC-CSM2-MR بارش بسیار بالاتری را در ماه‌های ژوئن تا اکتبر پیش‌بینی می‌کند؛ درحالی‌که سناریوی SSP585 به‌طورکلی منجر به دماهای بالاتری نسبت به SSP126 می‌شود. نتایج همچنین نشان‌دهنده افزایش دما در تمامی سناریوهای مورد بررسی، به‌ویژه سناریوی با انتشار بالاتر (SSP5-8.5). علاوه بر این، بین مدل‌ها در پیش‌بینی بارش

نتیجه‌گیری

به‌طورکلی یافته‌های این پژوهش نشان می‌دهد که پدیده تغییر اقلیم به‌عنوان یک عامل تأثیرگذار، الگوی هیدرولوژیکی حوضه آبریز رودخانه کشکان در استان لرستان را دگرگون خواهد کرد. در این پژوهش، از مدل پیش‌بینی‌کننده اقلیمی CanESM5.0 از سری مدل‌های گزارش ششم CMIP6 استفاده شد. این مدل ابتدا برای دوره پایه ۱۹۹۲ تا ۲۰۲۳ واسنجی شد و سپس برای پیش‌بینی وضعیت جوی دوره سی‌ساله آینده نزدیک (۲۰۲۰ تا ۲۰۵۰) تحت دو سناریوی خوش‌بینانه SSP1-2.6 و بدبینانه SSP5-8.5 به کار گرفته شد. سپس با بهره‌گیری از مدل‌های هیبریدی فراکوشی شبکه عصبی مصنوعی-موجک (WANN)، شبکه عصبی مصنوعی-ازدحام مرغ (CSO-ANN) و شبکه عصبی مصنوعی-ازدحام ذرات (PSO-ANN) میزان رسوبات رودخانه کشکان با استفاده از پارامترهای بارش، دما و دبی جریان پیش‌بینی شد.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به‌صورت زیر است:
نویسنده اول: جمع‌آوری و تحلیل اولیه داده‌ها یا انجام مراحل نویسنده دوم: تحلیل داده‌ها، راهنمایی، ویرایش و بازبینی مقاله، کنترل نتایج
نویسنده سوم: ویرایش مقاله، انجام مدل‌سازی

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر عملی رعایت نموده‌اند و این موضوع مورد تأیید همه آن‌ها می‌باشد.

منابع

- Eberhart, R. and Kennedy, J., 1995. A New Optimizer Using Particle Swarm Theory Proc. Sixth International Symposium on Micro Machine and Human Science, Nagoya, Japan, Piscataway. NJ: IEEE Service Center, 15(1), pp.39-43. <https://doi.org/10.1109/MHS.1995.494215>
- Hornik, K., 1998. Multilayer feed-forward networks are universal approximators. *Neural Networks*, 2(5), pp.359-366. [https://doi.org/10.1016/08936080\(89\)90020-8](https://doi.org/10.1016/08936080(89)90020-8)
- Irwin, A.J., Nelles, A.M. and Finkel, Z.V., 2012. Phytoplankton niches estimated from field data. *Limnol Oceanogr*, 57, 787-797. <https://doi.org/10.4319/lo.2012.57.3.0787>
- Jaiswal, R.K., Tiwari, H.L. and Lohani, A. K., 2017. Assessment of climate change impact on rainfall for studying water availability in upper Mahanadi catchment, India. *Journal of Water and Climate Change*, 8 (4), pp.755-770. <https://doi.org/10.2166/wcc.2023.037>
- Kido, R., Inoue, T., Hatono, M. and Yamanoi, K., 2023. Assessing the impact of climate change on sediment discharge using a large ensemble rainfall dataset in Pekerebetsu River basin, Hokkaido. *Prog Earth Planet Science*, 10, pp.54-68. <https://doi.org/10.1186/s40645-023-00580-0>
- Hosseini, R., Takemura, A. and Hosseini, A., 2015. Non-linear time-varying stochastic models for agroclimate risk assessment. *Environmental and Ecological Statistics*, 22(2), pp.227-246. <https://doi.org/10.1007/s10651-014-0295-2>
- Neverman, A., Donovan, M., Smith, H., Gaele Ausseil, A. and Zammit, C., 2023. Climate change impacts on erosion and suspended sediment loads in New Zealand. *Geomorphology*, 427, 108-

تفاوت‌های قابل‌توجهی مشاهده شد. نتایج حاصل از عملکرد مدل‌های هیبریدی نشان داد مدل‌های مورد بررسی در ساختار ترکیبی شامل کلیه پارامترهای ورودی از عملکرد بهتری به دلیل افزایش حافظه برخوردار هستند و مدل شبکه عصبی مصنوعی-موجک (WANN) دقت بیشتر و خطای کمتری نسبت به سایر مدل‌های مورد بررسی دارد.
نتایج حاصل از پیش‌بینی بار رسوبی در سال‌های آتی حاکی از افزایش میانگین ۲۳ درصدی میزان رسوبات رودخانه است. این افزایش کمی، عمدتاً تابعی از برهم‌کنش غیرخطی بین افزایش پیش‌بینی شده در میانگین دما (به‌عنوان عامل اصلی افزایش تبخیر و کاهش دبی پایه) و تغییرات الگوی بارش (افزایش شدت بارش در دوره‌های کوتاه‌تر، حتی اگر میانگین سالانه تغییر چندانی نکند) است که توسط بهترین مدل هیبریدی موجک شبکه عصبی مصنوعی یاد گرفته شده است. به‌طور خاص، تحلیل حساسیت پسینی نشان داد که سهم نسبی تغییرات بارش در افزایش رسوب، در مقایسه با سهم دما، در سناریوی بدبینانه (SSP5-8-5) افزایش می‌یابد، که سازوکار فیزیکی آن را می‌توان به افزایش پتانسیل فرسایش سطحی ناشی از رویدادهای شدید بارش نسبت داد. این یافته‌ها، لزوم توجه جدی به مدیریت جامع حوضه آبریز و اجرای برنامه‌های کنترل فرسایش و رسوب‌زدایی را با تمرکز ویژه بر مدیریت رواناب‌های ناشی از بارش‌های شدید، بیش از پیش نمایان می‌سازد.

تقدیر و تشکر

نویسندگان از همکاری شرکت آب منطقه‌ای لرستان جهت تأمین داده‌های موردنیاز قدرانی می‌شود.

تضاد منافع نویسندگان

در این مقاله هیچ‌گونه تضاد منافی وجود ندارد و این مسئله مورد تأیید همه نویسندگان است.

دسترسی به داده‌ها

داده‌های استفاده‌شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

- machines in bankruptcy prediction model. *Expert Systems with Applications*, 28(4), pp.127-135. <https://doi.org/10.1016/j.eswa.2004.08.009>
17. Shrestha, B., Cochrane, T.A., Caruso, B. S., Arias, M. E. and Piman, T., 2016. Uncertainty in flow and sediment projections due to future climate scenarios for the 3S Rivers in the Mekong Basin. *Journal of Hydrology*, 540, pp.1088-1104. <https://doi.org/10.1016/j.jhydrol.2016.07.019>
 18. Shrivatava, M., Prasad, V. and Khare, R., 2015. Multi-objective optimization of water distribution system using particle swarm optimization. *Journal of Mechanic Civil Engineering*, 12(1), pp.21-28. <https://doi.org/10.5004/dwt.2021.26944>
 19. Tan, M.L., Gassman, P. W., Yang, X. and Haywood, J., 2020. A review of SWAT applications, performance and future needs for simulation of hydro-climatic extremes. *Advances in Water Resources*, 143, 103662. <https://doi.org/10.1016/j.advwatres.2020.103662>
 20. Wang, D., Safavi, A.A. and Romagnoli, J.A., 2000. Wavelet-based adaptive robust M-estimator for non-linear system identification. *AIChE Journal*, 46(4), pp.1607-1615. <https://doi.org/10.1002/aic.690460812>
 21. Zhang, G., Deng, A., Chen, J., Wang, D., Yin, Y. and Wang, H., 2024. Impacts of climate change and human activities on sediment load in Longchuan River Basin, China. *Journal of Hydrology: Regional Studies*, 51, pp.613-632. <https://doi.org/10.1016/j.ejrh.2023.101613>
 22. Zhang, A.A., Williams, J. and Davies, T., 2023. Modeling climate change impacts on sediment transport in the Nina River, New Zealand, using GCMs and neural networks. *Journal of Hydrology, Regional Studies*, 45(2), pp.234-252. <https://doi.org/10.1016/j.ejrh.2023.101234>
 23. Zouache, D., Arby, Y. O., Nouioua, F. and Abdelaziz, F.B., 2019. Multi-objective chicken swarm optimization: A novel algorithm for solving multi-objective optimization problems. *Computers and Industrial Engineering*, 129, pp.377-391. <https://doi.org/10.1016/j.cie.2019.01.055>
 24. Zeidalinejad, N. and Dehghani, R., 2023. Use of meta-heuristic approach in the estimation of aquifer's response to climate change under shared socioeconomic pathways. *Groundwater for Sustainable Development*, 20(4), pp.112-132. <https://doi.org/10.1016/j.gsd.2022.100882>
 122. <https://doi.org/10.1016/j.geomorph.2023.108607>
 8. Nourani, V., Kisi, Ö. and Komasi, M., 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*, 402(2), pp.41-59. <https://doi.org/10.1016/j.jhydrol.2011.03.002>
 9. Nourani, V., Alami, M.T. and Aminfar, M.H., 2009. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, 22(2), pp.466-472. <https://doi.org/10.1016/j.engappai.2008.09.003>
 10. Pandey, D., Tiwari, A.D. and Mishra, V., 2022. On the occurrence of the observed worst flood in Mahanadi River basin under the warming climate. *Weather and Climate Extremes*, 38, 100520. <https://doi.org/10.1016/j.wace.2022.100520>
 11. Jahangir, M.H., Haghghi, P. and Danekar, S., 2022. Downscaling climate parameters in Fars province, using models of the fifth report and RCP scenarios. *Ecological Informatics*, 68, pp.112-128. <https://doi.org/10.1016/j.ecoinf.2022.101558>
 12. Ranjan, R. and Mishra, A., 2023. Climate change impact on streamflow and suspended sediment load in the flood-prone river basin Open Access. *Journal of Water and Climate Change*, 14 (7), pp.2260-2276. <https://doi.org/10.2166/wcc.2023.037>
 13. Riahi, K., Van Vuuren, D.P., Kriegler, E., Edmonds, J., O'Neill, B.C., Fujimori, S., Bauer, N., Calvin, K., Dellink, R., Fricko, O. and Lutz, W., 2017. The shared socioeconomic pathways and their energy, land use, and greenhouse gas emissions implications: An overview. *Global Environ. Change*, 42, pp.68-153. <https://doi.org/10.1016/j.gloenvcha.2016.05.009>
 14. Saha, A., Ghosh, S., Sahana, A. S. and Rao, E. P., 2014. Failure of CMIP5 climate models in simulating post-1950 decreasing trend of Indian monsoon. *Geophysical Research Letters*, 41 (20), pp.7323-7330. <https://doi.org/10.1002/2014GL061573>
 15. Shadkani, S., Hemmatzadeh, Y., Pak, A. and Abolfathi, S. 2025. Prediction of suspended sediment concentration in fluvial flows using novel hybrid deep learning model. *International Journal of Sediment Research*, 40(4), pp.573-587. <https://doi.org/10.1016/j.ijsrc.2025.02.004>
 16. Shin, S., Kyung, D., Lee, S., Taik and Kim, J. and Hyun, J., 2005. An application of support vector