

Impact of IPCC-CMIP6 climate scenarios on basin runoff using ANN and multiple-regression approaches

Mahdieh Kalhori¹ , Emad Kahrizi² , Golnaz Amiri³ , Mozhgan Yarahmadi⁴ 

1. Department of Civil Engineering, University of Qom, Qom, Iran. E-mail: M.Kalhori@stu.qom.ac.ir
2. Corresponding Author, Department of Civil Engineering, Faculty of Technical and Engineering, University of Ayatollah Boroujerdi, Boroujerd, Iran. E-mail: Emad.kahrizi@gmail.com
3. Department of Civil Engineering, University of Zanjan, Zanjan, Iran. E-mail: amirigolnaz20@gmail.com
4. Department of Reclamation of Arid and Mountainous Regions, Faculty of Natural Resources, University of Tehran, Tehran, Iran. E-mail: myarahmadi1128@gmail.com

Article Info

Article type:
Research Article

Article history:
Received 06 Oct 2025
Revised 08 Dec 2025
Accepted 19 Dec 2025
Published 26 Dec 2025

Keywords:
Water Resources,
SSP Scenario,
Runoff Simulation,
Artificial Neural Network,
Multiple Regression.

ABSTRACT

Objective: The objective of this study is to assess future runoff variations in the Khorramabad basin using up-to-date climate data and data-driven modeling approaches.

Method: To this end, outputs from the Sixth Assessment Report of the Intergovernmental Panel on Climate Change (IPCC) under the Shared Socioeconomic Pathways SSP1-2.6 (optimistic) and SSP5-8.5 (pessimistic) were employed for the future periods 2040–2069 and 2070–2099. Climate variables were downscaled using the change factor method. To simulate future runoff, two data-driven models, namely Artificial Neural Networks (ANN) and Multiple Linear Regression (MLR), were developed.

Results: The evaluation of climate models indicated that CMIP6 models perform more reliably in simulating historical temperature than precipitation, highlighting the higher uncertainty associated with precipitation projections. Furthermore, analysis of the downscaled data revealed a decreasing trend in precipitation and an increasing trend in long-term monthly mean temperature under both climate scenarios. In the hydrological modeling framework, the ANN model outperformed the multiple linear regression model in terms of runoff simulation accuracy and its ability to capture complex nonlinear relationships among climatic variables.

Conclusion: Runoff projections derived from the ANN model indicate a substantial decline in runoff across all future periods and scenarios, suggesting intensified water stress and underscoring the urgent need for targeted planning and adaptive strategies to ensure sustainable water resources management in the studied watershed.

Cite this article: Kalhori M, Kahrizi E, Amiri G, Yarahmadi M. Impact of IPCC-CMIP6 climate scenarios on basin runoff using ANN and multiple-regression approaches. *Water Resources and Climate Change*. (2025); 1(4): 55-68. <https://doi.org/10.22091/wrcc.2025.14715.1026>.



Introduction

Climate change is a principal driver of hydrological alteration worldwide, and semi-arid catchments are especially vulnerable because reductions in precipitation and increases in temperature translate directly into heightened water-stress.

The present study quantifies the projected evolution of surface runoff in the Khorramabad River Basin (4250 km², Lorestan Province, Iran) by coupling the latest IPCC-AR6 climate information with data-driven hydrological models.

The primary objectives were to (i) evaluate the performance of the newest CMIP6 general-circulation models (GCMs) for the basin, (ii) downscale the GCM outputs to the basin scale, and (iii) assess the ability of a non-linear Artificial Neural Network (ANN) and a multiple linear regression (MR) model to simulate future runoff under the SSP1-2.6 (optimistic) and SSP5-8.5 (pessimistic) pathways.

Method

Historical climate series (1971-2000) for precipitation and air temperature were compiled from local stations and used as the reference for model evaluation. Fourteen CMIP6 GCMs were extracted for the historical period and for two future windows – mid-century (2040-2069) and end-century (2070-2099) – under SSP1-2.6 and SSP5-8.5.

A simple change-factor (bias-correction) approach was applied to translate the coarse-resolution GCM fields to the basin scale; the precipitation factor was defined as the ratio of future to baseline mean monthly precipitation, while the temperature factor was the difference between future and baseline mean monthly temperature.

Model skill was assessed using *RMSE*, *NSE*, Kling-Gupta Efficiency (*KGE*) and the coefficient of determination (R^2). IPSL-CM6A-LR emerged as the most skillful GCM for precipitation ($RMSE \approx 49$ mm yr⁻¹, $NSE \approx 0.82$, $KGE \approx 0.86$) and ACCESS-CM2 for temperature ($RMSE \approx 0.83$ °C, $NSE \approx 0.99$). For hydrological simulation, two data-driven models were constructed:

- Multiple Linear Regression (MR): A linear equation linking monthly runoff (Q) to precipitation (P) and temperature (T).
- Artificial Neural Network (ANN): A feed-forward network with a 3-10-1 architecture (three inputs, ten hidden neurons, one output). The observed dataset was partitioned into training (70 %), validation (15 %), and testing (15 %) subsets. ANN training employed the Levenberg-Marquardt algorithm, and model performance was evaluated with the same statistical metrics as above.

Results

Downscaled CMIP6 projections indicate a consistent decline in mean annual precipitation of 5–9 % and a rise in mean monthly temperature of up to ~5 °C by the 2070-2099 horizon, with the magnitude of change markedly larger under the high-emission SSP5-8.5 scenario.

The ANN consistently outperformed the MR model across all evaluation periods and metrics. In the independent test set the ANN achieved $NSE = 0.35$, $RMSE \approx 12\%$ of the observed runoff range, $KGE > 0.60$ and a correlation coefficient $r \approx 0.71$, whereas the MR model produced NSE values close to zero and substantially larger $RMSE$, reflecting its inability to capture the non-linear precipitation-runoff relationship.

Using the ANN, future runoff is projected to decrease by 15-30 % relative to the historic period across both scenarios, with the greatest reductions occurring under SSP5-8.5. The runoff decline mirrors the simulated precipitation deficits and the temperature-driven increase in evapotranspiration, signalling a pronounced intensification of water scarcity in the Khorramabad basin.

Conclusion

Integrating up-to-date CMIP6 climate projections with an ANN-based hydrological framework provides a robust, basin-specific assessment of future water availability in a semi-arid environment.

The analysis reveals a clear trajectory toward reduced surface-water resources, especially under the pessimistic SSP5-8.5 pathway, and underscores the urgency of implementing adaptive water-management strategies such as improved irrigation efficiency, optimized allocation policies, the development of flood-and-drought mitigation infrastructure, and early-warning systems.

Future work should explore hybrid physics-data models and multi-scenario ensembles to better resolve extreme flow events and to further reduce predictive uncertainty.

Declarations

Ethical Approval

The paper is not currently being considered for publication elsewhere. All authors have been personally and actively involved in substantial work leading to the paper, and will take public responsibility for its content.

Competing interests

Conflict of Interest – None

Availability of data and materials

Data will be made available on the request.

Authors Contributions

Mahdieh Kalhori performed the calculations. Golnaz Amiri approved the analytical methods. Emad Kahrizi supervised the findings of this work. Mozhgan Yarahmadi discussed the results, and contributed to the final version of the paper.

Acknowledgements

The authors would like to thank all participants in the present study.

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.



تأثیر سناریوهای اقلیمی IPCC-CMIP6 بر رواناب حوضه با رویکردهای ANN و رگرسیون چندگانه

مهديه کلهری^۱، عماد کهريزی^۲، گلناز امیری^۳، مژگان یاراحمدی^۴

۱. گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران. رایانامه: M.Kalhari@stu.qom.ac.ir
۲. نویسنده مسئول، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه آیتالله العظمی بروجردی (ره)، بروجرد، ایران. رایانامه: Emad.Kahrizi@gmail.ac.ir
۳. گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه زنجان، زنجان، ایران. رایانامه: amirigolnaz20@gmail.com
۴. گروه مهندسی احیای مناطق خشک و کوهستانی، دانشکده مهندسی منابع طبیعی، دانشگاه تهران، تهران، ایران. رایانامه: myarahmadi1128@gmail.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	هدف: هدف این پژوهش، ارزیابی تغییرات آبی رواناب در حوضه آبریز خرم‌آباد با استفاده از داده‌های به‌روز اقلیمی و مدل‌های داده‌محور می‌باشد.
تاریخ دریافت: ۱۴۰۴/۰۷/۱۴	روش: بدین‌منظور، داده‌های گزارش ششم ارزیابی هیئت بین‌دولتی تغییر اقلیم (IPCC) تحت سناریوهای اجتماعی-اقتصادی مشترک ^۳ SSP1-2.6 (خوش‌بینانه) و SSP5-8.5 (بدبینانه) برای دوره‌های زمانی ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰ مورد استفاده قرار گرفت. ریزمقیاس‌نمایی متغیرهای اقلیمی با بهره‌گیری از روش عامل تغییر ^۴ انجام شد. برای شبیه‌سازی رواناب آینده، دو مدل داده‌محور شامل شبکه عصبی مصنوعی ^۵ (ANN) و رگرسیون چندگانه ^۶ (MR) توسعه داده شد.
تاریخ بازنگری: ۱۴۰۴/۰۹/۱۷	یافته‌ها: نتایج نشان دادند که مدل‌های CMIP6 در شبیه‌سازی دمای دوره تاریخی عملکرد بهتری نسبت به بارش دارند که بیانگر عدم قطعیت بیش‌تر در پیش‌بینی بارش است. هم‌چنین تحلیل داده‌های ریزمقیاس‌نمایی شده حاکی از کاهش بارش و افزایش دمای متوسط بلندمدت ماهانه در هر دو سناریوی اقلیمی می‌باشد. در بخش مدل‌سازی آب‌شناسی، ANN در مقایسه با مدل MR، دقت بالاتری در شبیه‌سازی رواناب و بازنمایی روابط غیرخطی میان متغیرهای اقلیمی از خود نشان داد.
تاریخ پذیرش: ۱۴۰۴/۰۹/۲۸	نتیجه‌گیری: پیش‌بینی‌های حاصل از مدل ANN کاهش قابل توجه رواناب را در تمامی دوره‌ها و سناریوهای آینده نشان می‌دهند که بیانگر افزایش تنش آبی و ضرورت برنامه‌ریزی هدفمند برای مدیریت پایدار منابع آب در حوضه مورد مطالعه است.
تاریخ انتشار: ۱۴۰۴/۱۰/۰۵	
کلیدواژه‌ها: منابع آب، سناریوهای SSP، شبیه‌سازی رواناب، شبکه عصبی مصنوعی، رگرسیون چندگانه.	

استناد: کلهری مهديه، کهريزی عماد، امیری گلناز، یاراحمدی مژگان. تأثیر سناریوهای اقلیمی IPCC-CMIP6 بر رواناب حوضه خرم‌آباد با رویکردهای ANN و رگرسیون چندگانه. *منابع آب و تغییر اقلیم*. ۱۴۰۴؛ (۴): ۵۵-۶۸. <http://doi.org/10.22091/wrcc.2025.14715.1026>

²- Intergovernmental Panel on Climate Change
³- Shared Socioeconomic Pathways
⁴- Change Factor
⁵- Artificial Neural Network
⁶- Multiple Regression



۱- مقدمه

در ارزیابی دقت مدل‌های CMIP6 در ایران مشخص شد که مدل IPSL-CM6A-LR بهترین عملکرد را در برآورد دما و مدل HadGEM3-GC31-LL دقیق‌ترین نتایج را در شبیه‌سازی بارش سالانه ارائه می‌دهند. همچنین، خطای این مدل‌ها در مناطق مرکزی و شرقی کشور کم‌تر از سایر نواحی گزارش شده است [۷]. در مجموع، ۴۰ مدل CMIP6 مورد بررسی قرار گرفتند. نتایج نشان دادند که این مدل‌ها در شبیه‌سازی دما عملکرد بسیار مطلوبی دارند، در حالی که در بازنمایی بارش ضعیف‌تر عمل می‌کنند. علاوه بر این، پژوهش حاضر مدل‌های NorESM2-MM، AWI-ESM1-1-LR و MPI-ESM1-2-LR را به‌عنوان گزینه‌های برتر برای شبیه‌سازی بارش و مدل‌های MPI-ESM1-2-LR، TaiESM1، INM-CM4-8 و IITM-ESM را به‌عنوان بهترین مدل‌ها برای شبیه‌سازی دما معرفی کرده است [۸].

در حوضه گرگانرود، با استفاده از مدل‌های CMIP6 تحت سناریوهای SSP2-4.5 و SSP5-8.5، کاهش بارش سالانه (تا ۹- درصد) و افزایش دمای سالانه (حدود ۱۳ تا ۱۵ درصد) را پیش‌بینی کردند و دریافتند که مدل‌های چرخه عمومی در شبیه‌سازی دما قوی‌تر از شبیه‌سازی بارش هستند. این پژوهش همچنین نشان داد که بیش‌ترین افزایش رواناب آینده نسبت به دوره مشاهداتی، مربوط به فصل بهار و زمستان است که به ذوب برف در این فصول ارتباط دارد و بیش‌ترین کاهش رواناب مربوط به فصل پاییز می‌باشد [۹].

در پژوهشی که بر حوضه آبریزی در تانزانیا انجام گرفت، با بهره‌گیری از مدل SWAT و داده‌های شبیه‌سازی شده CMIP6، نتایج نشان دادند که افزایش دما در بازه ۰/۶ تا ۲ درجه سلسیوس همراه با رشد بارش سالانه بین ۷ تا ۱۷ درصد، می‌تواند موجب افزایش رواناب سطحی و تقویت جریان رودخانه در دوره‌های مرطوب گردد [۱۰]. در بررسی انجام‌شده بر منطقه شهری در برزیل، داده‌های اقلیمی CMIP6 تحت سناریوهای SSP1-2.6 و

فعالیت‌های انسانی به‌طور قطعی موجب تشدید گرمایش جهانی شده و تغییرات سریع و گسترده‌ای را در سامانه‌های اصلی زمین شامل اتمسفر، اقیانوس‌ها، کریوسفر و بیوسفر رقم زده است. این روند، فراوانی و شدت رخداد‌های اقلیمی حدی هم‌چون سیلاب‌های ویرانگر و خشکسالی‌های شدید را در مناطق مختلف جهان افزایش داده است [۱]. پیامدهای ناشی از این تغییرات، به‌ویژه بر جوامع آسیب‌پذیری که سهم اندکی در ایجاد بحران اقلیمی داشته‌اند، به‌طور نامتناسبی سنگینی می‌کند. در همین راستا، گزارش ششم IPCC نشان می‌دهد که تا سال ۲۰۲۰ میانگین دمای جهانی حدود ۱/۰۹ درجه سلسیوس بالاتر از سطح پیش از انقلاب صنعتی بوده است [۲].

در سطح منطقه‌ای، ایران به‌عنوان کشوری نیمه‌خشک، به‌طور جدی در معرض پیامدهای تغییرات اقلیمی، به‌ویژه کاهش منابع آب قرار دارد [۳]. وابستگی بخش‌های کلیدی هم‌چون کشاورزی و تأمین آب شهری به رواناب‌های سطحی سبب می‌شود که هرگونه تغییر در الگوهای بارش و دما آثار قابل‌توجهی بر امنیت آبی و توسعه پایدار کشور برجای گذارد. این شرایط، ضرورت بهره‌گیری از پیش‌بینی‌های دقیق و روزآمد را برای تدوین راه‌بردهای مدیریتی و تطبیقی در حوضه‌های آبریز حیاتی دوچندان می‌سازد [۴]. در این میان، حوضه آبریز خرم‌آباد به‌عنوان یکی از مهم‌ترین حوضه‌های غرب ایران، نیازمند مطالعه‌ای جامع و روزآمد برای پیش‌بینی دقیق وضعیت آینده منابع آب است. مطالعات پیشین در این حوضه به‌طور عمده بر پایه مدل‌های قدیمی‌تر و سناریوهای انتشارات گذشته نظیر گزارش ارزیابی سوم (TAR) و گزارش ارزیابی پنجم (AR5) و انجام شده‌اند [۵]. با انتشار گزارش ششم IPCC، ضرورت به‌روزرسانی و ارزیابی مجدد این مطالعات با بهره‌گیری از جدیدترین داده‌های علمی بیش از پیش احساس می‌شود [۶].

متغیرهای آب و هوایی و آب‌شناسی با روابط غیرخطی پیچیده کارایی بالایی دارند [۱۵].

یکی از روش‌های ریزمقیاس‌نمایی روش عامل تغییر بوده که روشی ساده و پرکاربرد براساس مقایسه میانگین داده‌های GCM در دوره تاریخی و آینده بوده و یک ضریب تغییر برای داده‌های مشاهداتی محلی ایجاد می‌کند. مزیت اصلی آن سادگی و سرعت است و به‌همین دلیل در بسیاری از مطالعات مورد استفاده قرار گرفته است. با این حال، فرض ثابت بودن ضریب تغییر در طول زمان و عدم تغییر الگوهای روزانه یا فصلی، می‌تواند در مدل‌سازی رویدادهای حدی مانند سیلاب و خشک‌سالی منجر به افزایش عدم قطعیت شود [۱۶].

مطالعات اخیر از روش‌هایی مانند نگاشت چندک، نگاشت چندک تجربی^۹ (EQM) و ANN برای ریزمقیاس‌نمایی بهره برده‌اند [۱۷].

در حوضه رودخانه‌ای در پاکستان، عملکرد سه مدل ANN، RNN و ANFIS مورد ارزیابی قرار گرفت. نتایج نشان دادند که مدل ANN با معماری ۳-۱۰-۱ در شبیه‌سازی جریان، با مقادیر برابر با ۰/۹۴ در مرحله آموزش و ۰/۹۲ در مرحله آزمون، نسبت به دو مدل دیگر برتری دارد [۱۸]. همچنین، الگوریتمی ترکیبی از ANN و ماشین بردار پشتیبان^{۱۰} (SVM) برای ارتقای پیش‌بینی رواناب به کار گرفته شد [۱۹].

با وجود این، برخی مطالعات گزارش کرده‌اند که مدل‌های ANN در پیش‌بینی اوج جریان عملکرد ضعیف‌تری دارند و در برخی سال‌ها قادر به بازنمایی اوج‌های جریان نیستند [۲۰]. این محدودیت‌ها نشان می‌دهند که مدل‌های یادگیری ماشین در پیش‌بینی مقادیر حدی با چالش مواجه‌اند و نیازمند بهبود برای دستیابی به مدیریت مطمئن‌تر منابع آب هستند [۲۱].

8.5-SSP با بهره‌گیری از روش‌های ریزمقیاس‌نمایی آماری و الگوریتم‌های یادگیری ماشین، شامل رویکرد رگرسیون و روش دلتا، پردازش شدند. هدف این تحلیل، ارزیابی تغییرات در مجموع بارش سالانه، تعداد روزهای بارانی و میزان وقوع رخداد‌های بارش بود. نتایج نشان دادند که روش‌های مبتنی بر یادگیری ماشین و رگرسیون از دقت بیش‌تری نسبت به روش دلتا برخوردار بودند و بنابراین به‌عنوان گزینه‌های مناسب‌تر برای مطالعات آینده در زمینه تغییرات بارش توصیه می‌شوند [۱۱].

در یک پژوهش، عملکرد ANN در پیش‌بینی رواناب، با مدل‌های تجربی متداول مقایسه شد. نتایج این مقایسه در یک حوضه آبریز نشان داد که مدل ANN به دلیل توانایی بالاتر در یادگیری روابط پیچیده، از دقت و کارایی برتر نسبت به روش‌های تجربی برخوردار است [۱۲].

در یک مطالعه، رواناب حوضه‌ای در هند با بهره‌گیری از ANN و مدل‌های تجربی مورد پیش‌بینی قرار گرفت. نتایج نشان دادند که مدل ANN-5، با استفاده از داده‌های بارش و بارش با یک روز تأخیر، عملکرد بهتری داشته و توانسته است پیش‌بینی دقیق‌تری از رواناب ارائه دهد. این مدل به‌عنوان ابزاری کارآمد می‌تواند در تصمیم‌گیری‌های مرتبط با برنامه‌ریزی، مدیریت منابع آب و پیش‌بینی سیلاب مورد استفاده قرار گیرد [۱۳].

از آنجا که مدل‌های اقلیمی جهانی^۸ (GCMs) دارای مقیاس فضایی بزرگ در حدود ۲۰۰ تا ۶۰۰ کیلومتر هستند، استفاده مستقیم از خروجی آنها در مطالعات آب‌شناسی مقیاس حوضه امکان‌پذیر نیست. به‌همین دلیل، فرایند ریزمقیاس‌نمایی برای تبدیل داده‌های GCM به مقیاس محلی ضروری محسوب می‌شود [۱۴].

ریزمقیاس‌نمایی به‌طور کلی در دو دسته پویا و آماری طبقه‌بندی می‌شود. روش‌های آماری که با بهره‌گیری از روش‌های یادگیری ماشین توسعه یافته‌اند، در شبیه‌سازی

^۸- General Circulation Models

^۹- Empirical Quantile Mapping

^{۱۰}- Support Vector Machine

در این تحقیق، روند کلی ارزیابی اثرات تغییر اقلیم بر متغیرهای آب‌شناسی حوضه مورد مطالعه تشریح می‌گردد. در ابتدا با گردآوری داده‌های پایه و آماده‌سازی اطلاعات ضروری، خروجی مدل‌های اقلیمی گزارش ششم IPCC تحت دو سناریوی SSP1-2.6 و SSP5-8.5 مورد بهره‌برداری قرار خواهد گرفت تا تغییرات بارش و دما در دوره‌های آینده شبیه‌سازی شوند. پس از آن، براساس این داده‌ها، پیش‌بینی رواناب در شرایط آبی انجام خواهد شد. برای دستیابی به نتایج دقیق‌تر، دو رویکرد تحلیلی شامل MR و ANN به کار گرفته خواهند شد تا خروجی‌ها از جنبه‌های مختلف مورد ارزیابی قرار گیرند. ترکیب این روش‌ها امکان ارائه تحلیلی جامع‌تر از تغییرات احتمالی منابع آب سطحی در سناریوهای گوناگون اقلیمی را فراهم خواهد ساخت.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

حوضه آبریز خرم‌آباد در استان لرستان، میان طول‌های جغرافیایی ۴۷ درجه و ۵۳ دقیقه تا ۴۸ درجه و ۴۵ دقیقه شرقی و عرض‌های جغرافیایی ۳۳ درجه و ۱۳ دقیقه تا ۳۳ درجه و ۴۴ دقیقه شمالی واقع شده است (شکل ۱). مساحت این حوضه برابر با ۲۵۰۱/۴ کیلومتر مربع بوده و به‌عنوان بخشی از حوضه بزرگ کرخه شناخته می‌شود. ارتفاع آن از ۹۴۵ تا ۳۰۵۳ متر تغییر می‌کند و میانگین ارتفاع برابر با ۱۶۰۴ متر است. در خروجی این حوضه، ایستگاه هیدرومتری دوآب ویسان قرار دارد که داده‌های مربوط به دبی خروجی آن در این مطالعه مورد استفاده قرار گرفته است [۲۴].

در دهه‌های اخیر GCMها به ابزارهای قدرتمندی برای پیش‌بینی تغییرات آینده اقلیم تبدیل شده‌اند. با پیشرفت‌های پیوسته، مدل‌های چرخه عمومی اتمسفر-اقیانوس^{۱۱} (AOGCMs) از نسل‌های CMIP3 و CMIP5 که در گزارش‌های سوم و پنجم IPCC (AR5 و TAR) مورد استفاده قرار گرفتند، به نسل CMIP6 در گزارش ششم (AR6) تکامل یافته‌اند. این مدل‌ها با سناریوهای جدیدی تحت عنوان مسیرهای اجتماعی-اقتصادی مشترک (SSPs) تکمیل شده‌اند که چارچوبی جامع‌تر و واقع‌بینانه‌تر برای تحلیل آینده اقلیم فراهم می‌کنند [۲۲].

سناریوهای SSP علاوه بر انتشار گازهای گلخانه‌ای، بر عواملی هم‌چون رشد جمعیت، توسعه اقتصادی، فناوری و سیاست‌های اقلیمی نیز تمرکز دارند. در این پژوهش، دو سناریوی کلیدی شامل SSP1-2.6 (مسیر توسعه پایدار با انتشار پایین) و SSP5-8.5 (مسیر توسعه مبتنی بر سوخت‌های فسیلی با انتشار بسیار بالا) مورد استفاده قرار گرفته است [۲۳].

برای شبیه‌سازی رواناب، رویکردهای داده‌محور نظیر ANN و MR به‌عنوان جایگزین‌های قدرتمند مدل‌های فیزیکی مطرح هستند. شبکه‌های عصبی مصنوعی به دلیل توانایی در شناسایی و بازنمایی روابط پیچیده و غیرخطی میان متغیرهای ورودی و خروجی، کاربرد گسترده‌ای در مطالعات آب‌شناسی یافته‌اند.

شواهد پژوهشی اخیر نشان می‌دهند که مدل‌های ANN در پیش‌بینی رواناب عملکرد بسیار مطلوبی دارند و حتی در مقایسه با مدل‌های مفهومی نیز نتایج دقیق‌تری ارائه می‌کنند.

در مقابل، رگرسیون چندگانه به‌عنوان یک مدل خطی ساده‌تر، امکان تحلیل پایه را فراهم کرده و می‌تواند به‌عنوان معیار مرجع برای ارزیابی مدل‌های پیچیده‌تر مورد استفاده قرار گیرد. با این حال، توانایی این مدل در شبیه‌سازی روابط غیرخطی بارش-رواناب محدود است.

¹¹ - Atmosphere-Ocean General Circulation Models

محاسبه می‌شود. برای دما نیز عامل تغییر مطابق با رابطه (۲) به صورت تفاوت میانگین دمای ماهانه در دوره آینده مدل با میانگین آن در دوره پایه تعیین می‌گردد. در نهایت، این ضرایب بر داده‌های مشاهداتی اعمال می‌شوند تا شرایط آینده شبیه‌سازی شود.

$$T_{\text{fut,scen}} = T_{\text{hist,obs}} + (\bar{T}_{\text{fut,GCM}} - \bar{T}_{\text{hist,GCM}}) \quad (1)$$

$$P_{\text{fut,scen}} = P_{\text{hist,obs}} \times \left(\frac{\bar{P}_{\text{fut,GCM}}}{\bar{P}_{\text{hist,GCM}}} \right) \quad (2)$$

که در آن، $T_{\text{fut,scen}}$ = مقدار دمای ریزمقیاس شده و تعدیل شده برای یک گام زمانی خاص در سناریوی آینده؛ $T_{\text{hist,obs}}$ = مقدار دمای مشاهده شده در ایستگاه محلی برای همان گام زمانی (در دوره پایه)؛ $\bar{T}_{\text{fut,GCM}}$ = میانگین بلندمدت دما از مدل GCM برای دوره آینده؛ $\bar{T}_{\text{hist,GCM}}$ = میانگین بلندمدت دما از مدل GCM برای دوره پایه؛ $(\bar{T}_{\text{fut,GCM}} - \bar{T}_{\text{hist,GCM}})$ = همان عامل تغییر دما است که نشان‌دهنده میزان تغییر مدل GCM (برحسب درجه سانتی‌گراد) است؛ $P_{\text{fut,scen}}$ = مقدار بارش ریزمقیاس شده و تعدیل شده برای یک گام زمانی خاص در سناریوی آینده؛ $P_{\text{hist,obs}}$ = مقدار بارش مشاهده شده در ایستگاه محلی برای همان گام زمانی (در دوره پایه)؛ $\bar{P}_{\text{fut,GCM}}$ = میانگین بلندمدت بارش از مدل GCM برای دوره آینده؛ $\bar{P}_{\text{hist,GCM}}$ = میانگین بلندمدت بارش از مدل GCM برای دوره پایه، و $\frac{\bar{P}_{\text{fut,GCM}}}{\bar{P}_{\text{hist,GCM}}}$ همان ضریب تغییر بارش است که نشان‌دهنده درصد یا نسبت تغییر مدل GCM است.

۲-۴-۲- رویکرد مدل‌سازی آب‌شناسی

۲-۴-۱-۱- مدل MR

مدل رگرسیون چندگانه به‌عنوان یکی از روش‌های آماری خطی، برای تبیین و برآورد ارتباط میان رواناب به‌عنوان متغیر وابسته و متغیرهای اقلیمی شامل بارش و دما به‌عنوان متغیرهای مستقل مورد استفاده قرار می‌گیرد

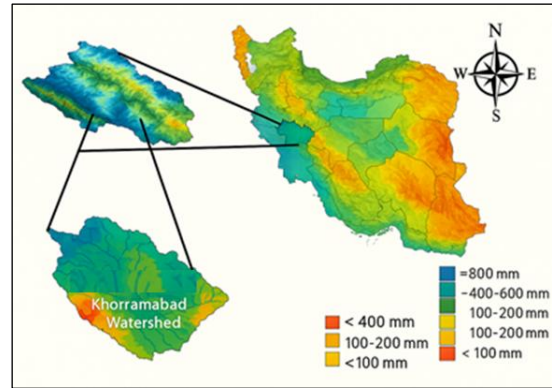


Figure 1. Geographical location of the Khorramabad watershed

شکل ۱- موقعیت جغرافیایی حوزه آبریز خرم‌آباد

۲-۲- جمع‌آوری و آماده‌سازی داده‌ها

داده‌های تاریخی مورد استفاده در این پژوهش شامل رواناب اندازه‌گیری شده در ایستگاه هیدرومتری دوآب ویسان و اطلاعات بارش و میانگین دمای ماهانه از ایستگاه‌های هواشناسی منتخب طی دوره زمانی ۱۹۷۱ تا ۲۰۰۰ است. این بازه ۳۰ ساله به‌عنوان دوره پایه برای مقایسه با نتایج آینده در نظر گرفته شد. در ادامه، خروجی مدل‌های اقلیمی مجموعه CMIP6 مرتبط با گزارش ششم IPCC به‌کار گرفته شد؛ به‌طوری‌که ۱۴ مدل از این مجموعه برای ارزیابی عملکرد در شبیه‌سازی داده‌های تاریخی مورد استفاده قرار گرفتند. هم‌چنین، داده‌های این مدل‌ها برای دو سناریوی SSP5-8.5 و SSP1-2.6 در دو بازه زمانی آینده نزدیک (۲۰۴۰-۲۰۶۹) و آینده دور (۲۰۷۰-۲۰۹۹) استخراج شدند.

۲-۳- روش ریزمقیاس‌نمایی عامل تغییر

ریزمقیاس‌نمایی فرآیندی است که طی آن داده‌های اقلیمی با مقیاس بزرگ جهانی به مقیاس محلی تبدیل می‌شوند. این روش با بهره‌گیری از یک رابطه ساده، تغییرات دما و بارش را از خروجی مدل‌های اقلیمی به داده‌های مشاهداتی منتقل می‌کند. در مورد بارش، ضریب تغییر مطابق با رابطه (۱) به صورت نسبت میانگین بارش ماهانه در دوره آینده مدل به میانگین همان متغیر در دوره پایه

اعتبارسنجی (۱۵ درصد) و آزمون (۱۵ درصد) تفکیک گردید. فرآیند آموزش شبکه با بهره‌گیری از الگوریتم پس‌انتشار خطا و استفاده از روش لوبنرگ-مارکوارت^{۱۲} انجام شد. در این الگوریتم، با انتقال تدریجی خطا به لایه‌های پیشین، مقادیر وزن‌ها و بایاس‌ها^{۱۳} به صورت تکراری به‌روزرسانی می‌شوند تا میزان خطای مدل کمینه شود.

۲-۴-۵- معیارهای ارزیابی عملکرد مدل

به‌منظور ارزیابی دقت و کارایی مدل‌های اقلیمی و آب‌شناسی، نتایج حاصل از شبیه‌سازی‌ها با استفاده از مجموعه‌ای از شاخص‌های آماری مورد بررسی قرار گرفت. یکی از معیارهای به‌کاررفته، ریشه میانگین مربعات خطا^{۱۴} ($RMSE$) است که فرمول آن به صورت رابطه (۴) بوده و میزان دقت پیش‌بینی مدل را نشان داده و نسبت به خطاهای بزرگ، به‌ویژه در مقادیر حدی، حساسیت بالایی دارد؛ به‌طوری‌که مقادیر کم‌تر آن بیان‌گر عملکرد بهتر مدل است.

هم‌چنین میانگین خطای مطلق^{۱۵} (MAE) به‌عنوان معیاری برای محاسبه میانگین قدرمطلق اختلاف بین مقادیر شبیه‌سازی‌شده و مشاهده‌شده مطابق با رابطه (۵) استفاده شد که کاهش مقدار آن نشان‌دهنده افزایش دقت مدل می‌باشد.

شاخص کارایی کلینگ-گوپتا^{۱۶} (KGE) به‌عنوان معیاری جامع برای ارزیابی مدل‌های آب‌شناسی مطابق با رابطه (۶) مورد استفاده قرار گرفت؛ این شاخص با در نظر گرفتن هم‌زمان مؤلفه‌های همبستگی، نسبت میانگین و میزان پراکندگی، محدودیت‌های شاخص‌هایی نظیر نش-ساتکلیف را کاهش می‌دهد و توان مدل را در بازتولید رفتار کلی داده‌ها به‌صورت یک‌پارچه ارزیابی می‌کند.

علاوه‌بر این، ضریب تعیین^{۱۷} (R^2) مطابق با رابطه (۷) برای سنجش سهم واریانس داده‌های مشاهده‌شده که

[۲۵] و رابطه بین این متغیرها را به‌صورت رابطه (۳) بیان می‌کند:

$$Q_t = \beta_0 + \beta_1 P_t + \beta_2 T_t + \varepsilon_t \quad (3)$$

که در آن، Q_t = رواناب در گام زمانی فعلی t ؛ P_t = بارش در گام زمانی t ؛ T_t = دما در گام زمانی t ؛ β_0 = عرض از مبدأ؛ β_1 = ضریب رگرسیون بارش؛ β_2 = ضریب رگرسیون دما، و ε_t = جمله خطا در گام زمانی، هستند.

۲-۴-۲- ANN مدل

ANN یکی از مدل‌های داده‌محور کارآمد است که ساختار و عملکرد آن با الهام از سامانه عصبی انسان توسعه یافته است. این مدل به‌طور معمول از سه بخش اصلی شامل لایه ورودی، لایه پنهان و لایه خروجی تشکیل می‌شود. همان‌گونه که در شکل ۲ نشان داده شده است، داده‌ها در لایه ورودی به شبکه وارد شده، فرآیند یادگیری و استخراج الگوها در لایه پنهان انجام می‌گیرد و در نهایت لایه خروجی پاسخ یا برآورد نهایی مدل را ارائه می‌دهد. شبکه‌های عصبی از طریق سازوکار یادگیری، قادر به شناسایی و بازنمایی روابط غیرخطی پیچیده میان متغیرهای ورودی و خروجی بوده و از این‌رو کاربرد گسترده‌ای در مدل‌سازی سامانه‌های پیچیده دارند [۲۶].




Figure 2. The designed sample of the ANN model.

شکل ۲- نمونه طراحی‌شده از مدل ANN

در این مطالعه، متغیرهای اقلیمی بارش و دما به‌عنوان داده‌های ورودی و رواناب به‌عنوان خروجی مدل شبکه عصبی در نظر گرفته شد. داده‌های مشاهداتی موجود به سه مجموعه مستقل شامل داده‌های آموزش (۷۰ درصد)،

15- Mean Absolute Error

16- Kling-Gupta Efficiency

17- Coefficient of Determination

12- Levenberg-Marquardt

13- Bias

14- Root Mean Square Error

آبریز خرم‌آباد مورد بررسی و ارزیابی قرار گرفته است و نتایج مربوطه در جدول‌های ۱ و ۲ آورده شده است:

همان‌طور که در جدول ۱ نشان داده شده است، اغلب مدل‌های اقلیمی در شبیه‌سازی بارش عملکرد به نسبت ضعیفی دارند، که با مقادیر پایین شاخص‌های NSE و R^2 و مقادیر بالای $RMSE$ قابل مشاهده است. این وضعیت بیانگر وجود عدم قطعیت ذاتی در پیش‌بینی‌های بارش توسط مدل‌های چرخه عمومی، به‌ویژه در مناطق نیمه‌خشک، می‌باشد.

با این حال، مدل IPSL-CM6A-LR با کمترین مقدار $RMSE$ (۱۵/۴۹) و بهترین مقادیر NSE (۰/۸۲) و KGE (۰/۸۶) به‌عنوان بهترین مدل در شبیه‌سازی بارش در این حوضه شناخته شد.

جدول ۱- عملکرد مدل‌های اقلیمی CMIP6 در شبیه‌سازی بارش

Table 1. CMIP6 climate models' performance in simulating historical precipitation

MODEL	RMSE	MAE	KGE	R^2	NSE
ACCESS-CM2	23.94	16.3	0.56	0.68	0.57
BCC-CSM2-MR	30.16	21.47	0.31	0.74	0.32
CAMS-CSM1-0	29.39	20.09	0.39	0.67	0.36
CanESM2	49.41	36.51	-0.26	0.28	-0.81
CESM2	36.76	24.66	0.15	0.5	0
CMCC-ESM2	49.05	36.46	-0.25	0.37	-0.79
FGOALS-f3-L	15.42	10.35	0.82	0.85	0.82
GFDL-ESM4	23.87	16.07	0.57	0.68	0.58
IITM-ESM	23.66	15.7	0.57	0.77	0.58
INM-CM5-0	45.58	35	-0.16	0.35	-0.54
IPSL-CM6A-LR	13.48	8.56	0.86	0.9	0.87
MIROC6	43.1	30.49	-0.06	0.38	-0.38
MPI-ESM1-2-HR	25.04	0.87	0.44	0.87	0.53

توسط مدل توضیح داده می‌شود به کار رفت، به طوری که مقادیر نزدیک به یک نشان‌دهنده قدرت توضیح‌دهندگی بالای مدل هستند.

در نهایت، ضریب نش-ساتکلیف^{۱۸} (NSE) مطابق با رابطه (۸) به منظور بررسی میزان انطباق بین داده‌های شبیه‌سازی شده و مشاهداتی محاسبه شد که مقادیر نزدیک به یک، بیانگر تطابق مطلوب مدل با داده‌های واقعی می‌باشد.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - S_i)^2} \quad (۴)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - S_i| \quad (۵)$$

$$KGE = 1 - \sqrt{(r-1)^2 + (\beta-1)^2 + (\gamma-1)^2} \quad (۶)$$

$$\beta = \frac{\bar{S}}{\bar{O}}$$

$$\gamma = \frac{SD_S}{SD_O}$$

$$r = \frac{\sum_{i=1}^N (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^N (S_i - \bar{S})^2}} \quad (۷)$$

$$R^2 = r^2$$

$$NSE = 1 - \frac{\sum_{i=1}^N (O_i - S_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (۸)$$

که در آن، N = تعداد کل مشاهدات/گام‌های زمانی؛ O_i = مقدار مشاهده شده در گام زمانی؛ S_i = مقدار پیش‌بینی شده در گام زمانی؛ \bar{O} = میانگین مقادیر مشاهده شده؛ \bar{S} = میانگین مقادیر پیش‌بینی شده، و SD_S و SD_O = به ترتیب انحراف معیار مقادیر مشاهده شده و پیش‌بینی شده، هستند.

۳- بحث و بررسی نتایج

۳-۱- ارزیابی مدل‌های اقلیمی CMIP6

در این بخش، توانایی ۱۴ مدل اقلیمی مجموعه CMIP6 در بازتولید مقادیر تاریخی بارش و دما در حوضه

¹⁸- Nash-Sutcliffe Efficiency

جدول ۳- تغییرات بارش ماهانه پیش‌بینی‌شده نسبت به دوره پایه

Table 3. Projected changes in monthly precipitation relative to the baseline period

Scenario	Time series	Average precipitation (mm)	Percentage change relative to the baseline period (43.41 mm)
SSP1-2.6	2040-2060	37.19	0.028
	2070-2099	33.41	-0.143
SSP5-8.5	2040-2060	34.33	-0.209
	2070-2099	35.01	-0.193

جدول ۴- تغییرات دمای ماهانه پیش‌بینی‌شده نسبت به دوره پایه

Table 4. Projected changes in monthly temperature relative to the baseline period

Scenario	Time series	Average temperature (°C)	Percentage change relative to the baseline period (16.79 °C)
SSP1-2.6	2040-2060	22.06	0.314
	2070-2099	22.43	0.336
SSP5-8.5	2040-2060	23.18	0.38
	2070-2099	25.36	0.51

نتایج در جدول ۳ نشان‌دهنده نوسانات قابل توجه بارش در SSP1-2.6 و SSP5-8.5 است. همچنین، همان‌طور که در جدول ۴ مشاهده می‌شود، پیش‌بینی‌های دما افزایش قابل توجهی را در هر دو سناریوی مذکور نشان می‌دهند. در ادامه، میانگین بلندمدت ماهانه بارش طی دوره مشاهداتی و تغییر اقلیم تحت SSP1-2.6 و SSP5-8.5 به ترتیب در شکل‌های ۳ و ۴ آورده شده است.

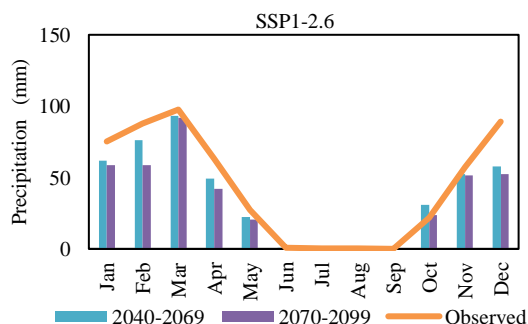


Figure 3. Long-term monthly average precipitation during the observed period and climate change under the SSP1-2.6 Scenario

شکل ۳- میانگین بلندمدت ماهانه بارش طی دوره مشاهداتی و تغییر اقلیم تحت سناریوی SSP1-2.6

جدول ۲- عملکرد مدل‌های اقلیمی CMIP6 در شبیه‌سازی دما

Table 1. CMIP6 climate models' performance in simulating historical Temperature

MODEL	RMSE	MAE	KGE	R ²	NSE
ACCESS-CM2	0.83	0.71	0.94	1	0.99
BCC-CSM2-MR	2.04	1.65	0.81	1	0.95
CAMS-CSM1-0	2.51	2.07	0.81	0.99	0.92
CanESM2	1.9	1.54	0.84	0.99	0.95
CESM2	7.82	7.61	0.52	0.99	0.24
CMCC-ESM2	7.98	7.85	0.52	1	0.21
FGOALS-f3-L	3.08	2.74	0.78	1	0.88
GFDL-ESM4	5.16	4.39	0.61	1	0.67
IITM-ESM	3.23	2.9	0.78	0.99	0.87
INM-CM5-0	4.66	3.85	0.7	0.96	0.73
IPSL-CM6A-LR	3.25	2.82	0.69	1	0.87
MIROC6	13	12.17	0.13	0.99	-1.1
MPI-ESM1-2-HR	3.49	2.78	0.71	1	0.85

در مقابل، نتایج ارائه‌شده در جدول ۲ عملکرد بسیار مطلوب مدل‌های اقلیمی در شبیه‌سازی دمای تاریخی را نشان می‌دهد. بیش‌تر مدل‌ها دارای مقادیر R^2 نزدیک به ۱، مقادیر بالای NSE و $RMSE$ پایین هستند که بیانگر دقت بالای آن‌ها در بازتولید الگوهای دمایی منطقه‌ای می‌باشد. این یافته‌ها نشان می‌دهند که مدل‌های اقلیمی در پیش‌بینی دما نسبت به بارش، قابلیت اطمینان بیشتری دارند. در این میان، مدل ACCESS-CM2 با کم‌ترین $RMSE$ (۰/۸۳) و بالاترین NSE (۰/۹۹) به‌عنوان بهترین مدل برای شبیه‌سازی دما در حوضه خرم‌آباد انتخاب شد.

۲-۳- پیش‌بینی اقلیم آینده برای حوضه خرم‌آباد

با بهره‌گیری از مدل‌های اقلیمی منتخب، تغییرات آبی بارش و دما برای دو دوره زمانی ۲۰۴۰-۲۰۶۹ و ۲۰۷۰-۲۰۹۹ تحت سناریوهای SSP1-2.6 (خوش‌بینانه) و SSP5-8.5 (بدبینانه) پیش‌بینی شد، که نتایج مربوطه در جداول ۳ و ۴ ارائه شده است.




Figure 6. Long-term monthly average temperature during observed period and climate change under the SSP5-8.5

شکل ۶- میانگین بلندمدت ماهانه دما طی دوره مشاهداتی و تغییر اقلیم تحت SSP5-8.5

بررسی نتایج نمایش داده شده در شکل‌های ۵ و ۶ حاکی از افزایش قابل توجه دما در هر دو سناریوی SSP1-2.6 و SSP5-8.5 است. با این حال، شدت این روند افزایشی در سناریوی بدبینانه SSP5-8.5 به مراتب بیشتر بوده و به گونه‌ای است که در دوره بلندمدت ۲۰۷۰-۲۰۹۹ میانگین دما تا حدود ۵۱ درصد نسبت به دوره پایه افزایش می‌یابد. این افزایش محسوس دما می‌تواند موجب تشدید فرآیند تبخیر و تفرق شده و در نتیجه حتی در شرایط تغییرات محدود بارش نیز به کاهش رواناب و افت منابع آب سطحی منجر شود.

۳-۳- مقایسه عملکرد ANN و MR

عملکرد ANN و MR در شبیه‌سازی رواناب مشاهداتی مقایسه شده است که نتایج مربوطه در جدول ۵ آورده شده است:

جدول ۵- معیارهای عملکرد مدل ANN و MR

Table 5. ANN and MR model performance metrics in training, validation, and testing periods

Index	MR	ANN
RMSE	4.63	3.56
MAE	3.26	2.43
KGE	0.56	0.70
R ²	0.35	0.58
NSE	0.28	0.58




Figure 4. Long-term monthly average precipitation during the observed period and climate change under the SSP5-8.5 Scenario

شکل ۴- میانگین بلندمدت ماهانه بارش طی دوره مشاهداتی و تغییر اقلیم تحت سناریوی SSP5-8.5

براساس نتایج ارائه شده در شکل ۳، در سناریوی خوش بینانه SSP1-2.6 تغییرات بارش به نسبت محدود بوده و کاهش‌های خفیفی به طور عمده در برخی ماه‌ها مشاهده می‌شود. در مقابل، در سناریوی بدبینانه SSP5-8.5 شدت تغییرات بارش بیش‌تر است؛ به طوری که مطابق شکل ۴، در دوره بلندمدت ۲۰۷۰-۲۰۹۹ کاهش بارش در ماه‌های خشک سال برجسته‌تر شده و احتمال تشدید شرایط کم‌آبی و وقوع خشک‌سالی افزایش می‌یابد. هم‌زمانی این تغییرات با روند افزایشی دما می‌تواند اثرات تشدیدکننده‌ای بر کاهش رواناب و افت منابع آب سطحی در منطقه مورد مطالعه داشته باشد. در ادامه، میانگین بلندمدت ماهانه دما طی دوره مشاهداتی و تغییر اقلیم تحت سناریوهای SSP1-2.6 و SSP5-4.5 به ترتیب در شکل‌های ۵ و ۶ آورده شده است.




Figure 5. Long-term monthly average temperature during observed period and climate change under the SSP1-2.6

شکل ۵- میانگین بلندمدت ماهانه دما طی دوره مشاهداتی و تغییر اقلیم تحت SSP1-2.6

۴-۳- رواناب پیش‌بینی‌شده و تحلیل تطبیقی


با توجه به برتری عملکرد مدل ANN نسبت به مدل MR، پیش‌بینی‌های رواناب آینده مبتنی بر مدل ANN مطابق شکل‌های ۸ و ۹، قابلیت اطمینان بیشتری برخوردار است.

نتایج حاصل از این مدل بیان‌گر کاهش رواناب در هر دو سناریوی SSP1-2.6 و SSP5-8.5 می‌باشد، که این روند با کاهش پیش‌بینی‌شده بارش و افزایش دما سازگاری دارد. این یافته‌ها با نتایج مطالعات اخیر که کاهش رواناب را در حوضه‌های نیمه‌خشک ایران گزارش کرده‌اند، هم‌راستا است [۲۷].


در مقایسه با پژوهش‌های پیشین انجام‌شده در حوضه مورد مطالعه [۲۸] که از مدل آب‌شناسی IHACRES و سناریوهای اقلیمی قدیمی‌تر استفاده کرده‌اند، نتایج این تحقیق با اتکا به داده‌های به‌روز گزارش ششم IPCC (AR6) و مدل‌های CMIP6، الگوی کاهش رواناب را به‌صورت منسجم‌تر و قابل‌اعتمادتر نشان می‌دهد. این موضوع بیان‌گر آن است که سناریوهای جدید SSP و مدل‌های اقلیمی نسل جدید، درک دقیق‌تر و یک پارچه‌تری از اثرات تغییر اقلیم بر منابع آب ارائه می‌کنند. در مقابل، مدل MR به‌دلیل ناتوانی در بازنمایی روابط غیرخطی پیچیده و عدم‌پایداری ضرایب مرتبط با دما، گزینه مناسبی برای پیش‌بینی شرایط آینده محسوب نمی‌شود.

این مقایسه تطبیقی، برتری مدل‌های داده‌محور غیرخطی نظیر ANN را در تحلیل مسائل پیچیده آب‌شناسی به‌وضوح نشان داده و محدودیت‌های قابل‌توجه مدل‌های آماری خطی سنتی را در چنین کاربردهایی برجسته می‌سازد.

براساس جدول ۵، مدل ANN در مرحله آموزش با مقدار NSE برابر با ۰/۵۱ و ضریب همبستگی (r) معادل ۷۱/۷ درصد، توانایی قابل‌قبولی در یادگیری و بازنمایی ارتباط میان متغیرهای ورودی و خروجی از خود نشان داده است. هرچند کارایی مدل در مراحل اعتبارسنجی و آزمون با کاهش نسبی همراه بوده، اما مقادیر NSE به‌ترتیب برابر با ۰/۱۸ و ۰/۳۵ و ضرایب همبستگی بیش از ۵۰ درصد حاکی از عملکرد مطلوب آن بوده و نسبت به مدل MR برتری محسوسی دارد. در شکل ۷، روند این تغییرات رواناب در دوره واسنجی و صحت‌سنجی حاصل از ANN و MR به تصویر کشیده شده است. به‌طور کلی، نتایج نشان می‌دهند که مدل ANN قابلیت بالاتری در شبیه‌سازی فرآیندهای غیرخطی پیچیده آب‌شناسی دارد. علاوه‌بر این، نمودارهای مقایسه رواناب شبیه‌سازی‌شده و مشاهداتی از تطابق مناسب بین داده‌ها حکایت داشته و اعتبار استفاده از این مدل را در پیش‌بینی شرایط آینده تأیید می‌کند.



(a)



(b)

Figure 7. Trends in changes for runoff in the period of calibration and verification resulted from (a) ANN and (b) MR

شکل ۷- روند تغییرات رواناب در دوره واسنجی و صحت‌سنجی

حاصل از (الف) ANN و (ب) MR

بر این اساس، اتخاذ راه‌بردهای انطباقی از جمله بهینه‌سازی الگوی مصرف آب، ارتقای راندمان سامانه‌های آبیاری و توسعه زیرساخت‌های مرتبط با مدیریت سیلاب و خشک‌سالی، امری ضروری به‌نظر می‌رسد.

افزون بر این، نتایج مطالعه حاضر بر اهمیت استقرار و تقویت سامانه‌های هشدار زود هنگام سیلاب و خشک‌سالی به‌منظور کاهش خسارات احتمالی و افزایش تاب‌آوری منطقه در برابر تغییرات اقلیمی تأکید دارد.

۴- نتیجه‌گیری

نتایج این پژوهش نشان دادند که مدل‌های اقلیمی CMIP6 به‌کاررفته در گزارش ششم IPCC از دقت بالایی در بازتولید دمای تاریخی حوضه آبریز خرم‌آباد برخوردارند، در حالی که شبیه‌سازی بارش با عدم قطعیت بیش‌تری همراه است.

براساس خروجی‌های اقلیمی تحت سناریوهای SSP1-2.6 و SSP5-8.5، روند افزایشی معنی‌داری در دما و کاهش میانگین بارش برای دهه‌های آینده پیش‌بینی می‌شود که شدت این تغییرات در سناریوی بدبینانه SSP5-8.5 به‌مراتب بیش‌تر است.

بررسی نتایج شبیه‌سازی رواناب با استفاده از مدل‌های داده‌محور نشان داد که ANN در مقایسه با مدل MR، توانمندی بالاتری در برآورد رواناب داشته و قادر است روابط غیرخطی پیچیده میان بارش، دما و رواناب را با دقت بیش‌تری بازنمایی کند.

پیش‌بینی‌های مبتنی بر مدل ANN بیانگر کاهش رواناب و تشدید تنش آبی در آینده حوضه خرم‌آباد است؛ موضوعی که می‌تواند پیامدهای مستقیمی برای تأمین آب شرب، کشاورزی و مسیر توسعه پایدار منطقه به‌همراه داشته باشد.

یافته‌های این مطالعه بر ضرورت بازنگری در سیاست‌های مدیریت منابع آب تأکید دارد، به‌گونه‌ای که راه‌بردهای انطباقی نظیر بهینه‌سازی مصرف آب، ارتقای بهره‌وری سامانه‌های آبیاری، توسعه زیرساخت‌های مدیریت




Figure 8. Long-term monthly average runoff during the observed period and climate change periods in the ANN under the SSP1-2.6 scenario

شکل ۸- میانگین بلندمدت ماهانه رواناب طی دوره مشاهداتی و دوره‌های تغییر اقلیم در ANN با سناریوی SSP1-2.6

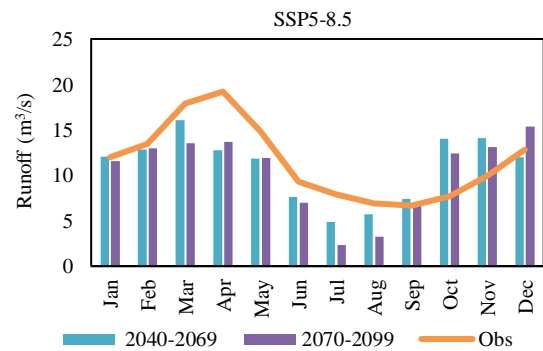


Figure 9. Long-term monthly average runoff during the observed period and climate change periods in the ANN under the SSP5-8.5 scenario

شکل ۹- میانگین بلندمدت ماهانه رواناب طی دوره مشاهداتی و دوره‌های تغییر اقلیم در ANN با سناریوی SSP5-8.5

نتایج حاصل از این پژوهش دارای پیامدهای قابل توجهی برای برنامه‌ریزی و مدیریت منابع آب در حوضه آبریز خرم‌آباد می‌باشد.

کاهش پیش‌بینی شده رواناب بیانگر افزایش فشار بر منابع آب سطحی و زیرزمینی منطقه است که می‌تواند به تشدید خشک‌سالی‌های آب‌شناسی و کشاورزی، افزایش نیاز آبی بخش کشاورزی و کاهش بهره‌وری محصولات منجر شود.

تداوم چنین شرایطی زمینه‌ساز بروز چالش‌های اجتماعی و اقتصادی در سطح منطقه خواهد بود.

هستند، دوچندان می‌شود. در چنین مناطقی، استفاده از مدل‌های دقیق و جامع می‌تواند به شناسایی نقاط بحرانی، پیش‌بینی روندهای آینده و طراحی سیاست‌های سازگاری مؤثر کمک کند. همچنین، نتایج به‌دست‌آمده بر ضرورت همکاری میان پژوهشگران، سیاست‌گذاران و مدیران منابع آب تأکید دارد تا بتوان با اتخاذ رویکردهای علمی و عملی، اثرات منفی تغییر اقلیم را کاهش داد و مسیر توسعه پایدار را هموارتر ساخت.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت نموده و این موضوع مورد تأیید ایشان است.

مشارکت نویسندگان

مهديه کلهری محاسبات را انجام داد. گلناز امیری روش‌های تحلیلی را تأیید کرد، عماد کهریزی بر یافته‌های این پژوهش نظارت داشت، مژگان یاراحمدی نتایج را بحث نمود و در نسخه نهایی مقاله مشارکت داشت.

تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.

حامی مالی

این پژوهش هیچ‌گونه کمک هزینه خاصی دریافت نکرده است.

سپاسگزاری

از داوران محترم به‌خاطر ارائه نظرهای ساختاری و علمی سپاسگزاری می‌شود.

خشک‌سالی و سیلاب و استقرار سامانه‌های هشدار زودهنگام در اولویت قرار گیرند.

افزون بر این، نتایج نشان می‌دهند که به‌کارگیری داده‌های به‌روز IPCC AR6، سناریوهای SSP و مدل‌های داده‌محور غیرخطی نظیر ANN می‌تواند به ارائه برآوردهایی منسجم‌تر و قابل اعتمادتر نسبت به رویکردهای قدیمی منجر شود.

با این حال، باید توجه داشت که مدل‌های یادگیری ماشین، علی‌رغم توانایی‌های چشمگیر در تحلیل داده‌های پیچیده و استخراج الگوهای پنهان، همچنان با محدودیت‌هایی جدی در بازنمایی مقادیر حدی و شبیه‌سازی جریان‌های اوج مواجه هستند. این محدودیت‌ها به‌ویژه در شرایطی که داده‌های تاریخی ناکافی یا پراکنده باشند، می‌تواند منجر به کاهش دقت نتایج و افزایش عدم قطعیت در پیش‌بینی‌ها شود. از این‌رو، پیشنهاد می‌شود که در پژوهش‌های آتی، به‌جای اتکا صرف به مدل‌های داده‌محور، از رویکردهای ترکیبی که تلفیقی از مدل‌های فیزیکی و داده‌محور هستند استفاده گردد. چنین رویکردی می‌تواند با بهره‌گیری از اصول علمی و قوانین فیزیکی در کنار قدرت یادگیری ماشین، توانایی مدل‌ها را در شناسایی و بازنمایی شرایط حدی به‌طور قابل توجهی افزایش دهد. علاوه بر این، استفاده از رویکردهای چندسناریویی که طیف وسیعی از شرایط اقلیمی و آب‌شناسی را در نظر می‌گیرند، می‌تواند به کاهش عدم قطعیت و ارتقای قابلیت اعتماد نتایج کمک کند. این راه‌کارها نه تنها موجب افزایش دقت پیش‌بینی‌ها خواهند شد، بلکه امکان ارائه راه‌بردهای مدیریتی کارآمدتر برای مواجهه با شرایط بحرانی را نیز فراهم می‌سازند.

به‌طور کلی، نتایج این پژوهش نشان می‌دهد که بهره‌گیری از مدل‌های پیشرفته اقلیمی و آب‌شناسی، به همراه برنامه‌ریزی هدفمند و مبتنی بر شواهد علمی، نقشی اساسی در کاهش اثرات تغییر اقلیم ایفا می‌کند. این اهمیت به‌ویژه در حوضه‌های نیمه‌خشک ایران که با محدودیت منابع آب و آسیب‌پذیری بالا در برابر تغییرات اقلیمی مواجه

References

- [1] Li B, Rodell M. How have hydrological extremes changed over the past 20 years. *Journal of Climate*. 2023; 36: 8581-8599. <https://doi.org/10.1175/JCLI-D-23-0199.1>.
- [2] Allafta H, Opp C. Climate change paradox: the least responsible for it encounters the most of its implications. *Climate*. 2024; 12: 38. <https://doi.org/10.3390/cli12030038>.
- [3] Jafarpour M, Adib A, Lotfirad M, Kisi O. Spatial evaluation of climate change-induced drought characteristics in different climates based on De Martonne aridity index in Iran. *Applied Water Science*. 2023; 13: 133. <https://doi.org/10.1007/s13201-023-01939-w>.
- [4] Amiri SN, Khoshravesh M, Valashedi RN. Assessing the effect of climate and land use changes on hydrologic regimes in the upstream of Tajan River Basin using SWAT model. *Applied Water Science*. 2023; 13: 130. <https://doi.org/10.1007/s13201-023-01932-3>.
- [5] Ashofteh PS, Kalhori M, Singh VP. Water resources management considering groundwater instability affected by climate change scenarios. *Physics and Chemistry of the Earth*. 2024; 135: 103606. <https://doi.org/10.1016/j.pce.2024.103606>.
- [6] Intergovernmental Panel on Climate Change. *Climate Change 2022: Impacts, Adaptation and Vulnerability. Working Group II Contribution to the Sixth Assessment Report*. Cambridge: Cambridge University Press; 2023. <https://doi.org/10.1017/9781009325844>.
- [7] Zareian MJ, Dehban H, Gohari A, Torabi Haghghi A. Assessment of CMIP6 models performance in simulating precipitation and temperature over Iran and surrounding regions. *Environmental Monitoring and Assessment*. 2024; 196: 701. <https://doi.org/10.1007/s10661-024-12878-7>.
- [8] Azad N, Ahmadi A. Assessment of CMIP6 models and multi-model averaging for temperature and precipitation over Iran. *Scientific Reports*. 2024; 14: 24165. <https://doi.org/10.1038/s41598-024-74789-4>.
- [9] Mollel GR, Mulungu DMM, Nobert J, Alexander AC. Assessment of climate change impacts on hydrological processes in the Usangu catchment of Tanzania under CMIP6 scenarios. *Journal of Water and Climate Change*. 2023; 14: 4162-4182. <https://doi.org/10.2166/wcc.2023.542>.
- [10] Jimenez Osorio DA, Menapace A, Zanfei A, et al. Statistical and machine learning downscaling methods to assess changes in rainfall amounts and frequency under climate change (CMIP6). *Hydrology and Earth System Sciences*. 2024; 28: 1981-1998. <https://doi.org/10.5194/hess-28-1981-2024>.
- [11] Meer MS. A review on enhancing flood mitigation strategies: a comparative study of SCS-CN and ANN model integration with GIS for rainfall-runoff simulation. *Water Conservation Science and Engineering*. 2025; 10(2): 51. <https://doi.org/10.1007/s41101-025-00369-w>.
- [12] Dalavi P, Bhakar SR, Rajput J, et al. Modeling runoff in Bhima River catchment, India: comparison of artificial neural networks and empirical models. *Water Practice and Technology*. 2024; 19(7): 2595-2612. <https://doi.org/10.2166/wpt.2024.157>.
- [13] Rampal N, Hobeichi S, Gibson PB, et al. Enhancing regional climate downscaling through advances in machine learning. *Artificial Intelligence for the Earth Systems (AIES)*. 2024; 3: 230066. <https://doi.org/10.1175/AIES-D-23-0066.1>.
- [14] Hernanz A, García-Valero JA, Domínguez M, Rodríguez-Camino E. A critical view on the suitability of machine learning techniques to downscale climate change projections. *Atmospheric Science Letters*. 2022; 23: e1087. <https://doi.org/10.1002/asl.1087>.
- [15] Tabari H, Paz SM, Buekenhout D, Willems P. Comparison of statistical downscaling methods for climate change impact analysis on precipitation-driven drought. *Hydrology and Earth System Sciences*. 2021; 25: 3493-3517. <https://doi.org/10.5194/hess-25-3493-2021>.
- [16] Yousefi S, Pourghasemi HR, Emami SN, et al. A machine learning framework for multi-hazards modeling and mapping in a mountainous area. *Scientific Reports*. 2020; 10: 12144. <https://doi.org/10.1038/s41598-020-69233-2>.

- [17] Zhang Y, Chiew FHS, Li M, Post D. Predicting runoff signatures using regression and hydrological modeling approaches. *Water Resources Reserch*. 2018; 54: 7859-7878. <https://doi.org/10.1029/2018WR023325>.
- [18] Khan M, Khan AU, Khan S, Khan FA. Assessing the impacts of climate change on streamflow dynamics: a machine learning perspective. *Water Science and Technology*. 2023; 88: 2309-2331. <https://doi.org/10.2166/wst.2023.340>.
- [19] Sharma N, Zakaullah M, Tiwari H, Kumar D. Runoff and sediment yield modeling using ANN and support vector machines: a case study from Nepal watershed. *Modeling Earth Systems and Environment*. 2015; 1: 23. <https://doi.org/10.1007/s40808-015-0027-0>.
- [20] Esmaeili-Gisavandani H, Zarei H, Fadaei Tehrani MR. Regional flood frequency analysis using data-driven models and multiple regression in ungauged catchments. *Applied Water Science*. 2023; 13: 139. <https://doi.org/10.1007/s13201-023-01940-3>.
- [21] Al-Nouti AF, Fu M, Bokde ND. Reservoir operation-based machine learning models: a comprehensive review. *Knowledge-Based Systems*. 2024; 5: 75-139. <https://doi.org/10.51526/kbes.2024.5.2.75-139>.
- [22] Raju KS, Kumar DN. Review of approaches for selection and ensembling of GCMs. *Journal of Water and Climate Change*. 2020; 11: 577-599. <https://doi.org/10.2166/wcc.2020.128>.
- [23] Rabezanahary Tanteliniaina MF, Rahaman MH, Zhai J. Assessment of future climate change impacts on hydrology using ANN and SWAT. *Water*. 2021; 13: 1239. <https://doi.org/10.3390/w13091239>.
- [24] Meinshausen M, Nicholls ZRJ, Lewis J, et al. The shared socio-economic pathway (SSP) greenhouse gas concentrations and their extensions to 2500. *Geoscientific Model Development*. 2020; 13: 3571-3605. <https://doi.org/10.5194/gmd-13-3571-2020>.
- [25] Ekwueme BN, Agunwamba JC. Modeling the influence of meteorological variables on runoff in a tropical watershed. *Civil Engineering Journal*. 2020; 6: 2344-2351. <https://doi.org/10.28991/cej-2020-03091621>.
- [26] Kapucu C, Akpolat O. Artificial neural network parameter optimization for meteorological data prediction. *Journal of Artificial Intelligence Research (JAIR)*. 2024; 4: 53-61. <https://doi.org/10.54569/aair.1535217>.
- [27] Bagheri Khanghahi M, Hazar Jaribi A, Kamali MI, Zamani F. Forecasting rainfall in different climatic regions of Iran using the LARS WG7 climate model. *Water Resources and Climate Change*. (2025); 1(1): 28-39. <https://doi.org/10.22091/wrcc.2025.11744.1008>.
- [28] Kalhori M, Ashofteh PS, Moghadam SH, Singh VP. Investigating the effect of uncertainty of AOGCM-TAR and AOGCM-AR5 climate change models on river runoff. *Arabian Journal of Geosciences*, 2022; 15(13): 1198. <https://doi.org/10.1007/s12517-022-10471-1>.