



Assessment of Flood Vulnerability in the Face of Future Climate Change: An Integrated Approach Using CMIP6 Models, Machine Learning, and Remote Sensing

Saeedeh Fakhari¹, Zahra Sedighifar^{2*}, Ali Reza Karbalaee³, Junye Wang⁴

¹ Department of Geography & Tourism, Faculty of Geographical Sciences, Kharazmi University, Tehran, Iran

² Department of Geomorphology, Faculty of Geographical Sciences, Kharazmi University, Tehran, Iran

³ Department of Climatology, Faculty of Geographical Sciences, Kharazmi University, Tehran, Iran

⁴ Faculty of Science and Technology, Athabasca University, Athabasca, AB, T9S 3A3, Canada

Article Info	Abstract
Article History: Received: 25 August 2026 Revised: 08 October 2026 Accepted: 10 October 2026 Available online: 10 October 2026	The increasing frequency of floods driven by global warming and anthropogenic interventions poses a growing challenge. To address this issue, the present study investigates the impacts of future climate change scenarios on flood vulnerability in the Qareh-Sou watershed, Iran. To this end, an integrated approach combining machine learning algorithms, CMIP6 climate models, and remote sensing techniques was employed. Due to its superior accuracy among global models, the MPI-ESM1-2-HR climate model was selected to estimate precipitation trends under the Shared Socioeconomic Pathways (SSP1-2.6, SSP2-4.5, and SSP5-8.5) across two future time horizons: the mid-future (2041–2070) and the far-future (2071–2100). These scenarios encompass key variables, such as greenhouse gas emissions, urbanization, and land use changes, which play a crucial role in modulating flood susceptibility. Flood susceptibility mapping was conducted using Random Forest (RF) and Support Vector Machine (SVM) algorithms, utilizing 320 flood inventory points alongside 16 environmental and climatic conditioning factors. The predictive accuracy of the models was evaluated using the Area Under the Receiver Operating Characteristic Curve (ROC-AUC). The results demonstrated the outstanding performance of the RF model; by achieving an AUC of 94.75% during the validation phase and maintaining an accuracy exceeding 90% across all future time horizons and scenarios, this algorithm exhibited absolute superiority over the SVM model. These findings are vital for effective flood risk management.
Keywords: Flood Hazard Mapping Climate Change Scenarios CMIP6 Random Forest (RF) Support Vector Machine (SVM)	

*Corresponding author: Zahra Sedighifar

E-mail address: Zsedighifar@gmail.com

How to cite this article: Fakhari, S., Sedighifar, Z., Karbalaee, A. R., & Wang, J. (2025). Assessment of Flood Vulnerability in the Face of Future Climate Change: An Integrated Approach Using CMIP6 Models, Machine Learning, and Remote Sensing. *Journal of Geography and Environmental Hazards*, ?(?), ?-?. <https://doi.org/10.22067/geoe.2026.100637.1697>



©2026 The author(s). This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0)

Extended Abstract

Introduction

In recent years, the frequency and intensity of flood events have escalated globally due to anthropogenic climate change and alterations in land use patterns. These extreme hydrological events pose severe threats to critical infrastructure, ecosystems, and human safety, resulting in substantial economic losses annually. Developing nations, in particular, face heightened vulnerability due to limited resources and adaptive capacity. The Intergovernmental Panel on Climate Change (IPCC) reports that shifting precipitation patterns are intensifying atmospheric systems, leading to more frequent flash floods. Consequently, understanding and modeling basin-scale flood dynamics is essential for effective risk management and preventive action. The advent of the Coupled Model Intercomparison Project Phase 6 (CMIP6) and Shared Socioeconomic Pathways (SSPs) has revolutionized environmental hazard assessment by providing more realistic scenarios of future greenhouse gas emissions and socioeconomic development. However, uncertainties associated with downscaling methods and bias correction necessitate robust multi-index evaluation approaches. Furthermore, integrating Remote Sensing (RS), Geographic Information Systems (GIS), and Machine Learning (ML) algorithms—such as Random Forest (RF) and Support Vector Machine (SVM)—has emerged as a powerful methodology for identifying critical flood-prone areas. Despite these advancements, there remains a knowledge gap in simultaneously assessing the impacts of SSP scenarios and data-driven models in susceptible basins in western Iran. Therefore, this study aims to comprehensively evaluate the effects of climate change on flood susceptibility in the Qareh-Sou River Basin using CMIP6 scenarios (SSP1-2.6, SSP2-4.5, and SSP5-8.5). The primary objective is to quantify and map changing flood hazards under mid-future (2041–2070) and far-future (2071–2100) horizons to provide actionable insights for water resource management and disaster risk reduction. The advent of the Coupled Model Intercomparison Project Phase 6 (CMIP6) and Shared Socioeconomic Pathways (SSPs) has revolutionized environmental hazard assessment by providing more realistic scenarios of future greenhouse gas emissions and socioeconomic development. However, uncertainties associated with downscaling methods and bias correction necessitate robust multi-index evaluation approaches. Furthermore, integrating Remote Sensing (RS), Geographic Information Systems (GIS), and Machine Learning (ML) algorithms—such as Random Forest (RF) and Support Vector Machine (SVM)—has emerged as a powerful methodology for identifying critical flood-prone areas. Despite these advancements, there remains a knowledge gap in simultaneously assessing the impacts of SSP scenarios and data-driven models in susceptible basins in western Iran. Therefore, this study aims to comprehensively evaluate the effects of climate change on flood susceptibility in the Qareh-Sou River Basin using CMIP6 scenarios (SSP1-2.6, SSP2-4.5, and SSP5-8.5). The primary objective is to quantify and map changing flood hazards under mid-future (2041–2070) and far-future (2071–2100) horizons to provide actionable insights for water resource management and disaster risk reduction. Given the complex nature of flood phenomena, the integration of machine learning algorithms, such as Random Forest (RF) and Support Vector Machine (SVM), with remote sensing (RS) data provides an innovative approach for the multidimensional and accurate assessment of flood vulnerability (Chen et al., 2024; Hooshyaripor et al., 2024). This integrated data- and model-based framework enhances the ability to capture nonlinear relationships among the natural and anthropogenic factors influencing flood occurrence and substantially improves predictive accuracy compared with conventional statistical methods (Kazemi et al., 2024; Wang et al., 2025). The implementation of this research is expected to contribute not only to the scientific advancement of flood risk management but also to practical decision-making and policy development. The findings can provide a scientific basis for decision-making by key governmental organizations, including the Ministry of Energy, the National Disaster Management Organization, and the Ministry of Agriculture Jihad, particularly in climate change adaptation planning, the development of flood-resilient infrastructure, and the formulation of comprehensive policies aimed at reducing vulnerability in high-risk areas (Khodaei et al., 2025; Naderi et al., 2025).

Material and Methods

This study employs an integrated approach combining climate modeling, remote sensing, and machine learning. The study area is the Qareh-Sou River Basin in Kermanshah Province, western

Iran. First, 320 historical flood and non-flood points were extracted using Sentinel-1 SAR imagery via Google Earth Engine and validated through field surveys. Sixteen effective environmental and climatic factors (including topography, hydrology, geology, and land use) were identified and processed into 30-meter raster layers. Multicollinearity among these factors was assessed using Variance Inflation Factor (VIF) and Tolerance (TOL) tests to ensure model stability. For climate projections, the MPI-ESM1-2-HR model from the CMIP6 ensemble was selected based on its superior performance in simulating historical precipitation trends compared to observational data from Kermanshah and Ravansar synoptic stations. Bias correction and statistical downscaling were performed using the Distribution Mapping (DM) method. Future precipitation trends were analyzed under three SSP scenarios (SSP1-2.6, SSP2-4.5, and SSP5-8.5) for two time horizons: mid-future (2041–2070) and far-future (2071–2100). Flood susceptibility maps were generated using two machine learning algorithms: Random Forest (RF) and Support Vector Machine (SVM). The dataset was randomly split into training (70%) and validation (30%) subsets. Model performance was evaluated using several statistical metrics, including the Area Under the Receiver Operating Characteristic Curve (ROC-AUC), Positive Predictive Value (PPV), Negative Predictive Value (NPV), Sensitivity, Specificity, and Root Mean Square Error (RMSE).

Results and Discussion

The multicollinearity test confirmed the independence of the 16 input factors ($VIF < 10$; $TOL > 0.1$). Among the climate models, MPI-ESM1-2-HR demonstrated the highest accuracy (lowest RMSE and highest R^2) after bias correction, as validated by Taylor diagrams and statistical indices. Climate projections indicate a significant increase in annual precipitation volume and extreme rainfall events, particularly in the far-future horizon under the SSP5-8.5 scenario. For instance, precipitation in the Ravansar station is projected to more than double under SSP5-8.5 by 2100. In terms of flood susceptibility modeling, the RF algorithm outperformed SVM significantly. During the validation phase, RF achieved an ROC-AUC of 94.75%, with high sensitivity (91.89%) and specificity (84.62%), whereas SVM yielded a lower AUC of 72.35%. The RF model also maintained exceptional stability across all future scenarios, with AUC values consistently exceeding 90%. In contrast, SVM showed moderate performance with higher RMSE values. Spatial analysis revealed that under the mid-future horizon, the SSP1-2.6 scenario unexpectedly resulted in a wider spatial extent of high-risk areas due to the alignment of precipitation patterns with local topography. However, in the far-future horizon (2071–2100) under the pessimistic SSP5-8.5 scenario, both models predicted a dramatic expansion of high and very high susceptibility classes. Approximately 47–48% of the basin's total area is projected to fall into critical risk categories, with flood-prone zones expanding from lowland plains into mountainous and foothill regions. This shift is attributed to the intensification of extreme rainfall events interacting with steep slopes and impermeable surfaces.

Conclusion

This study demonstrates that climate change will significantly exacerbate flood risks in the Qareh-Sou River Basin, particularly under high-emission scenarios. The Random Forest model proved to be a superior tool for flood susceptibility mapping compared to SVM, offering higher accuracy and stability in handling complex, non-linear relationships between climatic and environmental variables. The findings highlight a critical transition in flood hazard patterns by the end of the century, where risk extends beyond traditional riverine corridors into upstream areas. These results underscore the urgent need for proactive risk management strategies, including improved urban planning, watershed management, and engineering interventions, to enhance resilience against future climate-induced flooding. Policymakers and stakeholders should prioritize adaptive measures based on these high-resolution susceptibility maps to mitigate potential catastrophic losses.

Acknowledgements

This work is based upon research funded by the Iran National Science Foundation (INSF) under project No. 40402705.



ارزیابی آسیب پذیری ناشی از سیلاب در مواجهه با تغییرات اقلیمی آینده: رویکردی تلفیقی از مدل‌های CMIP6، یادگیری ماشین و سنجش از دور

سعیده فخاری^۱، زهرا صدیقی فر^{۲*}، علیرضا کربلائی^۳، جونی وانگ^۴

^۱ گروه گردشگری، دانشکده علوم جغرافیایی، دانشگاه خوارزمی، تهران، ایران
^۲ گروه ژئومورفولوژی، دانشکده علوم جغرافیایی، دانشگاه خوارزمی، تهران، ایران
^۳ گروه آب و هواشناسی، دانشکده علوم جغرافیایی، دانشگاه خوارزمی، تهران، ایران
^۴ گروه علوم محیطی، دانشکده علوم و فناوری، دانشگاه آتاباسکا، آتاباسکا، آلبرتا، کانادا

اطلاعات مقاله چکیده

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۵/۰۶/۰۳

تاریخ بازنگری: ۱۴۰۵/۰۷/۱۶

تاریخ پذیرش: ۱۴۰۵/۰۷/۱۸

کلمات کلیدی:

نقشه برداری خطرپذیری سیلاب

سناریوی تغییرات اقلیمی

فاز ۶ پروژه مقایسه متقابل مدل جفت شده (CMIP6)

جنگل تصادفی (RF)

ماشین بردار پشتیبان (SVM)

افزایش فراوانی سیلاب‌ها در پی گرمایش جهانی و مداخلات انسانی، چالشی فزاینده محسوب می‌شود. مطالعه حاضر با هدف پرداختن به این چالش، به بررسی چگونگی تأثیر سناریوهای تغییرات اقلیمی آینده بر آسیب پذیری سیل در حوزه آبخیز قره سو، در ایران می‌پردازد. بدین منظور، از تلفیق الگوریتم‌های یادگیری ماشین، مدل‌های اقلیمی CMIP6 و تکنیک‌های سنجش از دور بهره گرفته شد. مدل اقلیمی MPI-ESM1-2-HR به دلیل دقت برتر در میان مدل‌های جهانی، جهت برآورد روندهای بارش تحت مسیرهای اجتماعی-اقتصادی SSP1-2.6، SSP2-4.5 و SSP5-8.5 در دو افق زمانی میانی (۲۰۴۱-۲۰۷۰) و دور (۲۰۷۱-۲۱۰۰) انتخاب گردید. این سناریوها متغیرهای کلیدی نظیر انتشار گازهای گلخانه‌ای، و گسترش شهرنشینی که در تعدیل حساسیت سیلاب مؤثرند، دربر می‌گیرند. ارزیابی حساسیت با الگوریتم‌های جنگل تصادفی (RF) و ماشین بردار پشتیبان (SVM)، مبتنی بر ۳۲۰ نقطه سیلاب و ۱۶ عامل محیطی و اقلیمی انجام شد. دقت پیش‌بینی مدل‌ها با شاخص سطح زیر منحنی (ROC-AUC) ارزیابی گردید. نتایج حاکی از عملکرد درخشان مدل RF بود، به طوری‌که این الگوریتم با ثبت AUC معادل ۰.۹۴۷۵ در مرحله اعتبارسنجی و حفظ دقت بالای ۹۰٪ در کلیه افق‌های زمانی و سناریوهای آینده، برتری مطلق نسبت به مدل SVM از خود نشان داد. این یافته‌ها برای مدیریت ریسک سیلاب حیاتی است.

مقدمه

سیلاب به عنوان یکی از مخرب ترین مخاطرات طبیعی، به دلیل تغییرات اقلیمی و دگرگونی چرخه هیدرولوژیکی، ابعاد گسترده تر و مخرب تری یافته است. افزایش چشمگیر شدت، تداوم و فراوانی بارش های حدی^۱، زیرساخت های حیاتی و اکوسیستم ها را به شدت با چالش مواجه کرده است (Ullah et al., 2025). در نتیجه، این حوادث سالانه میلیاردها دلار خسارت اقتصادی به همراه داشته و جان میلیون ها انسان را به خطر می اندازند (Hooshyaripor, Faraji-Ashkavar, Koohyian, Tang & Noori, 2020). تغییر اقلیم اثرات پیچیده و ناهمگونی بر توازن هیدرولوژیکی حوضه های آبریز دارد (Reshmidevi, Kumar, Mehrotra & Sharma, 2018) که در این میان، کشورهای درحال توسعه به دلیل محدودیت منابع و ضعف مدیریتی، آسیب پذیری بسیار بیشتری در برابر این پیامدها دارند. طبق گزارش IPCC، تغییر الگوهای بارش باعث تشدید سامانه های جوی و افزایش شدت وقوع سیلاب های ناگهانی^۲ شده است (Arnell & Gosling, 2016). به همین دلیل، مطالعات نوین تأکید دارند که درک و مدل سازی پویایی سیلاب ها در مقیاس حوضه ای، گامی ضروری برای مدیریت ریسک و اقدامات پیشگیرانه است (Maghsood et al., 2019). نسل جدید مدل های اقلیمی (CMIP6) و سناریوهای مشترک اقتصادی-اجتماعی (SSPs)، تحولی بنیادین در ارزیابی مخاطرات محیطی ایجاد کرده اند (Asencios, Lavado & Sabino, 2023). این سناریوها با در نظر گرفتن متغیرهای واقع بینانه تر توسعه و انتشار گازها، چشم اندازهای دقیق تری از آینده اقلیمی ارائه می دهند (Szczurek, Gonstał & Maciejewska, 2023). پژوهش ها نشان می دهد که مدل های CMIP6 به دلیل ساختار پویاتر و تفکیک مکانی بالاتر، در برآورد بارش های حدی و جریان های سطحی نسبت به نسل های پیشین (CMIP3 و CMIP5) بسیار قابل اعتمادترند (Ullah et al., 2025). با این وجود، عدم قطعیت های ناشی از روش های ریزمقیاس نمایی و ضرورت اعمال تکنیک های تصحیح اریب^۳، همچنان استفاده از رویکردهای ارزیابی چند شاخصه را الزامی می سازد. نقشه برداری و ارزیابی پتانسیل حساسیت به سیل^۴ با ترکیب فناوری های RS، GIS و الگوریتم های ML به رویکردی کارآمد برای شناسایی مناطق بحرانی تبدیل شده است (Khosravi et al., 2018; Nguyen et al., 2022). الگوریتم هایی نظیر جنگل تصادفی^۵ و ماشین بردار پشتیبان^۶، به دلیل توانمندی بالا در تحلیل روابط پیچیده و غیرخطی متغیرهای محیطی، جایگزین های بسیار مناسبی برای مدل های سنتی به شمار می روند (Abedi, Costache, Shafizadeh-Moghadam & Pham, 2022; Liu et al., 2022; Hooshyaripor, Faraji-Ashkavar, Koohyian, Tang & Noori, 2024). همچنین، پژوهش های اخیر نشان می دهند که حرکت به سمت مدل سازی های چند رویدادی^۷ و تلفیق متغیرهای پویای اقلیمی با عوامل ثابت محیطی، دقت و اعتبار نقشه های پیش بینی خطر را به طور چشمگیری ارتقا داده است (McGrath, 2026).

بررسی پیشینه پژوهش ها در ارزیابی حساسیت به سیل با استفاده از هوش مصنوعی و مدل های اقلیمی، برای شناخت خلاها و انتخاب روش شناسی بهینه ضروری است. مطالعات مختلفی کارایی این رویکردها را تأیید کرده اند: در زمینه الگوریتم های یادگیری ماشین، بند و همکاران (Band et al., 2020) مدل درختان رگرسیونی تصادفی (ERT) را با دقت ۸۲٪ در حوضه کلوان، و بختیاری و جهان تاب (Mosavi, Ozturk & Chau, 2018) شبکه عصبی مصنوعی را در حوضه کن به عنوان ابزارهای پیش بینی قدرتمند معرفی کردند. در رویکردهای تلفیقی و مکانی، لو و همکاران (Luu, Von Meding & Kanjanabootra, 2021) در ویتنام بر نقش کلیدی کاربری اراضی، زمین شناسی و شیب در بروز سیلاب تأکید کرده اند. با وجود پیشرفت های اخیر، ارزیابی هم زمان اثرات سناریوهای انتشار (SSPs) و مدل های داده محور در حوضه های مستعد غرب کشور همچنان نیازمند مطالعات بومی عمیق تری است. از این

1- Extreme Precipitation Event

2- Flash Floods

3- Bias Correction

4- Flood Susceptibility

5- Random Forest

6- Support Vector Machine


7- Multi-temporal modeling

رو، حوضه آبریز قره سو در استان کرمانشاه به دلیل مواجهه با چالش های پیچیده اقلیمی و سیلاب های ادواری مخرب، جهت مطالعه انتخاب شده است. هدف پژوهش حاضر، ارزیابی جامع اثرات تغییر اقلیم بر پتانسیل حساسیت به سیل در این حوضه با استفاده از سناریوهای CMIP6 (شامل SSP1-2.6، SSP2-4.5 و SSP5-8.5) است. بدین منظور، با بهره گیری از مدل اقلیمی بهینه MPI-ESM1-2-HR، الگوریتم های یادگیری ماشین (RF و SVM) و بررسی ۱۶ عامل مؤثر محیطی و انسانی، وضعیت سیلاب در دو افق زمانی آینده میانی (۲۰۴۱-۲۰۷۰) و دور (۲۰۷۱-۲۱۰۰) شبیه سازی می شود تا چشم اندازی دقیق و کاربردی جهت مدیریت منابع آب، ارتقای تاب آوری و کاهش پیشگیرانه ی ریسک فراهم گردد. تغییرات اقلیمی در دهه های اخیر به عنوان یکی از بزرگ ترین تهدید های زیست محیطی و انسانی مطرح شده است. افزایش دما، تغییر در الگوهای بارش و افزایش فراوانی پدیده های حدی از جمله بارش های سیل آسا، به ویژه در مناطق خشک و نیمه خشک، سبب افزایش خطر وقوع سیلاب در بسیاری از حوضه های آبریز ایران شده است. بر اساس گزارش های اخیر سازمان هواشناسی جهانی و مطالعات منطقه ای، پیش بینی می شود که تا میانه قرن حاضر، شدت بارش های حدی در مناطق شمالی و غربی کشور تا ۲۵٪ افزایش یابد (Hooshyaripor et al., 2024; Zarrin & Dadashi-Roudbari, 2024). چنین شرایطی می تواند زیرساخت های شهری، شبکه های حمل و نقل و منابع آب را با تهدیدهای جدی مواجه کند. از سوی دیگر، بخش قابل توجهی از پژوهش های داخلی تاکنون تنها به بررسی روندهای گذشته یا شرایط فعلی خطر سیلاب پرداخته اند و تحلیل های آینده نگر مبتنی بر سناریوهای اقلیمی نسل ششم (CMIP6) در سطح ملی هنوز محدود است (Behzadi, Javadi, Hafezi, Vasheghani Farahani & Golmohammadi, 2024; Janizadeh et al., 2024). این در حالی است که مدل های CMIP6 به دلیل دقت بالاتر در بازنمایی فرآیندهای اقلیمی و تنوع سناریوهای انتشار (SSP)، ابزار قدرتمندی برای تحلیل تغییرات مکانی و زمانی مخاطرات آبی محسوب می شوند. با توجه به ماهیت پیچیده پدیده سیلاب، بهره گیری از الگوریتم های یادگیری ماشین مانند Random Forest (RF) و Support Vector Machine (SVM) در کنار داده های سنجش از دور (RS)، رویکردی نوین برای تحلیل چند بعدی و دقیق آسیب پذیری سیلاب فراهم می سازد (Chen et al., 2024; Hooshyaripor et al., 2024). این ترکیب داده ای و مدلی، توانایی استخراج روابط غیرخطی بین عوامل طبیعی و انسانی مؤثر بر وقوع سیلاب را افزایش داده و دقت پیش بینی را نسبت به روش های آماری سنتی به طور قابل توجهی ارتقاء می دهد (Kazemi, Mohammadi, Nafooti, 2024; Behvar & Kariminejad, 2024; Wang, Sanderson, Iqbal & Woo, 2025). اجرای این پژوهش نه تنها به غنای علمی حوزه مدیریت ریسک سیلاب کمک می کند، بلکه از منظر کاربردی و سیاست گذاری نیز حائز اهمیت است. نتایج حاصل می تواند مبنای تصمیم سازی برای سازمان های کلیدی از جمله وزارت نیرو، سازمان مدیریت بحران کشور و وزارت جهاد کشاورزی در جهت برنامه ریزی های سازگاری با تغییر اقلیم، توسعه زیرساخت های مقاوم در برابر سیلاب، و تدوین سیاست های جامع کاهش خطر پذیری مناطق پرریسک قرار گیرد (Khodaei, Nasiri Saleh, Nobakht Dalir & Zarei, 2025).

منطقه مورد مطالعه

بر اساس شکل ۱، حوضه آبخیز قره سو با مساحت ۵۲۷۸ کیلومتر مربع در استان کرمانشاه (غرب ایران) واقع شده است (بین ۳۴ درجه و ۳۰ ثانیه تا ۳۴ درجه و ۵۴ ثانیه عرض شمالی، و ۴۶ درجه و ۲۲ دقیقه تا ۴۷ درجه و ۲۲ دقیقه طول شرقی). ارتفاع این حوضه از ۱۲۳۷ تا ۳۳۷۴ متر، متوسط دمای سالانه آن ۶/۱۴ درجه سانتی گراد و میانگین بارش متغیر آن بین ۳۰۰ تا ۸۰۰ میلی متر است. این منطقه از زیرحوضه های مهم کرخه به شمار می رود و شامل سه رودخانه اصلی مرگ، رازآور و قره سو است؛ رودخانه قره سو با طولی حدود ۶۰ کیلومتر، از سراب روانسر سرچشمه گرفته و پس از گذر از دشت ها و شهر کرمانشاه به رودخانه گاماسیاب می پیوندد. این حوضه سابقه سیلاب های مخربی دارد؛ از جمله سیل ویرانگر سال ۱۳۹۸ که خسارات هنگفتی به اراضی کشاورزی، زیرساخت ها و آثار تاریخی وارد کرد (Bahrami & Dastorani, 2021). از منظر زمین شناسی، قره سو در کمربند کوه زایی زاگرس قرار داشته و سازندهای آن عمدتاً شامل سنگ های رسوبی کرتاسه و پالئوژن (بیشتر آهک و دولومیت) است. خاک های منطقه نیز

عمدتاً از نوع آهکی و قهوه ای کوهستانی بوده و به دلیل شیب تند، پتانسیل فرسایش بالایی دارند. همچنین (مطابق شکل ۱)، نقاط سیلابی و غیرسیلابی حوضه با استفاده از تصاویر ماهواره ای سنتینل-۱ در محیط گوگل ارث انجین با دقت بالا استخراج شده اند. الگوریتم های یادگیری ماشین استفاده شده در این پژوهش RF و SVM ماهیت طبقه بندی کننده دارند و برای آموزش، نیازمند دو کلاس حضور (سیلاب = ۱) و عدم حضور (فاقد سیلاب = ۰) هستند. اگرچه از نظر فیزیکی سایر پهنه های حوضه فاقد سیلاب بوده اند، اما وارد کردن کل پیکسل های حوضه به عنوان کلاس صفر منجر به خطای عدم تعادل کلاس ها در مدل سازی می شود. لذا، بر اساس استانداردهای مدل سازی مکانی، به تعداد برابر با نقاط سیلابی (۳۲۰ نقطه)، نقاط فاقد سیلاب یا شبه عدم حضور به صورت تصادفی استخراج گردید. معیار انتخاب این نقاط، قرارگیری آن ها در خارج از پلیگون های سیلابی، در مناطقی با شیب های بالاتر و با رعایت یک فاصله حریم از مناطق سیلابی بوده است تا اطمینان حاصل شود که این نقاط قطعاً در مناطق امن قرار دارند.



شکل ۱- حوضه آبریز قره سو در استان کرمانشاه

Fig.1. Qareh Su Watershed in Kermanshah Province

مواد و روش ها

سیل ها یکی از عوامل بالقوه مرگ و میر مردم و جابجایی آن ها از مساکن خود در سطح جهان هستند که ضمن آسیب به محیط زیست، اقتصاد، توسعه اقتصادی آن منطقه را تحت تاثیر قرار می دهد (Bai, Tahmasebipour, Zeinivand, Sadoddin & Kaheh, 2024). این پژوهش با هدف نقشه برداری مکانی-زمانی حساسیت به سیلاب در حوضه قره سو، عملکرد دو مدل RF و SVM را تحت سناریوهای مختلف اقلیمی ارزیابی کرده است. برای این منظور، ابتدا ۱۶ عامل مؤثر محیطی (شکل ۲) شامل شیب (Slope)، ارتفاع (Altitude)، جهت شیب (Aspect)، تراکم آبراهه (Drainage Density)، خاک (Soil)، زمین شناسی (Geology)، فاصله از رودخانه (Distance from River)، بارش (Precipitation)، رطوبت توپوگرافی (Topographic Wetness Index)، دما (Temperature)، قدرت رودخانه (Stream Power Index)، موقعیت توپوگرافیک (Topographic Position Index)، کاربری اراضی (Land use)، انحنای عمودی (Profile Curvature) و انحنای افقی (Plan Curvature) که تاثیرگذار بر روی سیلاب می باشد تهیه گردید. همچنین ۳۲۰

نقطه تاریخی استخراج شده از تصاویر ماهواره ای و داده های اقلیمی آینده (تحت سه سناریو و دو افق زمانی) آماده سازی شدند. پس از آموزش مدل ها، عملکرد آن ها با شاخص های آماری مانند ROC-AUC اعتبارسنجی شد و در نهایت، نقشه های حساسیت به سیلاب تولید و توانایی مدل ها مقایسه گردید.

تهیه نقشه پراکنش سیلاب

نقشه پراکنش سیلاب با ارائه چشم اندازی از مناطق سیل گیر و فاقد سیلاب گذشته، ابزاری حیاتی برای شناسایی الگوهای وقوع سیلاب در آینده است (Khosravi et al., 2019). در این پژوهش، اطلاعات ۳۲۰ رویداد سیلاب حوزه قره سو طی سال های ۱۳۹۸، ۱۴۰۲ و ۱۴۰۴ با استفاده از تصاویر ماهواره ای رادار (SAR) سنتینل-۱ استخراج و با بررسی های میدانی اعتبارسنجی شد؛ با این رویکرد که الگوهای گذشته پیش بینی کننده ای ارزشمند برای رویدادهای آتی هستند (Iosub, Minea, Chelariu & Urzica, 2020). به منظور مدل سازی، ۳۲۰ نقطه فاقد سیلاب نیز به طور تصادفی در محیط ArcGIS 10.5 تولید گردید. در نهایت، کل داده ها (سیلابی و فاقد سیلاب) با استفاده از کتابخانه Scikit-learn در پایتون به صورت تصادفی به دو بخش آموزش (۷۰ درصد) و اعتبارسنجی (۳۰ درصد) تقسیم شدند. این رویه متداول و بدون سوگیری، تخصیص داده های کافی برای آموزش و دستیابی به نتایج بهینه در ارزیابی مدل های یادگیری ماشین را تضمین می کند (Iosub et al., 2020; Tehrani, Pradhan, Mansor & Ahmad, 2015).

آماده سازی عوامل مهم حساسیت به سیلاب

دقت مدل سازی حساسیت به سیلاب وابستگی زیادی به داده های در دسترس و مدل های انتخابی دارد (Hooshyaripor et al., 2020). با این حال، با وجود اهمیت گردآوری متغیرهای مؤثر، هنوز رویکرد سیستماتیک جامعی برای انتخاب بهترین عوامل وجود ندارد (Zhao, Pang, Xu, Peng & Xu, 2019). بر این اساس، در پژوهش حاضر با توجه به پیشینه تحقیق و شرایط هیدرولوژیکی، اقلیمی و محیطی، ۱۶ عامل کلیدی استخراج گردید (شکل ۲) (Iosub et al., 2020; Yousefi et al., 2020; Gholami, Nemati, Li & Zhang, 2022). داده های مکانی این عوامل با استفاده از تکنیک های سنجش از دور استخراج شده و توسط روش درون یابی نزدیک ترین همسایه^۱ در محیط ArcGIS به لایه های رستری با قدرت تفکیک ۳۰ متر تبدیل شدند. همچنین، برای طبقه بندی یکپارچه ای داده ها از الگوریتم فواصل طبیعی^۲ و جهت ارزیابی روابط خطی میان متغیرهای مستقل، از آزمون هم خطی چندگانه استفاده شد که جزئیات تکمیلی و نتایج این فرایندها در بخش های آتی ارائه می گردد.

پیش بینی تغییر اقلیم و مدل سازی داده ها

پیش بینی دقیق تغییرات اقلیمی برای ارزیابی تأثیرات بالقوه ی آن بر ریسک وقوع سیلاب در آینده امری حیاتی است (Xiang et al., 2022). در این پژوهش، به منظور دستیابی به یک چارچوب ارزیابی جامع، ابتدا داده های اقلیمی مدلسازی و تصحیح شدند و سپس خروجی این مدل ها به عنوان داده های ورودی در الگوریتم های یادگیری ماشین جهت پهنه بندی حساسیت سیلاب مورد استفاده قرار گرفتند. مراحل اجرایی این فرآیند به شرح زیر است:

تهیه داده های اقلیمی مشاهداتی

تحلیل الگوهای بارش بلندمدت، درک اثرات تغییر اقلیم و صحت سنجی مدل های آینده را ممکن می سازد (Heo et al., 2019). در این پژوهش، داده های بارش روزانه دوره ی پایه ۳۰ ساله (۱۹۸۵ تا ۲۰۱۴) از ایستگاه های سینوپتیک کرمانشاه و روانسر اخذ

گردید. انتخاب این ایستگاه ها بر اساس کیفیت داده ها، پراکنش جغرافیایی، تنوع ارتفاعی و انطباق بازه زمانی آن ها با دوره تاریخی مدل های اقلیمی جهانی صورت گرفته است (جدول ۱).

انتخاب و استخراج داده های مدل های CMIP6

تغییر اقلیم با افزایش شدت و تواتر بارش ها، خطر وقوع سیلاب ها را تشدید کرده است (Deng, Wang, Wu, Lai & Liu, 2023); از این رو بررسی سناریوهای آینده ضروری است (Zarrin, Dadashi-Roudbari & Hassani, 2022). در این پژوهش از مجموعه داده های فاز ششم پروژه مقایسه متقابل مدل های جفت شده (CMIP6) استفاده شد. انتخاب مدل های اقلیمی فرآیندی هدفمند بود، بر اساس پیشینه مطالعات اقلیمی معتبر در غرب ایران، در دسترس بودن داده های روزانه بارش برای هر سه سناریوی هدف، و همچنین لزوم استفاده از مدل هایی با قدرت تفکیک مکانی متنوع جهت پوشش عدم قطعیت ها، چهار مدل معتبر جهانی انتخاب شدند که جزئیات و مشخصات آن ها در جدول ۲ ارائه شده است (Copernicus Climate Change Service, Climate Data Store, 2021). سناریوهای در نظر گرفته شده شامل سه مسیر اجتماعی-اقتصادی (SSP1-2.6)، (SSP2-4.5) و (SSP5-8.5) می باشند که چشم اندازهای متفاوتی از توسعه و انتشار گازهای گلخانه ای را برای دو افق زمانی میانی (۲۰۴۱-۲۰۷۰) و دور (۲۰۷۱-۲۱۰۰) ارائه می دهند (Wu, Liu, Zhou & Zhang, 2022; Tang et al., 2021; Jiang, Hu, Tian & Lang, 2020; Usta, Teymouri & Chatterjee, 2022). جزئیات این سناریوها در جدول ۳ ارائه شده است.

ریزمقیاس نمایی مکانی و تصحیح اریب (Bias Correction)

خروجی خام مدل های GCM در فاز CMIP6 به دلیل قدرت تفکیک مکانی پایین و وجود اریب های سیستماتیک (خطاهای محاسباتی ذاتی مدل)، نمی توانند مستقیماً در شبیه سازی های هیدرولوژیکی مقیاس حوضه استفاده شوند و حتماً نیازمند ریزمقیاس نمایی و تصحیح اریب هستند (Yazdandoost, Moradian, Izadi & AghaKouchak, 2021; Pastén-Zapata, Jones, Moggridge & Widmann, 2020). در این پژوهش، از رویکرد علمی نگاشت توزیع (Distribution Mapping - DM) استفاده شد (Zhu & Yang, 2020). مبانی تئوریک روش DM بر این اصل استوار است که تابع توزیع تجمعی (CDF) مقادیر شبیه سازی شده ی مدل، از طریق توابع انتقال ریاضی (نظیر توزیع گاما برای متغیر بارش)، بر تابع توزیع داده های مشاهداتی منطبق می گردد تا خطای سیستماتیک اصلاح شود (Deutschbein & Seibert, 2012; Heo et al., 2019). پیاده سازی این الگوریتم های آماری و ریاضی در بستر نرم افزار CMhyd انجام گرفت تا داده های شبکه ای مدل های CMIP6 بر اساس داده های نقطه ای ایستگاه های سینوپتیک حوضه قره سو به صورت دقیق ریزمقیاس و تصحیح گردند (Rathjens, Bieger, Srinivasan, Chaubey & Arnold, 2016). سناریوهای مسیرهای اجتماعی-اقتصادی مشترک (SSPs)، چشم اندازی از روندهای توسعه، انتشار گازهای گلخانه ای و سیاست های اقلیمی آینده ارائه می دهند (Wu et al., 2022; Tang et al., 2021). در این پژوهش، جهت انجام تحلیلی جامع، سه سناریوی متمایز برای دو افق زمانی میانی (۲۰۴۱-۲۰۷۰) و دور (۲۰۷۱-۲۱۰۰) انتخاب شدند (Zarrin & Dadashi-Roudbari, 2021)، که عبارتند از:

- سناریوی SSP1-2.6 خوش بینانه: مبتنی بر اقتصاد کم کربن، چالش های پایین و شیوه های پایدار کاربری اراضی
- سناریوی SSP2-4.5 نسبتاً خوش بینانه: متمرکز بر ایجاد تعادل میان رشد اقتصادی و پایداری محیطی با چالش های متوسط
- سناریوی SSP5-8.5 بدبینانه: مبتنی بر صنعتی سازی سریع و اتکای شدید به سوخت های فسیلی، که به پیامدهای شدید اقلیمی منجر می گردد (Jiang et al., 2020).

در افق آینده دور (۲۱۰۰-۲۰۷۱)، دو سناریوی اول با هدف تثبیت اقلیم و انتشار خالص صفر تدوین شده اند، در حالی که سناریوی سوم پیامدهای اقلیمی مخرب تری را به تصویر می کشد (Usta et al., 2022). در نهایت، با استفاده از مدل اقلیمی بهینه، روندهای بارش آینده تحت این سه سناریو و در دو افق زمانی مذکور کمی سازی شدند (جزئیات سناریوها در جدول ۳ ارائه شده است).

ارزیابی عملکرد مدل ها و انتخاب مدل بهینه

در مطالعات تغییر اقلیم، جهت کاهش عدم قطعیت، دو رویکرد اصلی شامل استفاده از مدل همدادی (Ensemble) و یا انتخاب مدل برتر وجود دارد. در این پژوهش، به منظور جلوگیری از ورود خطای مدل های ضعیف تر به یک مدل همدادی ساده، رویکرد ارزیابی و انتخاب دقیق ترین مدل اتخاذ گردید. بدین منظور، شبیه سازی های دوره تاریخی هر چهار مدل پس از تصحیح اریب با مقادیر مشاهداتی مقایسه شدند. عملکرد مدل ها با به کارگیری همزمان شاخص های خطاسنجی شامل R^2 ، NSE، PBIAS، MAPE و RMSE و KGE ارزیابی شد تا صحت، سوگیری و تغییرپذیری آن ها سنجیده شود (Zhu & Yang, 2020; Mohanty & Simonovic, 2021). برای رتبه بندی نهایی، از شاخص عملکرد کامپوزیت (CP) استفاده گردید (رابطه ۱) (Zarrin & Dadashi-Roudbari, 2021). همچنین برای نمایش بصری تطابق واریانس و همبستگی داده ها از نمودار تیلور (Wang et al., 2020; Zarrin et al., 2022) استفاده شد. بر اساس این ارزیابی های سخت گیرانه، مدلی که بهترین عملکرد و کمترین خطا را داشت برای تولید داده های اقلیمی آینده در حوضه انتخاب گردید.

تأکید می گردد که مبنای علمی و تحلیلی در این پژوهش، روش آماری نگاشت توزیع (DM) است و نرم افزار CMhyd تنها به عنوان ابزار محاسباتی جهت اجرای این الگوریتم و برازش توزیع گاما به کار گرفته شده است.

بنابراین، در این پژوهش هیچ گونه مدل همدادی (Ensemble) ساخته نشده است و تمام پیش بینی های آینده منحصر بر پایه خروجی های دقیق ترین مدل انتخاب شده (MPI-ESM1-2-HR) انجام گرفته است.

ارزیابی عملکرد داده های مدل های GCM در CMIP6

جهت انتخاب مناسب ترین مدل های جهانی اقلیم (GCMs) از مجموعه CMIP6 و مقایسه شبیه سازی های بارش با مشاهدات، از شاخص های آماری متنوعی شامل MAPE (سنجش دقت)، PPC (ارزیابی سوگیری)، NSE (تغییرپذیری زمانی)، R^2 یا ضریب تعیین (تبیین واریانس مشاهدات)، RMSE (سنجش صحت) و KGE (ارزیابی کلی عملکرد) استفاده شد (Zhu & Yang, 2020). به کارگیری هم زمان این شاخص ها، ارزیابی جامع و مستحکم تری از جنبه های مختلف عملکرد مدل ها ارائه می دهد (Mohanty & Simonovic, 2021). به منظور رتبه بندی مدل ها بر اساس بهترین برازش با مشاهدات، روش عملکرد کامپوزیت (CP) به کار گرفته شد تا نقاط قوت و ضعف هر مدل به روشنی مقایسه و ارزیابی گردد (Zarrin & Dadashi-Roudbari, 2021). در نهایت، مدل های منتخب GCM با بهترین عملکرد، برای تولید پیش بینی های اقلیمی و تحلیل تغییرات احتمال وقوع سیلاب در حوضه آبریز قره سو برای افق های آینده نزدیک و دور مورد استفاده قرار گرفتند.

رابطه (۱)

$$L_p = \left[\sum_{j=1}^j f_j^* - f_j^p \right] \frac{1}{p}$$

علاوه بر این، ما از نمودار تیلور که یک نمایش گرافیکی دوبعدی است، برای ارزیابی بصری شباهت بین مجموعه داده های GCM و داده های بارش مشاهداتی در ایستگاه های روانسر، کرمانشاه در حوضه آبریز قره سو استفاده کرده ایم. نمودار تیلور، همبستگی بین مشاهدات بارش ماهانه و داده های پیش بینی شده توسط GCM ها را با استفاده از سه آماره کمی می کند: ریشه میانگین مربعات خطا (RMSE)، ضریب همبستگی پیرسون و انحراف معیار (Wang et al., 2020). با استفاده از این نمودار، همچنین می توانیم تعیین کنیم که توزیع الگوی داده های مشاهداتی و داده های پیش بینی شده تا چه حد با یکدیگر برازش دارند (Zarrin et al., 2022).

مدل جنگل تصادفی (RF)

روش جنگل تصادفی، مجموعه ای از درختان تصمیم گیری است که برای انجام وظایف پیش بینی در حوزه های طبقه بندی و رگرسیون مورد استفاده قرار می گیرد و معرفی آن به عنوان الگوریتمی غالب در حوزه یادگیری گروهی توسط بریمن صورت گرفت (Zangeneh Asadi, Goli Mokhtari & Namitabar, 2026). مدل جنگل تصادفی (RF)، یک الگوریتم تجمعی (Ensemble) قدرتمند و سریع است (Breiman, 2001) که در این پژوهش برای طبقه بندی پیکسل های حوضه به دو کلاس حساس و فاقد حساسیت سیلاب اجرا شد. این مدل با استفاده از نمونه گیری بوت استرپ، حدود ۳۰ درصد از داده ها (نقاط سیلابی) را به عنوان نمونه خارج از پاکت (OOB) برای آزمون کنار می گذارد. در این پژوهش، الگوریتم RF با تنظیم روی ۵۰۰ درخت (با میانگین گره ۵۷/۵۳ در مرحله آموزش) پیاده سازی شد. علاوه بر این، جهت رتبه بندی اهمیت هر یک از ۱۶ عامل مؤثر (Hengl, Nussbaum, Wright, 2018)، از روش میانگین کاهش دقت (MDA) استفاده گردید که اهمیت هر متغیر را بر اساس میزان افت دقت در زمان حذف آن محاسبه می کند (Tehrany et al., 2015). جزئیات مبانی ریاضی این الگوریتم در پژوهش سدler و همکاران (Sadler, Goodall, Morsy & Spencer, 2018) ارائه شده است.

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان (SVM) یک الگوریتم محبوب یادگیری تحت نظارت برای رگرسیون و طبقه بندی است (Mountrakis, Im & Ogole, 2011) این مدل که به عنوان طبقه بندی کننده با حاشیه بیشینه (Maximal-margin classifier) نیز شناخته می شود، حتی با داده های محدود نتایج بسیار دقیقی ارائه می دهد. اساس کار SVM بر نگاشت بردارهای ورودی به یک فضای ویژگی با ابعاد نامحدود استوار است تا یک ابرصفحه (Hyperplane) بهینه با حداکثر حاشیه جداسازی میان کلاس ها ایجاد گردد (Wang, Wang & Yu, 2022). عملکرد این مدل به شدت به توابع ریاضی معروف به هسته (Kernel) شامل هسته های چند جمله ای (PL)، سیگموئید (SIG)، خطی (LN) و تابع پایه شعاعی (RBF) وابسته است. مطالعات نشان می دهد در ارزیابی آسیب پذیری سیلاب، هسته RBF به دلیل قدرت بالا در مدیریت ابعاد متعدد داده ها و تعمیم دهی بهتر، به عنوان تابع معیار انتخاب می شود (Choubin et al., 2019). تعریف ریاضی این هسته در رابطه (۲) و جزئیات تکمیلی تکنیک SVM در پژوهش های پیشین (Tehrany et al., 2015) ارائه شده است.

$$k(x, x^I) = \exp\left(-\frac{\|x - x^I\|^2}{2\sigma^2}\right) \quad \text{رابطه (۲)}$$

که در آن $\|x - x^I\|$ بیانگر فاصله اقلیدسی (L2_Norm) بین دو نقطه x_1 و x_2 . مدل های یادگیری ماشین قادرند اهمیت متغیرهای پیش بینی را بر اساس تحلیل میزان مشارکت (Contribution analysis) برآورد کنند.

اعتبارسنجی مدل ها

به دلیل تفاوت در عملکرد الگوریتم های یادگیری ماشین، انتخاب شاخص های ارزیابی مناسب بسیار حائز اهمیت است (Choubin et al., 2019). در این پژوهش، جهت ارزیابی دقت مدل ها از شاخص های آماری ROC-AUC، NPV، PPV، Sensitivity، Specificity و RMSE استفاده شد. شاخص ROC-AUC به طور گسترده برای ارزیابی دقت مدل های طبقه بندی دودویی کاربرد داشته و توانایی مدل را در تشخیص نمونه های مثبت و منفی در آستانه های مختلف نشان می دهد (Jiang et al., 2022). این شاخص ها بر پایه عناصر ماتریس درهم ریختگی شامل مقادیر TP، TN، و FN محاسبه می شوند. در این راستا، شاخص Sensitivity نسبت مثبت های واقعی، Specificity نسبت منفی های واقعی، و مقادیر PPV و NPV (نسبت صحت پیش بینی های مثبت و منفی) برای سنجش تشخیصی مدل ها به کار می روند (Khosravi et al., 2019). روابط ریاضی این شاخص ها در معادلات (۳) تا (۷) ارائه شده است؛ دامنه تمامی این معیارها بین ۰ تا ۱ متغیر بوده و مقادیر بالاتر، نشان دهنده عملکرد بهتر مدل است.

$$\text{Accuracy} = \frac{\sum TP + \sum TN}{P + N} \quad \text{رابطه ۳}$$

$$\text{PPV} = \frac{TP}{FP + TP} \quad \text{رابطه ۴}$$

$$\text{NPV} = \frac{TP}{TP + FN} \quad \text{رابطه ۵}$$

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad \text{رابطه ۶}$$

$$\text{Specificity} = \frac{TN}{FP + TN} \quad \text{رابطه ۷}$$

بر اساس جدول ۱، داده های بارش روزانه ایستگاه های سینوپتیک کرمانشاه و روانسر برای یک دوره پایه مشترک ۳۰ ساله (۱۹۸۵-۲۰۱۴) اخذ گردید. این بازه زمانی به منظور تطابق کامل با دوره تاریخی شبیه سازی شده توسط مدل های اقلیمی CMIP6 انتخاب شده است تا فرآیند ارزیابی و تصحیح اریب با بالاترین دقت ممکن انجام پ گیرد.

جدول ۱- مشخصات ایستگاه های سینوپتیک

Table 1- Specifications of Synoptic Stations

شماره Number	نام ایستگاه Station Name	طول جغرافیایی Longitude	عرض جغرافیایی Latitude	ارتفاع (متر) Elevation (m)
1	کرمانشاه Kermanshah	47.15	34.35	1318
2	روانسر Ravansar	46.65	34.71	1379

بر اساس جدول ۲، معیار انتخاب این چهار مدل، عملکرد مطلوب آن ها در مطالعات اقلیمی پیشین در منطقه، در دسترس بودن داده های روزانه برای سناریوهای هدف و همچنین پوشش تنوعی از تفکیک های مکانی بوده است. لازم به ذکر است که تفاوت در قدرت تفکیک مکانی شبکه ها (از ۰/۹۳ تا ۲/۸ با استخراج داده ها بر اساس مختصات ایستگاه های سینوپتیک و اعمال تکنیک ریزمقیاس نمایی در فرآیند تصحیح اریب یکپارچه گردید. همچنین، شناسه واریانت ها بر اساس تحقق اصلی و استاندارد منتشر شده توسط هر مؤسسه مدل سازی انتخاب شده اند. لازم به ذکر است که تفاوت در قدرت تفکیک مکانی شبکه ها (از ۰/۹۳ تا ۲/۸) با استخراج داده ها بر اساس مختصات ایستگاه های سینوپتیک و اعمال تکنیک ریزمقیاس نمایی در فرآیند تصحیح اریب یکپارچه گردید. لازم به ذکر است از آنجا که در این پژوهش مدل ها در یک مدل همادی (Ensemble) ادغام نشده اند و عملکرد هر مدل پس از تصحیح اریب مجزا به صورت مستقل ارزیابی شده است، تفاوت در شناسه واریانت برخی مدل ها مانند r1i1p1f2 در مدل-CNRM-ESM2-1 هیچ گونه تداخلی در ساختار تحلیل ایجاد نمی کند.

جدول ۲- خلاصه اطلاعات مدل های اقلیمی منتخب از CMIP6


Table 2- Summary of Selected CMIP6 Climate Models


شماره Number	مدل اقلیمی Climate Model	موسسه سازنده Developing Institution	وضوح مکانی Spatial Resolution	برچسب نسخه Variant Label
1	CanESM5	Canadian Centre for Climate Modelling and Analysis, Canada	2.8° × 2.8°	r1i1p1f1
2	CNRM-ESM2-1	National Centre for Meteorological Research (CNRM-CERFACS), France	1.4° × 1.4°	r1i1p1f2
3	MPI-ESM1-2-HR	Max Planck Institute for Meteorology (MPI-M), Germany	0.93° × 0.93°	r1i1p1f1
4	MRI-ESM2-0	Meteorological Research Institute (MRI), Japan	1.125° × 1.125°	r1i1p1f1


جدول ۳- سناریوهای (SSP) مسیرهای اجتماعی-اقتصادی مشترک منتخب در این پژوهش

Table 3- Selected Shared Socioeconomic Pathways (SSP) Scenarios in this Study

چالش ها Challenges	توصیف Description	سناریو Scenario
چالش های کم در زمینه کاهش انتشار گازهای گلخانه ای و سازگاری Low challenges to mitigation and adaptation	توسعه پایدار-مسیر سبز Sustainable development (Taking the green road)	SSP1-2.6
چالش های متوسط در زمینه کاهش انتشار و سازگاری Medium challenges to mitigation and adaptation	مسیر میانه Middle of the road	SSP2-4.5
چالش های زیاد در زمینه کاهش انتشار و چالش های کم در سازگاری High challenges to mitigation and low challenges to adaptation	توسعه مبتنی بر سوخت های فسیلی-مسیر پرسرعت Fossil-fueled development (Taking the highway)	SSP5-8.5







شکل ۲- عوامل مهم حساسیت به سیلاب که در این پژوهش مورد استفاده قرار گرفته اند: (a) ارتفاع؛ (b) جهت شیب؛ (c) شیب؛ (d) تراکم آبراهه؛ (e) پوشش گیاهی؛ (f) نوع خاک؛ (g) انحنا افقی؛ (h) انحنا عمودی؛ (i) فاصله از رودخانه؛ (j) زمین شناسی؛ (k) شاخص قدرت رودخانه؛ (l) دما؛ (m) کاربری و پوشش اراضی؛ (n) شاخص موقعیت توپوگرافیک؛ (o) شاخص رطوبت توپوگرافیک؛ و (p) بارش.

Fig.2. Important flood susceptibility factors used in this study: (a) elevation; (b) aspect; (c) slope; (d) drainage density; (e) vegetation cover; (f) soil type; (g) plan curvature; (h) profile curvature; (i) distance from river; (j) geology; (k) stream power index (SPI); (l) temperature; (m) land use/land cover (LULC); (n) topographic position index (TPI); (o) topographic wetness index (TWI); and (p) precipitation.

نتایج و بحث


در این بخش، عملکرد مدل های گردش عمومی اقلیمی (GCMs) در پیش بینی الگوهای تغییر اقلیم بر اساس روندهای تاریخی مورد ارزیابی قرار گرفته است. سپس، مدل اقلیمی دارای بهترین عملکرد، جهت پیش بینی شرایط اقلیمی آینده تحت سناریوهای مختلف انتخاب می گردد. علاوه بر این، نقشه های حساسیت به سیلاب تولید شده توسط مدل های یادگیری ماشین با در نظر گرفتن اثرات تغییر اقلیم آینده تحت سناریوهای گوناگون، ارائه شده و مورد بحث و مقایسه قرار می گیرند.

تحلیل تغییر اقلیم

ارزیابی و امتیازدهی به عملکرد مدل های GCM

در این پژوهش، اگرچه سری های زمانی بارش به صورت روزانه جهت تحلیل های سیلاب استخراج و استفاده گردیدند، اما به دلیل نوبت و عدم قطعیت بالای مدل های اقلیمی در شبیه سازی های مقیاس روزانه، از روش نگاشت توزیع (DM) برای تصحیح اریب و ریزمقیاس نمایی خروجی مدل های GCM بر مبنای مقادیر ماهانه استفاده شد. در واقع، مقایسه میانگین بارش ماهانه (شکل ۳) منحصر به منظور ارزیابی عملکرد و صحت سنجی روندهای اقلیمی مدل ها صورت گرفته است و نشان می دهد که پیش از تصحیح،

داده های خام به ویژه در مدل های CNRM-ESM2-1 و MRI-ESM2-0 میزان بارش هر دو ایستگاه را بیش برآورد می کنند. اما پس از اعمال روش DM، خروجی مدل ها تغییر یافته و خطای آن ها با انطباق بسیار بالا بر مشاهدات واقعی، به طور چشمگیری کاهش می یابد، کارایی مطلوب این روش پیش تر نیز تأیید شده است. (Li & Li, 2023) جهت انتخاب مناسب ترین مدل برای پیش بینی های آتی، شش شاخص آماری MAE، PBIAS، NSE، R^2 و RMSE ارزیابی شدند. بررسی ها نشان داد که پیش از تصحیح، مدل MPI-ESM1-2-HR بالاترین تطابق و CNRM-ESM2-1 بیشترین عدم قطعیت را داشتند. پس از اعمال تصحیح اریب، تمامی شاخص ها به ویژه از طریق ارتقای R^2 و کاهش چشمگیر RMSE در محدوده کاملاً قابل قبولی قرار گرفتند که این امر پایایی (Reliability) مدل ها را برای توسعه نقشه حساسیت به سیلاب تأیید می کند. بر اساس این شاخص ها، مدل MPI-ESM1-2-HR به عنوان دقیق ترین مدل و CanESM5 در رتبه دوم جای گرفتند. در نهایت، نمودار تیلور (شکل ۴) با تجمیع شاخص های ضریب همبستگی پیرسو (PCC)، RMSE و انحراف معیار، عملکرد مدل ها را به صورت بصری تأیید می کند. این نمودار نشان می دهد که پس از تصحیح اریب (تغییر از نقاط دایره ای به لوزی شکل)، تمامی مدل ها همگرایی بسیار مطلوبی به سمت نقطه مشاهداتی (ستاره مشکی) پیدا کرده اند. بر اساس این ارزیابی های بصری و کمی، مدل MPI-ESM1-2-HR (نقاط سبز رنگ) به دلیل کمترین خطای RMSE و بالاترین ضریب همبستگی در هر دو حالت پیش و پس از تصحیح، به عنوان بهترین گزینه جهت شبیه سازی های اقلیمی آینده حوضه قره سو تحت سناریوهای SSP انتخاب گردید.



شکل ۳- میانگین بارش ماهانه داده های مشاهداتی و خروجی مدل های GCM در دوره پایه: (a و b) پیش از تصحیح اریب، به ترتیب در ایستگاه های کرمانشاه و روانسر؛ و (c و d) پس از تصحیح اریب، به ترتیب در ایستگاه های کرمانشاه و روانسر.

Fig.3. Mean monthly precipitation of observational data and GCM model outputs during the baseline period: (a and b) before bias correction, for Kermanshah and Ravansar stations, respectively; and (c and d) after bias correction, for Kermanshah station.

جدول ۵- ارزیابی دقت خروجی مدل‌های گردش عمومی جو (GCM) بر مبنای شاخص‌های آماری در دوره پایه (حالت پیش و پس از روش تصحیح اریبی (DM)

Table 5- Evaluation of GCM output accuracy based on statistical indices in the base period (Before and After Bias Correction methods)


ایستگاه سینوپتیک Synoptic Station	شرایط Condition	مدل اقلیمی Climate Model	MAE خطای مطلق (میانگین)	PBIAS (%) (درصد اریبی)	NSE نش- (ساتکلیف)	R ² (ضریب تعیین)	RMSE (mm) جذر مربعات (خطا)	KGE کلاین- (گوپتا)	رتبه Rank
ایستگاه کرمانشاه Kermanshah	پیش از تصحیح Before BC	CanESM5	244.77	-56.9	-6.73	0.28	268.41	-0.18	2
		CNRM-ESM2-1	578.28	134.6	-40.71	0.11	623.49	-1.27	4
		MPI-ESM1-2-HR	103.97	-13.5	-0.81	0.42	129.96	0.33	1
		MRI-ESM2-0	386.34	92.2	-19	0.18	431.74	-0.54	3
	پس از تصحیح After BC	CanESM5	138.5	-21.4	-1.95	0.35	162.2	0.12	2
		CNRM-ESM2-1	215.1	48.3	-5.8	0.22	248.6	-0.35	4
		MPI-ESM1-2-HR	97.42	7.1	-0.71	0.51	126.37	0.29	1
		MRI-ESM2-0	172.4	33.6	-3.42	0.31	198.55	0.05	3
ایستگاه روانسر Rawansar	پیش از تصحیح Before BC	CanESM5	279.53	-67.5	-6.67	0.31	301.53	-0.19	2
		CNRM-ESM2-1	370.3	84.9	-14.42	0.15	427.43	-0.66	4
		MPI-ESM1-2-HR	169.08	-34.6	-2.3	0.46	197.68	-0.07	1
		MRI-ESM2-0	240.23	49.4	-5.51	0.24	277.72	-0.2	3
	پس از تصحیح After BC	CanESM5	165.2	-28.1	-2.15	0.39	191.4	-0.02	2
		CNRM-ESM2-1	238.6	56.4	-4.8	0.28	272.1	-0.41	4
		MPI-ESM1-2-HR	126.64	-18.5	-1.07	0.54	156.73	0.14	1
		MRI-ESM2-0	198.3	39.2	-3.65	0.35	225.8	-0.08	3

MAE: Mean Absolute Error, PBIAS: Percent Bias, NSE: Nash-Sutcliffe Efficiency, RMSE: Root Mean Square Error, KGE: Kling-Gupta Efficiency)

مدل های تغییر اقلیم در افق های آینده میانی و دور تحت سناریوهای مختلف SSP


پس از انتخاب مدل MPI-ESM1-2-HR، از تکنیک DM برای پیش بینی بارش های آینده تحت سه سناریوی SSP1-2.6، SSP2-4.5 و SSP5-8.5 در دو افق میانی (۲۰۴۱-۲۰۷۰) و دور (۲۰۷۱-۲۱۰۰) استفاده شد. نتایج (شکل ۵) نشان می‌دهد که تغییر اقلیم موجب نوسانات شدید در توزیع ماهانه (Monthly Variability) و تشدید رخداد های بارش فرین (Extreme Events) به ویژه در ماه های زمستان تحت سناریوی بدبینانه SSP5-8.5 شده است. با وجود این نوسانات نامنظم، حجم کلی بارش سالانه روندی کاملاً افزایشی دارد: در افق آینده میانی (۲۰۴۱-۲۰۷۰)، میزان بارش در ایستگاه کرمانشاه تحت سه سناریوی مذکور به ترتیب ۵۳/۱۱، ۲۰/۲۲ و ۱۱/۳۷ درصد و در ایستگاه روانسر ۰۱/۳۶، ۶۸/۴۲ و ۴۶/۶۲ درصد نسبت به دوره تاریخی افزایش می‌یابد. در افق آینده دور (۲۰۷۱-۲۱۰۰)، این روند تداوم یافته و بارش ها در کرمانشاه به ترتیب ۶۴/۳۳، ۷۹/۴۴ و ۱۷/۴۰ درصد افزایش خواهند یافت. ایستگاه روانسر نیز با یک شیب صعودی شدید، افزایش بی سابقه ۳۶/۵۶، ۱۲/۶۹ و ۹۸/۱۰۳ درصدی بیش از دو برابر شدن در

سناریوی SSP5-8.5 را تجربه خواهد کرد. در مجموع، افزایش چشمگیر حجم بارش ها در کنار توزیع بسیار متغیر و همراه با پیک های ناگهانی، ضرورت ارزیابی دقیق خطر و حساسیت وقوع سیلاب در حوضه آبریز قره سو را بیش از پیش آشکار می سازد.



شکل ۴- نمودار تیلور برای شبیه سازی های بارش ماهانه (میلی متر) توسط چهار مدل GCM از مجموعه CMIP6 در مقایسه با داده های مشاهداتی، پیش و پس از تصحیح اریب در ایستگاه های (a) کرمانشاه، و (b) روانسر.

Fig.4. Taylor diagram for monthly precipitation simulations (mm) by four GCM models from the CMIP6 ensemble compared to observational data, before and after bias correction at (a) Kermanshah, and (b) Ravansar stations.



شکل ۵- روند بارش آینده دو ایستگاه سینوپتیک تحت سناریوهای مختلف (a) ایستگاه کرمانشاه؛ و (b) ایستگاه روانسر در افق آینده میانی (۲۰۴۱-۲۰۷۰)؛ و (c) ایستگاه کرمانشاه؛ و (d) ایستگاه روانسر در افق آینده دور (۲۰۷۱-۲۱۰۰).

Fig.5. Future precipitation trends for two synoptic stations under different SSP scenarios: (a) Kermanshah station; and (b) Ravansar station in the mid-future horizon (2041-2070); and (c) Kermanshah station; and (d) Ravansar station in the far-future horizon (2071-2100).


بررسی افق آینده میانی (۲۰۷۰-۲۰۴۱) نشانگر تغییر توزیع فصلی و نوسانات شدید بارش است. برای مثال، در کرمانشاه تحت سناریوی SSP 5-8.5 بارش در ماه های ژانویه و مارس (به ترتیب ۰.۲/۵۷ و ۸/۲۹ درصد) افزایش و در فوریه و آوریل (۶/۳۵- و ۹/۴۴ درصد) کاهش می یابد؛ درحالی که سناریوی SSP2-4.5 پیک های بارشی را به فوریه و دسامبر (۱/۲۷ و ۷/۱۹ درصد افزایش) منتقل می کند. این بی نظمی در ایستگاه روانسر شدیدتر است؛ به طوری که تحت SSP 5-8.5 دسامبر و فوریه (۲/۳۰ و ۳/۴۱ درصد) افزایش و ژانویه (۱/۴۹- درصد) افت شدیدی دارند. این روند، گویای تغییر رژیم بارشی منطقه از الگویی منظم به سمت رویدادهای حدی است. وقوع پیک های فرین^۱ در پاییز و زمستان تمامی سناریوها، نشان دهنده افزایش نگران کننده خطر سیلاب در هر دو افق آینده است؛ در مقابل، کاهش بارش های بهاره (به ویژه آوریل و می) تحت سناریوهای بدبینانه، زنگ خطری برای خشکسالی های بهاره محسوب می شود. همچنین، ایستگاه کوهستانی روانسر نسبت به ایستگاه دشت کرمانشاه الگوهای متفاوتی داشته و در افق دور (۲۰۷۱-۲۱۰۴)، رخدادهای فرین را با سرعت و حجم بسیار بیشتری تجربه خواهد کرد. تغییرات الگوی بارش در سناریوهای-SSP1 و 2.6 SSP2-4.5 ناشی از تغییرات گردش جوی و دمایی است، اما غلظت بالای گازهای گلخانه ای در سناریوی SSP5-8.5 نوسانات و رویدادهای شدیدتری در پی دارد (Usta et al., 2022). اگرچه این اثرات پیچیده به شدت به توپوگرافی وابسته اند (Xiang et al., 2022) و باعث افزایش بارش زمستانه در مناطق کوهستانی می شوند، اما همزمان چالش هایی نظیر تخریب اکوسیستم ها و سیلاب های ناگهانی را به همراه دارند (Zarrin & Dadashi-Roudbari, 2021). این یافته ها با نتایج مطالعات پیشین مبنی بر تشدید بارش های حدی در مناطق مرتفع غرب کشور مطابقت کامل دارد (Zamani, Hashemi Monfared & Hamidianpour, 2020; Usta et al., 2022).

ارزیابی و اعتبارسنجی حساسیت به سیلاب

در این بخش، حساسیت به سیلاب با بهره گیری از مدل های یادگیری ماشین (RF و SVM) تحت سناریوها و دوره های زمانی مختلف تغییر اقلیم مورد ارزیابی قرار می گیرد. همچنین، برآورد میزان اهمیت عوامل مؤثر در وقوع سیلاب و ارزیابی عملکرد نقشه های تولید شده انجام می پذیرد. نقشه های حاصل از این فرآیند، با برجسته سازی اثرات تغییر اقلیم بر سیلاب ها، اطلاعات و بینش لازم را جهت تدوین راهبردهای مدیریت ریسک و سازگاری فراهم می آورند.

ارزیابی هم خطی چندگانه و عوامل مهم مؤثر بر سیلاب

در بررسی اهمیت عوامل (شکل ۶)، مدل جنگل تصادفی (RF) نشان داد که متغیرهای توپوگرافی و هیدرولوژیکی شامل ارتفاع (Elevation)، شاخص قدرت جریان (SPI)، جهت شیب (Aspect)، شیب (Slope)، شاخص رطوبت توپوگرافی (TWI) و بارش (Rainfall) با مقادیر نزدیک به هم (حدود ۸/۷ تا ۲/۸ درصد) بیشترین نقش را در وقوع سیلاب دارند. در مقابل، مدل ماشین بردار پشتیبان (SVM) رفتار متفاوتی نشان داد؛ به طوری که جهت شیب (بیش از ۱۱ درصد) در صدر قرار گرفت و پس از آن SPI (حدود ۲/۱۰ درصد)، انحنای پروفیل (Profile curvature)، TWI و تراکم زهکشی بیشترین وزن را به خود اختصاص دادند. مقایسه این دو مدل حاکی از آن است که هر دو بر اهمیت متغیرهای کنترل کننده مورفولوژی حوضه نظیر SPI، TWI و جهت شیب (توافق دارند؛ اما درحالی که عواملی مانند بارش و ارتفاع در مدل RF بسیار کلیدی (حدود ۸ درصد) ارزیابی شده اند، در مدل SVM وزن بسیار ناچیزی (کمتر از ۳ درصد) دریافت کرده اند. این تفاوت فاحش، نشان دهنده توانایی برتر الگوریتم های مبتنی بر درخت تصمیم مانند RF در شناسایی روابط غیرخطی و درک بهتر اهمیت داده های اقلیمی نظیر خروجی های دقیق بارش CMIP6 در رخداد سیلاب است.



شکل ۶- اهمیت نسبی عوامل مؤثر بر وقوع سیلاب، رتبه بندی شده توسط مدل های RF و SVM

Fig.6. Relative importance of factors influencing flood occurrence, ranked by the RF and SVM models.

نقشه های توزیع حساسیت به سیلاب


در این پژوهش، نقشه های حساسیت به سیلاب حوزه قره سو با استفاده از مدل های RF و SVM تولید و با بکارگیری الگوریتم فواصل طبیعی (Natural break/Jenks) در محیط نرم افزار ArcGIS به پنج طبقه (بسیار کم تا بسیار زیاد) دسته بندی شدند (Shafizadeh-Moghadam, Valavi, Shahabi, Chapi & Shirzadi, 2018). بررسی توزیع مکانی و مساحتی (اشکال ۷ و ۸) نشان داد که پهنه های پرخطر (حساسیت زیاد و بسیار زیاد) در هر دو مدل عمدتاً در نوار مرکزی پایین دست و جنوب شرقی حوزه متمرکز هستند. با این حال، سهم طبقات حساسیت (بسیار زیاد، زیاد، متوسط، کم، بسیار کم) در مدل RF به ترتیب معادل ۱۰/۱٪، ۱۴/۲٪، ۱۹/۳٪، ۳۳/۵٪ و ۲۲/۹٪ برآورد شد (مجموعاً ۲۴/۳٪ برای مناطق پرخطر)؛ درحالی که مدل SVM گستردگی مکانی بیشتری را برای مناطق پرخطر پیش بینی کرد و سهم طبقات را به ترتیب ۱۷/۷٪، ۱۹/۰٪، ۱۵/۲٪، ۲۰/۱٪ و ۲۸/۱٪ (مجموعاً ۳۶/۷٪ برای مناطق پرخطر) نشان داد. از منظر ژئومورفولوژیکی، تمرکز این پهنه های حساس در دشت پست کرمانشاه (بخش های مرکزی و جنوب شرقی) کاملاً توجیه پذیر است؛ چرا که رواناب های سطحی حاصل از شیب تند کوهستان های حاشیه ای در شمال و غرب، مستقیماً به این دشت هموار سرازیر شده و به دلیل توسعه گسترده سطوح نفوذناپذیر شهری و اراضی کشاورزی، ریسک سیلاب را به شدت تشدید می کنند.

در نهایت، نتایج اعتبارسنجی حاکی از برتری مطلق الگوریتم جنگل تصادفی بود. مدل RF با ثبت سطح زیر منحنی-ROC (AUC برابر با ۷۵/۹۴ در مرحله اعتبارسنجی (Validating)، کمترین میزان خطای RMSE ۳۰/۰ و بالاترین نرخ حساسیت ۸۹/۹۱)، دقت بسیار بالاتری را نسبت به مدل SVM با AUC معادل ۳۵/۷۲ به نمایش گذاشت که این سطح از دقت، قابلیت اتکای بالای آن را جهت برنامه ریزی های مدیریتی تأیید می کند (Muis, Güneralp, Jongman, Aerts & Ward, 2015; Arabameri, Rezaei, Cerdà, Conoscenti & Kalantari, 2019; Choubin et al., 2019).

جدول ۶- اعتبارسنجی مدل های RF و SVM در تولید نقشه های حساسیت به سیلاب

Table 6- Validation of RF and SVM models in generating flood susceptibility maps

مدل Model	مرحله Phase	ROC-AUC (%)	PPV (%)	NPV (%)	حساسیت (%)Sensitivity	ویژگی (%)Specificity	RMSE
RF	آموزش (Training)	100.0	100.0	100.0	100.0	100.0	0.12
RF	اعتبارسنجی (Validating)	94.75	89.47	88.0	91.89	84.62	0.30
SVM	آموزش (Training)	73.09	66.37	80.65	92.59	39.68	0.45
SVM	اعتبارسنجی (Validating)	72.35	69.81	100.0	100.0	38.46	0.43



شکل ۷- نقشه حساسیت به سیلاب تولید شده با استفاده از (a) مدل RF؛ و (b) مدل SVM در دوره تاریخی.


Fig.7. Flood susceptibility maps generated using (a) RF model; and (b) SVM model in the historical period.

شکل ۸- درصد مساحت واقع در طبقات مختلف حساسیت به سیلاب، تولید شده توسط (الف) مدل RF؛ و (ب) مدل SVM بر اساس سناریوی بارش مشاهداتی

Fig.8. Percentage of area located in different flood susceptibility classes, generated by (a) RF model; and (b) SVM model based on the observed precipitation scenario.

ارزیابی و مقایسه مدل‌ها

شکل ۹، دقت هر یک از مدل‌های پیش‌بینی کننده را بر اساس منحنی ویژگی عملکرد سیستم و شاخص آماری سطح زیر منحنی (AUC) به وضوح نشان می‌دهد. مدل RF عملکرد فوق العاده‌ای از خود نشان داد؛ به طوری که برای مجموعه داده‌های آموزش (Training) به این مقادیر بی نقص دست یافت: NPV (۱۰۰.۰٪)، PPV (۱۰۰.۰٪)، AUC (۱۰۰.۰٪)، حساسیت یا sensitivity (۱۰۰.۰٪)، ویژگی یا specificity (۱۰۰.۰٪) و خطای RMSE (۰.۱۲). برای مجموعه داده‌های اعتبارسنجی (Validating)، مقادیر متناظر نیز حاکی از قدرت پیش‌بینی بسیار بالای این مدل است و عبارتند از: NPV (۸۸.۰٪)، PPV (۸۹.۴۷٪)، AUC (۹۴.۷۵٪)، حساسیت (۹۱.۸۹٪)، ویژگی (۸۴.۶۲٪) و RMSE (۰.۳۰). در مدل SVM، ارزیابی مجموعه داده‌های آموزش مقادیر زیر را به همراه داشت: NPN (۸۰.۶۵٪)، PPV (۶۶.۳۷٪)، AUC (۷۳.۰۹٪)، حساسیت (۹۲.۵۹٪)، ویژگی (۳۹.۶۸٪) و RMSE (۰.۴۵). برای مجموعه داده‌های اعتبارسنجی نیز این مقادیر به این شرح است: NPV (۱۰۰.۰٪)، PPV (۶۹.۸۱٪)، AUC (۷۲.۳۵٪)، حساسیت (۱۰۰.۰٪)، ویژگی (۳۸.۴۶٪) و RMSE (۰.۴۳). نتایج نشان می‌دهند در حالی که مدل RF با اختلاف، بهترین و پایدارترین عملکرد را در ارزیابی حساسیت به سیلاب در حوضه آبریز قره سو از خود نشان می‌دهد (با مساحت زیر منحنی ۹۴.۷۵٪ در مرحله اعتبارسنجی)، مدل SVM نتایج متوسط تری را ارائه می‌نماید. یافته‌های ما با سایر پژوهش‌ها همخوانی دارد و مطالعات پیشین نیز با تأکید بر توانمندی و برتری مدل‌های یادگیری ماشین نظیر RF در تولید نقشه‌های آسیب پذیری سیلاب در مناطق سیل خیز، روش‌های بکار رفته در این تحقیق را تأیید می‌کنند (Nachappa et al., 2020; Seleem, Ayzel, de Souza, Bronstert & Heistermann, 2022).



شکل ۹- منحنی ROC-AUC با استفاده از مجموعه داده‌های آموزش و اعتبارسنجی مدل‌های RF و SVM.

Fig.9. ROC-AUC curve using training and validation datasets of RF and SVM models.


تأثیر نسبی تغییر اقلیم آینده بر حساسیت به سیلاب

تهیه نقشه حساسیت به سیلاب تحت سناریوی اقلیمی آینده میانی (۲۰۴۱-۲۰۷۰)

بررسی حساسیت به سیلاب در حوضه قره سو برای آینده میانی (۲۰۴۱-۲۰۷۰) با مدل‌های RF و SVM، الگویی قابل تأمل از تأثیر نوسانات بارشی و ویژگی‌های توپوگرافی را نشان می‌دهد. برخلاف انتظار، نتایج هر دو مدل حاکی از آن است که سناریوی

خوش بینانه (SSP1-2.6) به دلیل تطابق مکانی الگوی بارش با مورفولوژی حوضه، بیشترین گستره ی پرخطر سیلاب را ایجاد می کند. در مقابل، در سناریوی بدبینانه (SSP5-8.5)، بارش های شدید زمستانه بیشتر ماهیت نقطه ای داشته و در مقیاس سالانه، مساحت یکپارچه کمتری از حوضه را در کلاس های خطر زیاد و بسیار زیاد درگیر می کنند.

با این وجود، تحلیل های مکانی ثابت می کند که فارغ از نوع سناریوی اقلیمی، اراضی پایین دست و دشت های مرکزی قره سو همواره گلوگاه های بحرانی منطقه محسوب می شوند. سرازیر شدن رواناب های پرسرعت از ارتفاعات به این مناطق مسطح دارای کاربری های متراکم و سطوح نفوذناپذیر، خطر بروز خسارات سنگین را به شدت افزایش می دهد. این یافته ها ضرورت درک روابط پیچیده و غیرخطی میان بارش و مورفولوژی را برای مدیریت جامع و مؤثر ریسک سیلاب نمایان می سازد.




شکل ۱۰- نقشه های حساسیت به سیلاب پیش بینی شده تحت سناریوی اقلیمی آینده میانی (۲۰۴۱-۲۰۷۰) با استفاده از مدل RF در (a) SSP2.6، (b) SSP4.5، (c) SSP8.5 و با استفاده از مدل SVM در (d) SSP4.5، (e) SSP8.5 و (f) SSP8.5.

Fig.10. Predicted flood susceptibility maps under mid-future climate scenarios (2041–2070) using the RF model for (a) SSP2.6, (c) SSP4.5, and (e) SSP8.5; and using the SVM model for (b) SSP2.6, (d) SSP4.5, and (f) SSP8.5.

تهیه نقشه حساسیت به سیلاب تحت سناریوی اقلیمی آینده دور (۲۰۷۱-۲۱۰۰)


بررسی نقشه های حساسیت به سیلاب حوضه قره سو در افق آینده دور (۲۰۷۱-۲۱۰۰) نشان دهنده تغییرات بنیادین و نگران کننده تحت تأثیر تغییر اقلیم است. بر اساس خروجی همسو از دو مدل RF و SVM، با افزایش شدید بارش ها در بدبینانه ترین سناریو (SSP5-8.5)، حدود نیمی از مساحت کل حوضه در وضعیت بحرانی خطر سیلاب قرار می گیرد. در این شرایط، پهنه های سیل خیز از مناطق پست پایین دست فراتر رفته و به شکل گسترده ای ارتفاعات را نیز درگیر خواهند کرد که این زنگ خطر، ضرورت اتخاذ فوری راهبردهای کلان مدیریت ریسک را گوشزد می کند.



شکل ۱۱- درصد مساحت طبقات حساسیت به سیلاب بر اساس سناریوی اقلیمی آینده میانی (۲۰۴۱-۲۰۷۰) با استفاده از مدل RF

در SSP2.6؛ (a) SSP2.6؛ (b) SSP4.5؛ (c) SSP8.5؛ و با استفاده از مدل SVM در SSP2.6؛ (d) SSP2.6؛ (e) SSP4.5؛ و (f) SSP8.5.


Fig.11. Percentage of area in flood susceptibility classes based on the mid-future climate scenario (2041–2070) using the RF model for (a) SSP2.6, (b) SSP4.5, and (c) SSP8.5; and using the SVM model for (d) SSP2.6, (e) SSP4.5, and (f) SSP8.5.



شکل ۱۲- درصد مساحت طبقات حساسیت به سیلاب بر اساس سناریوی اقلیمی آینده دور (۲۰۷۱-۲۱۰۰) با استفاده از مدل RF در

در SSP2.6؛ (a) SSP2.6؛ (b) SSP4.5؛ و (c) SSP8.5؛ و با استفاده از مدل SVM در SSP2.6؛ (d) SSP2.6؛ (e) SSP4.5؛ و (f) SSP8.5.

Fig.12. Percentage of area in flood susceptibility classes based on the far-future climate scenario (2071–2100) using the RF model for (a) SSP2.6, (b) SSP4.5, and (c) SSP8.5; and using the SVM model for (d) SSP2.6, (e) SSP4.5, and (f) SSP8.5.




شکل ۱۳- نقشه های حساسیت به سیلاب پیش بینی شده تحت سناریوی اقلیمی آینده دور (۲۰۷۱-۲۱۰۰) با استفاده از مدل RF در (a) SSP2.6؛ (c) SSP4.5؛ و (e) SSP8.5؛ و با استفاده از مدل SVM در (b) SSP2.6؛ (d) SSP4.5؛ و (f) SSP8.5.

Fig.13. Predicted flood susceptibility maps under the far-future climate scenario (2071–2100) using the RF model for (a) SSP2.6, (c) SSP4.5, and (e) SSP8.5; and using the SVM model for (b) SSP2.6, (d) SSP4.5, and (f) SSP8.5.

ارزیابی دقت مدل ها و نقشه های آینده

در این مطالعه، دقت مدل های RF و SVM برای پیش بینی و تهیه نقشه حساسیت به سیلاب تحت سناریوهای مختلف تغییر اقلیم (در دو افق آینده میانی و دور) ارزیابی شده است. بررسی نتایج مبتنی بر شاخص های آماری نشان می دهد که مدل RF با دقت بالای ۹۰ درصد در تمامی زمان ها و سناریوها، عملکرد بسیار دقیق تر و پایدارتری نسبت به مدل SVM (با دقت حدود ۷۷ تا ۸۱ درصد) داشته و برای این پیش بینی ها کاملاً برتر است.



شکل ۱۴- منحنی ROC-AUC با استفاده از مجموعه داده های اعتبارسنجی مدل های RF و SVM تحت سناریوهای مختلف SSP2.6، SSP4.5 و SSP8.5 در سری های زمانی (a) آینده میانی (۲۰۴۱-۲۰۷۰)؛ و (b) آینده دور (۲۰۷۱-۲۱۰۰)

Fig.14. ROC-AUC curve using the validation datasets of the RF and SVM models under different SSP2.6, SSP4.5, and SSP8.5 scenarios for the (a) mid-future horizon (2041–2070); and (b) far-future horizon (2071–2100).

نتیجه گیری

پژوهش حاضر با هدف ارزیابی و پیش بینی حساسیت به سیلاب در حوضه آبریز قره سو، یک رویکرد نوین و تلفیقی از مدل های اقلیمی فاز ششم (CMIP6) و الگوریتم های یادگیری ماشین را به کار گرفت. ارزیابی مدل های گردش عمومی اقلیم نشان داد که پس از اعمال تکنیک تصحیح اریب (DM)، مدل MPI-ESM1-2-HR با کمترین میزان خطا و بالاترین همبستگی با داده های مشاهداتی، دقیق ترین عملکرد را در شبیه سازی روندهای بارشی منطقه دارد. در فاز مدل سازی مکانی نیز، مقایسه دو الگوریتم یادگیری ماشین حاکی از برتری مطلق و پایداری خیره کننده مدل جنگل تصادفی (RF) بود. این مدل با ثبت سطح زیر منحنی (ROC-AUC) برابر با ۷۵/۹۴ درصد در مرحله اعتبارسنجی و حفظ دقت بالای ۹۰ درصد در تمامی سناریوهای اقلیمی آینده، توانایی بسیار بالاتری در درک روابط پیچیده و غیرخطی میان متغیرهای محرک سیلاب به ویژه بارش، شاخص های مورفولوژیکی نظیر SPI و TWI و ویژگی های توپوگرافی نسبت به مدل ماشین بردار پشتیبان (SVM) از خود نشان داد.

تحلیل سناریوهای اقلیمی در دو افق آینده میانی (۲۰۴۱-۲۰۷۰) و دور (۲۰۷۱-۲۱۰۰) بیانگر تغییرات نگران کننده ای در رژیم هیدرولوژیکی حوضه است. نتایج نشان می دهد که تحت تأثیر تغییر اقلیم، توزیع فصلی بارش ها دستخوش نوسانات شدید شده و رویدادهای بارش فرین به ویژه در فصول زمستان به شدت افزایش خواهد یافت، به طوری که در افق آینده دور و تحت بدبینانه ترین سناریوی انتشار (SSP5-8.5)، حجم بارش ها در برخی ایستگاه های کوهستانی مانند روانسر بیش از دو برابر خواهد شد. این نوسانات شدید بارشی، مستقیماً بر الگوی مکانی خطر سیلاب تأثیر گذاشته و توزیع فضایی آن را دگرگون می سازد. نقشه های پیش بینی آینده نشان می دهند که پهنه های بحرانی، دیگر تنها به دشت های پست و متراکم مرکزی و جنوب شرقی محدود نخواهند بود، بلکه تحت سناریوی بدبینانه، مناطق در معرض خطر شدید به سمت نواحی بالادست نیز گسترش یافته و حدود نیمی از مساحت کل حوضه را درگیر خواهند کرد.

این تغییر الگوی مکانی و گسترش چشمگیر پهنه های پرخطر، زنگ خطری جدی برای تاب آوری زیرساخت ها، اراضی کشاورزی و سکونتگاه های انسانی در حوضه قره سو محسوب می شود. هم افزایی بارش های سیل آسای آینده با شیب های تند ارتفاعات و همچنین توسعه سطوح نفوذناپذیر در دشت ها، پتانسیل بروز خسارات فاجعه بار را به شدت بالا می برد. بر این اساس، یافته های این پژوهش لزوم گذار از رویکردهای سنتی به سمت استراتژی های پیشگیرانه و سازگار با اقلیم را گوشزد می کند. برنامه ریزان و

مدیران محیطی باید با بهره گیری از این نقشه های آسیب پذیری با تفکیک بالا، اقداماتی نظیر بازنگری در حریم بستر رودخانه ها، کنترل کاربری اراضی شهری، اجرای پروژه های آبخیزداری در بالادست و توسعه زیرساخت های مهندسی مهار سیلاب را در اولویت برنامه های کلان مدیریتی قرار دهند.

سپاسگزاری

این اثر تحت حمایت مادی بنیاد ملی علم ایران (INSF) برگرفته از طرح شماره ۴۰۴۰۲۷۰۵ انجام شده است.

References

- Abedi, R., Costache, R., Shafizadeh-Moghadam, H., & Pham, Q. B. (2022). Flash-flood susceptibility mapping based on XGBoost, random forest and boosted regression trees. *Geocarto International*, 37(19), 5479-5496. <https://doi.org/10.1080/10106049.2021.1920636>
- Arabameri, A., Rezaei, K., Cerdà, A., Conoscenti, C., & Kalantari, Z. (2019). A comparison of statistical methods and multi-criteria decision making to map flood hazard susceptibility in Northern Iran. *Science of The Total Environment*, 660, 443–458. <https://doi.org/10.1016/j.scitotenv.2019.01.021>
- Arnell, N. W., & Gosling, S. N. (2016). The impacts of climate change on river flood risk at the global scale. *Climatic Change*, 134(3), 387-401. <https://doi.org/10.1007/s10584-014-1084-5>
- Asencios, H., Lavado, W., & Sabino, E. (2023). Climate change effects on flooding at Lurin river basin, Peru. *EGU General Assembly Conference Abstracts*, 9028. <https://doi.org/10.5194/egusphere-egu23-9028>
- Bahrami, A., & Dastorani, M. (2021). Estimation of flood hydrograph in the ungauged Gharasou watershed using the Gamma synthetic unit hydrograph model. *Journal of Hydrogeomorphology*, 8(29), 173-186. [in Persian] <https://doi.org/10.22034/hyd.2022.49180.1614>
- Bai, M., Tahmasebipour, N., Zeinivand, H., Sadoddin, A. & Kaheh, M. (2024). Investigating the Two-Dimensional HEC-RAS Model Capability for Flood Risk Mapping in the Qarachai River in Ramian, Golestan Province. *Journal of Geography and Environmental Hazards*, 12(4), 187–203. [in Persian] <https://doi.org/10.22067/geoch.2022.75557.1185>
- Mosavi, A., Ozturk, P., & Chau, K. W. (2018). Flood prediction using machine learning models: Literature review. *Water*, 10(11), 1536. <https://doi.org/10.3390/w10111536>
- Band, S. S., Janizadeh, S., Chandra Pal, S., Saha, A., Chakraborty, R., Melesse, A. M., & Mosavi, A. (2020). Flash flood susceptibility modeling using new approaches of hybrid and ensemble tree-based machine learning algorithms. *Remote Sensing*, 12(21), 3568. <https://doi.org/10.3390/rs12213568>
- Behzadi, F., Javadi, S., Hafezi, S., Vasheghani Farahani, E., & Golmohammadi, G. (2024). Flood risk projection in Iran using CMIP6 models and frequency analysis of precipitation. *Stochastic Environmental Research and Risk Assessment*, 38, 4843–4861. <https://doi.org/10.1007/s00477-024-02835-8>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Chen, G., Hou, J., Liu, Y., Xue, S., Wu, H., Wang, T., ... & Yang, S. (2024). Urban inundation rapid prediction method based on multi-machine learning algorithm and rain pattern analysis. *Journal of Hydrology*, 633, 131059. <https://doi.org/10.1016/j.jhydrol.2024.131059>
- Choubin, B., Moradi, E., Golshan, M., Adamowski, J., Sajedi-Hosseini, F., & Mosavi, A. (2019). An ensemble prediction of flood susceptibility using multivariate discriminant analysis, classification and regression trees, and support vector machines. *Science of The Total Environment*, 651, 2087–2096. <https://doi.org/10.1016/j.scitotenv.2018.10.064>
- Copernicus Climate Change Service, Climate Data Store. (2021). CMIP6 climate projections. Copernicus Climate Change Service (C3S) Climate Data Store (CDS). <https://doi.org/10.24381/cds.c866074c>

- Deng, Z., Wang, Z., Wu, X., Lai, C., & Liu, W. (2023). Effect difference of climate change and urbanization on extreme precipitation over the Guangdong-Hong Kong-Macao Greater Bay Area. *Atmospheric Research*, 282, 106514. <https://doi.org/10.1016/j.atmosres.2022.106514>
- Gholami, F., Nemati, A., Li, Y., & Zhang, J. (2022). Calculation of runoff computation cost and sensitivity analysis of topological attributes. *Remote Sensing Applications: Society and Environment*, 26, 100714. <https://doi.org/10.1016/j.rsase.2022.100714>
- Hengl, T., Nussbaum, M., Wright, M. N., Heuvelink, G. B., & Gräler, B. (2018). Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *Peer Journal*, 6, e5518. <https://doi.org/10.7717/peerj.5518>
- Heo, J.-H., Ahn, H., Shin, J.-Y., Kjeldsen, T. R., & Jeong, C. (2019). Probability distributions for a quantile mapping technique for a bias correction of precipitation data: A case study to precipitation data under climate change. *Water*, 11(7), 1475. <https://doi.org/10.3390/w11071475>
- Hooshyaripor, F., Faraji-Ashkavar, S., Koohyian, F., Tang, Q., & Noori, R. (2020). Annual flood damage influenced by El Niño in the Kan River basin, Iran. *Natural Hazards and Earth System Sciences*, 20(10), 2739-2751. <https://doi.org/10.5194/nhess-20-2739-2020>
- Hooshyaripor, F., Faraji-Ashkavar, S., Koohyian, F., Tang, Q., & Noori, R. (2024). Quantifying the impact of future climate change on flood susceptibility: An integration of CMIP6 models, machine learning, and remote sensing. *Journal of Water Resources Planning and Management*, 150(9), 04024035. <https://doi.org/10.1061/JWRMD5.WRENG-6344>
- Iosub, M., Minea, G., Chelariu, O. E., & Urzica, A. (2020). Assessment of flash flood susceptibility potential in Bârlad river catchment using bivariate statistics and machine learning approaches. *Water*, 12(12), 3465. <https://doi.org/10.3390/w12123465>
- Janizadeh, S., Kim, D., Jun, C., Bateni, S. M., Pandey, M., & Mishra, V. N. (2024). Impact of climate change on future flood susceptibility projections under shared socioeconomic pathway scenarios in South Asia using artificial intelligence algorithms. *Journal of Environmental Management*, 124785. <https://doi.org/10.1016/j.jenvman.2024.124785>
- Jiang, D., Hu, D., Tian, Z., & Lang, X. (2020). Differences between CMIP6 and CMIP5 models in simulating climate over China and the East Asian monsoon. *Advances in Atmospheric Sciences*, 37(10), 1102-1118. <https://doi.org/10.1007/s00376-020-2034-y>
- Jiang, Z., Yang, S., Liu, Z., Xu, Y., Xiong, Y., Qi, S., ... & Xu, T. (2022). Coupling machine learning and weather forecast to predict farmland flood disaster: A case study in Yangtze River basin. *Environmental Modelling & Software*, 155, 105436. <https://doi.org/10.1016/j.envsoft.2022.105436>
- Kazemi, M., Mohammadi, F., Nafooti, M. H., Behvar, K., & Kariminejad, N. (2024). Flood susceptibility mapping using machine learning and remote sensing data in the Southern Karun Basin, Iran. *Applied Geomatics*, 16(3), 731-750. <https://doi.org/10.1007/s12518-024-00582-7>
- Khodaei, H., Nasiri Saleh, F., Nobakht Dalir, A., & Zarei, E. (2025). Future flood susceptibility mapping under climate and land use change. *Scientific Reports*, 15, 12394. <https://doi.org/10.1038/s41598-025-12394-x>
- Khosravi, K., Pham, B. T., Chapi, K., Shirzadi, A., Shahabi, H., Revhaug, I., ... & Bui, D. T. (2018). A comparative assessment of decision trees algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. *Science of The Total Environment*, 627, 744-755. <https://doi.org/10.1016/j.scitotenv.2018.01.266>
- Khosravi, K., Shahabi, H., Pham, B. T., Adamowski, J., Shirzadi, A., Pradhan, B., ... & Ho, H. L. (2019). A comparative assessment of flood susceptibility modeling using multi-criteria decision-making analysis and machine learning methods. *Journal of Hydrology*, 573, 311-323. <https://doi.org/10.1016/j.jhydrol.2019.03.073>
- Li, X., & Li, Z. (2023). Evaluation of bias correction techniques for generating high-resolution daily temperature projections from CMIP6 models. *Climate Dynamics*, 61(7-8), 3893-3910. <https://doi.org/10.1007/s00382-023-06778-8>

- Liu, J., Wang, J., Xiong, J., Cheng, W., Li, Y., Cao, Y., ... & Yang, G. (2022). Assessment of flood susceptibility mapping using support vector machine, logistic regression and their ensemble techniques in the Belt and Road region. *Geocarto International*, 37(25), 9817-9846. <https://doi.org/10.1080/10106049.2022.2025918>
- Luu, C., Von Meding, J., & Kanjanabootra, S. (2021). Spatial flood risk assessment using multi-criteria decision analysis and remote sensing data in Quang Binh province, Vietnam. *Water*, 13(12), 1655. <https://doi.org/10.3390/w13121655>
- Maghsood, F. F., Moradi, H., Massah Bavani, A. R., Panahi, M., Berndtsson, R., & Hashemi, H. (2019). Climate change impact on flood frequency and source area in northern Iran under CMIP5 scenarios. *Water*, 11(2), 273. <https://doi.org/10.3390/w11020273>
- McGrath, H. (2026). Multi-event machine learning for annual flood susceptibility prediction across Canada. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XI-M-1-2026, 21–29. <https://doi.org/10.5194/isprs-annals-XI-M-1-2026-21-2026>
- Mohanty, M. P., & Simonovic, S. P. (2021). Changes in floodplain regimes over Canada due to climate change impacts: Observations from CMIP6 models. *Science of The Total Environment*, 792, 148323. <https://doi.org/10.1016/j.scitotenv.2021.148323>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247–259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Muis, S., Güneralp, B., Jongman, B., Aerts, J. C. J. H., & Ward, P. J. (2015). Flood risk and adaptation strategies under climate change and urban expansion: A probabilistic analysis using global data. *Science of the Total Environment*, 538, 445–457. <https://doi.org/10.1016/j.scitotenv.2015.08.068>
- Nachappa, T. G., Piralilou, S. T., Gholamnia, K., Ghorbanzadeh, O., Rahmati, O., & Blaschke, T. (2020). Flood susceptibility mapping with machine learning, multi-criteria decision analysis and ensemble using Dempster Shafer Theory. *Journal of Hydrology*, 590, 125275. <https://doi.org/10.1016/j.jhydrol.2020.125275>
- Nguyen, H. D., Nguyen, Q. H., Du, Q. V. V., Nguyen, T. H. T., Nguyen, T. G., & Bui, Q. T. (2022). A novel combination of Deep Neural Network and Manta Ray Foraging Optimization for flood susceptibility mapping in Quang Ngai province, Vietnam. *Geocarto International*, 37(25), 7531-7555. <https://doi.org/10.1080/10106049.2021.1975832>
- Pastén-Zapata, E., Jones, J. M., Moggridge, H., & Widmann, M. (2020). Evaluation of the performance of Euro-CORDEX Regional Climate Models for assessing hydrological climate change impacts in Great Britain: A comparison of different spatial resolutions and quantile mapping bias correction methods. *Journal of Hydrology*, 584, 124653. <https://doi.org/10.1016/j.jhydrol.2020.124653>
- Rathjens, H., Bieger, K., Srinivasan, R., Chaubey, I., & Arnold, J. (2016). *CMhyd user manual: Documentation for preparing simulated climate change data for hydrologic impact studies*. USDA Agricultural Research Service.
- Reshmidevi, T., Kumar, D. N., Mehrotra, R., & Sharma, A. (2018). Estimation of the climate change impact on a catchment water balance using an ensemble of GCMs. *Journal of Hydrology*, 556, 1192-1204. <https://doi.org/10.1016/j.jhydrol.2017.02.016>
- Sadler, J. M., Goodall, J. L., Morsy, M. M., & Spencer, K. (2018). Modeling urban coastal flood severity from crowd-sourced flood reports using Poisson regression and random forest. *Water Resources Research*, 54(11), 9037–9052. <https://doi.org/10.1029/2018WR023403>
- Seleem, O., Ayzel, G., de Souza, A. C. T., Bronstert, A., & Heistermann, M. (2022). Towards urban flood susceptibility mapping using data-driven models in Berlin, Germany. *Geomatics, Natural Hazards and Risk*, 13(1), 1640–1662. <https://doi.org/10.1080/19475705.2022.2097131>
- Shafizadeh-Moghadam, H., Valavi, R., Shahabi, H., Chapi, K., & Shirzadi, A. (2018). Novel forecasting approaches using combination of machine learning and statistical models for flood susceptibility mapping. *Journal of Environmental Management*, 217, 1–11. [in Persian] <https://doi.org/10.1016/j.jenvman.2018.03.089>

- Szczurek, A., Gonstał, D., & Maciejewska, M. (2023). The gas sensing drone with the lowered and lifted measurement platform. *Sensors*, 23(3), 1253. <https://doi.org/10.3390/s23031253>
- Tang, S., Gleckler, P., Xie, S., Lee, J., Ahn, M.-S., Covey, C., & Zhang, C. (2021). Evaluating the diurnal and semidiurnal cycle of precipitation in CMIP6 models using satellite-and ground-based observations. *Journal of Climate*, 34(8), 3189–3210. <https://doi.org/10.1175/JCLI-D-20-0639.1>
- Tehrany, M. S., Pradhan, B., Mansor, S., & Ahmad, N. (2015). Flood susceptibility assessment using GIS-based support vector machine model with different kernel types. *Catena*, 125, 91–101. <https://doi.org/10.1016/j.catena.2014.10.017>
- Teutschbein, C., & Seibert, J. (2012). Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *Journal of Hydrology*, 456, 12–29. <https://doi.org/10.1016/j.jhydrol.2012.05.052>
- Ullah, K., Wang, Y., Xi, C., Du, B., Li, P., Liu, T., ... & Hamed, M. M. (2025). Multi-Scenario flood susceptibility projections in the Eastern Hindu kush: integrating machine Learning, CMIP6, and land use change. *Earth Systems and Environment*, 1-20. <https://doi.org/10.1007/s41748-025-00793-x>
- Usta, D. F. B., Teymouri, M., & Chatterjee, U. (2022). Assessment of temperature changes over Iran during the twenty-first century using CMIP6 models under SSP1-26, SSP2-4.5, and SSP5-8.5 scenarios. *Arabian Journal of Geosciences*, 15(5), 1–16. <https://doi.org/10.1007/s12517-022-09709-9>
- Wang, J., Sanderson, J., Iqbal, S., & Woo, W. L. (2025). Accelerated and interpretable flood susceptibility mapping through explainable deep learning with hydrological prior knowledge. *Remote Sensing*, 17(9), 1540. <https://doi.org/10.3390/rs17091540>
- Wang, Q., Xu, Y., Wang, Y., Zhang, Y., Xiang, J., Xu, Y., & Wang, J. (2020). Individual and combined impacts of future land-use and climate conditions on extreme hydrological events in a representative basin of the Yangtze River Delta, China. *Atmospheric Research*, 236, 104805. <https://doi.org/10.1016/j.atmosres.2019.104805>
- Wang, X., Wang, J., Wang, X., & Yu, C. (2022). A pseudo-spectral Fourier collocation method for inhomogeneous elliptical inclusions with partial differential equations. *Mathematics*, 10(3), 296. <https://doi.org/10.3390/math10030296>
- Wu, Y., Liu, Y., Zhou, W., & Zhang, J. (2022). The mid-Holocene East Asian summer monsoon simulated by PMIP4-CMIP6 and PMIP3-CMIP5: Model uncertainty and its possible sources. *Global and Planetary Change*, 219, 103986. <https://doi.org/10.1016/j.gloplacha.2022.103986>
- Xiang, Y., Wang, Y., Chen, Y., & Zhang, Q. (2022). Impact of climate change on the hydrological regime of the Yarkant River Basin, China: An assessment using three SSP scenarios of CMIP6 GCMs. *Remote Sensing*, 14(1), 115. <https://doi.org/10.3390/rs14010115>
- Yazdandoost, F., Moradian, S., Izadi, A., & AghaKouchak, A. (2021). Evaluation of CMIP6 precipitation simulations across different climatic zones: Uncertainty and model intercomparison. *Atmospheric Research*, 250, 105369. <https://doi.org/10.1016/j.atmosres.2020.105369>
- Yousefi, S., Pourghasemi, H. R., Emami, S. N., Rahmati, O., Tavangar, S., Pouyan, S., ... & Nekoeimehr, M. (2020). Assessing the susceptibility of schools to flood events in Iran. *Scientific Reports*, 10(1), 1–15. <https://doi.org/10.1038/s41598-020-75291-3>
- Zamani, Y., Hashemi Monfared, S. A., & Hamidianpour, M. (2020). A comparison of CMIP6 and CMIP5 projections for precipitation to observational data: The case of Northeastern Iran. *Theoretical and Applied Climatology*, 142(3), 1613-1623. <https://doi.org/10.1007/s00704-020-03406-x>
- Zangeneh Asadi, M. A., Goli Mokhtari, L. & Namitabar, M. (2026). Flood Risk Assessment, Prediction and Zonation in the Kashafrud Basin Using Machine Learning Algorithms. *Journal of Geography and Environmental Hazards*, 15(2), 63–92. [in Persian] <https://doi.org/10.22067/geoh.2026.96351.1624>

- Zarrin, A., & Dadashi-Roudbari, A. (2021). Projection of future extreme precipitation in Iran based on CMIP6 multi-model ensemble. *Theoretical and Applied Climatology*, 144, 643–660. <https://doi.org/10.1007/s00704-021-03568-2>
- Zarrin, A., & Dadashi-Roudbari, A. (2024). Assessment of mean precipitation and precipitation extremes in Iran as simulated by dynamically downscaled RegCM4. *Dynamics of Atmospheres and Oceans*, 106, 101452. <https://doi.org/10.1016/j.dynatmoce.2024.101452>
- Zarrin, A., Dadashi-Roudbari, A., & Hassani, S. (2022). Future changes in precipitation extremes over Iran: Insight from a CMIP6 bias-corrected multi-model ensemble. *Pure and Applied Geophysics*, 179(1), 441–464. <https://doi.org/10.1007/s00024-021-02904-x>
- Zhao, G., Pang, B., Xu, Z., Peng, D., & Xu, L. (2019). Assessment of urban flood susceptibility using semi-supervised machine learning model. *Science of The Total Environment*, 659, 940–949. <https://doi.org/10.1016/j.scitotenv.2018.12.217>
- Zhu, Y. Y., & Yang, S. (2020). Evaluation of CMIP6 for historical temperature and precipitation over the Tibetan Plateau and its comparison with CMIP5. *Advances in Climate Change Research*, 11(3), 239–251. <https://doi.org/10.1016/j.accre.2020.08.001>