



Comparison of machine learning methods for statistical downscaling of climate models precipitation and temperature

Ali Sadian¹, Nima Nemati Shishehgaran^{*2}

1. Ph.D. Candidate, Department of Water Engineering and Management, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran, Email: Ali.sadian@modares.ac.ir
2. Former M.Sc. Student, Department of Water Engineering and Management, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran, Email: Nima.Nemati@modares.ac.ir

ARTICLE INFO	ABSTRACT
Article type: Article history Received: 07 December 2025 Revised: 07 January 2026 Accepted: 19 January 2026 Published online: 20 January 2026 Keywords: Climate change, General circulation models, Multilayer perceptron, Support vector machine, Random forest, Upstream Karkheh River Basin	Statistical downscaling of General Circulation Model (GCM) outputs to obtain accurate climate estimates at local scales is one of the fundamental challenges in climate change studies, particularly in hydrologically sensitive regions. Considering the limitations of conventional statistical methods and the emergence of modern machine learning algorithms, the present study aims to evaluate the performance of three methods—Multilayer Perceptron (MLP), Support Vector Machine (SVM), and Random Forest (RF)—for downscaling precipitation and temperature variables. Accordingly, the outputs of 10 CMIP6 climate models under four scenarios (SSP1-2.6, SSP2-4.5, SSP3-7.0, and SSP5.58) were extracted for the upstream basin of the Karkheh Dam during the historical period 1990–2014. The data were used for training for 20 years, and five years for testing the models.. Evaluation results based on three statistical indices (R^2, MAE, and RMSE) showed that the RF method outperformed the other two methods for both precipitation and temperature, while SVM yielded the weakest results, particularly in precipitation downscaling. Leveraging the superior RF approach, climate variables were projected for the periods 2031-2055 and 2056-2080, with trends analyzed using the Mann-Kendall test and Sen's slope estimator. The findings indicated that mean precipitation decreases under all four scenarios, with reductions of approximately 2.96% to 19.22%, while average temperature increases by 1.13°C to 3.13°C. Furthermore, trend analysis of precipitation and temperature variables for future periods under the evaluated scenarios indicates the persistence of natural and random fluctuations in precipitation alongside statistically significant upward trends in regional mean temperature. These results highlight the high sensitivity of the study area to climate change impacts and the necessity of employing machine-learning-based approaches to improve the accuracy of projections. Moreover, the application of these models enhances the ability to capture complex climate patterns and can effectively contribute to improving the downscaling of climate-model-simulated variables.
Citation: Sadian, A., & Nemati Shishehgaran, N. (2025). Comparison of machine learning methods for statistical downscaling of climate models precipitation and temperature. <i>Iranian Journal of Rainwater Catchment Systems</i>, 13(4), 109-132. DOR: 20.1001.1.24235970.1404.13.4.1.7	
Publisher: Iranian Rainwater Catchment Systems Association	© Author(s)



***Corresponding author:** Nima Nemati Shishehgaran

Address: Department of Water Engineering and Management, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran.

Email: Nima.Nemati@modares.ac.ir



Comparison of machine learning methods for statistical downscaling of climate models precipitation and temperature

Ali Sadian¹ , Nima Nemati Shishehgaran^{*2} 

1. Ph.D. Candidate, Department of Water Engineering and Management, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran, Email: Ali.sadian@modares.ac.ir
2. Former M.Sc. Student, Department of Water Engineering and Management, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran, Email: Nima.Nemati@modares.ac.ir

EXTENDED ABSTRACT

Introduction: Accurate regional-scale projections of climate change play a critical role in water resources management, agricultural planning, and climate adaptation strategies, particularly in hydrologically sensitive regions such as the upstream basin of the Karkheh Dam in western Iran. General Circulation Models (GCMs) are the primary tools used to simulate the Earth's climate system and assess future climate changes under different greenhouse gas emission pathways. Despite their ability to represent large-scale atmospheric and oceanic processes, GCMs operate at relatively coarse spatial resolutions, which limits their capacity to capture local-scale climatic variability, especially for precipitation and temperature in regions with complex topography. To address this limitation, downscaling techniques are employed to translate large-scale GCM outputs into finer-resolution, site-specific climate information. Among these approaches, statistical downscaling has been widely adopted due to its simplicity and lower computational demands compared to dynamical downscaling methods. However, conventional statistical techniques often rely on linear assumptions and predefined probability distributions, which restrict their ability to represent complex and nonlinear relationships between large-scale climate predictors and local climatic variables. In recent years, advances in machine learning have provided powerful alternatives for statistical downscaling, as these methods are capable of learning nonlinear patterns directly from data without strong distributional assumptions. Given the growing use of machine learning approaches and the limited number of comprehensive comparative studies in Iran, this research aims to evaluate and compare the performance of three widely applied machine learning algorithms—Multilayer Perceptron (MLP), Support Vector Machine (SVM), and Random Forest (RF)—for downscaling precipitation and temperature simulated by CMIP6 GCMs under different Shared Socioeconomic Pathway (SSP) scenarios in the upstream Karkheh River Basin.

Methodology: In this study, monthly observed precipitation and mean temperature data from 11 meteorological stations, including eight stations located within the study basin and three stations in surrounding areas, were used as reference data. The historical period from 1990 to 2014 was selected as the baseline period due to data availability and consistency across stations and climate models. This period was divided into a 20-year training phase (1990–2009) and a 5-year testing phase (2010–2014) to develop and validate the machine learning models. Climate model outputs were obtained from ten CMIP6 GCMs under four SSP scenarios (SSP1-2.6, SSP2-4.5, SSP3-7.0, and SSP5-8.5), and large-scale predictors derived from these models were statistically related to station-scale observations. Three machine learning algorithms—MLP, SVM, and RF—were implemented to establish nonlinear relationships between GCM predictors and observed climate variables. Model performance was assessed using three commonly used statistical indicators: the coefficient of determination (R^2), mean absolute error (MAE), and root mean square error (RMSE), which collectively evaluate goodness-of-fit, bias, and overall predictive accuracy. After identifying the best-performing downscaling method based on the evaluation results, this method was applied to generate future downscaled projections of precipitation and temperature for two future periods, 2031–2055 and 2056–2080. Finally, the Mann–Kendall non-parametric test and Sen's slope estimator

***Corresponding author:** Nima Nemati Shishehgaran

Address: Department of Water Engineering and Management, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran.

Email: Nima.Nemati@modares.ac.ir

were employed to analyze trends in the projected climate variables and to assess the direction and magnitude of future changes.

Results and Discussion: The comparative evaluation of the three machine learning algorithms reveals clear differences in their downscaling performance. Overall, the Random Forest method consistently outperformed MLP and SVM for both precipitation and temperature across all stations and evaluation metrics, achieving higher R^2 values and lower MAE and RMSE during both training and testing periods. The superior performance of RF can be attributed to its ensemble structure, which effectively captures complex nonlinear relationships while reducing overfitting through bootstrap sampling and averaging multiple decision trees. In contrast, the SVM approach exhibited the weakest performance, particularly for precipitation downscaling, which can be explained by the highly variable and intermittent nature of rainfall in the study region. The MLP model showed moderate performance and generally outperformed SVM, but its accuracy and robustness were lower than those of RF, especially during the testing period. Using the RF model, future climate projections indicate a consistent decrease in mean precipitation under all evaluated SSP scenarios, with reductions ranging from approximately 2.96% to 19.22% relative to the historical period. These changes are characterized by strong seasonal variability and irregular patterns, reflecting the persistence of natural and random fluctuations in precipitation. Trend analysis using the Mann–Kendall test confirms that statistically significant precipitation trends are limited in most months, although Sen's slope estimator suggests an overall downward tendency as greenhouse gas concentrations increase. In contrast, temperature projections show a clear and statistically significant upward trend across all scenarios, with increases ranging from approximately 1.13°C under SSP1-2.6 to 3.13°C under SSP5-8.5. The magnitude of warming intensifies under higher emission scenarios, indicating an increased likelihood of heat stress events, enhanced evapotranspiration, and greater drought risk in the region.

Conclusion: This study demonstrates the strong potential of machine learning-based statistical downscaling methods for improving the accuracy of local-scale climate projections derived from GCM outputs. Among the evaluated algorithms, Random Forest proved to be the most reliable and robust method for downscaling both precipitation and temperature in the upstream Karkheh River Basin. The projected combination of decreasing precipitation and increasing temperature highlights the high sensitivity of the study area to climate change impacts and underscores the need for proactive water management and adaptation strategies. While machine learning approaches offer notable advantages in capturing complex climate patterns and reducing computational costs, their performance remains dependent on the choice of algorithm, climate variable, and regional characteristics. The findings of this research provide a comprehensive comparative framework for selecting appropriate downscaling methods and contribute valuable insights for climate impact assessments and decision-making processes in Iran and similar semi-arid regions.

Ethical Considerations

Data availability statement: All information and results are presented in the text of the article.

Funding: This research was independently conducted and did not receive any financial support from any organization or agency.

Authors' contribution: **Ali Sadian:** Writing and editing, data source, results and coding process; **Nima Nemati Shishehgaran:** Conceptualization, methodology, software.

Conflicts of interest: The authors of this paper declared no conflict of interest regarding the authorship or publication of this article.

Acknowledgment: The authors extend their sincere gratitude to the Iran Meteorological Organization (IRIMO) for granting access to the station data utilized in this study.

مقایسه عملکرد روش‌های یادگیری ماشین در ریزمقیاس‌نمایی متغیرهای بارش و دمای شبیه‌سازی شده توسط مدل‌های اقلیمی

علی سعدیان^۱، نیما نعمتی شیشه‌گران^{۲*}

۱. کاندیدای دکتری، گروه مهندسی و مدیریت آب، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران، Ali.sadian@modares.ac.ir

۲. دانش‌آموخته کارشناسی ارشد، گروه مهندسی و مدیریت آب، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران، Nima.Nemati@modares.ac.ir

مشخصات مقاله	چکیده
نوع مقاله: تاریخچه مقاله دریافت: ۱۶ آذر ۱۴۰۴ بازنگری: ۱۷ دی ۱۴۰۴ پذیرش: ۲۹ دی ۱۴۰۴ انتشار برخط: ۳۰ دی ۱۴۰۴ واژه‌های کلیدی: تغییر اقلیم، مدل‌های گردش عمومی جو، پرسپترون چندلایه، ماشین بردار پشتیبان، جنگل تصادفی، حوضه رودخانه بالادست سد کرخه.	ریزمقیاس‌نمایی خروجی مدل‌های گردش عمومی جو (GCM) به منظور دستیابی به برآوردهای دقیق اقلیمی در مقیاس‌های محلی، یکی از چالش‌های اساسی در مطالعات تغییر اقلیم به‌ویژه در مناطق حساس هیدرولوژیکی است. با توجه به محدودیت‌های روش‌های آماری مرسوم و ظهور الگوریتم‌های نوین یادگیری ماشین، پژوهش حاضر با هدف ارزیابی عملکرد سه روش پرسپترون چندلایه (MLP)، ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) برای ریزمقیاس‌نمایی متغیرهای بارش و دما انجام شده است. در این راستا، خروجی ۱۰ مدل اقلیمی CMIP6 تحت چهار سناریوی SSP2.45، SSP3.70 و SSP5.85 برای حوضه رودخانه بالادست سد کرخه در دوره تاریخی ۱۹۹۰ تا ۲۰۱۴ استخراج شد. داده‌ها در یک دوره ۲۰ ساله برای آموزش و دوره پنج‌ساله برای آزمون مدل‌ها به کار رفتند. نتایج ارزیابی با سه شاخص آماری MAE، $RMSE$ و R^2 نشان داد که روش RF در هر دو متغیر بارش و دما نسبت به دو روش دیگر عملکرد برتری دارد، در حالی که SVM ضعیف‌ترین نتیجه را به‌ویژه در ریزمقیاس‌نمایی بارش ارائه کرد. با بهره‌گیری از روش برتر (RF)، پیش‌نگری متغیرهای اقلیمی برای دوره‌های ۲۰۳۱-۲۰۵۵ و ۲۰۵۶-۲۰۸۰ انجام شده و در نهایت روند تغییرات متغیرهای مورد مطالعه با استفاده از آزمون من-کندال و برآوردگر شیب سن بررسی شد. یافته‌ها نشان دادند که متوسط بارش در هر چهار سناریو دارای تغییرات کاهشی بوده و در حدود ۲/۹۶ تا ۱۹/۲۲ درصد کاهش خواهد یافت؛ در حالی که متوسط دما بین ۱/۱۳ تا ۳/۱۳ درجه سانتی گراد افزایش می‌یابد. همچنین، نتایج حاصل از ارزیابی روند متغیرهای بارش و دما برای دوره‌های آتی تحت سناریوهای مورد ارزیابی، نشانگر تداوم نوسانات طبیعی و تصادفی متغیر بارش و افزایش معنادار روند متوسط دمای منطقه است. این نتایج بیانگر حساسیت بالای منطقه مطالعاتی به اثرات تغییر اقلیم و ضرورت استفاده از رویکردهای مبتنی بر یادگیری ماشین جهت بهبود دقت پیش‌نگری‌ها است. همچنین، به‌کارگیری این مدل‌ها با افزایش توانایی استخراج الگوهای پیچیده اقلیمی همراه بوده و می‌تواند در بهبود فرآیند ریزمقیاس‌نمایی متغیرهای شبیه‌سازی شده توسط مدل‌های اقلیمی مؤثر واقع شود.
استناد: سعدیان، علی، و نعمتی شیشه‌گران، نیما. (۱۴۰۴). مقایسه عملکرد روش‌های یادگیری ماشین در ریزمقیاس‌نمایی متغیرهای بارش و دمای شبیه‌سازی شده توسط مدل‌های اقلیمی. <i>سامانه‌های سطوح آبگیر باران</i>، ۱۳(۴)، ۱۰۹-۱۳۳. DOR: 20.1001.1.24235970.1404.13.4.1.7 ناشر: انجمن علمی سیستم‌های سطوح آبگیر باران ایران	© نویسندگان

* نویسنده مسئول: نیما نعمتی شیشه‌گران

نشانی: گروه مهندسی و مدیریت آب، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران.

پست الکترونیکی: Nima.Nemati@modares.ac.ir

مقدمه

مدل‌های اقلیمی، به‌ویژه مدل‌های گردش عمومی^۱ ابزارهای حیاتی به‌شمار می‌روند که پژوهشگران اقلیم از آن‌ها برای پیش‌نگری و بررسی سناریوهای احتمالی آتی اقلیم بهره می‌برند (Flato et al., 2014). این مدل‌ها با ترکیب پدیده‌های متعدد جوی، اقیانوسی و فرایندهای سطح زمین، درک عمیقی از دینامیک‌های اقلیم زمین ارائه می‌دهند و همچنین امکان ارزیابی اثرات متقابل اقدامات انسانی را فراهم می‌کنند (Pachauri et al., 2014). با وجود قابلیت گسترده آن‌ها، GCMها معمولاً در مقیاس مکانی به نسبت بزرگ عمل می‌کنند که ممکن است قادر به بازنمایی کامل نوسانات محلی یا ویژگی‌های متمایز منطقه‌ای نباشند (Wilby et al., 2004). بهره‌گیری از مقیاس مکانی کوچک می‌تواند به‌ویژه در مطالعه پدیده‌های محدود به مکان‌های خاص یا هنگام تهیه پیش‌نگری‌های اقلیمی برای مناطق جغرافیایی مشخص، منجر به نادقتی‌هایی شود. در نتیجه، توسعه و پذیرش روش‌های ریزمقیاس‌نمایی^۲ با شتاب چشمگیری همراه بوده است. ریزمقیاس‌نمایی، روشی است که شکاف مکانی و زمانی میان خروجی‌های مدل‌های گردش عمومی با مقیاس بزرگ و داده‌های مشاهداتی مرتبط به یک منطقه را پر می‌کند (Fowler et al., 2007). به عبارتی، تبدیل داده‌های بزرگ‌مقیاس (خروجی GCMها) به داده‌های ریزمقیاس و دقیق، فرآیندی به نام ریزمقیاس‌نمایی نامیده می‌شود.

به‌طور کلی، دو رویکرد اصلی ریزمقیاس‌نمایی وجود دارد: رویکرد دینامیکی^۳ و رویکرد آماری^۴. ریزمقیاس‌نمایی دینامیکی به استفاده از مدل‌های اقلیم منطقه‌ای^۵ برای شبیه‌سازی شرایط اقلیمی در یک حوزه جغرافیایی محدود و مشخص اطلاق می‌شود (Amnuaylojaroen, 2023b). در مقابل، کاهشی مقیاس آماری بر پایه برقراری روابط آماری میان متغیرهای جوی با مقیاس بزرگ و متغیرهای اقلیمی مشاهداتی در مقیاس محلی است. با توجه به پیچیدگی محاسباتی و مدل‌سازی روش‌های ریزمقیاس‌نمایی دینامیکی، تکنیک‌های ریزمقیاس‌نمایی آماری به دلیل سادگی و سهولت اجرا، به‌طور گسترده در مطالعات تغییر اقلیم مورد استفاده قرار می‌گیرند. به‌طور خاص، در مطالعاتی که تأثیر تغییرات اقلیمی بر منابع آب و هیدرولوژی (مثل رودخانه‌ها، مخازن و سیلابی‌ها) در مناطق مختلف کره زمین بررسی شده‌اند، روش‌های ریزمقیاس‌نمایی آماری بسیار بیشتر از روش‌های پویا (RCM) مورد استفاده قرار گرفته‌اند (Amnuaylojaroen, 2023b). به‌طور کلی، روش‌های ریزمقیاس‌نمایی آماری را می‌توان به سه دسته تقسیم کرد: طبقه‌بندی وضعیت‌های جوی^۶، مولدهای آب‌وهوایی^۷، و روش‌های مبتنی بر رگرسیون^۸.

با نگرش به پیشرفت‌های اخیر در حوزه یادگیری ماشین و توان محاسباتی، نسل جدیدی از الگوریتم‌های ریزمقیاس‌نمایی ظهور یافته‌اند. این الگوریتم‌ها توانایی بالایی در درک روابط غیرخطی پیچیده دارند. همان‌گونه که Ghosh و همکاران (۲۰۰۸) تأکید کرده‌اند، این تکنیک‌ها از پتانسیل بالایی برای ارائه برآوردهای اقلیمی دقیق‌تر و کاملاً محلی‌شده برخوردارند. در این راستا، مدل‌های مختلفی جهت ریزمقیاس‌نمایی متغیرهای اقلیمی توسعه یافته و به کار گرفته شده‌اند؛ از جمله شبکه‌های عصبی مصنوعی^۹ (Coulibaly et al., 2005)، ماشین‌های بردار پشتیبان^{۱۰} (Anandhi et al., 2008)، جنگل تصادفی^{۱۱} (Malekipirbazari and Aksakalli, 2015)، ماشین‌گرادیان^{۱۲} Boosting (Bedia et al., 2013)، درخت تصمیم^{۱۳} (Ray et al., 2019) و غیره. این روش‌ها نقش مهمی در بهبود ریزمقیاس‌نمایی داشته‌اند، چرا که آن‌ها قادر به شناسایی و تحلیل الگوهای پیچیده‌ای هستند که پیش‌بینی‌کننده‌های اقلیم در مقیاس بزرگ را به متغیرهای هواشناسی محلی مرتبط می‌سازند. مطالعات مقایسه‌ای مختلفی نیز در این زمینه انجام شده‌است. برای نمونه، Schoof و Pryor نشان دادند که مدل‌های ANN در برآورد دمای روزانه در Indianapolis عملکرد بهتری نسبت به رگرسیون خطی چندگانه^{۱۴} دارند. در مقابل، Kostopoulou و همکاران (۲۰۰۷) گزارش کردند که MLR و CCA در شبیه‌سازی دماهای حداقل و حداکثر در یونان بهتر از ANN عمل می‌کنند. این مطالعات نشان می‌دهند که هیچ یک از روش‌های یادشده نمی‌توانند در همه شرایط تخمین دقیقی از متغیر اقلیمی مورد ارزیابی ارائه دهند.

¹ General Circulation Models (GCMs)

² Downscaling

³ Dynamical Approaches

⁴ Statistical Approaches

⁵ Regional Climate Models (RCM)

⁶ Weather Typing

⁷ Weather Generators

⁸ Regression-Based Methods

⁹ Artificial Neural Network (ANN)

¹⁰ Support Vector Machines (SVM)

¹¹ Random Forest (RF)

¹² Gradient Boosting Machine (GBM)

¹³ Decision Tree (DT)

¹⁴ Multiple Linear Regression (MLR)

در کنار ادبیات مذکور، برخی از پژوهشگران طی مطالعه‌ای به مقایسه روش‌های یادگیری ماشین با روش‌های آماری در راستای ریزمقیاس‌نمایی اطلاعات اقلیمی پرداخته و با توجه به نتایج حاصل اظهار می‌کنند که هیچ یک از این روش‌ها (یادگیری ماشین و آماری) به وضوح بر دیگری برتری ندارند. به عنوان مثال، Li و همکاران (۲۰۲۰) در طی مطالعه‌ای دو روش یادگیری ماشین (SVM و LSTM^۱) و دو روش آماری (میانگین تجمعی^۲ و رگرسیون خطی چندمتغیره) را در راستای ریزمقیاس‌نمایی متوسط دمای روزانه کانادا با یکدیگر مقایسه کردند که در نهایت نتایج حاصل نشانگر عملکرد مشابه هر چهار روش با توجه به معیار ارزیابی جذر میانگین مربعات خطا (RMSE) است. Vandal و همکاران (۲۰۱۹) نیز در طی پژوهشی تفاوت چشمگیری بین چندین روش آماری و یادگیری ماشین به کار رفته جهت ریزمقیاس‌نمایی خروجی GCM‌های مورد استفاده پیدا نکردند.

با توجه به اینکه روش‌های یادگیری ماشین در شناخت اطلاعات معنادار سیستم‌های اقلیمی از طریق شناسایی الگوها و استخراج ویژگی‌ها قابلیت بالایی دارند (Tanimu et al., 2024)، لذا، به کارگیری از این روش‌ها جهت ریزمقیاس‌نمایی اطلاعات اقلیمی در سال‌های اخیر بسیار مورد توجه پژوهشگران قرار گرفته است (Kim et al., 2021; Ling et al., 2022). شایان ذکر است، در کنار مزایای مذکور از روش‌های یادگیری ماشین، مشاهده شده‌است که به دلیل بیش‌برازش در طول دوره آموزش، می‌توانند منجر به برآورد نادرست شوند (Seo and Ahn, 2023). لذا، بهبود فرآیند ریزمقیاس‌نمایی با استفاده از روش‌های یادگیری ماشین به طور قطعی تضمین شده نیست (Tanimu et al., 2024). اما، اهمیت استفاده از این روش‌ها به طور گسترده در مناطق مختلف زمین و مقایسه آن‌ها با سایر روش‌های آماری مرسوم جهت ریزمقیاس‌نمایی خروجی GCM‌ها برای پژوهشگران پوشیده نیست.

اگرچه انتخاب روش مناسب ریزمقیاس‌نمایی خروجی مدل‌های اقلیمی که بتواند جنبه‌های اساسی اقلیم‌شناسی ایران را به تصویر بکشد، از اهمیت قابل توجهی برخوردار است؛ اما، با توجه به بررسی مطالعات صورت گرفته، پژوهش‌های محدودی به طور خاص در زمینه ارزیابی روش‌های نوظهور یادگیری ماشین جهت ریزمقیاس‌نمایی متغیرهای اقلیمی برگرفته از GCM‌ها در مناطق مختلف ایران انجام شده است (Khosravi et al., 2025; Niazkar et al., 2023). همچنین، با در نظر گرفتن ضرورت بررسی یکپارچه روش‌های مختلف ریزمقیاس‌نمایی خروجی مدل‌های اقلیمی جهانی در راستای ارائه ادبیات مستند برای پژوهشگران تغییر اقلیم جهت به کارگیری مناسب از این خروجی‌ها به منظور ارزیابی اثر تغییر اقلیم بر مولفه‌های هیدرولوژیکی در ایران، طی پژوهش حاضر تلاش شد در کنار ارائه روش‌شناسی مناسب، عملکرد سه روش مبتنی بر یادگیری ماشین جهت ریزمقیاس‌نمایی متغیرهای بارش و دمای شبیه‌سازی شده توسط ۱۰ مدل اقلیمی از CMIP6^۳ با توجه به داده‌های مشاهداتی در حوضه آبریز رودخانه بالادست سد کرخه مورد ارزیابی قرار گیرند. در نهایت تحت مناسب‌ترین روش مورد ارزیابی، پیش‌نگری متغیرهای اقلیمی در دو دوره آتی منتخب انجام شده و نتایج حاصل ارائه شد. شایان ذکر است، در عمده مطالعات انجام شده در راستای ریزمقیاس‌نمایی خروجی مدل‌های اقلیمی با استفاده از روش‌های یادگیری ماشین در مناطق مختلف ایران، روش بخصوصی مورد ارزیابی قرار گرفته و به بررسی ظرفیت و توانایی روش‌های مختلف در کنار هم و مقایسه آن‌ها پرداخته نشده است. لذا، مطالعه حاضر به صورت کلی تلاشی در راستای مقایسه روش‌های ریزمقیاس‌نمایی مبتنی بر یادگیری ماشین و ارائه چارچوب روش‌شناسی مطلوب جهت محدودسازی ورود عدم قطعیت اقلیمی در فرآیند ارزیابی‌های آماری است. نتایج حاصل از مطالعه فعلی می‌تواند به ایجاد اعتماد در به کارگیری از روش‌های ریزمقیاس‌نمایی خروجی مدل‌های گردش عمومی جو بر پایه یادگیری ماشین در راستای مطالعات تحلیل اثر کمک کرده و به تصمیم‌گیرندگان در اخذ راهبردهای سازگاری و کاهش گازهای گلخانه‌ای جهت مواجهه با اثرات تغییر اقلیم یاری رساند.

مواد و روش تحقیق

منطقه مورد مطالعه و داده‌های مورد استفاده


حوضه آبریز رودخانه بالادست سد کرخه در غرب کشور و در مناطق میانی و جنوب غربی رشته کوه زاگرس قرار گرفته و از چهار زیر حوضه اصلی کشکان، سیمره، گاماسیاب و قره‌سو تشکیل شده است (شکل ۱). این حوضه از نظر مختصات بین طول‌های جغرافیایی ۴۶ درجه و ۶ دقیقه تا ۴۹ درجه و ۱۰ دقیقه و عرض‌های جغرافیایی ۳۰ درجه و ۵۸ دقیقه تا ۳۵ درجه و ۴ دقیقه گسترده است. وسعت این حوضه ۴۲۲۶۷۰۰ هکتار بوده که عمده آن را مناطق کوهستانی تشکیل داده و بیش از نیمی از استان‌های لرستان و کرمانشاه و بخش‌هایی از استان‌های کردستان، همدان و ایلام را در بر می‌گیرد (احمدی و دلاور، ۱۳۹۸). به منظور نیل به اهداف پژوهش حاضر، برای برآورد بارش و دمای متوسط از اطلاعات ۱۱ ایستگاه هواشناسی استفاده شده است. با توجه به عدم پراکندگی متناسب ایستگاه‌های داخل حوضه و محدودیت‌های مربوط به طول دوره آماری مورد نظر جهت انجام تحلیل‌های لازم، از بین تمامی ایستگاه‌های هواشناسی منتخب ۳ ایستگاه خارج از منطقه و ۸

^۱ Long Short-Term Memory (LSTM)

^۲ Ensemble Mean

^۳ Coupled Model Intercomparison Project

ایستگاه در داخل منطقه مورد ارزیابی قرار دارند. همچنین، با نگرش به کامل بودن داده‌های هواشناسی ایستگاه‌های منطقه مورد مطالعه و از طرفی یکسان بودن طول دوره آماری داده‌های تمامی ایستگاه‌های منتخب، جهت مقایسه روش‌های ریزمقیاس‌نمایی استفاده شده با مقادیر مشاهداتی بارش و دما در دوره پایه مدل‌های گردش عمومی جو، طول دوره آماری ۲۵ ساله (۲۰۱۴-۱۹۹۰) در نظر گرفته شد که ۲۰ سال (۲۰۰۹-۱۹۹۰) از این اطلاعات جهت آموزش^۱ مدل‌ها و پنج سال (۲۰۱۴-۲۰۱۰) نیز جهت آزمایش^۲ استفاده شده است.



شکل ۱- منطقه مورد مطالعه و موقعیت جغرافیایی ایستگاه‌های هواشناسی
Figure 1- Study area and geographical location of meteorological stations

مدل‌های گردش عمومی

جهت ارزیابی تغییرات بارش و دما در منطقه مورد مطالعه، از خروجی ۱۰ مدل گردش عمومی جو ارائه شده در گزارش ششم ارزیابی هیأت بین‌الدول تغییر اقلیم استفاده شده است. تمامی مدل‌های منتخب از CMIP6 تحت شرایط r1i1p1f1 از پایگاه^۳ ESGF MetaGrid^۲ اخذ شده و تلاش شد مدل‌هایی که دارای اطلاعات کامل در طول دوره تاریخی ۱۹۹۰-۲۰۱۴، دوره‌های آتی ۲۰۳۱-۲۰۵۵ و ۲۰۸۰-۲۰۵۶ تحت سه سناریو SSP1.26، SSP2.45 و SSP3.70 هستند از سایر مدل‌ها تفکیک شوند. پس از ارزیابی اولیه از مدل‌های اقلیمی، ۱۰ مدل با توجه به ادبیات پیشین انتخاب شده (Doulabian et al., 2021; Yaghoobzadeh, 2022; Zamani et al., 2020) و از خروجی آن‌ها جهت ارزیابی‌های مورد نیاز استفاده شد. مقادیر بارش و دمای متوسط شبیه‌سازی شده توسط مدل‌های GCM در طول دوره تاریخی از سال ۱۹۹۰ الی ۲۰۱۴ با توجه به تطابق طول دوره آماری آن‌ها با مقادیر مشاهداتی به صورت ماهانه استخراج شده و با نگرش به مقیاس مکانی متفاوت، تمامی مدل‌ها در مقیاس ایستگاهی ریزمقیاس شدند. در نهایت، میزان تغییرات بارش و دمای منطقه مدنظر با کمک مدل‌های مورد استفاده تحت سناریوهای SSP1.26، SSP2.45 و SSP3.70 برای دوره‌های آتی ۲۰۳۱-۲۰۵۵ و ۲۰۸۰-۲۰۵۶ شبیه‌سازی شده و در مقیاس زمانی متوسط ماهانه با مقادیر مشاهداتی مورد مقایسه قرار گرفت. اطلاعات تمامی مدل‌های استفاده شده از جمله، گروه مدل‌سازی مربوطه، کشور و درجه تفکیک در جدول ۱ ارائه شده است.

^۱ Train

^۲ Test


^۳ www.esgf-node.llnl.gov

جدول ۱- مدل‌های اقلیمی CMIP6 مورد استفاده در مطالعه حاضر
Table 1- CMIP6 climate models used in the present study

ردیف	نام مدل	درجه تفکیک	موسسه/کشور
۱	ACCESS-ESM1-5	$1.9^{\circ} * 1.3^{\circ}$	مرکز عالی شورای تحقیقات استرالیا برای علوم سیستم اقلیمی، استرالیا
۲	BCC-CSM2-MR	$1.12^{\circ} * 1.12^{\circ}$	مرکز اقلیم پکن، چین
۳	CanESM5	$1.41^{\circ} * 1.41^{\circ}$	مرکز ملی تحقیقات هواشناسی، تولوز، فرانسه
۴	CMCC-ESM2	$0.35^{\circ} * 0.35^{\circ}$	کنسرسیوم EC-Earth، اروپا
۵	FGOALS-f3-L	$1^{\circ} * 1^{\circ}$	آکادمی علوم چین (CAS)، چین
۶	GFDL-ESM4	$1.25^{\circ} * 1.00^{\circ}$	آزمایشگاه دینامیک سیالات ژئوفیزیکی (GFDL)، ایالات متحده آمریکا
۷	IPSL-CM6A-LR	$2.5^{\circ} * 1.3^{\circ}$	موسسه Pierre Simon Laplace (IPSL)، پاریس، فرانسه
۸	MPI-ESM1-2-LR	$0.94^{\circ} * 0.94^{\circ}$	موسسه هواشناسی ماکس پلانک (MPI-M)، آلمان
۹	MRI-ESM2-0	$1.12^{\circ} * 1.12^{\circ}$	موسسه تحقیقات هواشناسی، ایباراکی، ژاپن
۱۰	NorESM2-LM	$2.5^{\circ} * 1.89^{\circ}$	مرکز اقلیم نروژ، نروژ

مدل‌های ریزمقیاس‌نمایی یادگیری ماشین پرسپترون چندلایه (MLP^1)

روش MLP به عنوان الگوریتم شبکه عصبی مصنوعی از نوع کلاسیک شناخته می‌شود (Minsky and Papert, 1969). وظیفه اصلی شبکه عصبی، بهبود تابع عملکرد بین مقادیر پیش‌بینی شده و مشاهده شده است. روش MLP به طور گسترده برای ترسیم رابطه غیرخطی بین متغیر پیش‌بینی‌کننده و پیش‌بینی‌شونده استفاده می‌شود (Chadwick et al., 2011) و شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است که هر یک از این لایه‌ها دارای تعدادی گره (نورون^۲) هستند. هر گره در یک لایه به تمام گره‌های لایه قبلی و لایه بعدی متصل است. هر اتصال بین گره‌ها دارای وزن است که با حرف w نشان داده می‌شود و در راستای تضعیف یا قوی کردن اتصال بین گره‌ها این وزن‌ها می‌توانند اصلاح شوند. در واقع، وزن‌های موجود بین گره‌ها باعث هوشمندسازی شبکه عصبی شده و شبکه به تغییر دادن این وزن‌ها آموزش می‌بیند. به طور کلی می‌توان چنین اظهار کرد که ویژگی و قدرت یک شبکه MLP به معماری شبکه (تعداد لایه‌ها و گره‌ها) و وزن‌های بین گره‌ها بستگی دارد (Chadwick et al., 2011). معمولاً وجود یک لایه پنهان برای تقریب توابع پیوسته به صورت کافی در نظر گرفته می‌شود، اما قانون پذیرفته شده و قطعی درباره تعداد گره‌های پنهان وجود ندارد. به عبارتی، تعداد گره‌های لایه پنهان باید تجربی و با اعتبارسنجی انتخاب شود و فرمول ثابت و عمومی برای آن وجود ندارد (Harpham and Dawson, 2006; Hsieh, 2009). به طور معمول، رویکردهای ریزمقیاس‌نمایی آماری فرض می‌کنند که داده‌ها از یک توزیع خاص پیروی می‌کنند، اما MLP هیچ فرضی درباره توزیع داده‌ها در نظر نمی‌گیرد؛ این روش آموزش می‌بیند تا هر گونه تابع قابل اندازه‌گیری را تقریب بزند. MLP می‌تواند توابع بسیار غیرخطی را مدل کرده و زمانی که داده‌های جدید به آن داده شوند، قابلیت تعمیم دارد. لذا، MLP گزینه بسیار خوبی برای ساخت مدل‌های عددی بوده و در مقایسه با روش‌های آماری در راستای ریزمقیاس‌نمایی مدل‌های اقلیمی انتخاب مناسبی است (Gardner and Dorling, 1998). در شکل ۲ شمایی از یک شبکه MLP سه لایه معمولی ارائه شده و معادله (۱) نیز مقدار خروجی یک شبکه MLP سه لایه را نشان می‌دهد (Kim and Valdés, 2003) که در آن y_k و x_j به ترتیب مربوط به ورودی‌ها و خروجی‌های شبکه هستند.



شکل ۲- ساختار یک شبکه MLP سه لایه معمولی

Figure 2- Structure of a typical three-layer MLP network

¹ Multilayer Perceptron

² Neuron

$$y_k = f_2 \left[\sum_{i=1}^m w_{ki} f_1 \left(\sum_{j=1}^n w_{ij} x_j + b_i \right) + b_k \right] \quad (۱)$$

در رابطه فوق، اندیس‌های i ، j و k به ترتیب مرتبط با لایه‌های پنهان، ورودی و خروجی بوده و n و m نیز به ترتیب نشانگر تعداد گره‌های لایه‌های ورودی و پنهان هستند. w_{ij} نمایانگر وزن مابین گره‌های لایه‌های ورودی و پنهان و w_{ki} نیز نشانگر وزن بین گره‌های لایه‌های پنهان و خروجی هستند. f_1 و f_2 به ترتیب توابع فعال‌ساز برای لایه‌های پنهان و خروجی بوده و b_i و b_k نیز مربوط به ارباب گره‌ها در لایه‌های پنهان و خروجی هستند.

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یا SVM (Vapnik, 1998) یکی دیگر از روش‌های یادگیری ماشین است که می‌تواند به شکل یک شبکه عصبی دو لایه نیز ارائه شود (Tripathi et al., 2006). اصل SVM بر اساس نظریه یادگیری آماری^۱ و روش کمینه‌سازی ریسک ساختاری^۲ است (Haykin, 2009). این روش هم برای رگرسیون خطی و هم برای رگرسیون غیرخطی قابل استفاده است. SVM مسائل رگرسیون غیرخطی را با کمک توابع کرنل^۳ حل می‌کند به طوری که؛ داده‌های ورودی با بعد کم را به یک فضای چند بعدی انتقال می‌دهد (Fan et al., 2018). در ادامه شرح مختصری از نظریه رگرسیون SVM ارائه شده و جزئیات بیشتر از این روش را می‌توان از پژوهش Vapnik (۲۰۱۳) مطالعه کرد.

فرض کنید مجموعه‌ای از داده‌های آموزشی به صورت $\{(x_i, y_i), i = 1, \dots, n\}$ در اختیار است که در آن هر x_i بردار ورودی و y_i مقدار هدف (مقادیر مشاهداتی) متناظر با آن ورودی است. x_i بردارهای ورودی هستند که در فضای n بعدی قرار دارند. به عبارتی، هر بردار ورودی x_i یک بردار n بعدی از اعداد حقیقی است ($x_i \in R^n$). y_i نیز مقدار خروجی واقعی (مقدار هدف) مربوط به هر ورودی است، به طوری که هر مقدار از y_i یک عدد حقیقی تک‌بعدی به شمار می‌رود ($y_i \in R$). تابع رگرسیون کلی در ماشین بردار پشتیبان را می‌توان مطابق رابطه (۲) نوشت که در آن w بردار وزن‌ها و b مقدار ارباب (عرض از مبدأ) است. در این رابطه $\varphi(\cdot)$ به عنوان یک تابع تبدیل غیرخطی تعریف می‌شود تا فضای ورودی را به یک فضای ویژگی با ابعاد بالاتر نگاشت کند.

$$f(x_i) = w \cdot \varphi(x_i) + b \quad (۲)$$

هدف رگرسیون ماشین بردار پشتیبان این است که مقادیر مناسب بردار وزن w و ارباب b را طوری پیدا کند که مقادیر تابع رگرسیون $f(x)$ با کمینه کردن ریسک تجربی ($R_{empirical}$) طبق رابطه (۳) به دست آیند.

$$R_{empirical} = \frac{1}{n} \sum_{i=1}^n |y_i - f(x_i)| \quad (۳)$$

در رابطه (۳)، مقدار $|y_i - f(x_i)|$ به عنوان تابع زیان ϵ -insensitive Vapnik's تعریف می‌شود (Sachindra et al., 2018) که در رابطه (۴) نمایش داده شده است.

$$|y_i - f(x_i)| = \begin{cases} 0 & \text{if } |y_i - f(x_i)| \leq \epsilon \\ |y_i - f(x_i)| - \epsilon & \text{otherwise} \end{cases} \quad (۴)$$

متغیرهای w و b با کمینه کردن تابع هزینه ψ_ϵ که در رابطه (۵) نشان داده شده است، محاسبه می‌شوند به طوری که در این رابطه ξ_i و ξ_i^* متغیرهای کمکی^۴ و C نیز یک ثابت مثبت حقیقی است.

$$\psi_\epsilon = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (۵)$$

رابطه (۵) یک مسئله بهینه‌سازی بوده که هدف آن کمینه کردن تابع هزینه ψ_ϵ است، اما این کمینه‌سازی تحت قیود^۵ خاص برای هر نمونه آموزشی ($i = 1, 2, \dots, n$) انجام می‌شود.

$$\begin{cases} y_i - f(x_i) \leq \epsilon + \xi_i \\ -y_i + f(x_i) \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \quad i = 1, 2, \dots, n \end{cases}$$

¹ Statistical Learning Theory

² Structural Risk Minimization

³ Kernel Functions

⁴ Slack Variables

⁵ Constraints

بردار w در رابطه (۵) را می‌توان به صورت معادله (۶) نوشت؛ به طوری که در این رابطه جدید، α_i و α_i^* ضرایب لاگرانژ^۱ هستند که مقادیر حقیقی مثبت دارند.

$$w = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \varphi(x_i) \quad (6)$$

با جاگذاری معادله (۶) در رابطه (۲)، می‌توان رابطه کلی را به صورت رابطه (۷) بازنویسی کرد.

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) (\varphi(x) \cdot \varphi(x_i)) + b \quad (7)$$

ضرب داخلی موجود در رابطه (۷) را می‌توان با تابع کرنل $k(x, x_i)$ به شکل زیر جاگذاری کرد.


$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) k(x, x_i) + b \quad (8)$$

انواع مختلفی از توابع کرنل مانند خطی، چندجمله‌ای^۲، *Sigmoid*، *Spline* و تابع پایه شعاعی^۳ را می‌توان در رابطه (۸) به کار برد. تابع کرنل *RBF* که در رابطه (۹) نشان داده شده α در این رابطه پهنای یا عرض تابع کرنل است، به عنوان پرکاربردترین تابع کرنل در مطالعات مربوط به ریزمقیاس‌نمایی مدل‌های اقلیمی شناخته می‌شود (Ghosh and Mujumdar, 2008; Sachindra et al., 2013; Sachindra et al., 2018). جزئیات بیشتر از انواع توابع کرنل را می‌توان در مطالعه Hofmann و همکاران (۲۰۰۸) یافت.

$$k(x, x_i) = \exp \left[-\frac{1}{2\sigma^2} \|x - x_i\|^2 \right] \quad (9)$$

جنگل تصادفی (RF)

روش جنگل تصادفی (RF) یک روش بهبودیافته درخت رگرسیون و طبقه‌بندی^۴ است که توسط Breiman در سال (۲۰۰۱) معرفی شد. این روش شامل مجموعه‌ای از درخت‌های تصمیم است که از طریق نمونه‌برداری Bootstrap از داده‌های آموزشی و انتخاب تصادفی زیرمجموعه متغیرها تولید می‌شوند (Pang et al., 2017; Xu et al., 2020). به عبارتی دیگر، RF به عنوان الگوریتم یادگیری ماشین نوینی پیشنهاد شد که از چندین CART تشکیل شده و می‌تواند از بیش‌برازش جلوگیری کند و انواع مختلف متغیرهای ورودی را تنظیم نماید. این روش می‌تواند چندین درخت مستقل تولید کند و سپس تصمیم نهایی را بگیرد؛ این ویژگی به دلیل خاصیت رگرسیون آماری ناپارامتریک و تصادفی بودن آن است. RF توسط مجموعه‌ای از CARTها تشکیل می‌شود و دقت پیش‌بینی آن به قدرت هر CART بستگی دارد (Breiman, 2001). به عبارتی، توانایی تصمیم‌گیری مدل RF به هر CART وابسته است. هر CART از یک گره ریشه، گره‌های داخلی و برگ‌ها تشکیل می‌شود و در آن هر گره داخلی با یک تابع آزمایشی برای تقسیم داده‌های ورودی مرتبط است (شکل ۳).



شکل ۳- ساختار یک مدل جنگل تصادفی

Figure 3- Structure of a random forest model

¹ Lagrange Multipliers

² Polynomial

³ Radial Basis Function (RBF)

⁴ Classification and Regression Tree (CART)

به طور کلی، سه مرحله اصلی الگوریتم رگرسیون جنگل تصادفی را می‌توان به شکل زیر توصیف کرد.

۱- ابتدا از مجموعه داده اصلی با استفاده از روش Bootstrap مجموعه‌های آموزشی استخراج می‌شود. هر مجموعه آموزشی تقریباً معادل دو سوم حجم داده اصلی است و یک سوم باقی‌مانده به عنوان داده‌های out-of-bag (OOB) شناخته می‌شوند که برای ارزیابی داخلی مدل کاربرد دارند. این فرآیند در n دور تکرار می‌شود تا n مجموعه آموزشی مستقل (اما با امکان تکرار نمونه‌ها) تشکیل شود.

۲- سپس، هر مجموعه آموزشی برای ساخت یک درخت رگرسیون تصمیم استفاده می‌شود و مجموعه‌ای از این درخت‌ها جنگل را تشکیل می‌دهند. اصل حاکم بر ساخت درخت‌ها، کمینه‌سازی میانگین مربعات خطا (MSE) است.

۳- در نهایت، پیش‌بینی جنگل از میانگین پیش‌بینی‌های همه درخت‌ها محاسبه می‌شود؛ این رویکرد واریانس را کاهش داده و تعمیم‌پذیری مدل را افزایش می‌دهد. در حالت رگرسیون، پیش‌بینی نهایی برابر میانگین پیش‌بینی‌های همه تک درخت‌ها است. الگوریتم جنگل تصادفی از لحاظ ریاضی به شکل زیر بیان می‌شود.

$$D_b = \{(X_i, Y_i) | i \in \text{نمونه با تصادفی}\} \quad (10)$$

برای هر درخت b ، درخت T_b با استفاده از مجموعه داده D_b آموزش داده می‌شود. در نهایت، پیش‌بینی نهایی با میانگین‌گیری پیش‌بینی‌های همه درخت‌ها به دست می‌آید.

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B T_b(X) \quad (11)$$

در ادامه به چندین ویژگی کلیدی RF اشاره می‌شود (Tang et al., 2024) که عبارتند از:

- ۱- کاهش بیش‌برازش: با میانگین‌گیری پیش‌بینی‌های چندین درخت تصمیم، RF خطر بیش‌برازش را نسبت به تک درخت کم می‌کند.
- ۲- مدیریت داده‌های با بعد زیاد: RF داده‌های حجیم و با ابعاد زیاد را به خوبی پردازش می‌کند، زیرا در هر گره تقسیم، فقط زیرمجموعه تصادفی ویژگی‌ها بررسی می‌شود.
- ۳- اهمیت متغیرها: RF برآوردی از اهمیت هر متغیر در پیش‌بینی ارائه می‌دهد که برای انتخاب ویژگی مفید است.

معیارهای ارزیابی

در مطالعه حاضر، عملکرد روش‌های مختلف یادگیری ماشین اعمال شده بر داده‌های شبیه‌سازی شده توسط مدل‌های GCM جهت ریزمقیاس‌نمایی آن‌ها، مورد ارزیابی قرار گرفت. از شاخص‌های آماری جهت ارزیابی عملکرد مدل‌ها استفاده می‌شود تا تشابه بین داده‌های مشاهداتی و شبیه‌سازی شده در قالب مقادیر آماری ارائه شود (Gupta et al., 2009). سه معیار ارزیابی جهت ارائه کامل عملکرد روش‌ها از جمله، ضریب تعیین (R^2)، میانگین خطای مطلق (MAE) و جذر میانگین مربعات خطا (RMSE) به کار گرفته شد. این سه معیار با توجه به گستردگی استفاده آن‌ها جهت ارزیابی عملکرد روش‌های یادگیری ماشین در راستای ریزمقیاس‌نمایی مدل‌های اقلیمی انتخاب شدند (Pang et al., 2017; Tang et al., 2024; Xu et al., 2020).

۱- ضریب تعیین (R^2): معیاری آماری است که قدرت و جهت رابطه خطی بین مقادیر مشاهده‌شده (واقعی) و مقادیر پیش‌بینی‌شده (توسط مدل) را اندازه‌گیری می‌کند و به شکل زیر محاسبه می‌شود.

$$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (12)$$

۲- میانگین خطای مطلق (MAE): این معیار میانگین تفاوت‌های مطلق بین مقادیر مشاهده‌شده و مقادیر پیش‌بینی‌شده را نشان می‌دهد و رابطه آن به شکل زیر است.

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

۳- جذر میانگین مربعات خطا (RMSE): RMSE ریشه دوم میانگین مربعات تفاوت‌های بین مقادیر مشاهده‌شده و مقادیر پیش‌بینی‌شده را اندازه‌گیری می‌کند و رابطه آن به شکل زیر است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (14)$$

در روابط (۱۲) تا (۱۴)، O_i و P_i به ترتیب نشانگر مقادیر مشاهداتی و پیش‌بینی‌شده و $\bar{O}$ نیز نمایانگر میانگین مقادیر مشاهداتی است.

ارزیابی روند متغیرهای بارش و دما

در مطالعه حاضر به منظور ارزیابی روند بارش و دمای مشاهداتی و شبیه‌سازی شده، از دو روش رایج آزمون من-کندال^۱ و برآوردگر شیب سن^۲ استفاده شده است. آزمون ناپارامتریک من-کندال به طور معمول جهت ارزیابی روند سری داده‌های هیدرولوژیکی و هواشناسی استفاده می‌شود (Niazkar et al., 2022). دو مزیت اصلی آزمون MK این است که نتایج آن به نوع خاصی از توزیع آماری وابسته بوده و مقادیر حدی یا داده‌های بسیار بزرگ و کوچک تأثیر کمی بر نتیجه آزمون دارند (Partal and Kahya, 2006). در این آزمون، H_0 بیان می‌کند که داده‌ها به صورت تصادفی پراکنده‌اند و هیچ روندی در آن‌ها وجود ندارد، در حالی که فرضیه‌ی مقابل (H_1) نشان‌دهنده‌ی وجود یک روند معنادار در سری داده‌ها است (Zakwan and Niazkar, 2022). جهت اندازه‌گیری روند در آزمون MK از آماره استاندارد Z استفاده می‌شود که مقدار مثبت آن بیانگر روند صعودی و مقدار منفی آن بیانگر روند نزولی سری زمانی داده‌ها است (Maghrabi and Alotaibi, 2018). برای انجام این آزمون در ابتدا می‌بایست مقدار S بر اساس مقایسه هر یک از داده‌ها با داده‌هایی که بعد از آن به وقوع پیوسته‌اند با توجه به رابطه (۱۵) مشخص شود.

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(X_j - X_i) \quad (15)$$

در رابطه فوق، n مدت سری زمانی داده‌ها، X_i و X_j در سری زمانی z و i است. علامت تابع به صورت رابطه (۱۶) محاسبه می‌شود.

$$\text{sgn}(X_j - X_i) = \begin{cases} +1 & \text{if } (X_j - X_i) > 0 \\ 0 & \text{if } (X_j - X_i) = 0 \\ -1 & \text{if } (X_j - X_i) < 0 \end{cases} \quad (16)$$

مقدار Z استاندارد طبق رابطه (۱۷) محاسبه می‌شود.

$$Z = \begin{cases} \frac{S-1}{\sqrt{\text{Var}(S)}} & \text{if } S > 0 \\ 0 & \text{if } S = 0 \\ \frac{S+1}{\sqrt{\text{Var}(S)}} & \text{if } S < 0 \end{cases} \quad (17)$$

در رابطه فوق، مقدار انحراف معیار به صورت رابطه (۱۸) محاسبه می‌شود.

$$\text{Var}(S) = \frac{n(n-1)(2n+5) - \sum_{i=1}^n (t_i - 1)(2t_i + 5)}{18} \quad (18)$$

با توجه به روابط فوق، اگر مقدار Z بزرگتر از $1/96$ یا کوچکتر از $-1/96$ باشد، سری داده‌های دارای روند بوده که این موضوع بیانگر رد H_0 است. در غیر این صورت، داده‌های دارای روند نبوده و H_0 پذیرفته می‌شود.

در کنار آزمون من-کندال، برآوردگر شیب سن نیز یک آزمون ناپارامتریک است که به طور گسترده برای شناسایی روندها در یک سری زمانی و همچنین تعیین بزرگی و شدت روند مورد استفاده قرار می‌گیرد. به طور خلاصه، در این روش تحلیل روند بر پایه محاسبه‌ی میانه‌ی شیب‌ها در یک سری زمانی مورد بررسی استوار بوده و در ادامه معناداری شیب به دست آمده در سطوح مختلف اطمینان مورد ارزیابی قرار می‌گیرد. برای برآورد شیب سن، لازم است سری زمانی مورد بررسی حداقل ۱۰ مقدار داشته باشد. مشابه روش MK، این روش نیز بر پایه تحلیل اختلاف بین مقادیر مختلف سری زمانی عمل می‌کند تا روند تغییرات در طول زمان شناسایی شود (Niazkar et al., 2022). همچنین، این روش به سادگی در شرایطی که بخشی از داده‌ها وجود نداشته یا حذف شده باشند (داده‌های گمشده) نیز قابل استفاده است (Serrano et al., 1999). شیب هر جفت داده متوالی سری طبق رابطه (۱۹) محاسبه می‌شود.

$$Q_i = \frac{X_t - X_s}{t - s} \quad \text{for } i = 1, 2, \dots, n \quad (19)$$

در رابطه فوق، X_t و X_s به ترتیب نشان‌دهنده مقادیر داده‌ها در زمان‌های t و s است که با هم یک واحد زمانی اختلاف دارند. با اعمال این رابطه بین تمام جفت‌های ممکن از داده‌ها، مجموعه‌ای از شیب‌ها برای خطوط روند به دست می‌آیند. به طور دقیق‌تر، مقدار نهایی شیب سن از میانه این مجموعه شیب‌ها محاسبه می‌شود که مقدار مثبت Q نشانگر روند صعودی و مقدار منفی آن نمایانگر روند نزولی در داده‌ها است. به عبارتی، Q_i مقدار میانه n برآورد شده شیب سن است. اگر n فرد باشد، برآوردگر شیب سن به شکل رابطه (۲۰) محاسبه می‌شود.

$$Q_{med} = Q_{(n+2)/2} \quad (20)$$

در حالی که n فرد باشد، برآوردگر شیب سن طبق رابطه (۲۱) محاسبه می‌شود.

$$Q_{med} = (Q_{(n)/2} + Q_{(n+2)/2})/2 \quad (21)$$

¹ Mann-Kendall (MK)

² Sen's Slope Estimator

نتایج و بحث

تفسیر فرآیند ریزمقیاس‌نمایی بارش و دمای شبیه‌سازی شده توسط GCM‌ها

با در نظر گرفتن این که ایجاد رابطه رگرسیونی بر مبنای مقادیر روزانه متغیرهای هواشناسی به دلیل نوسانات زیاد و پایداری کمتر الگوهای تغییراتی بسیار پیچیده بوده و تعیین آن دشوار است. بنابراین، در مطالعه حاضر روابط رگرسیونی روش‌های یادگیری ماشین بر اساس داده‌های شبیه‌سازی (GCM) و مشاهده‌شده بارش و دمای ماهانه در دوره پایه ایجاد شدند. سپس عملکرد روابط ایجاد شده طبق معیارهای ارزیابی آماری مورد سنجش قرار گرفته و در ادامه تحت روش منتخب، مقادیر بارش و دمای ماهانه برای دوره‌های آتی برآورد شدند. در نهایت، نتایج حاصل از اعمال روش انتخابی بر متغیرهای مدنظر در دوره‌های آتی با مقادیر مشاهداتی مورد ارزیابی قرار گرفتند.

دقت مقادیر برآوردی از متغیرهای اقلیمی با اعمال روش‌های ریزمقیاس‌نمایی بر پایه یادگیری ماشین، تا حدودی به انتخاب طول دوره آماری در دوره پایه بستگی دارد. در این پژوهش که از خروجی ۱۰ مدل اقلیمی استفاده شده است، با توجه به موجودیت و همپوشانی طول دوره مقادیر مشاهداتی و شبیه‌سازی شده توسط GCM‌ها، بازه زمانی دوره پایه برای متغیرهای اقلیمی مورد ارزیابی از سال ۱۹۹۰ الی ۲۰۱۴ انتخاب شد. سپس، این طول دوره انتخابی به دو دوره آموزش (۲۰۰۹-۱۹۹۰) و آزمایش (۲۰۱۴-۲۰۱۰) تفکیک شده و مدل‌های یادگیری ماشین MLP، SVM و RF بر اساس مقادیر شبیه‌سازی‌شده متغیرهای هواشناسی از GCM‌ها و داده‌های مشاهداتی در این دو دوره ساخته شده و در نهایت عملکرد آن‌ها مورد ارزیابی قرار گرفت. از طرفی، با نگرش به این که دقت برآورد هر مدلی برای دوره آتی با طولانی‌تر شدن طول دوره برآورد کاهش می‌یابد لذا، می‌توان چنین اظهار کرد که برآوردهای تغییرات متغیرهای اقلیمی توسط GCM‌ها برای ۷۵ سال آتی (تا حدود سال ۲۱۰۰) از اعتبار مقبولی برخوردارند، در حالی که دقت برآوردها بعد از سال ۲۱۰۰ معقول ارزیابی نمی‌شود (Tang et al., 2024). در نتیجه، اعمال روش مطلوب یادگیری ماشین بر متغیرهای شبیه‌سازی شده توسط GCM‌ها در این پژوهش، به بازه قبل از سال ۲۱۰۰ (۲۰۳۱-۲۰۵۵) محدود شد.


لازم به ذکر است، در یک سناریوی اقلیمی مشخص، پیش‌نگری‌های ریزمقیاس‌شده از مدل‌های اقلیمی مختلف نتایج متفاوتی برای متغیرهای مورد ارزیابی ارائه می‌دهند و تاکنون هیچ مدل واحدی در پیش‌نگری تغییرات متغیرهای اقلیمی مورد توافق جهانی نرسیده است. به عبارتی، در یک منطقه لزوماً استفاده از خروجی مدل اقلیمی واحد، دقیق‌ترین پیش‌نگری را برای پارامترهای اقلیمی ارائه نمی‌دهد و ممکن است بهترین برآورد برای متغیرهای بارش و دمای آن منطقه توسط چندین مدل مختلف ایجاد شود (نعمتی شیشه‌گران و همکاران، ۱۴۰۳). بنابراین، انتخاب بین تکیه بر یک مدل خاص یا ترکیب نتایج چندین مدل در پیش‌نگری تغییر اقلیم مورد بحث است. اما، عمده پژوهشگران معتقدند که ادغام نتایج چندین مدل می‌تواند باعث کاهش عدم قطعیت ذاتی در پیش‌نگری‌ها، افزایش اعتبار برآوردها، همگرایی پیش‌نگری‌های متنوع و کاهش خطر ناشی از سوگیری‌های هر مدل شود (Meng et al., 2025; Zhang and Yan, 2015). از طرفی هدف از مطالعه حاضر به صورت کلی، ارزیابی و انتخاب روش مناسب ریزمقیاس‌نمایی متغیرهای اقلیمی بر پایه یادگیری ماشین بوده و بر انتخاب بهترین مدل برای محدوده مورد ارزیابی تمرکز نشده است. لذا، خروجی حاصل از شبیه‌سازی مدل‌های اقلیمی هم در دوره پایه و هم در دوره‌های آتی به روش حسابی میانگین‌گیری شده و نتایج مربوط به متوسط برآورد مدل‌های مورد استفاده برای پارامترهای دما و بارش تحت تحلیل قرار گرفت است. به عبارتی، در مطالعه حاضر تلاش شد به جای ارزیابی خروجی هر مدل اقلیمی واحد، خروجی حاصل از مدل‌های اقلیمی مورد استفاده میانگین‌گیری شده و برای کل منطقه مورد مطالعه دورنمایی شوند.

ارزیابی عملکرد روش‌های ریزمقیاس‌نمایی

در مطالعه حاضر، سه روش یادگیری ماشین جهت ریزمقیاس‌نمایی خروجی GCM‌های مورد استفاده برای متغیرهای بارش و دما به کار گرفته شد. روش‌های استفاده شده در طول دوره (۲۰۰۹-۱۹۹۰) آموزش دیده و در دوره (۲۰۱۴-۲۰۱۰) از نظر اعتبار مورد ارزیابی قرار گرفتند. در ادامه، پس از ریزمقیاس‌نمایی مقادیر بارش و دمای ماهانه شبیه‌سازی شده توسط مدل‌های اقلیمی با استفاده از سه روش MLP، SVM و RF ارائه شده در بخش روش‌شناسی، تلاش شد نتایج حاصل از ارزیابی عملکرد روش‌های مذکور با کمک معیارهای R^2 ، MAE و RMSE در دو دوره مدنظر ارائه شود. به‌منظور ارائه میزان عملکرد روش‌ها، مقادیر شبیه‌سازی شده توسط مدل‌های اقلیمی منتخب برای متغیرهای بارش و دما تحت سه روش مذکور ریزمقیاس‌شده و خروجی تمامی مدل‌ها تحت هر سه روش میانگین‌گیری شد. شکل ۴ الف و ب ترسیم شده به ترتیب بارش و دمای ریزمقیاس شده در دوره‌های آموزش و آزمایش را نشان می‌دهند.


همان‌طور که در شکل ۴ الف مشاهده می‌شود، میزان ضریب تعیین در هر دو دوره ارزیابی برای روش RF نسبت به دو روش دیگر در تمامی ایستگاه‌های مطالعاتی بیشتر بوده و اختلاف چشمگیری با روش‌های MLP و SVM در راستای ریزمقیاس‌نمایی بارش شبیه‌سازی شده توسط مدل‌های اقلیمی دارد. از طرفی، ضعیف‌ترین عملکرد طبق این معیار در هر دو دوره متعلق به روش SVM است. در دوره‌های آموزش و آزمایش، کمترین مقدار معیارهای MAE و RMSE برای روش RF اندازه‌گیری شده که نشان از برتری این روش نسبت به سایر روش‌ها طبق این دو معیار ارزیابی دارد. روش SVM در دوره آموزش، دارای بیشترین مقادیر برای دو معیار MAE و RMSE بوده که بیانگر ضعف این روش

ریزمقیاس‌نمایی در این دوره نسبت به روش‌های MLP و RF است. همچنین، در دوره آزمایش طبق دو معیار مزبور، روش‌های MLP و SVM به صورت تقریبی دارای مقادیر نزدیک به هم هستند؛ به طوری که روش MLP در عمده ایستگاه‌های مطالعاتی با در نظر گرفتن اختلافات جزئی نسبت به روش SVM طبق این دو معیار برتری داشته و عملکرد نسبی مطلوبی از خود نشان می‌دهد. به طور کلی، با توجه به سه معیار ارزیابی مورد استفاده، روش RF در هر دو دوره مدنظر در تمامی ایستگاه‌های مطالعاتی نسبت به دو روش دیگر عملکرد مطلوبی داشته و در مقابل، روش SVM نسبت به دو روش دیگر در عمده ایستگاه‌های مطالعاتی در راستای ریزمقیاس‌نمایی متغیر بارش شبیه‌سازی شده توسط مدل‌های اقلیمی دارای ضعیف‌ترین عملکرد است. بدون در نظر گرفتن متغیر اقلیمی دما، این بخش از نتایج حاصل، مطابق با یافته‌های پژوهش انجام شده توسط Tang و همکاران (۲۰۲۴) بوده و در این مطالعه نیز روش RF نسبت به سایر روش‌های مورد استفاده، عملکرد بهتری از خود نشان می‌دهد. شایان ذکر است، نتایج حاصل از پژوهش Xu و همکاران (۲۰۲۰) مغایر با یافته‌های این بخش از مطالعه حاضر است؛ چرا که در پژوهش مذکور روش ماشین بردار پشتیبان در مقایسه با سایر روش‌های استفاده شده قابلیت بالایی دارد. این موضوع نشانگر تفاوت عملکردی روش‌های ریزمقیاس‌نمایی مدل‌های اقلیمی بر پایه یادگیری ماشین در مناطق مختلف دنیا بوده و اهمیت ارزیابی این روش‌ها در مناطق مختلف و دستیابی به مناسب‌ترین روش برای محدوده مورد ارزیابی را دو چندان می‌کند.



شکل ۴ الف- معیارهای ارزیابی R^2 ، MAE و RMSE برای روش‌های MLP، SVM و RF جهت ریزمقیاس‌نمایی مقادیر شبیه‌سازی شده بارش در دو دوره آموزش (۱۹۹۰–۲۰۰۹) و آزمایش (۲۰۱۰–۲۰۱۴)

Figure 4a- Evaluation of MLP, SVM, and RF models using R^2 , MAE, and RMSE for precipitation downscaling during training (1990–2009) and testing (2010–2014) periods



شکل ۴ ب- معیارهای ارزیابی R^2 ، MAE و RMSE برای روش‌های MLP، SVM و RF جهت ریزمقیاس‌نمایی مقادیر شبیه‌سازی شده دما در دو دوره آموزش (۱۹۹۰–۲۰۰۹) و آزمایش (۲۰۱۰–۲۰۱۴)


Figure 4b- Evaluation of MLP, SVM, and RF models using R^2 , MAE, and RMSE for temperature downscaling during training (1990–2009) and testing (2010–2014) periods

در کنار ارائه میزان عملکرد روش‌های RF، MLP و SVM در راستای ریزمقیاس‌نمایی متغیر اقلیمی بارش طبق معیارهای ارزیابی استفاده شده، شکل ۴ ب نتایج مربوط به مقادیر معیارهای ارزیابی R^2 ، MAE و RMSE برای این روش‌ها جهت ریزمقیاس‌نمایی مقادیر شبیه‌سازی شده دما در دو دوره آموزش (۱۹۹۰–۲۰۰۹) و آزمایش (۲۰۱۰–۲۰۱۴) را نشان می‌دهد. همانند متغیر اقلیمی بارش، در متغیر دما نیز روش RF در هر دو دوره ارزیابی برای تمامی ایستگاه‌های مطالعاتی دارای بیشترین مقدار R^2 و کمترین مقادیر MAE و RMSE نسبت به روش‌های MLP و SVM است که این موضوع دلالت بر برتری عملکردی این روش نسبت به دو روش دیگر دارد. در هر دو دوره آموزش و آزمایش، روش‌های MLP و SVM طبق معیارهای ارزیابی استفاده شده عملکرد بسیار نزدیکی به یکدیگر داشته و اختلاف چندانی بین آن‌ها موجود نیست. اما، با در نظر گرفتن اختلافات جزئی بین این دو روش، در دوره آموزشی برای عمده ایستگاه‌های مطالعاتی، روش MLP نسبت به SVM عملکردی بهتری از خود نشان می‌دهد که این موضوع در رابطه با دوره آزمایشی صادق نبوده و تصمیم‌گیری در رابطه با برتری یک روش نسبت به دیگری را دشوار می‌کند. نکته حائز اهمیتی که در شکل ۴ ب نیز به وضوح مشاهده می‌شود، این است که اختلاف بین روش‌های مورد استفاده جهت ریزمقیاس‌نمایی مقادیر شبیه‌سازی شده دما در هر دو دوره مد نظر طبق معیار ارزیابی R^2 بسیار چشمگیر نبوده و نزدیک به هم هستند و همچنین طبق معیارهای MAE و RMSE نیز روش‌های MLP و SVM در هر دو دوره بدون در نظر گرفتن اختلافات جزئی، عملکرد مشابهی داشته و تنها روش RF طبق این دو معیار دارای اختلاف معناداری با دو روش دیگر است. دلیل این امر می‌تواند به ماهیت متغیر دما مربوط باشد که عنصری پیوسته بوده و دارای تغییرپذیری کم نسبت به متغیر بارش است. به عبارتی، هر چه پارامتر حالت پیوستگی بیشتری داشته باشد، میزان خطای مدل‌سازی به حداقل می‌رسد.

با نگرش به نتایج حاصل از ارزیابی روش‌های RF، MLP و SVM در راستای ریزمقیاس‌نمایی متغیر دما طبق معیارهای ارزیابی در مطالعه حاضر و با در نظر گرفتن نتایج حاصل از پژوهش‌های Amnuaylojaroen, (2023a) و Tang et al. (2024)، یافته‌های هر سه مطالعه در یک راستا بوده و روش RF نسبت به سایر روش‌های مورد ارزیابی در ریزمقیاس‌نمایی متغیر دما از کارایی و توانمندی بالایی برخوردار است. به طور کلی، با توجه به نتایج حاصل از مطالعه فعلی، روش RF در مقایسه با روش‌های MLP و SVM قابلیت عملکردی بالایی جهت ریزمقیاس‌نمایی متغیرهای بارش و دما در محدوده مورد ارزیابی دارد و برای این منطقه پیشنهاد می‌شود. در ادامه، به منظور ارزیابی تغییرات متغیرهای بارش و دما در دوره‌های آتی، خروجی حاصل از GCM استفاده شده برای دو متغیر مد نظر توسط روش RF ریزمقیاس‌شده و نتایج حاصل در بخش بعدی ارائه شد.

پیش‌نگری دوره آتی

با توجه به قابلیت عملکرد بالای روش RF نسبت به دو روش MLP و SVM، خروجی حاصل از شبیه‌سازی بارش و دما توسط GCMها برای دوره‌های ۲۰۳۱-۲۰۵۵ و ۲۰۸۰-۲۰۵۶ در چهار سناریو SSP1.26، SSP2.45، SSP3.70 و SSP5.85 تحت این روش ریزمقیاس‌شده و نتایج حاصل از آن ارائه شد. شکل ۸ الف نشانگر بارش متوسط ماهانه درازمدت داده‌های مشاهداتی در دوره پایه و شبیه‌سازی شده در دوره‌های پیش‌نگری تحت چهار سناریو مذکور است. نتایج بارش شبیه‌سازی شده توسط مدل‌های اقلیمی استفاده شده پس از اعمال روش RF نشان می‌دهند که در مقیاس ماهانه در ماه‌های ژانویه، آوریل و ژوئیه تحت هر چهار سناریو مقدار بارش کمتر از مقادیر مشاهداتی در دوره آتی اول (۲۰۳۱-۲۰۵۵) برآورد شده و در دوره آتی دوم (۲۰۸۰-۲۰۵۶) نیز این موضوع برای ماه‌های ژانویه، آوریل و می صدق می‌کند. همچنین در ماه اکتبر برای دوره آتی اول و در ماه فوریه نیز برای دوره آتی دوم، برآوردهای اقلیمی پس از ریزمقیاس‌نمایی بیش از مقادیر مشاهداتی به دست آمد. به طور کلی، زیاد و کم بودن مقادیر شبیه‌سازی نسبت به مقادیر مشاهداتی در هر دو دوره آتی تحت تمامی سناریوها به صورت نسبی در ماه‌های یکسان مشاهده می‌شود. همانطور که در شکل ۸ الف نیز مشاهده می‌شود، نکته قابل تامل در رابطه با برآورد بارش برای منطقه مورد مطالعه این است که؛ در هر دو دوره آتی تحت تمامی سناریوها برای ماه‌های می، آوریل و اکتبر مقدار بارش برآورد شده نسبت به مقادیر مشاهداتی در مقایسه با سایر ماه‌ها اختلاف زیادی دارد که این موضوع می‌تواند به دلیل عدم قطعیت‌های ناشی از مدل‌های اقلیمی مورد استفاده، روش ریزمقیاس‌نمایی، سناریوهای SSP و دوره‌های پیش‌نگری باشد (نعمتی شیشه‌گران و همکاران، ۱۴۰۳؛ نعمتی شیشه‌گران و همکاران، ۱۴۰۴). به عبارت دیگر، با نظر به شبیه‌سازی بارش منطقه مورد مطالعه در دوره‌های آتی ۲۰۳۱-۲۰۵۵ و ۲۰۷۶-۲۰۹۰ تحت سناریوهای SSP1.26، SSP2.45، SSP3.70 و SSP5.85 از CMIP6 که نشانگر کاهش بارش در عمده ماه‌ها و افزایش ناگهانی مقدار شبیه‌سازی شده بارش در ماه اکتبر برای دوره آتی اول و ماه فوریه برای دوره آتی دوم و همچنین کاهش ناگهانی مقدار شبیه‌سازی شده بارش در ماه آوریل برای هر دو دوره آتی نسبت به مقدار مشاهده‌ای، می‌توان چنین استدلال کرد که؛ خطای سیستماتیک مدل‌های CMIP6 در شبیه‌سازی منطقه مورد مطالعه همچنان وجود دارد و بسته به روش ریزمقیاس‌نمایی یا اصلاح متغیر اقلیمی مورد ارزیابی مقدار آن می‌تواند متفاوت باشد. این بخش از نتایج به دست آمده با اظهارات پژوهشگرانی همچون Li and Su, (2020)، Xin et al. (2020) و Wang et al. (2022) مطابقت دارد. شایان ذکر است، بیشترین اختلاف بین مقادیر مشاهداتی و شبیه‌سازی شده در هر دو دوره آتی اول و دوم متعلق به سناریو SSP5.85 به ترتیب در ماه‌های آوریل و مارس به میزان ۳۲/۸۸ و ۳۳/۰۵ میلی‌متر بوده و کمترین اختلاف نیز به ترتیب مربوط به سناریوهای SSP3.70 و SSP5.85 در سپتامبر و ژوئیه به میزان ۰/۰۶ و ۰/۰۸ میلی‌متر است.




شکل ۸ الف- متوسط بارش ماهانه شبیه‌سازی شده در دوره‌های ۲۰۳۱-۲۰۵۵ (سمت چپ) و ۲۰۵۶-۲۰۸۰ (سمت راست) تحت سناریوهای SSP1.26، SSP2.45، SSP3.70 و SSP5.85 در مقایسه با بارش مشاهداتی در دوره پایه

Figure 8a- Monthly simulated precipitation for the periods 2031–2055 (left) and 2056–2080 (right) under SSP1-2.6, SSP2-4.5, SSP3-7.0 and SSP5.85 scenarios, compared with observed precipitation in the baseline period

شکل ۸ ب نشانگر ارزیابی تغییرات زمانی دمای شبیه‌سازی شده به صورت متوسط ماهانه در دوره‌های پیش‌نگری ۲۰۳۱-۲۰۵۵ و ۲۰۸۰-۲۰۵۶ تحت چهار سناریو SSP1.26، SSP2.45، SSP3.70 و SSP5.85 است. مقادیر شبیه‌سازی شده دما پس از اعمال روش ریزمقیاس‌نمایی RF با توجه به قابلیت عملکردی بالای آن نسبت به سایر روش‌های مورد ارزیابی، در کنار مقادیر مشاهداتی برای دوره پایه در شکل مزبور نشان داده شده است. همان‌طور که در شکل ۸ ب مشاهده می‌شود، نتایج حاصل از دمای برآورد شده حاکی از افزایش آن در تمامی ماه‌ها در هر دو دوره ارزیابی تحت سناریوهای SSP1.26، SSP2.45، SSP3.70 و SSP5.85 است. در هر دو دوره آتی تحت تمامی سناریوها برای ماه‌های ژوئیه و اوت مقدار دمای برآورد شده نسبت به مقادیر مشاهداتی در مقایسه با سایر ماه‌ها اختلاف بسیار کم و جزئی

داشته و بلافاصله پس از ماه اوت در سپتامبر افزایش ناگهانی دما در تمامی سناریوها نسبت به مقادیر مشاهداتی رخ می‌دهد. همچنین، در دوره آتی اول اختلاف بین برآورد دما تحت سه سناریو SSP1.26، SSP2.45 و SSP3.70 در عمده ماه‌ها ناچیز بوده و تفاوت چندانی با یکدیگر ندارند. در حالی که در دوره آتی دوم این اختلاف بین سناریوها نسبت به دوره اول در عمده ماه‌ها بیشتر بوده و برآوردهای دمایی تحت هر سناریو مشابه هم نیستند. بیشترین اختلاف دمایی بین مقادیر مشاهداتی و شبیه‌سازی شده در هر دو دوره آتی اول و دوم متعلق به سناریو SSP5.85 در ماه سپتامبر به میزان $3/01$ و $4/7$ درجه سانتی‌گراد بوده و کمترین اختلاف نیز در هر دو دوره مربوط به سناریو SSP1.26 در ماه ژوئیه به میزان $0/16$ و $0/19$ درجه سانتی‌گراد است.



شکل ۸ ب- دمای متوسط ماهانه شبیه‌سازی شده در دوره‌های ۲۰۳۱-۲۰۵۵ (سمت چپ) و ۲۰۵۶-۲۰۸۰ (سمت راست) تحت سناریوهای SSP1.26، SSP2.45، SSP3.70 و SSP5.85 در مقایسه با دمای متوسط مشاهداتی در دوره پایه

Figure 8b- Monthly simulated temperature for the periods 2031-2055 (left) and 2056-2080 (right) under SSP1-2.6, SSP2-4.5, SSP3-7.0 and SSP5.85 scenarios, compared with observed precipitation in the baseline period

با توجه به جدول ۲، در مقایسه متوسط دراز مدت بارش و متوسط دمای سالانه مشاهداتی در دوره پایه با مقادیر پیش‌بینی شده برای دوره‌های ۲۰۳۱-۲۰۵۵ و ۲۰۵۶-۲۰۸۰، نکات قابل توجهی در دامنه تغییرات مشاهده می‌شود. با نگرش به جدول مذکور می‌توان چنین اظهار کرد که: (۱) تحت یک سناریوی واحد، دامنه تغییرات محاسبه شده برای دو دوره آتی در متغیر بارش تفاوت‌های چشمگیری با یکدیگر نداشته و روند آن‌ها یکسان (کاهش) است؛ (۲) برای هر دو دوره آتی در متغیر بارش میزان تغییرات محاسبه شده با سناریوهای مورد استفاده متناسب و سازگار است و به طور نسبی تحت تمامی سناریوها برای دو دوره از کاهش ۳ الی ۲۰ درصدی بارش مشاهده می‌شود که این بخش از نتایج حاصل مطابق با نتایج به دست آمده در پژوهش‌های Ahmadi و همکاران (۲۰۲۰) و Chegnizadeh و همکاران (۲۰۲۲) است؛ (۳) برای متغیر دما در دو دوره پیش‌نگری، دامنه تغییرات نوسان زیادی نداشته و تمامی سناریوها در هر دو دوره افزایش دما برای منطقه مورد نظر را نشان می‌دهند که این میزان افزایش دما برای اقلیم آتی منطقه نیز به صورت نسبی مطابق با ادبیات پیشین ارائه شده در این زمینه است (Ahmadi et al., 2020; Zohrabi et al., 2017). به طور کلی، نتایج حاصل از مقایسه میانگین چند ساله بارش و متوسط دمای سالانه مشاهداتی در دوره پایه با مقادیر پیش‌بینی شده حاکی از آن است که با افزایش انتشار گازهای کربن دی اکسید، متوسط دراز مدت بارش تحت سه سناریوی اقلیمی آینده در دوره آتی اول حدود $2/96$ الی $13/98$ درصد و در دوره دوم حدود $4/26$ الی $19/22$ درصد کاهش خواهد یافت. همچنین، برای متغیر دما نیز این تغییرات به ترتیب از $1/13$ تا $1/6$ و $1/44$ تا $3/13$ درجه سانتی‌گراد برای دوره‌های ۲۰۳۱-۲۰۵۵ و ۲۰۵۶-۲۰۸۰ به صورت افزایشی خواهد بود. چنین تغییراتی در متغیرهای بارش و دما برای منطقه مدنظر نشان‌دهنده قطعیت اثرگذاری پدیده تغییر اقلیم بر مناطق حساس به اختلالات هیدرولوژیکی است و نیاز به راهبردهای سازگاری پیشرفته برای مدیریت مؤثر منابع آب در پرتو تغییرات پیش‌نگری شده را الزامی می‌سازد.

جدول ۲- درصد تغییرات بارش و اختلاف دمای شبیه‌سازی شده با مقادیر مشاهداتی تحت سه سناریو SSP1.26، SSP2.45 و SSP3.70 در دو دوره پیش‌نگری

Table 2- Percentage changes in precipitation and differences in temperature between simulated and observed values under SSP1-2.6, SSP2-4.5, and SSP3-7.0 scenarios for two future periods

Scenario	Precipitation		Temperature	
	2031-2055	2056-2080	2031-2055	2056-2080
SSP1.26	-2.96 %	-4.26 %	1.13	1.44
SSP2.45	-5.5 %	-11.4 %	1.31	2.02
SSP3.70	-7.15 %	-13.97 %	1.32	2.59
SSP5.85	-13.98 %	-19.22 %	1.6	3.13

ارزیابی روند متغیرهای اقلیمی بارش و دما با استفاده از آزمون ناپارامتریک من-کندال و برآوردگر شیب سن

نتایج حاصل از آزمون ناپارامتریک من-کندال و برآوردگر شیب سن متغیرهای بارش و دما برای دوره مشاهداتی در جدول ۳ و دو دوره آتی طبق سناریوهای SSP1.26، SSP2.45، SSP3.70 و SSP5.85 از جدول ۴ در مقیاس‌های ماهانه و سالانه ارائه شده است. با توجه به جدول ۳، در بررسی روند معناداری متغیر بارش در دوره مشاهداتی (۱۹۹۰-۲۰۱۴)، عدم وجود روند و تأیید فرض H_0 در مقیاس‌های ماهانه و سالانه مشاهده می‌شود و برای متغیر دما نیز تنها در ماه نوامبر این متغیر در سطح ۹۵ درصد دارای روند کاهشی بوده و در سایر ماه‌های سال به اضافه متوسط تغییرات سالانه، این متغیر دارای روند نبوده و فرض H_0 همانند متغیر بارش برای متغیر دما نیز تأیید می‌شود. در نتیجه، تغییرات بارش و دما در طول دوره مشاهداتی (۱۹۹۰-۲۰۱۴) در محدوده مورد ارزیابی، به طور عمده تحت تأثیر نوسانات تصادفی حول مقادیر نسبتاً ثابت بوده و فاقد روند یکنواخت افزایشی یا کاهشی معنادار است.

جدول ۳- نتایج ارزیابی روند متغیرهای بارش و دما در دوره مشاهداتی (۱۹۹۰-۲۰۱۴)

Table 3- Trend Analysis Results for Precipitation and Temperature Variables in the Observational Period (1990-2014)

	Precipitation			Temperature		
	Z	Q	Trend	Z	Q	Trend
Jan	-0.72	-0.73	-	-0.21	-0.01	-
Feb	-1.89	-1.48	-	1.19	0.07	-
Mar	-1.7	-1.97	-	1.42	0.08	-
Apr	0.12	0.14	-	0.44	0.02	-
May	0.49	0.16	-	-0.02	0.00	-
Jun	-1.1	-0.02	-	1.38	0.4	-
Jul	-1.32	-0.01	-	-0.02	0.00	-
Aug	0.88	0.00	-	-0.4	-0.01	-
Sep	-0.58	0.00	-	-0.86	-0.02	-
Oct	1.1	0.34	-	0.26	0.01	-
Nov	1.47	1.35	-	-2.08	-0.06	**
Dec	-0.68	-0.85	-	-0.21	-0.01	-
Annual	-1.52	-3.66	-	-0.54	-0.01	-

** معناداری روند در سطح ۹۵ درصد *** معناداری روند در سطح ۹۹ درصد

در مطالعه حاضر، علاوه بر ارزیابی روند تغییرات بارش و دما در دوره مشاهداتی، نتایج حاصل از به‌کارگیری آزمون من-کندال و برآوردگر شیب سن برای تحلیل روند این متغیرها در دو دوره ۲۰۳۱-۲۰۵۵ و ۲۰۸۰-۲۰۵۶ تحت سناریوهای SSP1.26، SSP2.45، SSP3.70 و SSP5.85 ارائه شده که خلاصه آن در جدول ۴ آمده است. برای سناریو SSP1.26، تغییرات بارش تنها در ماه‌های ژانویه و سپتامبر در دوره آتی اول در سطح اطمینان ۹۵ درصد به ترتیب دارای روند کاهشی و افزایشی بوده و در سایر ماه‌ها برای این دوره و در تمامی ماه‌ها در دوره آتی دوم، روند معناداری مشاهده نشده و فرض H_0 عدم وجود روند تأیید می‌شود؛ به‌طوری که در مقیاس سالانه نیز برای هر دو دوره آتی، بارش فاقد روند معنادار است. در خصوص دما، تحت همین سناریو در دوره آتی اول، برای ماه‌های سپتامبر، اکتبر و نوامبر ای متغیر دارای روند افزایشی در سطح ۹۵ درصد بوده و در سایر ماه‌ها روندی مشاهده نمی‌شود، در حالی که در دوره آتی دوم، دما در تمامی ماه‌ها فاقد روند معنادار بوده و در مقیاس سالانه نیز در هر دو دوره آتی، فرض H_0 عدم وجود روند برای متغیر دما تأیید می‌شود.

تغییرات بارش در دوره آتی اول سناریو SSP2.45 تنها در ماه سپتامبر در سطح اطمینان ۹۹ درصد دارای روند افزایشی بوده و در سایر ماه‌ها عدم وجود روند برای این متغیر مشاهده می‌شود. در حالی که در دوره آتی دوم، این متغیر تنها در ماه آوریل در سطح ۹۵ درصد روند کاهشی معنادار نشان داده و بقیه ماه‌ها بدون روند باقی مانده‌اند. در هر دو دوره برای تغییرات سالانه باشد، عدم وجود روند مشاهده شده و فرض H_0 تأیید می‌شود. در دوره آتی اول، دما در ماه‌های مارس، ژوئن و دسامبر ($P<0.05$) و ماه‌های آوریل، می، سپتامبر و نوامبر ($P<0.01$) روند افزایشی معنادار داشته، اما سایر ماه‌ها بدون روند هستند. در دوره آتی دوم، روند افزایشی دما در ژانویه و دسامبر ($P<0.05$) و اوت ($P<0.01$) مشاهده شده و در سایر ماه‌ها نیز عدم وجود روند معنادار و تأیید فرض H_0 ملاحظه شد. برخلاف بارش، تغییرات سالانه متوسط دما در هر دو دوره آتی در سطح ۹۹ درصد ($P<0.01$) دارای روند افزایشی معنادار است.

در سناریو SSP3.70، تغییرات بارش در طول دوره آتی اول و دوم به ترتیب تنها برای ماه‌های ژوئن و نوامبر در سطح ۹۵ درصد دارای روند کاهشی بوده و در سایر ماه‌ها روند معناداری مشاهده نشده و فرض H_0 عدم وجود روند تأیید می‌شود؛ به‌طوری که در مقیاس سالانه نیز برای هر دو دوره آتی، بارش فاقد روند معنادار است. در رابطه با دما نیز، تحت همین سناریو در دوره آتی اول، ماه‌های ژانویه و آوریل ($P<0.05$) و ماه‌های فوریه، مارس، سپتامبر، اکتبر، نوامبر و دسامبر ($P<0.05$) دارای روند افزایشی معنادار بوده و سایر ماه‌ها بدون روند باقی مانده‌اند. در دوره آتی دوم، روند افزایشی دما در ماه‌های ژانویه، آوریل، می و ژوئن ($P<0.05$) و فوریه، مارس، سپتامبر، اکتبر و نوامبر ($P<0.01$) مشاهده شده و در سایر ماه‌ها نیز عدم وجود روند معنادار و تأیید فرض H_0 ملاحظه شد. تغییرات سالانه متوسط دما در هر دو دوره آتی در سطح ۹۹ درصد ($P<0.01$) همانند سناریو SSP2.45 دارای روند افزایشی معنادار است.

جدول ۴- نتایج ارزیابی روند متغیرهای بارش و دما در دوره‌های پیش‌نگری ۲۰۵۵-۲۰۳۱ و ۲۰۸۰-۲۰۵۶ تحت سناریوهای SSP1.26، SSP2.45، SSP3.70 و SSP5.85

Table 4. Trend Analysis Results for Precipitation and Temperature Variables in 2031-2055 and 2056-2080 Projection Periods under SSP1.26, SSP2.45, SSP3.70, and SSP5.85 Scenarios

SSP1.26	Precipitation						Temperature					
	2031-2055			2056-2080			2031-2055			2056-2080		
	Z	Q	P-Value	Z	Q	P-Value	Z	Q	P-Value	Z	Q	P-Value
Jan	-2.50	-2.58	** 0.01	-0.02	-0.05	0.98	0.35	0.01	0.73	-0.86	-0.02	0.39
Feb	0.26	0.19	0.80	-0.54	-0.04	0.59	0.82	0.02	0.41	0.07	0.00	0.94
Mar	-0.26	-0.24	0.80	-0.40	-0.04	0.69	1.56	0.04	0.12	-1.56	-0.03	0.12
Apr	0.54	0.34	0.59	0.68	0.61	0.50	-0.26	0.00	0.80	-1.80	-0.04	0.07
May	0.68	0.30	0.50	1.28	0.37	0.20	0.16	0.00	0.87	0.96	0.02	0.34
Jun	-1.37	0.00	0.17	-0.31	0.00	0.76	-0.77	-0.01	0.44	0.58	0.01	0.56
Jul	-0.85	0.00	0.40	0.00	0.00	1.00	0.07	0.00	0.94	-0.68	0.00	0.50
Aug	1.36	0.00	0.17	0.24	0.00	0.81	0.91	0.01	0.36	0.30	0.00	0.76
Sep	2.35	0.01	** 0.02	0.36	0.00	0.72	1.99	0.05	** 0.05	0.30	0.01	0.76
Oct	0.49	0.62	0.62	-0.40	-0.50	0.69	2.08	0.03	** 0.04	0.49	0.00	0.62
Nov	0.40	0.45	0.69	0.86	1.00	0.39	2.41	0.06	** 0.02	0.68	0.01	0.50
Dec	1.19	1.09	0.23	-0.82	-0.98	0.41	0.86	0.02	0.39	-1.19	-0.03	0.23
Annual	0.54	2.89	0.59	0.40	1.35	0.69	2.45	0.01	0.01	-0.96	0.00	0.34
***: معناداری روند در سطح ۹۵ درصد **: معناداری روند در سطح ۹۹ درصد												
SSP2.45	Precipitation						Temperature					
	2031-2055			2056-2080			2031-2055			2056-2080		
	Z	Q	P-Value	Z	Q	P-Value	Z	Q	P-Value	Z	Q	P-Value
Jan	0.58	0.52	0.56	-0.54	-0.81	0.59	0.12	0.00	0.91	2.03	0.06	** 0.04
Feb	-0.16	-0.09	0.87	0.12	0.19	0.91	1.61	0.03	0.11	1.38	0.02	0.17
Mar	-0.58	-0.47	0.56	-0.40	-0.44	0.69	2.03	0.04	** 0.04	1.05	0.02	0.29
Apr	-0.40	-0.36	0.69	-2.13	-1.17	** 0.03	2.87	0.08	*** 0.00	-0.40	-0.02	0.69
May	-0.35	-0.08	0.73	-0.30	-0.10	0.76	2.64	0.05	*** 0.01	0.96	0.01	0.34
Jun	-0.33	0.00	0.74	0.07	0.00	0.94	2.22	0.05	** 0.03	1.75	0.04	0.08
Jul	-0.58	0.00	0.56	0.99	0.00	0.32	0.96	0.00	0.34	0.98	0.00	0.33
Aug	-0.62	0.00	0.53	1.13	0.00	0.26	1.61	0.01	0.11	2.69	0.01	*** 0.01
Sep	-0.55	0.00	0.58	0.03	0.00	0.98	3.06	0.06	*** 0.00	0.44	0.00	0.66
Oct	2.85	1.98	*** 0.00	1.38	0.59	0.17	1.75	0.03	0.08	0.77	0.01	0.44
Nov	1.14	1.01	0.25	-0.02	-0.03	0.98	2.73	0.05	*** 0.01	1.75	0.04	0.08
Dec	-0.72	-0.85	0.47	0.40	0.21	0.69	2.13	0.05	** 0.03	2.27	0.03	** 0.02
Annual	0.82	2.45	0.41	-0.58	-1.88	0.56	4.83	0.04	*** 0.00	3.62	0.02	*** 0.00
***: معناداری روند در سطح ۹۵ درصد **: معناداری روند در سطح ۹۹ درصد												
SSP3.70	Precipitation						Temperature					
	2031-2055			2056-2080			2031-2055			2056-2080		
	Z	Q	P-Value	Z	Q	P-Value	Z	Q	P-Value	Z	Q	P-Value
Jan	-1.66	-1.83	0.10	0.16	0.12	0.87	2.55	0.05	** 0.01	2.50	0.06	** 0.01
Feb	1.00	1.06	0.32	-0.58	-0.82	0.56	2.78	0.06	*** 0.01	2.97	0.08	*** 0.00
Mar	-0.49	-0.51	0.62	1.05	0.50	0.29	2.69	0.06	*** 0.01	2.69	0.06	*** 0.01
Apr	0.77	0.54	0.44	0.68	0.86	0.50	2.50	0.05	** 0.01	2.22	0.03	** 0.03
May	0.70	0.07	0.48	0.72	0.12	0.47	1.61	0.04	0.11	2.08	0.04	** 0.04
Jun	-2.51	-0.03	** 0.01	-0.80	0.00	0.42	1.10	0.04	0.27	2.55	0.04	** 0.01
Jul	-1.33	0.00	0.18	-0.85	0.00	0.40	1.52	0.00	0.13	1.76	0.00	0.08
Aug	0.36	0.00	0.72	-1.45	0.00	0.15	1.70	0.00	0.09	0.65	0.00	0.51
Sep	0.58	0.00	0.56	1.08	0.00	0.28	4.41	0.13	*** 0.00	4.04	0.05	*** 0.00
Oct	0.72	0.38	0.47	-0.63	-0.30	0.53	3.53	0.06	*** 0.00	3.20	0.07	*** 0.00
Nov	-0.21	-0.70	0.83	-2.08	-2.33	** 0.04	2.87	0.07	*** 0.00	3.06	0.07	*** 0.00
Dec	0.86	0.77	0.39	0.35	0.32	0.73	2.92	0.07	*** 0.00	1.42	0.03	0.15
Annual	-0.26	-1.23	0.80	-0.86	-2.56	0.39	4.74	0.05	*** 0.00	3.81	0.05	*** 0.55
***: معناداری روند در سطح ۹۵ درصد **: معناداری روند در سطح ۹۹ درصد												
SSP5.85	Precipitation						Temperature					
	2031-2055			2056-2080			2031-2055			2056-2080		
	Z	Q	P-Value	Z	Q	P-Value	Z	Q	P-Value	Z	Q	P-Value
Jan	-1.28	-1.35	0.20	0.07	0.06	0.94	2.31	0.06	** 0.02	2.22	0.05	** 0.03
Feb	-0.40	-0.49	0.69	-1.10	-1.07	0.27	2.55	0.06	** 0.01	2.41	0.06	** 0.02
Mar	-1.19	-1.50	0.23	-0.91	-0.81	0.36	3.11	0.06	*** 0.00	1.80	0.03	0.07
Apr	-1.99	-1.02	** 0.05	-0.49	-0.32	0.62	0.91	0.03	0.36	3.25	0.08	*** 0.00
May	0.77	0.27	0.44	0.30	0.05	0.76	3.15	0.07	*** 0.00	2.83	0.06	*** 0.00
Jun	-0.82	0.00	0.41	-1.74	-0.01	0.08	3.85	0.10	*** 0.00	1.56	0.02	0.12
Jul	0.47	0.00	0.64	-1.48	0.00	0.14	2.31	0.01	** 0.02	2.19	0.00	** 0.03
Aug	0.57	0.00	0.57	1.03	0.00	0.30	2.73	0.01	*** 0.01	0.45	0.00	0.65
Sep	1.29	0.00	0.20	0.03	0.00	0.98	4.69	0.09	*** 0.00	5.25	0.07	*** 0.00
Oct	-1.24	-1.06	0.22	-2.13	-0.80	** 0.03	4.18	0.07	*** 0.00	3.81	0.10	*** 0.00
Nov	-1.14	-1.05	0.25	-0.07	-0.05	0.94	2.87	0.08	*** 0.00	3.20	0.06	*** 0.00
Dec	0.02	0.08	0.98	0.72	0.64	0.47	3.39	0.06	*** 0.00	3.62	0.09	*** 0.00
Annual	-2.13	-5.98	** 0.03	-2.30	-2.30	0.39	5.39	0.06	*** 0.00	5.35	0.05	*** 0.00
***: معناداری روند در سطح ۹۵ درصد **: معناداری روند در سطح ۹۹ درصد												

***: معناداری روند در سطح ۹۵ درصد **: معناداری روند در سطح ۹۹ درصد

در سناریوی SSP5.85، تغییرات بارش مشابه SSP3.70 تنها در یک ماه هر دوره (آوریل در دوره اول، $P < 0.05$ ؛ اکتبر در دوره دوم، $P < 0.05$) روند کاهشی معنادار نشان داده و سایر ماه‌ها فاقد روندند؛ فرضیه صفر تأیید می‌شود. با این حال، برخلاف SSP3.70، تغییرات سالانه بارش در دوره آتی اول روند کاهشی معنادار ($P < 0.05$) دارد، در حالی که دوره دوم بدون روند باقی مانده است. برای متغیر دما، در دوره آتی اول به جز ماه آوریل در تمامی ماه‌ها روند تغییرات به صورت افزایشی معنادار بود و برای دوره آتی دوم نیز در ماه‌های مارس، ژوئن و اوت روند تغییرات معنادار نبوده و در سایر ماه‌ها وجود روند افزایشی ملاحظه شد. در مقیاس سالانه نیز برای هر دو دوره آتی، دما در سطح اطمینان ۹۹ درصد دارای روند افزایشی معنادار است.

به طور کلی، در هر چهار سناریو مورد ارزیابی الگوی نامنظم بارش با روندهای محدود (به طور نسبی ۱ ماه در هر دوره) نشان‌دهنده تداوم نوسانات طبیعی بوده و برای متغیر اقلیمی دما نیز به صورت تقریبی روند این متغیر به صورت افزایشی تغییر می‌یابد و با افزایش گازهای گلخانه‌ای تحت سناریوهای مورد استفاده شدت این افزایش نیز بیشتر می‌شود؛ به طوری که روند افزایشی دما برای هر سناریو منطبق با نوع سناریو ارزیابی شده است. به عبارتی، تغییرات روند دما از سناریو SSP1.26 به سمت سناریو SSP5.85 افزایش احتمال وقوع دوره‌های گرم و تنش‌های گرمایی را نشان می‌دهد. با توجه به عدم وجود روند معنادار بارش برای دوره‌های آتی تحت چهار سناریو، با افزایش غلظت گازهای گلخانه‌ای، روند بارش برای منطقه مدنظر در طول سال‌های پیش‌نگری براساس برآوردگر شیب سن نیز به طور تقریبی روند کاهشی را نشان می‌دهد که این موضوع می‌تواند در تشدید تنش‌های گرمایی و وقوع خشکسالی برای منطقه در سال‌های آتی مؤثر باشد.

نتیجه‌گیری

مطالعه حاضر تلاشی در جهت ارزیابی روش‌های ریزمقیاس‌نمایی یادگیری ماشین در تعیین میزان تغییرات متغیرهای بارش و دما برای محدوده حوضه بالادست سد کرخه بود که از طریق اعمال این روش‌ها بر خروجی ۱۰ مدل اقلیمی از مجموعه مدل‌های CMIP6 در شبیه‌سازی بارش و دما در دو آموزش و آزمایش و مقایسه آن‌ها در ریزمقیاس‌نمایی متغیرهای بارش و دمای شبیه‌سازی شده توسط مدل‌های اقلیمی در این دوره‌ها انجام شد. نتایج حاصل از ارزیابی روش‌های مورد استفاده در این پژوهش پس از اعمال بر خروجی بارش و دمای مدل‌های اقلیمی، نشانگر برتری روش RF در هر دو دوره آموزش و آزمایش نسبت به دو روش دیگر است. پس از روش RF که برای هر دو متغیر در هر دو دوره ارزیابی قابلیت عملکردی بالایی از خود نشان داد، روش MLP نیز به طور نسبی روش معقولی از نظر عملکردی در زمینه ریزمقیاس‌نمایی متغیرها برای منطقه به شمار می‌رود. اما، روش SVM در هر دو دوره ارزیابی برای هر دو متغیر بارش و دما نسبت به دو روش دیگر از عملکرد ضعیفی برخوردار بوده و برای منطقه مورد مطالعه پیشنهاد نمی‌شود. به طور کلی، با توجه به نتایج حاصل از مطالعه فنی، روش RF در مقایسه با روش‌های MLP و SVM قابلیت عملکردی بالایی جهت ریزمقیاس‌نمایی متغیرهای بارش و دما در محدوده مورد ارزیابی دارد و جهت به کارگیری در این منطقه توصیه می‌شود. در نهایت، استفاده از روش RF در مرحله پیش‌نگری دوره‌های آتی نشان داد که بارش در هر چهار سناریو اقلیمی SSP1.26، SSP2.45، SSP3.70 و SSP5.85 روندی کاهشی و دما روندی افزایشی خواهد داشت. کاهش بارش و افزایش دما در دوره‌های ۲۰۳۱-۲۰۵۵ و ۲۰۵۶-۲۰۸۰، احتمال رخداد‌های خشکسالی و افزایش تبخیر-تعرق را تشدید می‌کند؛ عواملی که می‌توانند بر منابع آب سطحی و مدیریت سد کرخه اثرات قابل توجهی برجای بگذارند. همچنین مشاهده شد که نوسانات زیاد بارش در برخی ماه‌ها (مانند می و ژوئن) پس از ریزمقیاس‌نمایی می‌تواند ناشی از خطاهای سیستماتیک مدل‌های CMIP6 و حساسیت شدید بارش در این منطقه باشد. چنین رفتاری اهمیت توجه به عدم قطعیت‌های مدل، سناریو و روش ریزمقیاس‌نمایی را دوچندان می‌کند. از طرفی، طبق آزمون من-کندال و برآوردگر شیب سن در هر چهار سناریو مورد ارزیابی، الگوی نامنظم بارش با روندهای محدود (به طور نسبی ۱ ماه در هر دوره) نشان‌دهنده تداوم نوسانات طبیعی بوده و برای متغیر اقلیمی دما نیز به صورت تقریبی روند این متغیر به صورت افزایشی تغییر می‌یابد و با افزایش گازهای گلخانه‌ای تحت سناریوهای مورد استفاده شدت این افزایش نیز بیشتر می‌شود. با توجه به عدم وجود روند معنادار بارش برای دوره‌های آتی تحت چهار سناریو، با افزایش غلظت گازهای گلخانه‌ای، روند بارش برای منطقه مدنظر در طول سال‌های پیش‌نگری براساس برآوردگر شیب سن نیز به طور تقریبی روند کاهشی را نشان می‌دهد.

این پژوهش نشان داد که روش‌های یادگیری ماشین، اگرچه ابزارهای قدرتمندی برای استخراج الگوهای غیرخطی در داده‌های اقلیمی هستند، اما عملکرد آن‌ها بسته به نوع متغیر، ویژگی‌های منطقه و کیفیت داده‌ها می‌تواند متفاوت باشد. از میان روش‌های بررسی شده، الگوریتم جنگل تصادفی به دلیل ساختار مقاوم در برابر بیش‌برازش، قابلیت پردازش داده‌های چندمنبعی و توانایی ارزش‌گذاری ویژگی‌ها بهترین گزینه برای ریزمقیاس‌نمایی در این منطقه تشخیص داده شد. درعین حال، نتایج به‌وضوح نشان دادند که هیچ روش واحدی برای تمامی مناطق و همه شرایط اقلیمی به‌طور مطلق برتر نیست و لازم است ارزیابی‌ها براساس ویژگی‌های هر منطقه تکرار شوند.

ملاحظات اخلاقی

دسترسی به داده‌ها: تمامی اطلاعات و نتایج در متن مقاله ارائه شده است.

حمایت مالی: این پژوهش در قالب پژوهش آزاد انجام شده و از سازمانی حمایت مالی دریافت ننموده است.

مشارکت نویسندگان: علی سعدیان: نوشتار و اصلاح، منبع داده، نتایج و فرآیند کدنویسی؛ نیما نعمتی شیشه‌گران: مفهوم‌سازی، روش‌شناسی و نرم‌افزار

تضاد منافع نویسندگان: نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

سپاس‌گزاری: بدین‌وسیله از سازمان هواشناسی ایران به‌دلیل تامین داده‌های ایستگاهی مورد استفاده در این پژوهش سپاسگزاری می‌شود.

منابع

- ۱- احمدی، حامد و دلاور، مجید. (۱۳۹۸). مقایسه رویکردهای مختلف تفکیک آثار انسانی و اقلیمی بر تغییرات جریان حوضه‌های آبخیز. اکوهیدرولوژی ۶(۴)، ۹۴۳-۹۵۵. <https://doi.org/10.22059/ije.2019.283700.1139>
- ۲- نعمتی شیشه‌گران، نیما، بابائیان، فریبا، میان‌آبادی، حجت. (۱۴۰۴). ارزیابی و مقایسه مدل‌های CMIP6 و CMIP6 در برآورد بارش ایران. سامانه‌های سطوح آبگیر باران. ۱۳(۱)، ۸۵-۱۰۲. <http://jircsa.ir/article-1-573-en.html>
- ۳- نعمتی شیشه‌گران، نیما. بابائیان، فریبا و میان‌آبادی، حجت. (۱۴۰۳). ارزیابی عدم قطعیت بارش ماهانه با به‌کارگیری GCM‌ها و روش‌های تصحیح اریبی نگاشت چندکی. مدیریت آب و آبیاری. ۱۴(۲)، ۴۶۳-۴۸۶. <https://doi.org/10.22059/jwim.2024.369044.1121>

References

1. Ahmadi, H., & Delavar, M. (2019). Comparison of different approaches to separating human and climatic impacts on run-off changes in Basins. *Ecohydrology*, 6(4), 943-955. <https://doi.org/10.22059/ije.2019.283700.1139>. [In Persian]
2. Ahmadi, H., Rostami, N., & Dadashi-Roudbari, A. (2020). Projected climate change in the Karkheh Basin, Iran, based on CORDEX models. *Theoretical & Applied Climatology*, 142. <https://doi.org/10.1007/s00704-020-03335-9>
3. Amnuaylojaroen, T. (2023a). Air pollution modeling in Southeast Asia—an overview. *Vegetation Fires and Pollution in Asia*, 531-544. https://doi.org/10.1007/978-3-031-29916-2_31
4. Amnuaylojaroen, T. (2023b). Advancements in downscaling global climate model temperature data in southeast asia: a machine learning approach. *Forecasting*, 6(1), 1-17. <https://doi.org/10.3390/forecast6010001>
5. Anandhi, A., Srinivas, V. V., Kumar, D. N., & Nanjundiah, R. S. (2008). Role of predictors in downscaling surface temperature to river basin in India for IPCC SRES scenarios using support vector machine. *International Journal of Climatology*, 29(4), 583-603. <https://doi.org/10.1002/joc.1719>
6. Bedia, J., Herrera, S., & Gutiérrez, J. M. (2013). Dangers of using global bioclimatic datasets for ecological niche modeling. Limitations for future climate projections. *Global and Planetary Change*, 107, 1-12. <https://doi.org/10.1016/j.gloplacha.2013.04.005>
7. Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
8. Chadwick, R., Coppola, E., & Giorgi, F. (2011). An artificial neural network technique for downscaling GCM outputs to RCM spatial scale. *Nonlinear Processes in Geophysics*, 18(6), 1013-1028. <https://doi.org/10.5194/npg-18-1013-2011>, 2011
9. Chegnizadeh, A., Rabieifar, H., Ebrahimi, H., & Nayeri, M. Z. (2022). Evaluating the hydrological response due to the changes in climate and land use on streamflow in the Karkheh basin, Iran. *Journal of Water and Climate Change*, 13(11), 4054-4068. <https://doi.org/10.2166/wcc.2022.278>
10. Coulibaly, P., Dibike, Y. B., & Anctil, F. (2005). Downscaling precipitation and temperature with temporal neural networks. *Journal of Hydrometeorology*, 6(4), 483-496. <https://doi.org/10.1175/JHM409.1>
11. Doulabian, S., Golian, S., Toosi, A. S., & Murphy, C. (2021). Evaluating the effects of climate change on precipitation and temperature for Iran using RCP scenarios. *Journal of Water and Climate Change*, 12(1), 166-184. <https://doi.org/10.2166/wcc.2020.114>
12. Fan, J., Yue, W., Wu, L., Zhang, F., Cai, H., Wang, X., ... & Xiang, Y. (2018). Evaluation of SVM, ELM and four tree-based ensemble models for predicting daily reference evapotranspiration using limited meteorological data in different climates of China. *Agricultural and forest meteorology*, 263, 225-241. <https://doi.org/10.1016/j.agrformet.2018.08.019>
13. Flato, G., Marotzke, J., Abiodun, B., Braconnot, P., Chou, S. C., Collins, W., ... & Rummukainen, M. (2014). Evaluation of climate models. In *Climate change 2013: the physical science basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* (pp. 741-866). Cambridge University Press. 10.1017/CBO9781107415324.020
14. Fowler, H. J., Blenkinsop, S., & Tebaldi, C. (2007). Linking climate change modelling to impacts studies. <https://doi.org/10.1002/joc.1556>

15. Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14-15), 2627-2636. [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)
16. Ghosh, S., & Mujumdar, P. P. (2008). Statistical downscaling of GCM simulations to streamflow using relevance vector machine. *Advances in water resources*, 31(1), 132-146. <https://doi.org/10.1016/j.advwatres.2007.07.005>
17. Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1-2), 80-91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
18. Harpham, C., & Dawson, C. W. (2006). The effect of different basis functions on a radial basis function network for time series prediction: A comparative study. *Neurocomputing*, 69(16-18), 2161-2170. <https://doi.org/10.1016/j.neucom.2005.07.010>
19. Haykin, S. (2009). *Neural networks and learning machines*, 3/E. Pearson Education India.
20. Hofmann, T., Schölkopf, B., & Smola, A. J. (2008). Kernel methods in machine learning. *The Annals of Statistics*, 36(3), 1171-1220. <https://doi.org/10.1214/009053607000000677>
21. Hsieh, W. W. (2009). *Machine learning methods in the environmental sciences: Neural networks and kernels*. Cambridge university press.
22. Khosravi, Y., Ouada, T. B., & Homayouni, S. (2025). Developing an ensemble machine learning framework for enhanced climate projections using CMIP6 data in the Middle East. *NPJ Climate and Atmospheric Science*, 8(1), 174. <https://doi.org/10.1038/s41612-025-01033-9>
23. Kim, H., Ham, Y. G., Joo, Y. S., & Son, S. W. (2021). Deep learning for bias correction of MJO prediction. *Nature Communications*, 12(1), 3087. <https://doi.org/10.1038/s41467-021-23406-3>
24. Kim, T. W., & Valdés, J. B. (2003). Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering*, 8(6), 319-328. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2003\)8:6\(319\)](https://doi.org/10.1061/(ASCE)1084-0699(2003)8:6(319))
25. Kostopoulou, E., Giannakopoulos, C., Anagnostopoulou, C., Tolika, K., Maheras, P., Vafiadis, M., & Founda, D. (2007). Simulating maximum and minimum temperature over Greece: a comparison of three downscaling techniques. *Theoretical and Applied Climatology*, 90(1), 65-82. <https://doi.org/10.1007/s00704-006-0269-x>
26. Li, J., & Su, J. (2020). Comparison of Indian Ocean warming simulated by CMIP5 and CMIP6 models. *Atmospheric and Oceanic Science Letters*, 13(6), 604-611. <https://doi.org/10.1080/16742834.2020.1824546>
27. Li, X., Li, Z., Huang, W., & Pengxiao, Z. (2020). Performance of statistical and machine learning ensembles for daily temperature downscaling. *Theoretical and Applied Climatology*, 140(1-2), 571-588. <https://doi.org/10.1007/s00704-020-03098-3>
28. Ling, F., Li, Y., Luo, J. J., Zhong, X., & Wang, Z. (2022). Two deep learning-based bias-correction pathways improve summer precipitation prediction over China. *Environmental Research Letters*, 17(12), 124025. [10.1088/1748-9326/aca68a](https://doi.org/10.1088/1748-9326/aca68a)
29. Maghrabi, A. H., & Alotaibi, R. N. (2018). Long-term variations of AOD from an AERONET station in the central Arabian Peninsula. *Theoretical and Applied Climatology*, 134(3), 1015-1026. <https://doi.org/10.1007/s00704-017-2328-x>
30. Malekipirbazari, M., & Aksakalli, V. (2015). Risk assessment in social lending via random forests. *Expert systems with applications*, 42(10), 4621-4631. <https://doi.org/10.1016/j.eswa.2015.02.001>
31. Meng, H., Di, Z., Zhang, W., Sun, H., Tian, X., Wang, X., ... & Li, Y. (2025). Spatiotemporal analyses of high-resolution precipitation ensemble simulations in the Chinese mainland based on quantile mapping (QM) bias correction and Bayesian model averaging (BMA) methods for CMIP6 models. *Atmosphere*, 16(10), 1133. <https://doi.org/10.3390/atmos16101133>
32. Minsky, M., & Papert, S. (1969). *Perceptron: an introduction to computational geometry*. The MIT Press, Cambridge, expanded edition, 19(88), 2. <https://doi.org/10.7551/mitpress/11301.001.0001>
33. Nemati Shishehgaran, N., Babaeian, F., & Mianabadi, H. (2024). Uncertainty assessment of monthly precipitation using multiple GCMs and quantile mapping bias correction methods. *Journal of Water and Irrigation Management*, 14 (2), 463-486. [10.22059/jwim.2024.369044.1121](https://doi.org/10.22059/jwim.2024.369044.1121). [In Persian]
34. Nemati Shishehgaran, N., Babaeian, F., & Mianabadi, H. (2025). Evaluation and comparison of CMIP5 and CMIP6 models in estimating precipitation in Iran. *Iranian Journal of Rainwater Catchment Systems*, 13(1), 85-102. <http://jirca.ir/article-1-573-en.html>. [In Persian]
35. Niazkar, M., Goodarzi, M. R., Fatehifar, A., & Abedi, M. J. (2023). Machine learning-based downscaling: Application of multi-gene genetic programming for downscaling daily temperature at Dogonbadan, Iran, under CMIP6 scenarios. *Theoretical and Applied Climatology*, 151(1), 153-168. <https://doi.org/10.1007/s00704-022-04274-3>
36. Pachauri, R. K., Allen, M. R., Barros, V. R., Broome, J., Cramer, W., Christ, R., ... & van Ypserle, J. P. (2014). Climate change 2014: synthesis report. Contribution of Working Groups I, II and III to the fifth assessment report of the Intergovernmental Panel on Climate Change (p. 151). Ipcc. <https://www.ipcc.ch/report/ar5/syr/>

37. Pang, B., Yue, J., Zhao, G., & Xu, Z. (2017). Statistical downscaling of temperature with the random forest model. *Advances in Meteorology*, 2017(1), 7265178. <https://doi.org/10.1155/2017/7265178>
38. Partal, T., & Kahya, E. (2006). Trend analysis in Turkish precipitation data. *Hydrological Processes: An International Journal*, 20(9), 2011-2026. <https://doi.org/10.1002/hyp.5993>
39. Ray, P. A., Taner, M. Ü., Schlef, K. E., Wi, S., Khan, H. F., Freeman, S. S. G., & Brown, C. M. (2019). Growth of the decision tree: advances in bottom-up climate change risk management. *JAWRA Journal of the American Water Resources Association*, 55(4), 920-937. <https://doi.org/10.1111/1752-1688.12701>
40. Sachindra, D. A., Ahmed, K., Rashid, M. M., Shahid, S., & Perera, B. J. C. (2018). Statistical downscaling of precipitation using machine learning techniques. *Atmospheric research*, 212, 240-258. <https://doi.org/10.1016/j.atmosres.2018.05.022>
41. Sachindra, D.A., Huang, F., Barton, A., & Perera, B. J. (2013). Least square support vector and multi-linear regression for statistically downscaling general circulation model outputs to catchment streamflows. *International Journal of Climatology*, 33(5), 1087-1106. <https://doi.org/10.1002/joc.3493>
42. Schoof, J. T., & Pryor, S. C. (2001). Downscaling temperature and precipitation: A comparison of regression-based methods and artificial neural networks. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 21(7), 773-790. <https://doi.org/10.1002/joc.655>
43. Seo, G. Y., & Ahn, J. B. (2023). Comparison of bias correction methods for summertime daily rainfall in South Korea using quantile mapping and machine learning model. *Atmosphere*, 14(7), 1057. <https://doi.org/10.3390/atmos14071057>
44. Serrano, A., Mateos, V. L., & Garcia, J. A. (1999). Trend analysis of monthly precipitation over the Iberian Peninsula for the period 1921–1995. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 24(1-2), 85-90. [https://doi.org/10.1016/S1464-1909\(98\)00016-1](https://doi.org/10.1016/S1464-1909(98)00016-1)
45. Tang, T., Liu, T., & Gui, G. (2024). Forecasting precipitation and temperature evolution patterns under climate change using a random forest approach with seasonal bias correction. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. <https://doi.org/10.1109/JSTARS.2024.3425639>
46. Tanimu, B., Bello, A. A. D., Abdullahi, S. A., Ajibike, M. A., Yaseen, Z. M., Kamruzzaman, M., ... & Shahid, S. (2024). Comparison of conventional and machine learning methods for bias correcting CMIP6 rainfall and temperature in Nigeria. *Theoretical and Applied Climatology*, 155(6), 4423-4452. <https://doi.org/10.1007/s00704-024-04888-9>
47. Tripathi, S., Srinivas, V. V., & Nanjundiah, R. S. (2006). Downscaling of precipitation for climate change scenarios: a support vector machine approach. *Journal of hydrology*, 330(3-4), 621-640. <https://doi.org/10.1016/j.jhydrol.2006.04.030>
48. Vandal, T., Kodra, E., & Ganguly, A. R. (2019). Intercomparison of machine learning methods for statistical downscaling: the case of daily and extreme precipitation. *Theoretical and Applied Climatology*, 137(1), 557-570. <https://doi.org/10.48550/arXiv.1702.04018>
49. Vapnik, V. (2013). *The nature of statistical learning theory*. Springer science & business media. Springer, PP. 314. <https://doi.org/10.1007/978-1-4757-3264-1>
50. Vapnik, V. (1998). *Statistical learning theory*. Wiley. New York, PP. 768. <https://www.wiley.com/en-us/Statistical+Learning+Theory-p-9780471030034>
51. Wang, D., Liu, J., Wang, H., Shao, W., Mei, C., & Ding, X. (2022). Performance evaluations of CMIP6 and CMIP5 models for precipitation simulation over the Hanjiang River Basin, China. *Journal of Water and Climate Change*, 13(5), 2089-2106. <https://doi.org/10.2166/wcc.2022.402>
52. Wilby, R. L., Charles, S. P., Zorita, E., Timbal, B., Whetton, P., & Mearns, L. O. (2004). Guidelines for use of climate scenarios developed from statistical downscaling methods. Supporting material of the Intergovernmental Panel on Climate Change, available from the DDC of IPCC TGCIA, 27. <https://doi.org/10.5281/ZENODO.1438319>
53. Xin, X., Wu, T., Zhang, J., Yao, J., & Fang, Y. (2020). Comparison of CMIP6 and CMIP5 simulations of precipitation in China and the East Asian summer monsoon. *International Journal of Climatology*, 40(15), 6423-6440. <https://doi.org/10.1002/joc.6590>
54. Xu, R., Chen, N., Chen, Y., & Chen, Z. (2020). Downscaling and projection of multi-CMIP5 precipitation using machine learning methods in the upper Han River basin. *Advances in Meteorology*, 2020(1), 8680436. <https://doi.org/10.1155/2020%2F8680436>
55. Yaghoobzadeh, M. (2022). Selecting the best general circulation model and historical period to determine the effects of climate change on precipitation. *IDŐJÁRÁS/Quarterly Journal of the Hungarian Meteorological Service*, 126, 247-265. <https://doi.org/10.28974/idojaras.2022.2.5>
56. Zakwan, M., & Niazkar, M. (2022). Innovative triangular trend analysis of monthly precipitation at Shiraz Station, Iran. *Current Directions in Water Scarcity Research*, 7, 589-598. Elsevier. <https://doi.org/10.1016/B978-0-323-91910-4.00033-9>

57. 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 & Applied Climatology*, 142. <https://doi.org/10.1007/s00704-020-03406-x>
58. Zhang, X., & Yan, X. (2015). A new statistical precipitation downscaling method with Bayesian model averaging: a case study in China. *Climate Dynamics*, 45(9), 2541-2555. <https://doi.org/10.1007/s00382-015-2491-7>
59. Zohrabi, N., Goodarzi, E., Massah Bavani, A., & Najafi, H. (2017). Detection and attribution of climate change at regional scale: case study of Karkheh river basin in the west of Iran. *Theoretical and Applied Climatology*, 130(3), 1007-1020. <https://doi.org/10.2166/wcc.2017.043>