



Performance Evaluation of Machine Learning and Traditional Statistical Approaches in Bias Correction of CMIP6 Precipitation Data

Mohammad Fallah Kalaki¹ | Asghar Azizian² | Hadi Ramezani Etedali³

1. Department of Water Science and Engineering, Faculty of Agriculture and Natural Resources, Imam Khomeini International University, Qazvin, Iran. E-mail: mohammadfallahkalki1373@gmail.com
2. Corresponding Author, Department of Water Science and Engineering, Faculty of Agriculture and Natural Resources, Imam Khomeini International University, Qazvin, Iran. E-mail: azizian@eng.ikiu.ac.ir
3. Department of Water Science and Engineering, Faculty of Agriculture and Natural Resources, Imam Khomeini International University, Qazvin, Iran. E-mail: ramezani@eng.ikiu.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Sep. 18, 2025

Revised: Nov. 25, 2025

Accepted: Dec. 15, 2025

Published online: Jan. 2026

Keywords:

*Climate change,
CMIP6,
NEX-GDDP,
Bias correction,
Machine learning,
Poldokhtar watershed.*

ABSTRACT

Global climate models (GCMs) are key tools for analyzing and predicting future climate trends. However, these models often exhibit systematic errors (bias) in simulating climatic parameters. In this study, the impact of traditional statistical bias correction methods Linear Scaling (LS) and Quantile Mapping (QM) and machine learning-based methods Extreme Gradient Boosting (XGBoost) and Long Short-Term Memory neural networks (LSTM) was evaluated to improve the performance of CMIP6 models from the NEX-GDDP dataset in predicting precipitation for the historical period (1961–2014) and the future period (2025–2100) in the Poldokhtar watershed, an area highly sensitive to hydrological variability and frequent destructive floods. The results indicated that raw climate model outputs exhibit significant bias and are unsuitable for direct hydrological applications. The LS method moderately reduced errors and improved performance indices, while QM increased RMSE (up to 10.3 mm) and decreased NSE (down to –2.5). Among machine learning methods, XGBoost achieved the highest accuracy with increases in r (up to 0.67), NSE (up to 0.44), and KGE (by more than 0.4), whereas LSTM effectively corrected systematic errors but was limited in reproducing variability and temporal correlation. These findings provide a valuable foundation for future-oriented climate change analyses and water resource management in the Poldokhtar basin.

Cite this article: Fallah Kalaki, M., Azizian, A., & Ramezani Etedali, H. (2026). Evaluation of Machine Learning-Based Methods and Traditional Static Methods for Bias Correction of CMIP6 Climate Model Precipitation Data, *Iranian Journal of Soil and Water Research*, 56 (11), 3087-3106. <https://doi.org/10.22059/ijswr.2025.402248.670007>

© The Author(s).

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2025.402248.670007>



EXTENDED ABSTRACT

Introduction

Increasing greenhouse gas concentrations and climate change significantly affect water resources and hydrological processes, while extreme events such as floods and droughts impose substantial economic and social impacts (Almazroui et al., 2020; Kim et al., 2021; Aryal et al., 2019; UNISDR, 2009; Jongman et al., 2012; Hirabayashi et al., 2021; Houshmand Kouchi et al., 2019). General Circulation Models (GCMs) are the primary tools for predicting climate change, but their coarse spatial resolution requires bias correction for local and regional studies (Sachindra et al., 2018; Taylor et al., 2012). The CMIP6 project, providing SSP and RCP scenarios, enables higher-accuracy simulations of future climate changes (Eyring et al., 2016; O'Neill et al., 2016). Traditional bias correction methods, such as Linear Scaling (LS) and Quantile Mapping (QM), effectively reduce systematic errors but have limitations in capturing nonlinear relationships and temporal dependencies (Shiru and Park, 2020; Jaiswal et al., 2022; Heshmati et al., 2025). Recently, machine learning algorithms, including XGBoost and LSTM, have shown improved performance in modeling complex precipitation patterns and providing more accurate bias corrections (Li et al., 2023; Tanimu et al., 2024). This study evaluates the performance of both traditional and machine learning-based bias correction methods on CMIP6 precipitation outputs under SSP scenarios in the Poldokhtar watershed, aiming to reduce uncertainty and improve hydrological predictions and water resources management.

Method

This study focuses on the Poldokhtar watershed, a sub-basin of the Karkheh River in western Iran, covering an area of 2,073 km², with the Kashkan River as its main stream. The data used include daily projections from General Circulation Models (GCMs) in the NEX-GDDP-CMIP6 dataset for both historical and future periods under SSP126, SSP245, SSP370, and SSP585 scenarios. Observed precipitation data from three meteorological stations within the watershed were used to correct biases in the GCM outputs. Three bias correction methods Linear Scaling (LS), Quantile Mapping (QM), and the machine learning algorithm XGBoost were evaluated. Additionally, a Long Short-Term Memory (LSTM) recurrent neural network was applied to capture long-term temporal dependencies and achieve more accurate precipitation adjustments. Model performance before and after bias correction was assessed using statistical metrics including MAE, RMSE, Pearson correlation coefficient, NSH, and KGE. Based on these metrics, GCMs were ranked at each station, and the cumulative ranks across the three stations were used to select the best-performing model for the watershed. This approach enables more accurate precipitation predictions and supports the analysis of climate change impacts on water resources.

Results

In this study, the performance of 23 CMIP6 climate models in simulating precipitation at three stations Poldokhtar, Afrineh, and Doab Veisian was evaluated. Results indicated that the raw model outputs exhibited considerable bias, with high RMSE and MAE values and low correlation and NSE, performing even worse than the simple observational mean. After applying bias correction methods, the linear scaling (LS) approach only slightly reduced errors and provided limited improvements in performance metrics, while the quantile mapping (QM) method generally worsened model performance across most indices. The XGBoost machine learning algorithm significantly reduced systematic errors and improved RMSE, MAE, NSE, and KGE, leading to the identification of selected models such as CanESM6, MIROC6, and GISS-E2-1-G. The LSTM approach also reduced mean errors but failed to reproduce variance and temporal correlation structures. Future precipitation projections using XGBoost-corrected CanESM6 indicated increases in winter and spring precipitation and notable monthly seasonal shifts, particularly under more severe SSP370 and SSP585 scenarios, while summer precipitation remained largely unchanged. These findings highlight that combining climate models with advanced machine learning techniques substantially enhances the reconstruction of historical precipitation and the assessment of climate change impacts.

Conclusions

In this study, the performance of 23 CMIP6 climate models in simulating precipitation at three stations—Poldokhtar, Afrineh, and Doab Veisian—was evaluated. Raw model outputs exhibited significant errors and low correlation. The LS method provided only slight improvements, while QM performed worse. Machine learning approaches, particularly XGBoost, substantially enhanced model accuracy by reducing MAE and RMSE and improving NSE and KGE. The XGBoost-corrected CanESM6 model showed the best performance and was used for future scenario projections. Predictions indicate increased precipitation in spring and autumn and slight decreases in winter, highlighting important applications for water resources management and climate

change forecasting.

Author Contributions

“Conceptualization, M.F.K. and A.A.; methodology, M.F.K and A.A.; software, M.F.K.; validation, M.F.K. and A.A.; formal analysis, M.F.K., A.A. and H.R.E.; investigation, M.F.K., A.A. and H.R.E.; resources, X.X.; data curation, M.F.K and A.A.; writing original draft preparation, M.F.K.; writing review and editing, M.F.K and A.A.; visualization, M.F.K and A.A.; supervision, A.A. and H.R.E.; project administration, A.A.; funding acquisition, A.A. All authors have read and agreed to the published version of the manuscript.”

Data Availability Statement

Data available on request from the authors.

Acknowledgements

We sincerely thank all individuals who contributed to the completion of this research.

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

ارزیابی عملکرد روش‌های مبتنی بر یادگیری ماشین و روش‌های آماری سنتی در تصحیح اریبی داده‌های بارش مدل‌های اقلیمی CMIP6

محمد فلاح کلاکی^۱ | اصغر عزیزیان^۲ | هادی رمضانی اعتدالی^۳

۱. گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران. رایانامه:

mohammadfallahkalki1373@gmail.com

۲. نویسنده مسئول، گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران. رایانامه:

azizian@eng.ikiu.ac.ir

۳. گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران. رایانامه:

ramezani@eng.ikiu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	
تاریخ دریافت: ۱۴۰۴/۶/۲۷	
تاریخ بازنگری: ۱۴۰۴/۹/۵	
تاریخ پذیرش: ۱۴۰۴/۹/۲۴	
تاریخ انتشار: بهمن ۱۴۰۴	
واژه‌های کلیدی: CMIP6، NEX-GDDP، اصلاح اریبی، یادگیری ماشین، حوضه آبریز پلدختر.	مدل‌های اقلیمی جهانی ابزارهای کلیدی در بررسی و پیش‌بینی روندهای آبی اقلیمی به شمار می‌روند. با این حال، این مدل‌ها دارای خطای سیستماتیک (bias) در پیش‌بینی پارامترهای اقلیمی هستند. در این تحقیق، تأثیر روش‌های اصلاح اریبی آماری سنتی (مقیاس‌گذاری خطی (LS) و نگاشت چندک (QM)) و روش‌های مبتنی بر یادگیری ماشین (تقویت گرادیانی پیشرفته (XGBoost) و شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM)) بر بهبود عملکرد مدل‌های CMIP6 پایگاه NEX-GDDP در پیش‌بینی بارش برای دوره تاریخی (۱۹۶۱-۲۰۱۴) و دوره آینده (۲۰۱۰-۲۰۲۵) در حوضه آبریز پلدختر به‌عنوان منطقه‌ای با حساسیت هیدرولوژیکی و وقوع مکرر سیلاب‌های مخرب، مورد ارزیابی قرار گرفت. نتایج نشان داد که خروجی خام مدل‌های اقلیمی دارای اریبی قابل توجه بوده و قابلیت استفاده مستقیم در مطالعات هیدرولوژیکی را ندارند. روش مقیاس‌گذاری خطی (LS) موجب کاهش نسبی خطا و بهبود شاخص‌های عملکرد شد، درحالی‌که نگاشت چندک (QM) موجب افزایش (RMSE تا ۱۰/۳ میلی‌متر و افت NSE تا ۲/۵- شد. در روش‌های مبتنی بر یادگیری ماشین، XGBoost با افزایش r تا ۰/۶۷، NSE تا ۰/۴۴ و KGE بیش از ۰/۴ بالاترین دقت را نشان داد، درحالی‌که LSTM خطای سامانمند را اصلاح کرد اما در بازتولید نوسانات و همبستگی زمانی داده‌ها محدود بود. یافته‌ها می‌توانند به‌عنوان پایه‌ای مناسب برای تحلیل‌های آینده‌نگر تغییر اقلیم و مدیریت منابع آب در حوضه پلدختر مورد استفاده قرار گیرند.

استناد: فلاح کلاکی، محمد؛ عزیزیان، اصغر؛ و رمضانی اعتدالی، هادی (۱۴۰۴). ارزیابی عملکرد روش‌های مبتنی بر یادگیری ماشین و روش‌های استاتیکی در تصحیح اریبی داده‌های بارش مدل‌های اقلیمی CMIP6. *مجله تحقیقات آب و خاک ایران*، ۵۶ (۱۱)، ۳۰۸۷-۳۱۰۶.



<https://doi.org/10.22059/ijswr.2025.402248.670007>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2025.402248.670007>

مقدمه

افزایش قابل توجه میانگین جهانی غلظت گازهای گلخانه‌ای، تغییر در الگوهای اقلیمی و افزایش رخداد‌های حدی را به دنبال داشته است (Almazroui et al., 2020). روند رو به رشد انتشار این گازها و گرمایش جهانی نشان می‌دهد که تغییر اقلیم می‌تواند بر منابع آب و فرآیندهای هیدرولوژیکی اثرگذار باشد (Kim et al., 2021). افزایش دما و تغییر در الگوی توزیع بارش، چرخه هیدرولوژی حوضه‌ها را دگرگون کرده و در نتیجه بر میزان و دسترسی به منابع آب اثر می‌گذارد (Aryal et al., 2019). رخداد‌های حدی اقلیمی و تغییر در ویژگی‌های آن‌ها پیامدهای چشمگیری بر جوامع انسانی و اکوسیستم‌ها دارند و سالانه زیان‌های اقتصادی سنگینی ایجاد می‌کنند. از این رو، انتظار می‌رود شدت و فراوانی سیلاب‌ها در دهه‌های آینده به دلیل ترکیب تغییرات اقلیمی و تحولات اجتماعی-اقتصادی افزایش یابد (UNISDR, 2009; Jongman et al., 2012; Hirabayashi et al., 2021). در همین چارچوب، هیئت بین‌الدول تغییرات اقلیمی (IPCC) در گزارش پنجم (AR5)^۲ و ششم (AR6)^۳ نسبت به تشدید خطرات طبیعی مانند خشک‌سالی و سیلاب در نتیجه تغییر اقلیم هشدار داده است (هوشمند و همکاران، ۱۳۹۸). بنابراین، دستیابی به پیش‌بینی‌های دقیق از تغییرات آینده، به‌ویژه در زمینه رفتار هیدرولوژیکی، برای سیاست‌گذاری و مدیریت منابع آب اهمیت ویژه‌ای دارد؛ چراکه این اطلاعات می‌تواند مبنای اقدامات سازگاری^۴ و تسکین اثرات منفی باشد (Wang et al., 2020).

تاکنون مدل‌های اقلیمی متعددی به‌عنوان یکی از مهم‌ترین ابزارها برای شبیه‌سازی شرایط اقلیمی گذشته و پیش‌بینی تغییرات آینده توسعه یافته‌اند. فاز ششم پروژه مقایسه متقابل مدل جفت‌شده (CMIP6)^۵ تداوم و تکامل مراحل پیشین این پروژه را نشان می‌دهد و در عین حال، مجموعه‌ای از سناریوهای جدید مدل‌سازی جهانی را ارائه می‌کند که با هدف درک عمیق‌تر از سازوکارهای اقلیمی طراحی شده‌اند (Eyring et al., 2016). مدل‌های موجود در CMIP6 نسبت به نسخه‌های قبلی دارای وضوح بالاتر و بازنمایی بهبود یافته فرآیندهای دینامیکی هستند. همچنین در این مرحله از ترکیب سناریوهای اجتماعی-اقتصادی مشترک (SSPs)^۶ و مسیرهای غلظت نماینده (RCP)^۸ برای شبیه‌سازی تغییرات اقلیمی آینده استفاده شده است (O'Neill et al., 2016). خروجی‌های ارائه‌شده در گزارش ششم بر پایه سناریوهای جدید SSPs تدوین شده‌اند که غلظت‌های متنوع گازهای گلخانه‌ای در قالب RCP را نیز شامل می‌شوند. این سناریوها در پنج گروه اصلی دسته‌بندی شده‌اند و بر شاخص‌های کمی همچون جمعیت، روند شهرنشینی، توسعه اقتصادی منطقه‌ای و فرامنطقه‌ای، تغییرات کاربری زمین، برنامه‌های انرژی و نیز ابعاد مرتبط با اثرات، سازگاری و کاهش آسیب‌پذیری تأکید دارند. از جمله این سناریوها می‌توان به SSP1-1.9، SSP1-2.6، SSP2-4.5، SSP3-7.0، SSP4-3.4، SSP4-6.0، SSP5-3.4 و SSP5-8.5 اشاره کرد. به‌منظور شناسایی وضعیت هیدرولوژیکی یک منطقه و پیش‌بینی شرایط آینده به‌منظور برنامه‌ریزی بهینه منابع آب، داشتن درک دقیق از تغییرات اقلیمی در مقیاس‌های مکانی و زمانی مختلف ضروری است (هوشمند و همکاران، ۱۳۹۸). در این راستا، مدل‌های گردش عمومی جو (GCM)^۹ به‌عنوان پیشرفته‌ترین ابزار موجود جهت پیش‌بینی تغییرات اقلیمی و ارزیابی اثرات آن در مقیاس جهانی شناخته می‌شوند (Sachindra et al., 2018). با این حال، وضوح مکانی پایین این مدل‌ها (حدود ۲۵۰ تا ۶۰۰ کیلومتر) سبب می‌شود استفاده مستقیم از آن‌ها در مطالعات محلی و منطقه‌ای با عدم اطمینان همراه باشد (Taylor et al., 2012). به همین دلیل، به‌کارگیری روش‌های مقیاس‌کاهی^{۱۰} می‌تواند به بهبود دقت و افزایش قابلیت اعتماد خروجی‌های GCM کمک کند (Wilby et al., 1997; Maraun et al., 2010). با این حال، خروجی‌های مدل‌های اقلیمی به دلیل خطاهای سامانمند همچنان نیازمند اصلاح اریبی^{۱۱} هستند تا دقت آن‌ها بهبود یابد.

1 Intergovernmental Panel on Climate Change (IPCC)

2 IPCC Fifth Assessment Report (AR5)

3 IPCC Sixth Assessment Report (AR6)

4 Adaptation

5 Mitigation

6 Coupled Model Intercomparison Project-Phase 6 (CMIP6)

7 Shared Socioeconomic Pathways (SSPs)

8 Representative Concentration Pathways (RCP)

9 General Circulation Models

10 Downscaling

11 Bias Correction

پیشینه پژوهش

(Shiru and Park, 2020) با استفاده از مدل‌های اقلیمی CMIP5 تحت سناریوهای RCP4.5 و RCP8.5، بارش نیجریه را با به‌کارگیری چند روش اصلاح اریبی بررسی کرده است. نتایج نشان داد مقیاس‌گذاری خطی بهترین عملکرد را در کاهش خطای مدل‌ها دارد. Jaiswal et al. (2022) روش‌های LS و QM را برای بهبود شبیه‌سازی بارش‌های موسمی در ۱۴ منطقه اقلیمی-کشاورزی هند طی دوره ۱۹۷۰ تا ۲۰۰۵ به کار گرفتند. نتایج این مطالعه نشان داد که روش LS به‌ویژه در بازتولید روزهای بارانی عملکرد بهتری دارد، هرچند در کاهش اریبی در مناطق خشک تفاوت محسوسی میان روش‌ها مشاهده نشد. جوان و همکاران (۱۴۰۳) به بررسی تأثیر پنج روش تصحیح اریبی مقیاس‌گذاری خطی (LS)، نسبت‌گیری شدت موضعی (LOCI)، تبدیل توانی (PT)، نگاشت توزیع (DM) و تغییر عامل دلتا (DC) بر پیش‌نگری بارش مدل GFDL-ESM4 در حوضه دریاچه ارومیه پرداخت. برای ارزیابی دقت داده‌های تصحیح‌شده از شاخص‌های ضریب همبستگی، RMSE و PBIAS استفاده شد. نتایج نشان داد روش تغییر عامل دلتا (DC) بهترین عملکرد را داشته و پیش‌نگری‌ها کاهش بارش سالانه را در تمامی سناریوهای آینده نشان می‌دهند. Heshmati et al. (2025) با به‌کارگیری روش اصلاح اریبی QM، چهار مدل GFDL-ESM4، IPSL-CM6A-IL، MIROC6، MPI-ESML-2HR، تحت سه سناریوی SSP را به‌منظور تأثیر تغییر اقلیم بر جریان رودخانه در دشت قزوین را با استفاده از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE)، ضریب همبستگی، ضریب نش-ساتکلیف (NSH) و کلینگ گوپتا (KGE) ارزیابی کردند. نتایج نشان داد که روش QM عملکرد قابل‌قبولی داشته و مدل GFDL-ESM4 عملکرد بهتری نسبت به سه مدل دیگر داشته است. هرچند این روش‌ها تا حدودی در بهبود تطابق داده‌های شبیه‌سازی‌شده با مشاهدات مؤثر بوده‌اند، اما محدودیت‌هایی در بازنمایی روابط غیرخطی پیچیده و وابستگی‌های زمانی در داده‌های اقلیمی دارند.

با توجه به این محدودیت‌ها، در سال‌های اخیر استفاده از روش‌های یادگیری ماشین به‌عنوان رویکردی نوین برای اصلاح اریبی موردتوجه قرار گرفته است. روش‌های یادگیری ماشین قادرند الگوهای غیرخطی و وابستگی‌های پیچیده بین داده‌های اقلیمی و مشاهداتی را با دقت بیشتری شناسایی کنند. Li et al. (2023) در پژوهشی با هدف بهبود برآورد بارش در مناطق مرتفع، از الگوریتم XGBoost^۵ همراه با داده‌های سنجش‌ازدور نظیر GSMaP، IMERG و CHIRPS برای ایستگاه Yakou در فلات تبت استفاده کردند. یافته‌های آن‌ها نشان داد این روش نسبت به روش‌های آماری سنتی دقت بیشتری داشته و علاوه بر این، قابلیت تعمیم به ایستگاه‌های دیگر در نروژ و ایالات متحده را نیز داراست. در مطالعه‌ای دیگر، Tanimu et al. (2024) کارایی ۱۳ روش اصلاح اریبی شامل رویکردهای سنتی و مبتنی بر یادگیری ماشین، را در مقیاس‌کاهی چهار مدل اقلیمی CMIP6 برای نیجریه ارزیابی کرده است. داده‌های بارش و دماهای حداکثر و حداقل CRU طی دوره ۱۹۷۵-۲۰۱۴ به‌عنوان مبنای استفاده شد. نتایج نشان داد الگوریتم جنگل تصادفی (RF) به‌عنوان روش مبتنی بر یادگیری ماشین نسبت به سایر روش‌ها دقت بالاتری در اصلاح اریبی بارش و دما دارد. He et al. (2024) در حوضه رودخانه یانگ‌تسه به بررسی و تصحیح اریبی بارش ماهانه مدل‌های CMIP6 پرداختند. در این مطالعه داده‌های چهار مدل اقلیمی جهانی با استفاده از یک روش آماری (PCA)^۷ و دو روش یادگیری عمیق (DNN و LSTM)^۸ اصلاح شدند. نتایج نشان داد که روش مبتنی بر LSTM نسبت به دو روش دیگر عملکرد بهتری داشته و موجب بهبود قابل‌توجه در همبستگی، کاهش RMSE و کاهش اریبی نسبی شده است. همچنین اعمال این روش بر سناریوهای آینده، مشکل بیش‌برآورد بارش به‌ویژه در رخدادهای حدی را تا حد زیادی رفع کرده است.

به‌کارگیری خروجی‌های مدل‌های اقلیمی به‌ویژه بارش در مطالعات هیدرولوژیکی مستلزم داشتن دقت قابل‌قبول به‌منظور کاهش عدم قطعیت است. از این‌رو، هدف این تحقیق بررسی روش‌های مختلف اصلاح اریبی در بهبود خروجی بارش مدل‌های اقلیمی است. لذا در این تحقیق به‌منظور حذف اریبی خروجی بارش مدل‌های اقلیمی CMIP6 تحت سناریوهای SSP126، SSP245، SSP370 و SSP585 در حوضه آبریز پلدختر از روش‌های سنتی LS و QM و روش‌های مبتنی بر یادگیری ماشین شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت (LSTM) و تقویت گرادیانی پیشرفته (XGBoost) استفاده شد. نوآوری این تحقیق در مقایسه هم‌زمان روش‌های آماری سنتی

1 Local Intensity Scaling (LOCI)

2 Power Transformation (PT)

3 Distribution Mapping (DM)

4 Delta Change (DC)

5 Xtreme Gradient Boosting

6 Random Forest

7 Principal Component Analysis (PCA)

8 Deep Neural Network (DNN)


9 Long Short Term Memory (LSTM)

و یادگیری ماشین بر داده‌های با تفکیک‌بالای پایگاه NEX-GDDP در حوضه آبریز پلدختر است که تاکنون بررسی نشده بود و ارزیابی جامع کارایی روش‌های اصلاح اریبی در مناطق سیلاب‌خیز کشور را پوشش می‌دهد. نتایج این تحقیق می‌تواند مبنایی برای بهبود مدل‌سازی هیدرولوژیکی آینده، پیش‌بینی سیلاب و تدوین راهبردهای سازگاری و مدیریت پایدار منابع آب در این حوضه و حوضه‌های مشابه را فراهم آورد.

روش‌شناسی پژوهش

منطقه مورد مطالعه

حوضه آبریز پلدختر یکی از زیرحوضه‌های مهم حوضه آبریز کرخه در غرب ایران است که در محدوده جنوبی استان لرستان واقع شده است. حوضه آبریز پلدختر از زیرحوضه‌های حوضه آبریز کرخه است. موقعیت جغرافیایی این حوضه بین ۳۳ درجه و ۷ دقیقه تا ۳۳ درجه و ۵۵ دقیقه عرض شمالی و ۴۷ درجه و ۵۵ دقیقه تا ۴۸ درجه و ۴۳ دقیقه طول شرقی قرار دارد (شکل ۱). این حوضه به دلیل ویژگی‌های خاص توپوگرافی، اقلیم، منابع آبی و نقش آن در تولید رواناب، اهمیت قابل‌توجهی در مطالعات هیدرولوژی و مدیریت منابع آب دارد. مساحت این حوضه آبریز ۲۰۷۳ کیلومترمربع است. مهم‌ترین رودخانه در این حوضه، رودخانه کشکان است که از ارتفاعات سبز در شمال شهر الشتر سرچشمه می‌گیرد. شیب متوسط این رودخانه که از ارتفاع ۲۴۰۰ متری در شمال استان تا ۵۰۰ متری در جنوب پلدختر در مسافتی حدود ۳۷۴ کیلومتر امتداد دارد، معادل ۵۱ درصد است. ساختار زمین‌شناسی منطقه عمدتاً شامل سنگ‌های رسوبی و آهکی است که با توجه به نفوذپذیری متوسط تا زیاد، تأثیر قابل‌توجهی در رژیم هیدرولوژیکی منطقه دارد. همچنین این منطقه به دلیل وجود شیب‌های تند و بارش‌های ناگهانی، مستعد وقوع سیلاب‌های مخرب به‌ویژه در فصل زمستان و اوایل بهار است.



شکل ۱- محدوده مورد مطالعه-حوضه آبریز پلدختر

داده‌های مورد استفاده

مجموعه داده‌های NEX-GDDP^(۱) (پیش‌بینی‌های روزانه مقیاس‌کاهی شده جهانی ناسا) شامل سناریوهای اقلیمی مقیاس‌کاهی شده برای سراسر جهان است که از خروجی‌های مدل‌های گردش عمومی (GCM) تولید شده‌اند. این مجموعه داده به‌منظور پشتیبانی از مطالعات علمی درباره تأثیرات تغییر اقلیم در مقیاس‌های محلی و منطقه‌ای و افزایش درک عمومی از الگوهای احتمالی اقلیم آینده در سطح شهرها، روستاها و حوضه‌های آبریز ارائه شده است.

NEX-GDDP-CMIP6 (<https://nex-gddp-cmip6.s3.us-west-2.amazonaws.com/index.html>) آخرین نسخه از داده‌های روزانه جهانی مقیاس‌کاهی شده این پروژه است. این داده‌ها بر اساس خروجی‌های CMIP6 با استفاده از مقیاس‌کاهی و اصلاح اریبی تولید شده‌اند تا مجموعه‌ای با وضوح بالا ارائه دهند که دوره‌های تاریخی و آینده را پوشش می‌دهد. این نسخه با قدرت تفکیک مکانی (۲۵°/۰)



$\times 25^\circ/0$)، می‌تواند تغییرات اقلیمی را با مناسبی بازتاب دهد (Thrasher et al., 2022). در این مطالعه، داده‌های روزانه بارش برای دوره تاریخی (۱۹۶۱-۲۰۱۴) و دوره آینده (۲۰۱۵-۲۱۰۰) تحت سناریوهای SSP126, SSP245, SSP370, SS585 از ۲۳ مدل اقلیمی جهانی (GCM) در این مجموعه استخراج شدند (جدول ۱). همچنین به منظور ارزیابی و اصلاح آریبی خروجی این مدل‌ها، ایستگاه‌ها از ۳ ایستگاه سینوپتیک وابسته به سازمان هواشناسی موجود در حوضه آبریز پلدختر استفاده شده است (جدول ۲).

جدول ۱- اطلاعات مربوط به مدل‌های اقلیمی NEX-GDDP-CMIP6

ردیف	مدل	سازمان	کشور	تفکیک مکانی
۱	ACCESS-CM2	Commonwealth Scientific and Industrial Research Organization (CSIRO)	Australia	$25^\circ \times 25^\circ/0$
۲	ACCESS-ESM1-5	Commonwealth Scientific and Industrial Research Organization (CSIRO)	Australia	$25^\circ \times 25^\circ/0$
۳	BCC-CSM2-MR	Beijing Climate Center (BCC)	China	$25^\circ \times 25^\circ/0$
۴	CanESM6	Environment and Climate Change Canada (ECCC)	Canada	$25^\circ \times 25^\circ/0$
۵	CMCC-ESM2	Euro-Mediterranean Center on Climate Change (CMCC)	Italy	$25^\circ \times 25^\circ/0$
۶	CNRM-CM6-1	Centre National de Recherches Météorologiques (CNRM)	France	$25^\circ \times 25^\circ/0$
۷	CNRM_ESM2_2	Centre National de Recherches Météorologiques (CNRM)	France	$25^\circ \times 25^\circ/0$
۸	EC_Earth4	(European Centre for Medium-Range Weather Forecasts - ECMWF)	Netherlands, Sweden, Denmark, Spain	$25^\circ \times 25^\circ/0$
۹	EC_Earth3_Veg_LR	(European Centre for Medium-Range Weather Forecasts - ECMWF)	Netherlands, Sweden, Denmark, Spain	$25^\circ \times 25^\circ/0$
۱۰	FGOALS_g4	Institute of Atmospheric Physics (IAP), Chinese Academy of Sciences	China	$25^\circ \times 25^\circ/0$
۱۱	GFDL_ESM5	Geophysical Fluid Dynamics Laboratory (GFDL)	United States	$25^\circ \times 25^\circ/0$
۱۲	GISS_E2_1_G	NASA Goddard Institute for Space Studies (GISS)	United States	$25^\circ \times 25^\circ/0$
۱۳	INM_CM4_9	Institute for Numerical Mathematics (INM)	Russia	$25^\circ \times 25^\circ/0$
۱۴	INM_CM5_1	Institute for Numerical Mathematics (INM)	Russia	$25^\circ \times 25^\circ/0$
۱۵	IPSL_CM6A_LR	Institute Pierre-Simon Laplace (IPSL)	France	$25^\circ \times 25^\circ/0$
۱۶	MIROC6	University of Tokyo, JAMSTEC	Japan	$25^\circ \times 25^\circ/0$
۱۷	MIROC_ES2L	University of Tokyo, JAMSTEC	Japan	$25^\circ \times 25^\circ/0$
۱۸	MPI-ESM1-2-HR	Max Planck Institute for Meteorology	Germany	$25^\circ \times 25^\circ/0$
۱۹	MPI-ESM1-2-LR	Max Planck Institute for Meteorology	Germany	$25^\circ \times 25^\circ/0$
۲۰	MRI-ESM2-0	Meteorological Research Institute (MRI)	Japan	$25^\circ \times 25^\circ/0$
۲۱	NorESM2-LM	Norwegian Climate Centre	Norway	$25^\circ \times 25^\circ/0$
۲۲	NorESM2-MM	Norwegian Climate Centre	Norway	$25^\circ \times 25^\circ/0$
۲۳	TaiESM1	Research Center for Environmental Changes	Taiwan, China	$25^\circ \times 25^\circ/0$

جدول ۲- مشخصات ایستگاه‌های باران‌سنجی مورد استفاده

ایستگاه	عرض جغرافیایی	طول جغرافیایی	طول دوره زمانی (سال)	بازه زمانی	میانگین	انحراف معیار
آفرینه	۳۳/۳۱	۴۷/۸۹	۶۷	۲۰۲۳-۱۹۵۶	۴۶۰/۲۱	۲۱۲/۹۹
دوآب و بیسان	۳۳/۴۹	۴۸/۰۳	۲۴	۲۰۲۳-۱۹۶۱	۴۵۸/۶۱	۲۲۱/۵۳
پلدختر	۳۳/۱۶	۴۷/۷۱	۵۸	۲۰۲۳-۱۹۶۱	۴۷۱/۱۸	۱۸۰/۲۷

اصلاح آریبی بارش مدل‌های اقلیمی

داده‌های مدل‌های اقلیمی معمولاً دارای انحرافات سیستماتیک نسبت به داده‌های مشاهداتی هستند. برای از بین بردن این خطاها، باید از روش‌های اصلاح آریبی استفاده کرد. روش‌های بسیار متنوعی برای این منظور پیشنهاد شده است که می‌توان به روش‌هایی نظیر مقیاس گذاری خطی (LS)، نگاشت چندک (QM) و الگوریتم XGBoost اشاره نمود که برای متغیرهای مختلف قابل استفاده هستند (Fang et al., 2015). در این تحقیق سه روش LS، QM و XGBoost مورد ارزیابی قرار گرفته و دقت آن‌ها در اصلاح آریبی بارش مدل‌های اقلیمی بررسی شده است.


مقیاس‌گذاری خطی (LS)

هدف روش LS تطبیق کامل میانگین ماهانه مقادیر اصلاح‌شده با مقادیر مشاهده‌شده است (Lenderink et al., 2007). در این روش،

مقادیر خروجی مدل با استفاده از ضریب مقیاس و اصلاح خطی نسبت به میانگین و دامنه داده‌های تاریخی تنظیم می‌شوند، به‌طوری‌که میانگین مدل با میانگین مشاهدات تطبیق پیدا کند (شکل ۲). روش LS به دلیل سادگی و پیاده‌سازی آسان، به‌ویژه برای شبیه‌سازی متغیرهایی مانند بارش و دما در مقیاس روزانه یا ماهانه مورد استفاده قرار می‌گیرد. در روش LS، بارش معمولاً با یک ضریب به‌صورت زیر اصلاح می‌شود:

$$P_{Cor} = P_{raw,m,d} \times \frac{\mu(P_{Obs})}{\mu(P_{raw})} \quad (\text{رابطه ۱})$$

که در این رابطه $P_{cor,m,d}$ بارش اصلاح‌شده، P_{raw} بارش GCM، $\mu(P_{Obs})$ میانگین بارش مشاهداتی و $\mu(P_{raw})$ میانگین بارش مدل GCM هستند.




شکل ۲- طرح‌واره روش مقیاس‌گذاری خطی (LS) برای اصلاح اریبی (Nurdiati et al., 2021)

نگاشت چندک (QM)

روش QM یک روش اصلاح بایاس غیر پارامتری است و به‌طور کلی برای تمام توزیع‌های احتمالی بارندگی کاربرد دارد (Panofsky and Brier, 1958; Wood et al., 2002). این رویکرد می‌تواند به‌طور مؤثری بایاس را در میانگین، انحراف استاندارد و فراوانی روزهای تر و همچنین چندک‌ها اصلاح کند. مفهوم روش نگاشت چندک در شکل ۳ نشان داده شده است. برای بارش، تنظیم بارش با استفاده از QM با توجه به تابع توزیع احتمال تجمعی تجربی (ECDF) و معکوس آن طبق رابطه زیر صورت می‌گیرد:

$$P_{cor,m,d} = ECDF_{obs,m}^{-1} \left(ECDF_{raw,m} (P_{raw,m,d}) \right) \quad (\text{رابطه ۲})$$




شکل ۳- طرح‌واره روش نگاشت چندک (QM) برای اصلاح اریبی

الگوریتم تقویت گرادیانی XGBoost

XGBoost یک سیستم قدرتمند و مقیاس‌پذیر بر پایه درخت تصمیم است (شکل ۴) که با بهره‌گیری از الگوریتمی سازگار با داده‌های

پراکنده و روش چندک وزنی، ساختار درختی را به صورت تقریبی یاد می‌گیرد (Chen & Guestrin, 2016). این الگوریتم به طور مؤثر عمل تقویت گرادیانی را انجام می‌دهد؛ به این صورت که در هر مرحله یک مدل ضعیف جدید آموزش می‌دهد و خروجی آن را به نتایج پیش‌بینی شده قبلی اضافه می‌کند تا در نهایت، به دقت بالاتری دست یابد. مدل XGBoost مبتنی بر مجموعه‌ای از درختان تصمیم است که پیش‌بینی نهایی هر نمونه را با جمع کردن خروجی تمام درخت‌ها به دست می‌آورد. در روند آموزش، الگوریتم به طور پی‌درپی درخت‌های جدیدی به مدل اضافه می‌کند، ویژگی‌ها را تقسیم می‌کند و در هر گام، تابعی جدید برای برازش خطای پیش‌بینی قبلی می‌آموزد. بنابراین، مقدار پیش‌بینی شده نهایی حاصل جمع امتیازات مربوط به همه درخت‌ها خواهد بود. پیش از آموزش مدل XGBoost، برای تنظیم بهینه ابرپارامترهای مدل از جمله تعداد درخت‌ها (estimators)، نرخ یادگیری (learning rate)، بیشینه عمق درخت‌ها، حداقل مجموع وزن مورد نیاز در هر گره، نسبت نمونه‌برداری از داده‌های آموزشی و حداقل کاهش تلفات از تابع RandomizedSearchCV در کتابخانه Scikit-learn استفاده شد (Pedregosa et al., 2011).



شکل ۴- طرح‌واره روش تقویت گرادیانی پیشرفته (XGBoost) برای اصلاح اریبی

شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت (LSTM)


مدل یادگیری ماشین LSTM برای اصلاح اریبی متغیرهای اقلیمی استفاده می‌شود (Hochreiter and Schmidhuber., 1997). مدل LSTM، یک مدل شبکه عصبی بازگشتی، برای حل مسئله وابستگی بلندمدت طراحی شده است. این روش به دلیل توانایی در مدل‌سازی وابستگی‌های زمانی بلندمدت و کوتاه‌مدت در داده‌های سری زمانی یکی از کارآمدترین الگوریتم‌ها در یادگیری عمیق برای پیش‌پردازش و اصلاح داده‌های اقلیمی محسوب می‌شود. مدل‌های بازگشتی کلاسیک (RNN) اگرچه قادر به درک وابستگی‌های متوالی هستند، اما در مواجهه با داده‌های دارای وابستگی‌های طولانی‌مدت دچار مشکل محوشدگی یا انفجار گرادیان می‌شوند. مدل LSTM تعیین می‌کند که چه مقدار حافظه نگه داشته یا فراموش می‌شود و آن را به عنوان یک حالت سلول صادر می‌کند. اطلاعات گذشته را می‌توان با دریافت حالت سلول در لایه پنهان بعدی حفظ کرد و از مشکل محوشدگی گرادیان جلوگیری کرد (Seo and Ahn., 2023). ساختار الگوریتم LSTM در شکل ۵ نشان داده شده است.

داده‌های بارش مورد استفاده شامل دو مجموعه بودند: داده‌های مشاهده‌ای به عنوان معیار صحت و خروجی مدل اقلیمی (GCM) که دارای اریبی سیستماتیک بودند. ابتدا داده‌ها به صورت روزانه و در دوره زمانی مشترک بازنمونه‌گیری شدند. سپس داده‌های ورودی نرمال سازی گردیدند تا محدوده آن‌ها در بازه [۰،۱] قرار گیرد و فرآیند یادگیری شبکه پایدارتر شود. معماری مدل شامل یک یا دو لایه LSTM با تعداد نرون‌های بهینه‌سازی شده و یک لایه تمام‌متصل در خروجی برای تولید بارش اصلاح شده روزانه بود. برای آموزش مدل از تابع هزینه خطای مربعات میانگین (MSE) به منظور کمینه‌سازی اختلاف بین داده اصلاح‌شده و مشاهداتی و بهینه‌ساز آدام جهت

1 Resampling

2 Adam Optimizer

بهبود سرعت و پایداری همگرایی استفاده شد و از توقف زودهنگام^۱ برای جلوگیری از بیش‌برازش^۲ استفاده شد.



شکل ۵- طرح‌واره روش LSTM برای اصلاح اریبی

ارزیابی دقت مدل‌های اقلیمی

اطلاعات تاریخی ارائه‌شده در مدل‌های مذکور را می‌توان به‌عنوان مبنای ارزیابی دقت آن‌ها مورد استفاده قرار داد. از این‌رو اطلاعات مربوط به دوره تاریخی این مدل‌ها را می‌توان با داده‌های مبنای دوره تاریخی مورد مقایسه قرار داد تا بر اساس آن میزان دقت هر مدل مشخص شده و بتوان از مدل‌های با دقت مناسب به‌صورت منفرد یا گروهی جهت پیش‌بینی دما و بارش در دوره آینده استفاده نمود. برای سنجش میزان دقت مدل‌های اقلیمی قبل بعد از اصلاح اریبی بارش مدل‌های اقلیمی، از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE) (Hyndman and Koehler, 2006)، ضریب همبستگی پیرسون (Pearson, 1897)، ضریب نش-ساتکلیف (Nash and Sutcliffe, 1970)، شاخص ترکیبی کلینگ-گوپتا (Gupta et al., 2009) استفاده شد:

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad \text{رابطه ۳}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad \text{رابطه ۴}$$

$$r = \left(\frac{\sum_{i=1}^n (P_i - \bar{P})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (P_i - \bar{P})^2 \times \sum_{i=1}^n (O_i - \bar{O})^2}} \right) \quad \text{رابطه ۵}$$

$$NSH = 1 - \frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n (O_i - \bar{O})} \quad \text{رابطه ۶}$$

$$KGE = 1 - \sqrt{(\beta - 1)^2 + (\alpha - 1)^2 + (r - 1)^2} \quad \text{رابطه ۷}$$

$$\beta = \frac{\mu_P}{\mu_O} \quad \text{رابطه ۸}$$

$$\alpha = \frac{\sigma_P}{\sigma_O} \quad \text{رابطه ۹}$$

در روابط ۳ تا ۹، O_i و P_i به ترتیب مقادیر داده‌های تاریخی بارش یا دمای مشاهداتی و مدل‌های اقلیمی؛ μ_P و $\bar{P}$ میانگین داده‌های تاریخی بارش یا دمای مشاهداتی؛ μ_O و $\bar{O}$ میانگین داده‌های تاریخی بارش یا دمای مدل‌های اقلیمی؛ σ_P و σ_O به ترتیب انحراف معیار داده‌های تاریخی بارش یا دمای مشاهداتی و مدل‌های اقلیمی.

1 Early Stopping

2 Overfitting



انتخاب مدل منتخب با استفاده از روش مبتنی بر رتبه‌بندی مدل‌های اقلیمی

مدل‌های GCM برای شبیه‌سازی و پیش‌بینی اقلیم در مقیاس بزرگ برای گذشته، حال و آینده توسعه یافته‌اند. استفاده از این مدل‌ها جهت پیش‌بینی اقلیم در هر منطقه از جهان وابسته به توانایی مدل‌های مذکور در باز تولید خصوصیات آماری داده‌های تاریخی است. نتیجتاً یک فرآیند ارزیابی نظام‌مند عملکرد مدل‌های GCM برای تحلیل و مطالعه اثر تغییر اقلیم در سیستم‌های منابع آب لازم است. در این راستا پس از انتخاب بهترین و دقیق‌ترین روش اصلاح اریبی، مدل‌های GCM در هر ایستگاه بر اساس شاخص‌های MAE، RMSE، ضریب همبستگی، NSH و KGE به صورت جداگانه رتبه‌بندی می‌شوند. در مرحله بعد مجموع رتبه مدل‌ها در شاخص‌های مختلف محاسبه شده مدل دارای کمترین عدد بهترین عملکرد در هر ایستگاه را خواهد داشت. در نهایت با محاسبه مجموع رتبه‌ها در هر سه ایستگاه بهترین مدل در سطح حوضه آبریز پلدختر تعیین می‌شود.

یافته‌های پژوهشی و بحث

ارزیابی خروجی خام بارش مدل‌های اقلیمی

نتایج ارزیابی خروجی خام بارش مدل‌های اقلیمی در ایستگاه‌های آفرینه، پلدختر و دوآب ویسیان (شکل ۶) نشان می‌دهد که تمامی مدل‌های موردبررسی دارای اریبی قابل‌توجهی در شبیه‌سازی بارش منطقه هستند. مقادیر RMSE در هر سه ایستگاه عمدتاً در بازه‌ای بین ۶/۲ تا ۶/۹ میلی‌متر قرار دارد که بیانگر خطای نسبتاً بالا در برآورد بارش روزانه است. همچنین مقادیر MAE تقریباً در همه مدل‌ها نزدیک به ۲/۲ میلی‌متر بوده و اختلاف اندکی بین ایستگاه‌ها و مدل‌های مختلف مشاهده می‌شود. شاخص ضریب همبستگی در اغلب مدل‌ها کمتر از ۰/۱ است که نشان‌دهنده توان پایین مدل‌ها در بازتولید تغییرات زمانی بارش مشاهده‌ای است. علاوه بر این، مقادیر منفی NSE در تمامی مدل‌ها حاکی از آن است که شبیه‌سازی مدل‌ها حتی از میانگین ساده مشاهدات نیز دقت کمتری دارد. شاخص KGE نیز در اکثر موارد نزدیک به صفر یا حتی منفی بوده که مؤید عملکرد ضعیف مدل‌ها در بازنمایی هم‌زمان میانگین، انحراف معیار و همبستگی بارش است. به‌طور کلی، نتایج حاکی از آن است که خروجی خام مدل‌های اقلیمی بدون اعمال روش‌های اصلاح اریبی، قابلیت اطمینان کافی برای استفاده مستقیم در مطالعات هیدرولوژیکی و مدیریت منابع آب در حوضه پلدختر را ندارند و به‌کارگیری روش‌های اصلاح اریبی برای بهبود دقت این پیش‌بینی‌ها ضروری است.

اصلاح اریبی بارش مدل‌های اقلیمی با روش مقیاس‌گذاری خطی (LS)

شکل ۷.a، نشان‌دهنده بهبود نسبی عملکرد مدل‌ها پس از اصلاح اریبی با روش LS است. مقادیر MAE و RMSE در بیشتر مدل‌ها اندکی کاهش یافته یا تغییر محسوسی نداشته‌اند که بیانگر کاهش خطای مطلق و جذر میانگین مربعات خطا پس از اعمال اصلاح اریبی است.

همچنین ضریب همبستگی در اکثر مدل‌ها ثابت مانده یا بهبود جزئی نشان داده است که حاکی از عدم تغییر چشمگیر همبستگی خطی بین داده‌های مشاهداتی و شبیه‌سازی شده است. از سوی دیگر، شاخص‌های NSE و KGE که معیارهای جامع‌تری برای ارزیابی عملکرد مدل‌ها هستند، پس از اصلاح اریبی در بیشتر ایستگاه‌ها بهبود یافته‌اند، هرچند این بهبود در برخی مدل‌ها به‌ویژه در ایستگاه پلدختر چشمگیرتر بوده است. به‌طور کلی، روش LS توانسته است با کاهش خطا و افزایش نسبی شاخص‌های کارایی، خروجی مدل‌ها را به مقادیر مشاهداتی نزدیک‌تر کند، هرچند این بهبود برای استفاده از مقادیر بارش در مطالعات هیدرولوژیکی و منابع آب کافی نیست که علت آن را می‌توان در محدودیت‌های این روش و ویژگی‌های ذاتی داده‌های اقلیمی جستجو کرد. روش LS تنها میانگین بارش را هم‌تراز می‌کند و قادر به اصلاح واریانس و چولگی نیست؛ از این‌رو شدت و فراوانی رویدادهای حدی به‌درستی بازتولید نمی‌شوند. همچنین این روش همبستگی زمانی و فصلی داده‌ها را اصلاح نمی‌کند، درحالی‌که خطاهای مدل‌های اقلیمی غالباً ماهیت زمانی و فصلی دارند. لذا برای دستیابی به نتایج دقیق‌تر، استفاده از روش‌های سایر روش‌های اصلاح اریبی ضروری است.

اصلاح اریبی بارش مدل‌های اقلیمی با روش نگاشت چندک (QM)

بررسی شکل ۷.b نشان می‌دهد که اعمال نگاشت چندک (QM) بر خروجی مدل‌های اقلیمی نه‌تنها دقت را بهبود نداده، بلکه در غالب موارد، کارایی مدل را تضعیف کرده است. در ایستگاه آفرینه دامنه RMSE از حدود ۶/۵-۶/۹ میلی‌متر به ۸/۳-۱۰/۳ در QM افزایش

	Africn			Doab veisian			Polokhar			Africn			Doab veisian			Polokhar			Africn			Doab veisian			Polokhar			Africn			Doab veisian			Polokhar		
ACCESS-CM2	2.23	2.16	2.16	6.75	6.56	6.43	0.06	0.06	0.06	-0.52	-0.50	-0.57	0.04	0.03	0.04	0.60																				
ACCESS-ESM1-5	2.25	2.18	2.27	6.71	6.47	6.45	0.04	0.05	0.06	-0.51	-0.46	-0.58	0.01	0.00	0.04	--0.16																				
BCC-CSM2-MR	2.22	2.15	2.16	6.65	6.48	6.26	0.08	0.07	0.08	-0.48	-0.47	-0.49	0.05	0.04	0.06	0.45																				
CanESM6	2.22	2.16	2.26	6.55	6.34	6.42	0.04	0.04	0.04	-0.44	-0.40	-0.57	-0.01	-0.01	0.01	Correlation																				
CMCC-ESM2	2.23	2.15	2.12	6.79	6.5	6.34	0.05	0.05	0.03	-0.54	-0.47	-0.53	0.03	0.01	-0.01	0.67																				
CNRM-CM6-1	2.20	2.15	2.17	6.65	6.49	6.32	0.07	0.07	0.09	-0.48	-0.47	-0.52	0.04	0.03	0.07	RMSE (mm)																				
CNRM_ESM2_2	2.24	2.20	2.36	6.74	6.58	6.73	0.04	0.04	0.02	-0.52	-0.51	-0.72	0.01	0.01	0.01	MAE (mm)																				
EC_Earth4	2.24	2.19	2.42	6.9	6.6	6.96	0.05	0.05	0.03	-0.59	-0.52	-0.84	0.03	0.02	0.01	0.37																				
EC_Earth3_Veg_LR	2.24	2.17	2.33	6.78	6.54	6.86	0.05	0.06	0.04	-0.54	-0.49	-0.79	0.03	0.02	0.03																					
FGOALS_g4	2.21	2.15	2.18	6.66	6.31	6.49	0.07	0.07	0.07	-0.48	-0.39	-0.60	0.04	0.02	0.05																					
GFDL_ESM5	2.29	2.19	2.32	6.89	6.59	6.74	0.04	0.04	0.03	-0.59	-0.52	-0.72	0.02	0.00	0.02																					
GISS_E2_1_G	2.24	2.18	2.24	6.61	6.44	6.43	0.04	0.04	0.05	-0.46	-0.45	-0.57	0.00	0.00	0.03																					
INM_CM4_9	2.25	2.13	2.18	6.69	6.32	6.34	0.05	0.06	0.03	-0.50	-0.40	-0.53	0.01	0.00	0.00																					
INM_CM5_1	2.23	2.15	2.29	6.66	6.39	6.48	0.05	0.04	0.04	-0.48	-0.42	-0.60	0.02	-0.01	0.02																					
IPSL_CM6A_LR	2.21	2.16	2.23	6.59	6.49	6.29	0.04	0.05	0.04	-0.45	-0.47	-0.50	0.00	0.00	0.01																					
MIROC6	2.22	2.18	2.36	6.72	6.57	6.68	0.05	0.04	0.06	-0.51	-0.51	-0.70	0.02	0.00	0.04																					
MIROC_ES2L	2.21	2.16	2.14	6.55	6.35	6.24	0.05	0.05	0.05	-0.43	-0.41	-0.48	0.00	0.00	0.02																					
MPI-ESM1-2-HR	2.21	2.15	2.23	6.74	6.54	6.55	0.06	0.06	0.05	-0.52	-0.49	-0.63	0.03	0.03	0.04																					
MPI-ESM1-2-LR	2.24	2.17	2.20	6.62	6.43	6.34	0.06	0.06	0.07	-0.47	-0.44	-0.53	0.03	0.02	0.05																					
MRI-ESM2-0	2.21	2.17	2.28	6.72	6.55	6.63	0.06	0.07	0.08	-0.51	-0.50	-0.67	0.04	0.04	0.07																					
NorESM2-LM	2.22	2.19	2.18	6.71	6.56	6.29	0.05	0.06	0.08	-0.50	-0.50	-0.51	0.03	0.03	0.05																					
NorESM2-MM	2.24	2.14	2.13	6.79	6.51	6.39	0.05	0.05	0.04	-0.54	-0.48	-0.55	0.03	0.01	0.01																					
TaiESM1	2.24	2.17	2.14	6.81	6.55	6.34	0.04	0.04	0.04	-0.55	-0.50	-0.53	0.02	0.00	0.01																					

اصلاح داریم، بارش، مدل‌های اقلیمی، بارش، تقویت گردان، بیشتر فته (XGBoost)


شکل ۷.۷ نشان می‌دهد که به‌کارگیری روش XGBoost برای اصلاح اریبی خروجی بارش مدل‌های اقلیمی در ایستگاه‌های آفرینه، پلدختر و دوآب ویسیان منجر به بهبود قابل‌توجه عملکرد مدل‌ها شده است. پس از اعمال XGBoost، مقادیر r به بازه‌ای بین حدود ۰/۵ تا ۰/۶۷ رسیده و شاخص NSE از مقادیر منفی به مقادیر مثبت تا حدود ۰/۴۴ افزایش یافته است. همچنین شاخص KGE که در داده‌های خام تقریباً نزدیک به صفر یا منفی بود، پس از اعمال XGBoost در بسیاری از مدل‌ها به بیش از ۰/۴ ارتقا یافته است. علاوه بر این، مقادیر MAE و RMSE نیز به شکل چشمگیری کاهش یافته‌اند. این بهبود نشان می‌دهد که روش XGBoost توانسته است خطاهای



سیستماتیک مدل‌های اقلیمی را کاهش داده و تطابق بهتری با داده‌های مشاهداتی ایجاد کند. به‌طور کلی، مقایسه نتایج نشان می‌دهد که XGBoost برخلاف روش‌های ساده‌تر مانند اصلاح خطی (LS) و QM، کارایی بسیار بالاتری در کاهش خطا و افزایش قابلیت اعتماد مدل‌های اقلیمی داشته است و می‌تواند به‌عنوان یک رویکرد کارآمد در کاهش اریبی خروجی مدل‌های اقلیمی به کار گرفته شود.

اصلاح اریبی بارش مدل‌های اقلیمی با روش شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت (LSTM)

بررسی نتایج پس از اصلاح اریبی با روش LSTM (شکل ۷.d) نشان می‌دهد که استفاده از روش LSTM توانسته است خطای مدل‌ها را به‌طور محسوسی کاهش دهد، به‌طوری‌که شاخص‌های MAE و RMSE در هر سه ایستگاه بهبود داشته و از مقادیر نسبتاً بالا در خروجی خام مدل‌ها به سطوح پایین‌تری (MAE تا ۰/۳۷ میلی‌متر و RMSE تا ۲/۱۲ میلی‌متر) رسیده‌اند.



شکل ۷- ارزیابی خروجی بارش مدل‌های اقلیمی پس از اصلاح اریبی با روش‌های (a: LS, b: QM, c: XGBoost, d: LSTM) در ایستگاه‌های

آفرینه، پلدختر و دوآب ویسیان

این موضوع بیانگر توانایی LSTM در یادگیری الگوهای عمومی خطا و کاهش بایاس سیستماتیک مدل‌های اقلیمی است. همچنین شاخص NSE که در حالت خام غالباً منفی بوده، پس از اصلاح به مقادیری نزدیک صفر رسیده و نشان‌دهنده اندکی بهبود در بازتولید تغییرات کلی سری زمانی است. با این حال، ضریب همبستگی تغییر چندانی نکرده و شاخص KGE دچار افت تا ۰/۳۵- شده است. دلیل اصلی این وضعیت را می‌توان در ماهیت عملکرد LSTM جستجو کرد؛ این مدل با تمرکز بر کمینه‌سازی خطای مربعات میانگین، بیشتر به نزدیک کردن مقادیر پیش‌بینی‌شده به مقادیر مشاهده‌ای در مقیاس میانگین می‌پردازد و کمتر به حفظ نوسانات، همبستگی زمانی و ساختار تغییرپذیری طبیعی بارش توجه دارد. در نتیجه، خروجی اصلاح‌شده اگرچه از نظر مقدار به داده‌های مشاهداتی نزدیک‌تر است، اما به دلیل کاهش دامنه نوسانات، ساختار همبستگی زمانی ضعیف‌تر شده و اجزای واریانس و همبستگی که در شاخص KGE لحاظ می‌شوند، تضعیف گردیده‌اند. به عبارت دیگر، LSTM بایاس سامانمند را اصلاح کرده اما تنوع و پویایی درونی داده‌ها را بازتولید نکرده است؛ همین امر باعث کاهش شدید KGE و محدود ماندن بهبود ضریب همبستگی شده است.

رتبه‌بندی مدل‌های اقلیمی بر اساس شاخص‌های آماری

با توجه به نتایج به‌دست‌آمده، الگوریتم XGBoost توانایی بالایی در بهبود عملکرد مدل‌های اقلیمی در برآورد بارش داشته است. لذا با هدف ارزیابی و انتخاب بهترین مدل‌های اقلیمی در حوضه آبریز پلدختر، ۲۳ مدل اقلیمی که با الگوریتم XGBoost اصلاح شده‌اند؛ بر اساس شاخص‌های آماری رتبه‌بندی شدند (جدول ۳). رتبه نهایی هر مدل با جمع رتبه‌های هر شاخص محاسبه و بهترین مدل‌ها با رنگ سبز مشخص شده‌اند. همچنین در ستون آخر، مجموع رتبه هر مدل در سه ایستگاه محاسبه شده است که برای تعیین مدل‌های منتخب حوضه استفاده شده است. نتایج نشان می‌دهد مدل‌هایی نظیر MIROC6، CanESM5، GISS_E2_1_G و IPSL_CM6A_LR تمامی ایستگاه‌ها عملکرد پایدار داشته و در زمره مدل‌های منتخب قرار گرفته‌اند. بنابراین، مدل‌های انتخاب‌شده در این مرحله می‌توانند به‌عنوان پایه‌ای مناسب برای تحلیل‌های بعدی شامل تولید سناریوهای آینده و ارزیابی اثرات تغییر اقلیم در حوضه پلدختر مورد استفاده قرار گیرند. در ادامه به‌منظور بررسی تغییران بارش در دوره‌های آینده در شرایط تغییر اقلیم تحت سناریوهای SSP126، SSP245، SSP370، SSP585 از مدل CanESM6 به‌عنوان بهترین مدل که بیشترین دقت را دارد استفاده شده است.


جدول ۳- انتخاب بهترین مدل‌های اقلیمی در حوضه آبریز پلدختر با استفاده از رتبه‌بندی مدل‌ها بر اساس شاخص‌های آماری

رتبه‌بندی نهایی مدل‌ها		دوآب و سیپان										پلدختر										آفرینه											
Best Model	All_Rank	Final_Rank	Sum_Rank	KGE	NSE	r	RMSE	MAE	Final_Rank	Sum_Rank	KGE	NSE	r	RMSE	MAE	Final_Rank	Sum_Rank	KGE	NSE	r	RMSE	MAE	Final_Rank	Sum_Rank	KGE	NSE	r	RMSE	MAE	Model			
۱۶	۴۵	۱۴	۶۷	۱۴	۱۴	۱۴	۱۴	۱۳	۱۳	۲۰	۱۰۳	۲۱	۲۰	۲۰	۲۲	۱۱	۵۹	۱۴	۱۴	۱۴	۱۴	۱۳	۶	۱۱	۱۴	۱۴	۱۴	۱۳	۶	ACCESS-CM2			
۱۷	۴۶	۱۰	۵۱	۸	۸	۸	۹	۸	۱۱	۱۷	۸۳	۱۳	۱۹	۱۸	۱۴	۱۹	۹۵	۱۸	۲۱	۲۰	۲۱	۱۵	۲۱	۱۵	۲۱	۲۰	۲۱	۲۱	۱۵	ACCESS-ESM1-5			
۱۳	۳۹	۱۶	۷۹	۱۷	۱۴	۱۴	۱۶	۱۴	۱۷	۲۰	۹۷	۹	۹	۹	۱۱	۱۴	۶۹	۱۶	۱۴	۱۴	۱۴	۱۴	۱۴	۱۱	۱۴	۱۴	۱۴	۱۴	۱۱	BCC-CSM2-MR			
۱	۳	۱	۵	۱	۱	۱	۱	۱	۱	۵	۵	۱	۱	۱	۱	۱	۵	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	CanESM6			
۲۲	۴۳	۲۰	۹۶	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۱۶	۱۰۵	۲۲	۲۲	۲۲	۲۲	۲۱	۱۰۴	۲۲	۲۲	۲۲	۲۲	۲۲	۲۲	۱۶	۲۲	۲۲	۲۲	۲۲	۱۶	CMCC-ESM2			
۱۸	۴۸	۱۷	۸۱	۱۹	۱۷	۱۷	۱۷	۱۷	۱۷	۱۵	۷۸	۱۸	۱۵	۱۵	۱۷	۱۳	۷۶	۱۷	۱۵	۱۵	۱۵	۱۳	۱۵	۱۳	۱۵	۱۵	۱۳	۱۵	۱۳	CNRM-CM6-1			
۱۱	۳۴	۶	۳۳	۵	۵	۵	۶	۶	۶	۱۰	۷۹	۱۴	۱۶	۱۵	۱۶	۱۸	۶۱	۱۲	۱۸	۱۶	۱۵	۱۲	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۲	CNRM ESM2_2			
۲۰	۵۷	۲۲	۱۰۹	۲۲	۲۲	۲۲	۲۲	۲۲	۲۲	۲۱	۷۴	۱۴	۱۴	۱۴	۱۴	۲۰	۱۰۴	۲۱	۲۰	۲۱	۲۰	۲۱	۲۰	۲۱	۲۰	۲۱	۲۰	۲۱	۲۰	۲۱	EC Earth4		
۱۲	۳۶	۱۳	۶۴	۱۳	۱۳	۱۳	۱۳	۱۳	۱۳	۱۳	۶۵	۱۳	۱۲	۱۲	۱۲	۱۲	۱۵	۵۴	۱۰	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	EC Earth3 Veg_LR		
۴	۱۴	۲	۱۱	۲	۲	۲	۲	۲	۲	۳	۲۸	۷	۵	۵	۵	۳	۳۰	۶	۷	۶	۶	۶	۶	۶	۶	۶	۶	۶	۶	۶	FGOALS_g4		
۲۳	۶۹	۲۳	۱۱۵	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۱۱۵	۲۳	۲۳	۲۳	۲۳	۲۳	۱۱۵	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	۲۳	GFDL ESM5		
۵	۱۸	۱۱	۶۳	۷	۷	۷	۷	۷	۷	۱۲	۲۶	۵	۱۲	۱۲	۶	۶	۱۰	۲	۲	۲	۲	۲	۲	۲	۲	۲	۲	۲	۲	۲	GISS E2_1 G		
۵	۱۸	۷	۳۵	۱۰	۱۰	۱۰	۱۰	۱۰	۱۰	۳۲	۷	۶	۷	۷	۷	۵	۲۱	۲	۳	۳	۳	۳	۳	۳	۳	۳	۳	۳	۳	۳	INM_CM4_9		
۱۵	۴۴	۱۵	۶۸	۱۵	۱۵	۱۵	۱۵	۱۵	۱۵	۱۲	۶۴	۱۱	۱۱	۱۱	۱۱	۱۲	۱۷	۸۲	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	INM_CM5_1		
۲	۱۱	۴	۲۳	۴	۴	۴	۴	۴	۴	۵	۲۰	۴	۴	۴	۴	۴	۱۸	۳	۴	۴	۴	۴	۴	۴	۴	۴	۴	۴	۴	۴	۴	IPSL_CM6A_LR	
۷	۲۵	۸	۴۱	۹	۹	۹	۹	۹	۹	۱۰	۵۱	۱۰	۱۱	۱۰	۱۰	۱۰	۳۷	۷	۷	۷	۷	۷	۷	۷	۷	۷	۷	۷	۷	۷	۷	MIROC6	
۳	۱۳	۳	۱۴	۳	۳	۳	۳	۳	۳	۱۳	۲	۲	۲	۲	۲	۲	۲۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	MIROC ES2L	
۱۰	۳۳	۱۸	۹۱	۱۸	۱۸	۱۸	۱۸	۱۸	۱۸	۱۷	۳	۱۷	۱۷	۱۷	۱۷	۲	۸	۶۱	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	MPI-ESM1-2-HR	
۹	۳۹	۹	۴۷	۱۱	۱۱	۱۰	۱۱	۱۰	۱۱	۱۱	۵۸	۱۱	۷	۱۱	۱۰	۸	۴۷	۹	۹	۱۴	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	MPI-ESM1-2-LR	
۱۴	۴۲	۱۹	۹۵	۲۱	۲۱	۲۱	۲۱	۲۱	۲۱	۱۹	۸	۱۹	۱۸	۱۸	۱۸	۸	۷۵	۱۵	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	۱۲	MRI-ESM2-0
۸	۲۸	۵	۲۸	۵	۵	۵	۵	۵	۵	۱۸	۸۴	۱۵	۱۷	۱۶	۱۷	۱۶	۲۸	۵	۱۹	۱۷	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	NorESM2-LM	
۲۱	۶۰	۲۱	۱۰۱	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۲۰	۹۱	۱۹	۲۱	۱۸	۱۹	۲۰	۹۷	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	۲۰	NorESM2-MM	
۱۹	۴۹	۱۱	۶۳	۱۰	۱۰	۱۰	۱۰	۱۰	۱۰	۲۰	۱۰۳	۱۹	۲۱	۲۱	۲۱	۱۸	۸۸	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	۱۶	TaiESM1	

*** رنگ سبز نشان‌دهنده ۱۰ مدل برتر در هر ایستگاه و رنگ آبی نشان‌دهنده ۱۰ مدل برتر در مجموع سه ایستگاه آفرینه، پلدختر و دوآب و سیان است.

شکل ۸ مقادیر بارش مشاهداتی در مقابل بارش مدل CanESM6 به عنوان مدل منتخب قبل و پس از اصلاح اریبی با روش‌های مختلف را نشان می‌دهد. شکل ۸، بیانگر آن است که روش‌های مختلف اصلاح بایاس در بازسازی داده‌های بارش مشاهده‌ای، کارایی

متفاوتی از خود نشان داده‌اند. روش‌های آماری متداول مانند QM و LS به دلیل ماهیت خطی خود، توانایی محدودی در اصلاح خطاهای غیرخطی مدل‌های اقلیمی داشته‌اند؛ به‌طوری‌که مقدار ضریب تبیین R^2 در بیشتر ایستگاه‌ها کمتر از ۰/۲۵ گزارش شده است که نشان‌دهنده ضعف جدی این روش‌ها در بازتولید بارش‌های شدید و تغییرپذیری طبیعی اقلیم منطقه است. علاوه‌براین، تحلیل خطوط رگرسیونی نشان می‌دهد که این روش‌ها اغلب منجر به کم‌برآوردی بارش‌های بالا شده و به همین دلیل، کارایی آن‌ها در شرایط اقلیمی متغیر محدود است.




شکل ۸- بارش مشاهداتی و مدل CanESM6 پس از اصلاح اربیی با روش‌های مختلف در ایستگاه‌های آفرینه، پلدختر و دوآب ویسیان

در مقابل، به‌کارگیری روش‌های مبتنی بر یادگیری ماشین مانند XGBoost و در مواردی LSTM عملکرد بسیار بهتری نشان داده است. الگوریتم XGBoost با دستیابی به مقادیر R^2 حدود ۰/۷ و شیب‌خط رگرسیون نزدیک به یک، توانسته همبستگی قوی‌تری بین داده‌های شبیه‌سازی شده و مشاهداتی برقرار کند که بیانگر توانایی بالای این الگوریتم در مدل‌سازی روابط غیرخطی پیچیده و اصلاح

خطاهای ساختاری مدل‌های اقلیمی است. همچنین شکل ۹ نیز برتری مدل XGBoost در اصلاح اریبی بارش نسبت به سایر روش‌ها را نشان می‌دهد.


به‌طور خاص، نتایج حاکی از آن است که الگوریتم‌های یادگیری ماشین قادرند دقت پیش‌بینی مدل‌های اقلیمی را در بازسازی بارش‌های تاریخی به‌طور چشمگیری افزایش دهند و زمینه را برای استفاده از آن‌ها در پیش‌بینی تغییرات آبی بارش و تحلیل سناریوهای اقلیمی فراهم کنند. بنابراین، ترکیب مدل‌های اقلیمی با روش‌های پیشرفته یادگیری ماشین نسبت به رویکردهای آماری سنتی، رویکردی اثربخش‌تر در مدیریت و برنامه‌ریزی منابع آب به شمار می‌آید.



شکل ۹- میانگین ماهانه بارش مشاهداتی و مدل CanESM6 پس از اصلاح اریبی با استفاده از روش‌های مختلف در ایستگاه‌های آفرینه، پلدختر و دوآب ویسیان

بررسی تغییرات بارش در دوره آینده در شرایط تغییر اقلیم با استفاده از مدل CanESM6 تحت سناریوهای SSP پس از اصلاح اریبی با روش XGBoost

برای بررسی تغییرات بارش در آینده، از مدل CanESM6 اصلاح‌شده با روش XGBoost استفاده شد که بهترین عملکرد شبیه‌سازی بارش را داشت. تغییرات بارش در دوره‌های ۲۰۲۶-۲۰۵۰، ۲۰۵۱-۲۰۷۵ و ۲۰۷۶-۲۱۰۰ برای ایستگاه‌های آفرینه، پلدختر و دوآب ویسیان مورد بررسی قرار گرفت (شکل ۱۰). در ایستگاه آفرینه، بیشترین افزایش بارش در زمستان و بهار مشاهده شد، به‌ویژه تحت سناریوهای SSP370 و SSP585 که تا حدود ۵۰ میلی‌متر افزایش داشت. ماه‌های تابستان کاهش یا تغییرات ناچیز بارش را نشان دادند که حاکی از تمرکز بارش‌های شدید در فصل‌های بارندگی است. در پلدختر، روند مشابه است اما شدت تغییرات کمتر بوده و بیشترین افزایش در ماه‌های فوریه تا آوریل رخ می‌دهد. پاییز این حوضه با کاهش یا نوسان بارش همراه است که می‌تواند بر الگوی کشت و زمان‌بندی آبیاری تأثیرگذار باشد. در دوآب ویسیان، کاهش بارش در برخی ماه‌ها مانند مارس و آوریل و افزایش بارش در پاییز و اوایل زمستان تحت سناریوهای شدیدتر مشاهده شد. به‌طور کلی، بارش در زمستان کاهش، در بهار و پاییز افزایش و در تابستان تغییر چندانی ندارد. بیشترین افزایش بارش مربوط به SSP245 در ۲۰۲۶-۲۰۵۰ و SSP126 در ۲۰۷۶-۲۱۰۰ و بیشترین کاهش مربوط به SSP245 در هر سه دوره است. نتایج این مطالعه با یافته‌های Avazpour et al. (2025) همسو بوده و نشان‌دهنده افزایش بارش در تمامی فصول حوضه کشکان است.



شکل ۱۰- تغییرات بارش مدل CanESM6 اصلاح شده با روش XGBoost تحت سناریوهای SSP در دوره ۲۰۵۰-۲۰۲۶، ۲۰۷۵-۲۰۵۱ و ۲۱۰۰-۲۰۷۶

نتیجه گیری

در این پژوهش، دقت مدل های اقلیمی جهانی CMIP6 در شبیه سازی بارش در سه ایستگاه پلدختر، آفرینه و دوآب ویسیان مورد بررسی قرار گرفت و تأثیر روش های مختلف اصلاح اریبی بر عملکرد این مدل ها ارزیابی شد. نتایج نشان داد که خروجی خام مدل ها دارای خطای قابل توجهی در برآورد بارش روزانه بوده و شاخص های NSE و KGE منفی و ضریب همبستگی پایین، نشان دهنده توان محدود مدل ها در بازتولید تغییرات زمانی و نوسانات بارش است. این یافته ها اهمیت به کارگیری روش های اصلاح اریبی برای افزایش قابلیت اعتماد پیش بینی های اقلیمی در مطالعات هیدرولوژیکی و مدیریت منابع آب را آشکار می سازد. از میان روش های اصلاح اریبی بررسی شده، روش مقیاس گذاری خطی (LS) توانست تا حدودی خطاها را کاهش دهد و شاخص های NSE و KGE را بهبود بخشد، اما محدودیت های این روش در اصلاح واریانس و همبستگی زمانی باعث شد که بازتولید کامل نوسانات و رویدادهای حدی بارش ممکن نباشد. روش نگاشت چندک (QM) در این حوضه عملکرد ضعیف تری داشت و در بسیاری از شاخص ها منجر به کاهش دقت مدل ها شد. در مقابل، روش های پیشرفته تر مانند XGBoost و شبکه عصبی بازگشتی LSTM، توانستند به شکل محسوسی خطاهای مدل ها را کاهش دهند. به ویژه XGBoost ضمن کاهش MAE و RMSE و بهبود شاخص های r ، NSE و KGE، کارایی بسیار بالاتری نسبت به سایر روش ها نشان داد و مدل های اصلاح شده با این الگوریتم برای تحلیل های آینده قابل اعتمادتر تشخیص داده شدند. رتبه بندی مدل های اقلیمی اصلاح شده نشان داد که مدل CanESM6 پس از اصلاح اریبی با روش XGBoost عملکرد قابل قبولی در بازتولید بارش تاریخی منطقه دارد و می تواند به عنوان پایه ای مناسب برای تولید سناریوهای آینده و ارزیابی اثرات تغییر اقلیم استفاده شود. تحلیل تغییرات بارش آینده با استفاده از مدل CanESM6 اصلاح شده به عنوان دقیق ترین مدل اقلیمی در حوضه آبریز پلدختر، بیانگر کاهش بارش در فصل زمستان و افزایش آن در فصول بهار و پاییز است، در حالی که تابستان تغییر چندانی نخواهد داشت. بیشترین افزایش بارش تحت سناریوهای SSP245 و SSP126 و بیشترین کاهش تحت سناریو SSP245 مشاهده شد. به طور کلی، یافته های این مطالعه نشان می دهد که به کارگیری رویکردهای یادگیری ماشین برای اصلاح اریبی، به ویژه XGBoost، می تواند دقت پیش بینی های بارش را در حوضه پلدختر به شکل قابل توجهی بهبود بخشد و اتکای بیش از حد به روش های آماری خطی و ساده، را پوشش داده و مسیر تازه ای برای بهبود پیش بینی های اقلیمی و مدیریت منابع آب فراهم سازد.

هیچگونه تعارض منافع بین نویسندگان وجود ندارد.

منابع

- هوشمند، دل آرام؛ اسماعیلی، کاظم؛ فریدحسینی، علیرضا؛ ثنایی نژاد، سیدحسین و خلیلی، داور. (۱۳۹۸). شبیه سازی اثرات تغییر اقلیم با استفاده از مدل‌های گزارش ارزیابی پنجم تحت سناریوهای RCP بر منابع آبی حوضه ی آبریز سد سلمان فارسی. مجله آبیاری و زهکشی ایران، ۱۳(۲)، ۲۴۳-۲۵۸.
- جوان، خدیجه و عزیززاده، محمدرضا. (۱۴۰۳). ارزیابی روش‌های مختلف تصحیح اریبی بر پیش‌نگری بارش مدل GFDL-ESM4 در حوضه دریاچه ارومیه. جغرافیا و برنامه‌ریزی، ۲۸(۸۸)، ۳۹۷-۴۱۵.

REFERENCES

- Ahmed, K., Sachindra, D. A., Shahid, S., Demirel, M. C., & Chung, E. S. (2019). Selection of multi-model ensemble of general circulation models for the simulation of precipitation and maximum and minimum temperature based on spatial assessment metrics. *Hydrology and Earth System Sciences*. 23(11), 4803-4824.
- Almazroui M, Saeed F, Saeed S, Islam MN, Ismail M, Klutse NAB, Siddiqui MH (2020) Projected change in temperature and precipitation over Africa from CMIP6. *Earth Systems and Environment*. 4(3):455-475
- Aryal A, Shrestha S, Babel MS (2019) Quantifying the sources of uncertainty in an ensemble of hydrological climate-impact projections. *Theoretical and Applied Climatology*. 135(1/2):193-209
- Avazpour, F., Hadian, M. R., Talebi, A., & Haghighi, A. T. (2025). Impact of climate change on river flow, using a hybrid model of LARS_WG and LSTM: A case study in the Kashkan Basin. *Results in Engineering*, 104956.
- Chen, T. Guestrin, C. XGBoost: A Scalable Tree Boosting System. In KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; Association for Computing Machinery: New York, NY, USA, 2016; pp. 785-794.
- Eyring V, Bony S, Meehl GA, et al. (2016) Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development* 9:1937-58
- Fang, G., Yang, J., Chen, Y. N., & Zammit, C. 2015. Comparing bias correction methods in downscaling meteorological variables for a hydrologic impact study in an arid area in China. *Hydrology and Earth System Sciences*, 19(6), 2547-2559.
- 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 Model ling. *Journal of Hydrology* 377(1-2):80-91
- He, A., Wang, C., Xu, L., Wang, P., Wang, W., Chen, N., & Chen, Z. (2024). An evaluation of statistical and deep learning-based correction of monthly precipitation over the Yangtze River basin in China based on CMIP6 GCMs. *Environment, Development and Sustainability*, 1-21.
- Heshamati, S., Nazari, B., & Nikoo, M. R. (2025). Enhancing accuracy in streamflow prediction under climate change scenarios based on an integrated machine learning-metaheuristic optimization approach. *Journal of Water and Climate Change*, jwc2025499.
- Hirabayashi, Y., Tanoue, M., Sasaki, O., Zhou, X., & Yamazaki, D. (2021). Global exposure to flooding from the new CMIP6 climate model projections. *Scientific reports*, 11(1), 3740.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Houshmand Kouchi D, Esmaili K, Faridhosseini A, Sanaei Nejad SH, Khalili D (2019) Simulation of climate change impacts using fifth assessment report models under RCP scenarios on water resources in the upper basin of Salman Farsi Dam. *Iranian Journal of Irrigation and Drainage* 2(13):243-258 (In Persian)
- Hyndman R J, Koehler A B (2006) another look at measures of forecast accuracy. *International Journal of Forecasting* 22(4):679-688
- Jaiswal, R., Mall, R. K., Singh, N., Lakshmi Kumar, T. V., & Niyogi, D. (2022). Evaluation of bias correction methods for regional climate models: Downscaled rainfall analysis over diverse agroclimatic zones of India. *Earth and Space Science*, 9(2), e2021EA001981.
- Javan, K., & Azizzadeh, M. R. (2024). Evaluation of different bias correction methods and Projection of Future Precipitation Changes Using GFDL-ESM4 model in Lake Urmia basin. *Journal of Geography and Planning*, 28(88), 415-397. (In Persian)
- Jongman, B., Ward, P. J., & Aerts, J. C. (2012). Global exposure to river and coastal flooding: Long term trends and changes. *Global Environmental Change*, 22(4), 823-835.
- Kim J H, Sung J H, Chung E S, Kim S U, Son M, Shiru M S (2021) Comparison of projection in meteorological



- and hydrological droughts in the Cheongmicheon Watershed for RCP4. 5 and SSP2-4.5. *Sustainability* 13(4):2066
- Lenderink, G., Buishand, A., & Van Deursen, W. (2007). Estimates of future discharges of the river Rhine using two scenario methodologies: direct versus delta approach. *Hydrology and Earth System Sciences*, 11(3), 1145-1159.
- Li, H., Zhang, Y., Lei, H., & Hao, X. (2023). Machine learning-based bias correction of precipitation measurements at high altitude. *Remote Sensing*, 15(8), 2180.
- Maraun D, Wetterhall F, Ireson AM, Chandler RE, Kendon EJ, Widmann M, Brienen S, Rust HW, Sauter T, Themeßl M, et al. (2010) Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Reviews of Geophysics* 48(3):3003
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual Model s part I—A discussion of principles. *Journal of hydrology*, 10(3), 282-290
- Nurdiati, S., Sopaheluwakan, A., Pratama, Y. A., & Najib, M. K. (2021). Statistical bias correction on the climate model for el nino index prediction. *Al-Jabar: Jurnal Pendidikan Matematika*, 12(2), 273-282.
- O'Neill BC, Tebaldi C, van Vuuren DP, et al. (2016) the scenario model intercomparison project (ScenarioMIP) for CMIP6. *Geoscientific Model Development* 9:3461-82
- Panofsky, H. A., & Brier, G. W. (1958). Some applications of statistics to meteorology. Mineral Industries Extension Services, College of Mineral Industries, Pennsylvania State University.
- Pearson K (1897) Mathematical contributions to the theory of evolution. On a form of spurious correlation which may arise when indices are used in the measurement of organs. *Proceedings of the Royal Society of London* 60(359-367):489-498
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.
- Sachindra DA, Ahmed K, Rashid M, Shahid S, Perera BJC (2018) Statistical downscaling of precipitation using machine learning techniques. *Atmospheric Research* 212:240-258
- 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.
- Shiru, M. S., & Park, I. (2020). Comparison of ensembles projections of rainfall from four bias correction methods over Nigeria. *Water*, 12(11), 3044.
- 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.
- Taylor KE, Stouffer RJ, Meehl GA (2012) An overview of CMIP5 and the experiment design. *Bulletin of the American Meteorological Society* 93(4):485-498
- Thrasher, B., Wang, W., Michaelis, A., Melton, F., Lee, T., & Nemani, R. (2022). NASA global daily downscaled projections, CMIP6. *Scientific data*, 9(1), 262.
- UNISDR. (2009). UNISDR Terminology on disaster risk reduction, United Nations International Strategy for Disaster Reduction (UNISDR), Geneva, Switzerland, 35 pp
- Wang J, Hu L, Li D, Ren M (2020) Potential impacts of projected climate change under CMIP5 RCP scenarios on streamflow in the Wabash River Basin. *Advances in Meteorology* 2020:9698423
- Wilby R, Wigley T (1997) Downscaling general circulation model output: A review of methods and limitations. *Progress in Physical Geography: Earth and Environment* 21(4):530-548
- Wood, A. W., Maurer, E. P., Kumar, A., & Lettenmaier, D. P. (2002). Long-range experimental hydrologic forecasting for the eastern United States. *Journal of Geophysical Research: Atmospheres*, 107(D20), ACL-6.
- Zhang, L., Xue, B., Yan, Y., Wang, G., Sun, W., Li, Z., Shi, H. (2019). Model uncertainty analysis methods for semi-arid watersheds with different characteristics: a comparative SWAT case study. *Water*, 11(6), 1177.