

## Research Paper

# Performance Evaluation of Artificial Neural Network for Downscaling Temperature and Precipitation Using CMIP6 Climate Model Outputs (Case Study: Dorudzan Watershed)

Mohammad Sadegh Kamali<sup>1</sup>,Abolghasem Sayadi<sup>2\*</sup>,Hossein Khorshidi<sup>3</sup><sup>1</sup> PhD student in Civil Engineering, Department of Civil Engineering, Marv.C., Islamic Azad University, Marvdasht, Iran<sup>2</sup> Assistant Professor, Department of Civil Engineering, Marv.C., Islamic Azad University, Marvdasht, Iran<sup>3</sup> Assistant Professor, Department of Civil Engineering, Marv.C., Islamic Azad University, Marvdasht, Iran

10.22125/iwe.2026.592583.1938

Received:

June 18, 2026

Accepted:

August 9, 2026

Available online:

September 7, 2026

Keywords:

Statistical Downscaling,  
Climate Change, Artificial  
Neural Network (ANN),  
Temperature, Precipitation.

## Abstract

Due to the coarse spatial resolution of General Circulation Model (GCM) outputs, their direct application in water resources studies and climate change impact assessments is limited. Therefore, downscaling these outputs is important. This study aimed to evaluate the performance of an Artificial Neural Network (ANN) for downscaling temperature and precipitation outputs from CMIP6 climate models in the Dorudzan Watershed, Fars Province, Iran. Observed temperature and precipitation data, NCEP/NCAR reanalysis data, and outputs from eight CMIP6 climate models were used. The performance of climate models was evaluated using the coefficient of determination ( $R^2$ ), root mean square error (RMSE), and mean absolute error (MAE), and the HadGEM3-GC31-LL model was selected as the most appropriate model for the study area. Subsequently, downscaling was performed using selected large-scale atmospheric variables and an ANN model developed in MATLAB. The results showed that the ANN model provided high accuracy in simulating monthly temperature, with an  $R^2$  value of 0.99 in both training and testing stages. The RMSE values were 0.0191 and 0.0194°C for training and testing stages, respectively. For precipitation,  $R^2$  values of 0.84 and 0.83 were obtained for the training and testing stages, respectively. Climate projections for 2025–2050 indicated an increasing trend in temperature and a decreasing trend in annual precipitation under all emission scenarios, with the greatest changes observed under the SSP5-8.5 scenario. Overall, the results demonstrated that ANN is an effective approach for downscaling CMIP6 climate model outputs and assessing future climate changes at the watershed scale.

## 1. Introduction

Climate change has become one of the most significant environmental challenges affecting water resources worldwide. Reliable assessment of future climate conditions requires the use of General Circulation Models (GCMs). However, the coarse spatial resolution of GCM outputs limits their direct application at watershed and local scales. Therefore, downscaling techniques are required to convert large-scale climate information into local climate variables suitable for hydrological and water resources studies. Artificial Neural Networks (ANNs) have attracted considerable attention as an efficient statistical downscaling technique because of

\* **Corresponding Author:** Abolghasem Sayadi

**Address:** Assistant Professor, Department of Civil Engineering, Marv.C., Islamic Azad University, Marvdasht, Iran

**Email:** A.sayadi@iau.ac.ir

**Tel:** 09177283380

their ability to model complex nonlinear relationships between large-scale atmospheric variables and local climatic observations. Meanwhile, the Coupled Model Intercomparison Project Phase 6 (CMIP6) provides the latest generation of climate projections with improved representations of climate system processes. Evaluating the applicability of CMIP6 models and developing reliable downscaling approaches are essential for improving climate change impact assessments. The Dorudzan watershed, located in Fars Province, Iran, is one of the important water resources systems in southern Iran. Agriculture, reservoir operation, and groundwater resources in this basin are highly dependent on climatic conditions. Therefore, accurate projection of future temperature and precipitation is essential for sustainable water resources management. This study aimed to evaluate the performance of an Artificial Neural Network for downscaling CMIP6 climate model outputs and predicting future climatic conditions in the Dorudzan watershed.

## 2. Materials and Methods

Monthly observed precipitation and temperature data were collected from the Dorudzan synoptic station. Large-scale atmospheric predictors were obtained from the NCEP/NCAR reanalysis dataset, while future climate data were extracted from eight CMIP6 General Circulation Models, including ACCESS-CM2, BCC-CSM2-MR, CanESM5, CESM2, GFDL-ESM4, HadGEM3-GC31-LL, INM-CM4-8, and MRI-ESM2-0. The performance of the climate models during the historical period (1994–2014) was evaluated using the coefficient of determination ( $R^2$ ), root mean square error (RMSE), and mean absolute error (MAE). Based on these statistical criteria, the HadGEM3-GC31-LL model demonstrated the best agreement with observed climatic data and was selected for future climate projection. Sensitivity analysis was then performed using 26 large-scale atmospheric variables obtained from the NCEP/NCAR reanalysis dataset to identify the most influential predictors for precipitation and temperature downscaling. Selected predictors were used as inputs to a multilayer feed-forward Artificial Neural Network developed in MATLAB. The network was trained using the Levenberg–Marquardt learning algorithm with the tansig transfer function. Separate ANN models were developed for temperature and precipitation. The calibrated models were subsequently applied to downscale future climate projections under SSP1-2.6, SSP2-4.5, and SSP5-8.5 scenarios for the period 2025–2050.

## 3. Results

The results demonstrate that Artificial Neural Networks provide an effective statistical downscaling framework for converting large-scale atmospheric information into reliable local climate variables. The higher accuracy achieved for temperature compared with precipitation is consistent with the greater complexity and uncertainty associated with precipitation processes. Selection of appropriate large-scale predictors through sensitivity analysis significantly improved ANN performance and reduced model complexity. Moreover, evaluating the performance of CMIP6 models before downscaling proved essential for improving the reliability of future climate projections. The projected increase in temperature together with decreasing precipitation indicates an intensification of climatic stress in the Dorudzan watershed. Such changes may reduce surface water availability, increase evapotranspiration, decrease groundwater recharge, and intensify water scarcity in the region. Therefore, the proposed ANN-based downscaling framework can serve as a reliable decision-support tool for climate change adaptation and sustainable water resources management in semi-arid watersheds.

## 4. Discussion and Conclusion

The evaluation of CMIP6 climate models indicated that HadGEM3-GC31-LL provided the highest simulation accuracy among the eight models considered, with an  $R^2$  of 0.83 for precipitation and 0.99 for temperature during the historical period. The ANN exhibited excellent performance in reproducing monthly temperature, achieving an  $R^2$  of 0.99 in both training and testing stages, with RMSE values of 0.0191 and 0.0194 °C, respectively. For precipitation, the ANN also produced satisfactory results, with  $R^2$  values of 0.84 and 0.83 during training and testing, respectively. Future climate projections indicated a consistent warming trend under all emission scenarios. The mean annual temperature is projected to increase by approximately 0.9–1.0 °C during 2025–2050 relative to the baseline period, while annual precipitation is expected to decrease by approximately 12.9, 28.3, and 48.4 mm under SSP1-2.6, SSP2-4.5, and SSP5-8.5, respectively. The largest climatic changes were projected under the SSP5-8.5 scenario.

## 5. Six important references

- 1) Dibike, B., and P. Coulibaly. 2006. Temporal neural networks for downscaling climate variability and extremes. *Neural Networks*, 19 (2):135-144. <https://doi.org/10.1016/j.neunet.2006.01.003>

- 2) Eyring, V., S. Bony, G.A. Meehl, C.A. Senior, B. Stevens, R.J. Stouffer, and K.E. Taylor. 2016. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development*, 9: 1937-1958, <https://doi.org/10.5194/gmd-9-1937-2016>
- 3) IPCC. (2021). *Climate Change 2021: The Physical Science Basis*. Cambridge University Press
- 4) Samadi, S., A.M. Catherine, E. Wilson, and H. Moradkhani. 2013. Uncertainty analysis of statistical downscaling models using Hadley Centre Coupled Model. *Theoretical and Applied Climatology*, 114:673-690. <https://doi.org/10.1007/s00704-013-0844-x>
- 5) Hosseini Baghanam, A., V. Nourani, M. Bejani, and Ke, C.Q. 2024. Improving the statistical downscaling performance of climatic parameters with convolutional neural networks. *Journal of Water and Climate Change*, 15 (4): 1772-1796. <https://doi.org/10.2166/wcc.2024.592>
- 6) Nourani, V., K. Khodkar, A. Hosseini Baghanam, S.A. Kantoush, and I. Demir. 2023. Uncertainty Quantification of Deep Learning–Based Statistical Downscaling of Climatic Parameters. *Journal of Applied Meteorology and Climatology*, 62(9): 1223-1242. <https://doi.org/10.1175/JAMC-D-23-0057.1>

## Acknowledgments

The authors gratefully acknowledge the Fars Regional Water Authority for providing the meteorological data used in this study. Their support is sincerely appreciated.

## ارزیابی کارایی شبکه عصبی مصنوعی در ریزمقیاس‌نمایی دما و بارش با استفاده از خروجی مدل‌های اقلیمی CMIP6 (مطالعه موردی: حوضه آبریز درودزن)

محمدصادق کمالی<sup>۱</sup>، ابوالقاسم صیادی<sup>۲\*</sup>، حسین خورشیدی<sup>۳</sup>

تاریخ ارسال: ۱۴۰۵/۰۳/۲۸

تاریخ پذیرش: ۱۴۰۵/۰۵/۱۸

مقاله پژوهشی

چکیده

به دلیل تفکیک مکانی درشت خروجی مدل‌های گردش عمومی جو (GCMs)، استفاده مستقیم از آن‌ها در مطالعات منابع آب و ارزیابی اثرات تغییر اقلیم امکان‌پذیر نیست؛ از این رو، ریزمقیاس‌نمایی این داده‌ها از اهمیت ویژه‌ای برخوردار است. هدف این پژوهش، ارزیابی کارایی شبکه عصبی مصنوعی (ANN) در ریزمقیاس‌نمایی دما و بارش خروجی مدل‌های اقلیمی CMIP6 در حوضه آبریز درودزن استان فارس است. بدین منظور، داده‌های مشاهداتی دما و بارش، بازتحلیل NCEP/NCAR و خروجی هشت مدل اقلیمی CMIP6 تهیه شد. عملکرد مدل‌های اقلیمی با استفاده از شاخص‌های ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) ارزیابی و مدل HadGEM3-GC31-LL به عنوان مناسب‌ترین مدل انتخاب شد. سپس، با استفاده از متغیرهای بزرگ‌مقیاس منتخب و توسعه مدل ANN در محیط MATLAB، ریزمقیاس‌نمایی انجام گرفت. نتایج نشان داد که مدل ANN در شبیه‌سازی دمای ماهانه عملکرد بسیار مطلوبی دارد، به طوری که ضریب تعیین در مراحل آموزش و آزمون ۰/۹۹ و مقادیر RMSE به ترتیب ۰/۸۴ و ۰/۸۳ حاصل شد. نتایج پیش‌بینی اقلیم برای دوره ۲۰۲۵ تا ۲۰۵۰ نیز ضریب تعیین در مراحل آموزش و آزمون به ترتیب ۰/۸۴ و ۰/۸۳ حاصل شد. نتایج پیش‌بینی اقلیم برای دوره ۲۰۲۵ تا ۲۰۵۰ نیز نشان داد که در تمامی سناریوهای انتشار، بارش سالانه حوضه روندی کاهشی و دمای هوا روندی افزایشی خواهد داشت و بیشترین شدت این تغییرات در سناریوی SSP5-8.5 مشاهده شد. به طور کلی، نتایج این پژوهش نشان داد که شبکه عصبی مصنوعی ابزاری کارآمد و قابل اعتماد برای ریزمقیاس‌نمایی خروجی مدل‌های اقلیمی CMIP6 و پیش‌بینی تغییرات اقلیمی در مقیاس حوضه آبریز است.

واژه‌های کلیدی: ریزمقیاس‌نمایی، تغییر اقلیم، شبکه عصبی مصنوعی، دما، بارش.

<sup>۱</sup>-دانشجوی دکتری مهندسی عمران، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه آزاد اسلامی، واحد مرودشت، مرودشت، ایران. ایمیل: Mohamadsadegh.kamali@iau.ac.ir

<sup>۲\*</sup>-استادیار گروه مهندسی عمران، دانشکده مهندسی، دانشگاه آزاد اسلامی، واحد مرودشت، مرودشت، ایران. (نویسنده مسئول). ایمیل: A.sayadi@iau.ac.ir

<sup>۳</sup>-استادیار گروه مهندسی عمران، دانشکده مهندسی، دانشگاه آزاد اسلامی، واحد مرودشت، مرودشت، ایران. ایمیل: hossein\_khorshidi@iau.ac.ir



## مقدمه

تغییر اقلیم یکی از مهم‌ترین چالش‌های زیست‌محیطی قرن حاضر است که آثار آن در ابعاد مختلف منابع طبیعی، به‌ویژه منابع آب، بیش از گذشته آشکار شده است. افزایش غلظت گازهای گلخانه‌ای در جو سبب تغییر در تعادل انرژی زمین، افزایش دمای هوا، تغییر الگوی زمانی و مکانی بارش و تشدید فراوانی رخدادهای حدی شده است. این تغییرات، فرآیندهای هیدرولوژیکی را تحت تأثیر قرار داده و موجب تغییر در مؤلفه‌هایی نظیر تبخیر و تعرق، رواناب، تغذیه آب‌های زیرزمینی و نیاز آبی بخش‌های مختلف مصرف‌کننده آب شده است. در نتیجه، برنامه‌ریزی و مدیریت منابع آب بدون در نظر گرفتن آثار تغییر اقلیم، با عدم قطعیت قابل توجهی همراه خواهد بود (هیئت بین‌الدولی تغییر اقلیم، ۲۰۲۱؛ ترنبرث و همکاران، ۲۰۰۳؛ وروسمارتی و همکاران، ۲۰۰۰).

برای بررسی شرایط اقلیمی آینده، مدل‌های گردش عمومی جو (General circulation models, GCMs) به‌عنوان اصلی‌ترین ابزار شبیه‌سازی سامانه اقلیم مورد استفاده قرار می‌گیرند. این مدل‌ها با شبیه‌سازی برهم‌کنش میان جو، اقیانوس، سطح خشکی و یخ‌کره، امکان پیش‌بینی متغیرهای اقلیمی را تحت سناریوهای مختلف انتشار فراهم می‌کنند. در سال‌های اخیر، پروژه مقایسه مدل‌های جفت‌شده در فاز ششم (Coupled model intercomparison project phase 6, CMIP6) معرفی نسل جدید مدل‌های اقلیمی و سناریوهای مسیرهای مشترک اجتماعی-اقتصادی (Shared socioeconomic pathway, SSPs)، زمینه انجام مطالعات دقیق‌تر در زمینه تغییر اقلیم را فراهم کرده است. در این نسل از مدل‌ها، بسیاری از کاستی‌های موجود در CMIP5 برطرف شده و توانایی مدل‌ها در شبیه‌سازی متغیرهای اقلیمی و بازنمایی فرآیندهای فیزیکی سامانه اقلیم بهبود یافته است (وو و همکاران، ۲۰۱۹؛ هیئت بین‌الدولی تغییر اقلیم، ۲۰۲۱).

با وجود پیشرفت‌های حاصل‌شده در توسعه مدل‌های اقلیمی، خروجی آن‌ها معمولاً دارای قدرت تفکیک مکانی در حد ده‌ها تا صدها کیلومتر است. این موضوع باعث می‌شود داده‌های تولیدشده برای بسیاری از مطالعات محلی،

از جمله مطالعات هیدرولوژیکی، منابع آب و برنامه‌ریزی حوضه‌های آبریز، قابلیت استفاده مستقیم نداشته باشند. در چنین شرایطی، استفاده از روش‌های ریزمقیاس‌نمایی به منظور تبدیل اطلاعات بزرگ‌مقیاس مدل‌های اقلیمی به داده‌های محلی ضروری است، زیرا کیفیت داده‌های ورودی نقش تعیین‌کننده‌ای در دقت نتایج مطالعات اثرات تغییر اقلیم دارد (دیبیک و کولیبالی، ۲۰۰۶؛ سامدی و همکاران، ۲۰۱۳).

به‌طور کلی، روش‌های ریزمقیاس‌نمایی به دو گروه دینامیکی و آماری تقسیم می‌شوند. روش‌های دینامیکی استفاده از مدل‌های اقلیم منطقه‌ای، فرآیندهای فیزیکی جو را با تفکیک مکانی بالاتر شبیه‌سازی می‌کنند، اما به دلیل نیاز به توان پردازشی بالا، زمان اجرای طولانی و حجم زیاد داده‌های مورد نیاز، کاربرد آن‌ها در بسیاری از مطالعات محدود است. در مقابل، روش‌های آماری با برقراری ارتباط میان متغیرهای بزرگ‌مقیاس جوی و داده‌های مشاهده‌ای محلی، امکان تولید داده‌های اقلیمی با هزینه محاسباتی کمتر را فراهم می‌کنند. به همین دلیل، این روش‌ها در سال‌های اخیر به‌طور گسترده در مطالعات تغییر اقلیم و منابع آب مورد استفاده قرار گرفته‌اند (دیبیک و کولیبالی، ۲۰۰۶؛ سامدی و همکاران، ۲۰۱۳).

در میان روش‌های آماری، شبکه‌های عصبی مصنوعی (Artificial Neural Networks, ANNs) به دلیل قابلیت یادگیری روابط پیچیده و غیرخطی میان متغیرهای ورودی و خروجی، توجه بسیاری از پژوهشگران را به خود جلب کرده‌اند. این مدل‌ها بدون نیاز به تعریف روابط ریاضی صریح، قادرند الگوهای موجود در داده‌ها را استخراج کرده و ارتباط میان متغیرهای بزرگ‌مقیاس جوی و متغیرهای اقلیمی محلی را با دقت مناسبی شبیه‌سازی کنند. دیبیک و کولیبالی (۲۰۰۶) نشان دادند که شبکه‌های عصبی مصنوعی در ریزمقیاس‌نمایی تغییرپذیری اقلیم و رخدادهای حدی عملکرد مناسبی دارند. در سال‌های اخیر، استفاده از روش‌های مبتنی بر هوش مصنوعی و یادگیری عمیق برای ریزمقیاس‌نمایی خروجی مدل‌های CMIP6 نیز مورد توجه پژوهشگران قرار گرفته است. نورانی و همکاران (۲۰۲۳) با استفاده از شبکه‌های عصبی پیش‌خور و حافظه بلندکوتاه مدت (Long Short-Term Memory, LSTM)

شبکه عصبی مصنوعی در ریزمقیاس‌نمایی دما و بارش حاصل از مدل‌های CMIP6 در حوضه آبریز درودزن است. در حالی که بیشتر مطالعات پیشین بر بررسی اثرات تغییر اقلیم یا به‌کارگیری یک مدل اقلیمی متمرکز بوده‌اند، در پژوهش حاضر ابتدا عملکرد هشت مدل CMIP6 به صورت نظام‌مند ارزیابی و مناسب‌ترین مدل برای منطقه انتخاب شد. همچنین، برخلاف بسیاری از مطالعات که متغیرهای پیش‌بین را بدون ارزیابی جامع انتخاب کرده‌اند، در این پژوهش انتخاب متغیرها بر پایه تحلیل حساسیت انجام شد. افزون بر این، کارایی شبکه عصبی مصنوعی در ریزمقیاس‌نمایی هم‌زمان دما و بارش و پیش‌بینی تغییرات آن‌ها تحت سناریوهای مختلف SSP برای حوضه آبریز درودزن ارزیابی شد.

در این پژوهش، پس از ارزیابی عملکرد مدل‌های اقلیمی، مناسب‌ترین مدل برای منطقه مورد مطالعه انتخاب شد و سپس با استفاده از متغیرهای پیش‌بین منتخب، دقت شبکه عصبی مصنوعی در بازتولید متغیرهای اقلیمی در مقیاس محلی با بهره‌گیری از شاخص‌های آماری متداول ارزیابی شد. در ادامه، تغییرات آینده دما و بارش تحت سناریوهای مختلف انتشار SSP برای حوضه آبریز درودزن پیش‌بینی شد. این رویکرد، ضمن ارائه فرآیندی نظام‌مند برای انتخاب مدل اقلیمی و توسعه مدل ریزمقیاس‌نمایی، اطلاعات قابل اتکایی را برای مطالعات منابع آب و برنامه‌ریزی سازگاری با تغییر اقلیم در منطقه فراهم می‌کند.

## مواد و روش‌ها

### منطقه مورد مطالعه

حوضه آبریز درودزن در بخش مرکزی استان فارس واقع شده و یکی از حوضه‌های مهم تأمین‌کننده منابع آب این استان به شمار می‌رود. این حوضه با توجه به نقش مؤثر در تأمین آب مورد نیاز بخش‌های کشاورزی، شرب و صنعت، از اهمیت ویژه‌ای در برنامه‌ریزی و مدیریت منابع آب برخوردار است. وجود سد درودزن به‌عنوان یکی از مهم‌ترین سازه‌های ذخیره و تنظیم آب در استان فارس، اهمیت بررسی تغییرات اقلیمی و آثار آن بر این حوضه را دوچندان کرده است.

(LSTM)، خروجی مدل اقلیمی CanESM5 از مجموعه CMIP6 را برای ریزمقیاس‌نمایی دما و بارش در دو منطقه اقلیمی متفاوت ایران به کار گرفتند و نشان دادند که این روش‌ها توانایی مناسبی در بازسازی متغیرهای اقلیمی محلی دارند، هرچند عدم قطعیت ناشی از ساختار مدل و داده‌های ورودی باید در تفسیر نتایج مورد توجه قرار گیرد. همچنین، خیر و همکاران (۲۰۲۳) با توسعه یک روش مبتنی بر شبکه عصبی کانولوشنی (Convolutional Neural Network, CNN)، خروجی مدل‌های CMIP6 را برای ریزمقیاس‌نمایی دمای حداقل و حداکثر در یک منطقه خشک به کار گرفتند و نشان دادند که این روش می‌تواند خطای مدل‌های اقلیمی را کاهش داده و بازنمایی شرایط اقلیمی محلی را بهبود بخشد. افزون بر این، حسینی‌بقنام و همکاران (۲۰۲۴) نیز با استفاده از CNN، بهبود قابل‌توجهی در دقت ریزمقیاس‌نمایی پارامترهای اقلیمی گزارش کردند که بیانگر ظرفیت بالای روش‌های مبتنی بر هوش مصنوعی در این حوزه است.

در ایران نیز مطالعات متعددی به بررسی اثرات تغییر اقلیم بر منابع آب سطحی و زیرزمینی پرداخته‌اند. صیادی و همکاران (۱۳۹۸) تغییرات دما، بارش و رواناب حوضه آبریز درودزن را تحت سناریوهای مختلف تغییر اقلیم بررسی کردند و نشان دادند که تغییر الگوی متغیرهای اقلیمی می‌تواند بر وضعیت منابع آب این حوضه اثرگذار باشد. افزون بر این، پژوهش‌هایی نظیر کدخدا و همکاران (۱۳۹۸)، جعفری‌گنده و همکاران (۱۴۰۰)، نجفی و همکاران (۱۴۰۱) و تقوایی و همکاران (۱۴۰۳) بیشتر بر ارزیابی پیامدهای تغییر اقلیم بر منابع آب زیرزمینی متمرکز بوده‌اند. با وجود ارزشمند بودن این مطالعات، تمرکز اصلی آن‌ها بر تحلیل اثرات تغییر اقلیم بوده و ارزیابی مستقیم کارایی شبکه‌های عصبی مصنوعی در ریزمقیاس‌نمایی خروجی مدل‌های CMIP6، به‌ویژه برای حوضه آبریز درودزن، کمتر مورد توجه قرار گرفته است.


با توجه به اهمیت تولید داده‌های اقلیمی دقیق برای مطالعات منابع آب و نقش تعیین‌کننده ریزمقیاس‌نمایی در کاهش خطای خروجی مدل‌های اقلیمی، ارزیابی توانایی روش‌های مبتنی بر هوش مصنوعی در این زمینه ضروری به نظر می‌رسد. از این‌رو، هدف پژوهش حاضر ارزیابی کارایی



شامل دما و بارش از ایستگاه‌های هواشناسی واقع در محدوده حوضه تهیه شد. همچنین، داده‌های باز تحلیل NCEP/NCAR به‌عنوان داده‌های ورودی مدل شبکه عصبی مصنوعی و خروجی مدل‌های گردش عمومی جو (CMIP6) به‌عنوان داده‌های اقلیم آینده برای ریزمقیاس‌نمایی مورد استفاده قرار گرفتند. موقعیت جغرافیایی حوضه و پراکنش ایستگاه‌های مورد استفاده در شکل (۱) ارائه شده است.

موقعیت جغرافیایی و مشخصات ایستگاه‌های هواشناسی مورد استفاده در این پژوهش، که در داخل و پیرامون حوضه آبریز درودزن قرار دارند، در جدول (۱) ارائه شده است

از نظر اقلیمی، حوضه درودزن در منطقه‌ای با اقلیم نیمه‌خشک قرار دارد و بارش آن عمدتاً در ماه‌های سرد سال رخ می‌دهد، در حالی که تابستان‌ها با دمای بالا و بارندگی ناچیز همراه است. تغییرپذیری زمانی و مکانی بارش، وقوع دوره‌های خشکسالی و افزایش دما در سال‌های اخیر، این حوضه را در برابر پیامدهای تغییر اقلیم آسیب‌پذیر کرده است. از این‌رو، بررسی تغییرات آینده دما و بارش و تولید داده‌های اقلیمی با دقت مناسب، نقش مهمی در مطالعات منابع آب و برنامه‌ریزی بلندمدت این حوضه دارد. در این پژوهش، محدوده حوضه آبریز درودزن به‌عنوان منطقه مورد مطالعه انتخاب شد. داده‌های اقلیمی مورد نیاز



شکل (۱): موقعیت منطقه مورد مطالعه و ایستگاه‌های استفاده شده در حوضه آبریز و کشور ایران.

جدول (۱): مشخصات ایستگاه‌های مورد استفاده

| ردیف | نام ایستگاه        | نوع ایستگاه       | کد ایستگاه | طول (متر) | عرض (متر) | ارتفاع از سطح دریا (متر) |
|------|--------------------|-------------------|------------|-----------|-----------|--------------------------|
| ۱    | احمدآباد چهاردانگه | هواشناسی          | ۴۳-۰۶۸     | ۶۶۲۴۳۶    | ۳۳۶۳۱۱۷   | ۲۲۳۳                     |
| ۲    | امامزاده اسماعیل   | هواشناسی          | ۴۳-۱۲۴     | ۶۵۲۵۷۳    | ۳۳۵۵۲۳۹   | ۱۸۳۳                     |
| ۳    | بیدکل              | هواشناسی          | ۴۳-۰۲۵     | ۶۵۶۴۹۹    | ۳۳۳۸۴۴۶   | ۱۶۱۳                     |
| ۴    | دزکرد رئیسون       | هواشناسی          | ۴۳-۰۵۴     | ۵۹۲۰۵۸    | ۳۳۹۹۰۷۷   | ۲۱۰۷                     |
| ۵    | چوبخله             | هواشناسی          | ۴۳-۰۶۱     | ۵۸۵۷۶۲    | ۳۳۷۹۴۵۶   | ۲۰۵۳                     |
| ۶    | دشمن زیاری         | هواشناسی          | ۴۳-۰۶۰     | ۶۴۵۳۰۶    | ۳۳۳۵۸۸۷   | ۱۶۱۵                     |
| ۷    | دشتبال             | هواشناسی          | ۴۳-۰۳۵     | ۶۹۰۷۳۱    | ۳۳۲۱۰۹۰   | ۱۶۷۳                     |
| ۸    | دشتک               | هواشناسی          | ۴۳-۱۳۴     | ۶۴۱۱۱۴    | ۳۳۵۲۰۷۷   | ۲۰۴۶                     |
| ۹    | ده بید             | هواشناسی          | ۴۳-۰۹۵     | ۷۱۰۳۶۵    | ۳۳۸۸۸۴۰   | ۲۳۱۲                     |
| ۱۰   | سده                | هواشناسی          | ۴۳-۲۰۱     | ۶۱۱۴۷۰    | ۳۳۹۹۱۴۱   | ۲۱۹۲                     |
| ۱۱   | عباس‌آباد          | هواشناسی          | ۴۳-۰۸۲     | ۶۲۰۶۴۹    | ۳۳۵۴۴۶۵   | ۱۶۹۰                     |
| ۱۲   | کافت‌ر             | هواشناسی          | ۴۳-۰۲۹     | ۶۶۶۰۴۹    | ۳۳۷۹۰۵۴   | ۲۳۵۰                     |
| ۱۳   | مادر سلیمان        | هواشناسی          | ۴۳-۱۰۵     | ۷۰۹۷۶۹    | ۳۳۴۱۸۵۶   | ۱۸۶۱                     |
| ۱۴   | کمهر               | هواشناسی          | ۴۳-۲۰۲     | ۵۸۴۱۰۳    | ۳۳۶۸۸۰۵   | ۲۳۷۷                     |
| ۱۵   | مهرآباد رامجرد     | هواشناسی          | ۴۳-۰۰۸     | ۶۶۴۰۶۸    | ۳۳۱۶۹۰۳   | ۱۶۱۶                     |
| ۱۶   | جمال‌بیگ-شورخاست   | آبسنجی            | ۴۳-۰۱۱     | ۵۹۳۰۲۸    | ۳۳۸۵۱۵۸   | ۱۹۰۸                     |
| ۱۷   | جمال‌بیگ-شیرین     | آبسنجی            | ۴۳-۰۱۳     | ۵۹۳۰۲۸    | ۳۳۸۵۱۵۸   | ۱۹۱۵                     |
| ۱۸   | دهکده سفید-سفید    | آبسنجی            | ۴۳-۰۰۴     | ۶۰۶۵۰۲    | ۳۳۹۲۷۶۰   | ۲۰۸۰                     |
| ۱۹   | دهکده سفید-گاودار  | آبسنجی و هواشناسی | ۴۳-۰۰۱     | ۵۹۸۰۸۹    | ۳۱۶۷۵۷۸   | ۲۱۸۱                     |
| ۲۰   | خسروشیرین          | آبسنجی و هواشناسی | ۴۳-۰۵۵     | ۵۹۶۶۹۹    | ۳۴۱۹۱۴۶   | ۲۳۴۰                     |
| ۲۱   | چمبریز             | آبسنجی و هواشناسی | ۴۳-۰۱۵     | ۶۰۵۷۰۳    | ۳۳۷۰۹۰۲   | ۱۸۴۰                     |

#### داده‌های مورد استفاده

در این پژوهش، به منظور ریزمقیاس‌نمایی متغیرهای اقلیمی، از داده‌های مشاهداتی، داده‌های بازتحلیل و خروجی مدل‌های گردش عمومی جو استفاده شد. داده‌های مشاهداتی شامل دما و بارش ماهانه ایستگاه‌های هواشناسی منتخب در محدوده حوضه آبریز درودزن بود که از سازمان هواشناسی کشور تهیه شد. این داده‌ها پس از بررسی، کنترل کیفی و رفع نواقص احتمالی، به عنوان داده‌های مبنا در آموزش و ارزیابی مدل شبکه عصبی مصنوعی مورد استفاده قرار گرفتند.

به منظور استخراج متغیرهای بزرگ‌مقیاس جوی، از داده‌های بازتحلیل مرکز ملی پیش‌بینی محیطی و مرکز ملی

#### پژوهش‌های جوی ایالات متحده (NCEP/NCAR) استفاده

شد. این داده‌ها به دلیل پوشش زمانی مناسب و کاربرد گسترده در مطالعات ریزمقیاس‌نمایی، به عنوان متغیرهای ورودی در توسعه مدل شبکه عصبی مصنوعی به کار گرفته شدند.

همچنین، برای ارزیابی شرایط اقلیمی آینده، خروجی هشت مدل CMIP6 تحت سناریوهای SSPs مورد استفاده قرار گرفت. پس از ارزیابی عملکرد مدل‌های اقلیمی بر اساس شاخص‌های آماری، مناسب‌ترین مدل برای ادامه فرآیند ریزمقیاس‌نمایی انتخاب شد. مشخصات مدل‌های اقلیمی مورد استفاده در این پژوهش در جدول (۲) ارائه شده است.





جدول (۲): مشخصات مدل‌های اقلیمی CMIP6 مورد استفاده در پژوهش

| ردیف | مدل اقلیمی (GCM) | مرکز توسعه‌دهنده                                                                                  | کشور         | قدرت تفکیک مکانی (درجه)      | قدرت تفکیک مکانی جو (درجه)           | مرجع                           |
|------|------------------|---------------------------------------------------------------------------------------------------|--------------|------------------------------|--------------------------------------|--------------------------------|
| ۱    | ACCESS-CM2       | CSIRO and Bureau of Meteorology (BoM)                                                             | استرالیا     | $1^{\circ} \times 1^{\circ}$ | $1.25^{\circ} \times 1.875^{\circ}$  | Bi, D., et al. (2020)          |
| ۲    | BCC-CSM2-MR      | Beijing Climate Center (BCC), China Meteorological Administration (CMA)                           | چین          | $1^{\circ} \times 1^{\circ}$ | $1.125^{\circ} \times 1.125^{\circ}$ | Wu, T., et al. (2019)          |
| ۳    | CanESM5          | Canadian Centre for Climate Modelling and Analysis (CCCma), Environment and Climate Change Canada | کانادا       | $1^{\circ} \times 1^{\circ}$ | $2.8^{\circ} \times 2.8^{\circ}$     | Swart, N.C., et al. (2020)     |
| ۴    | CESM2            | National Center for Atmospheric Research (NCAR)                                                   | ایالات متحده | $1^{\circ} \times 1^{\circ}$ | $1^{\circ} \times 1^{\circ}$         | Danabasoglu, G., et al. (2020) |
| ۵    | GFDL-ESM4        | NOAA Geophysical Fluid Dynamics Laboratory (GFDL)                                                 | ایالات متحده | $1^{\circ} \times 1^{\circ}$ | $1^{\circ} \times 1^{\circ}$         | Dunne, J.P., et al. (2020)     |
| ۶    | HadGEM3-GC31-LL  | Met Office Hadley Centre                                                                          | انگلستان     | $1^{\circ} \times 1^{\circ}$ | $1.25^{\circ} \times 1.875^{\circ}$  | Williams, K.D., et al. (2018)  |
| ۷    | INM-CM4-8        | Institute for Numerical Mathematics (INM), Russian Academy of Sciences                            | روسیه        | $2^{\circ} \times 2^{\circ}$ | $2.0^{\circ} \times 1.5^{\circ}$     | Volodin, E. M., et al. (2018)  |
| ۸    | MRI-ESM2-0       | Meteorological Research Institute (MRI), Japan Meteorological Agency (JMA)                        | ژاپن         | $1^{\circ} \times 1^{\circ}$ | $1.125^{\circ} \times 1.125^{\circ}$ | Yukimoto, S., et al. (2019)    |

#### مدل‌های اقلیمی و سناریوهای مورد استفاده

در این پژوهش، به منظور شبیه‌سازی شرایط اقلیمی آینده، از خروجی هشت مدل GCM متعلق به CMIP6 استفاده شد. این مدل‌ها با توجه به کاربرد گسترده در مطالعات تغییر اقلیم، دسترسی به داده‌ها و توانایی مناسب در شبیه‌سازی متغیرهای اقلیمی انتخاب شدند. مشخصات مدل‌های اقلیمی مورد استفاده در جدول (۲) ارائه شده است.

به منظور بررسی تغییرات آینده دما و بارش، از سناریوهای SSPs استفاده شد. این سناریوها با در نظر گرفتن روندهای متفاوت توسعه اجتماعی، اقتصادی و میزان انتشار گازهای گلخانه‌ای، طیف وسیعی از شرایط اقلیمی آینده را شبیه‌سازی می‌کنند. در این پژوهش، خروجی مدل‌های اقلیمی تحت سناریوهای SSP1-2.6، SSP2-4.5 و SSP5-

8.5 مورد بررسی قرار گرفت تا تغییرات متغیرهای اقلیمی در شرایط انتشار پایین، متوسط و بالا ارزیابی شود. در این پژوهش، دوره زمانی ۲۰۲۵ تا ۲۰۵۰ به عنوان دوره آینده نزدیک در نظر گرفته شد. انتخاب این بازه زمانی با هدف بررسی تغییرات احتمالی دما و بارش در یک دوره زمانی کاربردی برای برنامه‌ریزی و مدیریت منابع آب انجام شد. از آنجا که تصمیم‌گیری‌های مرتبط با سازگاری با تغییر اقلیم، مدیریت منابع آب و برنامه‌ریزی بخش کشاورزی نیازمند اطلاعات اقلیمی میان‌مدت است، ارزیابی تغییرات اقلیمی در این دوره می‌تواند اطلاعات قابل استفاده‌ای برای مدیریت حوضه آبریز فراهم کند. همچنین، انتخاب دوره آینده نزدیک می‌تواند بخشی از عدم قطعیت‌های مرتبط با پیش‌بینی‌های بلندمدت اقلیمی را کاهش دهد.

مقادیر شبیه‌سازی شده و  $\overline{Q_{i_{pre}}}$  میانگین داده‌های شبیه‌سازی شده را نشان می‌دهند.

ضریب تعیین ( $R^2$ ) میزان همخوانی بین داده‌های شبیه‌سازی شده و داده‌های مشاهده‌ای را بیان می‌کند؛ به‌طوری‌که مقادیر نزدیک‌تر به یک، بیانگر دقت بیشتر مدل در بازنمایی متغیرهای اقلیمی است. شاخص RMSE میزان پراکندگی خطاهای شبیه‌سازی را نسبت به مقادیر مشاهده‌ای نشان می‌دهد و هرچه مقدار آن کمتر باشد، عملکرد مدل مطلوب‌تر خواهد بود. همچنین، شاخص MAE میانگین قدر مطلق اختلاف بین مقادیر مشاهده‌شده و شبیه‌سازی شده را بیان می‌کند و مقادیر کمتر آن نشان‌دهنده دقت بیشتر مدل در پیش‌بینی متغیرهای اقلیمی است.

#### مدل شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یکی از روش‌های هوشمند مدل‌سازی است که با الهام از عملکرد سیستم عصبی انسان، توانایی یادگیری روابط پیچیده و غیرخطی بین متغیرهای ورودی و خروجی را دارد. این ویژگی موجب شده است که این مدل در سال‌های اخیر به‌طور گسترده در مطالعات هیدرولوژی، هواشناسی و تغییر اقلیم، به‌ویژه در ریزمقیاس‌نمایی داده‌های اقلیمی، مورد استفاده قرار گیرد (سلگی و گلابی، ۱۴۰۴).

در این پژوهش، از شبکه عصبی مصنوعی برای برقراری ارتباط بین متغیرهای بزرگ‌مقیاس جوی و متغیرهای اقلیمی در مقیاس محلی استفاده شد. در این روش، داده‌های بازتحلیل NCEP/NCAR به‌عنوان ورودی‌های شبکه و داده‌های مشاهده‌ای دما و بارش ایستگاه‌های هواشناسی به‌عنوان خروجی‌های هدف در فرآیند آموزش شبکه مورد استفاده قرار گرفتند. پس از آموزش شبکه و ارزیابی عملکرد آن، ساختار بهینه برای ریزمقیاس‌نمایی خروجی مدل اقلیمی منتخب CMIP6 به کار گرفته شد.

یکی از مراحل مهم در توسعه مدل، انتخاب متغیرهای ورودی مناسب است. استفاده هم‌زمان از تمامی متغیرهای جوی علاوه بر افزایش پیچیدگی شبکه، می‌تواند موجب کاهش دقت مدل و افزایش زمان آموزش شود. ازاین‌رو، در

داده‌های خروجی مدل‌های اقلیمی از پایگاه داده فدراسیون شبکه علوم زمین (Earth System Grid Federation: ESGF) دریافت شد. با توجه به اینکه خروجی مدل‌های گردش عمومی جو دارای قدرت تفکیک مکانی نسبتاً درشت هستند، استفاده مستقیم از آن‌ها در مطالعات حوضه‌ای با محدودیت همراه است. ازاین‌رو، پیش از تحلیل تغییرات اقلیمی، خروجی مدل‌های منتخب با استفاده از شبکه عصبی مصنوعی ریزمقیاس‌نمایی شد تا داده‌هایی با مقیاس مناسب برای منطقه مورد مطالعه تولید شود.

#### معیارهای ارزیابی و انتخاب مدل اقلیمی برتر

به‌منظور ارزیابی عملکرد مدل‌های گردش عمومی جو (AOGCMs) و انتخاب مناسب‌ترین مدل برای شبیه‌سازی متغیرهای اقلیمی، لازم است توانایی آن‌ها در بازتولید شرایط اقلیمی دوره پایه مورد بررسی قرار گیرد. اگرچه ارزیابی عملکرد مدل‌ها در دوره پایه، تضمینی برای پیش‌بینی دقیق شرایط اقلیمی آینده نیست، اما مدلی که بتواند متغیرهای اقلیمی را با دقت بیشتری شبیه‌سازی کند، از قابلیت اطمینان بیشتری برای مطالعات آینده‌نگر برخوردار خواهد بود (سلگی و همکاران، ۲۰۲۲؛ رانا و همکاران، ۲۰۲۵).

در این پژوهش، به‌منظور مقایسه عملکرد مدل‌های اقلیمی، از سه شاخص آماری شامل ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده شد که روابط ریاضی آن‌ها به‌ترتیب در روابط (۱) تا (۳) ارائه شده است.

$$R^2 = \frac{(\sum_{i=1}^n (Q_{i_{obs}} - \overline{Q_{i_{obs}}})(Q_{i_{pre}} - \overline{Q_{i_{pre}}}))^2}{\sum_{i=1}^n (Q_{i_{obs}} - \overline{Q_{i_{obs}}})^2 \sum_{i=1}^n (Q_{i_{pre}} - \overline{Q_{i_{pre}}})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{i_{obs}} - Q_{i_{pre}})^2}{N}} \quad (2)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Q_{i_{obs}} - Q_{i_{pre}}| \quad (3)$$

در روابط فوق، (N) تعداد داده‌ها،  $Q_{i_{obs}}$  مقادیر مشاهده‌شده،  $\overline{Q_{i_{obs}}}$  میانگین داده‌های مشاهده‌شده،  $Q_{i_{pre}}$



## توسعه مدل ریزمقیاس نمایی مبتنی بر شبکه عصبی مصنوعی

انتخاب متغیرهای ورودی یکی از مهم‌ترین مراحل در توسعه مدل‌های ریزمقیاس‌نمایی آماری است، زیرا دقت شبیه‌سازی متغیرهای اقلیمی تا حد زیادی به نوع و تعداد متغیرهای ورودی وابسته است. استفاده از متغیرهای نامرتبط یا دارای همبستگی ضعیف با متغیرهای پیش‌بینی‌شونده می‌تواند موجب افزایش پیچیدگی مدل، کاهش دقت پیش‌بینی و بیش‌برازش (Overfitting) شود. از این رو، انتخاب متغیرهای ورودی مناسب نقش تعیین‌کننده‌ای در بهبود عملکرد مدل شبکه عصبی مصنوعی دارد.

در این پژوهش، متغیرهای بزرگ‌مقیاس جوی از داده‌های بازتحلیل NCEP/NCAR استخراج شدند. این مجموعه شامل ۲۶ متغیر جوی است که به‌طور گسترده در مطالعات ریزمقیاس‌نمایی اقلیمی به‌عنوان متغیرهای ورودی مورد استفاده قرار می‌گیرند. فهرست این متغیرها در جدول (۳) ارائه شده است.

به‌منظور توسعه مدل ریزمقیاس‌نمایی، در مرحله نخست تمامی ۲۶ متغیر به‌عنوان ورودی اولیه شبکه عصبی مصنوعی در نظر گرفته شدند. سپس با استفاده از تحلیل حساسیت، میزان تأثیر هر یک از متغیرها بر شبیه‌سازی بارش، دمای حداقل و دمای حداکثر ارزیابی شد و متغیرهای دارای بیشترین تأثیر به‌عنوان ورودی نهایی مدل انتخاب شدند. در ادامه، شبکه عصبی مصنوعی با استفاده از متغیرهای منتخب آموزش داده شد و پس از اعتبارسنجی، برای ریزمقیاس‌نمایی خروجی مدل اقلیمی منتخب و تولید داده‌های اقلیمی در مقیاس محلی به کار گرفته شد.

این پژوهش ابتدا شبکه با مجموعه کامل متغیرهای بزرگ‌مقیاس آموزش داده شد و سپس با استفاده از تحلیل حساسیت، میزان تأثیر هر یک از متغیرهای ورودی بر خروجی شبکه ارزیابی گردید. در این روش، حساسیت هر متغیر بر اساس تغییرات خروجی مدل در پاسخ به تغییرات ورودی محاسبه شده و متغیرهایی که بیشترین تأثیر را بر متغیرهای اقلیمی منطقه داشتند، به‌عنوان ورودی‌های نهایی شبکه انتخاب شدند. این رویکرد پیش‌تر توسط دیبیک و کولیبالی (۲۰۰۶) برای ریزمقیاس‌نمایی داده‌های اقلیمی ارائه شده و در مطالعات بعدی نیز مورد استفاده قرار گرفته است.

معماری شبکه عصبی شامل لایه ورودی، یک یا چند لایه پنهان و لایه خروجی است. تعداد نوروهای لایه پنهان و سایر پارامترهای شبکه تأثیر مستقیمی بر دقت شبیه‌سازی دارند و معمولاً از طریق آزمون و خطا تعیین می‌شوند. در این پژوهش نیز به‌منظور دستیابی به بهترین عملکرد، ترکیب‌های مختلفی از تعداد نوروهای لایه پنهان، توابع انتقال و الگوریتم‌های آموزش مورد ارزیابی قرار گرفت و ساختاری که کمترین خطا و بیشترین دقت را در مرحله اعتبارسنجی نشان داد، به‌عنوان ساختار بهینه انتخاب شد.

پس از تعیین ساختار بهینه، شبکه با استفاده از داده‌های دوره پایه آموزش داده شد و توانایی آن در بازتولید دما و بارش منطقه مورد ارزیابی قرار گرفت. در ادامه، همان شبکه برای ریزمقیاس‌نمایی خروجی مدل اقلیمی منتخب تحت سناریوهای مختلف انتشار به کار گرفته شد و داده‌های دما و بارش در مقیاس محلی برای دوره‌های آینده تولید شد.

جدول (۳): متغیرهای بزرگ مقیاس جوی استخراج شده از داده‌های بازتحلیل NCEP/NCAR

| ردیف | متغیر                                         | ردیف | متغیر                                    |
|------|-----------------------------------------------|------|------------------------------------------|
| ۱    | فشار تراز دریا                                | ۱۴   | سرعت مداری سطحی                          |
| ۲    | سرعت باد سطحی                                 | ۱۵   | حالت گردابی سطح                          |
| ۳    | سرعت نصف النهاری سطح                          | ۱۶   | واگرایی سطح                              |
| ۴    | جهت باد سطحی                                  | ۱۷   | سرعت مداری در تراز فشاری ۵۰۰ هکتوپاسکال  |
| ۵    | سرعت باد در تراز فشاری ۵۰۰ هکتوپاسکال         | ۱۸   | حالت گردابی در تراز فشاری ۵۰۰ هکتوپاسکال |
| ۶    | سرعت نصف النهاری در تراز فشاری ۵۰۰ هکتوپاسکال | ۱۹   | جهت باد در تراز فشاری ۵۰۰ هکتوپاسکال     |
| ۷    | ژئوپتانسیل در تراز فشاری ۵۰۰ هکتوپاسکال       | ۲۰   | واگرایی در تراز فشاری ۵۰۰ هکتوپاسکال     |
| ۸    | سرعت باد در تراز فشاری ۸۵۰ هکتوپاسکال         | ۲۱   | سرعت مداری در تراز فشاری ۸۵۰ هکتوپاسکال  |
| ۹    | سرعت نصف النهاری در تراز فشاری ۸۵۰ هکتوپاسکال | ۲۲   | حالت گردابی در تراز فشاری ۸۵۰ هکتوپاسکال |
| ۱۰   | ژئوپتانسیل در تراز فشاری ۸۵۰ هکتوپاسکال       | ۲۳   | جهت باد در تراز فشاری ۸۵۰ هکتوپاسکال     |
| ۱۱   | واگرایی در تراز فشاری ۸۵۰ هکتوپاسکال          | ۲۴   | رطوبت نسبی در تراز فشاری ۵۰۰ هکتوپاسکال  |
| ۱۲   | رطوبت نسبی در تراز فشاری ۸۵۰ هکتوپاسکال       | ۲۵   | رطوبت نسبی سطحی                          |
| ۱۳   | رطوبت ویژه سطحی                               | ۲۶   | دمای هوا در ارتفاع دو متری               |

## نتایج و بحث


### ارزیابی عملکرد مدل‌های اقلیمی و انتخاب مدل برتر

به منظور انتخاب مناسب‌ترین مدل اقلیمی برای شبیه‌سازی شرایط اقلیمی حوضه درودزن، عملکرد هشت مدل منتخب CMIP6 در بازتولید بارش و دمای دوره پایه (۱۹۹۴-۲۰۱۴) مورد ارزیابی قرار گرفت. بدین منظور، مقادیر شبیه‌سازی شده هر مدل با داده‌های مشاهده‌ای ایستگاه درودزن مقایسه و عملکرد آن‌ها با استفاده از شاخص‌های ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) بررسی شد. مقایسه میانگین ماهانه بارش و دما بین داده‌های مشاهده‌ای و خروجی مدل‌های اقلیمی نشان داد که اگرچه تمامی مدل‌ها روند تغییرات دما را با دقت مناسبی بازتولید کرده‌اند، اما در شبیه‌سازی بارش اختلاف قابل توجهی بین مدل‌ها مشاهده می‌شود (شکل‌های ۲ و ۳). این موضوع بیانگر پیچیدگی بیشتر شبیه‌سازی بارش نسبت به دما در مدل‌های گردش عمومی جو است.


نتایج شاخص‌های ارزیابی عملکرد مدل‌های اقلیمی در جدول (۴) ارائه شده است. بررسی مقادیر شاخص‌ها نشان داد که مدل HadGEM3-GC31-LL در شبیه‌سازی هر دو متغیر بارش و دما عملکرد بهتری نسبت به سایر مدل‌ها

دارد. این مدل برای بارش، بیشترین ضریب تعیین ( $0/83$ ) و کمترین مقادیر RMSE ( $35/51$  میلی‌متر) و MAE ( $22/19$  میلی‌متر) را به خود اختصاص داد. همچنین در شبیه‌سازی دما نیز با ضریب تعیین  $0/99$  و کمترین مقادیر RMSE ( $1/12$  درجه سلسیوس) و MAE ( $0/89$  درجه سلسیوس)، دقیق‌ترین نتایج را ارائه کرد.

بر این اساس، مدل HadGEM3-GC31-LL با کسب بیشترین ضریب تعیین و کمترین مقادیر RMSE و MAE در شبیه‌سازی هر دو متغیر بارش و دما، به عنوان مناسب‌ترین مدل اقلیمی برای منطقه مورد مطالعه انتخاب شد. برتری این مدل از دیدگاه آماری، احتمالاً با ویژگی‌های فیزیکی آن نیز مرتبط است؛ به گونه‌ای که در مطالعات پیشین، بهبود پارامترسازی فرایندهای جوی، از جمله انتقال رطوبت، تشکیل ابر، فرایندهای بارش و برهم‌کنش جو و سطح زمین، از عوامل مؤثر در افزایش دقت این مدل گزارش شده است. همچنین، تفکیک مکانی نسبتاً بالاتر این مدل نسبت به برخی از مدل‌های CMIP6 می‌تواند در بازنمایی مناسب‌تر تغییرپذیری اقلیمی منطقه مؤثر باشد. از این رو، خروجی این مدل به عنوان ورودی شبکه عصبی مصنوعی برای ریزمقیاس‌نمایی و پیش‌بینی متغیرهای اقلیمی دوره آینده مورد استفاده قرار گرفت.



شکل (۲): متوسط بارش ماهانه مشاهده‌ای حوزه مورد مطالعه و مدل‌های AOGCM



شکل (۳): متوسط دمای ماهانه مشاهده‌ای حوزه مورد مطالعه و مدل‌های AOGCM

جدول (۴): نتایج بررسی عملکرد مدل‌های AOGCM برای منطقه مورد مطالعه

| دما  |      |                | بارش  |       |                | مدل             |
|------|------|----------------|-------|-------|----------------|-----------------|
| MAE  | RMSE | R <sup>2</sup> | MAE   | RMSE  | R <sup>2</sup> |                 |
| ۱/۳۰ | ۱/۴۹ | ۰/۹۸           | ۴۳/۱۱ | ۵۸/۰۴ | ۰/۲۴           | ACCESS-CM2      |
| ۱/۴۱ | ۱/۶۸ | ۰/۹۸           | ۲۶/۴۴ | ۴۲/۶۴ | ۰/۷۷           | BCC-CSM2-MR     |
| ۱/۴۸ | ۱/۷۲ | ۰/۹۷           | ۳۳/۳۶ | ۵۰/۴۶ | ۰/۳۵           | CanESM5         |
| ۱/۲۳ | ۱/۴۶ | ۰/۹۹           | ۲۸/۷۹ | ۴۱/۷۵ | ۰/۴۹           | CESM2           |
| ۱/۳۶ | ۱/۵۰ | ۰/۹۸           | ۳۰/۶۴ | ۴۵/۳۹ | ۰/۵۰           | GFDL-ESM4       |
| ۰/۸۹ | ۱/۱۲ | ۰/۹۹           | ۲۲/۱۹ | ۳۵/۵۱ | ۰/۸۳           | HadGEM3-GC31-LL |
| ۱/۴۸ | ۱/۶۱ | ۰/۹۸           | ۲۹/۱۰ | ۳۹/۰۰ | ۰/۶۸           | INM-CM4-8       |
| ۱/۷۴ | ۱/۹۶ | ۰/۹۹           | ۴۴/۱۴ | ۵۵/۴۱ | ۰/۱۳           | MIROC-ES2H      |


مؤثر بر شبیه‌سازی بارش و دما یکسان نبوده و هر یک از این متغیرهای اقلیمی به ترکیب متفاوتی از متغیرهای بزرگ‌مقیاس جوی وابسته هستند. از این‌رو، برای هر متغیر هدف، مجموعه‌ای از متغیرهای ورودی با بیشترین میزان همبستگی و تأثیر انتخاب شد. متغیرهای ورودی منتخب برای توسعه مدل شبکه عصبی مصنوعی در جدول (۵) ارائه شده است.

برای شبیه‌سازی بارش، متغیرهای دمای هوا در ارتفاع دو متری، رطوبت نسبی در تراز فشاری ۵۰۰ هکتوپاسکال و رطوبت نسبی در تراز فشاری ۸۵۰ هکتوپاسکال به‌عنوان مؤثرترین متغیرهای ورودی شناسایی شدند و در آموزش شبکه عصبی مصنوعی مورد استفاده قرار گرفتند. همچنین، برای شبیه‌سازی دمای میانگین، ژئوپتانسیل در تراز فشاری ۵۰۰ هکتوپاسکال، جهت باد در تراز فشاری ۵۰۰ هکتوپاسکال، دمای هوا در ارتفاع دو متری، رطوبت نسبی در تراز فشاری ۵۰۰ هکتوپاسکال و رطوبت نسبی در تراز فشاری ۸۵۰ هکتوپاسکال به‌عنوان متغیرهای ورودی منتخب انتخاب شدند.

#### انتخاب متغیرهای ورودی بر اساس تحلیل حساسیت

پس از انتخاب مدل اقلیمی برتر، به‌منظور توسعه مدل ریزمقیاس‌نمایی مبتنی بر شبکه عصبی مصنوعی، متغیرهای ورودی از میان ۲۶ متغیر بزرگ‌مقیاس جوی استخراج‌شده از داده‌های بازتحلیل NCEP/NCAR انتخاب شدند. با توجه به اینکه استفاده هم‌زمان از تمامی متغیرهای ورودی می‌تواند موجب افزایش پیچیدگی مدل، افزایش زمان آموزش و کاهش دقت پیش‌بینی شود، تحلیل حساسیت به‌منظور شناسایی مؤثرترین متغیرهای جوی انجام گرفت. در این تحلیل، میزان تأثیر هر یک از متغیرهای بزرگ‌مقیاس بر شبیه‌سازی بارش و دما بررسی شد و متغیرهایی که بیشترین ارتباط را با متغیرهای هدف داشتند، به‌عنوان ورودی‌های نهایی مدل شبکه عصبی مصنوعی انتخاب شدند. روند انتخاب متغیرهای ورودی، آموزش شبکه عصبی مصنوعی و اجرای فرآیند ریزمقیاس‌نمایی به‌صورت شماتیک در شکل (۴) ارائه شده است.

بررسی نتایج تحلیل حساسیت نشان داد که متغیرهای



شکل (۴): روند انتخاب متغیرهای ورودی و توسعه مدل ریزمقیاس نمایی با شبکه عصبی مصنوعی

جدول (۵): متغیرهای ورودی منتخب بر اساس تحلیل حساسیت برای توسعه مدل شبکه عصبی مصنوعی

| متغیر هدف    | متغیرهای ورودی منتخب                                                                                                                                                                        |
|--------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| بارش         | دمای هوا در ارتفاع دو متری، رطوبت نسبی در تراز فشاری ۵۰۰ هکتوپاسکال، رطوبت نسبی در تراز فشاری ۸۵۰ هکتوپاسکال                                                                                |
| دمای میانگین | ژئوپتانسیل در تراز فشاری ۵۰۰ هکتوپاسکال، جهت باد در تراز فشاری ۵۰۰ هکتوپاسکال، دمای هوا در ارتفاع دو متری، رطوبت نسبی در تراز فشاری ۵۰۰ هکتوپاسکال، رطوبت نسبی در تراز فشاری ۸۵۰ هکتوپاسکال |

### توسعه، آموزش و ارزیابی عملکرد مدل شبکه عصبی مصنوعی

پس از انتخاب متغیرهای ورودی بر اساس نتایج تحلیل حساسیت، مدل شبکه عصبی مصنوعی برای ریزمقیاس نمایی متغیرهای اقلیمی توسعه داده شد. در این پژوهش، داده‌های بازتحلیل NCEP/NCAR به عنوان ورودی شبکه و داده‌های مشاهده‌ای بارش و دمای میانگین به عنوان خروجی شبکه در دوره پایه مورد استفاده قرار

گرفتند. هدف از آموزش شبکه، استخراج رابطه غیرخطی بین متغیرهای بزرگ مقیاس جوی و متغیرهای اقلیمی در مقیاس محلی و استفاده از این رابطه برای ریزمقیاس نمایی خروجی مدل اقلیمی منتخب در دوره آینده بود. پیش از آموزش شبکه عصبی مصنوعی، داده‌های ورودی و خروجی با استفاده از روش استانداردسازی به مقیاس بدون بعد تبدیل شدند. این فرآیند به منظور کاهش اثر اختلاف دامنه متغیرها، افزایش سرعت همگرایی

ساختار نهایی شبکه بر اساس توانایی آن در حفظ عملکرد مناسب روی داده‌های آزمون انجام گرفت؛ به طوری که کاهش محسوس عملکرد مدل در داده‌های آزمون نسبت به داده‌های آموزش مشاهده نشد.

مشخصات ساختارهای بهینه انتخاب شده و شاخص های ارزیابی عملکرد مدل برای شبیه سازی دمای میانگین و بارش در جدول (۶) ارائه شده است. نتایج جدول (۶) نشان می‌دهد که مدل شبکه عصبی مصنوعی عملکرد بسیار مناسبی در شبیه سازی دمای میانگین داشته است؛ به طوری که مقدار ضریب تعیین در مراحل آموزش و آزمون برابر با ۰/۹۹۱۸ بوده و مقادیر RMSE و MAE نیز پایین است. این نتایج نشان دهنده توانایی بالای شبکه در استخراج روابط غیرخطی بین متغیرهای بزرگ مقیاس جوی و دمای محلی است.

عملکرد مدل در شبیه سازی بارش نیز قابل قبول بود. مقادیر ضریب تعیین برابر با ۰/۸۴۳۳ و ۰/۸۲۶۴ در مراحل آموزش و آزمون و مقادیر مناسب RMSE و MAE نشان می‌دهد که شبکه عصبی مصنوعی توانایی بازسازی تغییرات زمانی بارش را با دقت قابل قبول دارد. اگرچه عملکرد مدل در شبیه سازی بارش نسبت به دما کمتر است، این موضوع با ماهیت پیچیده تر و تغییرپذیری بیشتر بارش نسبت به دما سازگار بوده و در مطالعات ریزمقیاس نمایی اقلیمی نیز گزارش شده است.

نتایج شبیه سازی دمای میانگین ماهانه توسط مناسب ترین ساختار مدل شبکه عصبی مصنوعی برای کل داده‌ها، مرحله آموزش و مرحله آزمون، در شکل های (۵) و (۶) ارائه شده است. این شکل‌ها شامل مقایسه مقادیر مشاهده ای و شبیه سازی شده و همچنین نمودار پراکنش بین دو مجموعه داده هستند.

الگوریتم آموزش و بهبود عملکرد شبکه انجام شد. پس از انجام شبیه سازی، مقادیر خروجی شبکه به مقیاس اولیه بازگردانی شدند تا امکان مقایسه با داده‌های مشاهده ای فراهم شود. سپس ۷۵ درصد از داده‌ها به مجموعه آموزش و ۲۵ درصد به مجموعه آزمون اختصاص یافت. تقسیم داده‌ها به صورت تصادفی انجام شد تا هر دو مجموعه نماینده مناسبی از کل داده‌ها باشند و عملکرد مدل مستقل از ترتیب زمانی داده‌ها ارزیابی شود.

به منظور دستیابی به ساختار بهینه شبکه عصبی مصنوعی، ترکیب های مختلفی از تعداد نوروهای لایه پنهان، توابع انتقال و الگوریتم های آموزش در محیط MATLAB مورد بررسی قرار گرفت. عملکرد هر ساختار با استفاده از شاخص های آماری  $R^2$ ، RMSE و MAE ارزیابی شد. در نهایت، ساختاری که دارای بیشترین مقدار  $R^2$  و کمترین مقادیر RMSE و MAE در مرحله ارزیابی بود، به عنوان ساختار بهینه انتخاب شد.



بر اساس نتایج حاصل از آزمون ساختارهای مختلف، شبکه با ساختار ۱-۸-۴ برای شبیه سازی دمای میانگین و شبکه با ساختار ۱-۶-۳ برای شبیه سازی بارش، به دلیل دستیابی به بهترین عملکرد آماری، انتخاب شدند. آموزش شبکه با استفاده از الگوریتم های مختلف موجود در محیط MATLAB انجام شد و الگوریتم Trainlm به عنوان الگوریتم آموزش بهینه انتخاب گردید. همچنین، توابع انتقال مختلف مورد بررسی قرار گرفت و تابع tansig بهترین عملکرد را ارائه داد. فرآیند آموزش تا دستیابی به حداقل خطای مدل یا رسیدن به حداکثر تعداد تکرار مجاز ادامه یافت و مشخصات نهایی شبکه های منتخب در جدول (۶) ارائه شده است.

به منظور کنترل بیش برآزش، عملکرد شبکه علاوه بر مرحله آموزش، در مجموعه آزمون نیز بررسی شد. انتخاب



جدول (۶): مشخصات ساختار بهینه و شاخص های عملکرد مدل شبکه عصبی مصنوعی

| متغیر        | ساختار | تکرار | قانون آموزش | تابع انتقال | پارامترهای مدل |        |        |
|--------------|--------|-------|-------------|-------------|----------------|--------|--------|
|              |        |       |             |             | $R^2$          | RMSE   | MAE    |
| دمای میانگین | ۱-۸-۴  | ۸۶۳   | trainlm     | tansig      | آموزش          | تست    | آموزش  |
|              |        |       |             |             | ۰/۹۹۱۸         | ۰/۹۹۱۸ | ۰/۰۱۹۱ |
| بارش         | ۱-۶-۳  | ۱۰۰۰  | trainlm     | tansig      | آموزش          | تست    | آموزش  |
|              |        |       |             |             | ۰/۸۴۳۳         | ۰/۸۲۶۴ | ۰/۰۵۶۶ |







شکل (۵): نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی در شبیه‌سازی دمای میانگین برای کل داده‌ها.



شکل (۶): نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی در شبیه‌سازی دمای میانگین برای داده‌های مرحله آموزش.




شکل (۷): نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی در شبیه‌سازی دمای میانگین برای داده‌های مرحله تست.


مقادیر پایین شاخص‌های خطا نشان‌دهنده عملکرد مطلوب مدل در هر دو مرحله آموزش و آزمون است. بنابراین، ساختار منتخب شبکه عصبی مصنوعی از قابلیت مناسبی برای ریزمقیاس‌نمایی و پیش‌بینی دمای میانگین ماهانه

همان‌گونه که مشاهده می‌شود، مقادیر شبیه‌سازی‌شده تطابق مناسبی با داده‌های مشاهده‌ای داشته و پراکنش نقاط در امتداد خط برازش بیانگر دقت بالای مدل در شبیه‌سازی دمای میانگین است. همچنین، مقدار بالای ضریب تعیین و

می‌دهند. نتایج نشان می‌دهد که مدل شبکه عصبی مصنوعی توانسته است تغییرات بارش ماهانه را با دقت قابل قبولی بازسازی کند و انطباق مناسب بین مقادیر مشاهده‌ای و شبیه‌سازی شده، بیانگر توانایی مطلوب مدل در شبیه سازی بارش دوره پایه است. از این رو، ساختار منتخب برای پیش‌بینی بارش ماهانه در دوره آینده (۲۰۲۵-۲۰۵۰) تحت سناریوهای انتشار SSP1-2.6، SSP2-4.5 و SSP5-8.5 مورد استفاده قرار گرفت.





شکل (۸): نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی در شبیه‌سازی بارش برای کل داده‌ها.





شکل (۹): نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی در شبیه‌سازی بارش برای داده‌های مرحله آموزش.

منطقه مورد مطالعه برخوردار است. در ادامه، این مدل برای شبیه‌سازی دمای میانگین در دوره آینده (۲۰۲۵-۲۰۵۰) تحت سناریوهای انتشار SSP1-2.6، SSP2-4.5 و SSP5-8.5 به کار گرفته شد.

نتایج شبیه‌سازی بارش ماهانه توسط مناسب‌ترین ساختار مدل شبکه عصبی مصنوعی برای کل داده‌ها، مرحله آموزش و مرحله آزمون، به ترتیب در شکل‌های (۸) تا (۱۰) ارائه شده است. این شکل‌ها مقایسه مقادیر مشاهده‌ای و شبیه‌سازی شده و نیز نمودار پراکنش آن‌ها را نمایش





شکل (۱۰): نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی در شبیه‌سازی بارش برای داده‌های مرحله تست.

تغذیه منابع آب، رواناب و مدیریت مخازن سدها اثرگذار باشد.

بررسی تغییرات دمای حداکثر نیز نشان داد که میانگین سالانه این متغیر در دوره آینده روند افزایشی خواهد داشت. افزایش دمای حداکثر برای سناریوهای SSP1-2.6، SSP2-4.5 و SSP5-8.5 به ترتیب ۱/۱، ۱/۳ و ۱/۳ درجه سانتی گراد پیش‌بینی شد و مقدار میانگین آن به ترتیب به ۲۵/۵، ۲۵/۷ و ۲۵/۷ درجه سانتی‌گراد خواهد رسید. نتایج مربوط به دمای حداقل نیز افزایش این متغیر را در تمامی سناریوهای انتشار نشان داد. میانگین سالانه دمای حداقل نسبت به دوره پایه به ترتیب ۰/۶، ۰/۵ و ۰/۶ درجه سانتی‌گراد افزایش خواهد یافت و مقادیر آن در دوره آینده به ترتیب برابر با ۱۱/۷، ۱۱/۵ و ۱۱/۷ درجه سانتی‌گراد خواهد بود.

همچنین، میانگین دمای سالانه حوضه در دوره آینده در هر سه سناریوی انتشار روند افزایشی دارد. نتایج نشان داد که میانگین دما برای سناریوهای SSP1-2.6، SSP2-4.5 و SSP5-8.5 به ترتیب ۰/۹، ۰/۹ و ۱/۰ درجه سانتی‌گراد نسبت به دوره پایه افزایش می‌یابد و به ترتیب به ۱۸/۶، ۱۸/۷ و ۱۸/۶ درجه سانتی‌گراد خواهد رسید.

افزایش دما در تمامی سناریوها موجب افزایش تبخیر و تعرق بالقوه و در نتیجه افزایش نیاز آبی بخش کشاورزی خواهد شد. از آنجا که حوضه درودزن یکی از مناطق مهم تأمین آب کشاورزی استان فارس محسوب می‌شود، تداوم این روند می‌تواند فشار بیشتری بر منابع آب موجود وارد

### پیش‌بینی تغییرات بارش و دما در دوره آینده (۲۰۲۵-۲۰۵۰) نسبت به دوره پایه (۱۹۹۴-۲۰۱۴)

پس از انتخاب مدل اقلیمی برتر و توسعه مدل ریزمقیاس نمایی مبتنی بر شبکه عصبی مصنوعی، داده‌های خروجی مدل HadGEM3-GC31-LL تحت سناریوهای انتشار SSP1-2.6، SSP2-4.5 و SSP5-8.5 به عنوان ورودی مدل قرار گرفت و متغیرهای اقلیمی دوره آینده (۲۰۲۵-۲۰۵۰) ریزمقیاس‌نمایی شدند. سپس، مقادیر پیش‌بینی شده با دوره پایه (۱۹۹۴-۲۰۱۴) مقایسه شد تا روند تغییرات بارش و دما در منطقه مورد مطالعه ارزیابی شود.

نتایج نشان داد که میانگین بارش سالانه حوضه در دوره آینده در هر سه سناریوی انتشار نسبت به دوره پایه کاهش خواهد یافت. میزان این کاهش برای سناریوهای SSP1-2.6، SSP2-4.5 و SSP5-8.5 به ترتیب ۱۲/۹، ۲۸/۳ و ۴۸/۴ میلی‌متر برآورد شد. بر این اساس، میانگین بارش سالانه در دوره آینده به ترتیب برابر با ۴۳۸/۹، ۴۵۴/۳ و ۴۱۸/۹ میلی‌متر خواهد بود. بیشترین کاهش بارش مربوط به سناریوی SSP5-8.5 است که بیانگر تشدید اثرات تغییر اقلیم در شرایط انتشار بالا است.

بررسی تغییرات ماهانه نیز نشان می‌دهد که کاهش بارش در همه ماه‌ها یکنواخت نیست و بیشترین تغییرات در ماه‌های پربارش سال مشاهده می‌شود. این موضوع نشان می‌دهد که تغییر اقلیم علاوه بر کاهش مجموع بارش سالانه، می‌تواند الگوی زمانی توزیع بارش را نیز تغییر دهد و بر

به دلیل فرض کنترل انتشار و اجرای سیاست‌های کاهش انتشار، تغییرات اقلیمی محدودتر بوده و کاهش بارش و افزایش دما نسبتاً کمتر است. در مقابل، سناریوی SSP5-8.5 که بیانگر تداوم وابستگی به سوخت‌های فسیلی و انتشار بالای گازهای گلخانه‌ای است، بیشترین کاهش بارش و بیشترین افزایش دما را نشان می‌دهد. این تفاوت بیانگر حساسیت اقلیم حوضه درودزن به شدت انتشار گازهای گلخانه‌ای است و نشان می‌دهد که در صورت تحقق سناریوهای با انتشار بالا، احتمال تشدید خشکسالی، افزایش تبخیر و تعرق و کاهش منابع آب سطحی و زیرزمینی در منطقه افزایش خواهد یافت.

کرده و ضرورت اتخاذ راهکارهای سازگاری با تغییر اقلیم را بیش از پیش آشکار سازد.

نتایج ماهانه و سالانه تغییرات بارش، دمای حداکثر، دمای حداقل و دمای میانگین در دوره آینده نسبت به دوره پایه در جداول (۷) تا (۱۰) ارائه شده است. همچنین، روند تغییرات این متغیرها تحت سناریوهای مختلف انتشار در شکل‌های (۱۱) تا (۱۴) نمایش داده شده است.

نتایج نشان می‌دهد که اگرچه هر سه سناریوی انتشار کاهش بارش و افزایش دما را برای دوره آینده پیش‌بینی می‌کنند، اما شدت این تغییرات با افزایش سطح انتشار گازهای گلخانه‌ای بیشتر می‌شود. در سناریوی SSP1-2.6،

جدول (۷): میزان بارش در دوره آتی (۲۰۲۵-۲۰۵۰) برای سناریوهای انتشار و مقایسه با دوره پایه (۱۹۹۴-۲۰۱۴)

| ماه میلادی   | بارش دوره پایه<br>(میلیمتر) | SSP1-2.6 | SSP2-4.5 | SSP5-8.5 | اختلاف دوره آتی نسبت به دوره پایه<br>(میلیمتر) |
|--------------|-----------------------------|----------|----------|----------|------------------------------------------------|
| ژانویه       | ۱۱۱/۴                       | ۱۵۹/۹    | ۱۹۲/۰    | ۱۲۹/۲    | ۴۸/۵                                           |
| فوریه        | ۸۸/۵                        | ۴۷/۰     | ۷۲/۸     | ۵۳/۶     | -۴۱/۵                                          |
| مارس         | ۷۲/۸                        | ۴۶/۰     | ۲۰/۲     | ۲۰/۸     | -۲۶/۸                                          |
| آوریل        | ۴۲/۵                        | ۱۳/۱     | ۱۶/۲     | ۲۳/۳     | -۲۹/۴                                          |
| مه           | ۵/۵                         | ۴/۱      | ۰/۹      | ۰/۹      | -۱/۴                                           |
| ژوئن         | ۰/۴                         | ۰/۰      | ۰/۰      | ۰/۰      | -۰/۴                                           |
| جولای        | ۰/۹                         | ۲/۶      | ۶/۸      | ۵/۲      | ۱/۷                                            |
| اگوست        | ۰/۳                         | ۰/۱      | ۰/۲      | ۰/۲      | -۰/۲                                           |
| سپتامبر      | ۰/۰                         | ۱/۱      | ۲/۴      | ۱/۵      | ۱/۱                                            |
| اکتبر        | ۷/۸                         | ۲/۴      | ۱/۸      | ۱/۹      | -۵/۴                                           |
| نوامبر       | ۵۰/۸                        | ۵۲/۲     | ۶۱/۱     | ۷۴/۹     | ۱/۴                                            |
| دسامبر       | ۵۶/۳                        | ۱۲۵/۸    | ۶۴/۵     | ۱۰۷/۳    | ۳۹/۵                                           |
| متوسط سالانه | ۴۶۷/۲                       | ۴۵۴/۳    | ۴۳۸/۹    | ۴۱۸/۹    | -۱۲/۹                                          |



جدول (۸): میزان دمای حداکثر در دوره آتی (۲۰۲۵-۲۰۵۰) برای سناریوهای انتشار و مقایسه با دوره پایه (۱۹۹۴-۲۰۱۴)


| ماه میلادی   | دمای حداکثر دوره پایه (درجه سانتیگراد) | میزان حداکثر دما (درجه سانتیگراد) |          |          | اختلاف دوره آتی نسبت به دوره پایه (درجه سانتیگراد) |          |          |
|--------------|----------------------------------------|-----------------------------------|----------|----------|----------------------------------------------------|----------|----------|
|              |                                        | SSP1-2.6                          | SSP2-4.5 | SSP5-8.5 | SSP1-2.6                                           | SSP2-4.5 | SSP5-8.5 |
| ژانویه       | ۱۰/۳                                   | ۱۴/۷                              | ۱۵/۵     | ۱۵/۰     | ۴/۴                                                | ۵/۲      | ۴/۸      |
| فوریه        | ۱۳/۶                                   | ۱۷/۱                              | ۱۷/۳     | ۱۷/۰     | ۳/۵                                                | ۳/۸      | ۳/۴      |
| مارس         | ۱۸/۰                                   | ۲۱/۱                              | ۲۱/۳     | ۲۱/۱     | ۳/۱                                                | ۳/۳      | ۳/۱      |
| آوریل        | ۲۲/۹                                   | ۲۴/۹                              | ۲۵/۲     | ۲۵/۰     | ۲/۰                                                | ۲/۲      | ۲/۱      |
| مه           | ۲۹/۳                                   | ۳۰/۴                              | ۳۰/۵     | ۳۰/۸     | ۱/۲                                                | ۱/۲      | ۱/۵      |
| ژوئن         | ۳۴/۷                                   | ۳۳/۱                              | ۳۳/۳     | ۳۳/۵     | -۱/۶                                               | -۱/۴     | -۱/۲     |
| ژوئای        | ۳۷/۰                                   | ۳۳/۹                              | ۳۴/۱3    | ۳۴/۲     | -۳/۰                                               | -۲/۸     | -۲/۸     |
| آگوست        | ۳۶/۱                                   | ۳۲/۷                              | ۳۲/۷     | ۳۳/۰     | -۳/۴                                               | -۳/۴     | -۳/۱     |
| سپتامبر      | ۳۲/۵                                   | ۳۱/۰                              | ۳۰/۹     | ۳۱/۲     | -۱/۵                                               | -۱/۵     | -۱/۳     |
| اکتبر        | ۲۶/۸                                   | ۲۷/۴                              | ۲۷/۴     | ۲۷/۵     | ۰/۶                                                | ۰/۶      | ۰/۷      |
| نوامبر       | ۱۸/۵                                   | ۲۲/۰                              | ۲۲/۲     | ۲۲/۴     | ۳/۵                                                | ۳/۸      | ۳/۹      |
| دسامبر       | ۱۳/۲                                   | ۱۷/۵                              | ۱۷/۸     | ۱۷/۸     | ۴/۴                                                | ۴/۶      | ۴/۶      |
| متوسط سالانه | ۲۴/۴                                   | ۲۵/۵                              | ۲۵/۷     | ۲۵/۷     | ۱/۱                                                | ۱/۳      | ۱/۳      |

جدول (۹): میزان دمای حداقل در دوره آتی (۲۰۲۵-۲۰۵۰) برای سناریوهای انتشار و مقایسه با دوره پایه (۱۹۹۴-۲۰۱۴)


| ماه میلادی   | دمای حداقل دوره پایه (درجه سانتیگراد) | میزان حداقل دما (درجه سانتیگراد) |          |          | اختلاف دوره آتی نسبت به دوره پایه (درجه سانتیگراد) |          |          |
|--------------|---------------------------------------|----------------------------------|----------|----------|----------------------------------------------------|----------|----------|
|              |                                       | SSP1-2.6                         | SSP2-4.5 | SSP5-8.5 | SSP1-2.6                                           | SSP2-4.5 | SSP5-8.5 |
| ژانویه       | ۰/۱                                   | ۴/۹                              | ۴/۶      | ۴/۹      | ۴/۹                                                | ۴/۴      | ۴/۸      |
| فوریه        | ۲/۱                                   | ۵/۸                              | ۵/۳      | ۵/۷      | ۳/۶                                                | ۳/۲      | ۳/۶      |
| مارس         | ۵/۶                                   | ۸/۱                              | ۷/۷      | ۸/۱      | ۲/۵                                                | ۲/۲      | ۲/۵      |
| آوریل        | ۹/۹                                   | ۱۱/۲                             | ۱۱/۰     | ۱۱/۲     | ۱/۳                                                | ۱/۱      | ۱/۳      |
| مه           | ۱۴/۹                                  | ۱۵/۱                             | ۱۵/۱     | ۱۵/۱     | ۰/۱                                                | ۰/۲      | ۰/۱      |
| ژوئن         | ۱۹/۵                                  | ۱۶/۸                             | ۱۶/۸     | ۱۶/۸     | -۲/۷                                               | -۲/۷     | -۲/۷     |
| ژوئای        | ۲۲/۳                                  | ۱۸/۲                             | ۱۸/۲     | ۱۸/۲     | -۴/۱                                               | -۴/۱     | -۴/۱     |
| آگوست        | ۲۰/۹                                  | ۱۷/۶                             | ۱۷/۶     | ۱۷/۶     | -۳/۴                                               | -۳/۴     | -۳/۴     |
| سپتامبر      | ۱۷/۰                                  | ۱۵/۴                             | ۱۵/۴     | ۱۵/۴     | -۱/۶                                               | -۱/۶     | -۱/۶     |
| اکتبر        | ۱۱/۹                                  | ۱۲/۳                             | ۱۲/۲     | ۱۲/۳     | ۰/۴                                                | ۰/۳      | ۰/۴      |
| نوامبر       | ۶/۳                                   | ۸/۹                              | ۸/۸      | ۸/۹      | ۲/۶                                                | ۲/۵      | ۲/۶      |
| دسامبر       | ۲/۱                                   | ۶/۳                              | ۵/۹      | ۶/۳      | ۴/۲                                                | ۳/۸      | ۴/۲      |
| متوسط سالانه | ۱۱/۱                                  | ۱۱/۷                             | ۱۱/۵     | ۱۱/۷     | ۰/۶                                                | ۰/۵      | ۰/۶      |

جدول (۱۰): میزان دمای متوسط در دوره آتی (۲۰۲۵-۲۰۵۰) برای سناریوهای انتشار و مقایسه با دوره پایه (۱۹۹۴-۲۰۱۴)


| ماه میلادی   | دمای متوسط دوره پایه (درجه سانتیگراد) | SSP1-2.6 | SSP2-4.5 | SSP5-8.5 | میزان متوسط دما (درجه سانتیگراد) | اختلاف دوره آتی نسبت به دوره پایه (درجه سانتیگراد) |
|--------------|---------------------------------------|----------|----------|----------|----------------------------------|----------------------------------------------------|
| ژانویه       | ۵/۲                                   | ۹/۶      | ۹/۸      | ۹/۸      | ۴/۶                              | ۴/۶                                                |
| فوریه        | ۷/۹                                   | ۱۱/۳     | ۱۱/۱     | ۱۱/۲     | ۳/۴                              | ۳/۳                                                |
| مارس         | ۱۱/۸                                  | ۱۴/۵     | ۱۴/۴     | ۱۴/۵     | ۲/۷                              | ۲/۶                                                |
| آوریل        | ۱۶/۴                                  | ۱۸/۱     | ۱۸/۱     | ۱۸/۱     | ۱/۷                              | ۱/۶                                                |
| مه           | ۲۲/۱                                  | ۲۲/۸     | ۲۲/۹     | ۲۳/۰     | ۰/۹                              | ۰/۸                                                |
| ژوئن         | ۲۷/۱                                  | ۲۵/۱     | ۲۵/۲     | ۲۵/۳     | -۱/۸                             | -۱/۹                                               |
| ژوئیه        | ۲۹/۶                                  | ۲۶/۳     | ۲۶/۴     | ۲۶/۴     | -۳/۲                             | -۳/۳                                               |
| آگوست        | ۲۸/۵                                  | ۲۵/۴     | ۲۵/۳     | ۲۵/۵     | -۳/۱                             | -۳/۲                                               |
| سپتامبر      | ۲۴/۷                                  | ۲۳/۳     | ۲۳/۳     | ۲۳/۴     | -۱/۳                             | -۱/۴                                               |
| اکتبر        | ۱۹/۴                                  | ۱۹/۹     | ۱۹/۸     | ۱۹/۹     | ۰/۵                              | ۰/۴                                                |
| نوامبر       | ۱۲/۴                                  | ۱۵/۴     | ۱۵/۴     | ۱۵/۶     | ۳/۲                              | ۳/۰                                                |
| دسامبر       | ۷/۶                                   | ۱۱/۸     | ۱۱/۷     | ۱۱/۹     | ۴/۳                              | ۴/۰                                                |
| متوسط سالانه | ۱۷/۷                                  | ۱۸/۶     | ۱۸/۶     | ۱۸/۷     | ۱/۰                              | ۰/۹                                                |




شکل (۱۱): نمودار بارش در دوره آتی (۲۰۲۵-۲۰۵۰) برای سناریوهای انتشار و مقایسه با دوره پایه (۱۹۹۴-۲۰۱۴)



شکل (۱۲): دمای حداکثر در دوره آتی (۲۰۲۵-۲۰۵۰) برای سناریوهای انتشار و مقایسه با دوره پایه (۱۹۹۴-۲۰۱۴)



شکل (۱۳): دمای حداقل در دوره آتی (۲۰۲۵-۲۰۵۰) برای سناریوهای انتشار و مقایسه با دوره پایه (۱۹۹۴-۲۰۱۴)



شکل (۱۴): دمای متوسط در دوره آتی (۲۰۲۵-۲۰۵۰) برای سناریوهای انتشار و مقایسه با دوره پایه (۱۹۹۴-۲۰۱۴)

اقلیمی، بر ضرورت انتخاب مدل مناسب پیش از انجام پیش‌بینی‌های اقلیمی تأکید کردند.

مدل شبکه عصبی مصنوعی نیز توانست ارتباط غیرخطی بین متغیرهای بزرگ‌مقیاس جو و متغیرهای اقلیمی محلی را با دقت مطلوبی شبیه‌سازی کند. مقدار ضریب تعیین برابر با ۰/۹۹ برای دمای میانگین و حدود ۰/۸۴ برای بارش نشان می‌دهد که این روش برای ریز مقیاس‌نمایی متغیرهای اقلیمی در حوضه آبریز درودزن از کارایی مناسبی برخوردار است. نتایج حاصل با یافته‌های دیبیک و کولیبال (۲۰۰۶) همخوانی دارد که کارایی شبکه های عصبی زمانی را در ریزمقیاس‌نمایی متغیرهای اقلیمی و مدل‌سازی روابط غیرخطی بین متغیرهای جوی و اقلیم محلی نشان دادند. همچنین حسینی‌باغانم و همکاران (۲۰۲۴) گزارش کردند که استفاده از شبکه‌های عصبی مبتنی بر یادگیری عمیق می‌تواند عملکرد ریزمقیاس‌نمایی آماری متغیرهای اقلیمی را بهبود بخشد. همسویی نتایج پژوهش حاضر با این مطالعات نشان می‌دهد که استفاده از شبکه‌های عصبی مصنوعی، به‌ویژه در مناطق با رفتار اقلیمی

نتایج این پژوهش نشان داد که از میان هشت مدل اقلیمی CMIP6 مورد بررسی، مدل HadGEM3-GC31-LL در شبیه‌سازی متغیرهای دما و بارش در دوره پایه عملکرد بهتری نسبت به سایر مدل‌ها داشت و به‌عنوان مدل برتر انتخاب شد. این موضوع بیانگر آن است که انتخاب مدل اقلیمی مناسب بر اساس شرایط اقلیمی هر منطقه، نقش مهمی در افزایش دقت مطالعات ریزمقیاس‌نمایی دارد. همان‌گونه که ایرینگ و همکاران (۲۰۱۶) در معرفی پروژه CMIP6 تأکید کرده‌اند، مدل‌های گردش عمومی جو دارای تفاوت‌هایی در ساختار، پارامترسازی و توانایی شبیه‌سازی فرآیندهای اقلیمی هستند؛ از این رو، ارزیابی عملکرد آن‌ها در هر منطقه پیش از استفاده در مطالعات تغییر اقلیم ضروری است. همچنین، این نتایج با توصیه‌های گزارش ششم (۲۰۲۱) IPCC مبنی بر ارزیابی و انتخاب مدل‌های اقلیمی متناسب با شرایط منطقه‌ای همخوانی دارد. از سوی دیگر، نتایج این پژوهش با یافته‌های صیادی و همکاران (۱۳۹۸) نیز همسو است؛ به‌طوری‌که آنان نیز در مطالعه حوضه آبریز درودزن، پس از ارزیابی مدل‌های





با وجود عملکرد مطلوب مدل اقلیمی منتخب و شبکه عصبی مصنوعی در شبیه‌سازی و ریزمقیاس‌نمایی متغیرهای اقلیمی، نتایج این پژوهش با برخی محدودیت‌ها همراه است. نخست، ارزیابی مدل‌ها بر اساس داده‌های مشاهده‌ای ایستگاه درودزن و دوره پایه ۱۹۹۴-۲۰۱۴ انجام شده است؛ بنابراین، کیفیت و طول دوره داده‌های مشاهده‌ای می‌تواند بر نتایج ارزیابی و آموزش مدل اثرگذار باشد. دوم، پیش‌بینی اقلیم آینده تنها بر اساس خروجی مدل HadGEM3-GC31-LL انجام شده است؛ در نتیجه بخشی از عدم قطعیت ناشی از اختلاف بین مدل‌های اقلیمی در نتایج نهایی منعکس نشده است. سوم، اگرچه شبکه عصبی مصنوعی توانایی مناسبی در استخراج روابط غیرخطی بین متغیرهای بزرگ‌مقیاس و محلی نشان داد، اما عملکرد آن به انتخاب متغیرهای ورودی، ساختار شبکه و داده‌های آموزشی وابسته است و تغییر هر یک از این عوامل می‌تواند بر دقت پیش‌بینی‌ها تأثیر بگذارد. همچنین، نتایج این پژوهش با توجه به شرایط اقلیمی، توپوگرافی و ویژگی‌های حوزه آبریز درودزن، بیشترین قابلیت کاربرد را برای مناطق دارای شرایط مشابه دارد و تعمیم مستقیم آن به سایر حوزه‌ها نیازمند ارزیابی مجدد مدل و کالیبراسیون متناسب با شرایط هر منطقه است. از این رو، استفاده از چند مدل اقلیمی، مقایسه روش‌های مختلف ریزمقیاس‌نمایی و بررسی دوره‌های زمانی طولانی‌تر در مطالعات آینده می‌تواند به کاهش عدم قطعیت و افزایش قابلیت اطمینان پیش‌بینی‌ها کمک کند.

### نتیجه‌گیری

در این پژوهش، با ترکیب مدل‌های CMIP6 و مدل ریزمقیاس‌نمایی مبتنی بر شبکه عصبی مصنوعی، تغییرات آینده بارش و دمای حوزه آبریز درودزن برای دوره ۲۰۲۵ تا ۲۰۵۰ مورد بررسی قرار گرفت. نتایج نشان داد که مدل HadGEM3-GC31-LL در مقایسه با سایر مدل‌های بررسی‌شده، عملکرد مناسب‌تری در شبیه‌سازی شرایط اقلیمی دوره پایه داشته و به‌عنوان مدل اقلیمی منتخب برای پیش‌بینی شرایط آینده انتخاب شد. همچنین، استفاده از تحلیل حساسیت در انتخاب متغیرهای ورودی، موجب بهبود عملکرد شبکه عصبی مصنوعی در ریزمقیاس‌نمایی

پیش‌بینی‌ها می‌تواند دقت قابل قبولی در بازسازی متغیرهای اقلیمی فراهم کند.

در این پژوهش، دقت شبیه‌سازی دما بیشتر از بارش بود؛ به‌گونه‌ای که خطای مدل در برآورد دما کمتر و ضریب تعیین آن بیشتر از بارش به دست آمد. این موضوع با نتایج صمدی و همکاران (۲۰۱۳) مطابقت دارد که نشان دادند پیش‌بینی بارش به دلیل تأثیرپذیری از فرآیندهای همرفتی، ناهمگنی مکانی و نوسانات زمانی، با عدم قطعیت بیشتری نسبت به دما همراه است. بنابراین، اختلاف عملکرد مدل در شبیه‌سازی دما و بارش که در پژوهش حاضر نیز مشاهده شد، با ویژگی ذاتی این دو متغیر اقلیمی و نتایج مطالعات پیشین سازگار است.

از سوی دیگر، انتخاب متغیرهایی مانند دمای هوا در ارتفاع دو متری، رطوبت نسبی در ترازهای ۵۰۰ و ۸۵۰ هکتوپاسکال، ژئوپتانسیل و مؤلفه‌های باد در تراز ۵۰۰ هکتوپاسکال به‌عنوان متغیرهای پیش‌بین، بیانگر نقش مهم این متغیرهای بزرگ‌مقیاس در کنترل تغییرات اقلیمی منطقه است. نتایج این بخش نیز با یافته‌های دیبیک و کولیالی (۲۰۰۶) همخوانی دارد؛ زیرا این پژوهش نیز بر نقش انتخاب مناسب متغیرهای پیش‌بین در بهبود عملکرد مدل‌های ریزمقیاس‌نمایی آماری تأکید کرده است.

بررسی سناریوهای آینده نیز نشان داد که در تمامی سناریوهای انتشار، روند کلی حوزه آبریز درودزن به سمت کاهش بارش و افزایش دما است و شدت این تغییرات در سناریوی SSP5-8.5 بیشتر از دو سناریوی دیگر خواهد بود. این نتایج با یافته‌های صیادی و همکاران (۱۳۹۸) برای حوزه آبریز درودزن و همچنین با نتایج رانا و همکاران (۲۰۲۵) همخوانی دارد که کاهش بارش و افزایش دما را تحت سناریوهای مختلف اقلیمی گزارش کردند. همچنین، نتایج پژوهش حاضر با گزارش ششم IPCC (2021) نیز سازگار است؛ زیرا این گزارش افزایش دما و تشدید مخاطرات مرتبط با چرخه هیدرولوژیکی را در بسیاری از مناطق جهان، به‌ویژه مناطق خشک و نیمه‌خشک، محتمل می‌داند. این همخوانی نشان می‌دهد که روندهای پیش‌بینی‌شده برای حوزه درودزن در چارچوب الگوهای شناخته‌شده تغییر اقلیم قابل تفسیر است.

اقلیم در طرح‌های توسعه‌ای و مدیریتی می‌تواند به افزایش توان سازگاری منطقه در برابر تغییرات اقلیمی آینده کمک کند.

به‌طور کلی، ترکیب مدل اقلیمی-HadGEM3-GC31-LL با شبکه عصبی مصنوعی در این پژوهش، توانایی مناسبی برای ریزمقیاس‌نمایی و بررسی روندهای احتمالی تغییرات اقلیمی در مقیاس محلی حوضه درودزن نشان داد. با توجه به اینکه ارزیابی‌ها بر اساس یک حوضه آبریز و یک مدل اقلیمی منتخب انجام شده است، در مطالعات آینده پیشنهاد می‌شود از مجموعه گسترده‌تری از مدل‌های اقلیمی، روش‌های مختلف ریزمقیاس‌نمایی و دوره‌های زمانی طولانی‌تر استفاده شود تا عدم قطعیت پیش‌بینی‌ها کاهش یابد. همچنین، بررسی اثر تغییرات اقلیمی پیش‌بینی‌شده بر مؤلفه‌های هیدرولوژیکی مانند رواناب، جریان رودخانه و نیاز آبی محصولات کشاورزی می‌تواند درک جامع‌تری از پیامدهای تغییر اقلیم در این حوضه فراهم کند.

متغیرهای اقلیمی شد و این روش توانست روابط غیرخطی بین متغیرهای بزرگ‌مقیاس جوی و شرایط اقلیمی محلی را با دقت قابل قبول بازسازی کند.

بر اساس نتایج پیش‌بینی، در تمامی سناریوهای انتشار بررسی‌شده، حوضه آبریز درودزن در آینده با افزایش دما و کاهش بارش مواجه خواهد شد و بیشترین شدت تغییرات در سناریوی SSP5-8.5 مشاهده شد. این تغییرات می‌تواند پیامدهای مهمی برای توازن منابع آب، نیاز آبی بخش کشاورزی، احتمال وقوع دوره‌های خشکسالی و پایداری سامانه‌های بهره‌برداری از منابع آب در منطقه داشته باشد. از دیدگاه کاربردی، نتایج این پژوهش می‌تواند به‌عنوان مبنایی برای برنامه‌ریزی و مدیریت پایدار منابع آب حوضه درودزن مورد استفاده قرار گیرد. پیش‌بینی روندهای اقلیمی آینده می‌تواند در تصمیم‌گیری‌های مرتبط با تخصیص منابع آب، مدیریت تقاضا، بهبود بهره‌وری مصرف آب در بخش کشاورزی و تدوین برنامه‌های کاهش اثرات خشکسالی مورد توجه قرار گیرد. همچنین، در نظر گرفتن سناریوهای تغییر

## تقدیر و تشکر

نویسندگان این تحقیق، از شرکت سهامی آب منطقه‌ای فارس به دلیل در اختیار قرار دادن اطلاعات ایستگاه‌های هواشناسی مورد استفاده در این پژوهش، کمال تقدیر و تشکر را بعمل می‌آورند.

## منابع

- تقوایی، س.ف.، خ. حسینی، و س.ع.ا. هاشمی. ۱۴۰۳. پیش‌بینی تأثیر تغییر اقلیم بر تراز آب زیرزمینی با استفاده از الگوریتم-های فراتکاملی (مطالعه موردی: دشت ریز-بوشهر). مجله پژوهش آب ایران، جلد ۱۸، شماره ۲، پیاپی ۵۳، صص ۳۹-۴۸.
- جعفری‌گدنه، م.، ع. سلاجقه، و آ. ملکیان. ۱۴۰۰. بررسی تأثیر سناریوهای مختلف تغییر اقلیم بر نوسانات آب زیرزمینی در مناطق خشک و نیمه‌خشک (مطالعه موردی: دشت کرمان). نشریه علمی پژوهشی مهندسی آبیاری و آب ایران، سال یازدهم، شماره چهل و چهار، صص ۲۷۵-۲۵۲.
- سلگی، ا.، و م.ر. گلابی. ۱۴۰۴. آموزش کاربردی مدل‌های هوشمند. انتشارات دارالفنون. چاپ اول. ص ۳۸۰.
- صیادی، ا.ق.، ن. طالب‌بیدختی، م. نجارچی، و س.م.م. نجفی‌زاده. ۱۳۹۸. تغییرات اقلیمی بر دما، بارش و رواناب حوضه درودزن استان فارس با استفاده از رویکرد میانگین گروهی چند تشبیهی. مهندسی منابع آب، دوره ۱۲، شماره ۴۳، صص ۱۳۰-۱۱۵.
- کدخدا، ا.، غ.ع. فلاح‌قاله‌ری، م. باعقیده، و س.ع.ر. فریدحسینی. ۱۳۹۸. مدلسازی عوامل اقلیمی مؤثر بر افت سطح آبهای

- زیرزمینی با رویکرد تغییر اقلیم (مطالعه موردی: دشت مشهد). مجله پژوهش آب ایران، جلد ۱۳، شماره ۳، صص ۲۷-۳۸.
- نجفی، س.، ا. شرافتی، و ح. کاردان مقدم. ۱۴۰۱. ارزیابی اثر تغییر اقلیم بر تغییرات تراز آب زیرزمینی در آبخوان ساحلی ساری-نکا. نشریه علمی پژوهشی مهندسی آبیاری و آب ایران، سال سیزدهم، شماره پنجم، صص ۳۱۲-۳۳۲.
- Bi, D., M. Dix, S.J. Marsland, S. O'Farrell, A. Sullivan, R. Bodman, and et al. 2020. Configuration and spin-up of ACCESS-CM2, the new generation Australian Community Climate and Earth System Simulator Coupled Model. *Journal of Southern Hemisphere Earth Systems Science*, 70(1): 225-251. <https://doi.org/10.1071/ES19040>
- Danabasoglu, G., J.F. Lamarque, J. Bacmeister, D.A. Bailey, A.K. DuVivier, J. Edwards, and et al. 2020. The Community Earth System Model version 2 (CESM2). *Journal of Advances in Modeling Earth Systems*, 12(2), e2019MS001916. <https://doi.org/10.1029/2019MS001916>
- Dibike, B., and P. Coulibaly. 2006. Temporal neural networks for downscaling climate variability and extremes. *Neural Networks*, 19 (2):135-144. <https://doi.org/10.1016/j.neunet.2006.01.003>
- Dunne, J.P., L.W. Horowitz, A.J. Adcroft, P. Ginoux, I.M. Held, J.G. John, and et al. 2020. The GFDL Earth System Model Version 4.1 (GFDL-ESM 4.1): Overall coupled model description and simulation characteristics. *Journal of Advances in Modeling Earth Systems*, 12 (11), e2019MS002015. <https://doi.org/10.1029/2019MS002015>
- Eyring, V., S. Bony, G.A. Meehl, C.A. Senior, B. Stevens, R.J. Stouffer, and K.E. Taylor. 2016. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development*, 9: 1937-1958, <https://doi.org/10.5194/gmd-9-1937-2016>
- Hosseini Baghanam, A., V. Nourani, M. Bejani, and Ke, C.Q. 2024. Improving the statistical downscaling performance of climatic parameters with convolutional neural networks. *Journal of Water and Climate Change*, 15 (4): 1772-1796. <https://doi.org/10.2166/wcc.2024.592>
- IPCC. 2021. *Climate Change 2021: The Physical Science Basis*. Cambridge University Press.
- Kheir, A., A. Elnashar, and A. Mosad. 2023. An improved deep learning procedure for statistical downscaling of climate data. *Heliyon*, 9(7), e18200. <https://doi.org/10.1016/j.heliyon.2023.e18200>
- Nourani, V., K. Khodkar, A. Hosseini Baghanam, S.A. Kantoush, and I. Demir. 2023. Uncertainty Quantification of Deep Learning-Based Statistical Downscaling of Climatic Parameters. *Journal of Applied Meteorology and Climatology*, 62(9): 1223-1242. <https://doi.org/10.1175/JAMC-D-23-0057.1>
- Rana, M.M., S.K. Adhikary, T. Suzuki, and M. Mall. 2025. Multiple GCM-Based Climate Change Projections Across Northwest Region of Bangladesh Using Statistical Downscaling Model. *Climate*, 13(62):1-24. <https://doi.org/10.3390/cli13030062>
- Samadi, S., A.M. Catherine, E. Wilson, and H. Moradkhani. 2013. Uncertainty analysis of statistical downscaling models using Hadley Centre Coupled Model. *Theoretical and Applied Climatology*, 114:673-690. <https://doi.org/10.1007/s00704-013-0844-x>
- Solgi, A., H. Zarei, and S. Marofi. 2022. A new approach to use of wavelet transform for baseflow separation of Karst springs (case study: Gamasiyab spring). *Applied Water Science*, 12(264):1-15. <https://doi.org/10.1007/s13201-022-01782-5>
- Swart, N.C., J.N.S. Cole, V.V. Kharin, M. Lazare, J.F. Scinocca, and et al. 2019. The Canadian Earth System Model version 5 (CanESM5.0.3), *Geoscientific Model Development*, 12: 4823-4873. <https://doi.org/10.5194/gmd-12-4823-2019>
- Trenberth, K.E., A. Dai, R.M. Rassen, and D.B. Parsons. 2003. The changing character of precipitation. *Bulletin of the American Meteorological Society*, 84 (9):1205-1217. <https://doi.org/10.1175/BAMS-84-9-1205>
- Volodin, E.M., E.V. Mortikov, S.V. Kostykin, V.Y. Galin, and et al. 2018. Simulation of the modern climate using the INM-CM48 climate model. *Russian Journal of Numerical Analysis and Mathematical Modelling*, 33(6): 367-374. <https://doi.org/10.1515/rnam-2018-0032>
- Vörösmarty, C.J., P. Green, J. Salisbury, B. Richard, and R.B. Lammers. 2000. Global Water Resources: Vulnerability from Climate Change and Population Growth. *Science*, 289(5477): 284-288. <https://doi.org/10.1126/science.289.5477.284>



Williams, K.D., D. Copsey, E.W. Blockley, and et al. 2018. The Met Office Global Coupled Model 3.0 and 3.1 (GC3.0 and GC3.1) configurations. *Journal of Advances in Modeling Earth Systems*, 10(2): 357-380. <https://doi.org/10.1002/2017MS001115>

Wu, T., Y. Lu, Y. Fang, and et al. 2019. The Beijing Climate Center Climate System Model (BCC-CSM): the main progress from CMIP5 to CMIP6. *Geoscientific Model Development*, 12: 1573-1600. <https://doi.org/10.5194/gmd-12-1573-2019>

Yukimoto, S., H. Kawai, T. Koshiro, and et al. 2019. The Meteorological Research Institute Earth System Model version 2.0 (MRI-ESM2.0): Description and basic evaluation of the physical component. *Journal of the Meteorological Society of Japan*, 97(5): 931-965. <https://doi.org/10.2151/jmsj.2019-051>