

An evaluation of the impact of exponential downscale input parameters with artificial intelligence method for estimation of hydrological parameters, case study: Ardabil Synoptic Station

Negar Einnollahzadeh¹, Atabak Feizi^{2*}, Farnaz Daneshvar Vousoughi³

¹ Msc in Civil Engineering, Water Resource Management and Engineering, Department of Civil Engineering, University of Mohaghegh Ardabili, Ardabil, Iran

² Associate Professor, Department of Civil Engineering, Faculty of Engineering, University of Mohaghegh Ardabili, Ardabil, Iran

³ Assistant Professor, Department of Civil Engineering, Islamic Azad University, Ardabil Branch, Ardabil, Iran

Received: 02 June 2022

Accepted: 27 August 2022

Extended abstract

Introduction

In recent years, factors such as the growth of industrial activities and environmental destruction have led to an increase in greenhouse gases, resulting in disruption of the climate balance known as climate change. The negative impact of this phenomenon on various systems, such as water resources, agriculture and industry, has raised concerns in human society. Consequently, addressing the issue of climate change regarding water resources has become one of the primary causes of concern today. Climate change and its effects pose significant challenges to water and energy resource management, necessitating thorough investigation and developing plans to mitigate its impact on water resources. This study aims to identify the region's most suitable climate change model and assess the effectiveness of artificial intelligence methods in studying the climate change phenomenon.

Materials and methods

One of the most reliable approaches for studying the parameters influencing hydrological phenomena under climate change is atmospheric general circulation models. To employ these models on a regional scale, downscaling operations are necessary. Given the large number of parameters derived from Earth's General Circulation Models (GCMs), selecting the most influential parameters is essential before proceeding with the exponential downscaling process. In this study, the meteorological and hydrological parameters of the Ardabil synoptic station were determined using 25 models from the fifth series of the IPCC report. The linear correlation coefficient between monthly precipitation and observed temperature with the output of GCM was used to identify the most appropriate model among the reviewed models. Artificial Neural Network (ANN) was also utilized to downscale the GCMs output. Before employing the neural network, the linear correlation coefficient, the standard information function, and the M5 decision tree were used to identify the most suitable input parameters from the parameters of the best GCMs in the region, to obtain an ideal and optimal network.

Results and discussion

This research investigated 25 models from the fifth series of the IPCC report to explore the uncertainty of GCMs. The results indicated that three models-MRI-CGCM3, CMCC-CMS, and MPI-ESMMR-demonstrated the most suitable correlation coefficients at the Ardabil synoptic station. The findings related to determining the most appropriate input parameters for exponential downscaling, using three methods: linear correlation coefficient, standard information function, and M5 decision tree, revealed that the decision tree algorithm

* Corresponding author: a_feizi@uma.ac.ir

provided the most suitable parameters. Moreover, the results obtained from the downscale analysis using the neural network with the variables selected by the decision tree method exhibited the excellent performance of this approach in selecting the effective input parameters of the neural network. Specifically, using the selected parameters of the MRI-CGCM3 model as input for the neural network as a downscaling method yielded better outcomes. The results obtained using the selected parameters of the MRI-CGCM3 model indicated that for the precipitation parameter, the values of the Determination Coefficient (DC), Root Mean Square Error (RMSE), and Correlation Coefficient (CC) for the test data were 0.39, 0.04, and 0.63, respectively. For the temperature parameter, the values of DC, RMSE, and CC for the test data of the superior model were 0.9, 0.03, and 0.95, respectively.

Conclusion

The performance of exponential downscaling networks is determined by the climatic conditions of the region. The superiority of a particular model in one study cannot be regarded as a valid argument for selecting that model for all regions. It is advisable to utilize different models of the general earth circulation within the region to identify an optimal model. Conducting such studies can assist researchers in investigating various hydrological phenomena that may occur in the future, which may have irreparable consequences.

Keywords: Artificial neural network, Correlation coefficient, Decision tree, GCM models, Mutual information

Cite this article: Einnollahzadeh, N., Feizi, A., Daneshvar Vousoughi, F., 2023. An evaluation of the impact of exponential downscale input parameters with artificial intelligence method for estimation of hydrological parameters, case study: Ardabil Synoptic Station. *Watershed Engineering and Management* 15 (3), 438-451.

© 2023, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>).



تأثیر پارامترهای ورودی ریزمقیاس‌نمایی با روش هوش مصنوعی در تخمین پارامترهای هیدرولوژیکی، مطالعه موردی: ایستگاه سینوپتیک اردبیل

نگار عین‌اله زاده^۱، اتابک فیضی^{۲*} و فرناز دانشور وثوقی^۳

^۱ کارشناسی ارشد مهندسی عمران، مهندسی و مدیریت منابع آب، دانشکده فنی مهندسی، دانشگاه محقق اردبیلی، اردبیل، ایران

^۲ دانشیار، گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه محقق اردبیلی، اردبیل، ایران

^۳ استادیار گروه مهندسی عمران، دانشگاه آزاد اسلامی، واحد اردبیل، اردبیل، ایران

تاریخ پذیرش: ۱۴۰۱/۰۶/۰۵

تاریخ دریافت: ۱۴۰۱/۰۳/۱۲

چکیده مبسوط

مقدمه

در سال‌های اخیر، مواردی از قبیل رشد فعالیت‌های صنعتی، از بین رفتن محیط زیست و غیره، منجر به افزایش گازهای گلخانه‌ای و برهم خوردن تعادل اقلیمی شده است که این پدیده با عنوان تغییر اقلیم یاد می‌شود. تأثیر منفی این پدیده در سامانه‌های مختلفی همچون منابع آب، کشاورزی، صنعت و غیره، موجب نگرانی‌هایی برای جوامع بشری شده است. بنابراین، یکی از علت‌های اصلی نگرانی‌های امروزه، بحث تغییر اقلیم در ارتباط با منابع آب است. تغییر اقلیم و آثار آن، یکی از مهمترین چالش‌های مدیریت منابع آب و انرژی است که باید به‌صورت جدی بررسی شود و برنامه‌ریزی‌هایی به‌منظور مقابله با آثار آن بر منابع آب صورت گیرد. هدف از این پژوهش، یافتن مناسب‌ترین مدل تغییر اقلیم برای منطقه و ارزیابی کارایی روش‌های هوش مصنوعی در بررسی پدیده تغییر اقلیم است.

مواد و روش‌ها

یکی از معتبرترین روش‌ها، برای بررسی پارامترهای موثر بر پدیده‌های هیدرولوژیکی تحت تأثیر تغییرات اقلیم، استفاده از مدل‌های گردش عمومی جو (GCM) است. برای استفاده از این مدل‌ها در مقیاس منطقه‌ای، نیاز به انجام عملیات ریزمقیاس‌نمایی است. قبل از انجام فرایند ریزمقیاس‌نمایی، به‌علت تعداد زیاد پارامترهای حاصل از مدل‌های گردش عمومی زمین، ابتدا باید موثرترین پارامترها از میان آن‌ها انتخاب شود. در این پژوهش، برای تعیین پارامترهای هواشناسی و هیدرولوژیکی ایستگاه سینوپتیک اردبیل، از ۲۵ مدل سری پنجم گزارش IPCC، استفاده شد. برای تعیین مدل برتر از میان مدل‌های بررسی شده، از شاخص ضریب همبستگی خطی بین مقادیر ماهانه بارش و دمای مشاهداتی با خروجی مدل‌های GCM استفاده شد. همچنین، برای ریزمقیاس‌نمایی خروجی مدل‌های GCM، از شبکه عصبی مصنوعی استفاده شد. قبل از به‌کارگیری شبکه عصبی، برای رسیدن به یک شبکه ایده‌آل و بهینه، مناسب‌ترین پارامترهای ورودی به شبکه از میان پارامترهای مدل‌های GCM برتر منطقه، با استفاده از ضریب همبستگی خطی، تابع اطلاعات مشترک و درخت تصمیم M5، بررسی و انتخاب شدند.

نتایج و بحث

در این پژوهش، برای بررسی عدم قطعیت مدل‌های GCM، ۲۵ مدل از سری پنجم IPCC، مورد بررسی قرار گرفتند. نتایج بیانگر آن بود که سه مدل MRI-CGCM3، CMCC-CMS و MPI-ESMMR، مناسب‌ترین ضرایب همبستگی را در ایستگاه سینوپتیک اردبیل ارائه می‌کنند. نتایج حاصل برای تعیین مناسب‌ترین پارامترهای ورودی، به‌منظور ریزمقیاس‌نمایی با استفاده

از سه روش ضریب همبستگی خطی، تابع اطلاعات مشترک و درخت تصمیم M5 نشان داد که الگوریتم درخت تصمیم، مناسبترین پارامترها را برای منطقه مورد نظر ارائه می‌کند. همچنین، نتایج حاصل از ریزمقیاس‌نمایی با شبکه عصبی با استفاده از متغیرهایی که با روش درخت تصمیم انتخاب شدند، عملکرد مناسب این روش را در انتخاب پارامترهای موثر ورودی شبکه عصبی نشان داد. به طوری که پارامترهای انتخاب شده مدل MRI-CGCM3، به عنوان ورودی شبکه عصبی در روش ریزمقیاس‌نمایی پاسخ‌های بهتری را ارائه داده است. نتایج به دست آمده با استفاده از پارامترهای انتخاب شده مدل MRI-CGCM3 نشان داد که در پارامتر بارش، مقدار DC، RMSE و CC برای داده‌های آزمون، به ترتیب ۰/۳۹، ۰/۰۴ و ۰/۶۳ به دست آمده و در پارامتر دما، مقدار DC، RMSE و CC برای داده‌های آزمون مدل برتر، به ترتیب ۰/۹، ۰/۰۳ و ۰/۹۵ بوده است.

نتیجه‌گیری

عملکرد شبکه‌های ریزمقیاس‌نمایی، به شرایط اقلیمی منطقه وابسته است. برتری یک مدل در یک پژوهش، نمی‌تواند یک استدلال صحیح برای انتخاب آن مدل در تمامی مناطق باشد. بهتر است برای دست‌یابی به یک مدل بهینه، از مدل‌های متنوع گردش عمومی زمین در منطقه استفاده شود. انجام چنین پژوهش‌هایی، می‌تواند پژوهشگران را برای بررسی پدیده‌های مختلف هیدرولوژیکی که ممکن است در آینده رخ دهد و عواقب جبران‌ناپذیری داشته باشد، کمک شایانی کند.

واژه‌های کلیدی: تابع اطلاعات مشترک، درخت تصمیم، شبکه عصبی مصنوعی، ضریب همبستگی خطی، مدل‌های GCM

مقدمه

های گردش عمومی جو^۴، یکی از معتبرترین مدل‌ها برای شبیه‌سازی متغیرهای اقلیمی هستند (Miao et al., 2013). مدل‌های GCM، برای شبیه‌سازی در مقیاس قاره‌ای طراحی شده‌اند، بنابراین، نمی‌توان به طور مستقیم در مطالعات منطقه‌ای استفاده کرد. این مدل‌ها به علت وضوح کم در حدود ۵۰۰۰۰ کیلومتر مربع (۱۵۰ تا ۳۰۰ کیلومتر) و عدم توانمندی در حل مشکل‌های ریزمقیاس شبکه، همچون ابر، تبخیر و توپوگرافی، برای پژوهش بر روی مقیاس‌های محلی دچار محدودیت می‌شوند. به همین دلیل، باید خروجی حاصل از این مدل‌ها به مقیاس محلی و منطقه‌ای تبدیل شوند که به این فرایند ریزمقیاس‌نمایی گفته می‌شود (Mora et al., 2014).

محققان مختلفی، به بررسی مدل‌های GCM برای مناطق مختلف پرداخته‌اند و از انواع روش‌های ریزمقیاس‌نمایی استفاده کرده‌اند. (Hamidi et al., 2015). در مدلسازی نوسانات بارش در مقیاس ماهانه از ماشین بردار پشتیبان^۵ و شبکه عصبی مصنوعی^۶ در همدان استفاده کردند. با ارزیابی ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا مشخص شد که مدل SVM از

طی دو دهه اخیر، تغییر اقلیم به علت اثرات قابل ملاحظه بر روی جوامع انسانی و محیط زیست، به عنوان یک دغدغه برای محققان تبدیل شده است. تغییر اقلیم، می‌تواند به دلیل نیروهای خارجی همچون تشعشعات خورشیدی، فوران آتشفشانی و نیروهای داخلی همچون، افزایش گازهای گلخانه‌ای و تغییر کاربری اراضی باشد (IPCC, 2014). پیش‌بینی‌ها حاکی از آن است که تا سال ۲۱۰۰ میلادی، دمای کره زمین به مقدار ۱/۸ تا چهار درجه سانتی‌گراد افزایش خواهد داشت (Gudmundsson et al., 2021).

یکی از اصلی‌ترین سازمان‌های فعال در این زمینه، هیئت بین‌الدول تغییر اقلیم^۱ است. گزارش پنجم این سازمان در سال ۲۰۱۳ با عنوان AR5^۲ یا CMIP5^۳ منتشر شد. مدل‌های اقلیمی برای ارزیابی تغییرات متنوع آب و هوایی مدلسازی شده‌اند که ویژگی‌های مختلفی مانند چرخش و حرکات اتمسفر و خصوصیات فیزیکی را بررسی می‌کنند. از بین مدل‌های مختلف اقلیمی، مدل

¹ Intergovernmental Panel on Climate Change (IPCC)

² Fifth Assessment Report

³ Coupled Model Intercomparison Project

⁴ General Circulation Models (GCM)

⁵ Support Vector Machines (SVM)

⁶ Artificial Neural Networks (ANN)

های شمالی و جنوبی کاهش و در بخش‌های مرکزی، افزایش خواهد داشت.

Alizadeh et al., (2020) به محاسبه شاخص خشکسالی در ایستگاه سینوپتیک اردبیل، تحت اثر تغییر اقلیم پرداختند. برای این منظور، از مدل اقلیمی HADGEM2-ES تحت سناریوهای RCP2.6, 4.5, 8.5 با به‌کارگیری نرم‌افزار LARS-WG، به‌عنوان روش ریزمقیاس‌نمایی داده‌های اقلیمی استفاده شد. نتایج به‌دست آمده نشان داد، تحت سناریوهای RCP در بازه زمانی آینده، تداوم خشکسالی اتفاق خواهد افتاد. Javaherian et al., (2021) برای پیش‌بینی پارامترهای اقلیمی در حوزه آبخیز سد لار از مدل ریزمقیاس‌نمایی SDSM^۳ استفاده کردند. نتایج حاصل با مقایسه آماره‌های R² و RMSE نشان داد که مدل SDSM برای ریزمقیاس‌نمایی قابل قبول است. در ادامه با استفاده از خروجی مدل CANESM2 و تحت سه سناریوی انتشار RCP8.5, 4.5, 2.6، پارامترهای هواشناسی پیش‌بینی شد. نتایج نشان داد که میانگین دما در منطقه ۱/۰۱ تا ۱/۱۲ و بارش ۲۱/۲۳ درصد افزایش می‌یابد.

Kia et al., (2021) به ریزمقیاس‌نمایی پارامترهای هواشناسی در حوزه آبخیز هراز، واقع در مازندران با روش SDSM پرداختند که با استفاده از مدل CANESM2 در گزارش سری پنجم IPCC طی دوره ۲۰۲۰-۲۰۷۹، پارامترهای هواشناسی را پیش‌بینی کردند. در نهایت، نتایج نشان آن‌ها داد، دما نسبت به دوره پایه، افزایش و مقدار بارش کاهش خواهد داشت. (Khezri et al., 2022). به بررسی اثرات تغییر اقلیم بر خشکسالی در دریاچه ارومیه پرداختند. بدین منظور، از مدل‌های تغییر اقلیمی GCM و ریزمقیاس‌نمایی با LARS-WG^۴ استفاده شد. نتایج پیش‌بینی طبق سناریوهای RCP نشان داد که مقدار دما در آینده افزایش خواهد داشت و خشکسالی‌ها متأثر از تغییرات اقلیم بوده است، به‌گونه‌ای که در دوره‌های آتی، ۴۶ تا ۴۸ درصد ماه‌ها در افق‌های مختلف، خشک خواهند بود. همچنین، نتایج حاصل از سری زمانی شاخص‌ها نشان داد که در طی دوره آماری مورد بررسی، حداقل ۴۰ درصد ماه‌ها خشک خواهد بود.

مدل ANN، عملکرد بهتری داشت. (Pattnayak et al., 2017)، بارش و دمای سالانه را در کشورهای بنگلادش، بوتان، هند، نپال، سریلانکا و دو کشور از آسیای جنوب شرقی شامل میانمار و تایلند، با استفاده از خروجی مدل‌های سری پنجم پیش‌بینی کردند. نتایج آن‌ها نشان داد، برخی از مدل‌های انتخابی، بارندگی را افزایش و برخی کاهش پیش‌بینی می‌کنند ولی در پارامتر دما، خروجی تمام مدل‌ها افزایش دما را پیش‌بینی کردند. همچنین، مقدار افزایش بارش و دما در سناریوی RCP8.5، نسبت به RCP4.5 بیشتر به‌دست آمد.

Asakereh and Hesami (2019) به ریزمقیاس‌نمایی پارامترهای دمای بیشینه و کمینه در ایستگاه اصفهان، با مدل آماری SDSM و شبکه عصبی مصنوعی پرداختند. نتایج حاصل از شبیه‌سازی نشان داد، شبکه عصبی مصنوعی نسبت به مدل آماری SDSM، نتایج قابل قبول‌تری را ارائه می‌دهد و عملکرد بهتری داشته است. (Dehghani et al., 2017). در پیش‌بینی جریان رودخانه کشکان واقع در استان لرستان از مدل‌های SVM، GP^۱ و شبکه بیزین^۲ استفاده کردند. نتایج آن‌ها نشان داد که مدل SVM، نسبت به سایر مدل‌ها دارای عملکرد بهتری است.

Sabziparvar and Khoshhal Jahromi (2018) به شبیه‌سازی و پیش‌بینی مقدار دمای کمینه با استفاده از مدل رگرسیونی و مدل شبکه عصبی پرسپترون چند لایه در چهار ایستگاه رشت، همدان، کرمان و شیراز پرداختند. نتایج نهایی نشان داد که شبکه عصبی مصنوعی، کارایی بهتری نسبت به مدل رگرسیونی در پیش‌بینی دمای کمینه از خود نشان داده است. (Goodarzi and Choobeh 2019)، کارایی یک روش رگرسیونی چند متغیره و مدل مولد آب و هوایی را در ریزمقیاس‌نمایی مقادیر بارش و دما، در ایستگاه سینوپتیک اردبیل بررسی کردند. نتایج حاصل نشان داد، مدل‌های مولد آب و هوایی نسبت به مدل‌های رگرسیونی عملکرد بهتری در ریزمقیاس‌نمایی دارند. (Almazroui et al., 2020)، داده‌های ۲۸ مدل از سری ششم GCM را برای منطقه آفریقا بررسی کردند. نتایج حاصل از پیش‌بینی مقادیر بارش و دما در آینده نشان داد، متوسط دما، افزایش و مقدار بارش در بخش

³ Statistical Downscaling Model

⁴ Long Ashton Research Station Weather Generator

¹ Genetic Programming

² Bayesian network

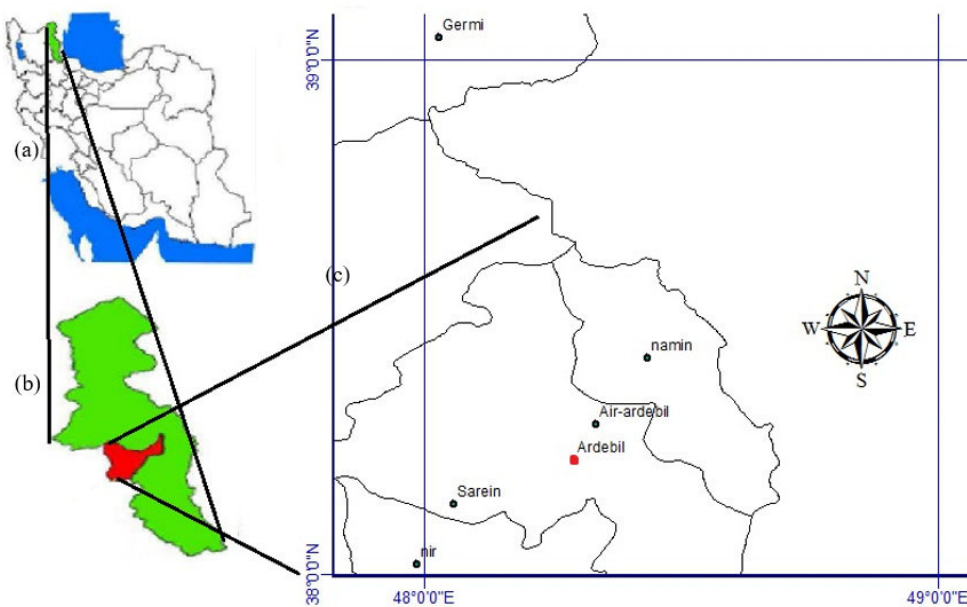
می‌شود. در این منطقه، ایستگاه سینوپتیک اردبیل در مختصات جغرافیایی با طول $48^{\circ}29'$ شرقی و عرض $38^{\circ}22'$ شمالی قرار دارد. موقعیت جغرافیایی منطقه مورد مطالعه موجب شده است که در فصل‌های سرد سال، تحت توده‌های هوایی مهاجر از سمت شمال، شمال غرب و غرب قرار گیرد. در فصل تابستان نیز، گاهی سامانه‌های کم‌فشار باران‌زا بر این منطقه تاثیر گذاشته است و بارندگی‌های تابستانه را در این منطقه باعث می‌شود.

بخش‌های شرقی منطقه مورد مطالعه، به‌صورت محسوس تحت تاثیر اقلیم خزری بوده است و بر شرایط دمایی و رطوبتی آن اثر می‌گذارد و موجب تعدیل در آب و هوا می‌شود. ویژگی مشترک اقلیم‌های منطقه، ویژگی سردی است که ناشی از تاثیر توده‌های سرد شمالی، ارتفاع و عرض جغرافیایی است. میانگین دمای روزانه در ایستگاه مورد مطالعه، 11 درجه سانتی‌گراد و متوسط تبخیر سالیانه، 70 میلی‌متر است. همچنین، میزان نزولات جوی سالیانه در حوضه به‌طور متوسط از 250 تا 400 میلی‌متر در نوسان است (Feizi and Aghajani, 2021). در شکل ۱، محدوده مورد مطالعه و محل ایستگاه سینوپتیک اردبیل نشان داده شده است.

با توجه به پژوهش‌های بررسی شده، بیشتر مطالعات تنها بر روی استفاده از یک مدل اقلیمی تمرکز داشته و انتخاب مناسب‌ترین مدل تغییر اقلیمی برای منطقه مورد نظر، کمتر مورد توجه قرار گرفته است. در این پژوهش، در ابتدا به تعیین مناسب‌ترین مدل‌های اقلیمی از میان مدل‌های GCM سری پنجم در ایستگاه سینوپتیک اردبیل، با استفاده از روش ضریب همبستگی خطی پرداخته شد. سپس، ریزمقیاس‌نمایی با شبکه عصبی مصنوعی که از نوع روش‌های آماری است، انجام شد. از آنجایی که تعداد پارامترهای مدل‌های GCM زیاد است، بنابراین، در این پژوهش برای انتخاب پارامترهای موثر ورودی در ریزمقیاس‌نمایی با شبکه عصبی مصنوعی، برای ایجاد یک شبکه بهینه با خطای کمتر، از روش‌های ضریب همبستگی خطی، تابع اطلاعات مشترک و درخت تصمیم (Decision tree) M5 استفاده شد.

مواد و روش‌ها

منطقه مطالعاتی: منطقه مطالعاتی در این پژوهش، شهر اردبیل در استان اردبیل که در شمال غربی ایران واقع شده است و حدود یک درصد از مساحت ایران را شامل



شکل ۱- موقعیت منطقه مورد مطالعه، الف: ایران، ب: استان اردبیل ج: حوزه آبخیز بالیخلوچای به همراه ایستگاه‌های سینوپتیک منطقه

Fig. 1. The location of the study area A: Iran, B: Ardabil Province, C: Balikhlochay Watershed along with synoptic stations of the region

ماهانه استفاده شد. مدل‌هایی که بیشترین مقادیر ضریب همبستگی را داشتند، به‌عنوان مناسب‌ترین مدل‌های اقلیمی برای منطقه انتخاب شدند. در جدول ۱، مشخصات ۲۵ مدل GCM استفاده شده در این پژوهش به همراه نام مدل و دقت آن‌ها به تفکیک آورده شده است.

معرفی مدل‌های مورد استفاده: در این پژوهش، برای انتخاب مدل مناسب اقلیمی از میان ۲۵ مدل GCM گزارش سری پنجم، از روش ضریب همبستگی خطی بین مقادیر دما و بارش مشاهداتی (ایستگاه سینوپتیک اردبیل) با مقادیر به‌دست آمده از مدل‌های GCM در مقیاس

جدول ۱- مدل‌های GCM استفاده شده در این پژوهش (<https://esgf-node.llnl.gov>)

Table 1. GCM models used in this study (<https://esgf-node.llnl.gov>)

Model	Resolution accuracy (latitude×longitude, degrees)
Can Esm2	2.8×2.8
CMCC-CM	0.75×0.74
Cmcc-cms	3.7×3.7
Cmcc-cesm	3.7×3.7
CNRM-CM5	1.5×1.5
CSIRO-MK3.6.0	1.9×1.9
FGOALS-S2	2.8×2.8
GFDL-ESM2M	2×2.5
HADCM3	2.7×3.7
HADGEM2-AO	2.7×3.7
HADGEM2-CC	2.7×3.7
HADGEM2-ES	2.7×3.7
INMCM4	1.5×2
IPSL-CM5A-LR	3.7×1.9
IPSL-CM5A-MR	3.7×1.9
IPSL-CM5B-LR	3.7×1.9
MIROC5	2.8×2.8
MIROC-ESM-CHEM	2.8×2.8
MIROC4H	2.8×2.8
MIROC-ESM	2.8×2.8
MPI-ESM-LR	1.86×1.87
MPI-ESM-MR	1.86×1.87
MPI-ESM-P	1.86×1.87
MRI-CGCM3	1.121×1.125
MRI-ESM1	1.121×1

در این رابطه، X_n داده‌های نرمال شده، X_i داده‌های ورودی، X_{min} و X_{max} به‌ترتیب مقادیر کمینه و بیشینه در بین داده‌های ورودی هستند.

روش‌های به‌کار رفته در انتخاب پارامترهای موثر ورودی با شبکه عصبی مصنوعی به‌عنوان روش ریزمقیاس‌نمایی: تعداد پارامترهای مدل‌های GCM، بسیار زیاد است و به‌طور تقریبی، برای هر مدل بیش از ۵۰ متغیر وجود دارد. اگر از تمام این متغیرها به‌عنوان ورودی شبکه عصبی به‌عنوان ریزمقیاس‌نمایی استفاده شود، باعث ابهام، ضعف و کاهش دقت در شبکه خواهد شد. از این رو، برای ایجاد شبکه بهینه و مطلوب، بهترین روش، انتخاب موثرترین پارامترهای ورودی شبکه هستند (Rajaei et al., 2011). در این پژوهش، برای انتخاب موثرترین پارامترهای مدل‌های انتخاب شده GCM، از روش‌های تابع اطلاعات مشترک، ضریب همبستگی خطی و درخت تصمیم M5، استفاده شد.

آماده‌سازی داده‌ها: در این پژوهش، از دو سری داده استفاده شده است. سری اول، داده‌های هواشناسی ایستگاه سینوپتیک اردبیل در بازه ۲۰۰۵-۱۹۷۶ است که از سازمان هواشناسی استان اردبیل تهیه شد. سری دوم، داده‌های مدل گردش عمومی جو GCM، در مقیاس ماهانه بوده است که برای دانلود داده‌های مدل‌ها از سایت <https://esgf-node.llnl.gov/search/cmip5> در سال ۲۰۲۰، با عنوان ESGF استفاده شد. پس از دریافت داده‌های GCM، برای تبدیل داده‌های دانلود شده که با فرمت nc هستند، از نرم‌افزار ArcGIS10.3 استفاده شد. از آن-جایی که استفاده از داده‌ها به‌صورت خام، باعث کم کردن سرعت و دقت شبکه می‌شود، بدین منظور، قبل از استفاده از داده‌های دانلود شده، همه داده‌ها با استفاده از رابطه (۱) نرمال شدند (Alvisi et al., 2006).

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

یک درخت تصمیم شامل چهار ساختار ریشه، شاخه، گره و برگ است. با توجه به این که این روش گرافیکی است، تفسیر نتایج از سایر روش‌های طبقه‌بندی ساده‌تر است. مدل M5، با ارائه توابع خطی چندگانه و سود بردن از مزایای روش‌های خطی، شرایط بینابینی توابع خطی و غیرخطی را نمایان می‌سازد (Nourani et al., 2019). برای ایجاد یک مدل درخت تصمیم، اولین اقدام استفاده از معیار تقسیم است. معیار تقسیم عبارت است از، به بیشینه رساندن مقدار کاهش انحراف استاندارد در هر طبقه داده‌ای است که در هر گره به دست آمده است. کاهش انحراف استاندارد از طریق رابطه‌های (۶) و (۷) به دست می‌آیند (Alberg et al., 2012).

$$SDR = Sd(T) - \frac{T_i}{N} Sd(T_i) \quad (6)$$

$$Sd(T) = \sqrt{\frac{1}{N} (y_i^2 - \frac{1}{N} (y_i)^2)} \quad (7)$$

در رابطه‌های بالا، T مجموعه‌ای از داده‌های ورودی به هر گره، T_i زیرمجموعه داده‌های ورودی به هر گره، Sd انحراف معیار، y_i مقدار عددی هر کدام از داده‌ها و N بیانگر شماره داده‌ها است. تقسیم کردن در این مبنای اغلب به یک درخت بزرگ منجر می‌شود. از این رو، مرحله بعدی در مشخص کردن درخت مدل، جمع کردن درخت و یا به عبارت بهتر، هرس شاخه‌ها و جایگزینی با توابع رگرسیونی است. در این پژوهش، برای اعمال روش درخت تصمیم از نرم‌افزار WEKA^۳ استفاده شد (Alberg et al., 2012).

نحوه انجام ریزمقیاس‌نمایی با استفاده از شبکه

عصبی مصنوعی: بیش از ۹۰ درصد شبکه‌های عصبی مصنوعی به کار رفته در بحث‌های مربوط به مهندسی آب، از نوع الگوریتم پس انتشار خطا هستند. شبکه عصبی پرسپترون چند لایه، برای تابع انتقال در لایه پنهان، از تابع محرک تانژانت سیگموئید و در لایه خروجی از تابع محرکه خطی استفاده می‌کند و الگوریتم به کار رفته در آن، تابع لونیبرگ مارکوات^۴ است (Amirabadizadeh et al., 2018). در این پژوهش، نیز از شبکه عصبی مصنوعی از نوع پرسپترون چند لایه با الگوریتم آموزشی لونیبرگ مارکوات استفاده شده است و ۷۵ درصد از داده‌ها به عنوان

تابع اطلاعات مشترک^۱: تابع اطلاعات مشترک، جز معیار نظارت شده است که در این نوع، معیار بر پایه رابطه میان ورودی و خروجی مدل تشریح می‌شود. تابع اطلاعات مشترک از رابطه (۲) به دست می‌آید.

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \quad (2)$$

در این رابطه، X و Y دو متغیر تصادفی و $H(X, Y)$ آنترپی مشترک X و Y هستند. لازم به توضیح است که $H(X)$ و $H(Y)$ با استفاده از رابطه (۳) محاسبه می‌شوند. همچنین، $H(A/B)$ آنترپی (محتوای اطلاعاتی) مشترک A به شرط B نامیده می‌شود و تعریف آن به صورت رابطه (۴) است (Yang et al., 2000).

$$H(X) = H(P) = - \sum_{i=1}^N p(x_i) \log[p(x_i)] \quad (3)$$

$$H(X/Y) = - \sum_{a \in A, b \in B} p(a, b) \log p(A/B) \quad (4)$$

که در آن‌ها، $H(X)$ آنترپی X و یا تابع آنترپی شانون، $P = \{p_i, i=1, \dots, N\}$ توزیع احتمال است که به صورت $P = \{p_i, i=1, \dots, N\}$ تعریف می‌شود.

ضریب همبستگی خطی^۲: دومین روش استفاده شده برای انتخاب پارامتر مناسب، استفاده از ضریب همبستگی خطی است. ضریب همبستگی خطی، جز آزمون‌های آماری محسوب می‌شود که نمایانگر درجه رابطه خطی بین دو متغیر است. ضریب همبستگی جز معیارهای نظارت شده محسوب می‌شود. روند به کار رفتن این روش مانند تابع اطلاعات مشترک است. دامنه ضریب همبستگی بین یک تا -۱ متغیر است. ضریب همبستگی خطی از رابطه (۵) به دست می‌آید.

$$R = CC = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{(\sum_{i=1}^N (X_i - \bar{X})^2) (\sum_{i=1}^N (Y_i - \bar{Y})^2)}} \quad (5)$$

در این رابطه، X_i و Y_i به ترتیب داده‌های مشاهداتی و شبیه‌سازی شده هستند (Razzaghzadeh و همکاران، 2020). تفاوت اصلی بین ضریب همبستگی و تابع اطلاعات مشترک این است که ضریب همبستگی ماهیتی خطی ولی تابع اطلاعات مشترک ماهیتی غیرخطی دارد. به عبارتی، می‌توان اظهار کرد که تابع اطلاعات مشترک رابطه غیرخطی بین دو متغیر تصادفی را بازگو می‌کند. **درخت تصمیم:** درخت تصمیم، یک ابزار توانا در طبقه‌بندی و پیش‌بینی در بحث داده‌کاوی است. در حالت کلی،

³ Waikato Environment for Knowledge Analysis

⁴ Levenberg-Marquardt algorithm

¹ Mutual Information (MI)

² Correlation Coefficient (CC)

نتایج و بحث

با توجه به مقادیر به‌دست آمده از جدول ۲، مشاهده می‌شود که نتایج حاصل از مدل‌های GCM برای پارامتر بارش از همبستگی پایین‌تری برخوردار است. علت این امر را می‌توان تصادفی‌تر و دوره‌ای بودن سری‌های زمانی بارش به نسبت دما بیان کرد. نتیجه‌ای مشابه در کار پژوهشی انجام شده به‌وسیله Razzaghzadeh and Nourani (2019) نیز بیان شده است. مدل‌های برتر که بیشترین مقدار همبستگی را بین مقادیر دما و بارش مشاهداتی و مدل‌های GCM دارند، طبق جدول ۲، انتخاب شدند. مدل‌های CMCC-CMS، MPI-ESMMR و MRI-CGCM3 به‌ترتیب با مقادیر CC، ۰/۳۵۸۱، ۰/۳۲۱۹ و ۰/۳۳۳۸ برای پارامتر بارش و مقادیر ۰/۹۲۴۴، ۰/۹۲۴۵ و ۰/۹۲۸۲ برای پارامتر دما، انتخاب شدند.

داده‌های آموزشی و ۲۵ درصد، به‌عنوان داده‌های آزمون در نظر گرفته شدند.

معیارهای ارزیابی شبکه عصبی استفاده شده: برای ارزیابی دقت و کارایی شبکه عصبی به‌دست آمده از سه روش ضریب تبیین (DC)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی خطی (CC) در مرحله آموزش و صحت‌سنجی استفاده شد که از معادله‌های (۸) و (۹) به‌دست می‌آیند (Nourani et al., 2009).

$$DC = 1 - \frac{\sum_{i=1}^n (O_i - S_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (8)$$

$$RMSE = \frac{\sum_{i=1}^n (S_i - O_i)^2}{n} \quad (9)$$

در روابط بالا، مقدار مشاهداتی، S_i مقدار محاسباتی، n تعداد داده‌های مورد مطالعه، \bar{O} و \bar{S} مقدار میانگین مقادیر مشاهداتی و محاسباتی در دوره مورد نظر هستند.

جدول ۲- مقادیر ضریب همبستگی برای مدل‌های GCM

Table 2. Values of the correlation coefficients for the GCM models

Model	CC	
	Precipitation	Temperature
CMCC-CESM	0.1018	0.9245
CMCC-CM	0.2991	0.9153
CMCC-CMS	0.3581	0.9244
CNRM-CM5	0.2777	0.9100
CSIRO-Mk3-6-0	0.1105	0.6900
CanESM2	0.1328	0.7178
GFDL-ESM2M	0.3050	0.7654
HadCM3	0.0991	0.5096
HadGEM2-AO	0.0559	0.5510
HadGEM2-CC	0.0569	0.5742
HadGEM2-ES	0.0509	0.5753
Inmcm4	0.0841	0.0079
IPSL-CM5A-LR	0.1173	0.7954
IPSL-CM5A-MR	0.1625	0.7677
IPSL-CM5B-LR	0.2198	0.7652
MIROC5	0.1325	0.7641
MIROC-ESM-CHEM	0.3151	0.9080
MIROC4H	0.2218	0.9033
MPI-ESM-LR	0.3129	0.9221
MPI-ESM-MR	0.3119	0.9245
MPI-ESM-P	0.2753	0.9247
MRI-CGCM3	0.3338	0.9282
MRI-ESM1	0.2461	0.9244
MIROC-ESM	0.2141	0.7196
FGOALS-s2	0.2170	0.9165

مشترک برای هر سه مدل منتخب در جدول ۳، ارائه شده است. در این جدول، علامت اختصاری و توصیف پارامترهای موثر بیان شده است. در ادامه، برای هر دو متغیر بارش و دما برای هر سه مدل انتخابی به صورت مجزا، پارامترهای منتخب بر اساس هر سه روش MI، CC و درخت تصمیم M5 در جدول ۴، ارائه شده است.

ارزیابی موثرترین پارامترهای ورودی به شبکه عصبی مصنوعی: برای انتخاب پارامترهای موثر ورودی شبکه عصبی به عنوان روش ریزمقیاس‌نمایی از سه روش MI، CC و درخت تصمیم M5، در بین مقادیر نرمال شده دما و بارش ایستگاه سینوپتیک اردبیل با پارامترهای مدل‌های منتخب GCM، در مقیاس ماهانه استفاده شد. مهمترین پارامترهای حاصل از این روش‌ها، به صورت

جدول ۳- نام اختصاری پارامترهای موثر برگزیده مدل‌های منتخب (<https://esgf-node.llnl.gov>)

Table 3. Abbreviation of the selected effective parameters of the selected models (<https://esgf-node.llnl.gov>)

Parameter abbreviation	Parameter description
Eastward near-surface wind	uas
Zonal wind	ua
Atmosphere mass content of cloud ice	Clivi
Air temperature	ta
Near surface air temperature	tas
Daily maximum near-surface air temperature	tasmax
Daily minimum near-surface air temperature	tasmin
Sea surface temperature	ts
near surface air temperature	tas
Total cloud cover percentage	clt
Air pressure at convective cloud base	ccb
Mass fraction of cloud liquid water	clw
Condensed water path	clwvi
Air pressure at convective cloud top	cct
Cloud area fraction	cl
relative humidity	Hur
Specific humidity	Hus
Surface upward sensible heat flux	hfss
Near surface specific humidity	huss
Surface upwelling longwave flux in air	rlus
Downwelling shortwave flux	rsds
Surface downwelling longwave flux in air assuming clear sky	rldsces
Surface upwelling shortwave radiation	rsus
Surface downwelling clear-sky shortwave radiation	rsdsces
TOA outgoing clear-sky shortwave radiation	rsutces
Geopotential height	zg
Precipitation	pr
Atmosphere water vapor content	prw
Mole fraction of O ₃	Tro3

جدول ۴- پارامترهای موثر تعیین شده با روش‌های MI، CC و درخت تصمیم M5

Table 4. Effective parameters determined by CC, MI and M5 decision trees

	CMCC-CMS			MRI-CGCM3			MPI-ESMMR		
	CC	MI	M5	CC	MI	M5	CC	MI	M5
Precipitation	ta100	ta850	clwvi	clt	uas	cct	hur250	zg250	clw
	clivi	clivi	rlus	clwvi	hur250	cl	ta100	rldsces	hfss
	clt	zg250	ta250	ccb	rlus	Hur10	clt	clivi	hur10
	hur500	ta	ts	clivi	ta500	huss	hur500	ua10	ta500
	hur250	ta500	ua250	ta100	rsds	rlus	clivi	rsus	tasmin
	pr	tasmax	ua500	hur500	tasmin	sfcwind	pr	ta700	-----
	ts	cct	hur50	tasmin	hur250	hus10	rldsces	rldsces	hur100
	zg50	clt	hus850	ts	uas	hur700	tasmin	zg250	hus50
Temperature	tas	clivi	hur 250	rldsces	rlus	ts	tas	zg	rsdsces
	rlus	zg250	ta10	rlus	prw	zg50	ta850	ua10	rsutces
	tasmin	ta850	ua50	Tasmax	ta500	zg700	ta	tro3	tro3
	ta850	ta500	ua700	ta500	tasmin	----	rlus	rsus	ta

مصنوعی: برای رسیدن به یک نتیجه بهینه در عملکرد شبکه عصبی مصنوعی، عملکرد ورودی‌های انتخاب شده با

ارزیابی عملکرد روش‌های MI، CC و درخت تصمیم M5 در تعیین مناسب‌ترین ورودی‌های شبکه عصبی

بنابراین، در حالت کلی برای هر سه مدل برتر، در شبیه‌سازی پارامترهای هیدرولوژیکی منطقه با استفاده از شبکه عصبی مصنوعی به‌عنوان روش ریزمقیاس‌نمایی، ورودی‌های انتخاب شده با استفاده از روش درخت تصمیم M5 عملکرد مناسبی داشته است. شایان ذکر است که اختلاف نتایج ارائه شده به‌وسیله درخت تصمیم و روش تابع اطلاعات مشترک قابل توجه نبوده است. به این علت که نتایج حاصل از روش CC، نسبت به دو روش دیگر، عملکرد کمتری داشته است و در ادامه فرایند ریزمقیاس‌نمایی فقط از نتایج دو روش درخت تصمیم و MI استفاده شد.

سه روش استخراج مشخص به‌کار رفته در این پژوهش، ارزیابی شد. بررسی کارایی MI، CC و درخت تصمیم M5، در انتخاب موثرترین پارامترهای ورودی شبکه عصبی مصنوعی به‌عنوان روش ریزمقیاس‌نمایی برای پارامتر بارش و دما در جدول ۵، به‌عنوان نمونه برای مدل MRI-CGCM3 ارائه شده است. طبق نتایج به‌دست آمده از جدول ۵، مشاهده می‌شود که برای هر دو متغیر بارش و دما، ورودی‌های انتخاب شده با روش درخت تصمیم M5، نسبت به دو روش دیگر، منجر به نتایج بهتر در ریزمقیاس‌نمایی شده است.

جدول ۵- نتایج حاصل از شبیه‌سازی مقادیر بارش و دما با شبکه عصبی مصنوعی برای مدل MRI-CGCM3

Table 5. The results of precipitation and temperature simulations using an artificial neural network for the MRI-CGCM3 model

Variable	Characteristic extraction method	Input(t)	epoch	Network structure	Output	CC		RMSE		DC	
						Train	Test	Train	Test	Train	Test
Precipitation	CC	Clf, chwvi, ccb, clivi, ta100, hur 500	260	1-3-6	Pr(t)	0.61	0.56	0.11	0.05	0.37	0.31
	MI	Uas, hur 250, rlus, ta500, rsds, tasmin	160	1-4-6	Pr(t)	0.71	0.63	0.09	0.05	0.50	0.38
	M5	hus10, hur 700, ts, zg50, zg700	300	1-4-5	Pr(t)	0.67	0.65	0.11	0.04	0.40	0.39
Temperature	CC	Tasmin, ts, rldscs, rlus, tasmax, ta500	280	1-3-6	Tas(t)	0.94	0.95	0.05	0.03	0.89	0.87
	MI	Hur250, uas, rlus, prw, ta500, tasmin	290	1-5-6	Tas(t)	0.95	0.95	0.05	0.03	0.91	0.88
	M5	Hus10, hur700, ts, zg50, zg700	170	1-10-6	Tas(t)	0.96	0.95	0.053	0.03	0.92	0.90

جریان آموزش شبکه عصبی هنگامی متوقف شد که کمترین مقدار خطا در ارزیابی داده‌های مرحله اعتبارسنجی به‌دست آمد. نتایج ریزمقیاس‌نمایی با شبکه عصبی مصنوعی برای سه مدل CESM-CMS، MPI-ESMMR و MRI-CGCM3، در جدول ۶، برای پارامترهای بارش و دما آورده شده است.

در حالت کلی، طبق جدول ۶، مشاهده می‌شود که نتایج به‌دست آمده از هر دو روش درخت تصمیم M5 و تابع اطلاعات مشترک قابل قبول و نشان از عملکرد مناسب هر دو روش است. اما نتایج روش درخت تصمیم M5، تا حدودی بهتر از روش تابع اطلاعات مشترک است. طبق جدول ۶، مشاهده می‌شود در بررسی پارامتر بارش، مدل MRI-CGCM3 دارای بیشترین مقدار DC را به میزان ۰/۳۹، برای داده‌های آزمون نسبت به دو مدل دیگر دارد و نتایج بهتری ارائه کرده است. برای سایر معیارهای ارزیابی نیز نتیجه مشابهی به‌دست آمده و مدل MRI-

نتایج ریزمقیاس‌نمایی با شبکه عصبی مصنوعی: در این پژوهش، از شبکه عصبی مصنوعی برای ریزمقیاس‌نمایی پارامترهای مدل‌های GCM، استفاده شده است. با توجه به مراحل قبل، پنج تا شش ورودی با روش‌های MI و درخت تصمیم M5 به‌عنوان ورودی‌های برتر شبکه عصبی انتخاب شدند. برای مدلسازی شبکه، از کدنویسی در نرم‌افزار متلب استفاده شده است. شبکه استفاده شده از نوع پرسپترون پیش‌تغذیه‌شونده سه لایه، شامل لایه ورودی، یک لایه پنهان و لایه خروجی است. برای به‌دست آوردن بهترین نتیجه برای شبکه، از آزمون و خطا استفاده شد. از تابع تانژانت سیگموئید به‌دلیل نگاشتن اطلاعات از سمت لایه ورودی به سمت لایه پنهان استفاده شد. ۷۵ درصد از داده‌ها، به‌عنوان داده‌های آموزش و ۲۵ درصد از داده‌ها، برای مرحله آزمون انتخاب شدند. الگوریتم آموزشی به‌کار رفته در این پژوهش، لونیبرگ مارکوات است.

تست بهتر از سایر مدل‌ها عمل کرده است. نتایج مطالعات قبلی نیز موید نتایج حاصل از این پژوهش در استفاده از ریزمقیاس‌نمایی با شبکه عصبی مصنوعی بوده است (Ahmadi Rezaee et al., 2018؛ Omidvar et al., 2018؛ Baseri et al., 2014).

CGCM3 عملکرد بهتری نسبت به دو مدل دیگر داشته است. بنابراین، این مدل برای شبیه‌سازی با شبکه عصبی مصنوعی برای بررسی پارامتر بارش به‌عنوان برترین مدل انتخاب شد. برای پارامتر دما نیز طبق جدول ۶، مدل MRI-CGCM3 با مقادیر DC به مقدار ۰/۹ برای داده‌های

جدول ۶- مقایسه نتایج مدل‌های منتخب منطقه برای پیش‌بینی پارامترهای دما و بارش

Table 6. Comparison of the results of selected regional models for the prediction of temperature and precipitation parameters

Variable	Model	Input(t)	Epoch	Network structure*	output	CC		RMSE		DC	
						Train	Test	Train	Test	Train	Test
Precipitation (MI)	CMCC-CMS	Ta850,clivi,zg250,ta,ta500,tasmax	220	1-2-6	Pr(t)	0.69	0.56	0.11	0.11	0.48	0.28
	MPI-ESMMR	Zg250,rldscs,clivi,ua10,rsus,ta700	260	1-3-6	Pr(t)	0.60	0.56	0.11	0.05	0.35	0.30
	MRI-CGCM3	Uas,hur250,rhus,ta500,rlds, tasmin	160	1-4-6	Pr(t)	0.71	0.63	0.09	0.05	0.50	0.38
Temperature (MI)	CMCC-CMS	Cct, clt, clivi, zg250,ta850,ta500	270	1-4-6	Tas(t)	0.94	0.94	0.11	0.11	0.89	0.88
	MPI-ESMMR	Rldscs,zg250,zg, ua10, tro3, rsus	240	1-2-6	Tas(t)	0.95	0.93	0.05	0.04	0.92	0.82
	MRI-CGCM3	Hur250,uas,rhus,prw,ta500,tasmin	290	1-5-6	Tas(t)	0.95	0.95	0.05	0.03	0.91	0.88
Precipitation (Decision tree)	CMCC-CMS	Clwvi,rhus,ta250,ts,ua250,ua500	180	1-3-6	Pr(t)	0.61	0.56	0.10	0.05	0.38	0.29
	MPI-ESMMR	Clw,hfss,hur10,ta500,tasmin	120	1-4-5	Pr(t)	0.55	0.54	0.11	0.05	0.30	0.29
	MRI-CGCM3	Cct,cl,hur10,huss,rhus,sfcwind,	300	1-4-6	Pr(t)	0.64	0.63	0.11	0.04	0.40	0.39
Temperature (Decision tree)	CMCC-CMS	Hur50,hus850,hus250,ta10,ua50,ua700	290	1-7-6	Tas(t)	0.97	0.92	0.05	0.04	0.94	0.82
	MPI-ESMMR	Hur100,hus50,rldscs,rsutcs,tro3,ta,	220	1-10-6	Tas(t)	0.98	0.94	0.03	0.03	0.96	0.84
	MRI-CGCM3	Hus10,hur700,ts,zg50,zg700	170	1-10-5	Tas(t)	0.96	0.95	0.05	0.03	0.92	0.90

نتیجه‌گیری

با توجه به یافته‌های به‌دست آمده در این پژوهش، می‌توان بیان کرد که نتایج حاصل از بررسی ۲۵ مدل سری پنجم IPCC برای منطقه مورد مطالعه با استفاده از روش ضریب همبستگی نشان داد که مدل‌های CMCC-CMS، MRI-CGCM3 و MPI-ESMMR، به‌عنوان مدل‌های برتر با بیشترین ضریب همبستگی برای دما و بارش ایستگاه سینوپتیک منطقه مطالعاتی هستند.

در بررسی کارایی سه روش CC، MI و درخت تصمیم M5، برای تعیین بهترین پارامترهای ورودی شبکه عصبی به‌عنوان روش ریزمقیاس‌نمایی، نتایج حاصل از شبیه‌سازی با شبکه عصبی مصنوعی نشان از عملکرد مناسب درخت

تصمیم M5، نسبت به دو روش دیگر در انتخاب پارامتر موثر ورودی بود و نهایتاً پنج تا شش پارامتر موثر برای هر یک از متغیرهای بارش و دما انتخاب شدند. در نتیجه، برای فرایند ریزمقیاس‌نمایی با شبکه عصبی، بهترین نتیجه از ورودی‌های تعیین شده با روش درخت تصمیم M5، به‌دست آمد، هر چند که اختلاف قابل ملاحظه‌ای با روش MI وجود نداشت.

نتایج حاصل از ریزمقیاس‌نمایی با استفاده از شبکه عصبی مصنوعی نشان داد که این روش قادر است، مقادیر پارامترهای دما و بارش را با تقریب قابل قبولی شبیه‌سازی کند. مقایسه نتایج حاصل از ریزمقیاس‌نمایی با شبکه عصبی مصنوعی نشان داد که از بین مدل‌های منتخب،

معنوی آن‌ها تشکر و قدردانی می‌کنند.

مدل MRI-CGCM3، دارای نتایج بهتری برای شبیه‌سازی پارامترهای دما و بارش منطقه است و به‌عنوان برترین مدل از سری پنجم برای منطقه انتخاب شد.

تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مساله مورد تایید همه نویسندگان است.

تشکر و قدردانی

نویسندگان این پژوهش، از اداره کل هواشناسی استان اردبیل و دانشگاه محقق اردبیلی برای حمایت‌های مالی و

منابع مورد استفاده

- Ahmadi Baseri, N., Shirvani, A., Nazemosadat, M.J., 2014. The application of ANN for downscaling GCMs outputs for prediction of precipitation in across Southern Iran. *J. Soil Water Conserv.* 28(5), 1037-1047 (in Persian).
- Alberg, D., Last, M., Kindle, A., 2012. Knowledge discovery in data streams with regression tree methods. *WIREs Data Mining Knowl. Discov.* (2), 69-78.
- Alizadeh, M., Gorbani, M., Darbandi, S., 2020. The effect of climate change on the severity and duration of meteorological drought under the LARS-WG model, case study: Ardabil Synoptic Station. *Proceedings of 9th National Conference on Rainwater Catchment Systems*, University of Tabriz, Tabriz, Iran.
- Almazroui, M., Saeed, F., Saeed, S., Islam, M.N., Ismail, M., Klutse, N.A.B., Siddiqui, M.H., 2020. Projected change in temperature and precipitation over Africa from CMIP6. *Earth Syst. Environ.* 4(3), 455-475.
- Alvisi, S., Mascellani, G., Franchini, M., Bardossy, A., 2006. Water level forecasting through fuzzy logic and artificial neural network approaches. *Hydrol. Earth Syst. Sci.* 10, 1-17.
- Amirabadizadeh, M., Nazeri Tahroudi, M., Zeynali, M.J., 2018. Evaluation of the accuracy of artificial intelligence and regression models for the simulation of daily temperature. *J. Meteor. Atmos. Sci.* 1(1), 65-76 (in Persian).
- Asakereh, H., Hesami, N., 2019. Assessing the application of artificial neural networks and SDSM models to simulate the minimum and maximum temperatures at Isfahan station. *J. Geophys. Res. Desert Areas* 7(2), 133-158 (in Persian).
- Dehghani, R., Younesi, H., Torabi Podeh, H., 2017. Comparing the performance of support vector machine, gene expression programming and Bayesian networks in predicting river flow, case study: Kashkan River. *Water Soil Conserv.* 24(4), 161-177 (in Persian).
- ESGF, 2020. Earth system grid federation. <https://esgf-node.llnl.gov/search/cmip5/> (accessed 25 April 2020).
- Feizi, A., Aghajani Jomayran, R., 2021. Allocation and management of water resources in the Yamchi Dam Basin with scenario analysis approach using WEAP model. *J. Environ. Sci. Technol.* 23(9), 89-107 (in Persian).
- Goodarzi, M., Choobeh, S., 2019. Assessment of downscaling methods in predicting climatic parameters under climate change status: a case study in Ardabil Synoptic Station. *Iran-Watershed Manag. Sci. Engin.* 13(45), 63-69 (in Persian).
- Gudmundsson, L., Boulange, J.D.O.X., Gosling, S.N., Grillakis, M.G., Koutroulis, A.G., Zhao, F., 2021. Globally observed trends in mean and extreme river flow attributed to climate change. *Science* 371(6534), 1159-1162.
- Hamidi, O., Poorolajal, J., Sadeghifar, M., Abbasi, H., Maryanaji, Z., Faridi, H., Tapak, L., 2015. A comparative study of support vector machines and artificial neural networks for predicting precipitation in Iran. *Theor. Appl. Climatol.* 119(3), 723-731.
- IPCC, 2014. Summary for policymakers, In: *Climate Change 2014: Impacts, Adaptation, and Vulnerability, Part A: Global and Sectoral Aspects*. Cambridge University Press, Cambridge, United Kingdom and New York.
- Javaherian, M., Ebrahimi, H., Aminnejad, B., 2021. Prediction of changes in climatic parameters using CanESM2 model based on RCP scenarios, case study: Lar Dam Basin. *Ain Shams Eng. J.* 12(1), 445-454.
- Khezri, F., Irandoust, M., Jalalkamali, N., Yazdanpanah, N., 2022. Modeling and bivariate analysis of meteorological drought using data generation with climate change approach, case study: Lake Urmia. *J. Soil Water Conserv.* 11(2), 49-68 (in Persian).
- Kia, E., Karimi, V., 2021. Investigation of temperature and rainfall parameters of Haraz River Basin affected by climate change. *J. Nat. Environ. Hazards* 26(9), 145-160 (in Persian).
- Miao, C.Y., Duan, Q.Y., Sun Q.H., Li, G.D., 2013. Evaluation and application of Bayesian multi-model estimation in temperature simulations. *Prog. Phys. Geogr.* 37(6), 727-744.

- Mora, D.E., Campozano, L., Cisneros, F., Wyseure, G., Willems, P., 2014. Climate changes of hydrometeorological and hydrological extremes in the Paute Basin, Ecuadorean Andes. *Hydrol. Earth Syst. Sci.* (18), 631–648.
- Nourani, V., Komasi, M., Mano, A., 2009. A multivariate ANN wavelet approach for rainfall–runoff modeling. *Water Resour. Manag.* 23(14), 2877-2894.
- Nourani, V., Razzaghzadeh, Z., Baghanam, A.H., Molajou, A., 2019. ANN-based statistical downscaling of climatic parameters using decision tree predictor screening method. *Theor. Appl. Climatol.* 137(3), 1729-1746.
- Omidvar, E., Rezaei, M., Pirnia, A., 2018. Performance evaluation of artificial neural network models for downscaling and predicting of climate variables. *J. Watershed Manag. Res.* 9(18), 80-90 (in Persian).
- Pattnayak, K.C., Kar, S.C., Dalal, M., Pattnayak, R.K., 2017. Projections of annual rainfall and surface temperature from CMIP5 models over the BIMSTEC countries. *Glob. Planet. Change* 152, 152-166.
- Rajaei, T., Nourani, V., Zounemat-Kermani, M., Kisi, O., 2011. River suspended sediment load prediction: application of ANN and wavelet conjunction model. *J. Hydrol. Eng.* 16(8), 613-627.
- Razzaghzadeh, Z., Nourani, V., Hosseini baghanam, A., 2020. Application of mutual information feature extraction methods in statistical downscaling for investigation of climate change effects on Tabriz precipitation. *J. Environ. Sci. Technol.*, in Press (in Persian).
- Rezaee, M., Nahtaj, M., Moghadamniya, A., Abkar, A., Rezaee, M., 2015. Comparison of artificial neural network and SDSM methods in the downscaling of annual rainfall in the HadCM3 modelling, case study: Kerman, Ravar and Rabor. *Water Resour. Engin. J.* 8(24), 25-40 (in Persian).
- Sabziparvar, A., F. Khoshhal Jahromi. 2018. Comparison of multi-layer perceptron artificial neural network and Linacre regression model performance for predicting daily minimum temperature (case study: Kerman, Shiraz, Rasht and Hamedan). *Iranian Journal of Geophysics*, 12(3):121-107, (in Persian)
- Yang, H. H., S.V. Vuuren, S. Sharma and H. Hermansky. 2000. Relevance of time-frequency features for phonetic and speaker-channel classification. *Speech Communication*, 31(1): 35-50.