



## Investigating the Effects of Climate Change on Temperature and Precipitation Using Neural Network and CMIP6 (Case Study: Aleshtar and Khorramabad Stations)

Moein Iranshahi<sup>1</sup> | Behrouz Ebrahimi<sup>2</sup> | Hossein Yousefi<sup>3</sup> | Ali Moridi<sup>4</sup>

1. Department of Water Science and Engineering, Faculty of Agriculture, Bu Ali Sina University, Hamadan, Iran. E-mail: [moeinir73@gmail.com](mailto:moeinir73@gmail.com)
2. Planning Deputy of the Regional Water Company of Lorestan Province, Iran. E-mail: [b.ebrahimi@lsrw.ir](mailto:b.ebrahimi@lsrw.ir)
3. Department of Water Resources Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran. E-mail: [ho\\_yousefi@sbu.ac.ir](mailto:ho_yousefi@sbu.ac.ir)
4. Corresponding Author, Department of Environmental Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran. E-mail: [a\\_moridi@sbu.ac.ir](mailto:a_moridi@sbu.ac.ir)

### Article Info

#### Article type:

Research Article

#### Article history:

Received: 04 August 2022

Received in revised form:

18 September 2022

Accepted: 24 September 2022

Published online:

25 December 2022

#### Keywords:

CMIP6,  
FFA,  
FFNN,  
SSP.

### ABSTRACT

The purpose of this research is to evaluate the effects of climate change on temperature, precipitation, and future droughts in Al-Shatar and Khorramabad stations, for this purpose, the output of the general circulation model MRI-ESM2 according to the latest IPCC report (sixth report) and the emission scenarios SSP 1.2.6, SSP 2.4.5, SSP 3.7.0 and SSP 5.8.5 were used in these study areas. Using the decision tree model (M5 Tree), the most dominant predictor variables of the MRI-ESM2 model were selected. Next, the predictor variables were included as input in the advanced artificial neural network (FFNN) statistical microscale model and with the firefly optimization algorithm (FFA), the process of the exponential micro-scale of precipitation parameters, maximum temperature, and minimum temperature for the base period (1970-2014) was carried out with favorable results in the studied stations. After proving the capability of the neural network model, forecasting the average temperature and monthly precipitation changes during the near future periods (2023-2023) and the distant future (2063-2100) were carried out under the scenarios of the joint socio-economic trajectories (SSP) related to the coupled model of the sixth phase (CMIP6). In general, the results showed that these variables in both future periods on a monthly scale will have several fluctuations, so that in the two stations of Aleshtar and Khorramabad, during the periods of the near future and the distant future, the maximum temperature, and the minimum temperature will have an increasing trend compared to the observation period in all SSP scenarios, and the minimum temperature changes compared to the maximum temperature will be higher in the near future. The annual rainfall of Aleshtar station will decrease between 0.3 Percent and 16 Percent and Khorramabad station between Seven percent and 12 Percent under SSP scenarios. In the distant future, the average annual precipitation of Aleshtar station will decrease between 10-20 Percent and Khorramabad station between 12-24% under SSP scenarios.

**Cite this article:** Iranshahi, M., Ebrahimi, B., Yousefi, H., & Moridi, A. (2022). Investigating the Effects of Climate Change on Temperature and Precipitation Using Neural Network and CMIP6 (Case Study: Aleshtar and Khorramabad Stations). *Journal of Water and Irrigation Management*, 12 (4), 821-845.

DOI: <http://doi.org/10.22059/jwim.2022.346796.1009>





## بررسی اثرات تغییر اقلیم بر وضعیت دما و بارش با استفاده از شبکه عصبی و گزارش ششم IPCC (مطالعه موردی: ایستگاه‌های الستر و خرم‌آباد)

معین ایرانشاهی<sup>۱</sup> | بهروز ابراهیمی<sup>۲</sup> | حسین یوسفی<sup>۳</sup> | علی مریدی<sup>۴</sup>

۱. گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران. رایانامه: [moeinir73@gmail.com](mailto:moeinir73@gmail.com)

۲. شرکت آب منطقه‌ای استان لرستان، ایران. رایانامه: [b.abrahimi@lsrw.ir](mailto:b.abrahimi@lsrw.ir)

۳. گروه مهندسی منابع آب، دانشکده عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: [ho\\_yousefi@sbu.ac.ir](mailto:ho_yousefi@sbu.ac.ir)

۴. گروه مهندسی منابع آب، دانشکده عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: [a\\_moridi@sbu.ac.ir](mailto:a_moridi@sbu.ac.ir)

### اطلاعات مقاله

### چکیده

نوع مقاله: مقاله پژوهشی

هدف از این پژوهش ارزیابی اثرات تغییر اقلیم بر دما، بارش و خشکسالی‌های آینده در ایستگاه‌های الستر و خرم‌آباد می‌باشد، که به این منظور از خروجی مدل گردش عمومی MRI-ESM2 مطابق جدیدترین گزارش IPCC (گزارش ششم) و سناریوهای انتشار SSP 1.2.6، SSP 2.4.5، SSP 3.7.0 و SSP 5.8.5 در این مناطق مطالعاتی استفاده شد. با کاربرد مدل درخت تصمیم (M5 Tree)، غالب‌ترین متغیرهای پیش‌بینی‌کننده مدل MRI-ESM2 انتخاب شدند. در ادامه متغیرهای پیش‌بینی‌کننده به‌عنوان ورودی در مدل ریزمقیاس‌نمایی آماری شبکه عصبی مصنوعی پیشرو (FFNN) قرار گرفتند و با الگوریتم بهینه‌سازی کرم‌شب‌تاب (FFA)، فرایند ریزمقیاس‌نمایی پارامترهای بارش، دمای حداکثر و دمای حداقل برای دوره پایه (۱۹۷۰-۲۰۱۴) با نتایج مطلوب انجام شد. پس از اثبات قابلیت مدل شبکه عصبی، پیش‌بینی تغییرات متوسط دما و بارش ماهانه در طی دوره‌های آینده نزدیک (۲۰۲۳-۲۰۶۲) و آینده دور (۲۰۶۳-۲۱۰۰) تحت سناریوهای خط سیرهای مشترک اجتماعی-اقتصادی (SSP) مربوط به مدل جفت‌شده فاز ششم (CMIP6) به انجام رسید. به‌طور کلی، نتایج نشان داد که این متغیرها در هر دو دوره آتی در مقیاس ماهانه دارای نوسان‌های متعددی خواهند بود، به‌طوری‌که در دو ایستگاه الستر و خرم‌آباد طی دوره‌های آینده نزدیک و آینده دور دمای حداکثر و دمای حداقل نسبت به دوره مشاهداتی در تمام سناریوهای SSP روندی افزایشی خواهند داشت و تغییرات دمای حداقل نسبت به دمای حداکثر بیش‌تر خواهد بود. در آینده نزدیک میانگین بارش سالانه ایستگاه الستر بین سه دهم تا ۱۶ درصد و ایستگاه خرم‌آباد بین هفت تا ۱۲ درصد تحت سناریوهای SSP کاهش خواهد داشت. در آینده دور نیز میانگین بارش سالانه ایستگاه الستر بین ۱۰ تا ۲۰ درصد و ایستگاه خرم‌آباد بین ۱۲ تا ۲۴ درصد تحت سناریوهای SSP کاهش خواهد داشت.

### کلیدواژه‌ها:

CMIP6  
FFA  
FFNN  
SSP

استناد: ایرانشاهی، م، ابراهیمی، ب، یوسفی، ج، و مریدی، ع (۱۴۰۱). بررسی اثرات تغییر اقلیم بر وضعیت دما و بارش با استفاده از شبکه عصبی و گزارش ششم IPCC (مطالعه موردی: ایستگاه‌های الستر و خرم‌آباد). نشریه مدیریت آب و آبیاری، ۱۲ (۴)، ۸۲۱-۸۴۵.

DOI: <http://doi.org/10.22059/jwim.2022.346796.1009>



## ۱. مقدمه

از دهه ۱۹۰۰ میلادی، میانگین جهانی غلظت گازهای گلخانه‌ای به سرعت افزایش یافته است که منجر به تغییر در ویژگی‌های متغیرهای اقلیمی و وقوع بیش‌تر رویدادهای حدی می‌شود (Almazroui et al., 2020). با توجه به این افزایش غلظت گازهای گلخانه‌ای و روند گرمایش جهانی، پیش‌بینی می‌شود که تغییرات اقلیمی بر منابع آب و ویژگی‌های هیدرولوژیک حوضه‌های آبریز تأثیر بگذارد (Kim et al., 2021). هیدرولوژی حوضه تحت تأثیر افزایش دما و تغییر توزیع بارش قرار می‌گیرد و در نتیجه مقدار و در دسترس بودن آب تغییر می‌کند (Aryal et al., 2019). حوادث شدید اقلیمی و تغییرات آن‌ها به‌طور کلی می‌تواند تأثیرات شدیدی بر جامعه و اکوسیستم‌ها بگذارد و هر ساله خسارت‌های اقتصادی زیادی را به بار آورد. در همین راستا مؤسسه بین‌المللی تغییرات اقلیمی (IPCC) در جدیدترین گزارش خود (AR6) به افزایش ریسک خطرات طبیعی هم‌چون خشکسالی و سیلاب که ممکن است در نتیجه تغییرات اقلیمی ایجاد شود، اشاره کرده و هشدار داده است. گزارش ششم ارزیابی تغییر اقلیم (AR6)<sup>۱</sup> که از سال ۲۰۲۱ میلادی در حال ارائه می‌باشد، شامل سه گروه کاری و یک گزارش تلفیقی (SYR)<sup>۲</sup> است که ارزیابی‌های گروه کاری و گزارش‌های ویژه تولیدشده را ادغام می‌کند. آخرین گزارش تلفیقی AR6 (SYR) که در سال ۲۰۲۲ میلادی عرضه شد، شرایط و اقدامات نگه‌داشتن افزایش دمای کره زمین در زیر ۲ درجه سانتی‌گراد را بررسی می‌کند (IPCC, 2020)، بنابراین پیش‌بینی‌های با دقت زیاد از تغییرات آینده به‌ویژه تغییرات در رفتار هیدرولوژیکی برای سیاست‌گذاری و برنامه‌ریزی منابع آب ضروری است تا اطلاعات دقیقی را در راستای سازگاری ارائه دهد.

سناریوهای خط سیرهای مشترک اجتماعی-اقتصادی (SSPs)<sup>۳</sup> گروه جدیدی از سناریوهای انتشار غیراقلیمی ناشی از مدل‌های جفت‌شده فاز ششم تغییر اقلیم (CMIP6)<sup>۴</sup> در راستای گزارش ششم ارزیابی تغییر اقلیم (AR6) می‌باشند. این سناریوها با هدف ارائه پیش‌آگاهی‌هایی در مسیرهای مشترک اجتماعی-اقتصادی عرضه شده‌اند؛ این سناریوها تغییرات جایگزین احتمالی در جنبه‌های اجتماعی مانند عوامل جمعیتی، اقتصادی، فناوری، اجتماعی، حاکمیت و عوامل محیطی را براساس تجزیه و تحلیل‌های یکپارچه‌ای از تأثیرات اقلیمی، آسیب‌پذیری، سیاست‌های مرتبط با سازگاری و تعدیل توصیف می‌کنند (O'Neill, 2016). این مجموعه سناریو امکان کاوش ساختاری تغییر اقلیم را در سطحی سازگار با محدودکردن افزایش میانگین درجه حرارت جهانی در سال ۲۱۰۰ میلادی تا ۱/۵ درجه سانتی‌گراد با احتمال تقریبی ۶۶ درصد فراهم می‌کند (Rogelj et al., 2018). با توجه به پژوهش O'Neill (2017)، SSPها شرایط آبی را براساس پنج رویکرد بنیادین توسعه پایدار (SSP1)، توسعه مبتنی بر سیاست‌های بینابین (SSP2) گسترش رقابت منطقه‌ای (SSP3)، نابرابری (SSP4) و توسعه کاربرد سوخت‌های فسیلی (SSP5) توصیف می‌کنند. SSPها نسبت به سناریوهای RCP گزارش پنجم (AR5) به‌روزتر بوده و در واقع تلفیقی از سناریوهای اقتصادی-اجتماعی با در نظر گرفتن میزان واداشت انرژی تابشی خورشیدی یا همان RCPها در سطح‌های ۲/۶، ۴/۵، ۶/۰ و ۸/۵ وات بر مترمربع ( $W/m^2$ ) می‌باشند؛ سناریوهای SSP در ترکیب با مدل‌های جفت‌شده فاز ششم (CMIP6)، عمل پیش‌بینی را تا سال ۲۱۰۰ میلادی به‌عنوان اهداف بلندمدت اقلیمی به انجام می‌رسانند. میزان واداشت انرژی تابشی خورشیدی در واقع همان اختلاف بین انرژی ورودی و خروجی از جو کره زمین است. در شرایط فعلی، SSPها شامل هفت سناریوی SSP1.1.9، SSP1.2.6، SSP2.4.5، SSP3.7.0 و SSP4.3.4، SSP4.6.0، SSP5.8.5 است.

مدل‌های GCM بهترین ابزار برای بررسی اثرات پدیده تغییر اقلیم بر روی پارامترهای چرخه هیدرولوژیکی می‌باشند. این مدل‌ها سه‌بعدی بوده و قادرند پارامترهای جوی و اقیانوسی را برای یک دوره درازمدت در مقیاس جهانی یا قاره‌ای و با در نظر گرفتن سناریوهای تأییدشده IPCC مدل‌سازی و تولید نمایند (Chen et al., 2019). با توجه به اهمیت تجزیه و

تحلیل عدم قطعیت، ارزیابی و انتخاب GCMها براساس عملکرد آنها در شبیه‌سازی متغیرهای آب‌وهوایی یک روش قابل‌استفاده برای انتخاب بهترین مدل‌ها و کاهش عدم قطعیت‌ها است (Zamani *et al.*, 2020). مدل‌های جفت‌شده فاز ششم (CMIP6)، نسخه‌های به‌روزشده و پیشرفته‌تر مدل‌های گردش عمومی (GCM) در راستای گزارش ششم ارزیابی تغییر اقلیم (AR6) می‌باشند که به‌همراه مجموعه جدیدی از سناریوهای تغییرات غلظت گازهای گلخانه‌ای، در راستای مسیرهای مشترک اجتماعی-اقتصادی (SSP) در بین سال‌های ۲۰۲۰ تا ۲۰۲۱ میلادی منتشر شده‌اند. دوره تاریخی مدل‌های پروژه CMIP6 از ۱۸۵۰ تا ۲۰۱۴ میلادی است (Gidden *et al.*, 2019). قدرت تفکیک ۱/۱ تا ۱/۵ درجه‌ای در مدل‌های GCM وجود دارد و این مشکل تحت عنوان بزرگ‌مقیاس‌بودن خروجی مدل‌های GCM شناخته می‌شود (Xu, 1999; Fischer *et al.*, 2007; Pearson *et al.*, 2008). اگرچه استفاده از به‌روزترین مدل‌های اقلیمی برای مطالعات تأثیر تغییرات اقلیمی بر روی فرایندهای هیدرولوژیکی ترجیح داده می‌شود، اما نباید خروجی خام مدل‌های گردش عمومی (GCM) با وضوح پایین به‌طور مستقیم در مدل‌های هیدرولوژیکی مورد‌استفاده قرارگیرد. زمانی که از مدل‌های GCM برای پیش‌بینی متغیرهای اقلیمی استفاده می‌شود، این مدل‌ها بارش متوسط را در یک مقیاس بزرگ مکانی پیش‌بینی می‌کنند. بزرگ‌بودن مقیاس مکانی شبکه یا سلول‌های محاسباتی مدل‌های GCM نسبت به مختصات محلی ایستگاه هواشناسی در محدوده مورد مطالعه، مسئله‌ای است که داده‌های خروجی مدل‌های GCM با آن مواجه می‌باشند. به‌عبارتی دیگر، مدل‌های گردش عمومی (GCM) بزرگ‌مقیاس بوده و نقطه ضعف عمده این مدل‌ها قدرت تفکیک مکانی و زمانی کم آن‌هاست. در این شرایط، روش معمول این است که تنوع مکانی داده‌های خروجی GCM را با استفاده از روش‌های ریزمقیاس‌نمایی آماری و دینامیکی افزایش داد (Olsson *et al.*, 2017). روش‌های ریزمقیاس‌نمایی به‌عنوان یک عامل ارتباط‌دهنده بین متغیرهای بزرگ‌مقیاس (پیش‌بینی‌کننده‌ها) و متغیرهای اقلیمی در مقیاس محلی و منطقه‌ای (پیش‌بینی شونده‌ها) شناخته می‌شوند و انجام ریزمقیاس‌نمایی بایستی قبل از انجام مطالعات ارزیابی اثرات تغییر اقلیم مورد‌استفاده قرار گیرد (Wilby *et al.*, 2002). به‌عبارتی دیگر، ریزمقیاس‌نمایی روشی است که قدرت تفکیک مدل GCM را با هدف ارزیابی صحیح تغییرات پارامترهای هواشناسی در مقیاس محلی افزایش می‌دهد. جهت تطبیق خروجی مدل‌های GCM با داده‌های مشاهداتی به‌طور کلی از دو روش آماری و دینامیکی استفاده می‌شود. روش‌های ریزمقیاس‌نمایی آماری بیش‌تر از سایر روش‌ها مورد توجه پژوهش‌گران قرار گرفته است. این روش‌ها کاهش مقیاس را مبتنی بر سابقه آماری و پیش‌بینی‌کننده‌های بزرگ‌مقیاس پایه‌ریزی می‌نمایند. برتری اصلی این روش اقتصادی‌بودن، سادگی و سرعت بالا در فرایند ریزمقیاس‌نمایی ناحیه‌ای می‌باشد (Fowler *et al.*, 2007). از معروف‌ترین مدل‌های آماری که برای ریزمقیاس‌نمایی داده‌های اقلیمی استفاده می‌شود، مدل LARS\_WG و SDSM هستند که به‌صورت بسته‌های نرم‌افزاری در اختیار هستند. قابلیت این مدل‌ها در ریزمقیاس‌نمایی متغیرهای دما و بارش توسط پژوهش‌گران مختلف ارزیابی شده است. به‌طور نمونه Dibike and Coulibaly (2006)، دو روش شبکه‌های عصبی مصنوعی و SDSM را به‌منظور ریزمقیاس‌کردن داده‌های بارش و درجه حرارت روزانه در حوضه ساکوتوری در شمال ایالت کبک کانادا مقایسه کردند و به این نتیجه رسیدند که شبکه عصبی مصنوعی در ریزمقیاس‌نمایی داده‌های بیشینه و کمینه دمای روزانه و هم‌چنین بارش روزانه نسبت به مدل SDSM پیش‌بینی بهتری دارد. Tripathi *et al.* (2006) با مقایسه روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای ریزمقیاس‌نمایی بارش ماهانه در هندوستان، روش ماشین بردار پشتیبان را مناسب دانستند.

Mahdizadeh *et al.* (2011)، اثرات تغییر اقلیم بر میزان بارش را در ایستگاه کریم‌ایشان و رباط‌قربیل در حوضه سد گلستان موردبررسی قرار داده و از مدل ریزمقیاس‌نمایی شبکه عصبی مصنوعی برای پیش‌بینی بارش استفاده کردند.

نتایج ایشان نشان داد که تا سال ۲۱۰۰، میانگین بارش ماهانه در ایستگاه کریم‌ایشان در فصل پاییز و زمستان تا ۴۳ میلی‌متر افزایش و در بهار و تابستان تا ۲۳ میلی‌متر کاهش و در ایستگاه رباط قریبیل در فصل پاییز و زمستان تا ۳۲ میلی‌متر افزایش و در بهار و تابستان تا ۱۱ میلی‌متر کاهش خواهد یافت. *Campozano et al.* (2016)، برای بررسی عملکرد روش‌های ریزمقیاس‌نمایی در مدل‌سازی بارش ماهانه منطقه مورد مطالعه از سه روش ANN (شبکه عصبی مصنوعی)، SVM-LS (حداقل مربعات ماشین بردار پشتیبان) و SDSM (مدل ریزمقیاس‌نمایی آماری) در ریزمقیاس‌نمایی استفاده کردند. نتایج بررسی‌ها نشان داد که در اکثر ماه‌ها مدل ANN و LS-SVM عملکرد بهتری نسبت به مدل SDSM در ریزمقیاس‌کردن بارش ماهانه دارد. *Laddimath et al.* (2019)، با استفاده از تکنیک شبکه عصبی مصنوعی ریزمقیاس‌نمایی آماری را برای داده‌های مربوط به حوضه رودخانه بهیما در هندوستان انجام دادند که نتایج، بیانگر کارایی مدل شبکه عصبی بوده است. طی پژوهشی که در حوضه رودخانه کالی در کلمبیا توسط *Montenegro-Murillo* (2019)، با استفاده از شبکه عصبی مصنوعی بر روی داده‌های RCP انجام گرفت، تغییرات مورد پیش‌بینی تا سال ۲۱۰۰ مطالعه شد و براساس سناریوهای مورد بررسی مشخص شد در سال‌های آتی، بارندگی از مناطق بالایی به مناطق میانی و تحتانی حوضه رودخانه منتقل می‌شود.

در پژوهش‌های انجام‌شده در ایران، امیدوار و همکاران (۱۳۹۷) ریزمقیاس‌نمایی و پیش‌بینی بلندمدت متغیرهای دما و بارش را برای ایستگاه سینوپتیک سیرجان با استفاده از مدل شبکه عصبی مصنوعی انجام دادند که نتایج، بیانگر افزایش میانگین دما تا سال ۲۰۱۹ بوده است. عساگره و غلامی (۱۴۰۰)، در پژوهشی با هدف ریزمقیاس‌نمایی و شبیه‌سازی دمای پیشینه ایستگاه سینوپتیک قزوین با استفاده از روش شبکه عصبی مصنوعی و بهره‌گیری از نرم‌افزار MATLAB پرداختند. نتایج نشان داد که مقادیر شبیه‌سازی‌شده تحت سناریوهای RCP4.5، RCP2.6 و RCP8.5 برای دمای ایستگاه سینوپتیک قزوین تا سال ۲۱۰۰ طی سناریوی RCP 2.6 نسبت به دوره پایه (۲۰۰۵-۱۹۹۱)، حدود ۱/۳ درجه سانتی‌گراد، طبق سناریوی RCP4.5 به میزان ۲/۷ درجه سانتی‌گراد و مطابق سناریوی RCP 8.5 مقدار ۴/۱ درجه سانتی‌گراد افزایش خواهد داشت.

با توجه به هدف این پژوهش، به ذکر مهم‌ترین مطالعات صورت‌گرفته در خصوص اثرات تغییر اقلیم بر بارش و دما و پیش‌بینی آن‌ها پرداخته می‌شود.

*Zhu et al.* (2018) تغییرات دهه‌ای دمای سطح زمین جهانی را با مجموعه مدل‌های CMIP5 مطالعه کردند. نتایج آن پژوهش نشان داد دمای سطح زمین در سطح جهانی از سال ۱۸۶۰ تا ۲۰۱۴ شش مرحله را پشت سر گذاشته است. به غیر از دهه اول ۱۹۰۰، که یک مرحله سرمایشی در دمای سطح زمین دیده شد، در سایر دهه‌ها این روند افزایشی بوده است. *García et al.* (2019) مشخصه‌های دمای هوا و سطح زمین را با شبیه‌سازی‌های تاریخی و آینده ۳۲ مدل CMIP5 در آمریکای شمالی مطالعه کردند. نتایج مطالعات نشان داد دمای سطح زمین که ارتباط تنگاتنگی با الگوهای جوی دارد، در آمریکای شمالی روندی افزایشی داشته است. *Nie et al.* (2020) فرین‌های دمای ماهانه و سطح زمین را با استفاده از نسخه‌های CMIP5 و CMIP6 مدل BCC مقایسه کردند. نتایج آن پژوهش نشان داد نسخه CMIP6 نسبت به نسخه CMIP5 در تغییرپذیری متقابل هر دو فرین گرم و سرد عملکرد بهتری دارد. هم‌چنین در نسخه CMIP6 مدل BCC به دلیل به روزرسانی، طرح‌واره کسر ابر (cloud fraction scheme) مقدار RMSE کم‌تری نسبت به CMIP5 داشته است. *Kasiri et al.* (2020)، برای بررسی چشم‌انداز آینده تغییرات دما و بارش در سواحل جنوبی دریای خزر از مدل جهانی CanESM2 تحت سناریوهای RCP2.6، RCP4.5 و RCP8.5 استفاده کردند. نتایج مطالعه حاکی از افزایش دمای حداقل و حداکثر و هم‌چنین

کاهش بارش برای تمامی ایستگاه‌ها به جز یک ایستگاه در تمامی دوره‌ها می‌باشد. Danandeh Mehr *et al.* (2020)، به بررسی خشکسالی هواشناسی در آنکارا پرداختند. بدین منظور، شاخص‌های بارش استاندارد (SPI) و استاندارد تبخیر و تعرق بارش (SPEI) تحت سناریوهای RCP4.5 و RCP8.5 را پیش‌بینی نمودند. نتایج نشان داد که منطقه مورد مطالعه دو واقعه خشکسالی شدید را در طول دوره مرجع (۱۹۹۱-۲۰۰۰) تجربه نموده است. با این حال، پیش‌بینی‌ها وقایع خشکسالی کم‌تری را برای دوره آینده نزدیک ۲۰۱۶-۲۰۴۰ نشان می‌دهند. با توجه به مقدمه بیان شده و نقش تغییر اقلیم در چرخه هیدرولوژی، هدف از این پژوهش بررسی تأثیر تغییر اقلیم بر میزان بارش و دمای ایستگاه‌های الشتر و خرم‌آباد تحت سناریوهای مختلف SSP در دوره‌های آینده می‌باشد، این ایستگاه‌ها از مهم‌ترین شهرهای موجود در حوضه کشکان بوده که میزان بارش در آن‌ها بر رواناب تولیدی در حوضه نقش به‌سزایی دارد. با توجه به خشکسالی و تنش‌های شدید آبی اخیر در حوضه کشکان و این که تاکنون مطالعات کامل و دقیقی در این حوضه صورت نگرفته، ایستگاه‌های این حوضه در این پژوهش مورد مطالعه قرار گرفته است. به‌طور عمده هدف از مطالعات اقلیمی دستیابی به نحوه تغییرات آب‌وهوایی مناطق مورد مطالعه بوده و همچنین در اکثر پژوهش‌های انجام شده از خروجی سری سوم CMIP3 یا CMIP5 استفاده شده است، اما در این مطالعه هدف بر آن بوده که جدیدترین مدل‌های در دسترس سری ششم (CMIP6) برای مناطق مورد مطالعه سنجیده شود. نتایج این پژوهش می‌تواند میزان تأثیرگذاری تغییر اقلیم را بررسی و برای سازگاری با این شرایط راه کارهای مربوطه را با توجه به حجم قابل توجه بهره‌برداری توسط مدیران اتخاذ کند.

## ۲. مواد و روش‌ها

### ۲.۱. منطقه مورد مطالعه

حوضه آبریز رودخانه کشکان با وسعت ۹۵۰۲/۶۶ کیلومترمربع در ناحیه جنوب غربی ایران واقع شده است. گستره جغرافیایی آن بین مختصات ۴۷ درجه و ۱۲ دقیقه تا ۴۸ درجه و ۵۹ دقیقه شرقی و ۳۳ درجه و ۸ دقیقه تا ۳۴ درجه و ۲ دقیقه شمالی واقع شده است. این حوضه بخش مهمی از سرشاخه‌های پرآب رودخانه کرخه را تشکیل می‌دهد و حدود یک سوم از خاک استان لرستان را در بر می‌گیرد. در تقسیم‌بندی هیدرولوژی ایران، جزیی از حوضه آبریز خلیج فارس به‌شمار می‌رود. این حوضه ۱۸/۵ درصد از مساحت حوضه آبریز بزرگ کرخه را شامل می‌شود. برای پیش‌بینی وضعیت الگوهای آب‌وهوایی منطقه از داده‌های باران‌سنجی و سینوپتیک شهرهای مهم در این حوضه یعنی شهرستان الشتر و مرکز لرستان، شهر خرم‌آباد استفاده شد. ایستگاه الشتر در موقعیت طول جغرافیایی ۴۸ درجه و ۱۲ دقیقه و عرض جغرافیایی ۳۳ درجه و ۴۷ دقیقه قرار دارد و ارتفاع از سطح دریا در این ایستگاه ۱۵۷۰ متر می‌باشد، ایستگاه خرم‌آباد نیز در موقعیت طول جغرافیایی ۴۸ درجه و ۱۷ دقیقه و عرض جغرافیایی ۳۳ درجه و ۲۶ دقیقه قرار دارد در موقعیت ارتفاع از سطح دریا در این ایستگاه ۱۱۴۸ متر می‌باشد. میانگین بارش سالیانه در ایستگاه خرم‌آباد و الشتر به ترتیب ۵۰۹ و ۵۵۰ میلی‌متر بوده و متوسط دمای حداکثر و حداقل ایستگاه خرم‌آباد به ترتیب ۲۵/۰۶ و ۸/۴۸ سانتی‌گراد هم‌چنین در ایستگاه الشتر نیز متوسط دمای حداکثر و حداقل مشاهداتی ۲۲/۱۳ و ۳/۳۱ سانتی‌گراد می‌باشد. در این پژوهش از آمار بلندمدت ماهانه ایستگاه‌های الشتر و خرم‌آباد در یک دوره آماری ۴۴ ساله مربوط به سال‌های ۲۰۱۴-۱۹۷۰ استفاده شده است. شکل (۱) موقعیت ایستگاه‌های الشتر و خرم‌آباد را نمایش می‌دهد.

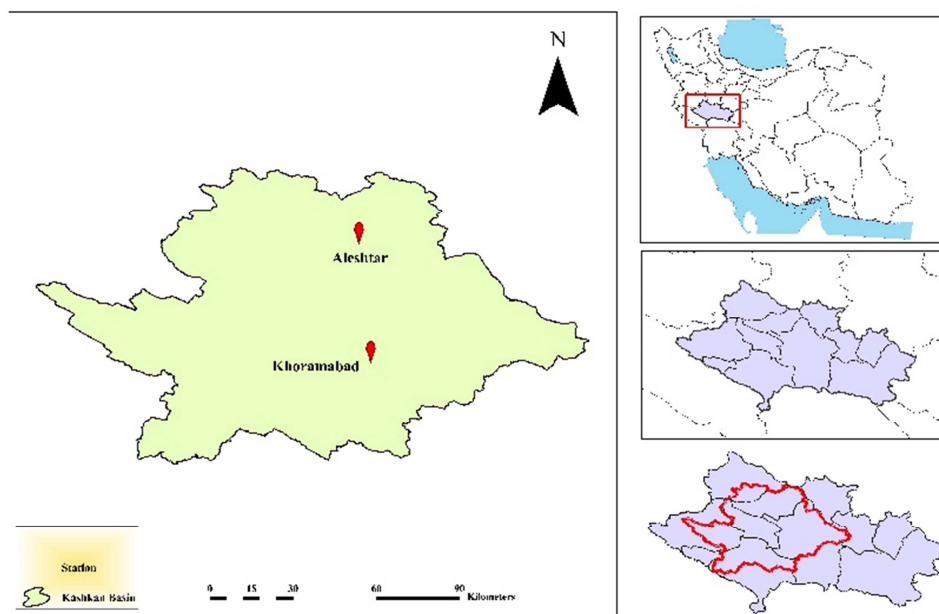


Figure 1. Location of Kashkan watershed and meteorological stations

## ۲.۲ روش تحقیق

### ۲.۲.۱ انتخاب مناسب‌ترین مدل گردش عمومی (GCM) و سناریوهای انتشار

در پژوهش حاضر با توجه به دلایلی هم‌چون تأثیر الگوی آب‌وهوایی غالب در هر منطقه بر روی آب‌وهوای مناطق اطراف، متفاوت بودن قدرت تفکیک جوی مکانی مدل‌های GCM و همچنین عدم توانایی این مدل‌ها در ارائه اطلاعات نقطه‌ای دقیق از ایستگاه زمینی هواشناسی، چهار نقطه با گرید از شبکه مختصات جغرافیایی در دسترس برای هر مدل GCM در اطراف نقطه مختصات ایستگاه سینوپتیک مشاهداتی به نحوی انتخاب شد که این محدوده را محاصره نمایند (point1, point2, point3, point4)؛ به گونه‌ای که در امر ارزیابی عدم قطعیت مدل‌های GCM و ریزمقیاس‌نمایی آماری پارامترهای دما و بارش نقش مؤثری ایفا نماید.

در پژوهش حاضر به جهت انتخاب مناسب‌ترین مدل از میان ۲۲ مدل GCM در راستای کاهش اثر عدم قطعیت کاربرد مدل‌ها در محدوده مورد مطالعه، ابتدا داده‌های ماهانه تاریخی متغیر بارش و دمای مربوط به هر کدام از مدل‌های GCM برای هر چهار نقطه از شبکه انتخاب شده در اطراف حوضه مطالعاتی کشکان از طریق پایگاه ESGF استخراج شد، سپس در محیط نرم‌افزار اکسل بین مقادیر تاریخی مشترک متغیرهای بارش و دمای مشاهداتی ایستگاهی و مدل‌های GCM، ضریب همبستگی پیرسون (PCC) محاسبه شد. با استفاده از ضریب همبستگی پیرسون و بررسی دوره مشاهداتی و دوره تاریخی (۲۰۱۴-۱۹۷۰) مدل‌های گردش عمومی، مدل MRI-ESM2 از مؤسسه تحقیقات هواشناسی ژاپن با توجه به قدرت تفکیک جوی آن (1.1×1.1) هم‌پوشانی بالایی را نسبت به ایستگاه‌های سینوپتیک خرم‌آباد و الشتر به نمایش گذاشت به‌عنوان مدل برتر انتخاب شد، نتایج ضریب همبستگی پیرسون متغیرهای بارش (Pt)، دمای حداقل ( $T_{min}$ ) و دمای حداکثر ( $T_{max}$ ) برای ایستگاه‌های الشتر و خرم‌آباد در جدول‌های (۱) و (۲) ارائه شده است. شکل (۲) نمونه‌ای از نقاط شبکه مدل MRI-ESM2 در اطراف محدوده مطالعاتی را با شماره‌های یک، دو، سه و چهار نمایش می‌دهد. به جهت داشتن ارزیابی صحیح از تغییرات دما و بارش برای دوره‌های آبی مورد پیش‌بینی در محدوده مطالعاتی، بایستی پارامترهای بزرگ‌مقیاس خروجی مدل GCM در محدوده‌ی مقیاس محلی ایستگاه سینوپتیک ریزمقیاس‌نمایی شوند. به‌طور کلی ریزمقیاس‌نمایی آماری منجر به ایجاد یک

رابطه آماری بین متغیرهای بزرگ‌مقیاس (پیش‌بینی‌کننده‌ها) و متغیرهای ایستگاهی با مقیاس کوچک یا محلی (پیش‌بینی‌شونده‌ها) می‌شود. شایان ذکر است، با توجه به شرایط موجود برای مناسب‌ترین مدل GCM انتخاب‌شده (MRI-ESM2)، دوره تاریخی در بازه زمانی ۱۹۷۰-۲۰۱۴ و دوره‌های آبی در بازه‌های زمانی ۲۰۲۳-۲۰۶۲ و ۲۰۶۳-۲۱۰۰ میلادی در نظر گرفته شدند. به جهت انجام امر ریزمقیاس‌نمایی آماری متغیرهای دمای حداکثر، دمای حداقل و بارش، مراحل مختلفی از تحلیل داده‌ها با استفاده از روش‌های مناسب صورت گرفته است که در ذیل بیان می‌شود.

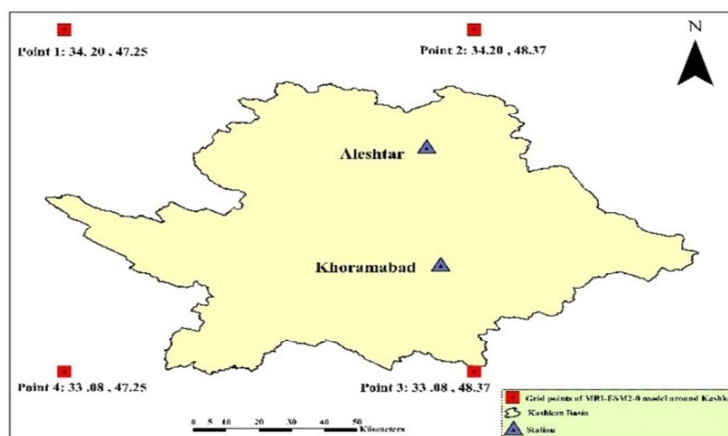


Figure 2. MRI-ESM2 model grid points around the study area

Table 1. PCC values for each grid point of the GCM model (point1, point2, point3, point4) selected with Aleshtar station

MRI-ESM2	PCC			
	Point1	Point2	Point3	Point4
Pr	0.88	0.88	0.89	0.87
Tmin	0.99	0.99	0.98	0.98
Tmax	0.98	0.98	0.98	0.98

Table 2. Table 3: PCC values for each grid point of the GCM model (point1, point2, point3, point4) selected with Khoramabad station

MRI-ESM2	PCC			
	Point1	Point2	Point3	Point4
Pr	0.90	0.90	0.91	0.89
Tmin	0.91	0.93	0.92	0.92
Tmax	0.90	0.92	0.92	0.93

## ۲.۲.۲. انتخاب غالب‌ترین متغیرهای پیش‌بینی‌کننده مدل GCM

جدول (۳) چندین متغیر پیش‌بینی‌کننده مربوط به مناسب‌ترین مدل GCM در محدوده مطالعاتی را نشان می‌دهد که تحت گزارش ششم تغییر اقلیم (AR6) و از سری مدل‌های فاز ششم CMIP بوده و در مرحله اول ریزمقیاس‌نمایی آماری به کار گرفته شدند، تهیه و انتخاب لیست متغیرهای پیش‌بینی‌کننده در جدول (۳) با توجه به مطالعات قبلی که به کاربرد روش‌های پیش‌پردازش داده‌ها برای استخراج پیش‌بینی‌کننده‌های غالب پرداخته‌اند، انجام گرفته است (Alizadeh Jabehtar *et al.*, 2021; Teegavarapu and Goly, 2018; Jato-Espino *et al.*, 2019; Nourani *et al.*, 2020). لازم به ذکر است مطابق جدول (۳)، متغیرهای پیش‌بینی‌کننده برای چهار نقطه شبکه مدل MRI-ESM2 در اطراف محدوده مطالعاتی استخراج شدند.



**Table 3. Predictors used in this research**

Predictors	Description	Predictors	Description		
1	rldscs	19	clivi	Surface downwelling longwave flux in air assuming clear sky	Atmosphere mass content of cloud ice
2	rlds	21	clt	Surface downwelling longwave flux in air	Total Cloud Cover Percentage
3	rlus	21	rlutcs	Surface upwelling longwave flux in air	TOA Outgoing Clear-Sky Longwave Radiation
4	rlut	22	hfss	Toa outgoing longwave flux	Surface upward sensible heat flux
5	prc	23	rsdscs	Convective precipitation	Surface Downwelling Clear-Sky Shortwave Radiation
6	prw	24	rsuses	Atmosphere water vapor content	Surface Upwelling Clear-Sky Shortwave Radiation
7	prsn	25	rsutcs	Snowfall flux	TOA Outgoing Clear-Sky Shortwave Radiation
8	psl	26	rtmt	Sea level pressure	Net Downward Radiative Flux at Top of Model
9	ps	27	rsds	Surface air pressure	Downwelling shortwave flux
10	tasmin	28	rsus	Minimum air temperature	Surface Upwelling Shortwave Radiation
11	tasmax	29	pr	Maximum air temperature	Precipitation
12	sci	30	rsut	Shallow convection time fraction	Toa outgoing shortwave flux
13	ts	31	tas	Sea surface temperature	Air temperature
14	clw	32	huss	Mass Fraction of Cloud Liquid Water	Specific humidity
15	cli	33	rsdt	Mass Fraction of Cloud Ice	TOA Incident Shortwave Radiation
16	cl	34	sfwind	Percentage Cloud Cover	Wind speed
17	evspsbl	35	hurs	Evaporation Including Sublimation and Transpiration	Relative humidity
18	hfls			Surface upward latent heat flux	

دقت روش‌های ریزمقیاس نمایی به رابطه آماری بین پیش‌بینی‌کننده‌های بزرگ‌مقیاس (متغیرهای دما و بارش خروجی مدل‌های GCM) و پیش‌بینی‌شونده‌ها (متغیرهای دما و بارش مشاهداتی در مقیاس ایستگاهی) بستگی دارد (Nourani *et al.*, 2020). مطابق جدول (۳)، تعداد متغیرهای پیش‌بینی‌کننده با توجه به داده‌های سطحی و نزدیک سطح گزارش ششم تغییر اقلیم (AR6) برابر با ۳۵ متغیر است؛ با در نظر گرفتن چهار نقطه شبکه برای بهترین مدل GCM، تعداد ۱۴۰ پیش‌بینی‌کننده باید جهت ورود به مدل ریزمقیاس نمای آماری مبتنی بر هوش مصنوعی ارزیابی شوند. شایان ذکر است، با این که متغیرهای پیش‌بینی‌کننده بسیاری برای توسعه مدل‌های ریزمقیاس نمایی آماری مبتنی بر هوش مصنوعی مانند مدل شبکه عصبی مصنوعی (ANN) مورد نیاز است، اما در نظر گرفتن این تعداد ورودی متعدد منجر به زوال در عملکرد مدل ANN می‌شود (Bowden *et al.*, 2005). بنابراین انتخاب غالب‌ترین یا مناسب‌ترین متغیرهای پیش‌بینی‌کننده ورودی از میان تمامی پیش‌بینی‌کننده‌های بالقوه ذکر شده در جدول (۳)، امری ضروری و اجتناب‌ناپذیر می‌باشد که وابستگی به زمان و مکان دارد. روش‌های استخراج ویژگی یکی از روش‌های پیش‌پردازش و انتخاب پیش‌بینی‌کننده‌هایی است که حداکثر تأثیر مثبت را بر روی مدل‌های ریزمقیاس نمایی آماری مانند شبکه عصبی مصنوعی (ANN) دارند.

### ۳.۲. داده‌کاوی<sup>۵</sup>

داده‌کاوی شامل تجزیه و تحلیل مقادیر زیادی از داده‌ها با هدف کشف الگوهای معنی‌دار و پنهان درون آن‌ها می‌باشد. به‌طور کلی بحث داده‌کاوی در دو بخش داده‌کاوی هدایت‌شده<sup>۶</sup> و غیرهدایت‌شده<sup>۷</sup> تقسیم‌بندی شده است. داده‌کاوی هدایت‌شده، شامل یک متغیر هدف از پیش تعیین شده می‌باشد که هدف آن یافتن الگویی خاص در بین داده‌ها است؛ درحالی‌که هدف از داده‌کاوی غیر هدایت‌شده، یافتن الگوها یا تشابهات موجود در بین گروه‌هایی از داده‌ها، بدون داشتن متغیر هدف مشخص و یا مجموعه‌ای از دسته‌ها و الگوهای از پیش تعیین شده است. به‌طور کلی می‌توان گفت انجام عمل داده‌کاوی در راستای ساخت مدل‌هاست؛ به گونه‌ای که با انجام درست داده‌کاوی می‌توان مدلی ایجاد نمود که منجر به پیش‌بینی متغیر هدف با دقت بالا شود (Sarzaeim *et al.*, 2017).

### ۴.۲. درخت تصمیم

الگوریتم‌های درخت تصمیم به دلیل ایجاد قواعد تفسیری و دقت بالا در امر پیش‌بینی، به‌عنوان یکی از پرکاربردترین و

مؤثرترین الگوریتم‌های یادگیری استقرایی شناخته می‌شوند و امروزه در علوم مختلف رایانه، سنجش از دور، محیط زیست و پزشکی کاربرد زیادی دارند. غیرپارامتری بودن و عدم حساسیت به وجود داده‌های مفقوده و انجام پیش‌بینی با دقت بالا از جمله ویژگی‌های مهم درخت تصمیم است؛ به گونه‌ای که با کمک آن می‌توان نتایج داده‌کاوی را در فرم ساده‌ای ارائه نمود. درخت تصمیم به‌منظور پیش‌بینی یا کلاس‌بندی داده‌ها بر مبنای مجموعه‌ای از قوانین تصمیم‌گیری ایجاد شده‌اند. ساختار یک مدل درختی متشکل از ریشه، ساقه، گره‌های درونی و برگ می‌باشد. مدل‌های درخت تصمیم برای حل بسیاری از مسائل طبقه‌بندی و رگرسیونی مورد استفاده قرار می‌گیرد. مدل درختی M5 یا مدل درخت تصمیم موسوم به M5، جزو یکی از روش‌های مرسوم داده‌کاوی و یادگیری ماشینی است (Quinlan, 1992) و با کاربرد الگوهای درخت تصمیم، قابلیت کشف نیمه‌اتوماتیک الگوهای ارزشمند موجود در درون داده‌ها را دارد. مدل M5 توانایی پیش‌بینی داده‌های پیوسته را دارد و برخلاف مدل‌های معمول درخت تصمیم که کلاس‌های خروجی را به‌صورت گسسته ارائه می‌کند، یک مدل خطی چندمتغیره را برای داده‌های موجود در هر گره از مدل درختی می‌سازد (Bhattacharya and Solomatine, 2006). مدل M5 مشابه یک تابع خطی چند بخشی است که از مدل‌های رگرسیونی و رگرسیون درختی تشکیل شده است (Witten and Frank, 2006). مدل رگرسیون M5، یک معادله رگرسیونی را برای کل داده‌های فضایی ارائه می‌دهد، درحالی‌که رگرسیون درختی دامنه داده‌ها را به زیرمجموعه‌هایی به نام برگ تقسیم می‌کند، بنابراین، به هر برگ یک معادله رگرسیونی اطلاق می‌شود. جایگزینی معادله رگرسیونی در قسمت برگ‌ها روشی است که در مدل M5 اعمال شده و می‌تواند متغیرهای عددی پیوسته را با کمک این روش پیش‌بینی نماید (Pal et al., 2012). مدل M5 با توجه به مطالعات قبلی، به‌عنوان یکی از روش‌های مطمئن در انتخاب غالب‌ترین پیش‌بینی‌کننده‌ها در راستای توسعه‌ی روش‌های ریزمقیاس‌نمایی آماری مانند ANN معرفی شده است (Alizadeh Jabehdar et al., 2021; Nourani et al., 2019). در این مطالعه از الگوریتم M5 نرم‌افزار WEKA برای ساخت درخت و انتخاب متغیرهای پیش‌بینی‌کننده غالب مدل GCM جهت اعمال ورودی به مدل ریزمقیاس‌نمایی آماری ANN، استفاده شده است.

## ۲.۵. ریزمقیاس‌نمایی آماری مبتنی بر مدل شبکه عصبی مصنوعی (ANN) و الگوریتم بهینه‌سازی گرم شب‌تاب (FFA)

تا زمان نگارش پژوهش حاضر، توسعه‌دهندگان نرم‌افزارهای ریزمقیاس‌نمایی آماری LARS-WG و SDSM نسخه به‌روزرشده‌ای از نرم‌افزارها را که حاوی مدل‌های GCM جفت‌شده فاز ششم (CMIP6) مربوط به گزارش ششم IPCC (AR6) باشد را ارائه نکرده‌اند. با این حال، می‌توان از روش‌های دیگری مانند روش ریزمقیاس‌نمایی آماری مبتنی بر مدل شبکه عصبی مصنوعی (ANN) نیز به‌منظور ریزمقیاس‌نمایی خروجی مدل‌های GCM جفت‌شده فاز ششم (CMIP6) استفاده نمود. بررسی پیشینه پژوهش در ارتباط با روش‌های ریزمقیاس‌نمایی آماری نشان داد که کارایی مدل‌های ریزمقیاس‌نمایی آماری مبتنی بر هوش مصنوعی (AI) معمولاً در قیاس با برخی از مدل‌های کلاسیک مانند SDSM عملکرد مناسبی داشته است. مدل SDSM به‌عنوان یک مدل ریزمقیاس‌نمایی آماری، از روش رگرسیون خطی چندگانه (MLR) برای ایجاد ارتباط آماری مابین متغیر پیش‌بینی‌شونده و پیش‌بینی‌کننده استفاده می‌کند. یکی از نکات مثبت مدل ANN نسبت به مدل SDSM، پذیرفتن داده‌های ورودی و انجام امر پیش‌بینی در هر مقیاس زمانی است، در حالی که مدل SDSM فقط به‌صورت روزانه امر ریزمقیاس‌نمایی را به انجام می‌رساند.

در طی تمامی مراحل ریزمقیاس‌نمایی آماری خروجی‌های دمای حداکثر، دمای حداقل و بارش مربوط به مناسب‌ترین مدل GCM در ایستگاه‌های خرم‌آباد و الشتر و پیش‌بینی مقادیر این متغیرها در دوره‌های آتی (۲۰۶۲-۲۰۲۳ و ۲۰۲۳-۲۱۰۰) از ساختار آموزش داده‌شده شبکه عصبی پیشرو (FFNN) استفاده شد. با توجه به پژوهش‌های صورت‌گرفته

ساختار FFNN با الگوریتم پس انتشار خطا (BP) می‌تواند منجر به نتایج قابل‌اعتمادی در شبیه‌سازی و پیش‌بینی متغیرهای اقلیمی و مدل‌سازی سری‌های زمانی شود. همچنین با هدف دستیابی به بهترین کارایی مدل شبکه عصبی ANN، از الگوریتم پس انتشار لونیبرگ-مارکواریت (LM) برای آموزش مدل به‌دلیل میزان همگرایی بالاتر استفاده شد (Haykin, 1996; Kisi, 2004; Ghorbani *et al.*, 2018). همچنین تابع تانزانت سیگموئید نیز به جهت نگاشت اطلاعات از لایه ورودی به لایه پنهان و به‌عنوان هسته غیرخطی شبکه‌های عصبی استفاده شد. روند آموزش شبکه ANN با حداکثر تکرار ۱۰۰۰ بار زمانی متوقف می‌شود که حداقل میزان خطا در ارزیابی داده‌های مرحله آزمون به‌دست آید. موضوع قابل توجه و مهم در بحث آموزش مدل ANN، تعیین ساختار مناسب این مدل از جمله تعداد نرون‌ها در لایه پنهان و همچنین تعداد تکرار آموزش است، به‌گونه‌ای که جهت دستیابی به بهترین ساختار بایستی روش آزمون و خطا را انجام داد. تعداد نرون‌های لایه پنهان نیز از تعداد نرون‌های کم آغاز شده و تا حداکثر عدد ۳۰ نرون محاسبات به جهت یافتن بهترین مدل پیش رفت (Anh and Taniguchi, 2018).

الگوریتم کرم شب‌تاب (FA)؛ توسط Yang (2010) بر مبنای رفتار و الگوهای چشم‌ک‌زن کرم‌های شب‌تاب ارائه شد. این الگوریتم یک روش جدید مبتنی بر رفتارهای جمعی است که از رفتارهای اجتماعی کرم شب‌تاب در طبیعت الهام گرفته است و به‌عنوان یکی از روش‌های قدرتمند در حل مسائل بهینه‌سازی شناخته شده است. کرم‌های شب‌تاب نورهای موزون و کوتاه تولید می‌کنند. الگوی نوری هر کدام از کرم‌های شب‌تاب با یکدیگر متفاوت می‌باشند. کرم‌های شب‌تاب از این نورها به دو منظور استفاده می‌کنند؛ یکی فرایند جذب جفت و دیگری برای جذب شکار. همچنین این نورها می‌توانند به‌عنوان یک مکانیزم محافظتی برای کرم‌های شب‌تاب باشند. نورهای موزون، نرخ تابیدن نور و میزان فاصله زمانی که بین سیگنال‌های نور وجود دارند باعث می‌شوند که کرم‌های شب‌تاب به یکدیگر جذب شوند. دو موضوع مهم در این الگوریتم، تغییرات شدت نور و فرموله کردن جذابیت حشرات می‌باشد. به‌منظور سادگی فرض می‌شود که جذابیت حشرات با شدت روشنایی آن‌ها بیان می‌شود. در حالت کلی جذابیت پارامتری نسبی بوده و از دید حشرات دیگر سنجیده می‌شود. همچنین به فاصله حشرات از یکدیگر نیز بستگی دارد رابطه جذابیت با تغییرات فاصله حشرات به‌صورت زیر می‌باشد:

$$\beta = \beta_0 e^{-\gamma r} \quad \text{رابطه (۱)}$$

که در آن  $\beta_0$  بیانگر بیشینه جذابیت بوده و مقدار آن در بازه  $[0, 1]$  تغییر می‌کند.  $\gamma$  نیز بیانگر ضریب جذب می‌باشد و مقدار آن در بازه  $[0, \infty]$  قابل تغییر است.  $r$  بیانگر فاصله حشرات بوده و به‌عنوان مثال در مقیاس دو بعدی فاصله حشرات  $\Delta m$  از حشره  $\Delta m$  به‌صورت رابطه (۲) محاسبه می‌شود، حرکت حشره  $\Delta m$  به سمت حشره  $\Delta m$  نیز با رابطه (۳) به‌دست می‌آید:

$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad \text{رابطه (۲)}$$

$$x_i = x_i + \beta_0 e^{-\gamma r} (x_j - x_i) + \alpha \epsilon_i \quad \text{رابطه (۳)}$$

در رابطه (۳)، قسمت مربوط به  $\beta_0 e^{-\gamma r} (x_j - x_i)$  نشانگر جذابیت کرم شب‌تاب،  $\alpha \epsilon_i$  ایجادکننده یا رندم‌ساز بردار تصادفی مربوط به اعداد دخیل در توزیع گوسین یا توزیع یکنواخت،  $x_i$  نشانگر موقعیت نقطه‌ای کرم شب‌تاب کم‌نور،  $x_j$  نشانگر موقعیت کرم شب‌تاب پر نور،  $n$  شماره تکرار،  $\alpha$  نشانگر برداری از اعداد تصادفی با توزیع یکنواخت یا گوسین است. جذب کرم‌های شب‌تاب در این الگوریتم تا جایی ادامه می‌یابد که آن‌ها به سمت پرنورترین کرم موجود جذب شوند؛ در حقیقت این کرم بهترین مقدار را برای تابع هدف موردنظر محقق ایجاد می‌کند. به جهت تعیین پارامترهای بهینه الگوریتم FFA  $\alpha$  و  $\beta_0$  معمولاً در محدوده‌ی صفر تا ۱ و  $\gamma$  در محدوده صفر تا مثبت بی‌نهایت مشخص می‌شوند (Alizadeh Jabehtar, 2021).

به‌طور کلی، سه قانون ایده‌آل برای توسعه الگوریتم‌های الهام گرفته‌شده از کرم شب‌تاب به کار برده شده است که عبارتند از ۱- همه کرم‌های شب‌تاب از یک جنس در نظر گرفته می‌شوند، به گونه‌ای که یک کرم شب‌تاب به کرم شب‌تاب دیگر صرف‌نظر از جنسیت‌شان جذب خواهد شد، ۲- جذابیت با روشنایی یک کرم شب‌تاب متناسب است. بنابراین برای هر کرم شب‌تاب چشم‌ک‌زن، یکی با روشنایی کمتر به سوی دیگری با درخشندگی بیشتر حرکت خواهد کرد. جذابیت با روشنایی متناسب است و هر دوی آن‌ها هرچه که فاصله افزایش می‌یابد، کاهش می‌یابند. اگر هیچ‌یک از کرم‌های شب‌تاب روشن‌تر از دیگری نباشد، کرم شب‌تاب به‌طور تصادفی حرکت خواهد کرد. ۳- روشنایی یک کرم شب‌تاب به‌وسیله چشم‌انداز تابع هدف تعیین می‌شود یا تحت تأثیر آن قرار می‌گیرد. در شبکه عصبی مصنوعی بهینه‌سازی توسط تابع موجود در خود شبکه توسط تابع‌های از پیش تعیین‌شده صورت می‌گیرد، اما در الگوریتم هیبریدی شبکه عصبی- کرم شب‌تاب (MLP-FA) بهینه‌سازی توسط تابع بهینه‌کننده کرم شب‌تاب موجود در الگوریتم هیبریدی شب‌تاب صورت می‌گیرد. در شکل (۳) عملکرد الگوریتم هیبریدی شبکه عصبی- کرم شب‌تاب توضیح داده شده است (Valipour *et al.*, 2019).

## ۶.۲. انتخاب پیش‌بینی‌کننده‌های غالب مدل MRI-ESM2

بعد از تعیین مناسب‌ترین مدل GCM، انتخاب متغیرهای پیش‌بینی‌کننده با خصوصیات مناسب از میان بسیاری از متغیرهای اقلیمی موجود در مدل GCM، به‌عنوان یکی از مهم‌ترین مراحل ریزمقیاس‌نمایی شناخته می‌شود. به این ترتیب، مدل درختی M5 برای انتخاب پیش‌بینی‌کننده‌های غالب از میان تمامی پیش‌بینی‌کننده‌ها (۱۴۰ متغیر) استفاده شد. جدول (۴) پیش‌بینی‌کننده‌های غالب به‌دست‌آمده توسط روش استخراج ویژگی مدل M5 با نرم‌افزار WEKA را نشان می‌دهد.

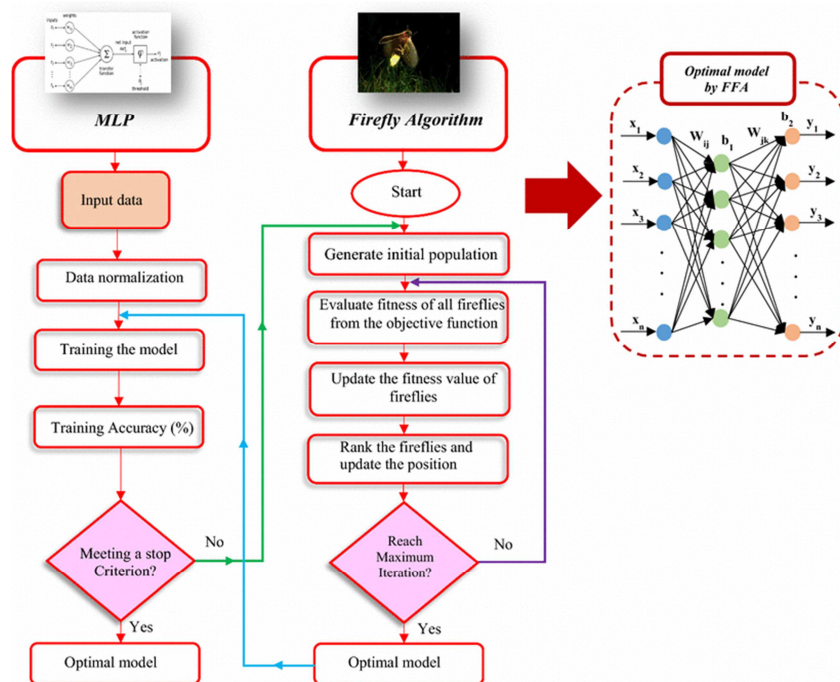


Figure 3. The general structure of the hybrid model of firefly optimization algorithm based on artificial neural network (MLP-FFA)

Table 4. Predominant predictors of precipitation parameter, maximum temperature and minimum temperature

Model	The most dominant predictors		
	Precipitation	T <sub>max</sub>	T <sub>min</sub>
MRI-ESM2	Clivi, hurs, rldscs, psl, rlut, sfcWin, clw, cl, prc, tasmax, tas, prw	hurs, rlds, rsuses, rlus, cl, prw, prc, ts, tas, tasmin	hfss, hurs, huss, rlus, rsds, tas, sfcWind, prc, tasmax, hfsls

مطابق جدول (۴)، با کاربرد الگوریتم M5 پیش‌بینی‌کننده‌های چهار نقطه شبکه مدل GCM که در گره‌های بالایی درخت قرار داشتند، به‌عنوان غالب‌ترین متغیرهای ورودی مدل عصبی ریزمقیاس‌نمایی آماری دو متغیر بارش و دما انتخاب شدند.

## ۲.۷. ریزمقیاس‌نمایی آماری متغیرهای دما و بارش مبتنی بر مدل شبکه عصبی مصنوعی (ANN)

پس از انتخاب مؤثرترین پیش‌بینی‌کننده‌ها، دو مدل شبکه عصبی پیش‌خور (FFNN) به‌صورت جداگانه و به‌منظور ریزمقیاس‌نمایی مقادیر متوسط ماهانه ۴۴ ساله پارامترهای دما و بارش (۱۹۷۰-۲۰۱۴) در مقیاس ایستگاه مشاهداتی (ایستگاه خرم‌آباد و الشتر) استفاده شد. شایان ذکر است، ۷۵ درصد داده‌ها (۱۹۷۰-۲۰۰۰) برای امر آموزش و ۲۵ درصد داده‌ها (۲۰۱۴-۲۰۰۱) به‌منظور آزمون نتایج مدل ANN تقسیم‌بندی شدند، تقسیم‌بندی داده‌ها به دو بخش آموزش و آزمون در بسیاری از مطالعات مربوط به مدل‌سازی فرایندهای هیدرولوژیکی از جمله فرایند بارش - رواناب تحت شرایط استفاده از مدل‌های مبتنی بر هوش مصنوعی (AI) به انجام رسیده است.

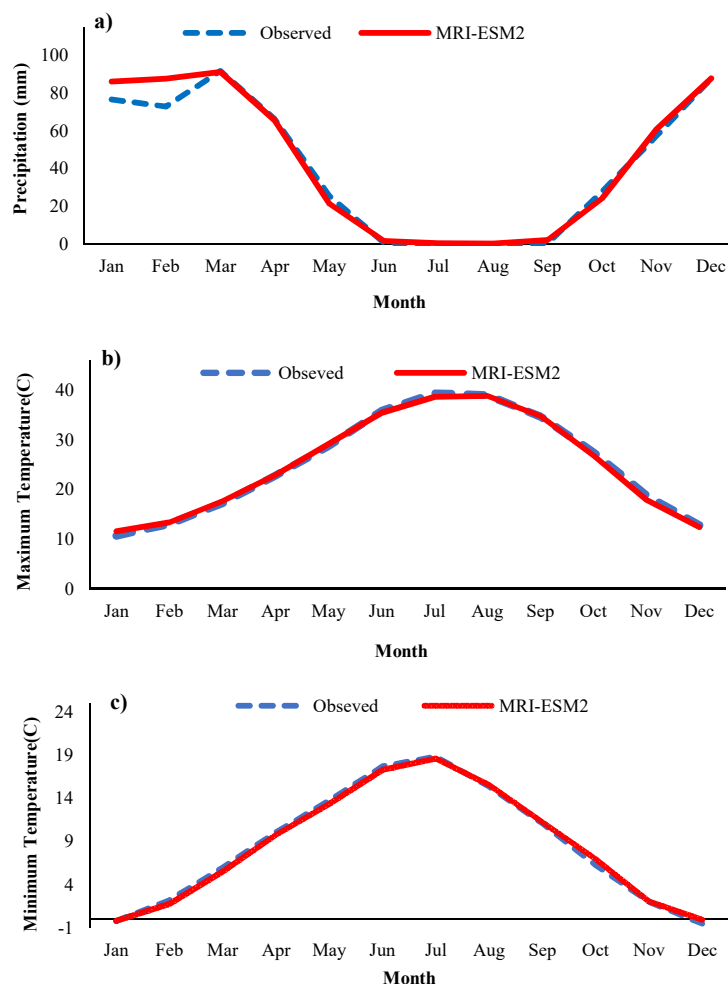
نتایج مدل ANN نشان داد که عملکرد بالای مدل ریزمقیاس‌نمایی شبکه عصبی مصنوعی پیش‌خور تحت شرایط تعداد تکرار ۱۰۰ مرتبه ثبت شده است. مقادیر شاخص‌های آماری ضریب همبستگی پیرسون (PCC) و جذر میانگین مربعات خطا (RMSE) موجود در جدول (۵) نشان می‌دهد که مدل ANN با کاربرد مؤثرترین متغیرهای پیش‌بینی‌کننده تعیین‌شده توسط مدل پیش‌پردازی M5 تخمین‌های قابل‌قبولی را برای دوره پایه (۱۹۷۰-۲۰۱۴) ارائه داده است. لازم به ذکر است که مطابق جدول (۵)، مدل ANN عملکرد بهتری را برای متغیر دما در مقایسه با بارش نشان داده است. سری‌های زمانی دما برخلاف سری‌های زمانی بارش، روندی قابل‌پیش‌بینی‌تر<sup>۱</sup>، نرم‌تر<sup>۲</sup> و تناوبی دارند، لذا می‌توان آن‌ها را به‌راحتی و به‌صورت دقیق تخمین زد (Ali et al., 2018; Dibike et al., 2006). واریانس نسبتاً کم سری زمانی بارش نسبت به دما، تأکید بر تصادفی‌تربودن وقایع بارش دارد (Sharafti and Khazaei, 2017; Tabari et al., 2008; Nourani et al., 2020)؛ از سویی دیگر، تعیین ویژگی‌های تغییرپذیری رژیم بارش در فرایند ریزمقیاس‌نمایی امری دشوار است، عملکرد مدل ANN طی دوره پایه (۱۹۷۰-۲۰۱۴) در پژوهش حاضر و در بحث ریزمقیاس‌نمایی آماری متغیر بارش در مقایسه با دما، نتایج پژوهش Nourani et al. (2020) در بررسی عملکرد مدل مذکور طی دوره پایه (۱۹۵۱-۲۰۰۰) در منطقه مطالعاتی حوضه دریاچه ارومیه است.

Table 5. Evaluation of the performance of ANN model in the base period (1970-2014) during the exponential downscaling, Khorramabad and Aleshtar stations

Model	Station	T <sub>min</sub>		T <sub>max</sub>		Precipitation	
		RMSE	PCC	RMSE	PCC	RMSE	PCC
MRI-ESM2	Khorramabad	1.9	0.96	2.02	0.98	33	0.74
	Aleshtar	1.62	0.96	1.9	0.98	33.6	0.73

مقایسه بصری نتایج متوسط ماهانه دمای حداکثر، حداقل و بارش ایستگاه‌های خرم‌آباد و الشتر طی دوره آماری پایه ۴۴ ساله (۱۹۷۰-۲۰۱۴) نسبت به سری زمانی دما و بارش تخمین زده‌شده توسط مدل ANN در شکل‌های (۴) و (۵) نشان داده شده است. مطابق شکل‌های (۴) و (۵)، نتایج ریزمقیاس‌نمایی در دوره پایه توسط مدل ANN تحت مدل گردش عمومی MRI-ESM2 عملکرد نسبتاً خوبی را در تخمین متوسط بارش ماهانه دو ایستگاه نشان داده است، نمودار سری زمانی بارش

ماهانه مدل MRI-ESM2 در مقایسه با مقادیر بارش ماهانه مشاهداتی دو ایستگاه، نشان‌دهنده اندکی خطای افزایشی در ماه‌های ژوئن، فوریه است، بقیه ماه‌های مدل شبیه‌سازی شده MRI-ESM2 انطباق خوبی با داده‌های مشاهداتی داشته‌اند. در صورت بررسی دقت مدل ریزمقیاس نمایی ANN در مقیاس جمع سالانه نیز، این مدل در قیاس نتایج تخمین زده شده متوسط ماهانه بارش MRI-ESM2 با مقادیر بارش مشاهداتی در ایستگاه‌های خرم‌آباد و الشتر به ترتیب تنها پنج و هشت درصد خطا را در طی دوره پایه از خود نشان داده است. با توجه به شکل (۵)، می‌توان گفت مدل MRI-ESM2 تقریباً در تمامی ماه‌ها، عملکرد خوبی را در تخمین متوسط دمای حداکثر و حداقل نشان داده است، در صورت بررسی دقت مدل ریزمقیاس نمایی ANN در مقیاس سالانه نیز، این مدل در قیاس نتایج تخمین زده شده متوسط ماهانه دمای مدل MRI-ESM2 با مقادیر ماهانه دمای مشاهداتی در هر دو ایستگاه خرم‌آباد و الشتر، تنها یک درصد خطا را در طی دوره پایه از خود نشان داد. مقدار صحت و خطای آزمون‌های آماری و عملکرد ریزمقیاس‌نمایی با شبکه عصبی در این پژوهش در راستای عملکرد پژوهش Rahimi and Rahimi (2018)، به‌منظور بررسی اثرات تغییر اقلیم بر بارش و دمای استان خوزستان و همچنین پژوهش Asakereh and Gholami (2021)، شبیه‌سازی دمای بیشینه ایستگاه سینوپتیک قزوین می‌باشد.



**Figure 4. The time series of average monthly precipitation (a), average monthly maximum temperature (b), average monthly minimum temperature (c) observed and estimated by the statistical exponential microscale model based on ANN for the base period (1970-2014), Khorramabad station**

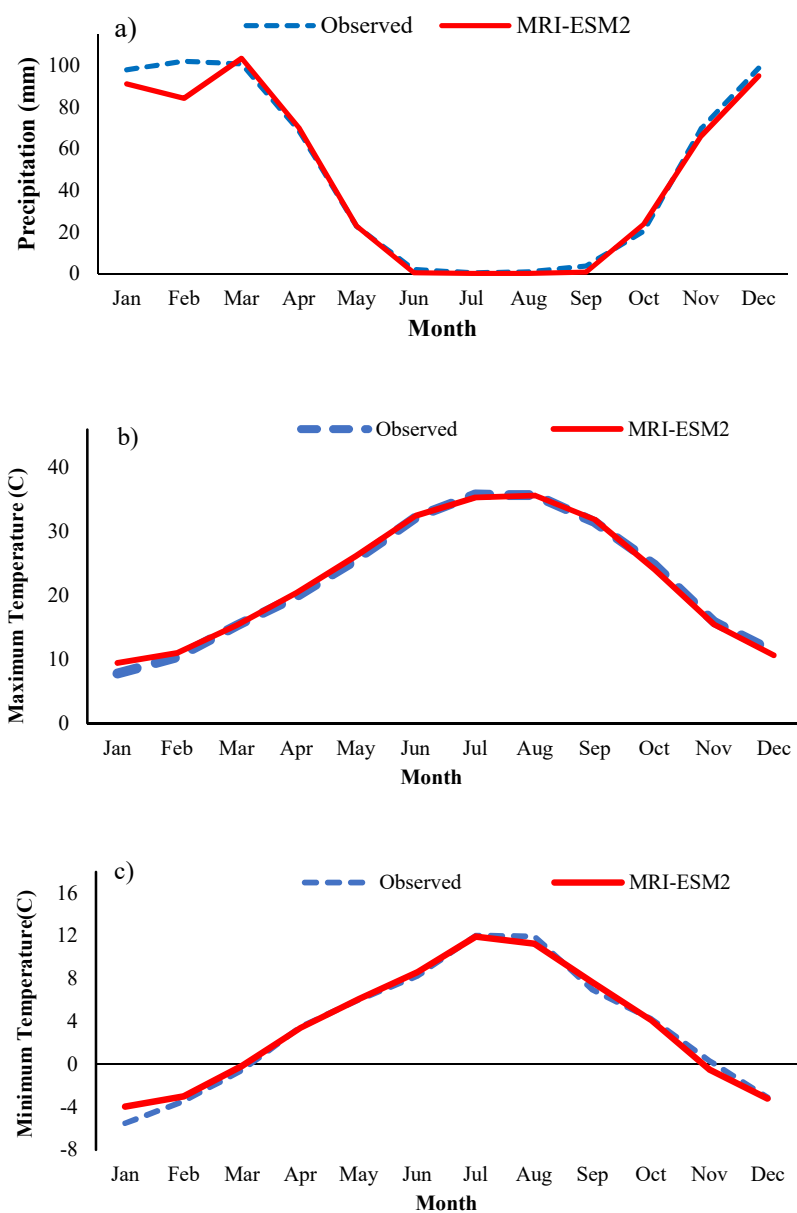


Figure 5. The time series of average monthly precipitation (a), average monthly maximum temperature (b), average monthly minimum temperature(c) observed and estimated by the statistical exponential microscale model based on ANN for the base period (1970-2014), Aleshtar station

## ۸.۲. پیش‌بینی تغییرات بارش و دما در آینده نزدیک (۲۰۲۳-۲۰۶۲) و آینده دور (۲۰۶۳-۲۱۰۰)

با توجه به نتایج مذکور و اثبات توانایی مدل شبکه عصبی مصنوعی (ANN) در ریزمقیاس‌نمایی و تخمین متغیرهای بارش، دمای حداکثر و دمای حداقل در طی دوره پایه (۱۹۷۰-۲۰۱۴)، نسخه‌ی آموزش داده‌شده مدل ANN به جهت تولید داده‌های اقلیمی بارش و دمای ماهانه در دو دوره آینده نزدیک (۲۰۲۳-۲۰۶۲) و آینده دور (۲۰۶۳-۲۱۰۰) تحت سناریوهای انتشار SSP1-2.6، SSP2-4.5، SSP3-7.0، SSP5-8.5، مدل گردش عمومی MRI-ESM2 مورد استفاده قرار گرفت. به عبارتی، پس از توسعه مدل ریزمقیاس‌نمایی آماری مبتنی بر ANN ورودی‌های مدل ANN که با استفاده

از روش استخراج ویژگی مدل M5 به دست آمده بودند، در این قسمت به منظور تخمین متغیرهای دما و بارش در دو دوره آینده نزدیک (۲۰۲۳-۲۰۶۲) و آینده دور (۲۰۶۳-۲۱۰۰) استفاده شدند. طی این فرایند، متغیرهای پیش‌بینی‌کننده بزرگ‌مقیاس در دوره‌های آتی تحت سناریوهای انتشار مذکور و براساس پیش‌بینی‌کننده‌های غالب انتخاب‌شده از طریق مدل M5 انتخاب و به مدل آموزش داده‌شده ANN اعمال شدند.

مطابق نتایج شکل (۶) مشاهده می‌شود که متوسط بارش ماهانه برای آینده نزدیک (۲۰۲۳-۲۰۶۲) در ماه‌های مختلف نوسان دارد و بیش‌تر به صورت کاهشی می‌باشد. در ایستگاه خرم‌آباد بیش‌ترین کاهش و افزایش بارش به ترتیب به میزان ۲۳ و ۱۷ میلی‌متر در ماه‌های آوریل (فروردین‌ماه) و ژانویه (دی‌ماه) و تحت سناریوی SSP-5.8.5 است، در ایستگاه الشتر نیز بیش‌ترین کاهش و افزایش بارش در ماه‌های نوامبر (آبان‌ماه) و ژانویه (دی‌ماه) به ترتیب به میزان ۲۶ و ۲۳ میلی‌متر و تحت سناریوهای SSP-5.8.5 و SSP-3.7.0 پیش‌بینی شده است. با مقایسه مقادیر جمع سالانه مشاهداتی دوره پایه (۱۹۷۵-۲۰۱۴) با نتایج متناظر آن در آینده نزدیک (۲۰۲۳-۲۰۶۲)، کاهش بارش در محدوده آبریز کشکان تحت تمامی سناریوهای SSP در سال‌های آتی (۲۰۲۳-۲۰۶۲) به وضوح مشخص می‌شود، به گونه‌ای که متوسط بارش سالانه در ایستگاه خرم‌آباد از ۵۰۹ میلی‌متر در دوره پایه، براساس سناریوهای SSP-1.2.6، SSP-2.4.5، SSP-3.7.0، SSP-5.8.5 به ترتیب ۴۵۷، ۴۶۷، ۴۶۵ و ۴۴۸ میلی‌متر در سال پیش‌بینی شده است. در ایستگاه الشتر نیز متوسط بارش سالانه در ایستگاه از ۵۵۰ میلی‌متر در دوره پایه، براساس سناریوهای SSP-1.2.6، SSP-2.4.5، SSP-3.7.0، SSP-5.8.5 به ترتیب ۴۶۳، ۵۲۷، ۴۴۸ و ۴۹۵ میلی‌متر در سال پیش‌بینی شده است. به عبارتی، می‌توان چنین استنباط نمود که وقوع بارش در آینده نزدیک در ایستگاه خرم‌آباد بین ۶ تا ۱۲ درصد و ایستگاه الشتر بین ۰/۳ تا ۱۶ درصد کاهش خواهد داشت.




Figure 6. Average monthly rainfall forecast in the near future (2023-2062) with MRI-ESM2 model SSP release scenarios along with the precipitation chart in the base period (1975-2014), a) Khorramabad station, b) Aleshtar station



در بررسی تغییرات بارش در آینده دور (۲۰۶۳-۲۱۰۰) نیز مطابق شکل (۷) مشاهده می‌شود که متوسط بارش ماهانه در ماه‌های مختلف نوسان دارد و بیش‌تر به‌صورت کاهشی می‌باشد. در دوره آینده دور (۲۰۶۳-۲۱۰۰) مقدار بارش علاوه بر دوره پایه حتی نسبت به دوره آینده نزدیک (۲۰۲۳-۲۰۶۲) هم رو به کاهش می‌باشد. در ایستگاه خرم‌آباد بیش‌ترین کاهش و افزایش بارش به‌ترتیب به میزان ۳۹ و ۱۳ میلی‌متر در ماه‌های آوریل (فروردین‌ماه) و ژانویه (دی‌ماه) و تحت سناریوی SSP-5.8.5 است، در ایستگاه الشتر نیز بیش‌ترین کاهش و افزایش بارش در ماه‌های نوامبر (آبان‌ماه) و فوریه (بهمن‌ماه) و به‌ترتیب به میزان ۳۹ و ۱۷ میلی‌متر و تحت سناریوهای SSP-5.8.5 و SSP-3.7.0 پیش‌بینی شده است. با مقایسه مقادیر جمع سالانه مشاهداتی دوره پایه (۱۹۷۵-۲۰۱۴) با نتایج متناظر آن در آینده دور (۲۰۶۳-۲۱۰۰)، کاهش بارش در محدوده آبریز کشکان تحت تمامی سناریوهای SSP در سال‌های آتی (۲۰۶۳-۲۱۰۰) به‌وضوح مشخص می‌شود، به‌گونه‌ای که متوسط بارش سالانه در ایستگاه خرم‌آباد از ۵۰۹ میلی‌متر در دوره پایه، براساس سناریوهای SSP-1.2.6، SSP-2.4.5، SSP-3.7.0، SSP-5.8.5 به‌ترتیب ۴۴۷، ۴۴۹، ۳۹۹ و ۳۸۵ میلی‌متر در سال پیش‌بینی شده است. در ایستگاه الشتر نیز متوسط بارش سالانه در ایستگاه از ۵۵۰ میلی‌متر در دوره پایه، براساس سناریوهای SSP-1.2.6، SSP-2.4.5، SSP-3.7.0، SSP-5.8.5 به‌ترتیب ۴۶۱، ۴۹۵، ۴۵۱ و ۴۴۰ میلی‌متر در سال پیش‌بینی شده است. به‌عبارتی، می‌توان چنین استنباط نمود که وقوع بارش در آینده نزدیک در ایستگاه خرم‌آباد بین ۱۲ تا ۲۴ درصد و ایستگاه الشتر بین ۱۰ تا ۲۰ درصد کاهش خواهد داشت. این نتایج مطابق با نتایج پژوهش‌های اشاره‌شده و بررسی‌های اقلیمی IPCC می‌باشد. هم‌چنین نتایج پژوهش Ansari *et al.* (2022) که با استفاده از گزارش ششم IPCC به بررسی وضعیت بارش در کشور ایران پرداختند تطابق دارد.




Figure 7. Average monthly precipitation forecast in the distant future (2063-2100) with the MRI-ESM2 SSP release scenarios along with the precipitation chart in the base period (1975-2014), a) Khorramabad station b) Aleshtar station

## ۹.۲. بررسی تغییرات دما در دوره های آتی

مطابق شکل (۸)، بررسی تغییرات متوسط ماهانه دما طی دوره آینده نزدیک (۲۰۲۳-۲۰۶۲) در ایستگاه خرم آباد، کمترین و بیشترین تغییرات افزایشی دمای حداکثر و حداقل ماهانه نسبت به دوره پایه در ماه نوامبر (آبان ماه) به ترتیب به میزان ۲/۵۶ و ۲/۳۳ درجه سانتیگراد تحت سناریوی SSP-5.8.5 بوده است، کمترین و بیشترین روند کاهشی تغییرات دمای حداکثر و حداقل نیز در دوره آینده نزدیک نسبت به دوره پایه در این ایستگاه به ترتیب در ماه های ژوئن (خردادماه) به میزان ۱- درجه سانتیگراد تحت سناریوی SSP-1.2.6 و جولای (تیرماه) به میزان ۰/۰۴ درجه سانتیگراد تحت سناریوی SSP-2.4.5 می باشد. در ایستگاه الشتر نیز کمترین و بیشترین تغییرات افزایشی دمای حداکثر و حداقل ماهانه نسبت به دوره پایه در ماه ژانویه (دی ماه) به ترتیب به میزان ۲/۳ و ۳/۸ درجه سانتیگراد تحت سناریوی SSP-3.7.0 بوده است، کمترین و بیشترین روند کاهشی تغییرات دمای حداکثر و حداقل نیز در دوره آینده نزدیک نسبت به دوره پایه در این ایستگاه به ترتیب در ماه های اکتبر (مهرماه) به میزان ۱/۲۳- درجه سانتیگراد تحت سناریوی SSP-1.2.6 و ماه آگوست (مردادماه) ۰/۲۸- درجه سانتیگراد تحت سناریوی SSP-3.7.0 می باشد. نتایج حاصل از پیش بینی تغییرات متوسط دمای سالانه تحت مدل MRI-ESM2 و سناریوهای SSP را نسبت به متوسط ۴۴ ساله ی مشاهدات (۲۰۱۴-۱۹۷۰) به نمایش می گذارد. با این که تغییرات دما در مقیاس ماهانه و در طول زمان دارای نوساناتی است، با این حال، متوسط دمای سالانه در دوره آینده نزدیک نسبت به دوره پایه کاملاً افزایشی خواهد بود (متوسط دمای حداکثر و حداقل مشاهداتی در دوره پایه ایستگاه خرم آباد به ترتیب ۲۵/۰۶ و ۸/۴۸ هم چنین در ایستگاه الشتر نیز متوسط دمای حداکثر و حداقل مشاهداتی در دوره پایه ۲۲/۱۳ و ۳/۳۱ می باشد). در ایستگاه خرم آباد متوسط دمای حداکثر به ۲۵/۶ تا ۲۶/۷۴ درجه سانتیگراد و دمای حداقل ۹/۶۲ تا ۹/۹۷ درجه سانتیگراد تحت سناریوهای افزایش می یابد. در ایستگاه الشتر متوسط دمای حداکثر به ۲۲/۸۵ تا ۲۴/۰۱ درجه سانتیگراد و دمای حداقل به ۴/۱۶ تا ۴/۵۰ درجه سانتیگراد تحت سناریوهای افزایش می یابد. نتایج پژوهش Zarrin and Dadashi-Roudbari (2022) در پیش بینی چشم انداز تغییرات بلندمدت دما تحت سناریوهای SSP و افزایش آن در مناطق مرتفع ایران است.

قدم بعدی در بررسی تغییرات دمایی حوضه کشکان به دوره پایه (۲۰۱۴-۱۹۷۵) تحت اثر تغییر اقلیم، ارزیابی نتایج مدل MRI-ESM2 تحت سناریوهای SSP در طی آینده دور (۲۰۶۳-۲۱۰۰) می باشد. مطابق شکل (۹)، بررسی تغییرات متوسط ماهانه دما طی دوره آینده دور (۲۰۶۳-۲۱۰۰) نسبت به دوره پایه (۲۰۱۴-۱۹۷۵) در ایستگاه خرم آباد، کمترین و بیشترین تغییرات افزایشی دمای حداکثر و حداقل ماهانه نسبت به دوره پایه در ماه نوامبر (آبان ماه) به ترتیب به میزان ۴/۱۹ و ۳/۷۱ درجه سانتیگراد تحت سناریوی SSP-5.8.5 بوده است، کمترین و بیشترین روند کاهشی تغییرات دمای حداکثر و حداقل نیز در دوره آینده دور نسبت به دوره پایه در این ایستگاه به ترتیب در ماه های ژوئن (خردادماه) به میزان ۰/۷۱- درجه سانتیگراد تحت سناریوی SSP-1.2.6 و جولای (تیرماه) به میزان ۰/۲۳ درجه سانتیگراد تحت سناریوی SSP-3.7.0 می باشد. در ایستگاه الشتر نیز کمترین و بیشترین تغییرات افزایشی دمای حداکثر و حداقل ماهانه آینده دور نسبت به دوره پایه در ماه می (اردیبهشت ماه) و ژانویه (دی ماه) به ترتیب به میزان ۵/۵۱ و ۳/۶۶ درجه سانتیگراد تحت سناریوی SSP-5.8.5 بوده است، کمترین و بیشترین روند کاهشی تغییرات دمای حداکثر و حداقل نیز در دوره آینده دور نسبت به دوره پایه در این ایستگاه به ترتیب در ماه های جولای (تیرماه) به میزان ۰/۸۶- درجه سانتیگراد تحت سناریوی SSP-1.2.6 و ماه ژوئن (خردادماه) ۱/۰۹- درجه سانتیگراد تحت سناریوی SSP-3.7.0 می باشد.

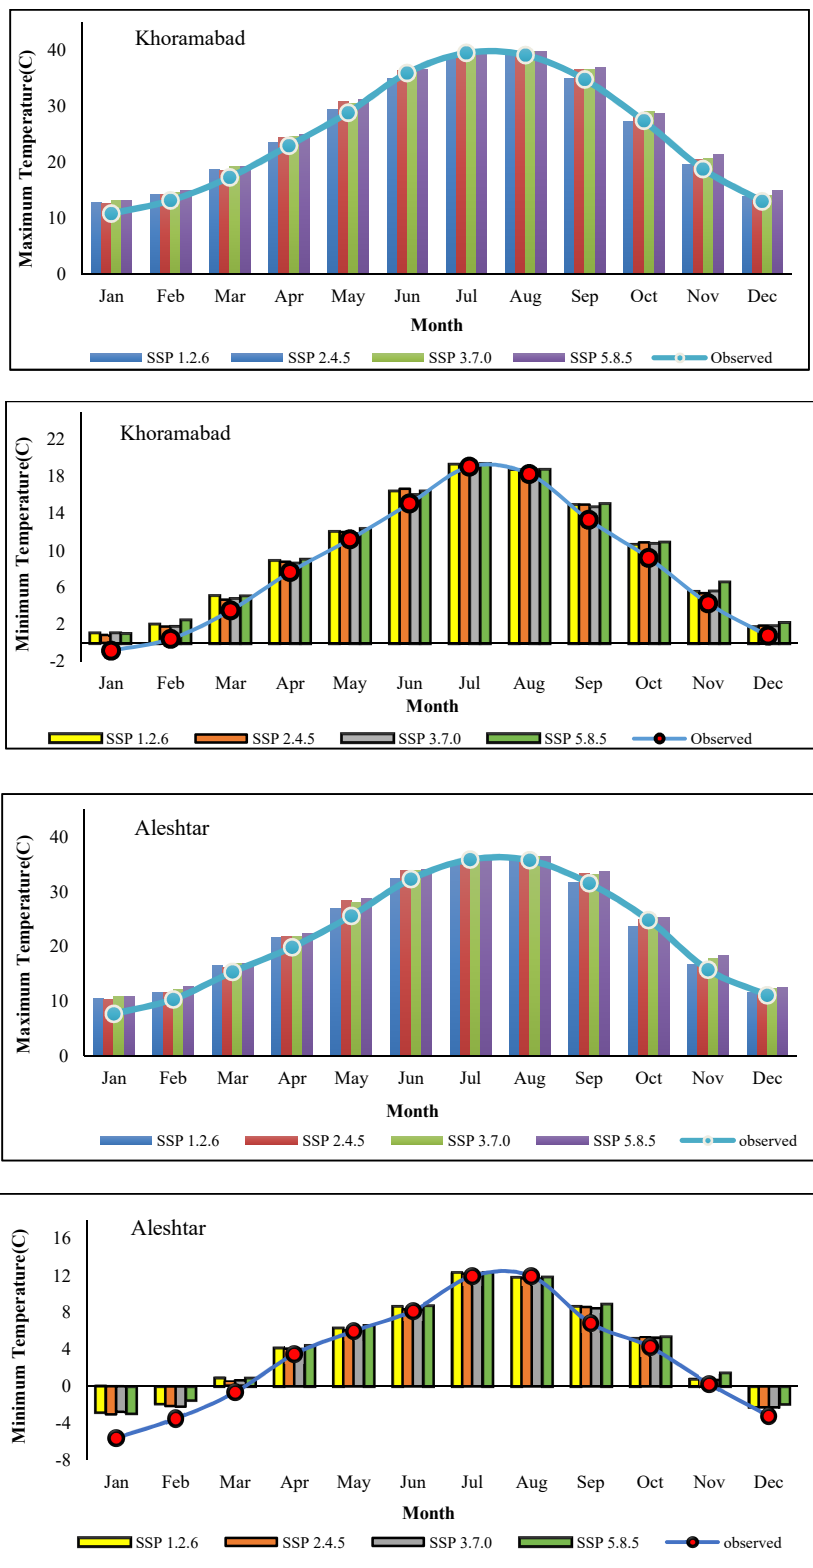


Figure 8. The average monthly maximum and minimum temperature predicted in the near future (2023-2062) with the MRI-ESM2 model SSP emission scenarios along with the temperature chart in the base period (1975-2014), a) Khorramabad station b) Aleshtar station

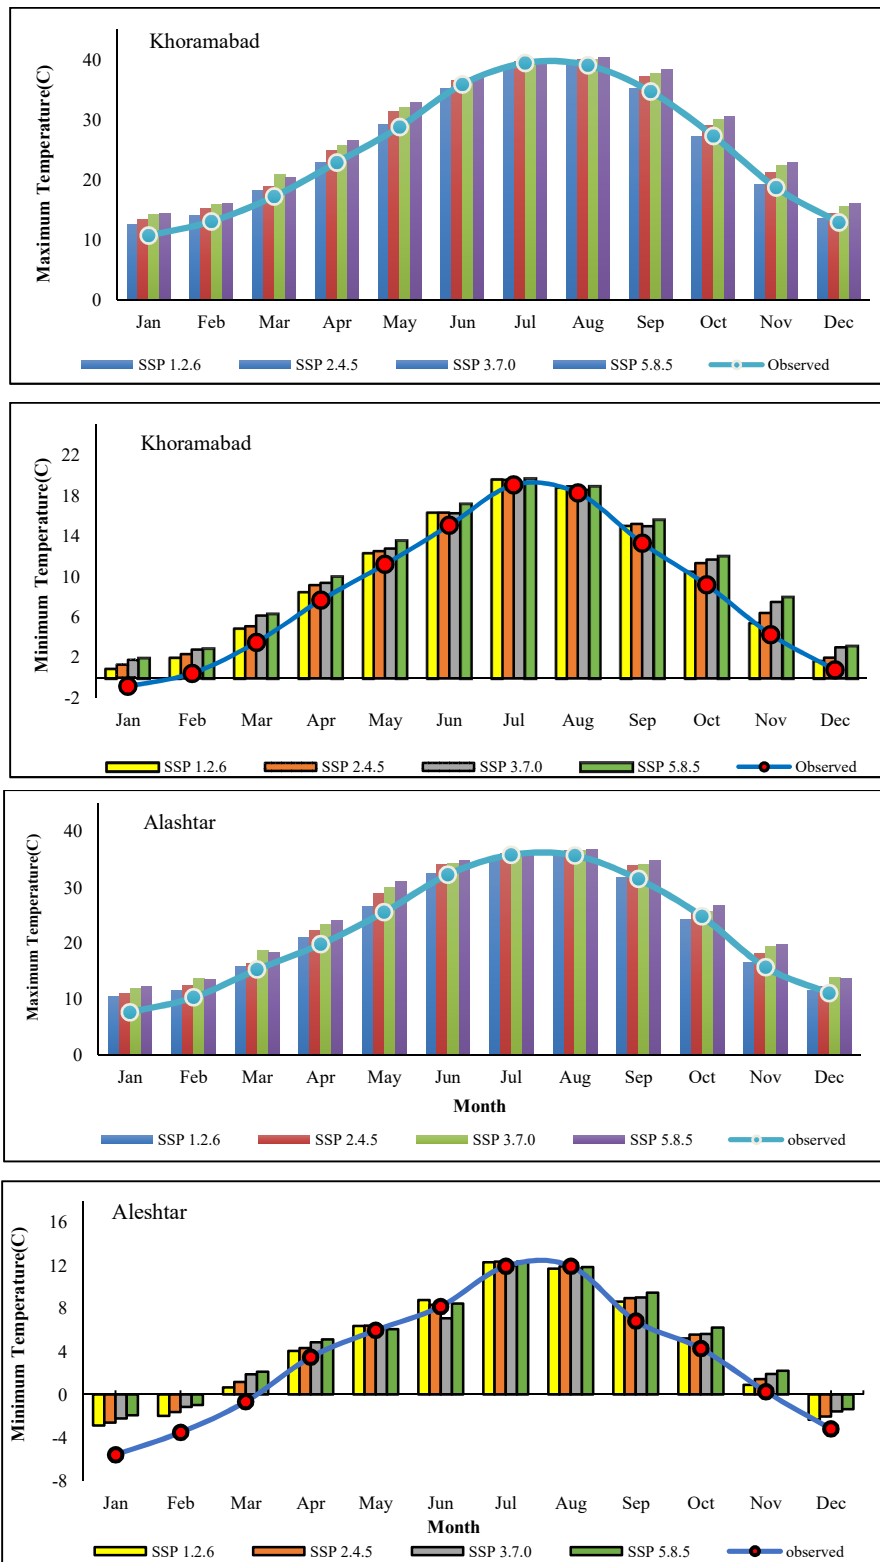


Figure 9. The average maximum and minimum monthly temperature predicted in the distant future (2063-2100) with MRI-ESM2 model SSP release scenarios along with the temperature chart in the base period (1975-2014), a:Khorramabad station, b:Aleshtar station

در ایستگاه خرم‌آباد، کم‌ترین و بیش‌ترین تغییرات افزایشی دمای حداکثر و حداقل ماهانه آینده دور نسبت به دوره پایه در ماه نوامبر (آبان‌ماه) به ترتیب به میزان ۴/۱۹ و ۳/۷۱ درجه سانتی‌گراد تحت سناریوی SSP-5.8.5 بوده است، کم‌ترین و بیش‌ترین روند کاهشی تغییرات دمای حداکثر و حداقل نیز در دوره آینده دور نسبت به دوره پایه در این ایستگاه به ترتیب در ماه‌های ژوئن (خردادماه) به میزان ۰/۷۱- درجه سانتی‌گراد تحت سناریوی SSP-1.2.6 و جولای (تیرماه) به میزان ۰/۲۳ درجه سانتی‌گراد تحت سناریوی SSP-3.7.0 می‌باشد. در ایستگاه الشتر نیز کم‌ترین و بیش‌ترین تغییرات افزایشی دمای حداکثر و حداقل ماهانه آینده دور نسبت به دوره پایه به ترتیب به میزان ۵/۵۱ در ماه می (اردیبهشت‌ماه) و ۳/۶۶ درجه سانتی‌گراد در ماه ژانویه (دی‌ماه) تحت سناریوی SSP-5.8.5 بوده است، کم‌ترین و بیش‌ترین روند کاهشی تغییرات دمای حداکثر در دوره آینده دور نسبت به دوره پایه در این ایستگاه به ترتیب در ماه‌های جولای (تیرماه) به میزان ۰/۸۶- درجه سانتی‌گراد تحت سناریوی SSP-1.2.6 و دمای حداقل نیز در ماه ژوئن (خردادماه) ۱/۰۹- درجه سانتی‌گراد تحت سناریوی SSP-3.7.0 می‌باشد. آینده دور در ایستگاه خرم‌آباد متوسط دمای حداکثر به ۲۵/۴۸ تا ۲۷/۹۹ درجه سانتی‌گراد و دمای حداقل ۹/۶۶ تا ۱۰/۳۲ درجه سانتی‌گراد تحت سناریوها افزایش می‌یابد. در ایستگاه الشتر متوسط دمای حداکثر به ۲۲/۷۹ تا ۲۵/۲۰ درجه سانتی‌گراد و دمای حداقل ۴/۶۱ تا ۴/۹۵ درجه سانتی‌گراد تحت سناریوها افزایش می‌یابد. بنابراین تحت مدل MRI-ESM2 و سناریوهای انتشار گزارش ششم IPCC در آینده دور (۲۰۶۳-۲۱۰۰) شاهد گرمای بیش‌تری نسبت به دو دوره پایه (۲۰۱۴-۱۹۷۵) و آینده نزدیک (۲۰۲۳-۲۰۶۲) در حوضه کشکان خواهیم بود. نتایج تغییرات دمایی پژوهش حاضر در تطابق پژوهش *Yousefi et al.* (2022) و پژوهش *Ansari et al.* (2022) می‌باشد.

#### ۴. نتیجه‌گیری

با مطالعه پژوهش‌های متعددی که در سال‌های اخیر منتشر شده است، می‌توان اذعان نمود که پدیده تغییر اقلیم و اثرات آن، یکی از چالش‌های مهم مدیریت منابع آب در قرن حاضر می‌باشد. به دلیل وقایع حدی که در چند سال اخیر در استان لرستان مشاهده شده است، بررسی پژوهشی جامع که بتواند الگوهای آب‌وهوایی موجود در منطقه را شبیه‌سازی کند از اهمیت زیادی برخوردار خواهد بود. در این پژوهش از جدیدترین سناریوهای انتشار تحت گزارش ششم IPCC استفاده شد. هم‌چنین سعی شد تا با رویکردی جدید نسبت به ریزمقیاس‌نمایی آماری متغیرهای GCM با استفاده از شبکه عصبی مصنوعی پرداخته شود. با وجود این که درخت تصمیم در مهندسی علوم آب کارایی زیادی دارد اما پژوهش حاضر اولین کاربرد این روش به‌عنوان معیار انتخاب مؤثرترین ورودی‌ها در ریزمقیاس‌نمایی متغیرهای GCM با استفاده از مدل شبکه عصبی مصنوعی تحت گزارش ششم می‌باشد. براساس این پژوهش، مدل MRI-ESM2 بهترین تطابق را با داده‌های مشاهداتی داشت و به‌عنوان بهترین و دقیق‌ترین مدل برای انتخاب در مورد بارش و دمای بیشینه و دمای کمینه انتخاب شد، نتایج این مدل در راستای نتایج پژوهش *Ansari et al.* (2022) پس از انتخاب غالب‌ترین متغیرهای پیش‌بینی‌کننده مدل MRI-ESM2 با کاربرد مدل درخت تصمیم (M5 Tree) و اعمال متغیرهای پیش‌بینی‌کننده به‌عنوان ورودی مدل ریزمقیاس‌نمایی آماری شبکه عصبی مصنوعی (ANN) و الگوریتم بهینه‌سازی کرم شبتاب (FFA)، متغیرهای بارش و دما برای دوره پایه (۲۰۱۴-۱۹۷۰) با مقادیر شاخص‌های آماری مطلوب، ریزمقیاس شدند. نتایج بررسی تغییرات بارش در دوره آینده نزدیک (۲۰۲۳-۲۰۶۲) تحت مدل گردش عمومی MRI-ESM2 و مدل ریزمقیاس‌نمایی ANN نشان داد که متوسط بارش ماهانه برای آینده نزدیک نسبت به دوره پایه (۲۰۱۴-۱۹۷۵) در ماه‌های مختلف نوسان دارد و بیش‌تر به‌صورت کاهشی است. این مطالعه، نخستین تلاش برای بررسی اثرات تغییرات

اقلیمی بر وضعیت آب‌وهوایی در ایستگاه خرم‌آباد و الشتر با استفاده از دو مدل از CMIP6 است. با توجه به این‌که سناریوهای گزارش ششم، سناریوهای اجتماعی اقتصادی (SSP) را نیز اعمال می‌کنند، نتایج حاصل از این پژوهش می‌تواند در برنامه‌ریزی و مدیریت بهتر و هم‌چنین، اتخاذ تصمیم‌های سیاستی مثمر ثمر واقع شود.

## ۵. پی‌نوشت‌ها

1. Sixth Assessment Report
2. Synthesis Report
3. Shared Socioeconomic Pathways (SSPs)
4. Coupled Model Intercomparison Project phase 6
5. Data mining
6. Directed
7. Undirected
8. Deterministic
9. Smoother

## ۶. تعارض منافع

هیچ‌گونه تعارض منافی بین نویسندگان وجود ندارد.

## ۷. منابع مورد استفاده

- Ali, N. M. S., Güven, A., & Al-Juboori, A. M. (2018). Statistical Downscaling of Precipitation and Temperature Using Gene Expression Programming. *Journal of Advanced Physics*, 7(4), 518-521.
- Alizadeh Jabejdar, A., Asadi E., & Ghorbani, M. A. (2021). Selection of the most appropriate GCM models of IPCC's fourth, fifth and sixth assessment reports (Case Study: Ardabil synoptic station). Second International Conference and Fifth National Conference on Natural Resources and Environment.
- Alizadeh Jabejdar, A. (2021). *Simulation of the inlet runoff to Yamchi Dam in Ardabil under the influence of climate change scenarios*. Master dissertation, Tabriz University, 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 Systems and Environment*, 4(3), 455-475.
- Anh, Q. T., & Taniguchi, K. (2018). Coupling dynamical and statistical downscaling for high-resolution rainfall forecasting: Case study of the Red River Delta, Vietnam. *Progress in Earth and Planetary Science*, 5(1), 1-18.
- Ansari, S., Dehban, H., Zareian, M., & Farokhnia, A. (2022). Investigation of temperature and precipitation changes in the Iran's basins in the next 20 years based on the output of CMIP6 model. *Iranian Water Researches Journal*, 16(1), 11-24. (In Persian).
- Asakereh, H., & Gholami, A. (2021). 'Simulating maximum temperature recorded in Qazvin Synoptic Station Using Statistical Downscaling of CanESM2 Output', *Scientific- Research Quarterly of Geographical Data (SEPEHR)*, 30(118), 25-41. (In Persian).
- Aryal, A., Shrestha, S., & Babel, M.S. (2019). Quantifying the sources of uncertainty in an ensemble of hydrological climate-impact projections. *Theoretical and Applied Climatology*, 135(1/2), 193-209.
- Bates, B., Kundzewicz, Z., & Wu, S. (2008). Climate change and water Intergovernmental Panel on Climate Change Secretariat.

- Bhattacharya, B., & Solomatine, D. P. (2006). Machine learning in sedimentation modelling. *Neural Networks*, 19(2), 208-214.
- Bowden, G. J., Dandy, G. C., & Maier, H. R. (2005). Input determination for neural network models in water resources applications. Part 1-background and methodology. *Journal of Hydrology*, 301(1-4), 75-92.
- Chen, C., Kalra, A., & Ahmad, S. (2019). Hydrologic responses to climate change using downscaled GCM data on a watershed scale. *Journal of Water and Climate Change*, 10(1), 63-77.
- Camposano, L., Tenelanda, D., Sanchez, E., Samaniego, E., & Feyen, J. (2016). Comparison of Statistical Downscaling Methods for Monthly Total Precipitation: Case Study for the Paute River Basin in Southern Ecuador. *Advances in Meteorology*, 13pp.
- Danandeh Mehr, A., Sorman, A. U., Kahya, E., & Hesami Afshar, M. (2020). Climate change impacts on meteorological drought using SPI and SPEI: case study of Ankara, Turkey. *Hydrological Sciences Journal*, 65(2), 254-268.
- Dibike, B.Y., & Coulibaly, P. (2006). Temporal neural networks for downscaling climate variability and extremes. *Neural Networks*, 19, 135-144.
- Fischer, G., Tubiello, F. N., Van Velthuizen, H., & Wiberg, D. A. (2007). Climate change impacts on irrigation water requirements: Effects of mitigation, 1990–2080. *Technological Forecasting and Social Change*, 74(7), 1083-1107.
- Fowler, H. J., Blenkinsop, S., & Tebaldi, C. (2007). Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 27(12), 1547-1578.
- García-García, A., Cuesta-Valero, F. J., Beltrami, H., & Smerdon, J. E. (2019). Characterization of air and ground temperature relationships within the CMIP5 historical and future climate simulations: *Journal of Geophysical Research: Atmospheres*, 124(7), 3903-3929.
- Gidden, M. J., Riahi, K., Smith, S. J., Fujimori, S., Luderer, G., Kriegler, E., & Takahashi, K. (2019). Global emissions pathways under different socioeconomic scenarios for use in CMIP6: a dataset of harmonized emissions trajectories through the end of the century. *Geoscientific Modeldevelopment*, 12(4), 1443-1475.
- Ghorbani, M. A., Deo, R. C., Karimi, V., Yaseen, Z. M., & Terzi, O. (2018). Implementation of a hybrid MLP-FFA model for water level prediction of Lake Egirdir, Turkey. *Stochastic Environmental Research and Risk Assessment*, 32(6), 1683-1697.
- Haykin, S. (1996). Neural networks expand SP's horizons. *IEEE Signal Processing Magazine*, 13(2), 24-49.
- Jato-Espino, D., Sillanpää, N., Charlesworth, S. M., & Rodriguez-Hernandez, J. (2019). A simulation-optimization methodology to model urban catchments under non-stationary extreme rainfall events. *Environmental Modelling & Software*, 122, 103960.
- Kasiri, M., Goodarzi, M., Jnbaz Ghobadi, G. R., Motavali, S. (2020). Future Projection of temperature and precipitation changes in the southern coast of Caspian sea. *Physical Geography Quarterly*, 13(47), 2020, 35-51.
- Kim, J. H., Sung, J. H., Chung, E. S., Kim, S. U., Son, M., & Shiru, M. S. (2021). Comparison of projection in meteorological and hydrological droughts in the Cheongmicheon Watershed for RCP4. 5 and SSP2-4.5. *Sustainability*, 13(4), 2066.
- Kisi, Ö. (2004). Multi-layer perceptrons with Levenberg-Marquardt training algorithm for suspended sediment concentration prediction and estimation/Prévision et estimation de la concentration en matières en suspension avec des perceptrons multi-couches et l'algorithme 156 d'apprentissage de Levenberg-Marquardt. *Hydrological Sciences Journal*, 49(6).
- Laddimath, R. S., & Patil, N. S. (2019). Artificial neural network technique for statistical downscaling of global climate model. *MAPAN-Journal of Metrology Society of India*, Springer, 34(1), 121-127.

- Mahdizadeh, S., Meftah halghi, M., Seyyed Ghasemi, S., & Mosaedi, A. (2011). Study of precipitation variation due to climate change (Case study: Golestan dam basin). *Journal of Water and Soil Conservation*, 18(3), 117-132. (In Persian)
- Montenegro-Murillo, D. D., Pérez-Ortiz, M. A., & Vargas-Franco, V. (2019). Using Artificial Neural Networks to predict monthly precipitation for the Cali river basin, Colombia. *Dyna*, 86(211), 122-130.
- Nengker, T., Choudhary, A., & Dimri, A. P. (2018). Assessment of the performance of CORDEX-SA experiments in simulating seasonal mean temperature over the Himalayan region for the present climate: part I: *Climate Dynamics*, 50, 2411-2441.
- Nie, S., Fu, S., Cao, W., & Jia, X. (2020). Comparison of monthly air and land surface temperature extremes simulated using CMIP5 and CMIP6 versions of the Beijing Climate Center climate model: *Theoretical and Applied Climatology*, 1-16.
- Nourani, V., Rouzegari, N., Molajou, A., & Baghanam, A. H. (2020). An integrated simulation-optimization framework to optimize the reservoir operation adapted to climate change scenarios. *Journal of Hydrology*, 587, 125018.
- Nourani, V., Razzaghzadeh, Z., Baghanam, A. H., & Molajou, A. (2019). ANNbased statistical downscaling of climatic parameters using decision tree predictor screening method. *Theoretical and Applied Climatology*, 137(3), 1729-1746
- Olsson, T., Kämäräinen, M., Santos, D., Seitola, T., Tuomenvirta, H., Haavisto, R., & Lavado-Casimiro, W. (2017). Downscaling climate projections for the Peruvian coastal Chancay-Huaral Basin to support river discharge modeling with WEAP. *Journal of Hydrology: Regional Studies*, 13, 26-42.
- Omidvar, E., Rezaei, M., & Pirnia, A. (2019). Performance Evaluation of Artificial Neural Network Models for Downscaling and Predicting of Climate Variables . *Journal of Watershed Management Research*, 9 (18), 80-90. (In Persian)
- O'Neill, B. C., Tebaldi, C., Vuuren, D. P. V., Eyring, V., Friedlingstein, P., Hurtt, G., & Sanderson, B. M. (2016). The scenario model intercomparison project (ScenarioMIP) for CMIP6. *Geoscientific Model Development*, 9(9), 3461-3482.
- O'Neill, B. C., Kriegler, E., Ebi, K. L., Kemp-Benedict, E., Riahi, K., Rothman, D. S., & Solecki, W. (2017). The roads ahead: Narratives for shared socioeconomic pathways describing world futures in the 21st century. *Global Environmental Change*, 42, 169-180.
- Pal, M., Singh, N. K., & Tiwari, N. K. (2012). M5 model tree for pier scour prediction using field dataset. *KSCE Journal of Civil Engineering*, 16(6), 1079-1084.
- Pearson, C. J., Bucknell, D., & Laughlin, G. P. (2008). Modelling crop productivity and variability for policy and impacts of climate change in eastern Canada. *Environmental Modelling & Software*, 23(12), 1345-1355.
- Quinlan, J. R. (1992). Learning with continuous classes. In 5th Australian joint conference on artificial intelligence, Vol. 92, 343-348.
- Rahimi, R., & Rahimi, M. (2018). 'Spatial and Temporal Analysis of Climate Change in the Future and Comparison of SDSM, LARS-WG and Artificial Neural Network Downscaling Methods (Case Study: Khuzestan Province)', *Iranian journal of Ecohydrology*, 5(4), 1161-1174. (In Persian)
- Rogelj, J., Popp, A., Calvin, K. V., Luderer, G., Emmerling, J., Gernaat, D., & Tavoni, M. (2018). Scenarios towards limiting global mean temperature increase below 1.5 C. *Nature Climate Change*, 8(4), 325-332.
- Sarzaeim, P., Bozorg-Haddad, O., Bozorgi, A., & Loáiciga, H. A. (2017). Runoff projection under climate change conditions with data-mining methods. *Journal of Irrigation and Drainage Engineering*, 143(8), 04017026.
- Sharafti, A., & Khazaei, M. (2017). Exploration of Randomness Characteristic of Rainfall Pattern Using RDP Model in Symareh Catchment., *Journal of Environmental Science and Technology*, 19(1), 1-14. (In Persian)



- Tabari, H., Shadmani, M., Sabziparvar, A., & Marofi, S. (2008). Comparison of empirical methods, nonlinear regression and artificial neural network in estimating daily evaporation from class A evaporation pan in a dry region. 3rd Iran Water Resources Management Conference, Tabriz. (In Persian)
- Kawagoe, S., & Sarukkalige, R. (2019). Estimation of probable maximum precipitation at three provinces in Northeast Vietnam using historical data and future climate change scenarios. *Journal of Hydrology: Regional Studies*, 23, 100599.
- Teegavarapu, R. S., & Goly, A. (2018). Optimal selection of predictor variables in statistical downscaling models of precipitation. *Water Resources Management*, 32(6), 1969-1992.
- Tripathi, S., Srinivas, V., & Nanjundiah, R.S. (2006). Downscaling of precipitation for climate change scenarios: A support vector machine approach. *Journal of Hydrology*, Pp: 621-640.
- Valipour, E., Ghorbani, M., & Asadi, E. (2019). Evaluation and Optimization of Rain Gauge Network Based on the Geostatistic Methods and Firefly Algorithm. (Case study: Eastern Basin of Urmia Lake). *Irrigation Sciences and Engineering*, 42(4), 153-166
- Wilby, R. L., Dawson, C.W., & Barrow, E.M. (2002). SDSM- A Decision Support Tool for the Assessment of Regional Climate Change Impacts. *Journal of Environmental Modeling and Software*, 17, 147-159
- Xu, C. Y. (1999). From GCMs to river flow: a review of downscaling methods and hydrologic modelling approaches. *Progress in physical Geography*, 23(2), 229-249.
- Witten, I. H., & Frank, E. (2006). *Data mining: Practical machine learning tools and techniques* 2nd edition.
- Yang, X. S. (2010). Firefly algorithm, stochastic test functions and design optimisation. *International Journal of Bio-Inspired Computation*, 2(2), 78-84.
- Yousefi, H., Pirbazari, S., Moridi, A., Khajehpour, H., Karbasi, H., & Fathi, T. (2021). 'Investigating Temperature Variation due to Climate Change in Iran', *Water and Irrigation Management*, 11(2), 237-248. (In Persian)
- Zamani, R., Ali, A. M. A., & Roozbahani, A. (2020). Evaluation of adaptation scenarios for climate change impacts on agricultural water allocation using Fuzzy MCDM Methods. *Water Resources Management*, 34(3), 1093-1110.
- Zarrin, A., & Dadashi-Roudbari, A. (2022). Evaluation of CMIP6 models in estimating the temperature in Iran with emphasis on Equilibrium Climate Sensitivity (ECS) and Transient Climate Response (TCR). *Iranian Journal of Geophysics*. (In Persian)
- Zhu, X., Dong, W., Wei, Z., Guo, Y., Gao, X., Wen, X., & Chen, J. (2018). Multi-decadal evolution characteristics of global surface temperature anomaly data shown by observation and CMIP5 models: *International Journal of Climatology*, 38, 1533-1542.