



Golestan University



Journal of the Climate Change Research

Scientific Journal of Golestan University
Vol. 7, No. 25, Spring 2026



Drought monitoring based on the Standardized Precipitation-Evaporation Index SPEI under the influence of climate change and the XGBoost algorithm

Hadi Ramezani Etedali^{1*}, Mojgan Ahmadi²

¹Associate Professor, Department of Water Science and Engineering, Imam Khomeini International University, Qazvin, Iran. Email: ramezani@eng.ikiu.ac.ir.

²Ph.D. Graduate, Department of Water Science and Engineering, Imam Khomeini International University, Qazvin, Iran. Email: mojganahmadi90@gmail.com.

Article Info

Article type:
Research Full Paper

Article history:
Received: 2025-12-25
Accepted: 2026-2-12

Keywords:
Atmospheric general circulation model
ensemble model
machine learning
Scenarios Six Report

ABSTRACT

In recent years, following the occurrence of global warming and changes in climate patterns and meteorological parameters, the frequency of droughts has increased in many regions of the world. In this study, drought monitoring using the SPEI index and examining the characteristics of this phenomenon (intensity, magnitude, duration) under climate change conditions at the Qazvin synoptic station in the historical period 2014-1986 and the future periods 2050-2026, 2051-2075 and 2100-2076 under SSP2-4.5 and SSP5-8.5 scenarios at time scales of 3, 6, 9 and 12 months have been studied. To reduce the uncertainty associated with individual models and enhance the reliability of the estimates, a machine learning-based Multi-Model Ensemble (MME) approach was employed. The XGBoost algorithm was used to perform a nonlinear and optimized combination of the outputs from three CMIP6 climate models: MIROC6, ACCESS-CM2, and CNRM-CM6-1. Drought characteristics were subsequently calculated based on the ensemble dataset derived from the combined outputs of these three climate models. In the SSP2-4.5 scenario, drought changes showed a slight increasing trend compared to the past. In the period 2026–2050, the average intensity was observed between 2.03 and 3.02, and the magnitude between 0.91 and 1.25. In the pessimistic scenario SSP5-8.5, the trend of increasing drought intensity and magnitude was more obvious. In the first half of the century (2026–2050), the intensity varied between 1.91 and 3.70, and the magnitude between 1.1 and 1.14. Overall, the results showed that both the intensity and magnitude indices of drought have an increasing trend from the past to the future, but the increase in intensity is more dramatic. Thus, it can be concluded that in the future, the study area will face an increase in the frequency, severity, and persistence of droughts, which further highlights the need for adaptation planning, water resource management, and the development of strategies to reduce the effects of drought.

Cite this article: Ramezani Etedali, H., Ahmadi, M. (2026). Drought monitoring based on the Standardized Precipitation-Evaporation Index SPEI under the influence of climate change and the XGBoost algorithm. *Journal of the Climate Change research*, 7 (25), 65-84.



©The author(s)

Publisher: Golestan University

DOI: [10.30488/ccr.2026.568744.1321](https://doi.org/10.30488/ccr.2026.568744.1321)



پایش خشکسالی بر مبنای شاخص بارش - تبخیر و تعرق استاندارد شده SPEI تحت تأثیر تغییر اقلیم و الگوریتم XGBoost

هادی رضانی اعتدالی^{1*}، مژگان احمدی²

¹ استاد گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بین المللی امام خمینی (ره) قزوین، قزوین، ایران. رایانامه: ramezani@eng.ikiu.ac.ir

² دانش آموخته دکتری، گروه علوم و مهندسی آب، دانشگاه بین المللی امام خمینی (ره) قزوین، قزوین، ایران. رایانامه: mojganahmadi90@gmail.com

چکیده	اطلاعات مقاله
<p>در سال‌های اخیر، به دنبال بروز پدیده‌ی گرمایش جهانی و تغییر در الگوهای اقلیمی و پارامترهای هواشناسی، فراوانی وقوع خشکسالی در بسیاری از مناطق جهان افزایش یافته است. در این مطالعه به پایش خشکسالی با استفاده از شاخص SPEI و بررسی خصوصیات این پدیده (شدت، بزرگی، مدت) در شرایط تغییر اقلیم در ایستگاه سینوپتیک قزوین در دوره تاریخی 2014-1986 و دوره‌های آینده 2026-2050، 2051-2075 و 2076-2100 تحت سناریوهای SSP2-4.5 و SSP5-8.5 در مقیاس‌های زمانی 3، 6، 9 و 12 ماهه پرداخته شده است. به منظور کاهش عدم قطعیت مدل‌های منفرد و افزایش قابلیت اعتماد برآوردها، از یک رویکرد ترکیب چندمدلی مبتنی بر یادگیری ماشینی (Multi-Model Ensemble) با استفاده از الگوریتم XGBoost جهت ترکیب غیرخطی و بهینه خروجی سه مدل اقلیمی CMIP6 شامل MIROC6، ACCESS-CM2 و CNRM-CM6-1 استفاده شد. ویژگی‌های خشکسالی بر اساس داده‌های مدل ترکیبی (Ensemble) حاصل از سه مدل اقلیمی محاسبه شدند. در سناریوی SSP2-4.5 تغییرات خشکسالی نسبت به گذشته روندی افزایشی ملایم نشان داد. در دوره‌ی 2026-2050، میانگین شدت بین 2/03 تا 3/02 و بزرگی بین 0/91 تا 1/25 مشاهده شد. در سناریوی بدبینانه SSP5-8.5، روند افزایش شدت و بزرگی خشکسالی‌ها واضح‌تر بود. در نیمه‌ی اول قرن (2050-2026)، شدت بین 1/91 تا 3/70 و بزرگی بین 1/1 تا 1/14 متغیر بود. به‌طور کلی، نتایج نشان داد که هر دو شاخص شدت و بزرگی خشکسالی از گذشته به آینده روندی افزایشی دارند، اما افزایش شدت چشمگیرتر است. بدین ترتیب می‌توان نتیجه گرفت که در آینده، منطقه‌ی مورد مطالعه با افزایش فراوانی، شدت و پایداری خشکسالی‌ها مواجه خواهد شد و این امر ضرورت برنامه‌ریزی سازگاری، مدیریت منابع آب و توسعه‌ی راهبردهای کاهش اثرات خشکسالی را بیش از پیش آشکار می‌سازد.</p>	<p>نوع مقاله: مقاله کامل علمی</p> <p>تاریخ دریافت: 1404/10/5 تاریخ پذیرش: 1404/11/24</p> <p>واژه‌های کلیدی: مدل گردش عمومی جو مدل گروهی یادگیری ماشینی سناریوهای گزارش ششم</p>

استناد: رضانی اعتدالی، هادی؛ احمدی؛ مژگان (۱۴۰۵). پایش خشکسالی بر مبنای شاخص بارش - تبخیر و تعرق استاندارد شده SPEI تحت تأثیر تغییر اقلیم و الگوریتم XGBoost. نشریه پژوهش‌های تغییرات آب و هوایی، 7 (۲۵)، 65-84.



مقدمه

خشکسالی یکی از مخرب‌ترین مخاطرات طبیعی است که به طور قابل توجهی بر اقتصاد، جوامع و محیط زیست تأثیر می‌گذارد. انتظار می‌رود تغییرات اقلیمی ویژگی‌های خشکسالی آینده را تغییر دهد و ممکن است شدت خشکسالی‌ها را افزایش دهد. برای کاهش این اثرات، شناسایی ویژگی‌های خشکسالی‌های آینده تحت تأثیر تغییرات اقلیمی با استفاده از روش‌های مناسب ضروری است.

تغییرات اقلیمی باعث افزایش پیچیدگی و شدت رویدادهای هیدرولوژیکی منطقه‌ای شده و بر منابع آب، امنیت غذایی و مدیریت سیل تأثیرگذار است (Cook et al., 2020; Li and Fang, 2016; Meaurio et al., 2017; Schilling et al., 2020; Zheng et al., 2018). بارش، به عنوان مؤلفه کلیدی چرخه آب، رابطه بارش-رواناب را شکل می‌دهد و تغییرات اقلیمی این رابطه را دچار نوسان می‌کند (Li et al., 2017; Wang et al., 2021). بنابراین، پیش‌بینی دقیق تغییرات بارش و شرایط خشکسالی در آینده برای کاهش اثرات منفی نوسانات هیدرولوژیکی، کاهش خطرات سیل و مدیریت منابع آب اهمیت ویژه‌ای دارد (Li et al., 2020; Xiong et al., 2017).

مدل‌های گردش عمومی جو (GCM) یکی از ابزارهای اصلی بررسی تغییرات اقلیمی هستند که از زمان اجرای پروژه CMIP در سال ۱۹۹۵ به طور گسترده مورد استفاده قرار گرفته‌اند (Eyring et al., 2016; Kim et al., 2020). این مدل‌ها با توسعه مراحل CMIP تا CMIP6، دارای وضوح مکانی بالاتر، دوره‌های شبیه‌سازی تاریخی طولانی‌تر و فرآیندهای فیزیکی پیچیده‌تر هستند و سناریوهای آینده دقیق‌تری ارائه می‌دهند (Eyring et al., 2016; O'Neill et al., 2013). با این حال، محدودیت‌ها و عدم قطعیت‌های سیستماتیک همچنان وجود دارد که ناشی از فرضیات ساده‌شده، سوگیری پارامترها و برآوردهای غیرواقعی فعالیت‌های طبیعی و انسانی است (Chen & Friedman, 2014; Eyring et al., 2016; Reichler & Kim, 2008; Wang et al., 2022; S. Zhang & Chen, 2021; Zhao et al., 2022).

برای کاهش این عدم قطعیت‌ها، روش‌های کوچک‌مقیاس‌سازی آماری و دینامیکی توسعه یافته‌اند، که روش آماری به دلیل کارایی محاسباتی بالا، سادگی و هزینه کم کاربرد گسترده‌ای دارد و معمولاً تحت عنوان تصحیح سوگیری (bias correction) استفاده می‌شود. روش‌های آماری مختلف شامل نگاشت چندکی، مقیاس‌بندی خطی، روش دلتا، روش توزیع احتمال تجمعی انتقالی و روش تطبیق توابع توزیع تجمعی هم‌فاصله هستند (Guo et al., 2018; Patel et al., 2021; Tong et al., 2020). میلانگین مدل گروهی (Ensemble Mean) که میانگین شبیه‌سازی‌های چند GCM است، یکی از متداول‌ترین رویکردهاست و مطالعات نشان داده‌اند که روش گروهی معمولاً عملکرد بهتری نسبت به مدل‌های منفرد دارد (Oh & Suh, 2016; D. Wang et al., 2021; Wang et al., 2021; Yue et al., 2022).

با پیشرفت الگوریتم‌های هوش مصنوعی، مدل‌های یادگیری ماشین برای توسعه مدل‌های گروهی نیز به کار گرفته شده‌اند و عملکرد بهتری نسبت به روش‌های سنتی از خود نشان داده‌اند (Ahmed et al., 2020; Jose et al., 2022; Xu et al., 2020; Yu et al., 2022). برای مثال، Crawford et al. (2019) توانایی مدل‌های گروهی مبتنی بر جنگل تصادفی، رگرسیون بردار پشتیبان، شبکه عصبی و رگرسیون خطی چندگانه را در شبیه‌سازی بارش و دمای گذشته در منطقه خلیج آمریکای شمالی ارزیابی کردند و نشان دادند که این روش‌ها عملکرد بهتری نسبت به مدل‌های منفرد GCM و میانگین مدل گروهی دارند. Ahmed et al. (2020) نیز کارایی مدل‌های گروهی مبتنی بر شبکه عصبی، KNN، رگرسیون بردار پشتیبان و ماشین بردار مرتبط را بررسی کردند و دریافتند که KNN و ماشین بردار مرتبط بالاترین مهارت را دارند. Jose et al. (2022) نشان دادند که روش‌های یادگیری ماشین شامل ماشین بردار پشتیبان، درخت اضافی، جنگل تصادفی و شبکه LSTM نسبت به میانگین مدل گروهی دقت بالاتری در شبیه‌سازی بارش و دما دارند. Acharya et al. (2013) گزارش کردند که XGBoost

محسوب می‌شود. در این پژوهش، برای افزایش دقت پیش‌بینی متغیرهای اقلیمی در سطح منطقه‌ای، سه مدل گردش عمومی جو (GCM) با استفاده از الگوریتم XGBoost ترکیب شده و یک مدل ترکیبی (ensemble) کارآمد توسعه یافته است. بر اساس خروجی این مدل ترکیبی، تغییرات بارش، دمای حداقل و دمای حداکثر برای دوره‌های آینده ارزیابی شده‌اند.

نوآوری اصلی این مطالعه در توسعه یک چارچوب Ensemble هوشمند مبتنی بر یادگیری ماشین برای تحلیل چند متغیر اقلیمی در مقیاس منطقه‌ای و تمرکز بر استان قزوین به عنوان یک منطقه حساس به تغییر اقلیم با اهمیت کشاورزی و منابع آب است. نتایج پژوهش، علاوه بر ارتقای دقت پیش‌بینی، می‌تواند ابزاری کاربردی برای برنامه‌ریزی مدیریت منابع آب و توسعه راهبردهای سازگاری با تغییر اقلیم در این منطقه ارائه دهد.

داده و روش‌ها

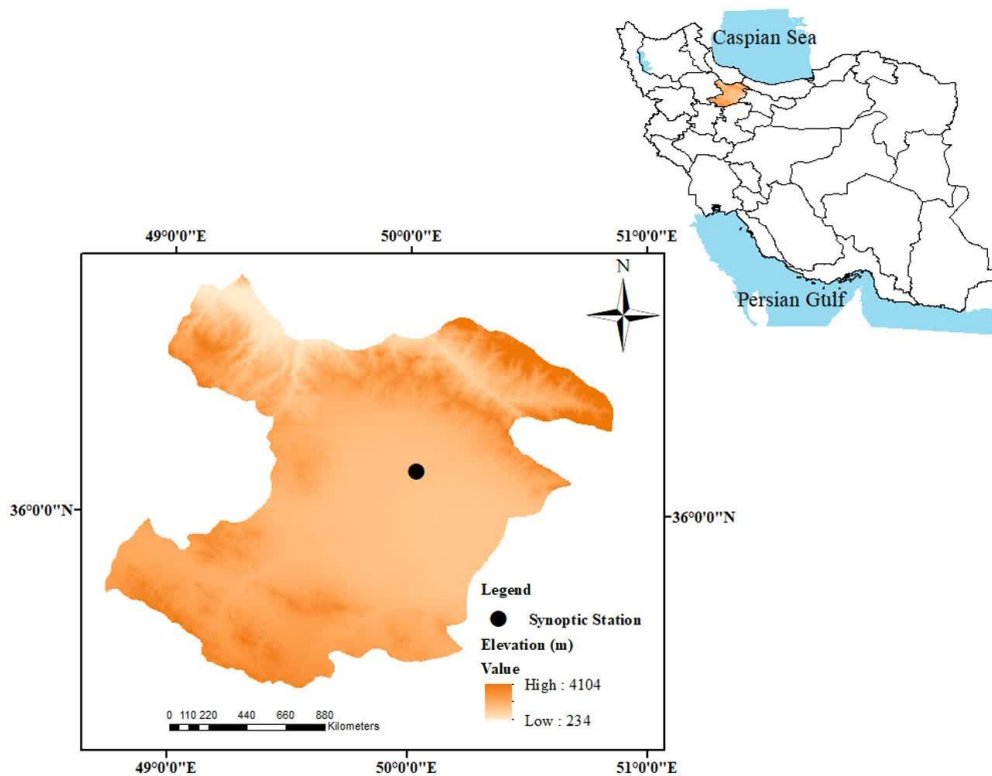
منطقه مورد مطالعه: استان قزوین در بخش شمال‌غربی ایران جای گرفته و از نظر فعالیت‌های کشاورزی، یکی از مناطق کلیدی کشور محسوب می‌شود (شکل 1). وجود دشت حاصلخیز قزوین با مساحتی نزدیک به ۴۵۰ هزار هکتار، اهمیت ویژه‌ای به این استان در تولید محصولات کشاورزی بخشیده است. بارندگی سالانه در استان تغییرپذیر بوده و از حدود ۲۱۰ میلی‌متر در نواحی شرقی تا بیش از ۵۵۰ میلی‌متر در ارتفاعات شمال‌شرقی افزایش می‌یابد. برای انجام این پژوهش از داده‌های ایستگاه سینوپتیک قزوین استفاده شد که در طول جغرافیایی 50/03 درجه شرقی، عرض جغرافیایی 36/15 درجه شمالی و ارتفاع 1279/2 متر از سطح دریا واقع شده است. اطلاعات ایستگاه سینوپتیک از سازمان هواشناسی دریافت شد.

بارش موسمی شمال‌شرقی شبه‌جزیره هند را با دقت و سرعت بیشتری نسبت به میانگین مدل گروهی و رگرسیون خطی چندگانه شبیه‌سازی می‌کند. همچنین Wang et al., (2018) دریافتند که جنگل تصادفی و ماشین بردار پشتیبان نسبت به روش‌های میانگین‌گیری بیزین و دیگر روش‌ها برتر هستند.

بنابراین، استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین در کنار مدل‌های گروهی، ابزار قدرتمندی برای پیش‌خشکسالی و ارزیابی اثر تغییر اقلیم در مقیاس منطقه‌ای محسوب می‌شود و مطالعات متعدد بین‌المللی در دو-سه سال اخیر بر این کاربرد تأکید کرده‌اند.

همان‌طور که اشاره شد، الگوریتم‌های یادگیری ماشین در توسعه مدل‌های گروهی عملکرد به‌مراتب بهتری نسبت به مدل‌های منفرد GCM و روش‌های سنتی دارند. با این حال، کاربرد این الگوریتم‌ها برای توسعه مدل‌های گروهی مبتنی بر GCM به‌منظور ارزیابی اثرات تغییر اقلیم هنوز محدود و در مراحل ابتدایی قرار دارد. هر مدل منفرد نقاط قوت و ضعف خاص خود را دارد و توانایی محدودی در ثبت روابط پیچیده و غیرخطی داده‌های اقلیمی دارد. به همین دلیل، بررسی پتانسیل الگوریتم‌های مختلف یادگیری ماشین برای بهبود مدل‌های گروهی و کاهش عدم قطعیت‌ها در پیش‌بینی تغییرات اقلیمی یک گپ مطالعاتی مهم محسوب می‌شود. علاوه بر این، هنوز قابلیت تعمیم این الگوریتم‌ها در مناطق مختلف جهان به‌طور کامل بررسی نشده است. بنابراین، پژوهش‌های بیشتر در این زمینه ضروری است تا روش‌های گروهی مبتنی بر یادگیری ماشین بتوانند به‌عنوان ابزارهای قابل اعتماد برای تحلیل اثرات تغییر اقلیم در مقیاس منطقه‌ای و جهانی مورد استفاده قرار گیرند.

ایران به‌عنوان کشوری واقع در کمربند خشک و نیمه‌خشک جهان، به شدت در معرض تغییرات اقلیمی قرار دارد و استان قزوین به دلیل موقعیت جغرافیایی و اهمیت کشاورزی و منابع آبی، منطقه‌ای حساس



شکل 1: منطقه مورد مطالعه

مجموعه داده‌ی GDDP-CMIP6 برگرفته از خروجی مدل‌های گردش عمومی جو متعلق به پروژه‌ی ICMP6 است که در راستای گزارش ششم هیئت بین‌دولتی تغییر اقلیم (IPCC AR6) توسعه یافته‌اند (Eyring et al., 2016). این مجموعه داده، سناریوهای مختلف انتشار گازهای گلخانه‌ای را مطابق با مسیرهای اجتماعی-اقتصادی مشترک (SSPs) شامل SSP2-4.5 و SSP5-8.5 پوشش می‌دهد (O'Neill et al., 2016; Meinshausen et al., 2020). خروجی مدل‌ها با استفاده از روش آماری (BCSD²) به صورت روزانه ریزمقیاس و تصحیح اریبی شده‌اند. (Thrasher et al., 2022) داده‌ها از طریق سامانه (GEE³) در دسترس قرار دارند و دارای وضوح مکانی 0/25 درجه و تفکیک زمانی روزانه هستند. در این پژوهش، داده‌های روزانه‌ی بارش، دمای حداقل و حداکثر سه مدل اقلیمی ACCESS-، MIROC6 و CNRM-CM6-1 تحت دو سناریوی SSP2-4.5

مدل‌های گردش عمومی جو: CMIP6 آخرین مرحله از همکاری تحت پروژه مقایسه متقابل مدل‌های جفت‌شده (CMIP) است. داده‌های CMIP6 جدیدترین داده‌های موجود در مورد مدل‌های اقلیمی جهانی هستند. این داده‌ها از نظر علمی قوی هستند و پایه و اساس ششمین گزارش‌های ارزیابی هیئت بین‌دولتی تغییرات اقلیمی را فراهم می‌کنند. از «مسیرهای اجتماعی-اقتصادی مشترک» (یا SSP¹ها) برای توسعه آخرین نسل سناریوهای انتشار گازهای گلخانه‌ای استفاده شد. SSPها به طور سیستماتیک روندهای بالقوه اجتماعی-اقتصادی را در طول قرن آینده بررسی کرده و تأثیر این تحولات را بر غلظت گازهای گلخانه‌ای کمی می‌کنند. انتشار گازهای گلخانه‌ای حاصل از این مسیرها به عنوان ورودی برای هدایت مدل‌های اقلیمی و پیش‌بینی سطوح حاصل از تغییرات اقلیمی عمل می‌کند.

³ Google Earth Engine

¹ Shared Socio-economic Pathways

² Bias Correction and Spatial Disaggregation

در روش T , Thornthwaite میانگین دمای ماهانه m , ($^{\circ}C$) ضریب وابستگی به شاخص گرما- I (dependency coefficient) شاخص حرارتی یا مجموع شاخص ۱۲ ماه سال، PET_c تبخیر و تعرق بالقوه تصحیح شده، N تعداد روزهای هر ماه، و D میانگین طولانی‌ترین مدت تابش خورشید در عرض جغرافیایی مورد نظر است. بنابراین، با محاسبه PET ، می‌توان اختلاف بین بارش (P) و تبخیر و تعرق بالقوه (PET) را برای هر ماه i به دست آورد (Selling, 1996).

$$D_i = P_i - PET_i \quad (5)$$

در شاخص SPEI، سری زمانی تراز آبی ابتدا با توزیع لاجستیک لگاریتمی سه پارامتری برازش داده می‌شود و سپس مقدار احتمال تجمعی حاصل $F(x)$ به مقادیر نرمال استاندارد تبدیل می‌گردد؛ بنابراین مقادیر نهایی SPEI بیانگر انحراف استاندارد شده از شرایط نرمال اقلیمی هستند.

$$SPEI = W - \frac{C_0 + C_1W + C_2W^2}{1 + d_1W + d_2W^2 + d_3W^3} \quad (6)$$

در اینجا $W = \sqrt{-2 \ln(p)}$ برای $P < 0.5$ مقدار احتمال برآورد بیش از حد D را نشان می‌دهد. همچنین، ضرایب $C_0, C_1, C_2, d_1, d_2, d_3$ مقادیر ثابت هستند. مقدار صفر برای شاخص SPEI بیانگر حالتی است که با احتمال تجمعی D برابر با ۵۰٪ مطابقت دارد (Vicente-Serrano et al., 2010).

خصوصیات خشکسالی: یکی از رویکردهای رایج در بررسی رخدادهای خشکسالی، استفاده از نظریه ران (Run Theory) است (شکل ۲). این روش امکان استخراج سه مشخصه اساسی خشکسالی شامل تداوم، شدت و بزرگی را فراهم می‌سازد. بر اساس این نظریه، یک دوره خشکسالی زمانی آغاز می‌شود که مقدار متغیر مورد نظر از آستانه بحرانی تعیین شده پایین‌تر رود و تا زمانی ادامه می‌یابد که این مقدار به بالاتر از سطح آستانه بازگردد. در نتیجه، تداوم یا طول دوره

و SSP5-8.5، برای دوره‌ی پایه‌ی 1986-2014 و دوره‌های آتی ۲۰۲۶-۲۰۵۱، ۲۰۵۱-۲۰۷۵ و ۲۰۷۶-۲۱۰۰ مورد استفاده قرار گرفتند.

شاخص خشکسالی SPEI: شاخص SPEI¹ توسط ویسنته-سرانو و همکاران (2010) پیشنهاد شد. شاخص (SPEI) یک شاخص چندزمانه‌ی خشکسالی است و برای تعیین آغاز، مدت‌زمان و شدت خشکسالی در منابع آب، اکوسیستم‌ها و کشاورزی استفاده می‌شود. برخلاف شاخص‌های سنتی مثل SPI که تنها به بارش توجه دارند، SPEI توازن آب را بر اساس اختلاف بین بارش و تبخیر و تعرق بالقوه (PET) در بازه‌های زمانی مختلف (مثلاً ۱ تا ۴۸ ماه) محاسبه می‌کند، که این امر باعث می‌شود حساسیت آن به تغییرات دما و تقاضای تبخیر جو بیشتر باشد و در مطالعات اقلیمی و ارزیابی خشکسالی در عصر تغییرات اقلیمی مناسب‌تر باشد. مقدار SPEI به صورت نرمال شده نشان می‌دهد که توازن آب نسبت به میانگین بلندمدت در یک دوره زمانی معین، در چه حدی خشک‌تر یا ترتر است، که مقادیر منفی نشان‌دهنده خشکسالی و مقادیر مثبت نشان‌دهنده شرایط ترتر از حد نرمال هستند (Vicente-Serrano et al., 2010).

SPEI به همان روش SPI محاسبه می‌شود؛ با این حال، SPEI از تفاوت بین بارش و تبخیر و تعرق پتانسیل (PET) استفاده می‌کند. PET با استفاده از روش Thornthwaite محاسبه شد (Thornthwaite, 1948).

$$PET = 16 \times \left(\frac{10T}{I}\right)^m \quad (1)$$

$$m = 6.75 \times 10^{-7} I^3 - 7.71 \times 10^{-5} I^2 + 1.79 \times 10^{-2} I + 0.49 \quad (2)$$

$$I = \sum_{i=1}^{12} \left(\frac{T_i}{5}\right)^{1.5} \quad (3)$$

$$PET_c = PET \times \left(\frac{D \times N}{360}\right) \quad (4)$$

¹ Standardized Precipitation Evapotranspiration Index

سطح بحرانی قرار دارد، اختلاف آن با آستانه تعیین شده محاسبه و مقادیر این کمبودها با یکدیگر جمع می‌شوند. بر این اساس شدت خشکسالی (DS) با در نظر گرفتن سطح آستانه X_0 برای متغیر اصلی X_t به صورت معادله 8 برآورد گردید (Mosaedi et al., 2017).

$$DS = \sum_{t=1}^{dl} |X_0 - X_t| \quad (8)$$

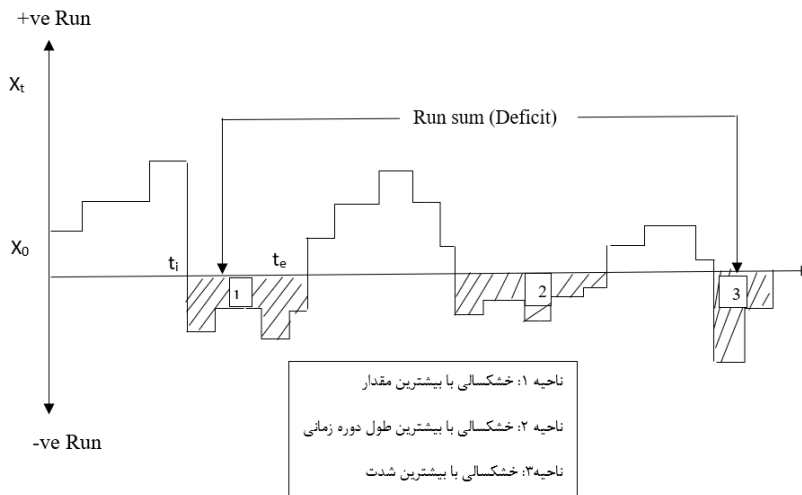
بزرگی خشکسالی (DM) که همان میانگین کمبودها است برابر با نسبت مجموع کمبودها (DS) به طول دوره خشکسالی (DL) بوده که از معادله 9 برآورد شد (Mosaedi et al., 2017).

$$DM = \frac{DS}{DL} \quad (9)$$

خشکسالی به صورت فاصله زمانی‌ای تعریف می‌شود که طی آن شاخص مورد بررسی کمتر از سطح بحرانی قرار دارد. بر این اساس طول دوره خشکسالی یا تداوم خشکسالی با کمک معادله 7 تعیین شد (Mosaedi et al., 2017).

$$DL = t_e - t_i + 1 \quad (7)$$

که در آن t_i و t_e به ترتیب زمان شروع و پایان خشکسالی و DL طول دوره (تداوم) خشکسالی می‌باشد. شدت خشکسالی (DS) به صورت مجموع مقادیر کسری متغیر مورد نظر نسبت به آستانه بحرانی در طول یک دوره خشکسالی تعریف می‌شود. به بیان دیگر، در طی بازه‌ای که مقدار متغیر اصلی کمتر از



شکل 2: نمودار شماتیک خصوصیات خشکسالی با استفاده از تئوری ران با سطح آستانه X_0

دلیل توانایی آن در ساخت تدریجی یک دنباله از یادگیرنده‌های ضعیف، که اغلب درخت‌های تصمیم هستند، مورد توجه قرار گرفته است. در این روش، هر درخت متوالی تلاش می‌کند خطاهای ایجاد شده توسط درخت قبلی را اصلاح کند، که در نهایت منجر به توسعه مدلی دقیق و قدرتمند می‌شود. فرایند تکراری بهبود مدل در XGBoost باعث افزایش تدریجی توان پیش‌بینی آن می‌شود. علاوه بر این، روش‌های منظم‌سازی در XGBoost برای کاهش بیش‌برازش به کار می‌روند. این الگوریتم شامل ضرایب L_1 (LASSO) و L_2 (Ridge) در تابع هدف خود است، که از توسعه مدل‌های بیش از حد پیچیده و تطبیق

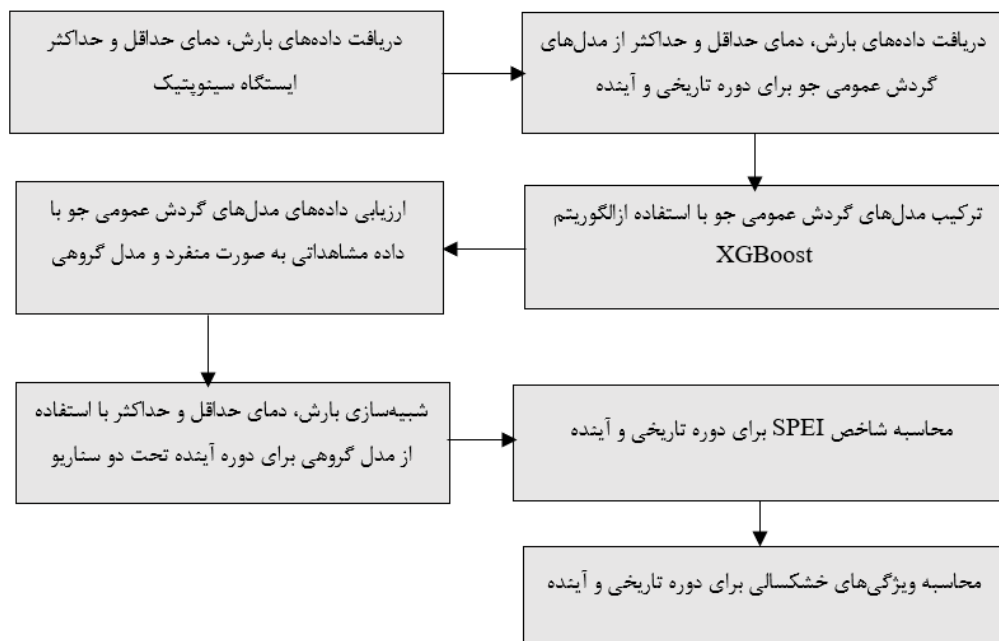
الگوریتم XGboost: XGBoost یک الگوریتم یادگیری ماشینی مبتنی بر تقویت گرادیان است و به دلیل کارایی و عملکرد پیش‌بینی قوی خود در وظایف رگرسیون و طبقه‌بندی شناخته شده است (Chen and Guestrin, 2016). این الگوریتم به ویژه برای پیش‌بینی الگوهای سری زمانی پیچیده مانند بارش و دما مناسب است زیرا می‌تواند وابستگی‌های غیرخطی را از طریق ساختار درختی خود به طور مؤثر ثبت کند (Chen and Guestrin, 2016; Friedman., 2001).

XGBoost که در یادگیری ماشینی به عنوان eXtreme Gradient Boosting شناخته می‌شود، یک الگوریتم قدرتمند تقویتی (boosting) است که به

الگوریتم از امتیاز اهمیت ویژگی‌ها (feature importance) بهره می‌برد تا اطلاعات ارزشمندی درباره نقش هر ویژگی در پیش‌بینی‌ها ارائه دهد و کمک کند تا مشارکت هر متغیر در نتایج مدل قابل درک باشد (Zhang et al., 2022). در این مطالعه با استفاده از الگوریتم XGBoost سه مدل اقلیمی MIROC6، ACCESS-CM2 و CNRM-CM6-1 با هم ترکیب شدند. از نرم افزار R برای روش الگوریتم XGBoost استفاده شده است. مراحل انجام تحقیق در شکل (3) آورده شده است.

بیش از حد با داده‌های آموزشی جلوگیری می‌کند. منظم‌سازی باعث بهبود عملکرد کلی مدل می‌شود و توانایی آن را در تعمیم به داده‌های جدید افزایش می‌دهد. (Chen & Guestrin, 2016)

XGBoost علاوه بر تقویت و منظم‌سازی، از روش‌های بهینه‌سازی مبتنی بر گرادینان نیز استفاده می‌کند تا عملکرد و سرعت همگرایی مدل بهبود یابد. مفهوم gradient boosting در XGBoost به فرآیند آموزش مدل اشاره دارد که با استفاده از روش‌های مبتنی بر گرادینان بهینه‌سازی می‌شود. همچنین، این



شکل 3: مراحل انجام تحقیق

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (11)$$

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (12)$$

در روابط یادشده O_i : مقادیر داده‌های اندازه‌گیری شده، P_i : مقادیر داده‌های شبیه‌سازی شده، \bar{O}_i : میانگین مقادیر داده‌های اندازه‌گیری شده، \bar{P}_i : میانگین مقادیر داده‌های شبیه‌سازی شده و n : تعداد داده‌ها است. RMSE میانگین مقادیر انحراف شبیه‌سازی شده را از مقادیر اندازه‌گیری شده نشان می‌دهد. هرچه مقدار

آماره ارزیابی: برای ارزیابی نتایج به دست آمده از آماره‌های ارزیابی جذر میانگین مربعات خطا ($RMSE^1$)، میانگین مطلق خطا (MAE^2)، خطای اریبی (MBE^3) و ضریب اسپیرمن استفاده شد. محاسبه شاخص‌های مذکور با استفاده از روابط 10 تا 12 امکان‌پذیر می‌باشد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (10)$$

³ Mean Bias Error

¹ Root Mean Squared Error

² Mean Absolute Error

نتایج و بحث

داده‌های ماهانه دمای حداقل، دمای حداکثر، و بارش مدل‌های اقلیمی MIROC6، ACCESS-CM2 و CNRM-CM6-1 با داده ایستگاه سینوپتیک قزوین در دوره پلایه 2014-1986 به صورت جداگانه و گروهی مقایسه شد (جدول 1). در این مطالعه، به منظور بهبود برآورد داده‌های دمای حداقل، دمای حداکثر و بارش حاصل از سه مدل گردش عمومی (GCM)، از الگوریتم XGBoost با هدف کمینه‌سازی ریشه میانگین مربعات خطا (RMSE) نسبت به داده‌های مشاهداتی استفاده شد. در این روش، مدل گروهی به روش الگوریتم XGBoost به گونه‌ای تنظیم شد که ترکیب حاصل، کمترین خطا را نسبت به داده‌های مشاهداتی داشته باشد. به منظور افزایش دقت مدل، ضرایب اصلاحی بارش در فرآیند کالیبراسیون تنظیم شدند تا مدل قادر به بازتولید روندهای اقلیمی آینده باشد.

RMSE کوچکتر باشد به معنی مطلوب بودن مدل می‌باشد. شاخص MBE بیانگر میزان اریبی روش است، در یک تخمین نسبتاً دقیق بایستی نزدیک به صفر باشد. شاخص MAE (میانگین مطلق خطا)، میانگین قدر مطلق اختلاف مقدار اندازه‌گیری شده مدل با مقدار واقعی کمیت می‌باشد. هرچه مقدار آن کمتر باشد دقت مدل بالاتر است.

آزمون اسپیرمن: آزمون اسپیرمن در اوایل دهه 1900 میلادی توسط چارلز اسپیرمن ارائه شد (Yue et al., 2002). آزمون اسپیرمن یک آزمون غیر پارامتری است. فرض صفر این آزمون، یکنواختی توزیع و مستقل بودن داده‌ها در سری زمانی و فرض مقابل آن روند افزایشی یا کاهششی داده‌ها در سری زمانی است.

$$P = 1 - \frac{6(\sum d_i^2)}{n(n^2 - 1)} \quad (13)$$

P ضریب همبستگی اسپیرمن، n تعداد مشاهده‌ها و d_i^2 مجموع مجذورات تفاوت دو رتبه است. در این پژوهش برای محاسبه ضریب اسپیرمن از نرم‌افزار R استفاده شد.

جدول 1: نتایج ارزیابی بارش، دمای حداقل و حداکثر مدل‌های گردش عمومی جو با ایستگاه سینوپتیک (1985-2014)

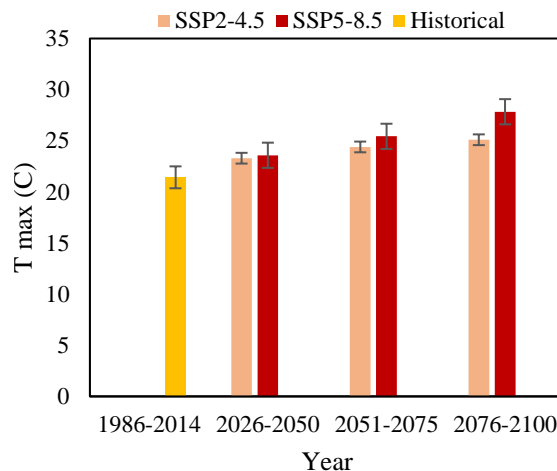
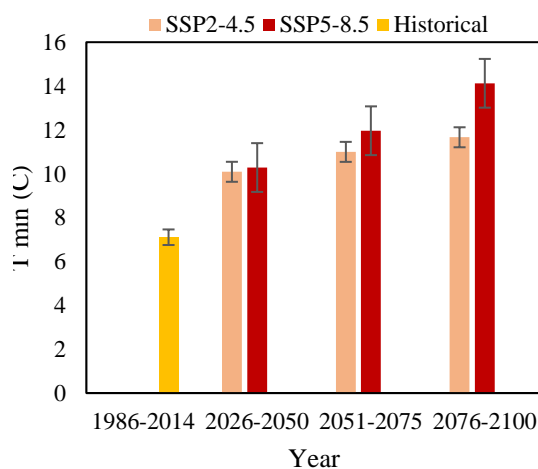
متغیر	مدل	RMSE	MAE	MBE	Spearman
بارش	ACCESS-CM2	31/51	19/43	-6/04	0/63
	CNRM-CM6-1	29/49	18/18	-5/37	0/65
	MIROC6	31/60	19/56	-4/96	0/60
	Ensemble (Train)	24/26	15/66	-6/79	0/80
	Ensemble (Test)	21/86	16/09	-1/14	0/63
دمای حداکثر	ACCESS-CM2	2/82	2/09	0/15	0/96
	CNRM-CM6-1	2/69	2/06	0/13	0/96
	MIROC6	2/74	2/10	-0/12	0/96
	Ensemble (Train)	1/45	1/09	-0/02	0/99
	Ensemble (Test)	2/50	1/91	-0/48	0/96
دمای حداقل	ACCESS-CM2	2/39	1/95	1/32	0/97
	CNRM-CM6-1	2/67	2/22	1/49	0/97
	MIROC6	2/26	1/86	1/34	0/97
	Ensemble (Train)	0/98	0/75	-0/02	0/99
	Ensemble (Test)	1/84	1/27	0/01	0/97


نشان‌دهنده خطای نسبتاً زیاد در برآورد بارش است. الگوریتم XGBoost در داده‌های آزمون عملکرد بسیار

مدل‌های منفرد دارای RMSE حدود 29-32 میلی‌متر و MAE حدود 18-19 میلی‌متر هستند که

داده‌های آموزش تنها $RMSE = 0.98$ و در داده‌های آزمون $RMSE = 1.84$ دارد. همبستگی Spearman در هر دو حالت بالا (0/99-0/97) است. نتایج مطالعه خوزه و همکاران (2022) نشان داد که برای شبیه‌سازی بارش، دمای حداکثر و حداقل، اجرای گروهی مدل‌های گردش عمومی جو با رویکردهای یادگیری ماشین در یک حوضه رودخانه گرمسیری در هند عملکرد بهتری نسبت به رویکرد میانگین گروهی داشتند (Jose et al., 2022). مطالعه‌ی شاهین‌رخسار و همکاران (1398) در ایستگاه سینوپتیک رشت نشان داد که استفاده از ترکیب گروهی مدل‌های گردش عمومی جو در شبیه‌سازی داده‌های هواشناسی، دقت برآورد پارامترهای اقلیمی را به‌طور قابل توجهی افزایش می‌دهد. نتایج این پژوهش با یافته‌های مطالعه‌ی حاضر هم‌راستا است. میانگین سالانه دمای حداقل و حداکثر، بارش در شکل 4 آورده شده است.

بهتری دارد ($RMSE = 21.86$) که نشان دهنده توان بالای آن در یادگیری الگوهای بارش است. و همبستگی 0/63 نشان می‌دهد که مدل توانایی بازتولید نوسانات بارش را به‌صورت قابل قبولی حفظ کرده است. این نتایج نشان دهنده برتری مدل ترکیبی در کاهش خطا و افزایش دقت مکانی-زمانی بارش است. در همه مدل‌ها همبستگی بالا ($Spearman \approx 0.96$) نشان می‌دهد که تغییرات زمانی دمای حداکثر به خوبی شبیه‌سازی شده است. مدل ترکیبی در مرحله آموزش ($RMSE = 1.45$ $MAE = 1.09$)، خطا را تقریباً نصف مدل‌های منفرد کاهش داده است. در داده‌های آزمون $RMSE = 2.50$ است که همچنان بهتر از سه مدل اولیه است. در مجموع، الگوریتم XGBoost توانسته دقت بالا و تعمیم‌پذیری مناسب را در برآورد دمای بیشینه نشان دهد. در دمای حداقل، عملکرد مدل‌ها مشابه دمای حداکثر است. مدل‌های منفرد $RMSE$ حدود 2/2-2/7 دارند، در حالی که مدل ترکیبی در





شکل 4: شبیه سازی بارش، دمای حداقل و حداکثر در دوره های آتی

درجه سانتی گراد برسد، در حالی که بارندگی می تواند به ترتیب تا ۱۹٪ و ۴۳٪ کاهش یابد که با نتایج مطالعه حاضر همخوانی دارد. ایزدی و همکاران (1402) به بررسی تغییرات دمای هوا در شهرستان طبس با استفاده از گزارش ششم تغییر اقلیم و دو سناریو SSP2-4.5 و SSP5-8.5 تا سال 2100 پرداختند. نتایج آنها نشان داد که با استفاده از سناریو SSP2-4.5 دمای هوای طبس نسبت به دوره پایه، 3/2 درجه سلسیوس و با سناریو SSP5-8.5 4/7 درجه سلسیوس افزایش خواهد داشت که با نتایج مطالعه حاضر همخوانی دارد.

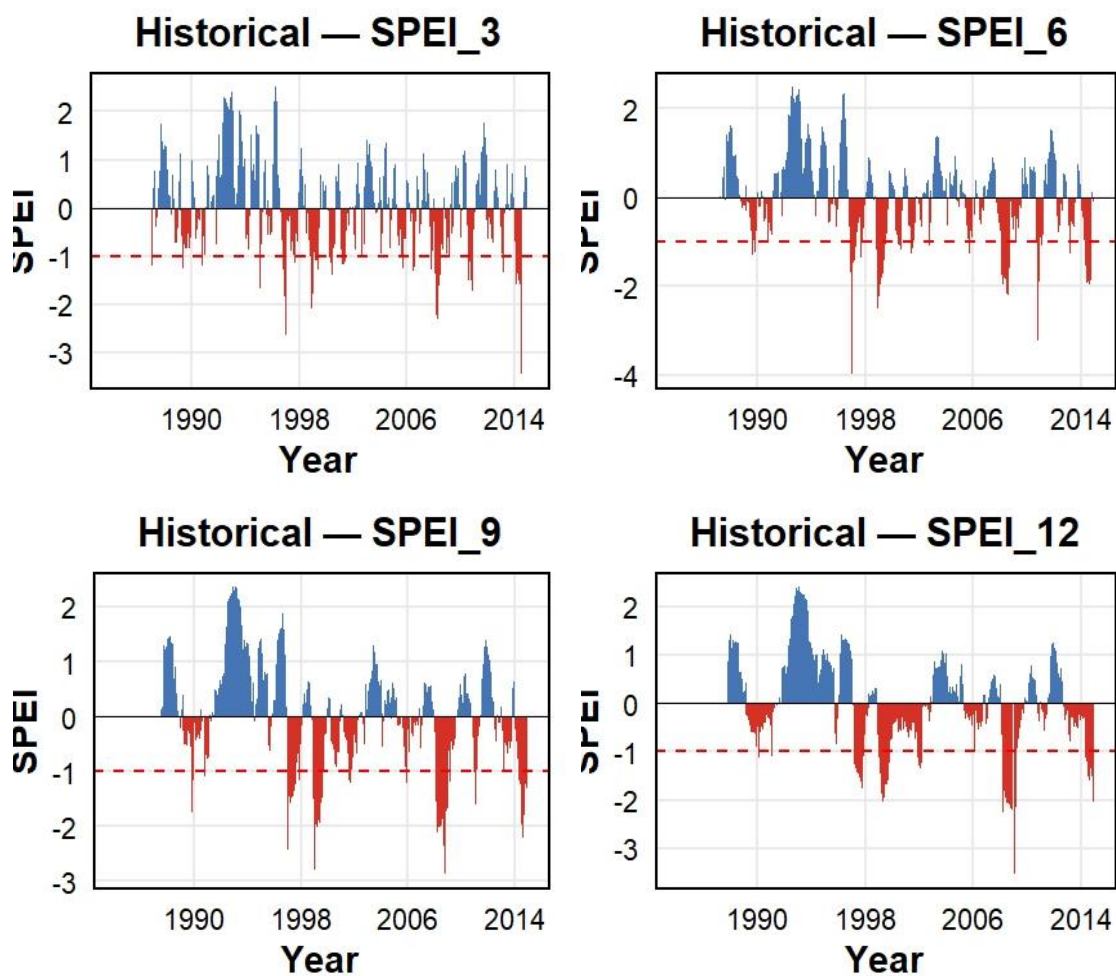
شاخص SPEI: در این پژوهش، شاخص های شدت و بزرگی خشکسالی بر اساس داده های مدل ترکیبی (Ensemble) حاصل از سه مدل گردش عمومی جو و الگوریتم XGBoost برای شبیه سازی شاخص خشکسالی SPEI محاسبه شدند. نتایج برای دوره تاریخی (1985-2014) و سه بازه ی آینده تحت سناریوهای RCP45 و RCP85 در مقیاس های زمانی 3، 6، 9 و 12 ماهه استخراج گردید.

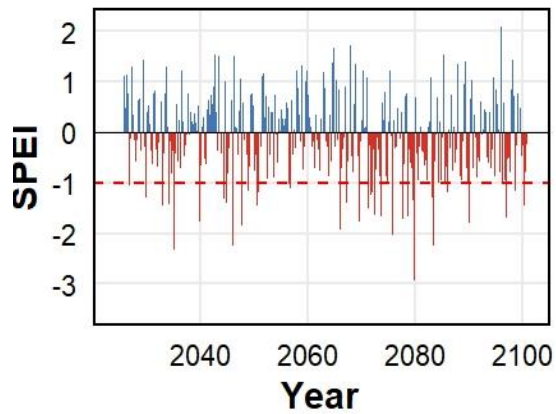





نتایج شکل (6) نشان داد که در بازه ی تاریخی، میانگین شدت خشکسالی بین 1/64 تا 2/97 متغیر است و با افزایش مقیاس زمانی (از 3 تا 12 ماهه) روندی افزایشی مشاهده می شود. به طور میانگین، بزرگی خشکسالی نیز بین 1/06 تا 1/20 قرار دارد که نشان دهنده ی خشکسالی های کوتاه مدت با شدت متوسط در دوره ی پایه است. نتایج شکل (7) نشان داد

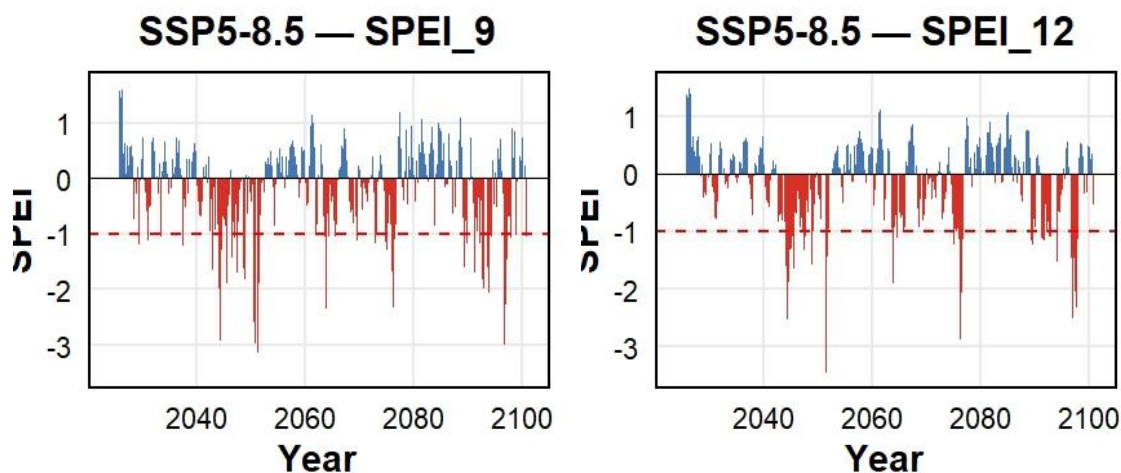
نتایج (شکل 4) نشان می دهد که دمای حداکثر در دوره های آتی افزایش می یابد به طوری که میزان تغییرات دمای حداکثر نسبت به دوره پایه در دوره 2026-2050 برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب 1/87 و 2/16 درجه سانتیگراد، در دوره 2075-2051 برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب 2/97 و 4/01 درجه سانتیگراد و در دوره 2076-2100 برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب 3/67 و 46/41 درجه سانتیگراد خواهد بود. دمای حداقل در دوره های آتی افزایش می یابد و میزان تغییرات آن نسبت به دوره پایه در دوره 2026-2050 برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب 2/98 و 3/17 درجه سانتیگراد خواهد بود. بارش در دوره های آتی کاهش می یابد و تغییرات آن نسبت به دوره پایه در دوره 2051-2075 برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب برابر 62/57- و 58/11- میلیمتر خواهد بود. مقصود و همکاران (2024) با استفاده از مدل ترکیبی حاصل از شش مدل گردش عمومی جو CMIP6 و دو سناریو SSP2-4.5 و SSP5-8.5 به بررسی تاثیر تغییرات اقلیمی بر متغیرهای دما و بارش در حوضه سد آلتینکایا است که پتانسیل قابل توجهی برای تولید انرژی برق آبی در ترکیه دارد پرداختند. نتایج آنها نشان داد که پیش بینی ها تا سال ۲۱۰۰ نشان می دهد که تحت سناریوهای خوش بینانه و بدبینانه، افزایش دما می تواند به ترتیب تا ۳.۱۱ درجه سانتیگراد و ۵.۶۴

بزرگی آن‌ها تغییر چشمگیری ندارد (0/91 تا 1/25). این وضعیت نشان می‌دهد که در آینده‌ی نزدیک، احتمال وقوع خشکسالی‌های نسبتاً کوتاه‌مدت ولی با شدت کمی بالاتر افزایش می‌یابد.


که افزایش شدت با مقیاس زمانی بلندمدت، نشان‌دهنده‌ی تجمع اثر کم‌بارشی در بازه‌های زمانی طولانی‌تر است. در سناریو SSP2-4.5 در دوره 2026-2050، شدت خشکسالی‌ها نسبت به گذشته اندکی افزایش یافته (میانگین 2/03 تا 3/02)، در حالی که



SSP2-4.5 — SPEI_3**SSP2-4.5 — SPEI_6****SSP2-4.5 — SPEI_9****SSP2-4.5 — SPEI_12****SSP5-8.5 — SPEI_3****SSP5-8.5 — SPEI_6**



شکل 5: شبیه سازی شاخص خشکسالی SPEI در دوره تاریخی و آینده







شکل 6: میانگین ویژگی‌های خشکسالی شاخص SPEI در دوره تاریخی

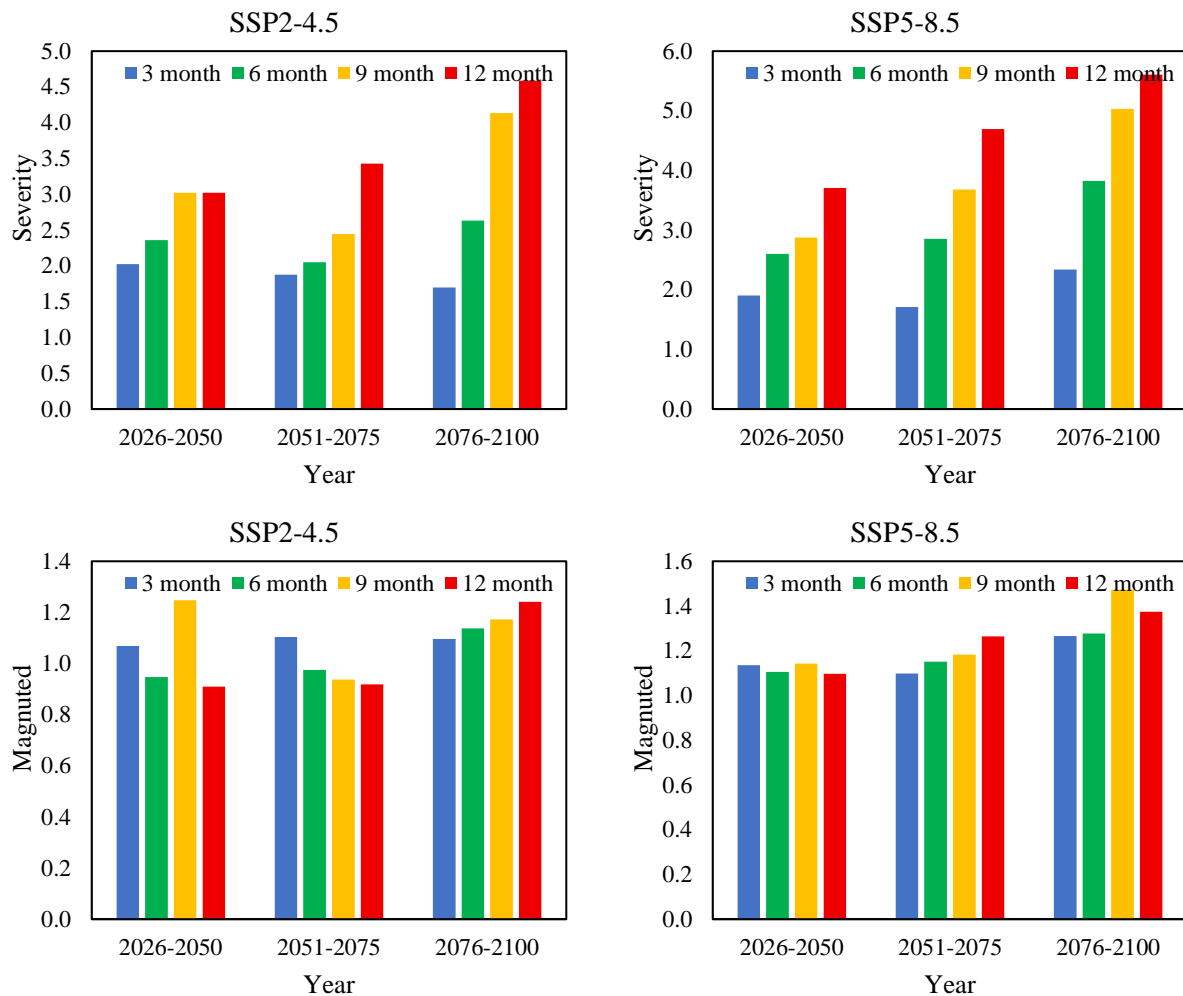
این وضعیت نشان می‌دهد که اگرچه خشکسالی‌ها ممکن است در برخی مقاطع طولانی‌تر شوند، ولی از

در دوره 2051-2075، شدت متوسط خشکسالی بین 1/88 تا 3/43 و بزرگی در حدود 0/92 تا 1/10 است.

تا 3/7 و بزرگی حدود 1/1 تا 1/14 است. که نشان دهنده این است که در آینده‌ی نزدیک، گرچه تغییر شدید نیست، اما فراوانی و تداوم خشکسالی‌ها بیشتر از دوره‌ی تاریخی است. در دوره 2051-2075، شدت به 1/71 تا 4/70 و بزرگی به 1/1 تا 1/26 افزایش می‌یابد. در این بازه، افزایش مقیاس زمانی موجب افزایش محسوس شدت خشکسالی‌های تجمعی می‌شود.

نظر بزرگی (میانگین شدت در هر ماه) تفاوت چشمگیری با گذشته ندارند. در دوره 2076-2100، شدت خشکسالی در مقیاس‌های بلندمدت (9 و 12 ماهه) افزایش محسوسی دارد (به ترتیب 4/14 و 4/59). این امر بیانگر احتمال وقوع خشکسالی‌های شدید و پایدارتر در مقیاس سالانه است، هرچند بزرگی میانگین آن‌ها (حدود 1/1 تا 1/2) همچنان در محدوده‌ی متوسط باقی می‌ماند. در سناریو SSP5-8.5، شدت بین 1/91 تا 2026-2050،





شکل 7: میانگین ویژگی‌های خشکسالی شاخص SPEI در دوره آینده

سناریوهای آینده، فراوانی، شدت و مدت خشکسالی‌ها به طور معنی داری افزایش می‌یابد که با نتایج مطالعه حاضر همخوانی دارد (Khazaei, 2025). تونگ و همکاران (2025) عملکرد مدل‌های CMIP6 را در شبیه‌سازی ویژگی‌های خشکسالی در منطقه مکزیک، از جمله مدت زمان، شدت و ضعف خشکسالی، با استفاده از شاخص‌های SPI و SPEI ارزیابی کردند. نتایج آنها نشان می‌دهد که مدل‌های CMIP6 قادر به بازتولید دقیق شرایط خشکسالی گذشته هستند. بررسی‌های آنها نشان داد که خشکسالی‌های آینده طولانی‌تر و شدیدتر خواهند شد که با نتایج مطالعه حاضر همخوانی دارد (Tuong et al., 2025).

در دوره 2076-2100، مقادیر شدت خشکسالی به بیش از 5 واحد می‌رسد (برای مقیاس‌های 9 و 12 ماهه)، که بیشترین مقدار در کل دوره‌ها است. بزرگی نیز در همین بازه‌ها به حدود 1/37 تا 1/47 افزایش می‌یابد؛ بنابراین می‌توان گفت در سناریوی SSP5-8.5، اقلیم منطقه به سمت خشکسالی‌های شدیدتر، طولانی‌تر و پایدارتر پیش می‌رود. به‌طور کلی، نتایج نشان داد که هر دو شاخص شدت و بزرگی خشکسالی از گذشته به آینده روندی افزایشی دارند، اما افزایش شدت چشمگیرتر است. خاضعی (2025) ویژگی‌های خشکسالی در تهران را با استفاده از شاخص SPEI تحت سناریوهای تغییر اقلیم و گزارش ششم تغییر اقلیم بررسی کردند. نتایج آنها نشان داد که در

نتیجه گیری

در این مطالعه، داده‌های ماهانه دمای حداقل، دمای حداکثر، و بارش مدل‌های اقلیمی MIROC6، ACCESS-CM2 و CNRM-CM6-1 با داده ایستگاه سینوپتیک قزوین در دوره پایه 1986-2014 به صورت جداگانه و گروهی مقایسه شد. نتایج نشان داد که اجرای گروهی سه مدل گردش عمومی جو برای منطقه مورد مطالعه منجر به کاهش خطای شبیه‌سازی و در نتیجه افزایش دقت پیش‌بینی‌ها گردیده است. نتایج شبیه‌سازی مدل گروهی در دوره‌های آتی تحت دو سناریو SSP2-4.5 و SSP5-8.5 نشان داد که بارش کاهش و دمای حداقل و حداکثر افزایش می‌یابد. شاخص‌های شدت و بزرگی خشکسالی بر اساس داده‌های مدل ترکیبی (Ensemble) حاصل از سه مدل گردش عمومی جو و الگوریتم XGBoost برای بازسازی شاخص خشکسالی SPEI تحت سناریوهای SSP2-4.5 و SSP5-8.5 محاسبه شدند. نتایج مدل ترکیبی XGBoost نشان داد که با افزایش دما و کاهش بارش تحت سناریوهای انتشار آینده، شدت و بزرگی خشکسالی در منطقه

مورد مطالعه روندی افزایشی دارد. این افزایش در سناریوی SSP5-8.5 محسوس‌تر بوده و بیانگر احتمال بروز خشکسالی‌های طولانی‌تر و شدیدتر در انتهای قرن بیست‌ویکم است. به‌ویژه در مقیاس‌های زمانی 9 و 12 ماهه، تجمع کم‌بارشی باعث افزایش قابل توجه شدت و بزرگی خشکسالی‌ها شده است. از این‌رو، نتایج حاضر اهمیت برنامه‌ریزی سازگاری و مدیریت منابع آب را در سناریوهای گرمایش جهانی بیشتر نمایان می‌سازد برای تعمیم نتایج این مطالعه به سایر مناطق با اقلیم مشابه، پیشنهاد می‌شود که از ترکیب مدل‌های گردش عمومی جو با الگوریتم‌های یادگیری ماشین برای شبیه‌سازی بارش و دما استفاده شود تا دقت پیش‌بینی خشکسالی افزایش یابد؛ همچنین شاخص‌های شدت، بزرگی و مدت خشکسالی در مقیاس‌های زمانی مختلف (3، 6، 9 و 12 ماهه) پایش گردند. مدیریت منابع آب و برنامه‌های کشاورزی باید بر اساس این پیش‌بینی‌ها تنظیم شوند تا اثرات منفی کم‌بارشی و افزایش دما کاهش یابد. علاوه بر این، استفاده از داده‌های ایستگاهی و مدل‌های منطقه‌ای در مطالعات آینده می‌تواند دقت شبیه‌سازی‌ها را در مناطق با شرایط اقلیمی مشابه افزایش دهد.

منابع

1. شاهین رخسار، پ.، علیزاده، ا.، انصاری، ح.، قربانی، م. 1398. بررسی عدم قطعیت گروهی مدل‌های گردش عمومی جو در شبیه‌سازی داده‌های هواشناسی (مطالعه موردی ایستگاه سینوپتیک رشت). آبیاری و زهکشی ایران، 13 (6): 1897-1909.
2. ایزدی، ن.، امیرآبادی زاده، م.، دستورانی، م. 1402. بررسی تغییرات دمای هوا در شهرستان طبرس در افق آینده با استفاده از گزارش ششم تغییر اقلیم. هواشناسی و علوم جو، 6 (1): 14-1.
3. Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). *A multiscale drought index sensitive to global warming: The Standardized Precipitation Evapotranspiration Index (SPEI)*. Journal of Climate, 23(7), 1696–1718. <https://doi.org/10.1175/2009JCLI2909.1>
4. Vicente-Serrano, S. M., Beguería, S. & López-Moreno, J. I. 2010 A multiscale drought index sensitive to global warming: the standardized precipitation evapotranspiration index. Journal of Climate 23 (7), 1696–1718. <https://doi.org/10.1175/2009JCLI2909.1>.
5. Thornthwaite, C. W. (1948). *An approach toward a rational classification of climate*. Geographical Review, 38(1), 55–94.
6. Khazaei, M. R. (2025). Projected changes to drought characteristics in Tehran under CMIP6 SSP-RCP climate change scenarios. *Heliyon*, 11(2).doi: 10.1016/j.heliyon.2025.e41811. PMID: 39882481; PMCID: PMC11774936.
7. Maqsood, J., Wang, X., Farooque, A. A., & Nawaz, R. A. (2024). Future projections of temperature-related indices in Prince Edward Island using ensemble average of three CMIP6

- models. *Scientific Reports*, 14(1), 12661. doi: 10.1038/s41598-024-63450-9. PMID: 38830965; PMCID: PMC11148011.
8. Jose, D.M., Vincent, A.M. & Dwarakish, G.S. Improving multiple model ensemble predictions of daily precipitation and temperature through machine learning techniques. *Sci Rep* 12, 4678 (2022). <https://doi.org/10.1038/s41598-022-08786-w>
 9. Chen T and Guestrin C 2016 XGBoost: a scalable tree boosting system Proc. 22nd Proc ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining pp 785–94
 10. Friedman J H 2001 Greedy function approximation: a gradient boosting machine *Ann. Stat.* 29 1189–232.
 11. Tuong, V. Q., Kiet, B. A., & Pham, T. T. (2025). Assessment of Future Drought Characteristics Using Various Temporal Scales and Multiple Drought Indices over Mekong Basin Under Climate Changes. *Water*, 17(10), 1507. <https://doi.org/10.3390/w17101507>
 12. Cook, B.I., Mankin, J.S., Marvel, K., Williams, A.P., Smerdon, J.E. & Anchukaitis, K.J. (2020) Twenty-first century drought projections in the CMIP6 forcing scenarios. *Earth's Future*, 8(6), e2019EF001461. Available from: <https://doi.org/10.1029/2019ef001461>
 13. Li, Z. & Fang, H. (2016) Impacts of climate change on water erosion: a review. *Earth-Science Reviews*, 163, 94–117. Available from: <https://doi.org/10.1016/j.earscirev.2016.10.004>
 14. Zheng, H., Chiew, F.H.S., Charles, S. & Podger, G. (2018) Future climate and runoff projections across South Asia from CMIP5 global climate models and hydrological modelling. *Journal of Hydrology: Regional Studies*, 18, 92–109. Available from: <https://doi.org/10.1016/j.ejrh.2018.06.004>
 15. Schilling, J., Hertig, E., Trambly, Y. & Scheffran, J. (2020) Climate change vulnerability, water resources and social implications in North Africa. *Regional Environmental Change*, 20(1), 15. Available from: <https://doi.org/10.1007/s10113-020-01597-7>
 16. Meaurio, M., Zabaleta, A., Boithias, L., Epelde, A.M., Sauvage, S., Sanchez-Pérez, J.M. et al. (2017) Assessing the hydrological response from an ensemble of CMIP5 climate projections in the transition zone of the Atlantic region (Bay of Biscay). *Journal of Hydrology*, 548, 46–62. Available from: <https://doi.org/10.1016/j.jhydrol.2017.02.029>
 17. Li, L., Krasovskaia, I., Xiong, L. & Yan, L. (2017) Analysis and projection of runoff variation in three Chinese rivers. *Hydrology Research*, 48(5), 1296–1310. Available from: <https://doi.org/10.2166/nh.2016.164>
 18. Wang, D. & Wang, A. (2017) Applicability assessment of GPCP and CRU precipitation products in China during 1901 to 2013. *Climatic and Environmental Research*, 22(4), 446–462 (in Chinese).
 19. Li, Z., Li, Q., Wang, J., Feng, Y. & Shao, Q. (2020) Impacts of projected climate change on runoff in upper reach of Heihe River basin using climate elasticity method and GCMs. *Science of the Total Environment*, 716, 137072. Available from: <https://doi.org/10.1016/j.scitotenv.2020.137072>
 20. Xiong, L., Yan, L., Li, L., Jiang, C. & Du, T. (2017) Advances in analysis of impacts of changing environments on extreme urban rainfall and drainage infrastructure. *Advances in Water Science*, 28(6), 930–942.
 21. Eyring, V., Bony, S., Meehl, G.A., Senior, C.A., Stevens, B., Stouffer, R.J. et al. (2016) Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development*, 9(5), 1937–1958. Available from: <https://doi.org/10.5194/gmd-9-1937-2016>
 22. Kim, Y., Rocheta, E., Evans, J.P. & Sharma, A. (2020) Impact of bias correction of regional climate model boundary conditions on the simulation of precipitation extremes. *Climate Dynamics*, 55(11–12), 3507–3526. Available from: <https://doi.org/10.1007/s00382-020-05462-5>
 23. O'Neill, B.C., Kriegler, E., Riahi, K., Ebi, K.L., Hallegatte, S., Carter, T.R. et al. (2013) A new scenario framework for climate change research: the concept of shared socioeconomic path

- ways. *Climatic Change*, 122(3), 387–400. Available from: <https://doi.org/10.1007/s10584-013-0905-2>
24. Hamed, M.M., Nashwan, M.S., Shahid, S., Ismail, T., Wang, X.J., Dewan, A. et al. (2022) Inconsistency in historical simulations and future projections of temperature and rainfall: a comparison of CMIP5 and CMIP6 models over Southeast Asia. *Atmospheric Research*, 265, 105927. Available from: <https://doi.org/10.1016/j.atmosres.2021.105927>
 25. Nashwan, M.S. & Shahid, S. (2022) Future precipitation changes in Egypt under the 1.5 and 2.0C global warming goals using CMIP6 multimodel ensemble. *Atmospheric Research*, 265, 105908. Available from: <https://doi.org/10.1016/j.atmosres.2021.105908>
 26. Yue, Y., Yan, D., Yue, Q., Ji, G. & Wang, Z. (2021) Future changes in precipitation and temperature over the Yangtze River Basin in China based on CMIP6 GCMs. *Atmospheric Research*, 264, 105828. Available from: <https://doi.org/10.1016/j.atmosres.2021.105828>
 27. Shuaifeng, S. & Xiaodong, Y. (2022) Projected changes and uncertainty in cold surges over northern China using the CMIP6 weighted multi-model ensemble. *Atmospheric Research*, 278, 106334. Available from: <https://doi.org/10.1016/j.atmosres.2022.106334>
 28. Chen, L. & Frauenfeld, O.W. (2014) A comprehensive evaluation of precipitation simulations over China based on CMIP5 multimodel ensemble projections. *Journal of Geophysical Research Atmospheres*, 119(10), 5767–5786. Available from: <https://doi.org/10.1002/2013jd021190>
 29. Zhang, S. & Chen, J. (2021) Uncertainty in projection of climate extremes: a comparison of CMIP5 and CMIP6. *Journal of Meteorological Research*, 35(4), 646–662. Available from: <https://doi.org/10.1007/s13351-021-1012-3>
 30. Wang, D. & Wang, A. (2017) Applicability assessment of GPCP and CRU precipitation products in China during 1901 to 2013. *Climatic and Environmental Research*, 22(4), 446–462 (in Chinese).
 31. Reichler, T. & Kim, J. (2008) How well do coupled models simulate today's climate? *Bulletin of the American Meteorological Society*, 89(3), 303–312. Available from: <https://doi.org/10.1175/bams-89-3-303>
 32. Friedman, J.H. (2001) Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232.
 33. Guo, L.-Y., Gao, Q., Jiang, Z.-H. & Li, L. (2018) Bias correction and projection of surface air temperature in LMDZ multiple simulation over central and eastern China. *Advances in Climate Change Research*, 9(1), 81–92. Available from: <https://doi.org/10.1016/j.accre.2018.02.003>
 34. Patel, J., Gnanaseelan, C., Chowdary, J.S. & Parekh, A. (2021) A quantile mapping approach-based bias correction in Coupled Model Intercomparison Project Phase 5 models for decadal temperature predictions over India. *International Journal of Climatology*, 42(4), 2455–2469. Available from: <https://doi.org/10.1002/joc.7376>
 35. Tong, Y., Gao, X., Han, Z., Xu, Y., Xu, Y. & Giorgi, F. (2020) Bias correction of temperature and precipitation over China for RCM simulations using the QM and QDM methods. *Climate Dynamics*, 57(5–6), 1425–1443. Available from: <https://doi.org/10.1007/s00382-020-05447-4>
 36. Oh, S.-G. & Suh, M.-S. (2016) Comparison of projection skills of deterministic ensemble methods using pseudo-simulation data generated from multivariate Gaussian distribution. *Theoretical and Applied Climatology*, 129(1–2), 243–262. Available from: <https://doi.org/10.1007/s00704-016-1782-1>
 37. Wang, D., Liu, J., Shao, W., Mei, C., Su, X. & Wang, H. (2021) Comparison of CMIP5 and CMIP6 multi-model ensemble for precipitation downscaling results and observational data: the case of Hanjiang River Basin. *Atmosphere*, 12(7), 867. Available from: <https://doi.org/10.3390/atmos12070867>
 38. Wang, D., Liu, J., Wang, H., Shao, W., Mei, C. & Ding, X. (2022) Performance evaluations of CMIP6 and CMIP5 models for precipitation simulation over the Hanjiang River Basin, China.

- Journal of Water and Climate Change, 13(5), 2089–2106. Available from: <https://doi.org/10.2166/wcc.2022.402>
39. Yue, Y., Yan, D., Yue, Q., Ji, G. & Wang, Z. (2021) Future changes in precipitation and temperature over the Yangtze River Basin in China based on CMIP6 GCMs. *Atmospheric Research*, 264, 105828. Available from: <https://doi.org/10.1016/j.atmosres.2021.105828>
 40. Yu, Y., Mao, J., Wullschleger, S.D., Chen, A., Shi, X., Wang, Y. et al. (2022) Machine learning-based observation-constrained projections reveal elevated global socioeconomic risks from wildfire. *Nature Communications*, 13(1), 1250. Available from: <https://doi.org/10.1038/s41467-022-28853-0>
 41. Xu, R., Chen, N., Chen, Y. & Chen, Z. (2020) Downscaling and projection of multi-CMIP5 precipitation using machine learning methods in the upper Han River basin. *Advances in Meteorology*, 2020, 1–17. Available from: <https://doi.org/10.1155/2020/8680436>
 42. Jose, D.M., Vincent, A.M. & Dwarakish, G.S. (2022) Improving multiple model ensemble predictions of daily precipitation and temperature through machine learning techniques. *Scientific Reports*, 12(1), 4678. Available from: <https://doi.org/10.1038/s41598-022-08786-w>
 43. Ahmed, K., Sachindra, D.A., Shahid, S., Iqbal, Z., Nawaz, N. & Khan, N. (2020) Multi-model ensemble predictions of precipitation and temperature using machine learning algorithms. *Atmospheric Research*, 236, 104806. Available from: <https://doi.org/10.1016/j.atmosres.2019.104806>
 44. Crawford, J., Venkataraman, K. & Booth, J. (2019) Developing climate model ensembles: a comparative case study. *Journal of Hydrology*, 568, 160–173. Available from: <https://doi.org/10.1016/j.jhydrol.2018.10.054>
 45. Acharya, N., Shrivastava, N.A., Panigrahi, B.K. & Mohanty, U.C. (2013) Development of an artificial neural network based multi-model ensemble to estimate the northeast monsoon rain fall over south peninsular India: an application of extreme learning machine. *Climate Dynamics*, 43(5–6), 1303–1310. Available from: <https://doi.org/10.1007/s00382-013-1942-2>
 46. Wang, B., Zheng, L., Liu, D.L., Ji, F., Clark, A. & Yu, Q. (2018) Using multi-model ensembles of CMIP5 global climate models to reproduce observed monthly rainfall and temperature with machine learning methods in Australia. *International Journal of Climatology*, 38(13), 4891–4902. Available from: <https://doi.org/10.1002/joc.5705>
 47. O'Neill, B. C., Tebaldi, C., van Vuuren, D. P., Eyring, V., Friedlingstein, P., Hurtt, G., Knutti, R., Kriegler, E., Lamarque, J.-F., Lowe, J., Meehl, G. A., Moss, R., Riahi, K., and Sanderson, B. M. (2016). The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6. *Geosci. Model Dev.*, 9, 3461–3482.
 48. Meinshausen, M., Nicholls, Z. R. J., Lewis, J., Gidden, M. J., Vogel, E., Freund, M., Beyerle, U., Gessner, C., Nauels, A., Bauer, N., Canadell, J. G., Daniel, J. S., John, A., Krummel, P. B., Luderer, G., Meinshausen, N., Montzka, S. A., Rayner, P. J., Reimann, S., Smith, S. J., van den Berg, M., Velders, G. J. M., Vollmer, M. K., and Wang, R. H. J. (2020). The shared socioeconomic pathway (SSP) greenhouse gas concentrations and their extensions to 2500, *Geosci. Model Dev.*, 13, 3571–3605.
 49. Thrasher, B., Depsky, N., Taylor, M. A., and Nemani, R. (2022). NASA-NEX-GDDP-CMIP6 Dataset. NASA Earth Exchange.
 50. Sellinger, C. E. (1996). *Potential evapotranspiration and the water balance*. *Journal of the American Water Resources Association*, 32(1), 49–56.
 51. Alam, M. M., Begum, R. A., & Er, A. C. (2017). *Spatial and temporal analysis of drought risk in Bangladesh using the Standardized Precipitation Evapotranspiration Index (SPEI)*. *Theoretical and Applied Climatology*, 128(1–2), 315–335. <https://doi.org/10.1007/s00704-015-1701-2>
 52. Chen, T., & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). ACM. <https://doi.org/10.1145/2939672.2939785>

53. Friedman, J. H. (2001). *Greedy function approximation: A gradient boosting machine*. *Annals of Statistics*, 29, 1189–1232.
54. Zhang, X., Ren, G., Yang, Y., Bing, H., Hao, Z. & Zhang, P. (2022) Extreme historical droughts and floods in the Hanjiang River Basin, China, since 1426. *Climate of the Past*, 18(8), 1775–1796. Available from: <https://doi.org/10.5194/cp-18-1775-2022>