

## Development of artificial neural network and particle swarm algorithm to predict inflow to dams under the influence of climate scenarios

Mehrnoosh Hedayatizadeh<sup>1</sup>, Saeed Jamali<sup>2,\*</sup>, Homan Hajikandi<sup>3</sup>, Somayeh Yousefi<sup>4</sup>

1. Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran. Email: [hedayati\\_m\\_1098@yahoo.com](mailto:hedayati_m_1098@yahoo.com)

2. Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran. Email: [sae.jamali@iauctb.ac.ir](mailto:sae.jamali@iauctb.ac.ir)

3. Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran. Email: [h\\_hajikandi@iauctb.ac.ir](mailto:h_hajikandi@iauctb.ac.ir)

4. Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran. Email: [s.yousefi@iauctb.ac.ir](mailto:s.yousefi@iauctb.ac.ir)

### Abstract

Climate change causes changes in the flow of rivers by causing changes in temperature and precipitation. Therefore, river flow simulation is important as a prerequisite for some environmental and engineering issues. In the current research, the effect of climate change on the Mahabad's river flow in the future periods (2045-2026) was predicted using machine learning models. First, two input scenarios were compiled, in which the first scenario included temperature and precipitation parameters and the second scenario included temperature, precipitation, and flow parameters one month ago. In the following, the performance of two ANN and ANN-PSO models in estimating the flow rate in the base period (1992-2014) was compared to select the best scenario and the best model for predicting the flow in the future period under the three scenarios SSP1.26, SSP2.45 and SSP5.85 of the CMIP6. The results of the error evaluation criteria showed that the ANN-PSO model makes the best estimation of the river flow using the second scenario and with the criteria (NSE=0.77, RMSE=6.4 MCM, MAE=3.4 MCM for the test data) and it was chosen to predict the flow in the future period (2026-2045). The results of investigating the effect of climate change on each of the meteorological parameters showed that climate change causes an increase in temperature and creates a fluctuating pattern in precipitation. The results of the climate change survey on flow showed that under the SSP1.26 scenario, there will not be much changes in flow, but in the SSP2.45 and SSP585 scenarios, there will be an increase in the discharge in December, and in May and April, the greatest decrease in discharge will be (36.5 MCM) and (36.5 MCM) respectively.

**Keywords:** Artificial neural network, Climate change, particle swarm algorithm, River discharge, Time series prediction.

توسعه شبکه عصبی مصنوعی و الگوریتم ازدحام ذرات برای پیش‌بینی جریان ورودی به سدها تحت تأثیر سناریوهای اقلیمی

مهرنوش هدایتی زاده<sup>۱</sup>، سعید جمالی<sup>۲\*</sup>، هومن حاجی کندی<sup>۳</sup>، سمیه یوسفی<sup>۴</sup>

۱. گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد تهران مرکز، تهران، ایران. رایانامه:

[hedayati\\_m\\_1098@yahoo.com](mailto:hedayati_m_1098@yahoo.com)

۲. نویسنده مسئول، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد تهران مرکز، تهران، ایران. رایانامه:

[sae.jamali@iauctb.ac.ir](mailto:sae.jamali@iauctb.ac.ir)

۳. گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد تهران مرکز، تهران، ایران.. رایانامه:

[h\\_hajikandi@iauctb.ac.ir](mailto:h_hajikandi@iauctb.ac.ir)

۴. گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد تهران مرکز، تهران، ایران.. رایانامه:

[s.yousefi@iauctb.ac.ir](mailto:s.yousefi@iauctb.ac.ir)

## چکیده

تغییر اقلیم با ایجاد تغییر در میزان دما و بارش موجب تغییر در آبدهی رودخانه‌ها می‌شود، از این رو، شبیه‌سازی جریان رودخانه به عنوان پیش‌نیاز برنامه‌ریزی و مدیریت منابع و مصارف آب اهمیت فراوان دارد. لذا در پژوهش حاضر تأثیر تغییر اقلیم بر میزان دبی رودخانه مهاباد در دوره‌های زمانی آینده (۲۰۲۶-۲۰۴۵) با استفاده از مدل‌های یادگیری ماشین بررسی شد. ابتدا دو سناریوی ورودی که در آن سناریو اول شامل پارامترهای دما و بارش و سناریو دوم شامل پارامترهای دما، بارش و دبی یک ماه قبل بود، تدوین شد. در ادامه عملکرد دو مدل ANN و ANN-PSO در تخمین دبی جریان در دوره پایه (۱۹۹۲-۲۰۱۴) مقایسه شد تا بهترین سناریو و بهترین مدل برای پیش‌بینی جریان در دوره آینده تحت سه سناریو SSP1.26، SSP2.45 و SSP5.85 گزارش ششم تغییر اقلیم (CMIP6) انتخاب شود. نتایج معیارهای ارزیابی خطا نشان داد که مدل ANN-PSO با استفاده از سناریوی دوم و با معیارهای  $NSE=0.77$ ،  $RMSE=6.4$  MCM،  $MAE=3.4$  MCM قادر به تخمین مناسب دبی می‌باشد. نتایج بررسی اثر تغییر اقلیم بر روی هر یک از پارامترهای هواشناسی نشان داد که تغییر اقلیم باعث افزایش دما در حدود نیم تا یک درجه در طول دوره و ایجاد یک الگوی نوسانی در بارش می‌شود. نتایج بررسی تغییر اقلیم روی دبی نشان داد که تحت سناریو SSP1.26 تغییرات چندانی در دبی رخ نخواهد داد اما در سناریوهای SSP2.45 و SSP5.85 در ماه دسامبر افزایش اندک دبی رخ خواهد داد و در ماه می و آوریل بیشترین کاهش دبی به ترتیب 3.65 MCM و 3.65 MCM خواهد بود.

**کلمات کلیدی:** پیش‌بینی سری زمانی، تخمین دبی رودخانه، تغییر اقلیم، ANN، PSO.

امروزه تغییرات آب و هوایی که منجر به تغییرات دما و الگوی بارشی می‌شود قابل درک است. چنین تغییراتی موجب ایجاد تغییراتی در منابع تامین و تقاضای آب می‌گردد (Kusangaya et al., 2014; Hodgkins et al., 2017; Ghasemain et al., 2020). طبق آخرین گزارش‌های IPCC، تغییرات آب‌وهوایی در سال‌های اخیر باعث تغییرات هیدرولوژیکی در سراسر جهان شده است و احتمال وقوع رویدادهای شدید آب‌وهوایی مانند سیل را افزایش داده است (Masson-Delmotte et al., 2021; Daba and You, 2020; Mitsova and Coupling, 2014). به دلیل انطباق اکوسیستم‌ها و ساختارهای فیزیکی جوامع انسانی با شرایط آب‌وهوایی معمولی، آن‌ها در برابر پدیده‌های اقلیمی از انعطاف‌پذیری کافی برخوردار نیستند. بنابراین، چنین ناهنجاری‌هایی می‌تواند بر اکوسیستم‌ها و جوامع تأثیر نامطلوب بگذارد و آسیب‌های اقتصادی و اجتماعی قابل توجهی ایجاد کند (IPCC, 2013 and 2017). بررسی دلایل وقوع تغییر اقلیم و چگونگی روند آن در گذشته، آینده و همچنین بررسی اثرات احتمالی آن بر منابع آب می‌تواند تا حد زیادی از مشکلات آینده منابع آب را حل کند (Zabardast Rostami et al., 2021). تأثیرات تغییر اقلیم بر متغیرهای هیدرولوژیکی و فرآیندهای آن به‌ویژه بر رواناب سطحی، جریان آب‌های زیرزمینی، جریان رودخانه، تبخیر-تعرق و رطوبت خاک، با تجزیه و تحلیل داده‌های اقلیمی پیش‌بینی شده با استفاده از مدل‌های مختلف هیدرولوژیکی مورد مطالعه قرار گرفته است (Daba, 2018; Daba and Rao, 2016; Behulu et al., 2014).

مطالعه اثرات تغییر اقلیم به‌ویژه در مناطق نیمه‌خشک و خشک حائز است، زیرا در این مناطق، منابع آب، عمدتاً جریان آب و رواناب سطحی، به شدت به تغییرات آب‌وهوایی حساس هستند. یک تغییر کوچک در متغیرهای آب‌وهوایی ممکن است منجر به تغییرات قابل توجهی در چرخه‌های هیدرولوژیکی و تغییرات بعدی منابع آب منطقه‌ای شود (Chang and Jung, 2010; Taye et al., 2018). مطالعه تغییرات اقلیم در زمینه‌های گوناگون هیدرولوژیکی می‌تواند به جلوگیری از خسارت‌های زیاد اجتماعی، اقتصادی و غیره کمک کند. یکی از پارامترهای هیدرولوژیکی که می‌تواند در مقابل تغییرات اقلیمی آسیب‌پذیر باشد، دبی رودخانه است، که هر تغییری در مقدار بارش و دما می‌تواند بر آن اثرگذار باشد. به منظور اقدامات اولیه و جلوگیری از بلایا، می‌توان با استفاده از مقادیر گذشته اطلاعات نهفته در جریان در یک دوره خاص را با استفاده از روش‌های موجود پیش‌بینی کرد (Nguyen, 2020; Fathian et al., 2019). معمولاً دو رویکرد در برآورد جریان رودخانه وجود دارد که می‌توان آن‌ها را در دو گروه مبتنی بر فیزیکی (یا مفهومی) و مبتنی بر ریاضی یا مبتنی بر داده طبقه‌بندی کرد (Di et al., 2014; He et al., 2014; Zhang et al., 2016). مدل‌های فیزیکی به دلایلی مانند نیاز به ابزارهای ریاضی پیچیده، داده‌های فیزیکی کافی و تخصص و تجربه کافی کمتر مورد استفاده قرار می‌گیرند (He et al., 2014). در مقابل اجرای مدل‌های داده محور ساده‌تر است و پیچیدگی زیادی ندارند. همچنین به اطلاعاتی در مورد ماهیت فیزیکی فرآیندهای هیدرولوژیکی نیاز ندارند. از این رو این مدل‌ها در بین محققان محبوبیت بیشتری پیدا کرده و برای مدل‌سازی فرآیندهای هیدرولوژیکی بیشتر مورد استفاده قرار می‌گیرند (Arya Azar et al., 2021; Milan et al., 2023; Kayhomayoon et al., 2023; Meshrm et al., 2019).

با وجود مزیت‌های الگوریتم‌هایی مانند شبکه عصبی مصنوعی، اما گاهی اوقات به دلیل به دام افتادن الگوریتم‌های آموزش آن در نقاط کمینه محلی و سراسری عمل تخمین را به‌خوبی انجام نمی‌دهد. از این رو این مشکل محققان را بر آن داشته

است تا از الگوریتم‌های بهینه‌سازی و تکاملی برای بهبود نتایج مدل‌های منفرد مانند ANN\* و ANFIS† استفاده کنند (Arya Azar et al., 2018; Shariati et al., 2019; Ashrafzadeh et al., 2018). در سال‌های اخیر، الگوریتم‌های متعددی مانند الگوریتم ژنتیک (GA)، بهینه‌سازی ازدحام ذرات (PSO)، بهینه‌سازی گرگ خاکستری\*\* (GWO)، برای آموزش بهتر مدل‌های منفرد مورد استفاده قرار گرفته‌اند (Kayhomayoon et al., 2023). استفاده از مدل‌های یادگیری ماشین و الگوریتم‌های تکاملی محققان را تا حد ممکن به تخمین مناسبی از سری‌های زمانی می‌رساند. لذا همواره استفاده از آن‌ها در کنار یکدیگر توصیه شده است. به عنوان نمونه فرناندو و همکاران از الگوریتم ژنتیک برای بهبود دقت شبکه عصبی مصنوعی در پیش بینی جریان رودخانه بهره بردند (Fernando et al., 2011). الگوریتم بهینه‌سازی که در تحقیق حاضر به کار گرفته شده است الگوریتم بهینه‌سازی ازدحام ذرات (PSO) است که با الهام گرفتن از طبیعت و ایجاد یک جمعیت تصادفی شروع می‌شود و هر ذره یک راه‌حل را ارائه می‌دهد و در نهایت بهترین راه‌حل انتخاب می‌شود.

همانطور که بیان شد میزان دبی خروجی از سدها و انرژی تولیدی برقابی از سدها تا حدود زیادی به میزان دبی ورودی به مخازن سدها بستگی دارد. عواملی مانند خشکسالی و تغییر اقلیم می‌تواند میزان دبی ورودی به مخازن سد را تحت تاثیر قرار دهد. از این رو این تحقیق با هدف تخمین دبی ورودی به مخازن سدها تحت تاثیر تغییر اقلیم انجام شد. سد مهاباد یکی از مهمترین سدهای شمالغرب کشور به عنوان محدوده مطالعاتی در نظر گرفته شد. استفاده از مدل‌های یادگیری ماشین و الگوریتم‌های تکاملی در کنار یکدیگر برای تخمین میزان دبی ورودی به سد و همچنین بررسی اثر تغییر اقلیم از تازگی های این تحقیق به شمار می‌آید. برای این منظور از مدل‌های گزارش ششم تغییر اقلیم تحت سناریوهای SSP1.26، SSP2.45 و SSP5.85 و مدل یادگیری ماشین (ANN) استفاده شده است. در ادامه به منظور بهبود نتایج ANN از مدل بهینه‌سازی (PSO) استفاده شد. لذا علاوه بر تحلیل تغییر اقلیم بر میزان جریان ورودی به سد، عملکرد مدل ترکیبی ANN-PSO نیز بررسی شد. در نهایت تاثیر تغییر اقلیم بر جریان ورودی توسط مدل منتخب یادگیری ماشین برای یک دوره آبی (۲۰۲۶-۲۰۴۵) بررسی شد.

## ۲. مواد و روش‌ها

### ۲.۱. منطقه مورد مطالعه

حوضه آبریز رودخانه مهاباد در جنوب دریاچه ارومیه یکی از مهم‌ترین محدوده‌های مطالعاتی کشور است که از اهمیت بالایی برخوردار است (شکل (۱)). این محدوده با وسعتی حدود ۱۵۲۴/۵۳ کیلومترمربع بخش کوچکی از حوضه دریاچه ارومیه (حدود ۳ درصد) را شامل می‌شود. از نظر موقعیت جغرافیایی بین ۲۵° ۹' ۴۵" طول شرقی و ۳۶° ۲۳' ۵۱" عرض شمالی قرار گرفته است. رودخانه مهاباد مهم‌ترین رودخانه در این محدوده است که به عنوان جریان ورودی به سد مهاباد در نظر گرفته می‌شود. این رودخانه از به هم پیوستن شاخه بیطاس در شرق و شاخه کوتر در غرب شکل گرفته است. سد مهاباد یکی از ده سد پر

---

\* Artificial Neural Network

† Adaptive Neuro-Fuzzy Inference System

‡ Genetic Algorithm

§ Particle swarm optimization

\*\* Grey Wolf Optimizer

آب کشور است که در سال ۱۳۴۶ احداث گردید. این سد نقش اساسی در تامین نیازهای آب محدوده را بر عهده دارد. همچنین بخشی از برق محدوده نیز از طریق انرژی برقابی حاصل از سد تامین می گردد.

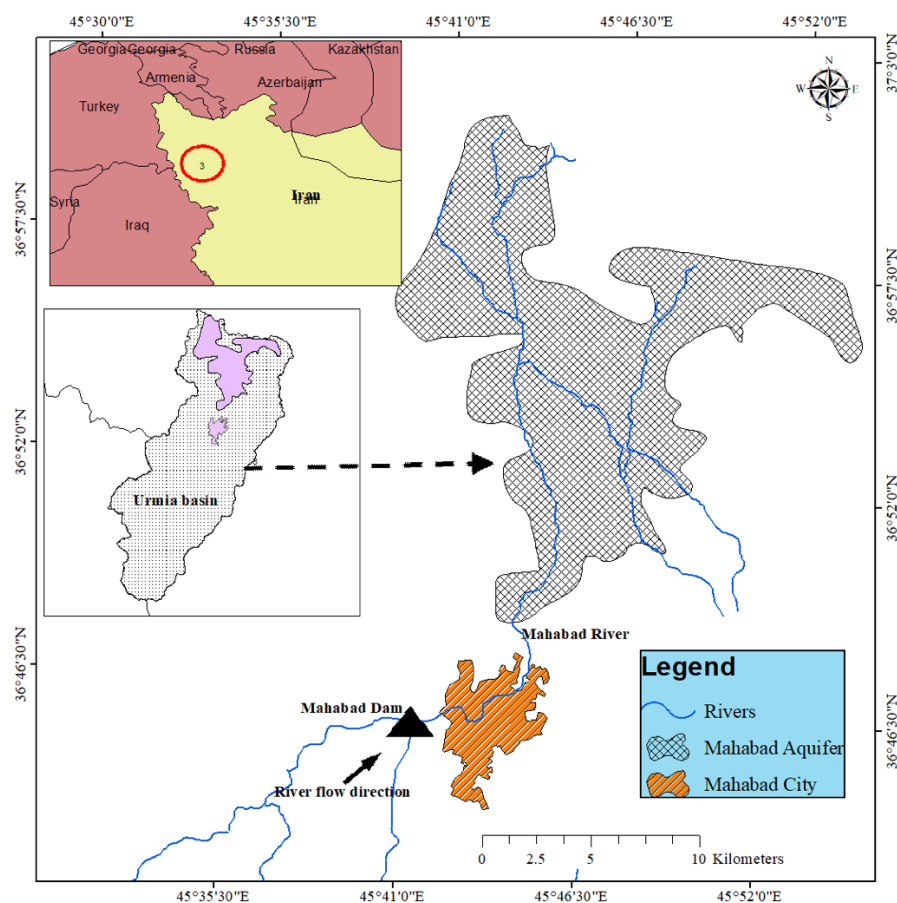


Figure 1. Characteristics of the study area

مطابق جدول (۱) که در آن مشخصات آماری هر یک از پارامترهای ورودی و خروجی بیان شده است، مقدار جریان ورودی به مخزن در محدوده ۰ تا ۵۹ MCM در ماه متغیر است. مقادیر بارش ماهانه در طول دوره مورد بررسی نیز نشان می دهد که از صفر تا ۲۲۲mm در ماه متغیر است. بیشترین دمای ماهانه حدود ۲۹ °C و مربوط به ماه های گرم سال می باشد. سایر خلاصه پارامترهای آماری در جدول (۱) قابل مشاهده می باشد.

Table 1. Summary of the statistical parameters of the data used

statistical parameter	Precipitation (mm)	Temperature (°C)	Inlet flow to reservoir dam the (MCM)
Minimum	0.00	0.00	0.00
Maximum	222	28.8	58.6
Average	40.6	13.4	6.80
Standard deviation	43.8	9.30	10.4

در تحقیق حاضر، جریان رودخانه ورودی به سد مهاباد تحت اثر تغییر اقلیم پیش‌بینی شده است. لذا برای این منظور، از داده‌های مدل‌های اقلیمی گزارش ششم IPCC تحت سه سناریوهای گزارش ششم استفاده شد. در ابتدا داده‌های بارش و دمای تاریخی (۲۰۱۴-۱۹۹۲) ۱۴ مدل اقلیمی گزارش ششم IPCC با داده‌های مشاهداتی بارش و دما مقایسه و سپس با استفاده از پارامترهای آماری بهترین مدل اقلیمی برای داده‌های بارش و دما انتخاب شد. در ادامه داده‌های دوره آینده (۲۰۲۶-۲۰۴۵) مدل‌های اقلیمی منتخب تحت سه سناریو استخراج شدند و به عنوان داده‌های ورودی به مدل یادگیری ماشین اعمال شد تا جریان رودخانه تحت اثر تغییر اقلیم شبیه‌سازی شود. برای پیش‌بینی جریان در دوره پایه دو سناریو در نظر گرفته شده است. ۱- در سناریو اول پارامترهای دما و بارش و ۲- در سناریو دوم پارامترهای دما، بارش و دبی یک ماه قبل گنجانده شد. عملکرد مدل یادگیری ماشین با استفاده از پارامترهای آماری و بصری مورد ارزیابی قرار گرفت تا دقت مدل در شبیه‌سازی جریان رودخانه سنجیده شود و در ادامه از مدل منتخب برای پیش‌بینی دبی جریان تحت اثر تغییر اقلیم در دوره آینده استفاده شد. شایان ذکر است که ۷۰٪ داده‌ها برای آموزش مدل یادگیری ماشین و ۳۰٪ نیز برای صحت‌سنجی به کار گرفته شده است. گام زمانی در نظر گرفته شده نیز ماهانه است (شکل ۲).

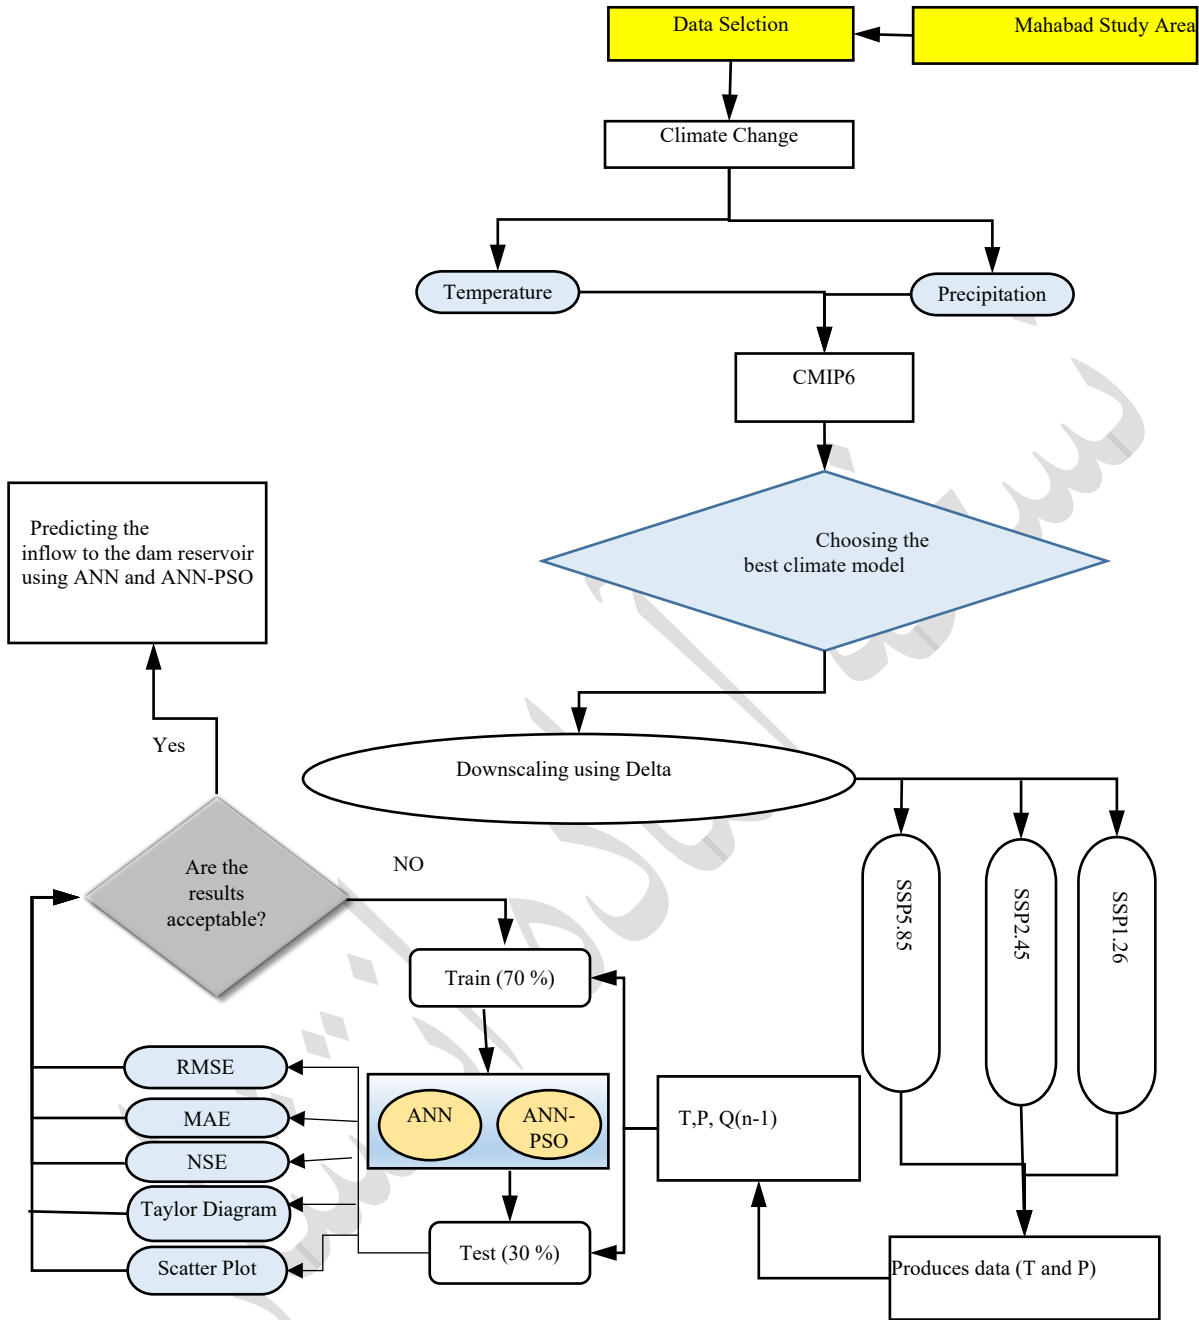


Figure 2. Flowchart of Study

در ادامه به تشریح هر یک از موارد مطرح شده پرداخته شده است.

### ۳.۲. شبکه عصبی مصنوعی (ANN)

مدل ANN سه دهه پیش توسط لیپمن معرفی شد و یکی از مدل‌های اولیه یادگیری ماشین است. این مدل‌ها یک سیستم پردازش اطلاعات توزیع شده موازی هستند که شبیه به شبکه‌های عصبی انسانی عمل می‌کنند. این مدل در مسائل شبیه‌سازی سری زمانی به وفور استفاده شده است. روند اجرای مدل بدین صورت است که در مرحله اول داده‌های ورودی به مدل وارد می‌شود،

سپس تعداد لایه‌های مخفی و خروجی و همچنین تعداد نرون‌ها مشخص می‌شود. در ادامه معیار ارزیابی شبکه برای محاسبه خطای بین مقادیر مشاهده شده و پیش بینی شده شبکه انتخاب می‌شود. ANN وزن و بایاس نرون‌ها را با الگوریتم‌های مختلف بر اساس داده‌های آموزشی تعیین می‌کند. این مرحله تا زمانی تکرار می‌شود که خطای بین مقادیر مشاهده شده و پیش بینی شده کمتر از یک آستانه شود. در این تحقیق از ۷۰ درصد داده‌ها برای آموزش و بقیه برای آزمون (۳۰ درصد باقیمانده) استفاده شد.

## ۴.۲. الگوریتم بهینه‌سازی ازدحام ذرات (PSO)

الگوریتم بهینه‌سازی ازدحام ذرات یکی از روش‌های بهینه‌سازی الهام گرفته از طبیعت است که اولین بار توسط کندی و ابراهام در سال ۱۹۹۵ مطرح گردید. الگوریتم PSO با ایجاد یک جمعیت تصادفی شروع می‌شود. هر جزئی در طبیعت مجموعه مختلف متغیرهای تصمیم می‌باشد که مقادیر بهینه آن‌ها باید تأمین گردد و در واقع هر ذره یک بردار را در فضای حل مسئله نشان می‌دهد. این الگوریتم علاوه برداشتن بردار حرکت دارای یک بردار سرعت نیز می‌باشد که اعضای مجموعه را به تغییر موقعیت در فضای جستجو وادار می‌کند. این بردار سرعت خود برآیند دو بردار به نام‌های  $p$  و  $Pg$  می‌باشد.  $p$  بهترین موقعیتی است که یک ذره تاکنون به آن رسیده است و  $Pg$  بهترین موقعیتی است که بهترین ذره در همسایگی آن ذره تاکنون به آن رسیده است. در این الگوریتم هر کدام از اعضای مجموعه در هر تکرار یک راه‌حل را ارائه می‌دهند. در جستجوی یک فضای  $d$  بعدی، مکان  $I$  امین ذره به وسیله یک بردار  $D$  بعدی به نام  $X_i = (X_{i1}, X_{i2}, \dots, X_{id})$  و سرعت هر ذره به وسیله یک بردار  $D$  بعدی سرعت به نام  $V_i = (V_{i1}, V_{i2}, \dots, V_{id})$  نشان داده می‌شود. سرانجام جمعیت، با استفاده از روابط (۱) و (۲) و به صورت هدفمند به سمت نقطه بهینه حرکت می‌کند.

$$V_{id}^{n+1} = X(\omega \cdot v_{id}^n + c_1 r_1^n (p_{id}^n - x_{id}^n) + c_2 r_2^n (p_{pg}^n - x_{id}^n)) \quad (1)$$

$$x_{id}^{n+1} = x_{id}^n + v_{id}^{n+1} \quad (2)$$

که در آن  $X$  فاکتور انقباض که از آن برای نرخ کارایی و سرعت همگرایی شدن استفاده می‌شود.  $r_1$  و  $r_2$  اعداد تصادفی در بازه صفر و یک با توزیع یکنواخت می‌باشد.  $n$  شماره تکرارها،  $c_1$  مؤلفه شناختی و بهترین راه‌حلی که یک ذره به دست می‌آورد.  $c_2$  مؤلفه اجتماعی و بهترین راه‌حلی توسط کل گروه تشخیص داده می‌شود. در نهایت برای هر خوشه مناسب‌ترین مدل به همراه الگوریتم ورودی مناسب از ترکیب پارامترهای ورودی مختلف انتخاب خواهد شد.

## ۵.۲. شبیه‌سازی تغییر اقلیم

برای بررسی اثرات تغییر اقلیم بر منابع آب همواره از گزارش‌های مختلف تغییر اقلیمی که از سوی IPCC تعریف می‌شود استفاده می‌گردد. بنابراین در این تحقیق از مدل‌های IPCC - ششمین گزارش تغییر اقلیم برای شبیه‌سازی تغییرات اقلیمی در منطقه مورد مطالعه استفاده شد که جدیدترین گزارش آن به شمار می‌آید. در این تحقیق، سه سناریو، RCP2.6، SSP2.45، و SSP5.85، برای تولید داده‌های بارش و دما در آینده (۲۰۲۶-۲۰۴۵) در نظر گرفته شد. با توجه به مرکزیت ایستگاه سینوپتیک مهاباد که دارای سری زمانی مناسب از آمارهای هواشناسی است، از آمار این ایستگاه برای تحلیل وضعیت تغییرات اقلیمی استفاده شد. در نهایت، دبی رودخانه تحت تأثیر تغییر اقلیم و پارامترهای اقلیمی با استفاده از مدل یادگیری ماشین شبیه‌سازی می‌شود.



## ۱.۵.۲. ریزمقیاس نمایی یا استفاده از روش تغییر عامل

در این تحقیق از روش دلتا برای ریزمقیاس استفاده شده است که در تحقیقات مشابه نیز مورد استفاده قرار گرفته است (Kayhomayoon et al., 2023). برای تولید داده‌های بارش و دما در آینده، از سه سناریوی گزارش ششم IPCC شامل SSP126، SSP245 و SSP585 استفاده شد. با استفاده از روش دلتا یا عامل تغییر می‌توان تغییرات متغیر اقلیمی مورد نظر را در دوره‌های آتی نسبت به دوره قبل محاسبه کرد و سناریوی تغییر اقلیم آن متغیر با استفاده از روش عامل تغییر محاسبه می‌شود. در این حالت از اختلاف بین دو متغیر برای دما استفاده می‌شود. و برای بارندگی از نسبت بین آن‌ها استفاده می‌شود. در مطالعه حاضر، این مقادیر برای سال‌های ۲۰۲۶-۲۰۴۵ برآورد شده است.

$$\Delta P = \frac{P_{future} - P_{base}}{P_{base}} \times 100 \quad (۳)$$

$$\Delta T = T_{future} - T_{base} \quad (۴)$$

$\Delta P$  و  $\Delta T$  به ترتیب سناریوی تغییر اقلیم، بارش و دما را در دوره بعدی در هر ماه نشان می‌دهند.  $T_{future}$  میانگین دمای ۲۰ ساله آینده (۲۰۲۶-۲۰۴۵) شبیه‌سازی شده توسط مدل‌های گردش عمومی جو-اقیانوس (AOGCM) در دوره بعدی برای هر ماه،  $T_{bases}$  میانگین دمای ۲۰ ساله شبیه‌سازی شده توسط AOGCM در دوره مشاهده (۲۰۰۵-۱۹۸۶) در هر ماه است.  $P_{future}$  و  $P_{base}$  نیز به ترتیب میانگین ۲۰ سال بارش شبیه‌سازی شده در آینده و پایه را نشان می‌دهند. بدین ترتیب در مرحله اول، متغیرهای اقلیمی ۱۴ مدل گزارش ششم برای دوره پایه از سایت IPCC دریافت و با مقادیر مشاهداتی محدوده مورد مطالعه مقایسه شدند. سپس با استفاده از پارامترهای آماری مدلی که نزدیک‌ترین مقادیر را به مقادیر مشاهداتی داشت، از داده‌های آن (سه سناریو SSP126، SSP245 و SSP585) برای آینده استفاده شد. سپس از نرم‌افزار ArcGIS برای استخراج داده‌ها استفاده شد. در ادامه مقادیر دما در دوره آینده از اضافه کردن مقادیر مشاهداتی ( $T_{obs}$ ) به  $\Delta T$  (رابطه ۵) و مقادیر بارش از ضرب بارش مشاهداتی ( $P_{obs}$ ) به  $\Delta P$  (رابطه ۶) به دست آمد (Goodarzi et al., 2015).

$$T = T_{obs} + \Delta T \quad (۵)$$

$$P = P_{obs} \times \Delta P \quad (۶)$$

در نتیجه می‌توان مقادیر بارش و دما در دوره آتی را برای محدوده مطالعاتی برآورد کرد.

## ۶.۲. معیارهای ارزیابی خطا

برای بررسی دقت مدل‌های یادگیری ماشین همواره از معیارهای ارزیابی خطا استفاده می‌کنند زیرا معیارها می‌توانند خلاصه‌ای از اطلاعات مفیدی در مورد خطاهای هر مدل بیان کنند. لذا در این تحقیق از معیارهای ارزیابی مختلفی از جمله جذر

میانگین مربعات خطا\* (RMSE) (رابطه ۷)، میانگین خطای مطلق<sup>۱</sup> (MAE) (رابطه ۸) به همراه ضریب ناش ساتکلیف<sup>۲</sup> (NSE) (رابطه ۹) و ضریب R<sup>2</sup> (رابطه ۱۰) استفاده شده است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_o - x_p)^2}{n}} \quad (۷)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_o - x_p}{x_o} \right| \quad (۸)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (x_o - x_p)^2}{\sum_{i=1}^n (x_o - \bar{x})^2} \quad (۹)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_p - \bar{x}_o)^2}{\sum_{i=1}^n (x_o - \bar{x}_o)^2} \quad (۱۰)$$

که در آن  $x_o$  مقادیر مشاهده شده،  $x_p$  مقادیر پیش‌بینی شده و  $n$  تعداد نمونه‌ها است. هر چه RMSE و MAE کمتر و NSE و R<sup>2</sup> بالاتر باشد، عملکرد مدل بهتر است.

### ۳. نتایج

#### ۱.۳. بررسی اثر تغییر اقلیم بر دما و بارش محدوده مطالعاتی

در تحقیق حاضر از گزارش ششم تغییر اقلیم برای بررسی اثرات تغییر اقلیم روی دبی جریان رودخانه استفاده شد. از بین ۱۴ مدل اقلیمی بهترین مدل برای داده‌های بارش و دما با استفاده از معیارهای MAE، RMSE و ضریب همبستگی انتخاب شد. با مقایسه داده‌های تاریخی (۱۹۹۲-۲۰۱۴) هر مدل با داده‌های مشاهده‌ای، مدلی با استفاده از معیارهای ارزیابی انتخاب شد و نتایج آن در جداول (۲) و (۳) ارائه شده است. در بین مدل‌های موجود، مدل BCC-CSM2-MR با MAE، RMSE و ضریب همبستگی به ترتیب ۱/۶۳، ۱/۴۲ و ۰/۹۹ بیشترین تطابق را با داده‌های میانگین دمای مشاهداتی منطقه مورد مطالعه دارد. بنابراین، این مدل برای استخراج داده‌های آینده دما (۲۰۲۶-۲۰۴۵) انتخاب شد. مطابق جدول (۳) برای داده‌های بارش، نتایج مدل FGOALS-g3 به مقادیر مشاهداتی نزدیک‌تر بود. برای این مدل، ضرایب MAE، RMSE و همبستگی به ترتیب ۱/۶۷۸، ۱۲/۵۷ و ۰/۶۱ بود که نسبت به سایر مدل‌ها کمتر بود. بنابراین از این مدل برای استخراج داده‌های بارش در دوره آینده استفاده شد.

Table 2. Error evaluation criteria of (CMIP6) models compared to the temperature observation data

CC	MAE	RMSE	Models	CC	MAE	RMSE	Models
0.99	7.31	7.44	FGOALS-g3	0.99	4.67	4.84	ACCESS-CM2
0.99	2.30	2.72	FIO-ESM-2-0	0.99	5.60	5.91	AWI-CM-1-1-MR
0.99	4.58	4.68	HadGEM3-GC31-LL	<b>0.99</b>	<b>1.42</b>	<b>1.63</b>	<b>BCC-CSM2-MR</b>
0.99	3.02	3.45	IPSL-CM6A-LR	0.99	2.82	2.94	CESM2
0.99	10.24	11.02	MIROC6	0.99	2.52	2.86	CNRM-CM6-1
0.99	1.54	1.76	MRI-ESM2-0	0.99	2.41	3.00	EC-Earth3-AerChem
0.99	3.09	3.79	NESM3	0.99	2.47	2.81	EC-Earth3-CC

<sup>۱</sup> Root Mean Square Error

<sup>۲</sup> Mean Absolute Error

<sup>۳</sup> Nash-Sutcliffe Efficiency Coefficient

Table 3. Error evaluation criteria of (CMIP6) models compared to the precipitation observation data

CC	MAE	RMSE	Models	CC	MAE	RMSE	Models
0.40	14.29	19.01	HadGEM3-GC31-LL	0.58	52.47	62.98	MRI-ESM2-0
0.59	41.33	51.81	IPSL-CM6A-LR	0.68	19.37	22.55	FIO-ESM-2-0
0.48	16.38	20.08	CanESM5	<b>0.61</b>	<b>12.75</b>	<b>16.78</b>	<b>FGOALS-g3</b>
0.52	13.02	16.99	MIROC6	0.51	19.44	24.08	EC-Earth3-Veg-LR
0.48	25.61	29.73	BCC-CSM2-MR	0.37	27.40	33.58	EC-Earth3-AerChem
0.54	26.60	33.59	AWI-CM-1-1-MR	0.43	54.24	67.48	CNRM-CM6
0.46	16.50	22.19	ACCESS-CM2	0.61	22.96	27.29	CESM2

نتایج تغییرات دما در دوره آینده تحت هر سه سناریو در شکل (۴) نشان داده شده است. در طول سال‌های ۲۰۲۶ و ۲۰۴۵، میانگین دما نسبت به دمای پایه افزایش نسبی خواهد داشت. در سناریوی SSP1.26 دما در ماه‌های ژانویه، فوریه، مارس، نوامبر و دسامبر کاهش خواهد یافت، که بیشترین مقدار کاهش در ماه ژانویه به میزان ۲/۳۳ درجه سانتی‌گراد خواهد بود. در سایر ماه‌ها تغییرات دما به مقدار ۱ درجه سانتی‌گراد برای ماه آوریل تا ۵/۵ درجه سانتی‌گراد برای ماه اوت افزایشی خواهد بود.

در دو سناریو SSP5.85 و SSP5.85 همانند سناریو SSP1.26، کاهش دما در ماه‌های مذکور به استثنای ماه نوامبر خواهد بود. بر اساس سناریو SSP245 دما از ۰/۲۸ تا ۵ درجه سانتی‌گراد افزایش خواهد یافت، که بیشترین افزایش دما در بین ماه‌های ژوئن تا اکتبر خواهد بود. طبق شکل (۴)، بیشترین تغییرات دما در سناریوی SSP5.85 رخ خواهد داد. برای این سناریو، ماه‌های جولای تا سپتامبر بیشترین افزایش دما را نسبت به ماه‌های مشابه دو سناریوی دیگر تجربه خواهند کرد. در ماه‌های ژوئن تا اوت میانگین دما بیشتر از ۵ درجه سانتی‌گراد افزایش خواهد یافت. تغییرات دمای زیاد تحت سناریوی SSP5.85 را می‌توان به افزایش غلظت دی‌اکسید کربن نسبت داد. تغییرات متوسط در دمای متوسط را نیز می‌توان به غلظت ثابت دی‌اکسید کربن در سال‌های آینده نسبت داد. طبق سناریوی SSP1.26، غلظت دی‌اکسید کربن به‌طور کلی کاهش می‌یابد که منجر به تغییرات جزئی در دمای متوسط شده است. با این حال نتایج کلی نشان می‌دهد که در بیشتر ماه‌ها افزایش دما تحت سناریوهای اقلیمی مشاهده خواهد شد. بیشترین افزایش دما در ماه‌های گرم سال اتفاق خواهد افتاد که در آن موجب افزایش دمای منطقه و به دنبال آن کاهش بارش و جریان ورودی به مخزن سد خواهد شد.




Figure 4. Temperature changes under different scenarios in the future (2026-2045)

در شکل (۵) تغییرات بارش در سال‌های (۲۰۲۶-۲۰۴۵) تحت سه سناریو نشان داده شده است. با توجه به مدل انتخابی برای بارش (FGOALS-g3)، در سناریو SSP1.26 بارش در ماه‌های ژانویه، مارس، آوریل، اوت، سپتامبر، اکتبر و نوامبر افزایش خواهد یافت، که بیشترین مقدار افزایش بارش در ماه‌های آوریل و ژانویه خواهد بود. در این دو ماه، افزایش بارش به ترتیب به مقدار ۸/۲ و ۷/۴ میلی‌متر خواهد بود. در مقابل، در ماه‌هایی که کاهش بارش رخ می‌دهد، دو ماه می و ژوئن به ترتیب با ۸/۳ و ۱۳ میلی‌متر بیشترین کاهش بارش را در دوره آبی تجربه خواهد کرد. در سناریو SSP2.45 بارش در ماه‌هایی به جز فوریه، مارس و آوریل کاهش خواهد یافت. برای سناریوی SSP5.85، با وجود یک سناریو بدبینانه بودن، کاهش بارش چشمگیر نخواهد بود. بر اساس داده‌های این سناریو، بارش در ماه‌های می تا دسامبر، به استثنای ماه نوامبر کاهش خواهند یافت. در ماه‌های مذکور، ماه دسامبر با کاهش ۱۳/۳ میلی‌متری در میانگین ماهانه بارش، بیشترین کاهش بارش را تجربه خواهد کرد.

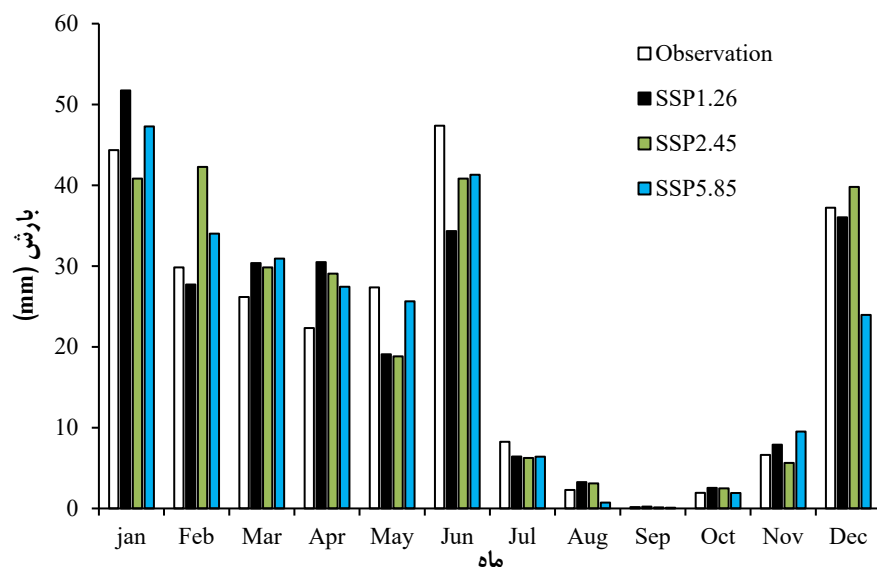


Figure 5. precipitation changes under different scenarios in the future (2026-2045)

### ۲.۳. ارزیابی مدل‌های ANN و ANN-PSO در برآورد دبی رودخانه


مقدار دبی رودخانه با در نظر گرفتن دو سناریو (T, P) و (T, P, Qn-1) با استفاده از مدل‌های ANN و ANN-PSO تخمین زده شد و نتایج آن‌ها با استفاده از معیارهای MAE، RMSE و NSE ارزیابی شد. هر مدل و الگوی ورودی که دارای دقت بیشتری باشد، برای پیش‌بینی دبی جریان در دوره آینده (۲۰۲۶-۲۰۴۵) تحت اثر تغییر اقلیم استفاده خواهد شد. مطابق جدول (۴)، هر دو مدل پیشنهادی با در نظر گرفتن سناریو دوم عملکرد مناسبی در برآورد مقدار دبی ورودی نسبت به سناریوی اول دارند، این بدان معناست که هر دو مدل برای پیش‌بینی بهتر دبی ورودی به سد به تعداد ورودی‌های بیشتری نیاز دارند. براساس جدول، مشاهده می‌گردد که مدل ANN در پیش‌بینی جریان دارای خطای زیادی است و همچنین ضریب NSE تقریباً کمتری دارد. در سناریو اول، مدل ANN، با معیارهای (RMSE=19.04, MAE=-2.65, NSE=0.42) برای داده‌های آزمون، از دقت کافی در برآورد دبی رودخانه برخوردار نبوده است، از این رو استفاده از الگوریتم PSO مقدار RMSE داده‌های آموزش و آزمون را به ترتیب حدود ۲ و ۵/۵ میلیون مترمکعب کاهش و مقدار NSE را به ترتیب ۰/۰۶ و ۰/۳۳ افزایش داده است. از طرف دیگر، اضافه کردن (Qn-1) دقت مدل ANN را به خصوص برای داده‌های آموزش افزایش داده است. به طوری که مقدار RMSE حدود ۷/۴ میلیون مترمکعب را کاهش و بر مقدار NSE حدود ۰/۳ افزوده است. مقادیر جدول (۴) نشان می‌دهد که استفاده از الگوریتم بهینه‌سازی PSO باعث افزایش دقت مدل ANN شده است. مدل ترکیبی ANN-PSO با استفاده از پارامترهای سناریو ۲ با دقت بیشتری مقدار جریان را تخمین زده است، به طوری که مقادیر MAE، RMSE و NSE برای داده‌های آموزش به ترتیب برابر ۰/۳۱ و ۲/۳۱ و ۰/۷۹ برای داده‌های آزمون نیز ۱۱/۸۲، ۲/۲۳ و ۰/۷۷ است. بنابراین از مدل ANN-PSO برای پیش‌بینی جریان در دوره آینده تحت اثر تغییر اقلیم استفاده خواهد شد.

Table 4. The results of scenarios and machine learning models in the prediction of inflow to the reservoir

NSE		MAE (MCM)		RMSE (MCM)		Model	Pattern
Test	Training	Test	Training	Test	Training		

0.38	0.69	5.8	4.3	8.90	7.13	ANFIS	Pattern 1
0.60	0.78	4.3	3.7	6.60	6.03	ANFIS-PSO	
0.52	0.90	4.8	2.0	8.96	3.70	ANFIS	Pattern 2
0.77	0.91	3.4	1.9	6.40	3.60	ANFIS-PSO	

نمودار سری زمانی داده‌های مشاهداتی و شبیه‌سازی شده مرحله آزمون با استفاده از مدل‌های ANN و ANN-PSO به ترتیب در شکل‌های (۶) و (۷) ارائه شده است. مطابق شکل (۶)، مدل منفرد ANN برای سناریو ۱ در برخی گام‌های زمانی مانند گام ۱۳، ۳۰ و ۹۱ مقدار جریان را بسیار کمتر از مقدار واقعی برآورد کرده است. همچنین در نقاطی مانند ۵، ۱۹، ۲۰، ۲۱، ۶۷ و ۸۶ بیشتر از مقدار مشاهداتی تخمین زده است. در سناریو ۲ نیز در بسیاری از گام‌های زمانی مقدار دبی را بیشتر و کمتر از مقدار واقعی پیش‌بینی کرده است. به عبارتی دیگر، فاصله بین داده‌های مشاهداتی به خصوص در دبی‌های بیشینه و جریان پایه بیشتر است. دلیل عملکرد ضعیف مدل منفرد در برخی گام‌ها به خصوص در مقادیر حدی جریان پایه و جریان بیشینه را می‌توان به، به دام افتادن الگوریتم‌های آموزش در نقاط کمینه محلی نسبت داد، از این رو استفاده از الگوریتم بهینه‌سازی PSO تا حد زیادی توانسته است دقت مدل ANN را افزایش دهد. مطابق شکل (۷)، با وجود اینکه در برخی گام‌های زمانی فواصل کمی بین داده‌های مشاهداتی و شبیه‌سازی شده وجود دارد، اما عملکرد مدل در برآورد مقادیر حدی قابل توجه است. استفاده از یک پارامتر اضافی ( $Q_{n-1}$ ) نیز باعث افزایش دقت مدل ترکیبی در مقایسه با سناریو ۱ شده است. به طوری که بیشترین تطابق بین داده‌های مشاهداتی و شبیه‌سازی شده در شکل b-۷ به چشم می‌خورد.







Figure 6. Time series diagram of observed and simulated test data using ANN model. a) Scenario 1 b) Scenario 2



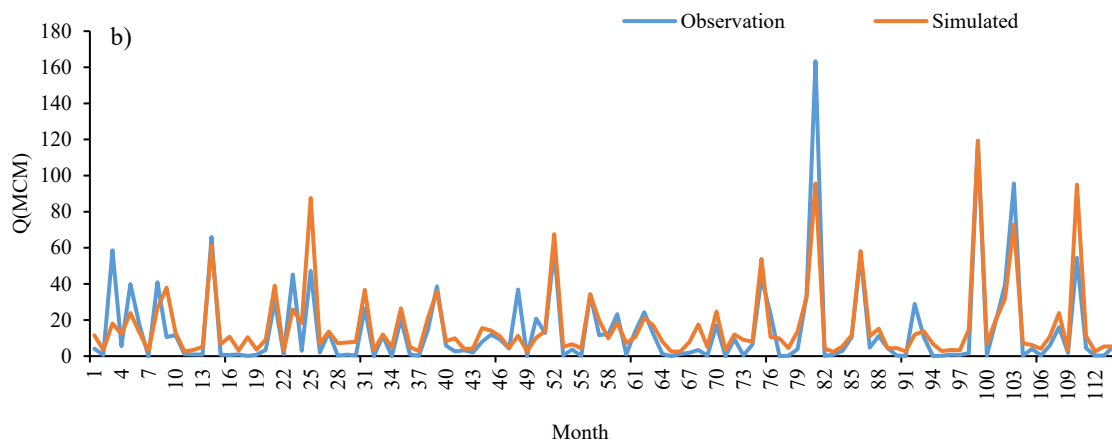
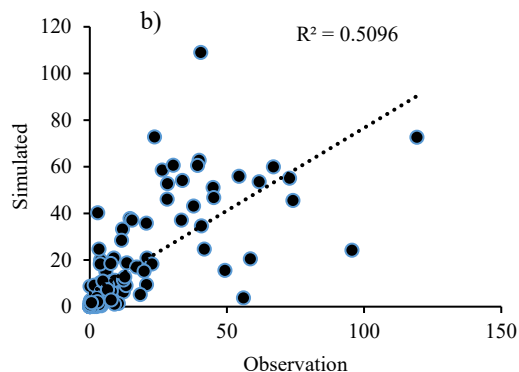



Figure 7. Time series diagram of observed and simulated test data using ANN-PSO model. a) Scenario 1 b) Scenario 2.

در شکل (۸) نمودار پراکندگی داده‌های آزمون مشاهداتی و شبیه‌سازی شده با استفاده از دو مدل حول خط رگرسیون ارائه شده است. مطابق شکل‌های 8a و 8b داده‌ها با پراکندگی بیشتری حول خط رگرسیون پراکنده شده‌اند، ضرایب  $R^2$  برای دو سناریو به ترتیب  $0.48$  و  $0.51$  است که نشان از همبستگی پایین بین داده‌ها دارد. در مقابل در مدل ترکیبی داده‌ها علاوه بر اینکه با تراکم بیشتری در اطراف خط رگرسیون قرار گرفته‌اند، از ضریب همبستگی بالایی نیز برخوردارند. داده‌های حاصل از مدل ANN-PSO در سناریو دوم با ضریب  $R^2=0.77$  بیشترین همبستگی را دارند.





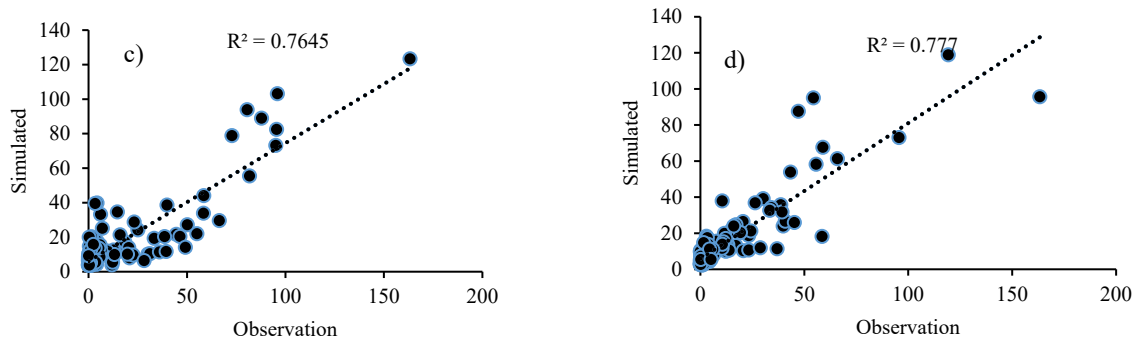


Figure 8. Scatter plot of observed and simulated test data around the regression line using ANN and ANN-PSO models. a) Scenario (1) ANN- b) Scenario (2) ANN- c) Scenario (1) ANN-PSO - d) Scenario (2) ANN-PS.

برای مقایسه بهتر مدل‌ها و سناریوهای مورد استفاده، از دیاگرام تیلور استفاده شد. مطابق این دیاگرام موقعیت هر مدلی که به داده‌های مشاهداتی نزدیک‌تر باشد، همبستگی بالا و RMSD پایین داشته باشد، عملکرد خوبی در برآورد دبی جریان داشته است. مطابق شکل (۹)، موقعیت مدل ترکیبی با استفاده از دو سناریو ورودی به داده‌های مشاهداتی نزدیک‌تر است و ضریب همبستگی داده‌های آن‌ها از حدود ۰/۸۹ برای (ANNPSO, S1) تا حدود ۰/۹۱ برای (ANN-PSO, S2) متغیر است. مقدار RMSD برای مدل ترکیبی و در هر دو سناریوی ورودی حدود (MCM) ۱۱ است، در حالی که این مقدار برای مدل ANN نزدیک به کمان عدد ۱۵ است. مدل ANN در به کارگیری پارامترهای سناریو ۲ نتایج بهتری نسبت به سناریوی ۱ ارائه داده است، بیشتر بودن مقدار ضریب همبستگی و موقعیتی نزدیک‌تر به داده‌های مشاهداتی نیز مویید این واقعیت است. در بین مدل‌ها و سناریوهای مورد استفاده، ضریب همبستگی (ANN-PSO, S2) بیشتر از سایر مدل‌هاست و از طرف دیگر، این مدل RMSD پایین‌تری نیز دارد، از این رو مدل ترکیبی ANN-PSO و سناریو دوم به عنوان مدل و سناریو برتر انتخاب می‌شود.

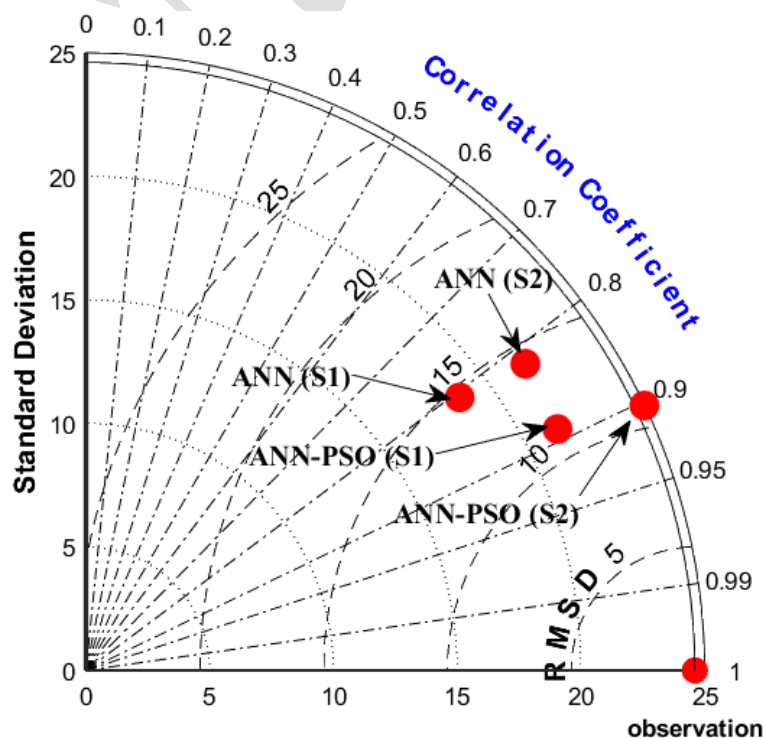


Figure 9. Taylor diagram for comparison between input models and scenarios.

در مرحله قبل، با استفاده از داده‌های مشاهداتی دما، بارش و دبی یک ماه قبل، دبی رودخانه با استفاده از دو مدل تخمین زده شد تا مناسب‌ترین الگوی ورودی و مدل پیش‌بینی کننده برای پیش‌بینی دبی جریان در دوره آینده تحت اثر تغییر اقلیم انتخاب شود. بنابراین با استفاده از پارامترهای سناریو دوم و مدل ANN-PSO دبی جریان برای دوره آینده تحت سناریوهای اقلیمی SSP1.26، SSP2.45 و SSP5.85 پیش‌بینی شد (شکل ۱۰). تحت سناریو SSP1.26، دبی جریان در ماه‌های فوریه، ژوئن، جولای و دسامبر افزایش و در بقیه ماه‌های سال نیز کاهش خواهد یافت. تحت این سناریو بیشترین افزایش دبی (1.5 MCM) در ماه جولای و در ماه می بیشترین کاهش (9.58 MCM) را تجربه خواهد کرد. اما در سناریوهای SSP2.45 و SSP5.85 تقریباً در همه ماه‌ها دبی رودخانه کاهش خواهد یافت. تحت این دو سناریو در ماه دسامبر به ترتیب به مقدار (1.11 MCM) و (0.26 MCM) افزایش خواهد یافت. در حالی که در بقیه‌های ماه‌های سال روند کاهشی را تجربه خواهد کرد.




Figure 10. Changes in flow rate under different scenarios in the future (2026-2045).

### ۳.۳. بحث

برای پیش‌بینی سری‌های زمانی در حالت کلی مدل‌های یادگیری ماشین نسبت به دیگر روش‌ها به عنوان ابزاری کارآمد و قابل اعتماد عمل کرده‌اند که این در تحقیقات (Arya Azar et al., 2021; Tikhmarine et al., 2019; Ghorbani et al., 2018) به اثبات رسیده است. در این تحقیق، برای پیش‌بینی دبی جریان از دو مدل ANN و ANN-PSO و دو سناریو با پارامترهای دما، بارش و دبی ماه قبل استفاده شد. نتایج نشان داد، هر دو مدل به پارامترهای ورودی بیشتری برای تخمین دبی جریان نیاز دارند. از بین دو مدل پیشنهادی، دقت مدل ANN-PSO بیشتر بود. این بدان معناست که اضافه کردن الگوریتم‌های فرا ابتکاری به مدل‌های منفرد باعث افزایش دقت آن می‌شود که این واقعیت در تحقیقات مختلفی مانند تحقیق (Bac et al., 2021; Sammen et al., 2020) به اثبات رسیده است. همچنین در ادامه اثر تغییر اقلیم بر روی دبی رودخانه نیز بررسی شد. نتایج کلی نشان داد که تغییر اقلیم باعث کاهش دبی در دوره آینده خواهد شد که این نتایج همسو با نتایج تحقیق (Emami et al., 2019) بود. نتایج این تحقیق نشان

داد عملکرد مدل‌های یادگیری ماشینی در پیش‌بینی دبی تحت تأثیر تغییر اقلیم عملکرد مناسبی دارند و نتایج تحقیق ( Emami et al., 2019; Kayhomayoon et al., 2023) تأیید کننده نتایج این تحقیق بود.

#### ۴. نتیجه‌گیری

هدف این تحقیق پیش‌بینی دبی رودخانه تحت تأثیر تغییرات اقلیمی بود. در ابتدا برای استخراج داده‌های تغییر اقلیم بارش و دما برای دوره آینده، از بین ۱۴ مدل گزارش ششم IPCC، برای دما مدل BCC-CSM2-MR و برای بارش مدل FGOALS-g3 براساس معیارهای ارزیابی انتخاب شد. در ادامه با استفاده از پارامترهای دما، بارش و دبی یک ماه قبل دو سناریو تدوین شد. سپس از دو مدل ANN و ANN-PSO برای تخمین دبی جریان مشاهداتی استفاده شد تا بهترین مدل و سناریو برای پیش‌بینی جریان در دوره آینده تحت اثر تغییر اقلیم مشخص شود. نتایج نشان داد که از بین دو مدل پیش‌بینی کننده، دقت مدل ترکیبی ANN-PSO بهتر از مدل منفرد ANN بود. همچنین استفاده از پارامتر دبی یک ماه قبل دقت پیش‌بینی هر دو مدل را تا حد زیادی افزایش داد. نتایج همچنین بیانگر این بود که با تغییر در الگوی دما و بارش، پارامتر دبی نیز دچار تغییراتی خواهند شد، به طوری که در حالت کلی تغییر اقلیم دبی را تا حد زیادی کاهش خواهد داد. شدت اثر تغییرات اقلیمی بسته به مناطق مختلف می‌تواند زیاد یا کم باشد، به ویژه در مناطق خشک و نیمه‌خشک مانند ایران، تغییرات اقلیمی می‌تواند الگوی بارش و دما را به شدت تحت تأثیر قرار دهد از این رو پیش‌بینی پارامترهای اقلیمی برای دوره آینده می‌تواند یک ابزار کاربردی باشد. بنابراین استفاده از مطالعه ترکیبی تغییر اقلیم و مدل‌های یادگیری ماشینی می‌تواند روشی سودمند در مدیریت بهتر اثرات تغییر اقلیم در آینده به کار گرفته شود.

#### منابع

- Arya Azar, N., Ghordoyee Milan, S., & Kayhomayoon, Z. (2021). Predicting monthly evaporation from dam reservoirs using LS-SVR and ANFIS optimized by Harris hawks optimization algorithm. *Environmental Monitoring and Assessment*, 193(11), 1-14.
- Ashrafzadeh A, Malik A, Jothiprakash V, Ghorbani MA, Biazar SM (2018) Estimation of daily pan evaporation using neural networks and meta-heuristic approaches. *ISH J Hydraul Eng*.
- Bac, B. H., Nguyen, H., Thao, N. T. T., Hanh, V. T., Duyen, L. T., Dung, N. T., ... & Hiep, N. H. (2021). Estimating heavy metals absorption efficiency in an aqueous solution using nanotube-type halloysite from weathered pegmatites and a novel Harris hawks optimization-based multiple layers perceptron neural network. *Engineering with Computers*, 1-16.
- Behulu, F.; Setegn, S.; Melesse, A.M.; Romano, E.; Fiori, A. Impact of climate change on the hydrology of Upper Tiber River Basin Using bias corrected regional climate model. *Water Resour. Manag.* 2014, 28, 1327–1343.
- Chang, H.; Jung, I.W. Spatial and temporal changes in runoff caused by climate change in a complex large river basin in Oregon. *J. Hydrol.* 2010, 388, 186–207.
- Daba, M. H., & You, S. (2020). Assessment of climate change impacts on river flow regimes in the upstream of Awash Basin, Ethiopia: based on IPCC fifth assessment report (AR5) climate change scenarios. *Hydrology*, 7(4), 98.
- Daba, M.; Rao, G.N. Evaluating Potential Impacts of Climate Change on Hydro- meteorological Variables in Upper Blue Nile Basin, Ethiopia: A Case Study of Finchaa Sub-basin. *J. Environ. Earth Sci.* 2016, 6, 48–57.
- Daba, M.H. Sensitivity of SWAT Simulated Runoff to Temperature and Rainfall in the Upper Awash Sab-Basin, Ethiopia. *Hydrol. Curr. Res.* 2018, 9, 293.
- Di, C., Yang, X., Wang, X., 2014. A four-stage hybrid model for hydrological time series forecasting. *PLoS ONE* (8), e104663.

- Emami, F., & Koch, M. (2019). Modeling the impact of climate change on water availability in the Zarrine River Basin and inflow to the Boukan Dam, Iran. *Climate*, 7(4), 51.
- Fathian, F. Mehdizadeh, S. Kozekalani Sales, A. Safari, M J. (2019). Hybrid models to improve the monthly river flow prediction: Integrating artificial intelligence and non-linear time series models.. *Journal of Hydrology*. 575. 1200.
- Fernando, A., Shamseldin, A., & Abrahart, R. (2011). Comparison of two data-driven approaches for daily river flow forecasting.
- Ghasemain, B.; Asl, D.T.; Pham, B.T.; Avand, M.; Nguyen, H.D.; Janizadeh, S. Shallow landslide susceptibility mapping: A comparison between classification and regression tree and reduced error pruning tree algorithms. *Vietnam J. Earth Sci.* 2020.
- Ghorbani, M. A., Deo, R. C., Yaseen, Z. M., Kashani, M. H., & Mohammadi, B. (2018). Pan evaporation prediction using a hybrid multilayer perceptron-firefly algorithm (MLP-FFA) model: case study in North Iran. *Theoretical and applied climatology*, 133(3), 1119-1131.
- Goodarzi E, Dastorani M, Talebi A (2015) Evaluation of the change-factor and LARS-WG methods of downscaling for simulation of climatic variables in the future (Case study: Herat Azam Watershed, Yazd-Iran). *Ecopersia* 3(1):833–846.
- Halik, G., Anwar, N., & Santosa, B. (2015). Reservoir inflow prediction under GCM scenario downscaled by wavelet transform and support vector machine hybrid models. *Advances in Civil Engineering*, 2015.
- He, Z., Wen, X., Liu, H., Du, J., 2014. A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *J. Hydrol.* 509, 379–386.
- Hodgkins, G.A.; Whitfield, P.H.; Burn, D.H.; Hannaford, J.; Renard, B.; Stahl, K.; Fleig, A.K.; Madsen, H.; Mediero, L.; Murphy, C.; et al. Climate-driven variability in the occurrence of major floods across North America and Europe. *J. Hydrol.* 2017, 552, 704–717.
- IPCC. *Climate Change 2013. In The Physical Science Basis Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change Edited by 2013; IPCC: Geneva, Switzerland, 2013.*
- IPCC. *Climate Change 2017: The Physical Science Basis; IPCC: Geneva, Switzerland, 2017.*
- Kayhomayoon, Z., Naghizadeh, F., Malekpoor, M., Arya Azar, N., Ball, J., & Ghordoyee Milan, S. (2023). Prediction of evaporation from dam reservoirs under climate change using soft computing techniques. *Environmental Science and Pollution Research*, 30(10), 27912-27935.
- Kayhomayoon, Z., Naghizadeh, F., Malekpoor, M., Arya Azar, N., Ball, J., & Ghordoyee Milan, S. (2023). Prediction of evaporation from dam reservoirs under climate change using soft computing techniques. *Environmental Science and Pollution Research*, 30(10), 27912-27935.
- Kusangaya, S., Warburton, M. L., Van Garderen, E. A., & Jewitt, G. P. (2014). Impacts of climate change on water resources in southern Africa: A review. *Physics and Chemistry of the Earth, Parts a/b/c*, 67, 47-54.
- Lupo, A.; Kininmonth, W.; Armstrong, J.; Green, K. Global climate models and their limitations. *Clim. Chang. Reconsidered II Phys. Sci.* 2013, 9, 148.
- Masson-Delmotte, V. P., Zhai, P., Pirani, S. L., Connors, C., Péan, S., Berger, N., ... & Scheel Monteiro, P. M. (2021). *Ipcc, 2021: Summary for policymakers. in: Climate change 2021: The physical science basis. contribution of working group i to the sixth assessment report of the intergovernmental panel on climate change.*
- Meshram, S.G., Ghorbani, M.A., Shamshirband, S. et al. River flow prediction using hybrid PSO-GSA algorithm based on feed-forward neural network. *Soft Comput* 23, 10429–10438 (2019).
- Milan, S. G., Kayhomayoon, Z., Azar, N. A., Berndtsson, R., Ramezani, M. R., & Moghaddam, H. K. (2023). Using machine learning to determine acceptable levels of groundwater consumption in Iran. *Sustainable Production and Consumption*, 35, 388-400.
- Mitsova, D. Coupling Land Use Change Modeling with Climate Projections Catchment Near Cincinnati, Ohio. *ISPRS Int. J. Geo-Inf.* 2014, 3, 1256–1277.
- Nguyen, X. H. (2020). Combining statistical machine learning models with ARIMA for water level forecasting: The case of the Red river. *Advances in Water Resources*, 142, 103656.

- Sammen, S. S., Ghorbani, M. A., Malik, A., Tikhamarine, Y., AmirRahmani, M., Al-Ansari, N., & Chau, K. W. (2020). Enhanced artificial neural network with Harris hawks optimization for predicting scour depth downstream of ski-jump spillway. *Applied Sciences*, 10(15), 5160.
- Shariati, M., Mafipour, M. S., Mehrabi, P., Bahadori, A., Zandi, Y., Salih, M. N., ... & Poi-Ngian, S. (2019). Application of a hybrid artificial neural network-particle swarm optimization (ANN-PSO) model in behavior prediction of channel shear connectors embedded in normal and high-strength concrete. *Applied sciences*, 9(24), 5534.
- Taye, M.; Dyer, E.; Hirpa, F.; Charles, K. Climate change impact on water resources in the Awash basin, Ethiopia. *Water* 2018, 10, 1560.
- Tikhamarine, Y., Malik, A., Kumar, A., Souag-Gamane, D., & Kisi, O. (2019). Estimation of monthly reference evapotranspiration using novel hybrid machine learning approaches. *Hydrological sciences journal*, 64(15), 1824-1842.
- Zabardast Rostami, H. A., Raeni Sarjaz, M., & Gholami Sefidkouhi, M. A. (2021). Assessment of Climate Change Effects on River Flow of Gelevar Dam Basin. *Journal of Watershed Management Research*, 12(24), 205-216.
- Zhang, H., Singh, V.P., Wang, B., Yu, Y., 2016. CEREF: A hybrid data-driven model for forecasting annual streamflow from a socio-hydrological system. *J. Hydrol.* 540, 246–256.