

Simulation of the Effects of Climate Change on Runoff Using Artificial Neural Network Models and Adaptive Fuzzy Neural Inference System (Case Study: Tashk-Bakhtegan Basin)

H. Mazandaranizadeh^{1*}, M. Fallah Kalaki²,
and A. Azizian³

Abstract

Estimating the available water plays a vital role in planning water resources projects. The first step in assessing water availability is to calculate runoff in catchments. Moreover, it is necessary to study the effects of climate change on water components such as runoff since climate change directly affects the hydrological components and water resources. In this study, the status of the inflow to Tashk-Bakhtegan lakes as one of the most important lakes in the country was investigated. Because generation of runoff is a complex concept due to its nonlinear and multidimensional nature, various theoretical and physical models have been developed to predict runoff. The high dependence of these physical models on numerous parameters and maps, practically challenged their efficiency in basins with limited observations. On the other hand, models based on artificial neural networks and fuzzy inference systems are considered applied tools that can help hydrologists in such circumstances. In this study, FFBPNN and ANFIS models and their combination with PSO and GA metaheuristic algorithms have been investigated in evaluating the runoff in historical conditions and under RCP and SSP climate change scenarios. The obtained results showed that the FFBPNN and ANFIS models combined with the PSO algorithm (ANFIS_PSO) using precipitation, minimum temperature, and maximum temperature as inputs had better performance compared to other models with different inputs. The values of the correlation coefficient, root mean square error (m³/s), Nash-Sutcliffe coefficient and Kling Gupta were respectively 0.99, 2.07, 0.99 and 0.98 in the training period and 0.94, 3.61, 0.91 and 0.88 in the test period and 0.98, 94.2, 0.97 and 0.98 in the training period and 0.93, 3.87, 0.85 and 0.88 in the test period. The results of this study can be used in investigating the effects of the above mentioned scenarios on important basins of the country and consequently in planning and managing water resources in the context of climate change.

Keywords: Climate Change, FFBPNN, ANFIS, Metaheuristic Algorithms.

Received: July 11, 2022

Accepted: October 12, 2022

شبیه‌سازی اثرات تغییر اقلیم بر رواناب با استفاده از مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی فازی تطبیقی (مطالعه موردی: حوضه آبریز طشک-بختگان)

حامد مازندرانی‌زاده^{۱*}، محمد فلاح کلاکی^۲ و اصغر عزیزیان^۳

چکیده

در برنامه‌ریزی پروژه‌های منابع آب، برآورد میزان دسترسی به آب نقش مهمی ایفا می‌کند. اولین مرحله در برآورد در دسترس بودن آب، محاسبه رواناب در حوضه‌های آبریز است. از طرفی، تغییر اقلیم به‌صورت مستقیم بر روی مؤلفه‌های هیدرولوژیکی و منابع آبی تأثیرگذار است؛ لذا بررسی اثرات تغییر اقلیم بر مؤلفه‌های آبی همچون رواناب امری ضروری است. از این رو در این مطالعه وضعیت جریان ورودی به دریاچه‌های طشک-بختگان به‌عنوان یکی از مهم‌ترین دریاچه‌های کشور مورد بررسی قرار گرفت. از آنجا که فرآیند بارش-رواناب به دلیل ماهیت غیرخطی و چند بعدی، مفهومی پیچیده است، تاکنون مدل‌های مفهومی و فیزیکی-پایه مختلفی به منظور پیش‌بینی رواناب توسعه یافته است. وابستگی زیاد این مدل‌ها به پارامترها و نقشه‌های متعدد، عملاً کارایی آنها را در حوضه‌های با آمار محدود با چالش اساسی روبرو می‌نماید. در مقابل، مدل‌های مبتنی بر شبکه عصبی مصنوعی و سیستم استنتاج فازی به عنوان ابزارهای کاربردی در نظر گرفته می‌شوند که می‌توانند در چنین شرایطی به هیدرولوژیست‌ها در فعالیتهای عملیاتی کمک کنند. در این مطالعه مدل‌های شبکه عصبی استنتاج فازی و FFBPNN و سیستم استنتاج عصبی فازی تطبیقی ANFIS و تلفیق آن با الگوریتم‌های فراابتکاری بهینه‌سازی ازدحام ذرات (PSO) و ژنتیک (GA) به منظور بررسی وضعیت رواناب در شرایط تاریخی و نیز تغییر اقلیم تحت سناریوهای RCP و SSP مورد بررسی قرار گرفته است. نتایج به‌دست‌آمده نشان می‌دهد که مدل‌های FFBPNN و ANFIS تلفیق شده با الگوریتم PSO (ANFIS_PSO) با استفاده از متغیرهای بارش، دمای حداقل و دمای حداکثر به عنوان متغیرهای ورودی، به ترتیب با مقادیر ضریب همبستگی، ریشه میانگین مربعات خطا (متر مکعب بر ثانیه)، ضریب نش-سانکلیف و کلینگ گوپتا (۰/۹۹، ۲/۰۷، ۰/۹۹ و ۰/۹۸) در دوره آموزش و (۰/۹۴، ۳/۶۱، ۰/۹۱ و ۰/۸۸) در دوره آزمون) و (۰/۹۸، ۹۴/۲، ۰/۹۷ و ۰/۹۸) در دوره آموزش و (۰/۹۳، ۳/۸۷، ۰/۸۵ و ۰/۸۸) در دوره آزمون) عملکرد بهتری نسبت به سایر مدل‌ها با ورودی‌های متفاوت داشته‌اند. نتایج این تحقیق می‌تواند برای بررسی اثرات این سناریوها بر حوضه‌های مهم کشور و در نتیجه برنامه‌ریزی و مدیریت منابع آب در شرایط تغییر اقلیم مفید باشد.

کلمات کلیدی: تغییر اقلیم، FFBPNN، ANFIS، الگوریتم‌های فراابتکاری.

تاریخ دریافت مقاله: ۱۴۰۱/۴/۲۰

تاریخ پذیرش مقاله: ۱۴۰۱/۷/۲۰

1- Associate Professor, Water Resources Engineering Department, Imam Khomeini International University, Qazvin, Iran. Email: mazandaranizadeh@eng.ikiu.ac.ir

2- Ph.D. Student, Water Resources Engineering Department, Imam Khomeini International University, Qazvin, Iran.

3- Associate Professor, Water Resources Engineering Department, Imam Khomeini International University, Qazvin, Iran.

*- Corresponding Author

Dor: [20.1001.1.17352347.1401.18.4.1.5](https://doi.org/10.1001.1.17352347.1401.18.4.1.5)

۱- دانشیار، گروه علوم و مهندسی منابع آب، دانشگاه بین‌المللی امام خمینی، قزوین، ایران.
۲- دانشجوی دکتری، گروه مهندسی منابع آب، دانشگاه بین‌المللی امام خمینی، قزوین، ایران.
۳- دانشیار، گروه علوم و مهندسی منابع آب، دانشگاه بین‌المللی امام خمینی، قزوین، ایران.
*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان بهار ۱۴۰۲ امکانپذیر است.



انجام شده است. به عنوان مثال، (Tokar and Markus, 2000) بررسی چند مدل مختلف از جمله شبکه عصبی مصنوعی، مدل‌های مفهومی تعادل آب (Watbal)^۴، مدل حسابداری رطوبت خاک ساکرامنتو (SAS-SMA)^۵، مدل مفهومی بارش-رواناب ساده (SCRR)^۶ در سه حوضه آبریز با شرایط آب و هوایی مختلف (رودخانه Fraser در کلرادو، رودخانه Raccoon در آیووا و رودخانه Patuxent در مریلند) نشان دادند که مدل شبکه عصبی مصنوعی در همه موارد عملکرد بهتری در تخمین رواناب ماهانه داشته است.

استفاده از روش سیستم استنتاج عصبی- فازی تطبیقی (ANFIS) به منظور مدل‌سازی سری زمانی هیدرولوژیکی در رودخانه بیترا نی هند نشان داد که این مدل در مقایسه با مدل شبکه عصبی مصنوعی و مدل‌های سری زمانی (ARMA)^۷ عملکرد بهتری داشته است و ویژگی‌های آماری سری زمانی مشاهداتی را نیز حفظ کرده است (Nayak et al., 2004). در مطالعه‌ای که در استان فارس انجام شده است، استفاده از روش‌های شبکه عصبی مصنوعی (ANN)، سیستم استنتاج عصبی- فازی تطبیقی (ANFIS)، رگرسیون خطی چندگانه (MLR)^۸ و رگرسیون غیرخطی چندگانه (MNL)^۹ به منظور پیش‌بینی حداکثر جریان روزانه در خروجی حوضه خسرو- شیرین نشان داد که استفاده از بارش به صورت میانگین وزنی در مدل‌های ANN و MNLR و استفاده از بارش با توزیع مکانی به صورت نقطه‌ای در مدل‌های ANFIS و MLR منجر به پیش‌بینی دقیق‌تری شده است (Rezaeianzadeh et al., 2014). استفاده از مدل شبکه عصبی مصنوعی، ترکیب شبکه عصبی با الگوریتم ژنتیک و مدل ترکیبی خوشه‌بندی کاهشی و سیستم استنتاج عصبی- فازی تطبیقی برای پیش‌بینی دبی حداکثر رودخانه‌ی یلفان با بکارگیری هشت متغیر بارندگی مربوط به روز وقوع سیل، بارندگی تا ۵ روز قبل، دبی پایه در روز وقوع سیل و CN حوضه به عنوان ورودی و دبی حداکثر به عنوان خروجی مدل‌ها نشان داد که مدل تلفیقی شبکه عصبی و الگوریتم ژنتیک نسبت به مدل شبکه عصبی و نیز مدل ترکیب خوشه‌بندی کاهشی و مدل ANFIS عملکرد بهتری در برآورد دبی سیلاب در حوضه یلفان دارد (Nouri et al., 2019).

در مطالعه‌ای که در حوضه رودخانه دیکو در هند انجام شده است؛ جریان رودخانه با استفاده از مدل ANFIS پیش‌بینی شد. همچنین، در این مطالعه به منظور بهبود دقت پیش‌بینی، مدل ANFIS با الگوریتم بهینه‌سازی فراابتکاری PSO ترکیب شد. نتایج حاصل از مقایسه مدل ترکیبی ANFIS-PSO با مدل‌های ANFIS معمولی و ARIMA^{۱۲} حاکی از دقت بالاتر مدل ترکیبی ANFIS-PSO در پیش‌بینی جریان

رشد بالای جمعیت، صنعتی شدن، افزایش نیازهای کشاورزی و شهرنشینی از مهمترین دلایل افزایش تقاضا برای آب در اکثر نقاط جهان است (Wu et al., 2019). برآورد میزان آب در دسترس نقش بسزایی در برنامه‌ریزی پروژه منابع آب دارد. اطلاعات مربوط به رواناب یک حوضه آبریز برای طراحی مهندسی هیدرولوژیکی و اهداف مدیریتی مورد نیاز است (Wajahat and Sundar, 2018). یکی از اهداف اصلی پیش‌بینی رواناب، ارائه پیش‌بینی صحیح در مورد وضعیت سیل و هشدار به جمعیت درگیر با آن در زمان کافی است (Jimmy et al., 2021). همچنین، هیدرولوژیست‌ها سعی می‌کنند جریان رودخانه را برای مقاصد مختلفی همچون کنترل سیل، آبیاری، تامین آب، کیفیت آب، تفریح و تولید برق پیش‌بینی کنند (Annayat et al., 2021). لذا با توجه به محدودیت منابع آب شیرین در دسترس، پیش‌بینی صحیح رواناب و تغییرات آن در طول سال از ارکان اساسی مدیریت و برنامه‌ریزی منابع آب است. از این رو همواره تلاش‌های بسیاری در راستای تدقیق پیش‌بینی‌های رواناب با استفاده از روش‌های مختلف انجام شده است (Nabizadeh et al., 2012).

اگرچه بسیاری از مدل‌های نظری و فیزیکی به منظور پیش‌بینی مؤلفه‌های هیدرولوژیکی به‌ویژه رواناب به کار گرفته شده‌اند، مدل‌های هوشمند شبکه عصبی و سیستم استنتاج فازی به عنوان ابزارهای کاربردی در نظر گرفته می‌شوند که می‌توانند در شرایط کمبود داده‌های هیدرولوژیکی به هیدرولوژیست‌ها کمک کنند (Jimmy et al., 2021). شبکه‌های عصبی مصنوعی بر اساس اصل سیستم‌های عصبی بیولوژیکی کار می‌کنند و از سیستم‌های موازی بسیار تشکیل شده است که دارای عناصر پردازشی هستند که توسط پیوندهایی با وزن‌های مختلف به هم متصل شده‌اند (Smith and Eli, 1995). مدل‌های شبکه عصبی مصنوعی قادر به مدل‌سازی رابطه بارش- رواناب هستند؛ زیرا توانایی تعمیم الگوها در داده‌های ورودی مبهم را دارند و یک مدل پیچیده را بدون توزیع احتمال یا دانش قبلی ترکیب می‌کنند و می‌توانند به عنوان یک مدل هیدرولوژیکی جعبه سیاه در مقیاس زمانی روزانه تا سالانه استفاده شوند (Ghose and Samantaray, 2018). از همین رو استفاده از روش‌های هوشمند از جمله شبکه عصبی مصنوعی (ANN)^۱، سیستم استنتاج فازی (FIS)^۲ و سیستم استنتاج عصبی- فازی تطبیقی (ANFIS)^۳ برای شبیه‌سازی مسائل هیدرولوژیکی مورد توجه بسیاری از محققین قرار گرفته است و از آنها می‌توان برای شبیه‌سازی مسائل غیرخطی و پیچیده استفاده کرد (Dastorani et al., 2010). تاکنون تحقیقات مختلفی در این زمینه در ایران و جهان

رودخانه است (Nath et al., 2020). در مطالعه‌ای دیگر روی حوضه رودخانه‌ی باراک در هند، ادغام مدل ANFIS با الگوریتم فراابتکاری PSO به‌منظور پیش‌بینی جریان ماهانه رودخانه با استفاده از متغیرهای بارش، دما، رطوبت و نفوذ به عنوان ورودی مدل، نشان داد که مدل ANFIS-PSO با $RMSE = 5.887$ ، $MAE = 4.978$ ، $R^2 = 0.9668$ و $NSH = 0.961$ بهترین عملکرد را با قابلیت اطمینان و دقت بیشتر در مقایسه با مدل‌های ANFIS و ANN دارد. یافته‌های این تحقیق نشان داد که مدل ANFIS ترکیبی با الگوریتم بهینه‌سازی PSO یک رویکرد مدل‌سازی قابل اعتماد برای پیش‌بینی جریان ماهانه است (Samanataray and Sahoo, 2021).

با توجه به افزایش گازهای گلخانه‌ای از دهه ۱۹۰۰ و در پی آن تغییر در ویژگی‌های متغیرهای اقلیمی که منجر به وقوع حوادث طبیعی شدیدتر شده است (Almazroui et al., 2020). منابع آب و هیدرولوژی حوضه را نیز با افزایش دما و تغییر در توزیع بارش تحت تأثیر قرار می‌دهد (Kim et al., 2021). از این‌رو، پیش‌بینی‌های دقیق تغییرات آینده در رفتار هیدرولوژیکی حوضه به‌ویژه در شرایط عدم وجود داده کافی به منظور سیاست‌گذاری و برنامه‌ریزی منابع آب ضروری است (Wang et al., 2020). در همین راستا، مطالعات مختلفی در زمینه بررسی اثرات تغییر اقلیم بر رواناب انجام شده است. در مطالعه‌ای که در جنوب غربی چین انجام شده است؛ اثر تغییر اقلیم بر رواناب با استفاده از مدل شبکه عصبی (ANN) مورد بررسی قرار گرفت. نتایج به‌دست آمده از این مطالعه نشان داد که مدل شبکه عصبی در شبیه‌سازی رواناب با استفاده از مقادیر بارش و دما عملکرد مناسبی ($R^2=0.962$) داشته است. همچنین، نتایج حاصل شده حاکی از کاهش بارش، افزایش دما و کاهش رواناب در شرایط تغییر اقلیم است (Lin et al., 2019). در مطالعه‌ای دیگر در حوضه آبخیز آچی چای در شمال غرب ایران، اثرات تغییر اقلیم بر روی خصوصیات هیدرولوژیکی با استفاده از مدل‌های M5، MLP، SVM و ANFIS مورد بررسی قرار گرفت. نتایج پژوهش نشان داد که دمای حداکثر و حداقل در طول دوره (۲۰۱۰-۲۰۵۰) تحت سناریوهای A2 و B2 افزایش یافته است. نتایج پیش‌بینی بارش ماهانه نیز نشان داد که بارش روند مشخصی نداشته و در بعضی ماه‌ها افزایش و در بعضی از ماه‌ها کاهش می‌یابد. نتایج حاصل از ارزیابی کارایی مدل‌ها نشان داد که مدل‌های M5 و MLP کمترین خطا را در بین مدل‌ها داشتند. در حالت کلی نتایج مدل‌سازی بارش-رواناب نشان داد که هر کدام از مدل‌های انتخاب شده، دارای عدم قطعیت بوده و در بعضی فصل‌ها رواناب افزایشی و در بعضی فصل‌ها کاهش‌ی است (Kazemzadeh et al., 2019).

حوضه آبریز طشک-بختگان، از نظر منابع آب و انرژی برق آبی وجود مخازن بزرگ آبی همچون سدهای بزرگ درودزن، ملاصدرا و سیوند، و دریاچه‌های طشک و بختگان و کافت‌ر حائز اهمیت است و از طرف دیگر وجود صنایع نفت و پتروشیمی و همچنین زمین‌های کشاورزی وسیع و تولید محصولات استراتژیک مختلف در فصول مختلف همچون گندم و تأمین بخشی از آب شرب شهرهای بزرگی همچون شیراز و مرودشت اهمیت آن را دو چندان نموده است (Shokri Kuchak and Radmanesh, 2015). از همین‌رو، مطالعات مختلفی بر روی آن انجام شده است. با توجه به اینکه خروجی‌های مدل‌های GCM¹³ تحت سناریوهای SSP¹⁴ اخیراً در دسترس قرار گرفته است، در مطالعه‌ای که Fallah Kalaki et al. (2021) در این حوضه انجام دادند، تغییرات جریان رودخانه در شرایط تغییر اقلیم تحت سناریوهای RCP¹⁵ و SSP با استفاده از مدل هیدرولوژیکی ابزار ارزیابی آب و خاک (SWAT)¹⁶ مورد بررسی قرار گرفته است. در این مطالعه، شبیه‌سازی مدل SWAT در شرایط تغییر اقلیم در هر ۴ ایستگاه تحت سناریوهای SSP کاهش رواناب و در ۳ ایستگاه تحت سناریوهای RCP افزایش رواناب را نشان داد. هدف اصلی مطالعه حاضر، بررسی تغییرات رواناب در شرایط تغییر اقلیم تحت سناریوهای انتشار (RCP) در گزارش پنجم و سناریوهای (SSP) که ترکیب مقادیر انتشار گازهای گلخانه‌ای و فعالیت‌های اجتماعی-اقتصادی است، با استفاده از روش‌های داده‌محور است. نتایج این مطالعه می‌تواند برای سیاست‌گذاری و برنامه‌ریزی منابع آب در آینده مؤثر باشد. از همین‌رو، میزان تغییرات جریان ورودی به دریاچه بختگان در محل ایستگاه حسن‌آباد با استفاده از روش‌های شبکه عصبی مصنوعی، سیستم استنتاج عصبی-فازی تطبیقی و ترکیب آن با الگوریتم‌های بهینه‌سازی فراابتکاری PSO و GA در شرایط تغییر اقلیم تحت سناریوهای RCP2.6، RCP8.5 و SSP (SSP1-2.6، SSP5-8.5) مورد بررسی قرار می‌گیرد. به همین منظور از مدل‌های (GFDL-ESM2، GFDL-ESM4M، IPSL-CMA5A-LR، IPSL-CMA6-LR) برای دریافت داده‌های تغییر اقلیم استفاده شده است.

۲- مواد و روش‌ها

۲-۱- محدوده مطالعاتی

حوضه آبریز طشک-بختگان در طول جغرافیایی $33^{\circ} 54'$ تا $33^{\circ} 51'$ شرقی و عرض جغرافیایی $29^{\circ} 02'$ تا $15^{\circ} 31'$ شمالی (شکل ۱) با مساحت حدود ۲۷۵۲۰ کیلومتر مربع واقع شده است که بلندترین نقطه آن در غرب حوضه به ارتفاع حدود ۳۹۰۰ متر از سطح دریای آزاد و کمترین ارتفاع در حاشیه دریاچه طشک-بختگان به ارتفاع حدود

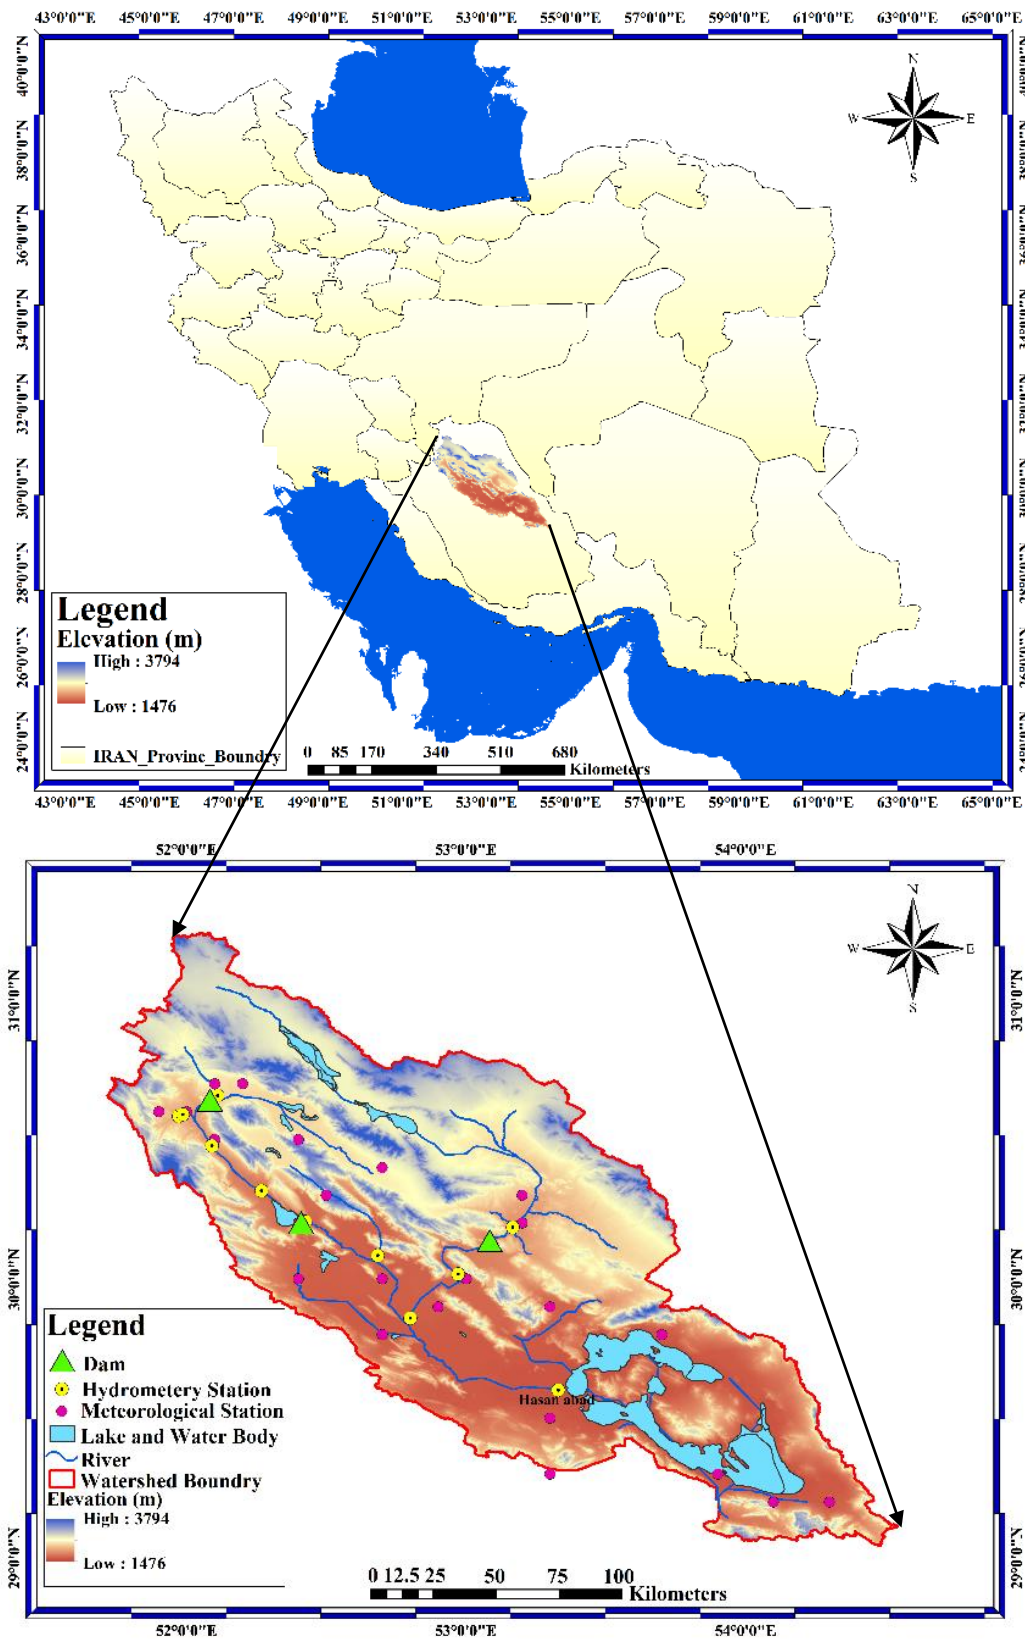


Fig. 1- The geographical location of the study area

شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه

۱۶۲۰ متر است (Delavar et al., 2017). حوضه آبریز طشک- بختگان در شمال استان فارس واقع شده و شامل ۴ زیر حوضه و ۲۲ محدوده مطالعاتی است که توسط اداره آب منطقه‌ای فارس مشخص شده است. دریاچه‌های طشک و بختگان، مقصد تمام رودخانه‌های حوضه هستند و به عنوان زیستگاه‌های مهم طبیعی، به ویژه برای پرندگان مهاجر عمل می‌کنند. حوضه طشک- بختگان، یک حوضه کارستی نیمه خشک با متوسط بارندگی سالانه ۳۲۰ میلی‌متر و تبخیر سالانه از ۱۷۶۳/۱ تا ۲۸۴۹/۴ میلی‌متر متغیر است (MOE, 2017). تغییرات درجه حرارت در این حوضه از دمای مطلق ۲۸- درجه سلسیوس در مناطق شمال و شمال غربی تا ۴۲ درجه سلسیوس در نواحی جنوب و جنوب شرقی مشاهده می‌گردد (Abbasi et al., 2020).

بیش از ۶۰ درصد آبیاری در حوضه آبریز طشک- بختگان به منابع آب زیرزمینی وابسته است. این حوضه در طول قرن‌ها، منابع مهمی را برای فعالیت‌های مهم اجتماعی، اقتصادی و اکولوژیکی فراهم کرده است. با این حال، این منطقه در ۵۰ سال اخیر از کمبود آب رنج می‌برد و برای رفع این کمبود آب، چندین مخزن در دهه‌های اخیر ساخته شده است (Delavar et al., 2020). این حوضه دارای ۳ سد مخزنی به نام‌های سد درودزن، سد سیبویید (سیوند) و سد ملاصدرا (تنگ براق) است که سد درودزن با حجم ۹۶۰ میلیون مترمکعب و با تنظیم آب ۵۲۶ میلیون مترمکعب بزرگترین سد این حوضه بوده و سد ملاصدرا با حجم ۴۴۰ میلیون مترمکعب و با حجم تنظیم آب ۳۲۹ میلیون مترمکعب دومین سد بزرگ این حوضه است (Abbasi et al., 2020).

جهت انجام تحقیق حاضر از آمار ماهانه بارندگی، دمای حداقل و دمای حداکثر ایستگاه‌های هواشناسی حوضه مورد مطالعه طی یک دوره آماری ۳۱ ساله (۲۰۱۵-۱۹۸۵) استفاده گردید. به همین منظور، آمار بارش، دمای حداقل و دمای حداکثر با استفاده از روش تبیین، منطقه‌ای شده و مورد استفاده قرار گرفت. همچنین، از آمار ماهانه دبی ایستگاه هیدرومتری حسن‌آباد خرامه در دوره ۲۰ ساله (۲۰۱۶-۱۹۹۷) به منظور برآورد ورودی به دریاچه طشک- بختگان استفاده شد.

۲-۲- شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی نقش مهمی را در هیدرولوژی ایفا می‌کنند (Wu et al., 2021) و می‌توانند مسائل غیرخطی پیچیده را به دلیل توانایی تقریب قدرتمند خود حل کنند. با کمک شبکه‌های عصبی

مصنوعی، هیدرولوژیست‌ها می‌توانند جریان را بدون در نظر گرفتن هیچ فرآیند فیزیکی پیش‌بینی کنند. شبکه عصبی پس انتشار (BPNN) محبوب‌ترین شبکه عصبی است که در مدل‌سازی رواناب باران با موفقیت به کار گرفته شده است (Yang and Chen, 2009).

مرحله اول در ایجاد مدل شبکه عصبی مصنوعی، جمع‌آوری داده‌ها و تعیین پارامترهای ورودی به مدل است. در این مطالعه از رویکرد FFBPNN^{۱۸} که شامل دو مرحله است؛ برای آموزش مدل استفاده شده است. مرحله اول شامل محاسبه وزن ورودی گام به جلو و مرحله دوم محاسبه خطا و به‌روزرسانی وزن‌ها با روش گام به عقب است. در ابتدا داده‌های آموزشی در محدوده (۰-۱) باید نرمال شوند. ۷۰ درصد از داده‌ها برای آموزش مدل استفاده شد، درحالی‌که ۳۰ درصد از داده‌ها برای آزمون به صورت تصادفی در هر تکرار در نظر گرفته می‌شوند (Shahin et al., 2004; Roy and Singh, 2020). همچنین، مدل بر اساس رابطه (۱) مقادیر جدید متغیر را برآورد کرده و تا زمانی که معیار خطا برآورده شود، آموزش داده شد. مراحل کلی ایجاد شبکه FFBPNN در شکل ۲ نمایش داده شده است:

$$x_k = \sum_i^n w_{ki} x_i \quad (1)$$

در رابطه ۱، x_k مقدار جدید متغیر، x_i مقدار اولیه متغیر و w_{ki} مقدار وزن متغیر است. تابع فعال‌سازی بین متغیر ورودی و لایه پنهان، از نوع تابع $tansig$ در نظر گرفته شد، همانطور که در رابطه (۲) نشان داده شده است:

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{2x}} \quad (2)$$

تابع خطی $purelin$ نیز بین لایه پنهان و لایه خروجی استفاده شد که در رابطه (۳) نشان داده شده است:

$$f(x) = x \quad (3)$$

به‌منظور توسعه مدل FFBPNN از زبان برنامه‌نویسی MATLAB استفاده شده است. در مرحله آموزش اولیه، مدل مبتنی بر FFBPNN با استفاده از داده‌های مشاهده‌ای، آموزش داده می‌شود. اگر مدل نتواند خطای مقادیر جدید متغیر را به میزان دلخواه برساند، به فرآیند اجازه می‌دهد تا زمانی که به بهترین نتیجه برسد، با استفاده از الگوریتم پس انتشار Levenberg-Marquardt، دوباره منتشر شود (Moayedi et al., 2020). پس از اتمام آموزش مدل، ۱۵ درصد از داده‌ها برای اعتبارسنجی و ۱۵ درصد باقیمانده داده‌ها جهت آزمایش استفاده می‌شود.

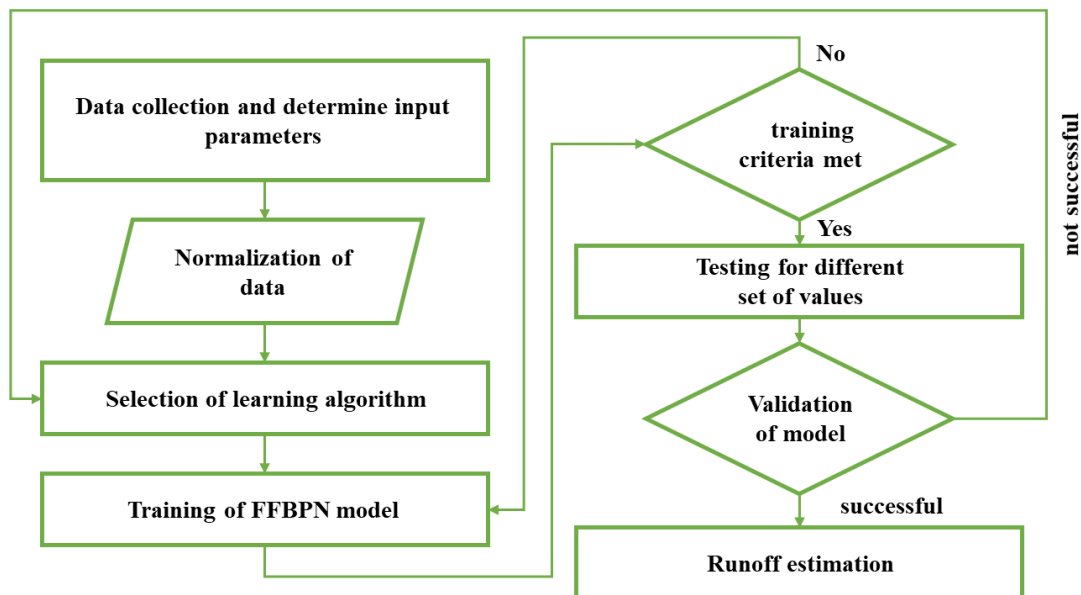


Fig. 2- FFBPN approach flowchart (Shaik et al., 2020)

شکل ۲- فلوچارت رویکرد FFBPN (Shaik et al., 2020)

۲-۳- سیستم استنتاج عصبی فازی تطبیقی (ANFIS)
 اگرچه ANN یک تکنیک قدرتمند برای مدل‌سازی مسائل مختلف دنیای واقعی است، اما کاستی‌هایی نیز دارد. اگر داده‌های ورودی مبهم یا در معرض عدم قطعیت نسبتاً بالایی باشند، سیستم فازی مانند ANFIS ممکن است گزینه بهتری باشد (Moghaddamnia et al., 2009).

همانطور که در شکل ۳ نشان داده شده است شبکه عصبی مورد نظر از سه لایه شامل ورودی، پنهان و خروجی تشکیل شده است. این معماری، شبکه عصبی پرسپترون چندلایه نیز نامیده می‌شود. پرسپترون‌های چندلایه استاندارد قادر به تقریب هر تابع قابل اندازه‌گیری به میزان دقت مطلوب هستند (Taqvi et al., 2020).




Fig. 3- FFBPNN approach architecture (Shaik et al., 2020)

شکل ۳- معماری رویکرد FFBPNN (Shaik et al., 2020)

۲-۴- الگوریتم بهینه‌سازی ازدحام ذرات (PSO)

الگوریتم PSO، یک الگوریتم فراابتکاری مبتنی بر جمعیت است که توسط ابره‌ه‌ارت و کندی در سال ۱۹۹۵ پیشنهاد شد (Eberhart and Kennedy, 1995). ایده PSO از رفتار اجتماعی دسته پرنده‌گان یا ماهی‌ها الهام می‌گیرد. هدف این الگوریتم یافتن یک راه‌حل بهینه (بهترین راه‌حل سراسری) از بین تمام راه‌حل‌های ممکن در یک فضای جستجوی معین است. در ابتدا، ذرات به طور تصادفی در فضای جستجو پخش می‌شوند. در پایان هر تکرار، یک ذره دانش خود را در مورد دو بخش مهم به‌روز می‌کند. ۱- بهترین مقدار تناسب که تاکنون محاسبه کرده است، که به عنوان بهترین محلی (PBest) شناخته می‌شود و ۲- بهترین مقدار تناسب کشف شده در بین ذرات دیگر شناخته شده به عنوان بهترین سراسری (GBest). بر اساس این دو مقدار، سرعتی را که باید با آن حرکت کند، محاسبه می‌کند تا بتواند به بهینه سراسری یا GBest نزدیک‌تر شود. نحوه به‌روزرسانی سرعت و موقعیت این ذرات را می‌توان در روابط (۶) و (۷) مشاهده کرد (Elbedwehy et al., 2012). این فرآیند تا رسیدن به مقدار هدف یا حداکثر تعداد تکرارها، ادامه می‌یابد.

$$V(t+1) = w \times V(t) \times r_1 \times c_1 \times (P_i\text{Best} - P_i(t)) + r_2 \times c_2 \times (G\text{Best} - P_i(t)) \quad (6)$$

$$P_i(t+1) = P_i(t) + V_i(t+1) \quad (7)$$

(Jang 1993) ابتدا روش ANFIS را پیشنهاد کرد و اصول آن را با موفقیت در بسیاری از مسائل به‌کار برد. ANFIS بر اساس سیستم استنتاج فازی Sugeno (Takagi, and Sugeno, 1985) همراه با ساختار شبکه انتقال است. این مدل در ساختار شبکه عصبی قرار می‌گیرد تا انطباق را میسر سازد (Jang and Gulley, 1995).

شکل ۴ یک سیستم ANFIS را با دو ورودی، یک خروجی و دو قانون نشان می‌دهد. این سیستم دارای دو ورودی x و y و یک خروجی است که قوانین آن در روابط (۴) و (۵) نشان داده شده است:

$$\text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f = p_1x + q_1y + r_1 \quad (4)$$

$$\text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f = p_2x + q_2y + r_2 \quad (5)$$

A_i و B_i مجموعه‌های فازی هستند، f_i خروجی در ناحیه فازی است که توسط قانون فازی مشخص شده است، p_i ، q_i و r_i پارامترهای طراحی هستند که در طول فرآیند آموزش تعیین می‌شوند. شکل ۴ نشان می‌دهد که هر گره در این لایه یک مجموعه فازی است و هر خروجی هر گره در این لایه با درجه عضویت متغیر ورودی در این مجموعه فازی مطابقت دارد (Zadeh, 1965). در این مطالعه به‌منظور توسعه سیستم استنتاج فازی از نوع Fuzzy C-Means clustering (FCM) که با genfis3 در محیط نرم‌افزار MATLAB مشخص شده است، استفاده شد.

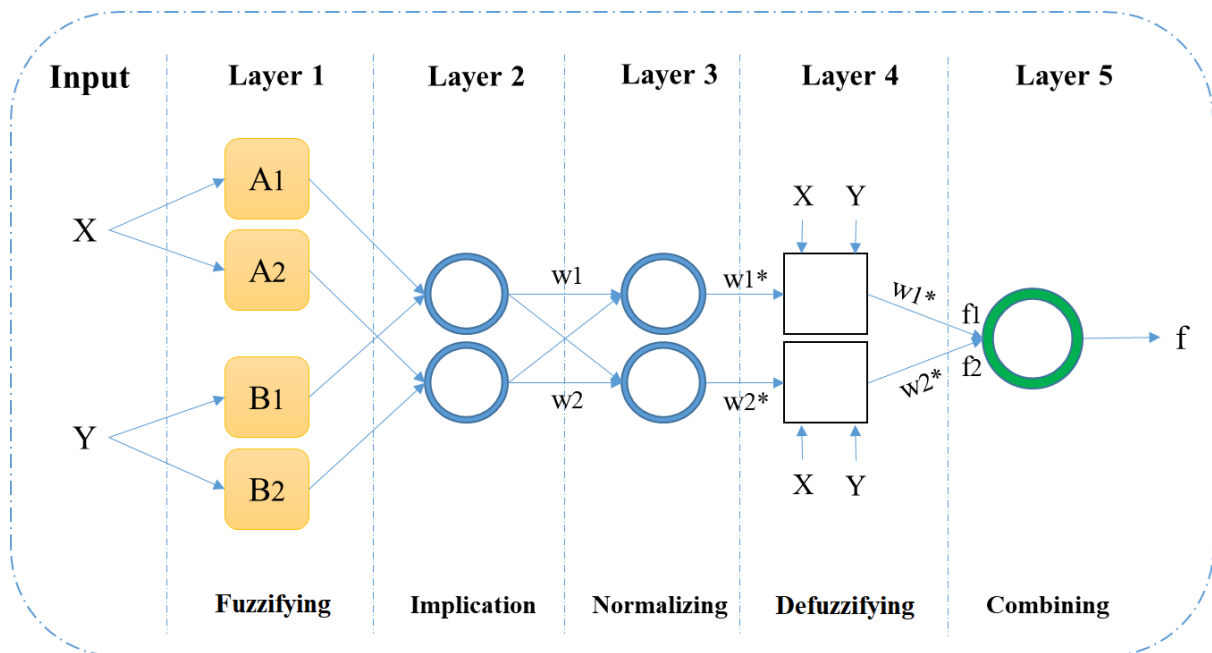


Fig. 4- Structure of an ANFIS system (Ghomsheh et al., 2007)

شکل ۴- ساختار یک سیستم ANFIS (Ghomsheh et al., 2007)

۲-۶- تلفیق سیستم استنتاج عصبی فازی تطبیقی (ANFIS) و الگوریتم‌های بهینه‌سازی PSO و GA

در این تحقیق از دو الگوریتم PSO و GA به منظور بهینه‌سازی ANFIS در پیش‌بینی رواناب استفاده شده است که این مدل‌ها در پلتفرم محاسباتی MATLAB پیاده‌سازی شد. بدین منظور متغیرهای بارش، دمای حداکثر و دمای حداقل به عنوان ورودی مدل‌ها در نظر گرفته شد. با توجه به روش‌های رایج یادگیری در ساختار ANFIS امکان گیر افتادن در نقاط بهینه محلی وجود دارد. لذا تلفیق روش‌های بهینه‌سازی می‌تواند با جستجوی تصادفی این مشکل را رفع کند (Mehri et al, 2020). نحوه‌ی مدل‌سازی تلفیقی ANFIS با الگوریتم‌های بهینه‌سازی PSO و GA در شکل ۵ نشان داده شده است.

۲-۷- مدل‌ها و سناریوهای تغییر اقلیم مورد استفاده

به منظور برآورد مقادیر جریان ورودی به دریاچه طشک- بختگان در دوره آینده به داده‌های بارش و دمای حداقل و حداکثر روزانه نیاز است. مدل‌های IPSL-CMA5-LR و GFDL_ESM2M در مطالعات بسیاری مورد استفاده قرار گرفته است و انطباق مناسبی را با داده‌های مشاهداتی از خود نشان داده‌اند (AghakhaniAfshar et al., 2016; Yang et al., 2018).

در روابط (۶) و (۷)، $V_{i(t)}$ سرعتی است که ذره i با آن حرکت می‌کند. موقعیت $P_{i(t+1)}$ به روز شده ذره بر اساس موقعیت فعلی آن $P_{i(t)}$ و سرعت حرکت $V_{i(t+1)}$ است. P_{iBest} و G_{Best} مقادیر بهینه ملی و سراسری هستند. مقادیر r_1 و r_2 (محدوده بین صفر و یک) مقادیر تصادفی هستند که برای هر به‌روزرسانی سرعت، بازسازی می‌شوند. r_1 و r_2 پارامتر نرخ یادگیری و c_1, c_2, w ضرایب ارائه شده توسط کاربر هستند.

۲-۵- الگوریتم ژنتیک (GA)

ساختار مفهومی الگوریتم ژنتیک (GA) برای اولین بار توسط (Goldberg and Holland., 1988) بر اساس نظریه داروین معرفی شد. GA به عنوان یک روش تصادفی بدون مشتق برای بهینه‌سازی، یکی از شناخته‌شده‌ترین، قدیمی‌ترین و پرکاربردترین الگوریتم‌های تکاملی در حل بسیاری از مسائل مهندسی است که می‌توان از آن برای حل مسائل غیرخطی، تصادفی و غیر قابل تمایز استفاده کرد که ممکن است با استفاده از روش‌های مبتنی بر گرادیان غیرممکن به نظر برسند (Mirjalili, 2019). مراحل اساسی GA شامل سه جزء مهم شامل انتخاب، ازدواج و جهش است (Yaseen et al., 2019).

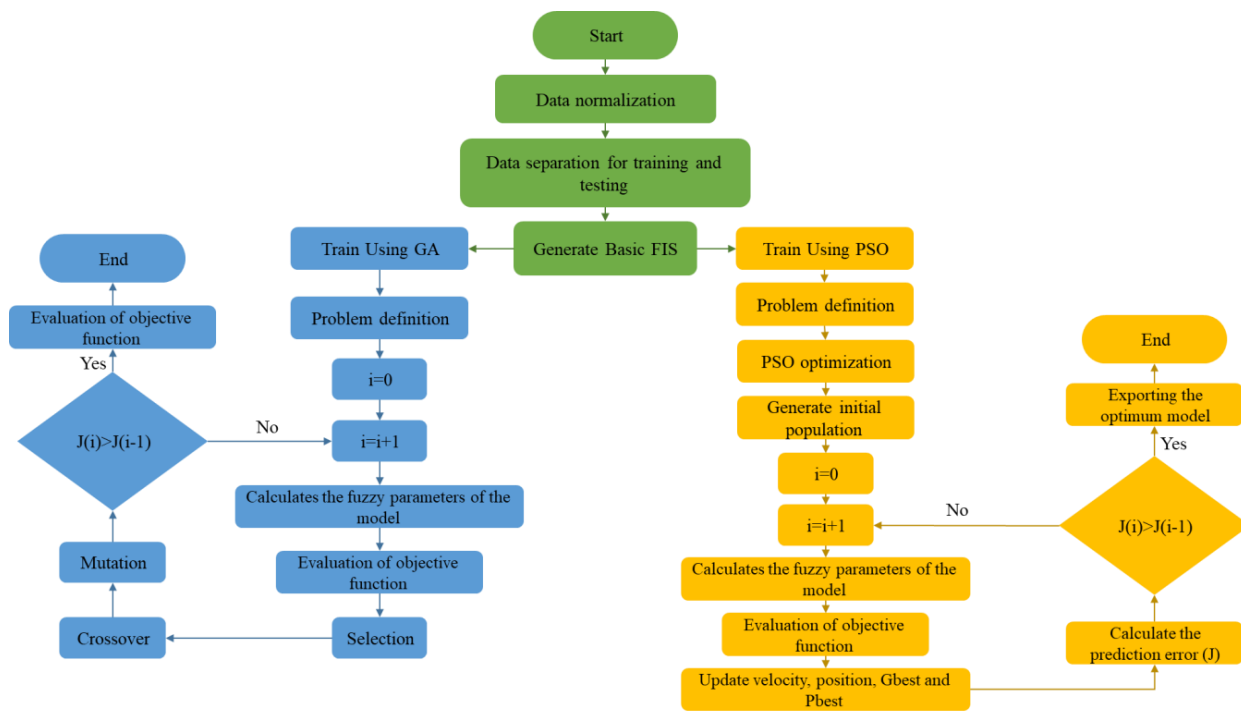


Fig. 5- Flowchart of ANFIS-PSO and ANFIS-GA (Mehri et al, 2020)

شکل ۵- فلوچارت ANFIS-PSO و ANFIS-GA (Mehri et al, 2020)

از مدل‌های شبکه عصبی مصنوعی، سیستم استنتاج عصبی فازی و تلفیق آن با الگوریتم‌های PSO و GA مورد بررسی قرار گرفته است.

۳- نتایج و بحث

۳-۱- ارزیابی مدل شبکه عصبی مصنوعی

در این تحقیق، شبکه عصبی مصنوعی FFBPNN برای پیش‌بینی جریان ورودی به دریاچه طشک- بختگان توسعه یافته است. متغیرهای اقلیمی بارش، دمای حداقل و دمای حداکثر به عنوان ورودی برای توسعه مدل در نظر گرفته شده‌اند. به همین منظور مدل‌های مختلفی متشکل از متغیرهای اقلیمی به صورت منفرد و ترکیبی مورد استفاده قرار گرفت (جدول ۱). مدل توسعه یافته بر اساس الگوریتم پس انتشار Levenberg-Marquardt آموزش داده شد. همچنین به منظور توسعه مدل، با استفاده از روش سعی و خطا از ۵ لایه پنهان با تعداد ۱۰ نرون استفاده شد. سپس مدل ساخته شده با ارائه تمام مجموعه‌های داده مورد آزمون قرار گرفته است.

در این تحقیق به منظور توسعه مدل شبکه عصبی حالت‌های مختلف معرفی ورودی به مدل مورد ارزیابی قرار گرفت. نتایج ارزیابی مدل‌های شبکه عصبی مصنوعی توسعه داده شده براساس ورودی‌های مختلف در جدول ۱ نشان داده شده است. با توجه به نتایج به دست آمده می‌توان دریافت بیشترین تأثیر در برآورد رواناب به وسیله‌ی مدل FFBPNN را متغیر بارش داشته است و دمای حداقل و دمای حداکثر به تنهایی قادر به پیش‌بینی رواناب با دقت مناسب نیستند. درحالی‌که بهترین حالت ورودی‌های مدل معرفی هر سه متغیر بارش، دمای حداقل و دمای حداکثر است که خطای ۲۴ درصد نسبت به میانگین بلندمدت نشان می‌دهد. همچنین، بررسی سایر شاخص‌های ارزیابی در دوره‌های آموزش و آزمون نیز نشان داد که استفاده از متغیرهای دمای حداقل، دمای حداکثر و بارش عملکرد مدل شبکه عصبی را بهبود بخشیده است. در مطالعه‌ای در حوضه آبریز طشک- بختگان، شبیه‌سازی رواناب با استفاده از مدل SWAT انجام شد. نتایج حاصل از این مطالعه حاکی از خطای کمتر و همبستگی کمتر (ضعیف‌تر) در شبیه‌سازی رواناب نسبت به مطالعه حاضر است (Fallah Kalaki et al., 2021). نتایج مربوط به مدل بهینه FFBPNN در شکل ۶ نمایش داده شده است. لذا این مدل توسعه داده شده به منظور برآورد رواناب در دوره تغییر اقلیم به کار گرفته می‌شود.

از این رو، خروجی مدل‌های IPSL-CMA5- و GFDL-ESM2M تحت سناریوهای LR و RCP2.6 و RCP8.5 و مدل‌های GFDL-ESM4 و IPSL-CMA6-LR تحت سناریوهای SSP1-2.6 و SSP5-8.5 از پروژه ISI-MIP Fast Track با قدرت تفکیک مکانی $0.5^\circ \times 0.5^\circ$ برای محدوده حوضه طشک- بختگان در دوره (۲۰۵۰-۲۰۲۱) از درگاه ESGF¹⁹ به نشانی <https://esg.pik-potsdam.de/search/isimip> دریافت شد (Hempel et al., 2013). پروژه ISI-MIP²⁰ با استفاده از متغیرهای اقلیمی پایگاه WATCH Forcing Data با قدرت تفکیک مکانی ۰/۵ درجه و دوره ۴۰ ساله ۱۹۶۰-۱۹۹۹ اصلاح اریبی (حذف انحرافات سیستماتیک بین مقادیر مشاهداتی و خروجی مدل‌های GCM) را با استفاده از روش عامل تغییر انجام داده است (Hempel et al., 2013).

۲-۸- معیار ارزیابی نتایج

به منظور ارزیابی عملکرد مدل‌ها از شاخص ریشه مقادیر میانگین مربعات خطا (Hyndman and Koehler, 2006) و ضریب همبستگی پیرسون (Pearson, 1897)، نش-ساتکلیف (Nash and Sutcliffe, 1970) و کلینگ گوپتا (Gupta et al., 2009) استفاده شده است که با استفاده از روابط (۸) و (۹) محاسبه شده است (Sarbayev et al., 2019):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_O - Q_P)^2} \quad (۸)$$

$$r = \left(\frac{\sum_{i=1}^n (Q_P - \bar{Q}_P)(Q_O - \bar{Q}_O)}{\sqrt{\sum_{i=1}^n (Q_P - \bar{Q}_P)^2 \times \sum_{i=1}^n (Q_O - \bar{Q}_O)^2}} \right) \quad (۹)$$

$$NSH = 1 - \frac{\sum_{i=1}^n (Q_O - Q_P)^2}{\sum_{i=1}^n (Q_O - \bar{Q}_O)^2} \quad (۱۰)$$

$$KGE = 1 - \sqrt{(\beta - 1)^2 + (\alpha - 1)^2 + (r - 1)^2} \quad (۱۱)$$

$$\beta = \frac{\bar{Q}_P}{\bar{Q}_O} \quad (۱۲)$$

$$\alpha = \frac{\sigma_{QP}}{\sigma_{QO}} \quad (۱۳)$$

در روابط (۸) تا (۱۳): Q_O مقادیر جریان مشاهداتی، Q_P مقادیر جریان پیش‌بینی شده، \bar{Q}_O میانگین جریان مشاهداتی، \bar{Q}_P میانگین جریان پیش‌بینی شده، σ_{QO} انحراف معیار جریان مشاهداتی و σ_{QP} انحراف معیار جریان پیش‌بینی شده است.

در مطالعه حاضر، اثرات تغییر اقلیم تحت سناریوهای گزارش‌های پنجم و ششم تغییر اقلیم بر تغییرات رواناب در شرایط تغییر اقلیم با استفاده

Table 1- Evaluation of the results for the FFBPNN Model

جدول ۱- ارزیابی نتایج مدل شبکه‌ی عصبی مصنوعی FFBPNN

Model Number	Model Input	Runoff average (MCM)	Train				Test			
			RMSE (m ³ /s)	r	NSH	KGE	RMSE (m ³ /s)	r	NSH	KGE
1	Pt	8.70	5.07	0.95	0.93	0.93	3.89	0.93	0.90	0.87
2	Tmint		12.20	0.68	0.59	0.47	8.65	0.58	0.37	0.42
3	Tmaxt		11.90	0.69	0.61	0.53	8.27	0.59	0.35	0.43
4	Pt, Tmint		4.23	0.97	0.95	0.95	4.02	0.93	0.88	0.86
5	Pt, Tmaxt		5.03	0.95	0.93	0.93	4.21	0.93	0.89	0.86
6	Tmint, Tmaxt		9.96	0.80	0.72	0.71	8.77	0.62	0.47	0.55
7	Pt, Tmint, Tmaxt		2.07	0.99	0.94	0.91	0.88	0.93	0.91	0.89

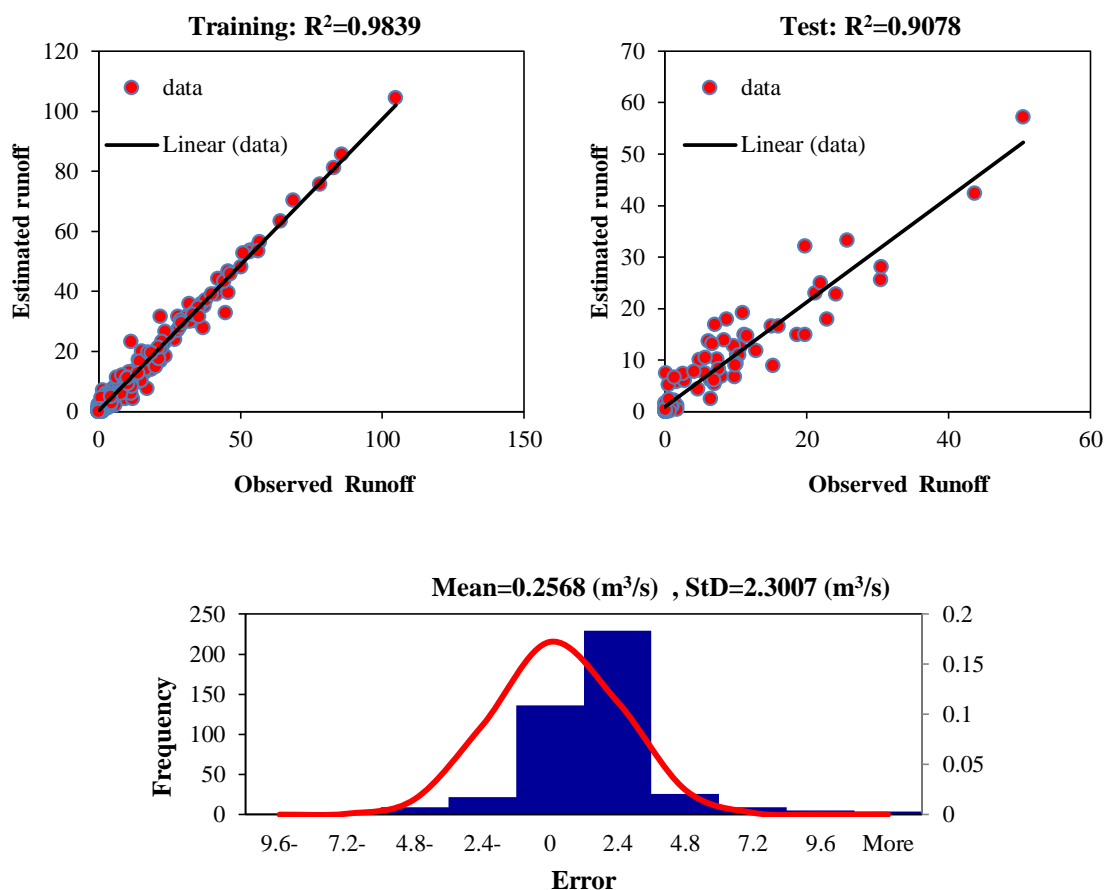


Fig. 6- Evaluation of the optimal FFBPNN model

شکل ۶- نتایج ارزیابی مدل FFBPNN بهینه

ANFIS توسعه داده شده با ورودی‌های مختلف با استفاده از تلفیق آن با الگوریتم‌های بهینه‌سازی PSO و GA مورد بررسی قرار گرفته است. نتایج ارزیابی دقت مدل‌های ANFIS، ANFIS_PSO و ANFIS_GA در برآورد مقادیر جریان رودخانه در جدول ۲ نشان داده شده است. بر این اساس، همانند مدل FFBPNN نتایج مدل‌هایی که در آن متغیر بارش به عنوان ورودی به کار گرفته شده است؛ از دقت

۳-۲- ارزیابی سیستم استنتاج عصبی فازی تطبیقی (ANFIS) و تلفیق آن با الگوریتم‌های بهینه‌سازی PSO و GA به منظور توسعه سیستم استنتاج عصبی فازی تطبیقی در مطالعه حاضر از سیستم استنتاج فازی پایه نوع Sugeno با تابع عضویت گوسی (gaussmf) استفاده شده است. همچنین، امکان بهبود نتایج مدل‌های

۳-۳- بررسی تغییرات بارش و دمای حوضه در شرایط تغییر اقلیم

تغییرات میانگین بلندمدت متغیرهای اقلیمی (دمای حداقل، دمای حداکثر و بارش) مدل‌های GCM مورد استفاده در این مطالعه تحت سناریوهای RCP و SSP در جدول ۳ نشان داده شده است. نتایج بدست‌آمده برای تمامی ۴ مدل GCM مورد بررسی، افزایش دمای حداقل و حداکثر را در دوره آینده نسبت به دوره‌ی نشان می‌دهد. با توجه به نتایج برای سناریوهای SSP دمای حداکثر و برای سناریوهای RCP دمای حداقل افزایش بیشتری داشته است. بررسی بارش حوضه طشک- بختگان در شرایط تغییر اقلیم، نشان داد که مدل GFDL-ESM2M تحت سناریوی RCP2.6، کاهش ۰/۱۳ درصدی و تحت سناریوی RCP8.5، کاهش ۰/۰۵ درصدی بارش را در دوره آینده نسبت به دوره گذشته نشان می‌دهد. مدل IPSL-CMA5-LR نیز تحت هر دو سناریوی RCP2.6 و RCP8.5 (۹/۸۲- و ۵/۶۶- درصد) کاهش بارش را نشان می‌دهد. نتایج به دست آمده برای مدل‌های GFDL-ESM4 و IPSL-CMA5-LR تحت هر ۲ سناریوی SSP مورد بررسی کاهش بارش را در دوره آینده نشان می‌دهد به‌صورتی که این کاهش بارش بیشتر از سناریوهای RCP بوده است.

بالتری برخوردار است. لذا می‌توان دریافت که تغییرات مقادیر رواناب ارتباط بیشتری را با تغییرات در مقادیر بارش دارند. همانطور که در جدول ۲ مشخص است؛ الگوریتم بهینه‌سازی PSO در بهبود نتایج مدل‌های ANFIS عملکرد بهتری را از خود نشان داده است.

در بین ۷ مدل مورد بررسی که از ورودی‌های مختلفی در آن استفاده شده است، مدل ANFIS شماره ۷ با متغیرهای ورودی بارش، دمای حداقل و دمای حداکثر و تلفیق آن با الگوریتم PSO با مقادیر خطای RMSE ۲/۹۴ و ۳/۸۷ مترمکعب بر ثانیه برای دوره‌های آموزش و آزمون، ضریب همبستگی ۰/۹۸ و ۰/۹۳ برای دوره‌های آموزش و آزمون، ضریب نش- ساتکلیف ۰/۹۸ و ۰/۸۵ برای دوره‌های آموزش و آزمون و مقادیر شاخص KGE ۰/۹۸ و ۰/۸۸ برای دوره‌های آموزش و آزمون بهترین عملکرد را داشته است و به همین خاطر از این مدل به‌منظور برآورد جریان رودخانه در دوره تغییر اقلیم استفاده خواهد شد. در مطالعه‌ای که در حوضه آبخیز آجی چای انجام شد؛ همچون مطالعه حاضر، مدل‌های داده‌محور با استفاده از متغیرهای دمای حداقل، دمای حداکثر و بارش بهترین عملکرد را در شبیه‌سازی رواناب دارند (Kazemzadeh et al., 2019). نتایج مربوط به مدل بهینه ANFIS در شکل ۷ نمایش داده شده است.

Table 2- Evaluation of the results of ANFIS, ANFIS_PSO, and ANFIS_GA Model
جدول ۲- ارزیابی نتایج مدل ANFIS، ANFIS_PSO و ANFIS_GA

Model Number	Model Type	Model Input	Train				Test			
			RMSE (m ³ /s)	r	NSH	KGE	RMSE (m ³ /s)	r	NSH	KGE
1	ANFIS	Pt	3.81	0.97	0.95	0.96	3.93	0.93	0.85	0.89
	ANFIS-PSO		3.65	0.98	0.95	0.96	3.91	0.92	0.85	0.89
	ANFIS-GA		4.13	0.97	0.94	0.96	3.94	0.93	0.86	0.91
2	ANFIS	Tmint	12.44	0.65	0.42	0.50	9.87	0.56	0.03	0.35
	ANFIS-PSO		11.49	0.71	0.54	0.59	9.52	0.57	0.10	0.42
	ANFIS-GA		12.15	0.67	0.45	0.52	10.75	0.56	0.05	0.29
3	ANFIS	Tmaxt	11.85	0.69	0.48	0.56	9.88	0.56	0.03	0.44
	ANFIS-PSO		10.87	0.75	0.59	0.64	9.21	0.59	0.15	0.48
	ANFIS-GA		11.16	0.73	0.54	0.61	9.45	0.58	0.11	0.43
4	ANFIS	Pt, Tmint	3.03	0.98	0.97	0.97	4.01	0.92	0.84	0.90
	ANFIS-PSO		2.94	0.98	0.97	0.98	4.16	0.92	0.83	0.83
	ANFIS-GA		3.98	0.97	0.94	0.96	3.97	0.94	0.87	0.90
5	ANFIS	Pt, Tmaxt	3.36	0.98	0.96	0.97	4.66	0.90	0.80	0.85
	ANFIS-PSO		3.13	0.98	0.96	0.97	4.21	0.95	0.88	0.86
	ANFIS-GA		4.29	0.97	0.93	0.94	3.90	0.92	0.86	0.86
6	ANFIS	Tmint, Tmaxt	10.51	0.77	0.59	0.67	9.49	0.56	0.13	0.51
	ANFIS-PSO		9.95	0.79	0.63	0.71	9.39	0.57	0.14	0.55
	ANFIS-GA		11.23	0.74	0.54	0.61	9.47	0.59	0.13	0.45
7	ANFIS	Pt, Tmint, Tmaxt	2.95	0.98	0.97	0.98	4.38	0.91	0.82	0.86
	ANFIS-PSO		2.94	0.98	0.97	0.98	3.87	0.93	0.85	0.88
	ANFIS-GA		4.21	0.97	0.94	0.94	3.96	0.91	0.80	0.84

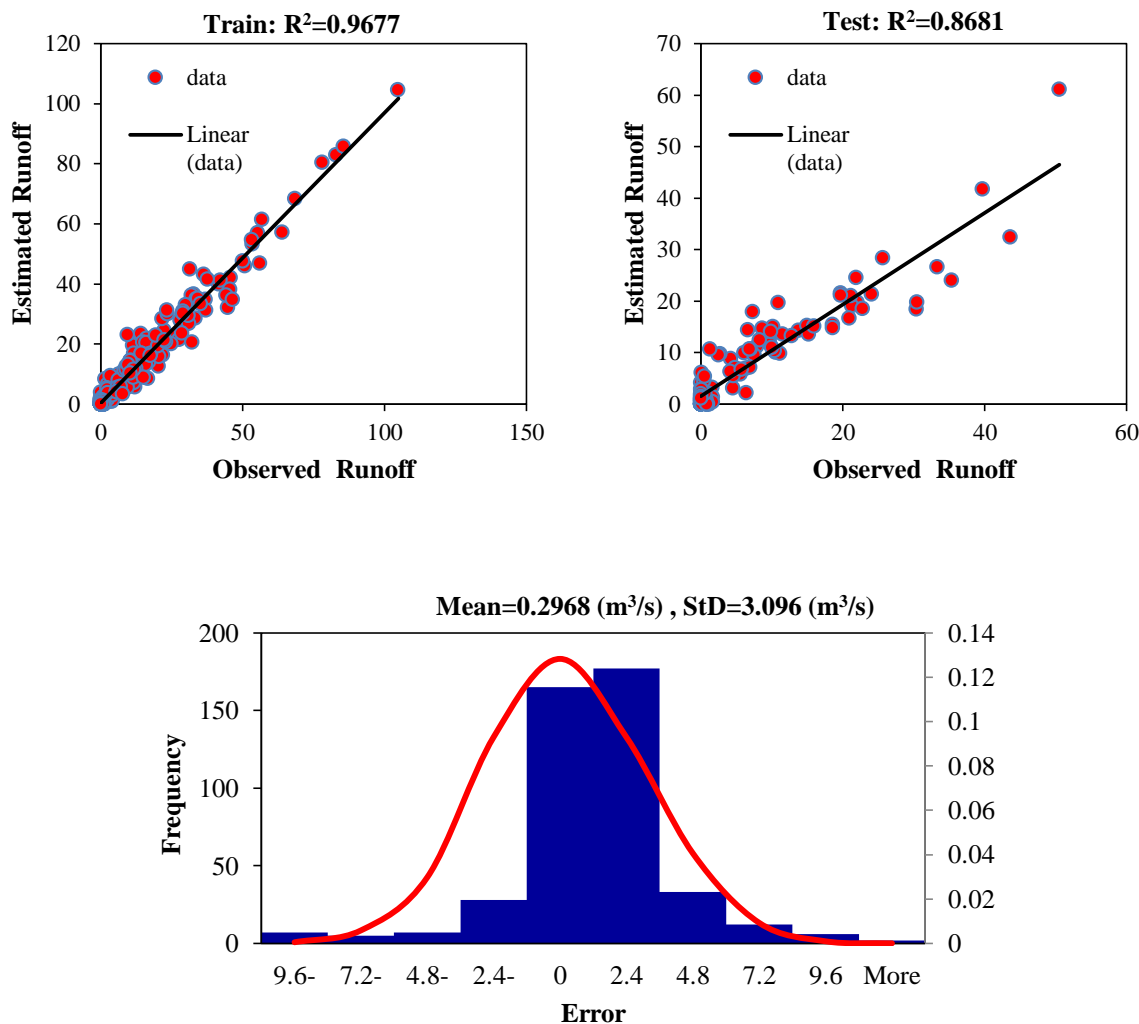


Fig. 7- Evaluation of the optimal ANFIS model
 شکل ۷- نتایج ارزیابی مدل ANFIS بهینه

Table 3- Changes in the long-term average of climatic variables of GCM models used under RCP and SSP scenarios in the future period compared to the previous period
 جدول ۳- تغییرات میانگین بلندمدت متغیرهای اقلیمی مدل‌های GCM مورد استفاده تحت سناریوهای RCP و SSP در دوره آینده نسبت به دوره گذشته

Climate Variable	GFDL-ESM2M		IPSL-CMA5-LR		GFDL-ESM4		IPSL-CMA6-LR	
	RCP2.6	RCP8.5	RCP2.6	RCP8.5	SSP1-2.6	SSP5-8.5	SSP1-2.6	SSP5-8.5
Minimum Temperature (°C)	2.12	2.58	2.59	2.91	1.62	2.03	2.19	2.52
Maximum Temperature (°C)	1.51	2.38	2.11	2.73	1.94	2.63	2.40	2.72
Precipitation (%)	-0.13	-0.05	-5.82	-7.66	-10.76	-11.15	-8.31	-9.62

۴-۳- بررسی تغییرات رواناب در شرایط تغییر اقلیم

سناریوهای خوش‌بینانه (RCP2.6, SSP1-2.6) و بدبینانه (RCP8.5, SSP5-8.5) مقادیر متوسط رواناب ماهانه و درصد تغییرات آن در دوره آینده (۲۰۲۱-۲۰۵۰) نسبت به دوره گذشته در شکل ۸ ارائه شده است.

پس از شبیه‌سازی جریان ورودی به دریاچه طشک- بختگان در مدل‌های بهینه FFBPNN و ANFIS_PSO با استفاده از داده‌های بارش، دمای حداقل و دمای حداکثر دوره‌ی آینده (۲۰۲۱-۲۰۵۰) تحت

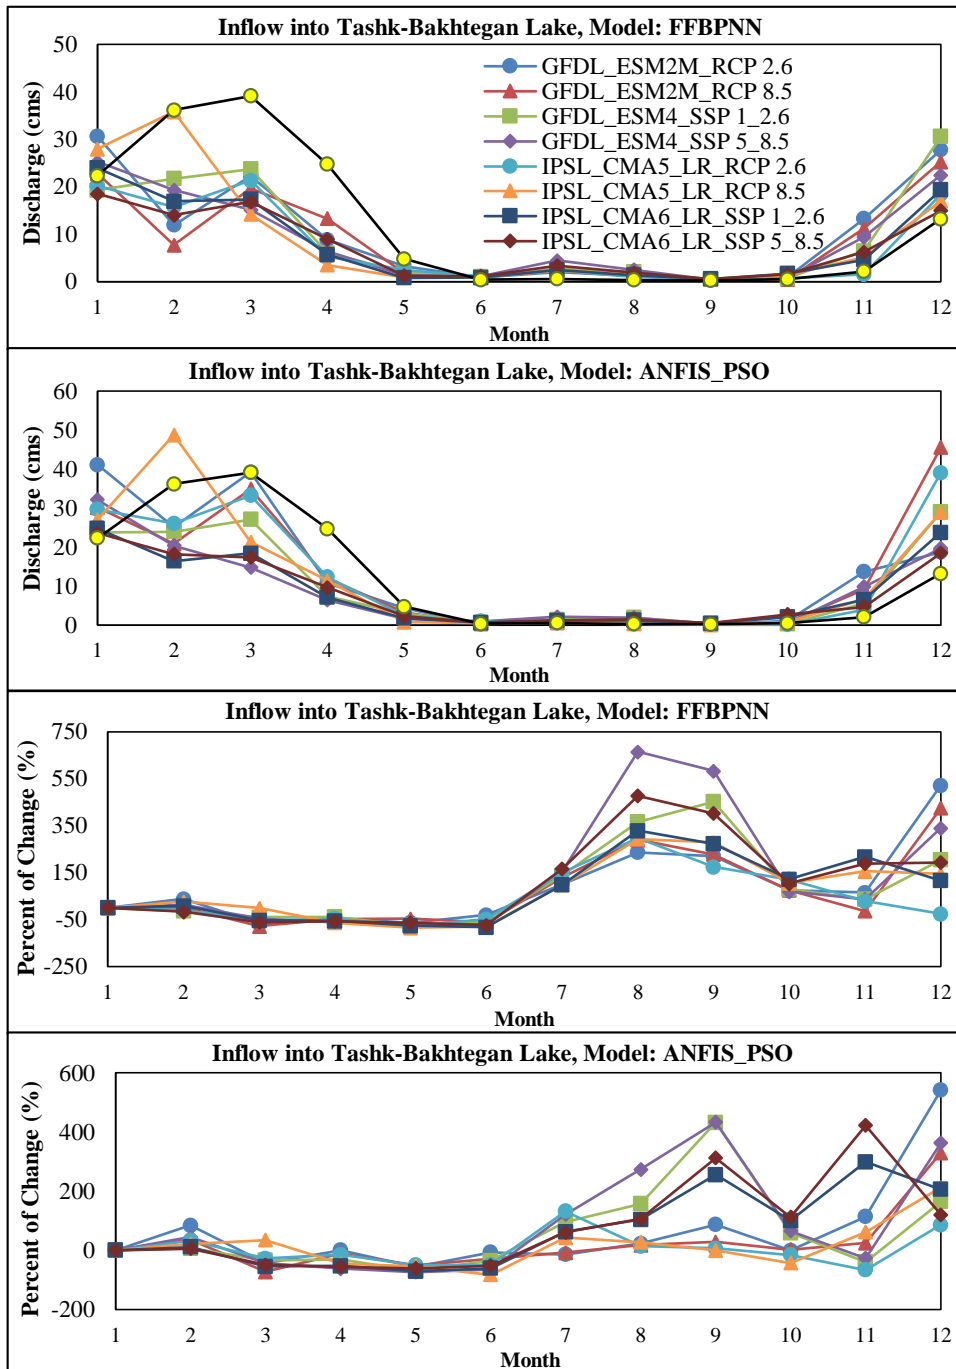


Fig. 8- Monthly Mean Discharge status in the under climate change for GCM models and scenarios under consideration

شکل ۸- وضعیت میانگین رواناب ماهانه بلندمدت در شرایط تغییر اقلیم برای مدل‌های GCM و سناریوهای مورد بررسی

است، بر خلاف مطالعه حاضر میزان تغییرات دبی در دوره (۲۰۵۰-۲۰۲۱) در ماه‌های پر بارش افزایش و در دوره‌های کم بارش کاهش یافته است (Mansouri et al., 2018).

۴- جمع‌بندی و نتیجه‌گیری

پیش‌بینی مؤلفه‌های منابع آبی در دوره‌های آینده به‌ویژه در شرایط تغییر اقلیم به‌منظور سیاست‌گذاری، برنامه‌ریزی و مدیریت منابع آب، امری ضروری است. همچنین، پیش‌بینی و برآورد جریان رودخانه برای هر منطقه به عنوان یکی از مهمترین پارامترها در استفاده بهینه از منابع آب محسوب می‌شود. در همین راستا، سیستم‌های هوشمند به دلیل استفاده از الگوریتم‌های خاص و پیچیده، قابلیت مناسبی برای پیش‌بینی پدیده‌های پیچیده و غیرخطی مانند رواناب را از خود نشان می‌دهند. لذا در این مطالعه، دقت مدل‌های شبکه عصبی مصنوعی از نوع FFBPNN، سیستم استنتاج عصبی فازی تطبیقی (ANFIS) و تلفیق آن با الگوریتم‌های بهینه‌سازی فراابتکاری PSO و GA با استفاده از متغیرهای اقلیمی بارش، دمای حداقل و دمای حداکثر به عنوان ورودی مورد بررسی قرار گرفته است. پس از انتخاب مدل‌های بهینه FFBPNN و ANFIS، اثرات تغییرات اقلیمی در حوضه طشک- بختگان در دوره آینده (۲۰۵۰-۲۰۲۱) با استفاده از مدل‌های منتخب بر رواناب مورد بررسی قرار گرفت. ارزیابی صورت‌گرفته برای مدل‌های GFDL_ESM2M و IPSL_CMA5_LR تحت سناریوهای RCP2.6 و RCP8.5 و مدل‌های GFDL_ESM4 و IPSL_CMA6_LR تحت سناریوهای SSP1-2.6 و SSP5-8.5 انجام شده است. نتایج حاصل از این مطالعه به شرح زیر قابل جمع‌بندی است:

- نتایج ارزیابی مدل‌های FFBPNN توسعه داده شده با استفاده از ترکیب ورودی‌های مختلف نشان داد که مدل‌هایی که در آن از متغیر بارش به عنوان ورودی استفاده شده است، از دقت بالاتری در برآورد رواناب برخوردار است. همچنین ارزیابی‌ها نشان داد که مدل شبکه عصبی FFBPNN با استفاده از سه متغیر اقلیمی بارش، دمای حداقل و دمای حداکثر بهترین عملکرد را داشته است و به عنوان مدل بهینه به‌منظور برآورد رواناب در دوره آینده در شرایط تغییر اقلیم، مورد استفاده قرار گرفت. همچنین، در نظر گرفتن متغیرهای بارش و دما با تأخیرهای مختلف و همچنین متغیرهای دیگری همچون تبخیر-تعرق و رطوبت می‌تواند در بهبود عملکرد شبیه‌سازی رواناب مؤثر باشد.

- نتایج حاصل از ارزیابی مدل‌های ANFIS نیز حاکی از تأثیرگذاری مثبت بارش در برآورد با دقت بالای رواناب است. بطوری‌که همانند مدل FFBPNN مدل ANFIS با ورودی‌های بارش، دمای حداقل و

همانطور که در شکل ۸ نشان داده شده است، مدل‌های FFBPNN و ANFIS_PSO در دوره آینده در شرایط تغییر اقلیم برای اغلب سناریوها در ۵ ماه اولیه سال کاهش رواناب و در ماه‌های بعدی افزایش رواناب را نشان می‌دهد. همچنین، بررسی نتایج نشان می‌دهد که غالباً سناریوهای RCP و مدل GFDL نسبت به سناریوهای SSP و مدل IPSL برآورد بیشتری از رواناب را دارا هستند. در مدل ANFIS_PSO بالاترین نرخ افزایش رواناب ۵۴۱ درصد در ماه نوامبر توسط مدل GFDL_ESM2M_RCP2.6 و بالاترین نرخ کاهش رواناب در ماه می توسط مدل IPSL_CMA5_LR_RCP8.5 برآورد شده است. همچنین، بالاترین نرخ افزایش و کاهش رواناب در مدل FFBPNN به ترتیب ۶۶۴ و ۸۵ درصد است که توسط مدل‌های IPSL_CMA5_LR_RCP8.5 و GFDL_ESM4_SSP5_8.5 در ماه‌های جولای و آوریل برآورد شده است. نتایج حاصل شده نشان می‌دهد که مدل‌های مختلف GCM مورد بررسی، روند یکسانی را در افزایش یا کاهش رواناب در دوره آینده نسبت به دوره گذشته نشان می‌دهد. بطوری‌که در ماه‌های ژانویه تا می (بهمین تا اردیبهشت) رواناب کاهش، در ماه‌های ژوئن تا اکتبر (خرداد تا آبان) رواناب از نظر عددی تغییر چندانی نداشته است (با توجه به میزان کم رواناب در این ماه‌ها، افزایش رواناب از نظر درصد بالا است). در صورتی که در ماه‌های نوامبر و دسامبر (آذر و دی) افزایش رواناب مشاهده می‌شود. همچنین، بر اساس نتایج به‌دست‌آمده مدل‌های GFDL مقادیر رواناب بیشتری را برآورد کرده‌اند.

در مطالعه‌ای روی حوضه آبریز طشک- بختگان، برآورد رواناب حوضه در شرایط تغییر اقلیم تحت سناریوهای RCP و SSP توسط مدل هیدرولوژیکی SWAT انجام شده است. نتایج حاصل از این مطالعه افزایش رواناب تحت سناریوهای RCP و کاهش رواناب را تحت سناریوهای SSP نشان می‌دهد (Fallah Kalaki et al., 2021). درحالی‌که در مطالعه حاضر رفتار افزایش یا کاهش رواناب تحت سناریوهای مختلف یکسان بوده است. در مطالعه (Fallah Kalaki et al., 2021) شبیه‌سازی رواناب در ۴ ایستگاه (ورودی به سدهای ملاصدرا، درودزن و سیوند و ورودی به دریاچه طشک بختگان) انجام شده است. همچنین، با توجه به اینکه شبیه‌سازی رواناب توسط مدل SWAT انجام شده است؛ شبیه‌سازی هر ایستگاه متأثر از شبیه‌سازی ایستگاه‌های بالادست و دقت آن‌ها است. در حالی که در مطالعه حاضر شبیه‌سازی رواناب صرفاً در محل ورودی به دریاچه طشک- بختگان انجام شده است. لذا تفاوت نتایج دو مطالعه می‌تواند به همین دلیل باشد. با توجه به اینکه در مطالعه دیگری که بر روی جریان ورودی به مخزن کارون ۴ با استفاده از مدل شبکه عصبی MLP انجام شده

انتخاب مدل‌های بهینه هر کدام، برآورد رواناب در شرایط تغییر اقلیم تحت سناریوهای RCP و SSP انجام شده و مورد مقایسه قرار گیرند. بر اساس نتایج به دست آمده در این تحقیق، تغییرات مقادیر رواناب در شرایط تغییر اقلیم و امکان ایجاد وقایع حدی همچون خشکسالی در حوضه آبریز و خشک و کم آب شدن دریاچه‌های طشک-بختگان و همچنین در مقاطعی سیل، لازم است برنامه‌ریزی و استراتژی مدیریتی مناسبی برای سازگاری و مقابله با تغییر اقلیم در نظر گرفته شود. لذا نتایج حاصل از این پژوهش می‌تواند در برنامه‌ریزی و مدیریت منابع آب و همچنین اتخاذ راهکارهای سازگار در راستای فعالیت‌های اجتماعی-اقتصادی مؤثر باشد. به‌منظور ارزیابی و بررسی دقیق‌تر اثرات تغییر اقلیم با استفاده از مدل‌های داده‌محور تحت سناریوهای SSP که اخیراً در دسترس قرار گرفته است، می‌بایست سایر متغیرهای تأثیرگذار بر رواناب نیز به عنوان ورودی استفاده و مورد بررسی قرار گیرد. همچنین، بررسی سایر مدل‌های GCM و سناریوهای RCP و SSP می‌تواند در تحلیل بهتر نتایج مفید باشد. همچنین، استفاده از مدل‌های هیدرولوژیکی به‌منظور شبیه‌سازی رواناب و سایر مؤلفه‌های هیدرولوژیکی و مقایسه آن‌ها با مدل‌های داده‌محور می‌تواند در انتخاب روش مناسب برای بررسی اثرات تغییر اقلیم مفید باشد.

پی‌نوشت‌ها

- 1- Artificial Neural Networks (ANN)
- 2- Fuzzy Inference System (FIS)
- 3- Adaptive Neuro-Fuzzy Inference System (ANFIS)
- 4- Water Balance Model (Watbal)
- 5- Sacramento Soil Moisture Accounting Model (SAC-SMA)
- 6- Simple Conceptual Rainfall-Runoff (SCRR)
- 7- AutoRegressive Moving Average (ARMA)
- 8- Multiple Linear Regression (MLR)
- 9- Multiple Non-Linear Regression (MNL)
- 10- Particle Swarm Optimization (PSO)
- 11- Genetic Algorithm (GA)
- 12- AutoRegressive Integrated Moving Average (ARIMA)
- 13- General Circulation Model (GCM)
- 14- Representative Concentration Pathway (RCP)
- 15- Shared Socioeconomic Pathway (SSP)
- 16- Soil and Water Assessment Tool (SWAT)
- 17- Back Propagation Neural Network (BPNN)
- 18- Feedforward Back Propagation Neural Network (FFBPNN)
- 19- Earth System Grid Federation (ESGF)
- 20- Inter-Sectoral Impact Model Intercomparison Project (ISIMIP) Fast Track

دمای حداکثر بهترین عملکرد را داشته است. همچنین، مقایسه مدل‌های FFBPNN و ANFIS نشان می‌دهد که توانایی مدل FFBPNN در برآورد رواناب اندکی بیشتر است. در مطالعه‌ای که در حوضه تریواندروم در هند انجام شده است عملکرد سه مدل NMR، FFBPNN و ANFIS مورد بررسی قرار گرفت، برخلاف مطالعه حاضر مدل ANFIS عملکرد بهتری را داشته است (Jimmy et al, 2021). لذا امکان بهبود مدل ANFIS با استفاده از الگوریتم‌های بهینه‌سازی PSO و GA مورد بررسی قرار گرفت.

- بررسی نتایج حاصل از تلفیق مدل ANFIS با الگوریتم‌های PSO و GA نشان می‌دهد که الگوریتم PSO در بهبود نتایج حاصل از مدل ANFIS موفق‌تر بوده است. بطوری‌که بهترین عملکرد در بین مدل‌های مختلف با استفاده از ورودی‌های مختلف را مدل تلفیقی ANIS_PSO با استفاده از متغیرهای بارش، دمای حداقل و دمای حداکثر را دارد. در مطالعه‌ای در حوضه آبریز هلیل رود-سدجیرفت انجام شده است، عملکرد مدل‌های که LS-SVM، NN، GEP و ANFIS_SO در برآورد رواناب مورد بررسی قرار گرفته است. نتایج حاصل شده نشان می‌دهد که مدل ANFIS_PSO بهترین عملکرد را داشته است (Kavoosi and Khozaymehnehad, 2021). لذا مدل ANFIS_PSO نیز برای برآورد رواناب در دوره آینده در شرایط تغییر اقلیم به‌کار گرفته شد.

- برآورد رواناب توسط مدل‌های FFBPNN و ANFIS_PSO با استفاده از داده‌های اقلیمی (بارش و دمای حداقل و حداکثر) مدل‌های GCM تحت سناریوهای پروژه‌های CMIP5 و CMIP6، انجام شد. نتایج حاصل شده نشان می‌دهد که مدل‌های مختلف GCM مورد بررسی، روند یکسانی را در افزایش یا کاهش رواناب در دوره آینده نسبت به دوره گذشته نشان می‌دهد. بطوری‌که مقادیر رواناب در ماه‌های پر بارش تغییرات با نسبت کمتری را نسبت به ماه‌های کم بارش دارد که به دلیل مقادیر کم رواناب در این ماه‌ها است. همچنین، عمدتاً رواناب در ماه‌های پر بارش (فصول زمستان و بهار) کاهش و در ماه‌های کم بارش افزایش یافته است.

در زمینه پیش‌بینی و برآورد رواناب، مطالعات متعدد و مختلفی با استفاده از انواع مدل‌های مفهومی و داده‌محور انجام شده است. همچنین، مطالعات بسیاری در زمینه بررسی تغییرات رواناب در دوره آینده در شرایط تغییر اقلیم انجام شده است. با توجه به اینکه اغلب مطالعات تغییر اقلیم در زمینه برآورد رواناب با استفاده از سناریوهای RCP بوده است و سناریوهای SSP اخیراً در دسترس قرار گرفته است، در این مطالعه تلاش شده است تا پس از مقایسه مدل‌های شبکه عصبی مصنوعی FFBPNN و ANFIS با یکدیگر در دوره پایه و

۵- مراجع

- Abbasi H, Delavar M, Bigdeli Naalbandan R (2020) Evaluation of the effects of climate change on water resource sustainability in basins using water footprint scarcity indicators. *Iran-Water Resources Research* 15(4):259-272 (In Persian)
- Aghakhaniashar A, Hasanzadeh Y, Pourreza-Bilondi A A B M (2016) Seasonal changes of precipitation and temperature of mountainous watersheds in future periods with approach of fifth report of Intergovernmental Panel on Climate Change (Case study: Kashafrud Watershed Basin). *Journal of Water and Soil* 30(5):1718-1732
- Almazroui M, Saeed F, Saeed S, Islam M N, Ismail M, Klutse N A B (2020) Siddiqui, M.H. projected change in temperature and precipitation over Africa from CMIP6. *Earth Systems and Environment* 4(3):455-475
- Annayat W, Gupta A, Prakash K R, Sil B S (2021) Application of artificial neural networks and multiple linear regression for rainfall-runoff modeling. In *Communication Software and Networks*, Springer, Singapore. 719-727
- Dastorani M T, Moghadamnia A, Piri J, Rico-Ramirez M (2010) Application of ANN and ANFIS models for reconstructing missing flow data. *Environmental Monitoring and Assessment* 166(1):421-434
- Delavar M, Morid S, and Morid R (2017) Basin-wide water accounting based on modified SWAT model (SWAT-PARS): an application on the Tashk Bakhtegan Basin, Iran. 2017 International SWAT Conference in Warsaw, Poland
- Delavar M, Morid S, Morid R, Farokhnia A, Babaeian F, Srinivasan R, Karimi P (2020) Basin-wide water accounting based on modified SWAT model and WA+ framework for better policy making. *Journal of Hydrology* 585:124762
- Eberhart R, Kennedy J (1995) A new optimizer using particle swarm theory. In *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science* (pp. 39-43)
- Elbedwehy M N, Zawbaa H M, Ghali N, Hassanien A E (2012) Detection of heart disease using binary particle swarm optimization. In *2012 Federated Conference on Computer Science and Information Systems (FedCSIS)* (pp. 177-182)
- Fallah Kalaki M, Shokri Kuchak V, Ramezani Etedali H (2021) Simulating the effects of climate change on runoff using the CMIP5 and CMIP6 climate models by SWAT hydrological model (Case Study: Tashk-Bakhtegan Basin). *Iran-Water Resources Research* 17(3):345-359 (In Persian)
- Ghomsheh V S, Shoorehdeli M A, Teshnehlab M (2007) Training ANFIS structure with modified PSO algorithm. In *2007 Mediterranean Conference on Control & Automation* (pp. 1-6), IEEE
- Ghose D K, Samantaray S (2018) Modelling sediment concentration using back propagation neural network and regression coupled with genetic algorithm. *Procedia Computer Science* 9(125):85-92
- Goldberg D E, Holland J H (1988) Genetic algorithms and machine learning. *Machine Learning*, Springer
- Gupta H V, Kling H, Yilmaz K K, Martinez G F (2009) Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology* 377(1-2):80-91
- Hempel S, Frieler K, Warszawski L, Schewe J, Piontek F (2013) A trend-preserving bias correction—the ISI-MIP approach. *Earth System Dynamics* 4(2):219-236
- Hyndman R J, Koehler A B (2006) Another look at measures of forecast accuracy. *International Journal of Forecasting* 22(4):679-688
- Jang J S (1993) ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics* 23(3):665-685
- Jang J S R, Gulley N (1995) *The fuzzy logic toolbox for use with MATLAB*. Natick, MA: The Mathworks
- Jimmy S R, Sahoo A, Samantaray S, Ghose D K (2021) Prophecy of runoff in a river basin using various neural networks. In *Communication software and networks*. Springer, Singapore 709-718
- Kavoosi M, Khozayemehnehad H (2021) Review and compare performance of 4 modeling methods LS-SVM, NN, GEP and ANFIS-PSO in simulation of rainfall-runoff (Study area: Halil River-Jiroft Dam). *Irrigation and Water Engineering* 11(3):96-110 (In Persian)
- Kazemzadeh M, Malekian A, Moghaddam N A, Khalighi S S (2019) Evaluation of climate change impacts on hydrological characteristics of watershed (Case study: Aji-Chai Watershed). *Iranian Journal of Watershed Management Science and Engineering* 13(45):1-11 (In Persian)
- 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

- Lin Y, Wen H, Liu S (2019) Surface runoff response to climate change based on artificial neural network (ANN) models: A case study with Zagunao catchment in Upper Minjiang River, Southwest China. *Journal of Water and Climate Change* 10(1):158-166
- Mansouri A, Aminnejad B, Ahmadi H (2018) Investigating the effect of climate change on inflow runoff into the Karun-4 Dam based on IPCC's fourth and fifth report. *JWSS-Isfahan University of Technology* 22(2):345-359
- Mehri Y, Mehri M, Soltani J (2020) Evaluation of combined models with optimization approach of PSO and GA in ANFIS for predicting of dispersion coefficient in rivers. *Water and Irrigation Management* 10(1):45-59 (In Persian)
- Mirjalili S (2019) Genetic algorithm. In *Evolutionary Algorithms and Neural Networks* (pp. 43-55), Springer, Cham
- Moayedi H, Aghel B, Vaferi B, Foong L K, Bui D T (2020) The feasibility of Levenberg–Marquardt algorithm combined with imperialist competitive computational method predicting drag reduction in crude oil pipelines. *Journal of Petroleum Science and Engineering* 185:106634
- MOE (Ministry of Energy) (2017) Climate change adaptation strategies and national plans in water sector, Simulating water resources and agricultural systems in Tashk-Bakhtegan basin. (In Persian)
- Moghaddamnia A, Gousheh M G, Piri J, Amin S, Han D (2009) Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources* 32(1):88-97
- Nabizadeh M, Mosaedi A, Dehghani A A (2012) Intelligent estimation of stream flow by adaptive neuro-fuzzy inference system. *Water and Irrigation Management* 2(1):69-80 (In Persian)
- Nash J E, Sutcliffe J V (1970) River flow forecasting through conceptual models, part I-A, discussion of principles. *Journal of Hydrology* 10(3):282-290
- Nath A, Mthethwa F, Saha G (2020) Runoff estimation using modified adaptive neuro-fuzzy inference system. *Environmental Engineering Research* 25(4):545-553
- Nayak P C, Sudheer K P, Rangan D M, Ramasastri K S (2004) A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology* 291(1-2):52-66
- Nouri H, Ildoromi A, Sepehri M, Artimani M (2019) Comparing three main methods of artificial intelligence in flood estimation in Yalphan Catchment. *Geography and Environmental Planning* 29(4):35-50 (In Persian)
- Pearson K (1897) Mathematical contributions to the theory of evolution. On a form of spurious correlation which may arise when indices are used in the measurement of organs. *Proceedings of the Royal Society of London* 60(359-367):489-498
- Rezaeianzadeh M, Tabari H, Arabi Yazdi A, Isik S, Kalin L (2014) Flood flow forecasting using ANN, ANFIS and regression models. *Neural Computing and Applications* 25(1):25-37
- Roy B, Singh M P (2020) An empirical-based rainfall-runoff modelling using optimization technique. *International Journal of River Basin Management* 18(1):49-67
- Samanatary S, Sahoo A (2021) A comparative study on prediction of monthly streamflow using hybrid ANFIS-PSO approaches. *KSCE Journal of Civil Engineering* 25(10):4032-4043
- Sarbayev M, Yang M, Wang H (2019) Risk assessment of process systems by mapping fault tree into artificial neural network. *Journal of Loss Prevention in the Process Industries* 60:203-212
- Shahin M A, Maier H R, Jaksa M B (2004) Data division for developing neural networks applied to geotechnical engineering. *Journal of Computing in Civil Engineering* 18(2):105-114
- Shaik N B, Pedapati S R, Taqvi S A A, Othman A R, Dzubir F A A (2020) A feed-forward back propagation neural network approach to predict the life condition of crude oil pipeline. *Processes* 8(6):661
- Shokri Kuchak S, Radmanesh F (2015) Drought forecast in Tashk Bakhtegan Basin. *National Congress of Irrigation and Drainage of Iran, Ferdowsi University of Mashhad* (In Persian)
- Smith J, Eli R N (1995) Neural-network models of rainfall-runoff process. *Journal of Water Resources Planning and Management* 121(6):499-508
- Takagi T, Sugeno M (1985) Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics* SMC-15(1):116-132
- Taqvi S A, Tufa L D, Zabiri H, Maulud A S, Uddin F (2020) Fault detection in distillation column using NARX neural network. *Neural Computing and Applications* 32(8):3503-3519
- Tokar A S, & Markus M (2000) Precipitation-runoff modeling using artificial neural networks and

- conceptual models. *Journal of Hydrologic Engineering* 5(2):156-161
- Wajahat A, Sundar S B (2018) Estimation and analysis of possible flood for the Silchar city-A Case Study. *Disaster Advances* 11(1):25-32
- Wang J, Hu L, Li D, Ren M (2020) Potential impacts of projected climate change under CMIP5 RCP scenarios on streamflow in the Wabash River Basin. *Advances in Meteorology* 2020(4):1-18
- Wu F, Shi Q, Hasan S S, Shi C, Gibson J (2019) Urbanization and industrial transformation for improved water management. *River Basin Management*, Book series Ecohydrology 1-29
- Wu S J, Hsu C T, Chang C H (2021) Stochastic modeling of artificial neural networks for real-time hydrological forecasts based on uncertainties in transfer functions and ANN weights. *Hydrology Research* 52(6):1490-1525
- Yang C C, Chen C S (2009) Application of integrated back-propagation network and self-organizing map for flood forecasting. *Hydrological Processes: An International Journal* 23(9):1313-1323
- Yaseen Z M, Ebtahaj I, Kim S, Sanikhani H, Asadi H, Ghareb M I, Shahid S (2019) Novel hybrid data-intelligence model for forecasting monthly rainfall with uncertainty analysis. *Water* 11(3):502
- Zadeh L A (1965) Fuzzy set theory. *Information and Control* 8(3):338-353