



## ریزمقیاس نمایی روابط بارش-رواناب حوضه آبریز رود زرد در بستر تغییر اقلیم

سعید جهانبخش اصل<sup>۱\*</sup>، حسین عساکره<sup>۲</sup>، سعیده اشرفی<sup>۳</sup>

۱- استاد اقلیم‌شناسی دانشکده برنامه‌ریزی و علوم محیطی دانشگاه تبریز، ایران

۲- استاد اقلیم‌شناسی دانشگاه زنجان، ایران

۳- دانش‌آموخته دکتری اقلیم‌شناسی دانشگاه تبریز، ایران

تأیید نهایی مقاله: ۱۳۹۷/۱۲/۲۶

وصول مقاله: ۱۳۹۷/۰۶/۰۵

### چکیده

بررسی و شناخت تغییرات اقلیمی رخ داده در نواحی مختلف می‌تواند شناختی از تغییرات اقلیمی محتمل در آینده را به دست دهد. یکی از راه‌های شناخت تغییرات احتمالی عناصر اقلیمی در آینده استفاده از مدل‌های اقلیمی موجود و ریزمقیاس‌نمایی آنهاست. در این پژوهش بارش و رواناب حوضه آبریز رود زرد، ریزمقیاس‌نمایی و برای دوره‌ی ۲۰۰۶-۲۱۰۰ شبیه‌سازی گردید. برای این منظور از سناریوهای RCP خروجی مدل CanESM2 استفاده شد. دوره‌ی پایه‌ی مورد استفاده برای این کار ۱۹۷۶-۲۰۰۵ می‌باشد. برای ریزمقیاس‌نمایی بارش و رواناب حوضه آبریز رود زرد از داده‌های بارش روزانه ایستگاه باغملک و رواناب ایستگاه ماشین و روش شبکه‌ی عصبی مصنوعی بهره گرفته شد. با استفاده از روش حذف پس‌رونده، متغیرهای میانگین فشار سطح دریا، ارتفاع ژئوپتانسیل تراز ۵۰۰ هکتوپاسکال و میانگین دما در ارتفاع نزدیک سطح زمین به عنوان متغیرهای پیش‌بینی‌کننده انتخاب شد. راستی‌آزمایی الگو با نمایه‌های  $RMSE$  و  $R^2$  انجام پذیرفت. در نهایت، معماری شبکه با الگوریتم قانون پسر و بیزی و با سه لایه‌ی پنهان به عنوان شبکه‌ی بهینه انتخاب شد. نتایج نشان‌دهنده‌ی روند کاهشی بارش سالانه برآورد شده در ۹۵ سال آینده بر اساس هر سه سناریو می‌باشد. همچنین افزایش بارش در ماه‌های فصل گرم و کاهش بارش در ماه‌های فصل سرد مورد انتظار است. به عبارت دیگر می‌توان افزایش بارش‌های محلی (احتمالاً همرفتی) ناشی از افزایش دما در دوره‌های آینده را محتمل دانست. رواناب حاصل از بارش نیز در ماه‌های سرد، کاهش و در ماه‌های گرم با صرف نظر از تأثیر دما و پوشش گیاهی، افزایش را تجربه خواهد کرد.

کلمات کلیدی: بارش، رواناب، ریزمقیاس‌نمایی، شبکه‌ی عصبی، حوضه آبریز رود زرد.

## ۱- مقدمه

تغییر اقلیم یکی از پدیده‌های مهم و تأثیرگذار بر اقلیم و محیط پیرامون زندگی بشر و نیز پدیده‌های محیطی (نظیر خشکسالی‌ها و ترسالی‌ها، منابع آب، تغییرات سطح آب دریاها، تغییرات دمایی، تغییرات رفتار عناصر اقلیمی و بسیاری پدیده‌های دیگر) است. بررسی بسیاری از رویدادهای دهه‌های گذشته نشان می‌دهد که اقلیم زمین در حال تغییر است. تغییر اقلیم یکی از فرایندهای پویای اثرگذار در مدیریت منابع آب است و به صورت بالقوه می‌تواند روی بسیاری از بخش‌هایی که در مدیریت منابع آب نقش مؤثری دارند از قبیل دسترسی به آب، کیفیت آب، کاهش ریسک سیل، زیست بوم، مناطق ساحلی و بسیاری بخش‌های دیگر اثرگذار باشد (برک و همکاران<sup>۱</sup>، ۲۰۰۹). نتایج مطالعات علمی نشان داده‌اند که پدیده‌ی تغییر اقلیم آثار قابل توجهی بر بارش، تبخیر- تعرق، رواناب و در نهایت بر تامین آب دارد (کارآموز و عراقی‌نژاد، ۱۳۹۳: ۴۹). بنابراین مطالعه بارش و رواناب ناشی از آن گام مهمی در مدیریت منابع آب خواهد بود. نگهداری و مدیریت منابع آب، هم تابعی از بارش دریافتی بوده و هم به تغییرپذیری بارش بستگی دارد (مسعودیان و کاویانی، ۱۳۸۷: ۸۱). در ایران بارش یکی از متغیرهای اساسی برای ارزیابی مهبایی بالقوه‌ی منابع آب است، اما توزیع زمانی و مکانی آن بسیار ناموزون بوده و به همین دلیل توزیع منابع آب کشور نیز یکنواخت نیست. با توجه به کمبود منابع آب ناشی از افزایش درخواست آن و تغییرات بارش وابسته به تغییرات آب‌وهوایی، مدیریت منابع آب امری پیچیده می‌باشد (عبدالباطن و تیتامر<sup>۲</sup>، ۲۰۱۶).

از آنجا که درصد بالایی از آب مورد استفاده در کشور از طریق رودها تأمین می‌شود، بنابراین رفتار رود در چگونگی برداشت و تامین آب از آن اهمیت بالایی دارد. نبود یا کمبود داده‌ها در مورد واکنش حوضه‌های آبریز مانع بزرگی در راه بررسی دقیق وضعیت آب یک منطقه یا کشور است و یکی از راه‌های برطرف نمودن این نقیصه تعیین حوضه‌های معرف و

---

1- Brekke

2- Abdul Baten &amp; Titumir

مطالعه در مورد واکنش هیدرولوژیکی این حوضه‌ها می‌باشد. گزینش این حوضه‌های آبریز به‌گونه‌ای صورت می‌گیرد که هر حوضه نماینده‌ی اراضی پهناوری از منطقه‌ی مورد بررسی باشد. در این صورت این حوضه‌ها به عنوان آزمایشگاه‌های هیدرولوژیکی، کمک مهمی در شناخت مؤلفه‌های چرخه‌ی آب و مطالعات آب‌شناسی خواهند بود. حوضه‌ی معرف رود زرد با توجه به برنامه ۱۰ ساله بین‌المللی هیدرولوژی<sup>۱</sup> سازمان جهانی یونسکو و با هدف تجهیز و بهره‌برداری از داده‌های برداشت شده از این حوضه، ایجاد شده است (امین و غفوری روزبهانی، ۱۳۸۱). بنابراین حوضه‌ی آبریز مذکور به عنوان نماینده ویژگی‌های منطقه‌ای است که در آن واقع شده و می‌توان نتایج مطالعه در مورد این حوضه را به کل منطقه مورد نظر تعمیم داد.

پیکره‌ی اقلیم و ارتباط متقابل و پیچیده خرده‌دستگاه‌های تشکیل‌دهنده‌ی آن موجبات تکوین رفتاری آشوب‌مند در آن شده است (مسعودیان و کاویانی، ۱۳۸۷: ۱) و موجبات دشواری فهم آن را فراهم نموده است. برای شناخت جامع اقلیم باید بتوان دستگاه‌های دخیل در شکل‌گیری آن را یک‌جا مطالعه نمود. برای این منظور، استفاده از مدل‌ها می‌تواند تا حدودی راه‌گشا باشد. مدل‌سازی فرآیند تولید یک مدل است و یک مدل ارائه‌کننده ساختار و کارکرد سامانه‌هاست. از جمله این روش‌ها GCMها هستند که اقلیم را شبیه‌سازی می‌کنند (هاردی، ۱۳۹۱: ۸۴). این مدل‌ها بر اساس سناریوهای مختلف اقلیمی به‌منظور شبیه‌سازی اثر گازهای گلخانه‌ای بر اقلیم حاضر کره‌ی زمین توسعه داده شده‌اند و قادرند اقلیم آینده‌ی زمین را شبیه‌سازی و بعضاً پیش‌بینی کنند. مطالعات فراوانی با بکارگیری این روش‌ها انجام گرفته است؛ برای مثال، کارآموز و همکاران (۲۰۰۹) بارش حوضه‌ی آبریز رودخانه‌ی کاجو در جنوب بلوچستان را شبیه‌سازی نمودند. نتایج بررسی ایشان نشان می‌دهد که مدل SDSM برآورد بارش نزدیک‌تری به واقعیت دارد. پالازی و همکاران<sup>۲</sup> (۲۰۱۳) بارش هندوکش، قره‌قوم و هیمالیا را براساس سناریوهای RCP 4.5 و RCP 8.5 شبیه‌سازی کردند. بررسی‌ها نشان می‌دهند که بارش هندوکش و قره‌قوم فاقد

1- International Hydrological Decade

2- Palazzi et al.,

روند معنادار و در هیمالیا روند افزایشی دیده می‌شود. جانسن و همکاران<sup>۱</sup> (۲۰۱۴) روند بارش‌های فرین در ایالات متحده را بر اساس سناریوهای RCP 4.5 و RCP 8.5 شبیه‌سازی کردند. نتایج حاکی از افزایش در بارش‌های فرین بر اساس سناریوهای آبیچوری<sup>۲</sup> و همکاران (۲۰۱۵) جریان رودخانه سیبوس در شمال شرقی الجزایر را از طریق شبکه عصبی مدل‌سازی کردند. نتایج نشان می‌دهد که شبکه‌ی عصبی روشی مناسب برای شبیه‌سازی جریان در حوضه‌های آبریز نواحی نیمه‌خشک و نواحی مدیترانه‌ای است. الطاف<sup>۳</sup> و همکاران (۲۰۱۷) دما و بارش در حوضه‌ی آبریز لیدر در هندوستان را با استفاده از داده‌های مدل CGCM3 ریزمقیاس‌نمایی نمودند. نتایج مطالعه ایشان نشان می‌دهد که بارش و دما با افزایش همراه خواهند بود. شریفی و همکاران (۲۰۱۹) بارش اتریش و زورزتو و مارانی<sup>۴</sup> (۲۰۱۹) بارش‌های فرین در ایالات متحده را ریزمقیاس‌نمایی نمودند.

در ایران نیز انوری تفتی و همکاران (۱۳۹۰) جریان رودخانه در حوضه‌ی کارون، صمدی نقاب و همکاران (۱۳۹۰) دما و بارش کشور، فتاحی و همکاران (۱۳۹۱) جریان رودخانه‌های کارون شمالی، طائی سمیرمی و همکاران (۱۳۹۳) دما و بارش حوضه آبریز بار نیشابور، رضایی و همکاران (۱۳۹۳) پارامترهای دمایی در اقلیم‌های خشک و فراخشک، جهانبخش و همکاران (۱۳۹۵) تاثیر تغییر اقلیم بر دما و بارش حوضه‌ی شهرچای، پورمحمدی و همکاران (۱۳۹۶) اثر تغییر اقلیم بر پارامترهای اقلیمی حوضه‌ی آبریز تویسرکان، عساکره و اکبرزاده (۱۳۹۶) دما و بارش ایستگاه تبریز و میراکبری و همکاران (۱۳۹۷) بارش، دما و سرعت باد استان یزد را شبیه‌سازی نموده‌اند.

تغییر اقلیم در دهه‌های اخیر موجب تغییراتی در رژیم بارندگی در قسمت‌های مختلف کشور شده است. تاثیرپذیری مستقیم جریان رودها از الگوی زمانی- مکانی بارندگی اهمیت مطالعه در رابطه با تأثیر تغییرات اقلیمی بر بارش و به تبع آن رواناب را آشکار می‌کند. زیرا

1- Janssen et al.,

2- Aichouri

3- Altaf

4- Zorzetto and Marani

با توجه به کاهش بارش در بسیاری مناطق و ازدیاد جمعیت، اهمیت مدیریت منابع آب را روز افزون کرده است. از این رو در تحقیق حاضر سعی بر آن است تا تاثیر تغییرات اقلیمی بر بارش و رواناب حوضه آبریز رود زرد (از زیر حوضه‌های جراحی و در شرق استان خوزستان) مورد ارزیابی قرار گیرد. در پژوهش حاضر از ریز مقیاس‌نمایی شبکه‌های عصبی با بکارگیری سناریوهای RCP خروجی مدل CanESM2 بهره گرفته شده است.

## ۲- مواد و روش‌ها

### - معرفی محدوده مورد مطالعه

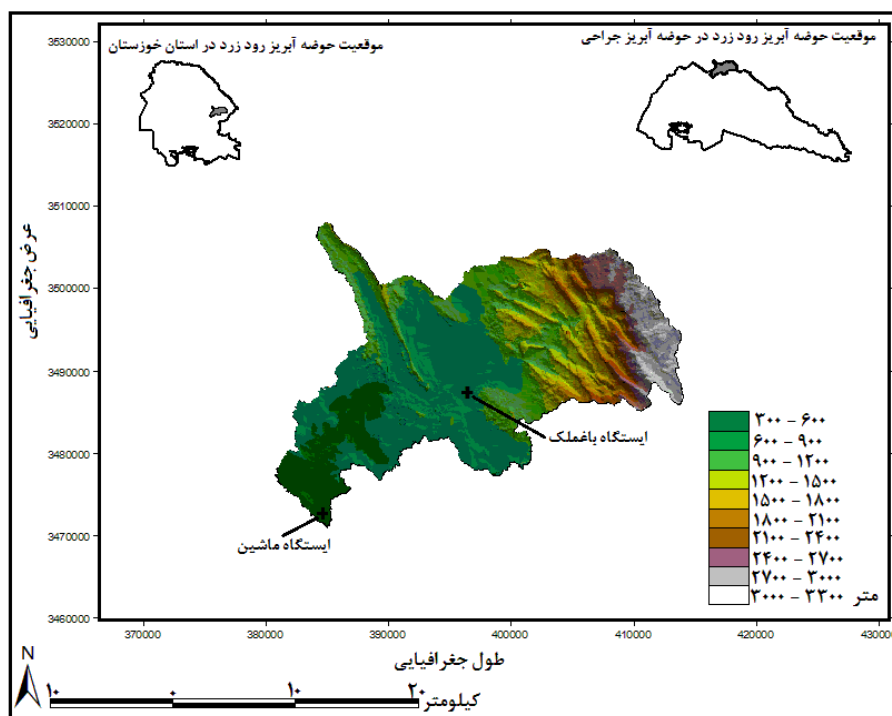
حوضه آبریز رود زرد در قسمت شرقی استان خوزستان و در قسمت شمالی حوضه آبریز جراحی (شکل ۱) واقع شده است. بیشترین سطح حوضه آبریز رود زرد در شهرستان باغملک قرار دارد. بخشی از ارتفاعات شرقی حوضه در شهرستان ایذه و قسمت خروجی حوضه نیز در شهرستان رامهرمز قرار گرفته است. میانگین ارتفاع حوضه ۱۸۰۲/۳ متر، بالاترین ارتفاع ۳۲۹۹ متر و کمینه ارتفاع ۳۴۶ متر از سطح آب‌های آزاد می‌باشد. سطح ارتفاعی ۹۰۰-۶۰۰ متر از سطح دریا، بیشترین مساحت (۳۷/۹۶ درصد) و ارتفاعات بیش از ۳۰۰۰ متر نیز کمترین مساحت (۲/۰۴ درصد) را در این حوضه دارند. حوضه آبریز رود زرد با مساحت ۸۸۱/۹۱ کیلومتر مربع (۸۸۱۹۱ هکتار) در دامنه‌های غربی زاگرس و در مختصات جغرافیایی زیر واقع شده است:

$$E: 49^{\circ} 39' - 50^{\circ} 10'$$

$$N: 31^{\circ} 21' - 31^{\circ} 41'$$

۱۴ ایستگاه در داخل حوضه آبریز رود زرد با دوره‌ی آماری قابل قبول وجود دارد که از این میان تنها یک ایستگاه زیر نظر سازمان هواشناسی است که کمترین میزان داده‌های مفقود را داشته و آمار آن قابل استفاده برای مدل‌سازی می‌باشد. از طرف دیگر بررسی‌های انجام شده نشان می‌دهد که داده‌های اندازه‌گیری شده در ایستگاه‌های داخل حوضه به هم

وابسته بوده و فاقد استقلال می‌باشند. تغییرنمای ترسیم شده برای ایستگاه‌های حوضه این امر را مورد تأیید قرار می‌دهد.



شکل (۱) سطوح ارتفاعی و موقعیت ایستگاه‌های مورد استفاده حوضه آبریز رود زرد  
Fig (1) Altitude surface and stations location in Rood Zard Basin

شکل (۲) تغییرنمای ایستگاه‌های داخل حوضه را نشان می‌دهد. همان‌طور که در شکل نیز آشکار است، تغییرنما به حد ثابتی نرسیده و شعاع تأثیر داده‌ها تا انتهای حوضه ادامه دارد. از طرف دیگر ایستگاه زیر نظر سازمان هواشناسی در مرکز حوضه واقع شده و با توجه با شعاع تأثیر داده‌ها می‌تواند نماینده مناسبی برای پهنه‌ی حوضه باشد. از این رو در پژوهش حاضر از داده‌های بارش ایستگاه باغملک در مرکز حوضه آبریز رود زرد و دبی روزانه

ایستگاه ماشین در گریزگاه حوضه استفاده شده است. جدول (۱) مشخصات ایستگاه‌های مورد استفاده را نشان می‌دهد.

جدول (۱) مشخصات ایستگاه‌های مورد استفاده

Tab (1) specifications of used stations

نام ایستگاه	طول جغرافیایی		عرض جغرافیایی		ارتفاع به متر	نوع ایستگاه	دوره‌ی آماری پایه
	درجه	دقیقه	درجه	دقیقه			
باغملک	۵۳	۴۹	۳۱	۳۱	۷۱۰	اقلیم‌شناسی	۱۹۷۶-۲۰۰۵
ماشین	۴۳	۴۹	۳۱	۲۳	۳۵۰	آب‌سنجی	۱۹۷۶-۲۰۰۵


همان‌طور که پیش‌تر ذکر گردید در این پژوهش بارش و رواناب حوضه آبریز رود زرد بر اساس سناریوهای اقلیمی RCP ریزمقیاس‌نمایی می‌شوند. RCPها سناریوهای جدید محرک گسیلش هستند (چارون، ۲۰۱۴: ۶۳). در این سناریوها، اشکالات سناریوهای مورد استفاده در مدل‌های پیشین، مرتفع شده است. در این مدل (CanESM2) سطح زمین به صورت ۱۲۸×۶۴ سلول شبکه‌بندی شده است. دقت مکانی این سلول‌ها ۲/۸۱۲۵ درجه طول جغرافیایی و ۲/۷۹۰۶ درجه عرض جغرافیایی است (سایت محیط زیست کانادا، ۲۰۱۸).<sup>۱</sup>

در سناریوهای RCP، ۲۶ فراسنج جوی برای شبیه‌سازی آینده‌ی اقلیم در نظر گرفته شده‌اند. هر یک از این فراسنج‌ها، ارتباط کمابیش قوی با عناصر محیطی نشان می‌دهند. انتخاب مناسب‌ترین فراسنج برای بیان روابط شرایط جوی با مشخصات محیطی به نوع فراسنج محیطی بستگی دارد. برای انتخاب فراسنج‌های مناسب از شاخص‌های همبستگی، همبستگی جزئی و روش حذف پس‌رونده<sup>۲</sup> استفاده شد. روش حذف پس‌رونده با محاسبه‌ی همبستگی چندمتغیره بین همه‌ی متغیرهای مستقل و متغیر وابسته آغاز می‌شود. سپس هر یک از متغیرهای مستقل به نوبت از معادله کنار گذاشته می‌شود و کاهش ناشی از آن

1- <http://climate-scenarios.canada.ca/?page=pred-canesm2>

2- Backward Variable Elimination

در ضریب تعیین بررسی می‌شود (عساکره، ۱۳۹۰: ۲۵۶). این کار تا جایی ادامه می‌یابد که بتوان متغیرهایی را انتخاب کرد که بیشترین تأثیر را در ثبات ضریب تعیین داشته باشند.



شکل (۲) تغییر نمای بارش ایستگاه‌های حوضه آبریز رود زرد  
Fig (2) Precipitation variogram in Rood Zard Basin stations

برای ریزمقیاس‌نمایی، داده‌های BOX\_019X\_44Y از سایت محیط زیست کانادا اخذ گردید. بررسی‌های انجام شده با محاسبه ضرایب همبستگی، همبستگی جزئی و به کارگیری روش حذف پس‌رونده نشان داد که ۳ متغیر، همبستگی قابل قبولی با بارش ایستگاه باغملک داشته و حذف متغیرهای دیگر نسبت پراش از دست رفته پایین‌تری ایجاد می‌کند. برای این کار میزان همبستگی چندمتغیره ۰/۴۳۸ و ضریب تعیین آن ۰/۱۹۲ به دست آمد. میزان ضریب تعیین با حذف هر یک از متغیرهای انتخابی در جدول (۲) ارائه شده است. بنابراین متغیرهای مذکور برای مدل‌سازی به‌عنوان متغیرهای مناسب ورودی شبکه‌ی عصبی مصنوعی انتخاب شدند.



جدول (۲) متغیرهای شبیه‌سازی منتخب

Table (2) chosen simulation variables

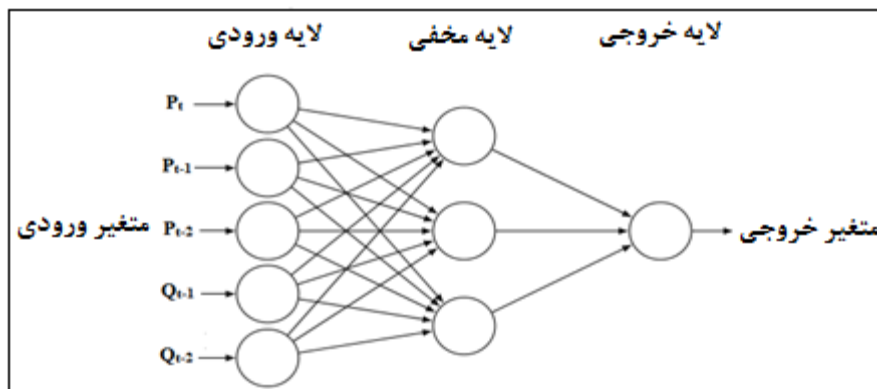
متغیر شبیه‌ساز	همبستگی ساده	همبستگی جزئی	ضرب تعیین با حذف متغیر	نسبت پراش از دست رفته با حذف متغیر
میانگین فشار سطح دریا	۰/۱۰۲	-۰/۰۳۴	۰/۱۷۳	۰/۱۷۳ - ۰/۱۹۲ = ۰/۰۱۹
ارتفاع ژئوپتانسیل در سطح ۵۰۰ هکتوپاسکال	-۰/۲۹۶	۰/۰۴۴	۰/۱۹۱	۰/۱۹۱ - ۰/۱۹۲ = ۰/۰۰۱
میانگین دما در ارتفاع نزدیک سطح زمین	-۰/۲۳۸	-۰/۰۶۴	۰/۱۸۱	۰/۱۸۱ - ۰/۱۹۲ = ۰/۰۱۱

ریزمقیاس نمایی براساس مدل شبکه‌ی عصبی مصنوعی پس‌انتشار با الگوریتم قانون بیزی<sup>۱</sup> انجام شد. این روش در طی دهه‌های اخیر به عنوان ابزاری مفید و قابل اعتماد جهت مدل سازی نگاشت‌های پیچیده‌ی موجود بین متغیرهای مختلف شناخته شده و مورد توجه قرار گرفته‌اند (فتحیان و هرمزی‌نژاد، ۱۳۹۰: ۳۰). در این پژوهش از شبکه‌ی پیش‌خور جهت پیش بینی استفاده می‌شود. شکل (۳) ساختار شبکه‌ی عصبی مصنوعی پیش‌خور را نشان می‌دهد. ارتباطات درونی شبکه‌های پیش‌خور توسط ماتریس وزن‌ها ( $w_{ij}$ ) برقرار می‌شود. پالس ورودی هر نرون تابعی از ماتریس وزن‌ها و اطلاعات رسیده به آن نرون ( $x_i$ ) می‌باشد و از رابطه‌ی زیر به دست می‌آید. در این رابطه  $b$  وزن بایاس می‌باشد (رستم‌افشار و همکاران، ۱۳۸۵: ۳۷).

$$net_j = \sum_{i=1}^n w_{ij}x_i + b_j \quad (1)$$

بایاس مقدار ثابتی است که در هر نرون به رابطه افزوده می‌شود (فتاحی و همکاران، ۱۳۹۱: ۵۹). در این پژوهش از شبکه‌ی پیش‌خور پروسپترون چندلایه<sup>۲</sup> استفاده شده است.

1- Bayesian Regularization  
2. Multi-layer perceptron



شکل (۳) ساختار شبکه‌ی عصبی پیش‌خور با سه لایه‌ی پنهان (کومار<sup>۱</sup> و همکاران، ۲۰۱۶: ۲۶۴)  
Fig (3) Architecture of the neural network model with 3 hidden layer (Kumar et al, 2016:264)

الگوریتم قانون بیزی یکی از روش‌های سیستم پشتیبان تصمیم‌گیری می‌باشد که ابزار قدرتمندی در مدل کردن روابط علی در قالب شبکه‌ای از احتمالات است (قربانی و دهقانی، ۱۳۹۶: ۱۴). چارچوب روش بیزی برای شبکه‌های عصبی بر میان‌یابی احتمالاتی پارامترهای شبکه بنا نهاده شده است (کایری<sup>۲</sup>، ۲۰۱۶: ۴). این روش، مربعات خطا و وزن‌ها را کمینه می‌کند و سپس بهترین ترکیب را برای تولید شبکه می‌یابد (آگاروال<sup>۳</sup> و همکاران، ۲۰۰۵: ۵۰۷). به عبارت دیگر وزن‌های بهینه از طریق کمینه شدن تابع خطا، انتخاب می‌شوند. روش بیزی یک توزیع احتمالی از وزن‌های شبکه را شامل می‌شود و به عنوان نتیجه، شبکه نیز یک توزیع احتمالاتی است. در فرایند آموزش، برای محاسبه‌ی فاصله بین داده‌های واقعی و برآورد شده، یک تابع عملگر عمومی استفاده می‌شود. این تابع می‌تواند به شکل زیر بیان شود:

$$F = E_D(D|w, M) = \frac{1}{N} \sum_{i=1}^n (\hat{t}_i - t_i)^2 \quad (۲)$$

1- Kumar  
2- Kayri  
3- Aggarwal

در اینجا  $E_D$  میانگین مجموع مربعات خطای شبکه،  $D$  سری آموزشی با جفت‌های ورودی و هدف،  $M$  ساختار شبکه‌ی عصبی است که می‌تواند از تعدادی لایه، بخش‌هایی در هر لایه و نوعی از تابع فعال‌ساز که توسط هر قسمت اجرا می‌شود، تشکیل شود (کاپری، ۲۰۱۶: ۴).

روش‌های مورد استفاده برای صحت سنجی دو دسته هستند. دسته‌ای از روش‌ها که داده‌ها را مورد بررسی قرار می‌دهند (همبستگی و ضریب تعیین) و دسته‌ای که باقیمانده‌ها را آزمون می‌کنند که اغلب به نوعی از  $RMSE$  مشتق شده‌اند. در این مطالعه نیز از روش ضریب تعیین ( $R^2$ ) برای آزمون داده‌ها و از  $RMSE$  برای آزمون باقی‌مانده‌ها بهره گرفته شده است. کمترین مربعات خطا از طریق رابطه‌ی زیر به دست می‌آید (کمال و مساح بوانی، ۱۳۹۱: ۱۸۲):

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (X_{obs,i} - X_{sim,i})^2} \quad (3)$$

در این رابطه  $X_{obs}$  متغیر برآورد شده و  $X_{sim}$  متغیره مشاهده شده برای دوره‌ی پایه می‌باشند.

شاخص  $R^2$  نیز از طریق رابطه‌ی زیر محاسبه می‌شود (جوشی<sup>۱</sup> و همکاران، ۲۰۱۳: ۱۴۲):

$$R^2 = \left( \frac{\sum_{i=1}^N (X_{obs,i} - \bar{X}_{obs})(X_{sim,i} - \bar{X}_{sim})}{\sqrt{\sum_{i=1}^N (X_{obs,i} - \bar{X}_{obs})^2 \sum_{i=1}^N (X_{sim,i} - \bar{X}_{sim})^2}} \right)^2 \quad (4)$$

پس از محاسبه‌ی شاخص‌های  $RMSE$  و  $R^2$ ، الگوریتمی که  $RMSE$  آن کمینه و  $R^2$  آن بیشینه باشد به عنوان الگوریتم بهینه برای ساخت مدل انتخاب می‌شود.

### ۳- بحث و نتایج

برای ریزمقیاس‌نمایی شبکه‌های عصبی با به کارگیری سناریوهای RCP خروجی مدل


1- Joshi

CanESM2 داده‌های بارش روزانه ایستگاه باغملک برای دوره‌ی ۳۰ ساله ۱۹۷۶-۲۰۰۵ به عنوان دوره‌ی آماری پایه انتخاب شد. پس از انتخاب متغیرهای جوی بزرگ مقیاس (جدول ۲)، این متغیرها به عنوان ورودی و بارش به عنوان متغیر هدف (target)، به شبکه‌ی عصبی معرفی شدند و شبکه با استفاده از الگوریتم‌ها و تعداد لایه‌های پنهان متعدد طراحی گردید. در نهایت شبکه‌ی طراحی شده با الگوریتم قانون پسر و بیزی و با تعداد ۳ لایه‌ی پنهان به عنوان شبکه‌ی بهینه انتخاب شد. پس از انتخاب شبکه‌ی مناسب، اقدام به برآورد داده‌های روزانه بارش برای دوره‌ی ۲۱۰۰-۲۰۰۶ گردید.

شکل (۴) مقادیر بارش سالانه دوره‌ی پایه و مقادیر بارش سالانه برآورد شده از طریق مدل برای همین دوره و شکل (۵) مقادیر بارش ماهانه و مقادیر بارش برآورد شده برای دوره پایه را نشان می‌دهند. شکل‌های مذکور نشان می‌دهند که شبکه‌ی طراحی شده توانسته است بارش را در دوره پایه نسبتاً قابل قبول برآورد کند. نتایج بررسی‌ها حاکی از اختلاف بارش‌های برآورد شده در دوره‌ی مرطوب (ماه‌های آبان تا فروردین) با بارش‌های مشاهداتی می‌باشد.


با انتخاب شبکه بهینه و با استفاده از متغیرهای پیش‌بینی‌کننده‌ی منتخب، بارش ایستگاه باغملک برای دوره‌ی ۲۱۰۰-۲۰۰۶ با استفاده از خروجی مدل CanESM2 برای سناریوهای RCP 2.6، RCP 4.5 و RCP 8.5 شبیه‌سازی گردید. شکل (۶) بارش روزانه، شکل (۷) بارش ماهانه و شکل (۸) بارش سالانه شبیه‌سازی شده برای دوره‌ی ۲۱۰۰-۲۰۰۶ را برای هر ۳ سناریو نشان می‌دهد. بررسی بارش روزانه شبیه‌سازی شده برای سناریوهای مختلف حاکی از وقوع بارش‌های بیشینه منظم‌تر و با فراوانی بیشتر در نیمه‌ی اول دوره است. همان‌طور که از شکل (۷) استنباط می‌شود، در ماه‌های آبان تا دی، مقادیر بارش ماهانه برآورد شده برای دوره‌ی ۹۵ سال آینده کاهش داشته است. در ماه‌های بهمن تا آبان نیز مقادیر بارش شبیه‌سازی شده بیش از مقادیر ماهانه بارش در دوره‌ی پایه است. البته در ماه‌های اردیبهشت و خرداد، مقادیر برآورد شده بارش بسیار نزدیک به داده‌های واقعی است. براین اساس می‌توان نتیجه گرفت که بارش در فصل سرد سال رو به کاهش و در فصل گرم با افزایش همراه خواهد بود. بر اساس هر سه سناریو، بیشترین افزایش بارش

در ماه اسفند و بیشترین کاهش بارش در ماه دی رخ خواهد داد (جدول ۳). مطالعات فینیس<sup>۱</sup> و همکاران (۲۰۰۷)، عباس‌پور و همکاران (۲۰۰۹) و مهدی‌زاده و همکاران (۱۳۹۰) نیز حاکی از تغییر بارش (اغلب کاهش بارش) در دوره‌های آینده می‌باشد.



شکل (۴) مقادیر بارش سالانه دوره‌ی پایه و بارش سالانه برآورد شده از طریق مدل


Fig (4) Annual precipitation and estimated annual precipitation by model in base period



شکل (۵) مقادیر بارش ماهانه دوره‌ی پایه و بارش ماهانه برآورد شده از طریق مدل

Fig (5) Monthly precipitation and monthly estimated precipitation by model in base period

1- Finnis et al.,




شکل (۶) نمودار مقادیر بارش روزانه شبیه‌سازی شده برای سال ۲۰۰۶-۲۱۰۰ با به کارگیری سناریوهای

الف: RCP 2.6 – ب: RCP 4.5 و ج: RCP 8.5

Fig (6) Estimated daily precipitation graph in 2006–2100 by using scenarios a: RCP 2.6 – b: RCP 4.5 and c: RCP 8.5

بررسی بارش سالانه شبیه‌سازی شده (شکل ۸) وجود روند کاهشی بارش بر اساس هر سه سناریو را آشکار می‌کند. کمترین روند کاهشی در سناریوی RCP 2.6 و بیشترین روند کاهشی در سناریوی RCP 8.5 دیده می‌شود. به طوری که میزان بارش شبیه‌سازی شده برای سال ۲۱۰۰ تقریباً نصف مقدار آن در اول دوره ۹۵ ساله می‌باشد.



شکل (۷) نمودار مقادیر بارش ماهانه شبیه‌سازی شده برای سال ۲۰۰۶-۲۱۰۰ با به کارگیری سناریوهای


RCP 8.5 و RCP 4.5 – RCP 2.6

Fig (7) Estimated monthly precipitation graph in 2006–2100 by using RCP 2.6 – RCP 4.5 and RCP 8.5 scenarios

به منظور برآورد رواناب روزانه برای دوره‌ی ۲۱۰۰-۲۰۰۶ از روش رگرسیون خطی بهره گرفته شد. به این صورت که بارش روزانه‌ی دوره‌ی پایه به عنوان متغیر مستقل و رواناب روزانه‌ی دوره‌ی پایه به عنوان متغیر وابسته در نظر گرفته شد. رابطه‌ی زیر معادله خط به دست آمده از این فرایند می‌باشد:

$$\text{runoff} = 6.25 + 1.956 \text{precipitation} \quad (5) \quad \text{ضریب تعیین } 0.253$$

پس از محاسبه‌ی شیب خط از طریق رگرسیون خطی برای دوره‌ی پایه، از طریق شیب خط به دست آمده و بارش برآورد شده برای دوره‌ی ۲۱۰۰-۲۰۰۶، رواناب برای این دوره برآورد گردید. در واقع بارش شبیه‌سازی شده از طریق سناریوهای RCP 4.5 - RCP2.6 و RCP 8.5 به عنوان متغیر مستقل در رابطه‌ی (۵) قرار داده شد. بدین ترتیب رواناب روزانه برای دوره‌ی ۲۱۰۰-۲۰۰۶ نیز به دست آمد. شکل (۹) رواناب روزانه برآورد شده بر اساس سناریوهای مختلف را نشان می‌دهد. مقایسه شکل مذکور و نمودارهای بارش روزانه دوره‌ی ۲۱۰۰-۲۰۰۶ نشان از تأثیرپذیری مستقیم رواناب از بارش دارد. به طوری که افت و خیزهای رواناب در شکل مذکور تابعی از افت و خیزهای میزان بارش (شکل ۶) می‌باشد. شکل (۱۰) مقادیر رواناب ماهانه مشاهداتی و برآورد شده دوره‌ی پایه را نمایش می‌دهد. همان‌طور که دیده می‌شود، رواناب ماه‌های بهمن تا خرداد در دوره‌ی پایه کمتر از رواناب مشاهداتی و در ماه‌های تیر تا دی در دوره پایه بیشتر از رواناب مشاهداتی برآورد شده است. زیرا برای مدل‌سازی تنها از بارش به عنوان متغیر مستقل استفاده شده است. در صورتی که رواناب، علاوه بر بارش، از پارامترهای دیگری مانند آب چشمه‌ها و... نیز متأثر می‌شود.



شکل (۸) نمودار مقادیر بارش سالانه شبیه‌سازی شده برای سال ۲۰۰۶-۲۱۰۰ با به کارگیری سناریوهای RCP 8.5 و RCP 4.5 – RCP 2.6


Fig (8) Estimated annual precipitation graph in 2006–2100 by using RCP 2.6 – RCP 4.5 and RCP 8.5 scenarios

جدول (۳) تغییرات بارش و رواناب دوره‌ی ۲۰۰۶-۲۱۰۰ در مقایسه با دوره‌ی پایه

Table (3) precipitation and runoff changes in 2006-2100 in compare with base period

ماه	تغییر در بارش (میلی‌متر) بر اساس			تغییر در رواناب (مترمکعب بر ثانیه) بر اساس سناریوهای		
	RCP 8.5	RCP 4.5	RCP 2.6	RCP 8.5	RCP 4.5	RCP 2.6
فروردین	-۶/۹	-۶/۵	-۶/۳	۱/۳	۷/۴	۱۰/۷
اردیبهشت	-۵	-۵/۱	-۴/۹	-۱/۲	-۱/۹	-۰/۵
خرداد	-۰/۸	-۰/۹	-۰/۸	۱/۲	۰/۷	۱/۷
تیر	۲/۶	۲/۷	۲/۹	۷/۴	۹/۶	۱۱/۴
مرداد	۳/۵	۳/۶	۳/۸	۴/۲	۵/۲	۸/۵
شهریور	۳/۳	۳/۸	۳/۴	۱/۵	۲/۴	۲/۹
مهر	۳/۴	۳/۵	۳/۷	۴/۳	۵/۷	۹/۱
آبان	۱/۹	۲/۶	۳/۲	۱/۴	۱۳/۳	۲۲/۳
آذر	-۱/۹	-۱/۵	-۱/۳	-۶۴/۴	-۵۸/۲	-۵۵/۷
دی	-۳/۸	-۳/۷	-۳/۵	-۶۸/۷	-۶۵/۸	-۶۳/۶
بهمن	-۱/۶	-۱/۵	-۱/۲	۹	۱۰/۲	۱۴/۸
اسفند	-۰/۱	۰/۹	۱/۱	۲۷/۹	۴۲/۹	۴۶/۱






شکل (۹) نمودار مقادیر رواناب روزانه شبیه‌سازی شده برای سال ۲۰۰۶-۲۱۰۰ با به کارگیری سناریوهای RCP 2.6 - الف: RCP 2.6 - ب: RCP 4.5 و ج: RCP 8.5

Fig (9) Estimated daily runoff graph in 2006-2100 by using scenarios a: RCP 2.6 - b: RCP 4.5 and c: RCP 8.5


شکل (۱۱) مقادیر رواناب ماهانه برآورد شده برای دوره‌ی ۲۰۰۶-۲۱۰۰ را نشان می‌دهد. همان‌طور که از شکل مذکور استنباط می‌شود، مقادیر رواناب ماهانه برآورد شده برای دوره‌ی ۹۵ سال آینده عموماً در ماه‌های آذر تا خرداد، کاهش داشته است. بیشترین کاهش در ماه فروردین مورد انتظار است. در ماه‌های تیر تا آبان نیز مقادیر رواناب شبیه‌سازی شده بیش از مقادیر ماهانه رواناب ماهانه در دوره‌ی پایه است (جدول ۳). بر این اساس می‌توان نتیجه گرفت که رواناب نیز در فصل سرد سال با کاهش و در فصل گرم با افزایش همراه خواهد بود. مطالعات چانگ و یونگ<sup>۱</sup> (۲۰۱۰)، فوری<sup>۲</sup> و همکاران (۲۰۱۲)، مشکین نژاد و همکاران (۲۰۱۳) نیز حاکی از تغییر در مقادیر رواناب در دوره‌های آینده می‌باشد.

1- Chang and Jung

2- Furey



شکل (۱۰) مقادیر رواناب ماهانه دوره‌ی پایه و رواناب ماهانه برآورد شده از طریق مدل  
Fig (10) Monthly runoff and monthly estimated runoff by model in base period



شکل (۱۱) نمودار مقادیر رواناب ماهانه شبیه‌سازی شده برای سال ۲۱۰۰-۲۰۰۶ با به کارگیری سناریوهای RCP 2.6 - RCP 4.5 - RCP 8.5 و RCP 8.5

Fig (11) Estimated monthly runoff graph in 2006-2100 by using RCP 2.6 - RCP 4.5 and RCP 8.5 scenarios

تغییر در زمان فصل بارش، تغییر در نقش آن را به دنبال خواهد داشت. زیرا شرایط اقلیمی فصول سرد و گرم موجب می‌شود که بارش باریده در فصل سرد تأثیری متفاوت از بارش فصل گرم داشته باشد. از آنجا که دمای بالا، هدر رفت آب از طریق تبخیر را به دنبال

دارد، بارش رخ داده در فصل سرد به دلیل دمای پایین‌تر و نیز کمتر بودن رشد گیاه در این فصل، بیشتر امکان تبدیل به رواناب را دارد. در صورتی که بارش فصل گرم به دلیل توان تبخیری بالای محیط، هدر رفت بیشتری دارد. همچنین بارش فصل گرم به علت رشد گیاهان، بیشتر به مصرف گیاه رسیده و از این رو کمتر به رواناب تبدیل می‌شود. بنابراین می‌توان این‌طور بیان کرد که بارش در فصل سرد بارش موثر در تولید رواناب محسوب می‌شود. به بیان دیگر، بارش در فصل سرد اهمیت بالاتری از نظر تامین منابع آب خواهد داشت. از آنجا که در پژوهش حاضر، رواناب تنها از طریق بارش، شبیه‌سازی شده است، بنابراین می‌توان این‌طور استنباط کرد که افزایش رواناب در فصل گرم به دلیل در نظر نگرفتن عواملی مانند دما و مصرف گیاه و ... می‌باشد.

#### ۴- نتیجه‌گیری

در این تحقیق اثر تغییر اقلیم بر روی بارش و رواناب حوضه‌ی آبریز رود زرد مورد بررسی قرار گرفت. برای این منظور از داده‌های بارش روزانه ایستگاه باغملک و رواناب روزانه ایستگاه ماشین و مدل CanESM2 تحت سناریوهای RCP 2.6، RCP 4.5 و RCP 8.5 بهره گرفته شد. سه متغیر از فراسنج‌های مدل مورد استفاده از طریق شاخص همبستگی و همبستگی جزئی و نیز روش حذف پس‌رونده به عنوان متغیرهای پیش‌بینی‌کننده‌ی انتخاب گردید. برای ریزمقیاس‌نمایی از روش شبکه‌ی عصبی مصنوعی استفاده و داده‌های روزانه بارش برای دوره‌ی آماری ۲۰۰۶-۲۱۰۰ شبیه‌سازی شد. برای شبیه‌سازی رواناب دوره‌ی مذکور از رگرسیون خطی استفاده و رواناب روزانه نیز برای این دوره برآورد گردید. نتایج حاکی از وجود روند کاهشی بارش سالانه در دوره‌ی ۲۰۰۶-۲۱۰۰ بر اساس هر سه سناریو می‌باشد. کمترین روند کاهشی در بارش سالانه برآورد شده بر اساس سناریوی RCP 2.6 کمینه و بیشترین روند کاهشی در بارش سالانه برآورد شده بر اساس سناریوی RCP 8.5 دیده می‌شود. بررسی‌های ماهانه نشان می‌دهند که در ماه‌های آبان تا دی، مقادیر بارش ماهانه برآورد شده برای دوره‌ی ۹۵ سال آینده کاهش داشته است. در ماه‌های بهمن تا آبان نیز مقادیر بارش شبیه‌سازی شده بیش از مقادیر ماهانه بارش در دوره‌ی پایه

می‌باشد. بر این اساس می‌توان گفت که بارش در فصل سرد رو به کاهش و در فصل گرم با افزایش همراه خواهد بود. رواناب نیز در ماه‌های بهمن تا خرداد در دوره‌ی پایه کمتر از رواناب مشاهداتی و در ماه‌های تیر تا دی در دوره‌ی پایه بیشتر از رواناب مشاهداتی برآورد شده است. این مسئله به این دلیل است که برای مدل‌سازی تنها از بارش به عنوان متغیر مستقل استفاده شده است. در صورتی که رواناب، علاوه بر بارش، از عوامل دیگری مانند آب چشمه‌ها و ... نیز متأثر می‌شود. در ماه‌های آذر تا خرداد، مقادیر رواناب ماهانه برآورد شده برای دوره‌ی ۹۵ سال آینده کاهش داشته است. در ماه‌های تیر تا آبان نیز مقادیر رواناب شبیه‌سازی شده بیش از مقادیر ماهانه رواناب ماهانه در دوره‌ی پایه می‌باشد. لازم به ذکر است که بیشینه‌ی بارش برآورد شده برای دوره ۹۵ سال آینده در ماه اسفند و بیشینه رواناب برآورد شده برای این دوره در ماه فروردین دیده می‌شود. این مسئله تأخیر در رخداد اوج رواناب پس از رخداد اوج بارش را نشان می‌دهد. البته بیشینه بودن رواناب در ماه فروردین می‌تواند به دلیل آب حاصل از ذوب برف نیز باشد که نیازمند بررسی بیشتر است. بر این اساس می‌توان گفت که رواناب نیز در فصل سرد با کاهش و در فصل گرم با افزایش همراه خواهد بود. افزایش بارش و رواناب در فصل گرم می‌تواند ناشی از افزایش بارش‌های محلی باشد. به عبارت دیگر می‌توان افزایش بارش‌های محلی ناشی از گرمایش جهانی در دوره‌های آینده را محتمل دانست.

۵- منابع

**-Reference**

- Abbaspour. Karim C, Faramarzi. Monireh, Seyed Ghasemi. Samaneh and Yang. Hong (2009). Assessing the impact of climate change on water resources in Iran, *Water Resources Research*, Vol. 45.
- Abdul Baten. Mohammed and Titumir. Rashed Al Mahmud (2016). Environmental challenges of trans-boundary water resources management: the case of Bangladesh, *Water resources management*, 2: 13-27.
- Aggarwal. K. K, Singh. Yogesh, Chandra. Pravin and Puri. Manimala (2005). Bayesian Regularization in a Neural Network Model to Estimate Lines of Code Using Function Points, *Journal of Computer Sciences* 1 (4): 505-509.
- Aichouri. I, Hani. A, Bougherira. Nabil. Diabri. L, Chaffai. H and Lallahem. S (2015). River flow model using artificial neural networks, *Energy Procedia* 74, 1007-1014.
- Altaf. Yasir, Manzoor Ahmad. Ahanger and Mohd. Fahimuddin (2017). MLR Based Statistical Downscaling of Temperature and Precipitation in Lidder Basin Region of India, *Environ Pollut Climate Change*, Vol. 1, 1-7.
- Amin, S and Roozbahani, A (2002). Simulation of Surface Runoff and Evapotranspiration of Rood Zard Basin with Stanford-4 Model, *Agricultural science and technology and natural resources*, 6(3).
- Anvari Tafti, S., Saghafian, B. and Marid, S. (2011). River flow prediction with ANN models and its performance with SOI inputs, *Journal of Soil Conservation Research*, 18(1), 163-180.
- Asakereh, H. (2011). *Fundamentals of Statistical Climatology*, Zanjan University Press.
- Asakereh, H. and Akbar Zadeh, Y. (2017). Assessment of climate change in Tabriz synoptic station Using Statistical Downscaling of canESM2 Climate Change Model Output, *Geography and environmental hazards*, 21, 153-174.
- Brekke. Levi D., Kiang. Julie E, J. Rolf. Olsen, Pulwarty. Roger S, Raff. David A, Turnipseed. D. Phil, Webb. Robert S and White. Kathleen D. (2009).

Climate Change and Water Resources Management: A Federal Perspective, U.S. Geological Survey, Reston, Virginia.

Chang. Heejun and Jung. Il-Won (2010). Spatial and temporal changes in runoff caused by climate change in a complex large river basin in Oregon, *Journal of Hydrology* 388, 186–207.

Charron, I. (2014). A Guidebook on Climate Scenarios: Using Climate Information to Guide Adaptation Research and Decisions. Ouranos, 86 p.

Fatahi, I et al (2012). Prediction of North Karun River Flow Using Artificial Neural Network, *Geographical Research Quarterly*, year 27, N 104, 51-77.

Fathian, H and Hormozi Nejad, I (2011). Predicting the Quantitative and Qualitative Parameters of the Karun River Flow (Mollasani-Farsiab interval), Using Artificial Neural Networks, *Wetland Scientific Journal*, Islamic Azad University of Ahvaz, year 2, N 8, 29-46.

Finnis. Joel, Holland. Marika M, Serreze. Mark C and Cassano. John J (2007). Response of Northern Hemisphere extratropical cyclone activity and associated precipitation to climate change, as represented by the Community Climate System Model, *Journal of Geophysical Research*, Vol 115.

Furey. Peter, Kampf. Stephanie, Lanini. Jordan S and Dozier. Andre Q (2012). A Stochastic conceptual Modeling Approach for Examining the Effects of Climate Change on Streamflows in Mountain Basins, *Journal of Hydrometeorology*, Vol. 13.

Ghorbani, M and Dehghani, R (2017). Comparison of Bayesian Neural Network, Artificial Neural Network and Gene Expression Planning Methods in River Water Quality Analysis (Case Study: Balkhlochai River), *Watershed Management Journal*, year 8, No. 15, 13-24.

Hardi, J. (2012). *Climate change causes, effects and solutions*, translated by Khazaneh Dari et al, Papoli Publication, second edition.

Jahanbakhsh Asl, S et al., (2016). The Impact of Climate Change on Temperature and Precipitation Considering the Uncertainty of Climate Models and Scenarios (Case Study: Urmia Shahr Chay Basin), *Hydrogeomorphology*, No. 7, 107-122.

- Janssen, E., D. J. Wuebbles, K. E. Kunkel, S. C. Olsen, and A. Goodman (2014). Observational- and model-based trends and projections of extreme precipitation over the contiguous United States, *Earth's Future*, 2, 99–113
- Joshi. Deepti, St-Hilaire. Andre, Daigle. Anik, Ouarda. Taha B.M.J (2013). Databased comparison of Sparse Bayesian Learning and Multiple Linear Regression for statistical downscaling of low flow indices, *Journal of Hydrology* 488, 136-149.
- Kamal, A and Masah Bavani, A (2012). Comparison of the uncertainty of AOGCM-TAR and AOGCM-AR4 climate change models on impact on basin runoff in the coming period, *Journal of Earth and Space Physics*, 38(3), 175-188.
- Karamouz, M and Araghi Nejan, Sh (2014). *Advanced Hydrology*, Amirkabir University of Technology Publications, Third Edition.
- Karamouz. M, Fahhahi. M, Nazif. S. and Rahimi Farahani. M. (2009). Long Lead Rainfall Prediction Using Statistical Downscaling and Artificial Neural Network Modeling, *Civil Engineering*, 16(2), 165-172.
- Kayri. Murat (2016). Predictive Abilities of Bayesian Regularization and Levenberg–Marquardt Algorithms in Artificial Neural Networks: A Comparative Empirical Study on Social Data, *Math. Comput. Appl.* 21, 20.
- Kumar. P. Sundara, Praveen. T.V and Prasad. M. Anjanaya (2016). Artificial Neural Network Model for Rainfall-Runoff -A Case Study, *International Journal of Hybrid Information Technology*, 9(3), 263-272.
- Mahdi Zadeh, S et al (2011). Impact of Climate Change on Precipitation in Golestan Dam Basin, *Journal of Water and Soil Conservation Research*, 18(3).
- Masoodian, A. and Kaviani, M. (2008). *Iran Climatology*, Isfahan University Press.
- Meshkin Nezhad. Sina, Mashal. Mahmud, Hedayat. Najaf (2013). Simulation of the Climate Change Impact on Runoff in the Dez Dam Area, *International Journal of Agriculture and Crop Sciences*, Vol. 6 (3), 121-126.
- Mir Akbari, M et al (2018). Performance Evaluation of CMIP5 Series Model in Simulating and Predicting Climate Parameters of Rainfall, Temperature and

Wind Speed (case Study: Yazd Province), *Natural Geography Research*, 50(3), 593-609.

Palazzi, E., J. von Hardenberg, and A. Provenzale (2013). Precipitation in the Hindu-Kush Karakoram Himalaya: Observations and future scenarios, *J. Geophys. Res. Atmos.*, 118, 85–100.

Poor Mohammadi, S et al (2017). Investigation of Climate Change Impacts on Tuyserkhan Watershed Climatic Parameters Using General Barley Circulation Models, *Hydrogeomorphology*, No. 12, 89-110.

Rezaei, M et al (2014). Evaluation of the Performance of SDSM Statistical Downscaling Model in Predicting Temperature Parameters in Two Dry and Extra Dry Climates (Kerman and Bam), *Watershed Management Research Paper*, year 5, No 10, 117-131.

Rostam Afshar, N et al (2006). Simulation and prediction of river flow using neural network and Fourier model, *Iranian Water Resources Research*, year 2, No. 1, 36-44.

Samadi Neghab et al., (2011). Application of SDSM Model to Downscaling GCM Data Case Study: Station Climate Forecasting in Iran, *Climatological Research*, No. 5-6.

Sharifi, E., Saghafian, B., & Steinacker, R. (2019). Downscaling satellite precipitation estimates with multiple linear regression, artificial neural networks, and spline interpolation techniques. *Journal of Geophysical Research: Atmospheres*, 124, 789–805.

Taei Semiromi, S et al (2014). Simulation and Prediction of Some Climate Variables by SDSM Multiple Linear Model and Barley General Circulation Models (Neyshabur Watershed), *Journal of Human and Environment*, No. 28, 1-15.

Zorzetto, E., & Marani, M. (2019). Downscaling of rainfall extremes from satellite observations. *Water Resources Research*, 55, 156–174.