

عملکرد مدل‌های AR4 در شبیه‌سازی پارامترهای اقلیمی دما و بارش با شبکه عصبی مصنوعی (مطالعه موردی: حوضه آبخیز قره‌سو)

وحید کاکاپور^۱ و مریم بیاتی خطیبی^{۲*}

۱. دانشجوی دکتری سنجش از دور و سیستم اطلاعات جغرافیایی، گروه سنجش از دور، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز

۲. استاد ژئومورفولوژی گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز

(تاریخ دریافت ۱۴۰۱/۱۰/۱۵؛ تاریخ بازنگری ۱۴۰۱/۱۱/۱۱؛ تاریخ تصویب ۱۴۰۱/۱۲/۲۲)

چکیده

افزایش غلظت گازهای گلخانه‌ای در جو با توجه به فعالیت‌های انسانی مانند تغییرات کاربری و استفاده از سوخت‌های فسیلی به گرم شدن کره زمین و عدم تعادل انرژی جهانی منجر شده است. این افزایش در گازهای گلخانه‌ای موجب بروز پدیده‌ای به نام تغییر اقلیم شده است. در این تحقیق عملکرد ۴ مدل GCM به نام‌های HADCM3، CGCM3T63، NCARCCSM3، CSIROMK3.5 (از مجموعه مدل‌های AR4) تحت سناریوی A2 در شبیه‌سازی پارامترهای اقلیمی دمای میانگین و بارش حوضه قره‌سو با استفاده از شبکه عصبی مصنوعی (ANN) مورد ارزیابی قرار گرفتند. برای آموزش شبکه عصبی مصنوعی از مدل پرسپترون forward استفاده شد. مطابق با ارزیابی عملکرد مدل‌ها با استفاده از ضرایب حداکثر خطای مطلق، میانگین قدر مطلق خطا، جذر میانگین مربعات و ضریب تبیین، در بین مجموعه مدل AR4، به طور میانگین مدل NCARCCSM3 بهترین عملکرد را در شبیه‌سازی پارامترهای اقلیمی دمای حوضه قره‌سو دارد. این مدل همراه با CGCM3T63 کمترین اختلاف را با پارامتر اقلیمی دمای مشاهداتی دارند، در حالی که مدل CGCM3T63 کمترین اختلاف را با پارامتر اقلیمی بارش مشاهداتی دارند. همچنین نتایج نشان داد مدل‌های CSIROMK3.5 و NCARCCSM3 بیشترین اختلاف را به ترتیب با پارامترهای اقلیمی دما و بارش مشاهداتی دارند. طبق نتایج شبکه عصبی ضریب تبیین برای دو پارامتر اقلیمی دما و بارش به طور میانگین به ترتیب ۰/۹۷ و ۰/۷۳ برای کل حوضه به دست آمد که نشان‌دهنده دقت شبکه عصبی در شبیه‌سازی این پارامتر دارد.

واژه‌های کلیدی: تغییر اقلیم، مدل‌های گردش عمومی جو، شبکه عصبی مصنوعی، قره‌سو، شبکه عصبی چندلایه.

مقدمه

پدیده تغییر اقلیم و تأثیرات آن به عنوان یکی از چالش‌های مهم پیش رو در بخش‌های کشاورزی و منابع آب و در نهایت، در ویژگی‌های خاک است. افزایش غلظت گازهای گلخانه‌ای در جو با توجه به فعالیت‌های انسانی مانند تغییرات کاربری و وابستگی به سوخت‌های فسیلی به گرم شدن کره زمین و عدم تعادل انرژی جهانی منجر شده است [۱].

روند گرم شدن جهانی در قرن ۲۱ توسط تمام گزارش‌های RSPs پیش‌بینی شده است که مقدار این افزایش برای گزارش‌های RSPs2.6، RSPs4.5، RSPs6 و RSPs8.5 به ترتیب ۰/۳-، ۱/۷-، ۲/۶-، ۱/۱-، ۱/۴-، ۳/۱- و ۲/۶- درجه سانتی‌گراد نسبت به دوره ۱۹۸۶-۲۰۰۵ است. در این زمینه شاه‌کرمی و همکاران (۲۰۱۷) سناریوهای تغییر اقلیم دما و بارندگی در حوضه آبخیز زاینده‌رود را با استفاده از هفت مدل AOGCM و سناریوی انتشار A2 تا سال ۲۱۰۰ تولید کردند. نتایج حاصل از تحقیق آن‌ها نشان داد در منطقه مطالعه‌شده، مدل HADCM3 عملکرد بهتری نسبت به سایر مدل‌ها نشان می‌دهد [۲]. کامل و همکاران علمی وی (۲۰۱۲) طی تحقیقی به ارزیابی عدم قطعیت ۹ مدل از مدل‌های AOGCM-AR4 و دو مدل هیدرولوژیکی را در تخمین دما، بارش و رواناب حوضه قره‌سو پرداختند. نتایج پژوهش این محققان بیانگر آن بود که از بین ۹ مدل AOGCM-AR4 مدل HADCM3 بهترین عملکرد را در بین مدل‌ها در شبیه‌سازی بارش و دما دارد [۳]. همچنین این محققان با مقایسه عدم قطعیت مدل‌های تغییر اقلیم AOGCM-TAR و AOGCM-AR4 در تأثیر بر رواناب حوضه قره‌سو، نشان دادند مدل‌های AOGCM-AR4 نسبت به مدل‌های AOGCM-TAR قطعیت کمتری دارند، ولی در عین حال، عملکرد بهتری را در شبیه‌سازی دما و بارش در حوضه‌ای مانند حوضه قره‌سو نشان می‌دهند. آباسید و همکاران (۲۰۰۹) تأثیر تغییر اقلیم را بر پارامترهای اقلیمی نیمه شمالی کشور با دو مدل گردش عمومی HADCM2 و ECHAM4 بررسی کردند [۴]. نتایج ارزیابی آن‌ها نشان داد مدل HADCM2 عملکرد بهتری نسبت به مدل ECHAM4 در شبیه‌سازی پارامترهای اقلیمی در دوره تاریخی دارد. علاوه بر آب، تغییرات در میزان رطوبت ناشی از تغییرات اقلیمی روی خاک نیز مهم است. های‌هو و همکاران (۲۰۱۴) تأثیر

تغییر اقلیم در مقیاس منطقه‌ای را با ۹ مدل AOGCM و A2، A1F1 و B1 مورد آزمایش قرار دادند [۵]. نتیجه این مطالعه در تغییرات فصلی بارش و دما و تأثیرات آن‌ها روی رواناب و پارامترهای رطوبت خاک نتایج ارزنده‌ای را ارائه داد. آن‌ها نشان دادند مدل HADCM3 و CGCM2 بهترین عملکرد را در شبیه‌سازی بارش و دما ایفا می‌کند و تغییرات روی رطوبت خاک هم قابل ملاحظه است. چوب‌دار و همکاران طی پژوهشی (۲۰۰۷) ورودی ماهانه دریاچه سد شهید مدنی تبریز را بر اساس تأثیر عناصر اقلیمی با استفاده از شبکه‌های عصبی پیش‌بینی کردند [۶]. نتایج پژوهش آن‌ها بیانگر موفقیت این روش بود. اصغری مقدم و همکاران (۲۰۱۴) طی تحقیقی از شبکه‌های عصبی مصنوعی و فرمول تجربی ارائه‌شده برای تعیین تعداد گره‌های میانی جهت تهیه مدل پیش‌بینی بارش دشت تبریز استفاده کردند [۷]. بر اساس نتایج به‌دست‌آمده، بهترین مدل از یک شبکه پیشرو با شش گره ورودی، یک گره خروجی، یک لایه میانی و الگوریتم لونیبرگ-مارکوارت تشکیل شد.

هوشمند و همکاران (۲۰۱۹) نیز با استفاده از مدل‌های ارزیابی CPAP و تحت سناریوهای مختلف روی منابع آبی حوضه سد سلمان فارسی [۸]، کالاکلی و همکاران (۲۰۲۲) با شبیه‌سازی‌های اثرات تغییر اقلیم با مدل‌های اقلیمی CMIP بر رواناب‌ها در حوضه بختگان [۹] و آذرناوان و براتی (۲۰۲۱) با استفاده از سناریوهای تغییر اقلیم و تأثیر آن بر بارش در دشت میناب [۱۰]، بررسی‌هایی انجام دادند و اثرات تغییر اقلیم بر منابع آبی را تأیید کردند.

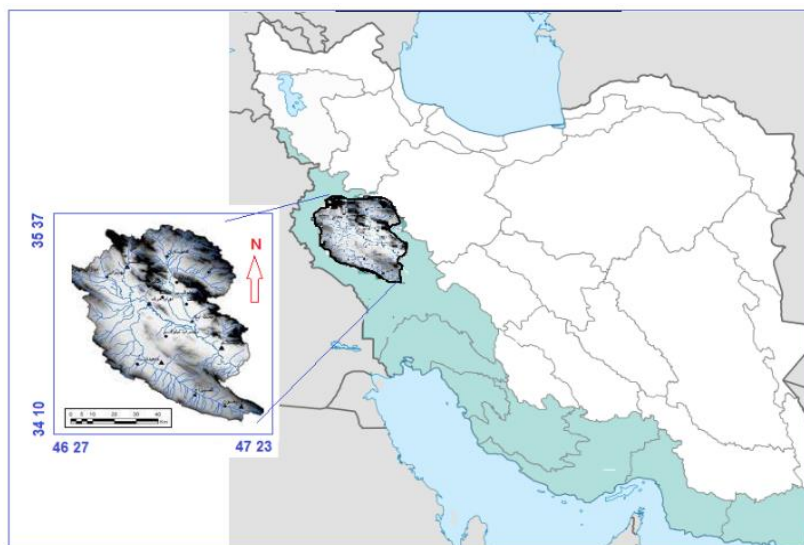
با توجه به اینکه حوضه قره‌سو طی سه دهه گذشته از نظر مقدار بارش و دما دچار تغییرات عمده‌ای شده است و به نظر می‌رسد که این تغییرات در رواناب‌ها و همچنین در رطوبت خاک نیز خودنمایی کرده، سعی شده است در این مقاله، با هدف بررسی دقیق میزان تأثیرات در تغییرات بارش و در پارامترهای مورد نظر در یک حوضه غربی کشور بررسی شود. بنابراین، با به‌کارگیری مدل‌های معتبر در این پژوهش و با منظور بررسی عدم قطعیت مدل‌ها GCM از چهار مجموعه مدل‌های AR4 به نام‌های HADCM3، CGCM2، CSIRO3.5 و NRCSSM تحت سناریوی A2 بارش در حوضه آبخیز قره‌سوی کرمانشاه استفاده شده است.

مواد و روش‌ها

منطقه مورد مطالعه

۲۲° تا ۴۶° طول شرقی در استان کرمانشاه واقع شده است که یکی از زیرحوضه‌های این حوضه است که حدود ۱۱/۴ درصد کل حوضه کرخه را در بر می‌گیرد. ۴۸ درصد این زیرحوضه کوهستانی و ۵۲ درصد آن را دشت تشکیل می‌دهد. حداکثر ارتفاع این زیرحوضه ۳۳۴۶ متر و حداقل ارتفاع آن ۱۱۸۰ متر است و رودخانه‌های اصلی این حوضه قره‌سو، دوآب‌مرگ و رازآور است و متوسط بارندگی این حوضه بین ۳۰۰ تا ۸۰۰ میلی‌متر است.

حوضه آبخیز کرخه به مساحت ۵۰۷۴۶ کیلومترمربع در غرب کشور به ۵ زیرحوضه تقسیم شده است، که در مناطق میانی و جنوب غربی رشته‌کوه‌های زاگرس و بین ۶° تا ۴۶° طول شرقی و ۵۸° تا ۳۰° عرض شمالی قرار گرفته است (شکل ۱ و جدول ۱). حوضه آبخیز قره‌سو با مختصات جغرافیایی ۳۰° تا ۳۴° عرض شمالی و ۵۴° تا ۳۴° عرض



شکل ۱. موقعیت حوضه قره‌سو کرمانشاه

جدول ۱. وضعیت ایستگاه‌های مورد نظر

نام ایستگاه	نوع ایستگاه	ارتفاع از سطح دریا (متر)	طول جغرافیایی	عرض جغرافیایی
اسلام‌آباد غرب	سینوپتیک	۱۳۴۸	۲۸°-۴۶°	۰۷°-۳۴°
کرمانشاه	سینوپتیک	۱۳۱۸	۰۹°-۴۷°	۲۱°-۳۴°
روانسر	سینوپتیک	۱۳۴۵	۳۹°-۴۶°	۴۳°-۳۴°

در ژاپن. از آنجا که مهم‌ترین ورودی این مدل‌ها، میزان انتشار گازهای گلخانه‌ای در دوره‌های آتی بوده و از طرفی تعیین میزان انتشار این گازها در دوره‌های آتی به طور قطعی امکان‌پذیر نیست، سناریوهای مختلفی که دربرگیرنده چگونگی تغییرات این گازها در آینده است ارائه شده که سناریوهای انتشار (Emission Scenario) نامیده می‌شوند (IPCC-TGCI, 1999). سری جدید سناریوهای انتشار را به نام SRES ارائه داد. در این پژوهش از سناریوی A2 که از جمله سناریوهایی است که بیشترین کاربرد را در میان سناریوهای تغییر اقلیم دارد استفاده شده است (جدول ۲).

تولید سناریوهای اقلیمی برای دوره آتی

تا کنون مدل‌های گردش عمومی مختلفی در مراکز مختلف تحقیقاتی تدوین و طراحی شده است. از جمله می‌توان به مدل‌های CSIRO, HADCM3, ECHAM4, GCM2, GFDL-30, NCAR و CCSR اشاره کرد [۱۱]. این مدل‌ها در مراکز مختلفی اجرا می‌شوند، از جمله مدل CSIRO-Mk2 در مرکز تحقیقاتی CSIRO در استرالیا، مدل‌های HADCM2 و HADCM3 در مرکز تحقیقاتی HCCPR در انگلیس، مدل GCM1 و GCM2 در مرکز CCCMA در کانادا، مدل NCAR1 در مرکز NCAR در آمریکا و مدل‌های CCSR و NIES در مراکز با همین نام

جدول ۲. سناریوهای اصلی مورد نظر IPCC برای آینده [۹]

سناریو	مشخصات
A1	رشد جمعیت کم، رشد اقتصادی زیاد، نوآوری‌ها در فناوری زیاد، همگرایی بین نواحی مختلف دنیا زیاد، کاهش اختلاف بین درآمد سرانه در سطح دنیا، تعاملات فرهنگی و اجتماعی زیاد
A2	ناهمگونی در دنیا زیاد، رشد جمعیت زیاد، رشد اقتصادی به صورت منطقه‌ای، توسعه و تغییرات فناوری به صورت منطقه‌ای (و نه جهانی)
B1	تأکید به دستیابی به راه‌حل‌های جهانی در مورد مسائل زیست‌محیطی، اجتماعی و اقتصادی (این سناریو مزایای سناریوی A1 را در کنار توسعه پایدار در نظر می‌گیرد)
B2	رشد جمعیت و رشد اقتصادی متوسط، رشد فناوری از سناریوی A1 و B1 کمتر است. تأکید به دستیابی به راه‌حل‌های محلی در مورد مسائل زیست‌محیطی، اجتماعی و اقتصادی.

ریزمقیاس‌سازی

یکی از محدودیت‌های اصلی در استفاده از خروجی مدل‌های چرخش عمومی، عدم تطابق قدرت تفکیک مکانی آن‌ها با دقت مورد نیاز مدل‌های هیدرولوژیک است. شبکه‌بندی این مدل‌ها همچنین برای کاربرد به‌خصوص در مناطق کوهستانی و شبیه‌سازی پارامترهای اقلیمی نظیر بارش و دما نامناسب است (IPCC-TGCI, 1999). برای حل این مشکلات با استفاده از تکنیک‌های ریزمقیاس‌سازی، خروجی‌های GCM را به متغیرهای سطحی در مقیاس حوضه مورد مطالعه تبدیل می‌کنند.

شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی (ANN) ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی گرفته شده و مانند مغز به پردازش اطلاعات می‌پردازد. این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده به‌هم‌پیوسته تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کند. در این شبکه‌ها به کمک دانش برنامه‌نویسی، ساختار داده‌ای طراحی می‌شود که می‌تواند همانند نرون عمل کند که به این ساختار داده‌ها Node گفته می‌شود. بعد با ایجاد شبکه‌ای بین این Nodeها و اعمال یک الگوریتم آموزشی به آن، شبکه را آموزش می‌دهند.

شبکه‌های پرسپترون چندلایه

شبکه‌های پرسپترون چندلایه از نوع شبکه‌های عصبی پیشخور هستند که یکی از مدل‌های پرکاربرد شبکه عصبی مصنوعی در مدل‌سازی و پیش‌بینی عناصر اقلیمی است [۱۳]. در شبکه‌های پرسپترون چندلایه هر نرون در هر لایه به تمام نرون‌های لایه قبل متصل است. به چنین

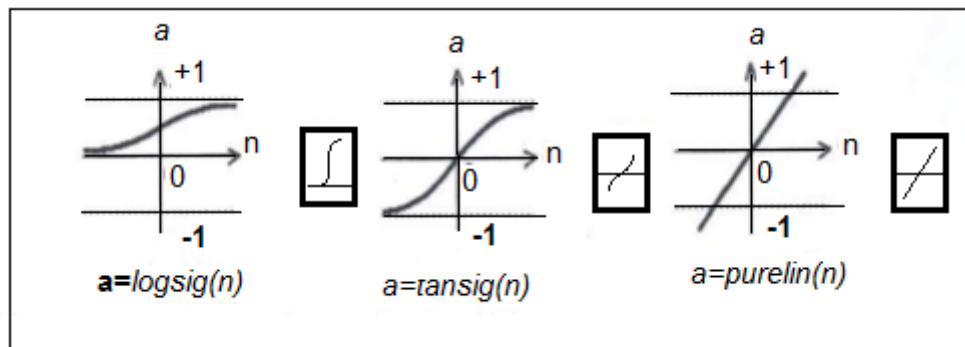
شبکه‌هایی، شبکه‌های کاملاً مرتبط گویند [۱۴]. در مورد مسئله برآورد عناصر جوی، شبکه عصبی باید قادر به نگهداری اطلاعات و دیده‌بانی‌های گذشته باشد به همین دلیل و با توجه به توانایی‌های شبکه پرسپترون و قابلیت آموزش و یادگیری زیاد این نوع شبکه عصبی، استفاده از آن به منظور برآورد عناصر جوی در تحقیقات گذشته توصیه شده است [۱۳]. در این بررسی نیز با توجه به کاربرد شبکه‌های پرسپترون چندلایه پیشخور در مسائل پیش‌بینی و قابلیت زیاد آن‌ها در تعمیم نتایج، از این شبکه‌ها برای پیش‌بینی میانگین دما و بارش ماهانه ایستگاه‌های مربوط به حوضه استفاده شده است.

تعداد لایه‌های پنهان

هر تابع می‌تواند حداکثر با سه لایه پنهان تقریب زده شود. البته شبکه با یک لایه پنهان آموزش داده می‌شود که در صورت عملکرد نامناسب، تعداد لایه‌های پنهان افزایش خواهد یافت. در این پژوهش با توجه به تعیین بهترین عملکرد از سه لایه پنهان استفاده شد.

تعداد نرون‌های لایه پنهان

اندازه یک لایه مخفی عموماً به طور تجربی به دست می‌آید. برای یک شبکه عصبی با اندازه معقول تعداد نرون‌های لایه مخفی با یک نسبت کوچکی از تعداد ورودی‌ها انتخاب می‌شود. اگر شبکه MLP به جواب مطلوب همگرا نشود، تعداد نرون‌های لایه مخفی را افزایش می‌دهند و اگر شبکه همگرا شد و از قدرت تعمیم خوبی هم برخوردار بود، در صورت امکان تعداد نرون‌های مخفی کمتری را مورد آزمایش قرار می‌دهند.



شکل ۲. توابع متحرک [۱۵]

کارایی بهتر مدل و چنانچه صفر باشد، نشان‌دهنده نبود خطا در برآورد مدل است و مقدار RS_{qr} نشان‌دهنده ارتباط بین داده‌های مشاهداتی و برآوردشده، به طوری که هرچه این مقدار به یک نزدیک باشد، نشان‌دهنده ارتباط قوی بین داده‌های مشاهداتی و برآوردشده است.

$$AME = \max(|Q_i - \hat{Q}_i|) \quad (۱) \quad \text{حداکثر خطای مطلق}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_i - \hat{Q}_i| \quad (۲) \quad \text{میانگین قدر مطلق خطا}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{n}} \quad (۳) \quad \text{جذر میانگین مربعات}$$

$$RS_{qr} = \left[\frac{\sum_{i=1}^n (Q_i - \bar{Q})(\hat{Q}_i - \bar{\hat{Q}})}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2 \sum_{i=1}^n (\hat{Q}_i - \bar{\hat{Q}})^2}} \right] \quad (۴) \quad \text{ضریب تبیین}$$

یافته‌های تحقیق

ارزیابی عملکرد بین مدل‌ها با استفاده از شبکه عصبی مصنوعی

ابتدا میانگین دمای ماهانه و بارش ماهانه ۴ مدل GCM به نام‌های HADCM3، CGCM3.5، CSIROMK3.5 و NCRCCSM (از مجموعه مدل‌های AR4) به صورت بزرگ‌مقیاس برای حوضه قره‌سو تحت سناریوی A2، از مرکز پیش‌بینی متغیرهای محیطی کانادا <http://www.cics.uvic.ca/scenarios/index.cgi> قابل دسترس استخراج شد. برای ریزمقیاس کردن پارامترهای اقلیمی هر یک از این مدل‌ها نسبت به هر ایستگاه هواشناسی از شبکه عصبی مصنوعی (ANN) در نرم‌افزار متلب استفاده شد. برای این کار بین پارامترهای

توابع محرک

نرون‌ها می‌توانند از توابع محرک متفاوتی برای تولید خروجی استفاده کنند؛ که از رایج‌ترین آن‌ها می‌توان به توابع لگاریتم سیگموئیدی، تانژانت سیگموئیدی و تابع محرک خطی اشاره کرد [۱۵]. در این پژوهش در تولید خروجی هر سه تابع مورد آزمون قرار گرفت.

روش‌های آموزش در شبکه‌های پرسپترون چندلایه

برای آموزش شبکه‌های عصبی چهار الگوریتم آموزشی مرسوم که بر اساس ساختار معروف پرسپترون چندلایه هستند، وجود دارد که این روش‌ها عبارت‌اند از: پس‌انتشار خطای بیشترین شیب (پس‌انتشار خطای استاندارد)، گرادیان مزدوج، شبه‌نیوتن و مارکوارت-لونبرگ. الگوریتم مارکوارت-لونبرگ از سال ۱۹۹۳ تا به امروز به عنوان سریع‌ترین روش آموزش شبکه‌های عصبی شناخته شده است [۱۶]. در این بررسی نیز از این الگوریتم استفاده خواهد شد. برای تعیین روند همبستگی بین داده‌های مشاهداتی و مدل‌ها در دوره واسنجی ۱۹۷۱-۱۹۹۵ از ضریب همبستگی^۱ استفاده شد [۱۷]. همچنین برای مقایسه عملکرد مدل‌ها در شبیه‌سازی پارامترهای اقلیمی در دوره ۱۹۹۶-۲۰۰۰ از چهار ضریب حداکثر خطای مطلق^۲، میانگین قدر مطلق خطا^۳، جذر میانگین مربعات^۴ و ضریب تبیین^۵ استفاده شد؛ که در این رابطه‌ها مقادیر RMSE و AME در بسیاری از روش‌های آماری معرف خطای مدل هستند، به طوری که هرچه مقادیر این پارامترهای آماری به صفر نزدیک‌تر باشد، نشان‌دهنده

1. Correlation coefficient
2. Max absolute error
3. mean absolute error
4. root-mean-square error
5. Russell Square

است. شکل‌های ۳ تا ۴ روند همبستگی بین پارامترهای دمای میانگین ماهانه و بارش ماهانه ایستگاه کرمانشاه به عموان نمونه با پارامترهای اقلیمی مدل‌های GCM را در مراحل آموزش، اعتبارسنجی، تست و مجموع این سه مرحله یعنی R نشان می‌دهد. ضریب همبستگی مربوط به سایر ایستگاه طی این مراحل در جدول‌های ۳ و ۴ مشاهده می‌شود.

ابتدا ذکر شد که برای آموزش شبکه داده‌های مربوط به هر ایستگاه و مدل به منظور آموزش وارد شبکه می‌شوند برای آموزش شبکه دوره ۱۹۷۱-۱۹۹۵ به عنوان مبنا قرار گرفت. پس از آموزش شبکه داده‌های هر مدل در دوره ۱۹۹۶-۲۰۰۰ برای هر ایستگاه ریزمقیاس شد.

مقایسه عدم قطعیت مدل‌ها در شبیه‌سازی دما و بارش

برای دوره ۱۹۹۶-۲۰۰۰

در شکل‌های ۱۱ تا ۱۶ به ترتیب مقایسه‌ای بین میانگین دما و بارش مشاهداتی ایستگاه‌ها با میانگین دما و بارش ریزمقیاس شده حوضه حاصل از نتایج شبیه‌سازی شبکه عصبی برای مجموعه مدل‌های AR4 در دوره ۱۹۹۶-۲۰۰۰ شده است.

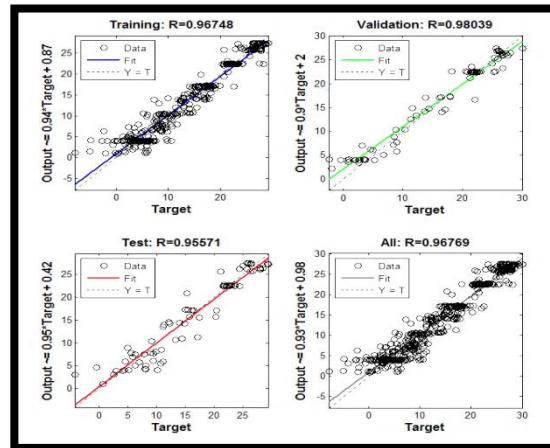
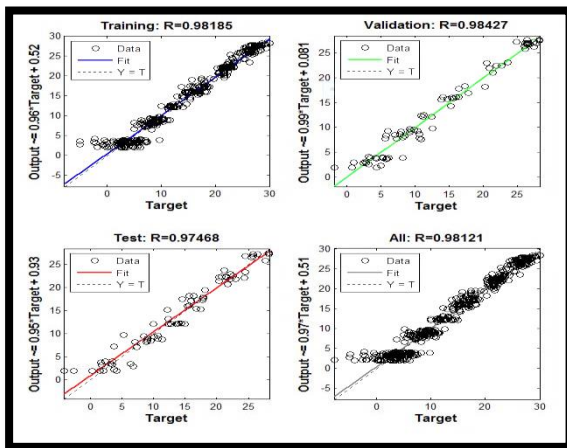
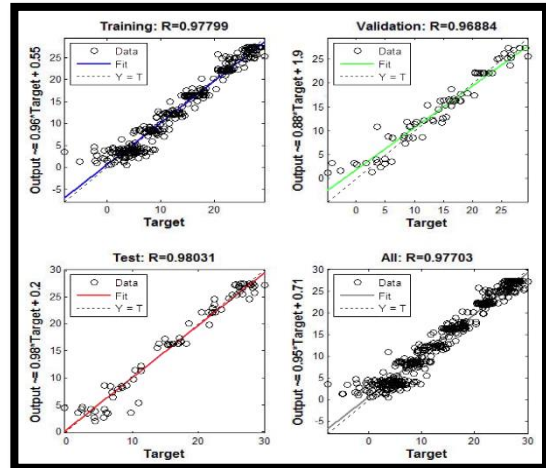
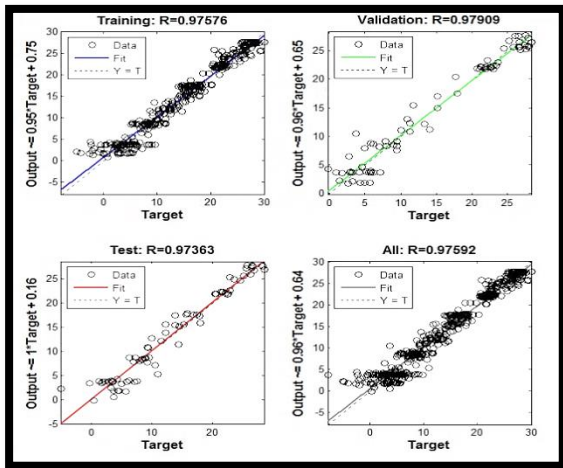
میانگین دمای مشاهداتی ایستگاه اسلام‌آباد غرب (شکل ۵) برای دوره ۱۹۹۶-۲۰۰۰ $13/73$ درجه سانتی‌گراد است و میانگین دمای ریزمقیاس شده حوضه برای هر یک از مدل‌های AR4 یعنی CSIRO MK3.5.HADCM3.CGCMT63 و NCARCCSM3 برای دوره ۱۹۹۶-۲۰۰۰ به ترتیب $13/41$ ، $13/22$ ، $14/08$ و $13/91$ درجه سانتی‌گراد است؛ و برای ایستگاه کرمانشاه (شکل ۶) میانگین دمای مشاهداتی برای دوره ۱۹۹۶-۲۰۰۰ $15/53$ درجه سانتی‌گراد است و میانگین دمای ریزمقیاس شده حوضه برای هر یک از مدل‌های AR4 به ترتیب ذکر شده برای دوره ۱۹۹۶-۲۰۰۰ $14/83$ ، $14/41$ ، $14/98$ و $14/93$ درجه سانتی‌گراد است. در ایستگاه روانسر میانگین دمای مشاهداتی برای دوره ۱۹۹۶-۲۰۰۰ $15/23$ درجه سانتی‌گراد است و میانگین دمای ریزمقیاس شده حوضه برای هر یک از مدل‌های AR4 برای دوره ۱۹۹۶-۲۰۰۰ به ترتیب $13/89$ ، $15/81$ ، $14/45$ و $14/28$ درجه سانتی‌گراد است (شکل ۷).

اقلیمی ایستگاه‌های هواشناسی و مدل‌ها ارتباط برقرار شد. درواقع پارامترهای اقلیمی هر یک از مدل‌ها به عنوان ورودی و پارامتر اقلیمی ایستگاه‌های هواشناسی به عنوان تابع هدف به شبکه عصبی وارد شد. برای آموزش شبکه از ۲۵ سال داده میانگین دما و بارش ماهانه استفاده و شبکه با ۳۰۰ داده آموزش داده شد. سپس با استفاده از نتایج این آموزش از روی ۵ سال باقی‌مانده (۶۰ داده) میانگین دما و بارش ماهانه مربوط به هر ایستگاه ریزمقیاس شد. درخور یادآوری است که دوره ۱۹۵۵-۱۹۷۱ به عنوان دوره آموزش شبکه و دوره ۱۹۹۶-۲۰۰۰ به عنوان دوره صحت‌سنجی مبنا قرار گرفت. در این پژوهش از شبکه عصبی پرسپترون تحت عنوان ۳ لایه پنهان استفاده شد. برای آموزش شبکه حداقل از یک نرون استفاده شد و تا حداکثر ۱۵ نرون ادامه می‌یابد. به طور میانگین در تمامی شبکه‌های ساخته شده تعداد نرون‌ها برای آموزش شبکه برای پارامتر دما بین ۲ تا ۴ و برای پارامتر بارش بین ۷ تا ۹ است. ضریب همبستگی نشان از کارایی شبکه برای همه ایستگاه‌های مورد نظر دارد.

آموزش شبکه و روند همبستگی بین ایستگاه‌ها مربوط به

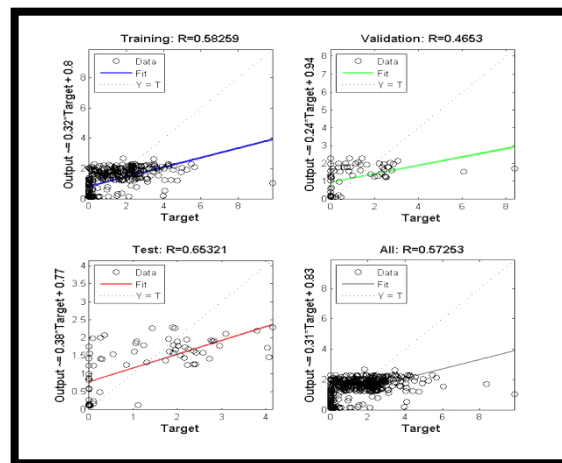
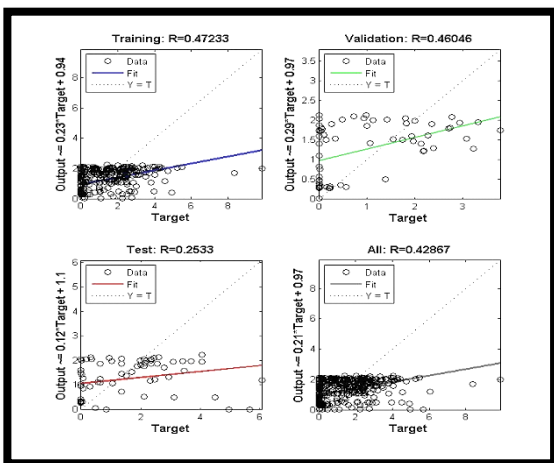
پارامتر اقلیمی دما

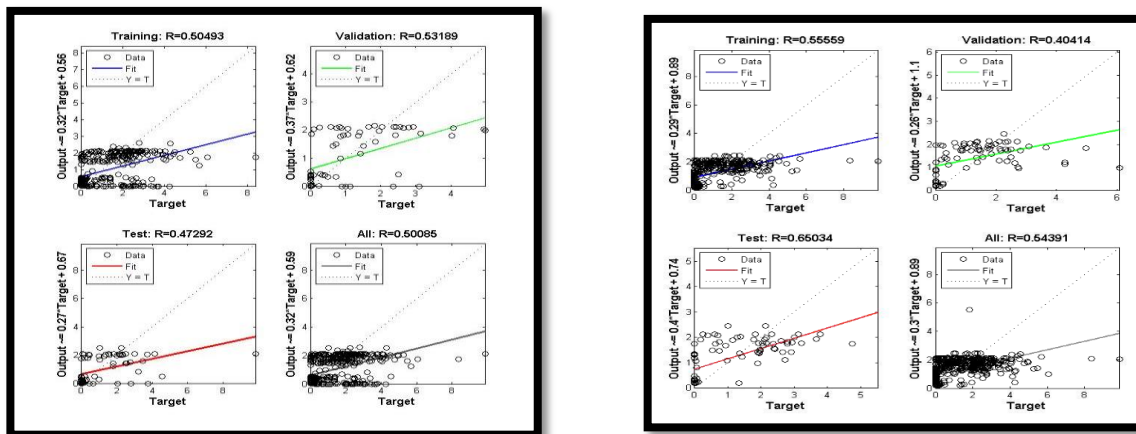
شکل‌های زیر روند همبستگی بین پارامتر اقلیمی دمای مشاهداتی ایستگاه‌های هواشناسی با پارامتر اقلیمی دمای خروجی هر یک از مدل‌های GCM به صورت بزرگ‌مقیاس را در دوره ۱۹۷۱-۱۹۹۵ نشان می‌دهد. محور افقی (X) نشان‌دهنده تابع هدف یا دمای مشاهداتی مربوط به هر ایستگاه است. محور عمودی (Y) نشان‌دهنده مقادیر دمای بزرگ‌مقیاس حاصل از خروجی مدل‌های GCM است. OUTPUT نشان داده شده روی محور Y رابطه بین داده‌های مشاهداتی دمای ماهانه ایستگاه‌ها و دمای ماهانه مدل‌های بزرگ‌مقیاس را نشان می‌دهد. مقدار R همبستگی بین مقادیر دمای مشاهداتی ایستگاه‌ها و دمای خروجی مدل‌های GCM را نشان می‌دهد. پارامتر R، ضریب همبستگی است و هر چه مقادیر OUTPUT به خط FIT نزدیک‌تر باشد یا به بیان دیگر، هر چه داده‌ها به خط FIT نزدیک‌تر و پراکنش مناسب داشته باشد، نشان‌دهنده همبستگی بیشتر بین مقادیر دمای مشاهداتی ایستگاه‌ها با دمای حاصل از خروجی مدل‌های GCM



شکل ۳. آموزش شبکه و روند همبستگی بین ایستگاه کرمانشاه برای پارامتر دما: الف) مدل CGCMT63؛ ب) مدل CSIROMK3.5؛

پ) مدل HADCM3؛ ت) مدل NCRCCSM





ت

پ


شکل ۴- آموزش شبکه و روند همبستگی بین ایستگاه کرمانشاه برای پارامتر بارش: الف) مدل CGCMT63؛ ب) مدل NCRCCSM؛ پ) مدل HADCM3؛ ت) مدل CSIROMK3.5

جدول ۳. میزان ضریب همبستگی دما بین ایستگاهها و مدلها


ایستگاه	NCRCCSM	HADCM3	CGCMT63	CSIROMK3.5
کرمانشاه	۰/۹۸۱	۰/۹۶۷	۰/۹۷۷	۰/۹۷۵
اسلام آباد غرب	۰/۹۸۰	۰/۹۶۰	۰/۹۷۶	۰/۹۶۵
روانسر	۰/۹۷۳	۰/۹۰۵	۰/۹۶۴	۰/۹۵۶

جدول ۴. میزان ضریب همبستگی بارش بین ایستگاهها و مدلها


ایستگاه	NCRCCSM	HADCM3	CGCMT63	CSIROMK3.5
کرمانشاه	۰/۵۰۰	۰/۹۶۷	۰/۵۷۲	۰/۴۲۸
اسلام آباد غرب	۰/۷۱۲	۰/۵۵۷	۰/۵۶۰	۰/۶۷۷
روانسر	۰/۶۶۰	۰/۵۹۰	۰/۶۲۱	۰/۵۶۲



شکل ۵. مقایسه دمای مشاهداتی ایستگاه اسلام آباد غرب با دمای شبیه سازی شده مدلها در دوره صحت سنجی




شکل ۶. مقایسه دمای مشاهداتی ایستگاه کرمانشاه با دمای شبیه سازی شده مدلها در دوره صحت سنجی




شکل ۷. مقایسه دمای مشاهداتی ایستگاه روانسر با دمای شبیه‌سازی شده مدل‌ها در دوره صحت‌سنجی

میانگین بارش ریزمقیاس‌شده حوضه برای هر یک از مدل‌های AR4 به ترتیب ذکر شده برای دوره ۱۹۹۶-۲۰۰۰ ۳۳۵/۲۶ و ۴۳۸/۵۷، ۳۹۲/۴۰۵، ۵۱/۶۸ میلی‌متر است. در ایستگاه روانسر (شکل ۱۰) میانگین بارش مشاهداتی برای دوره ۱۹۹۶-۲۰۰۰ ۴۶۵/۳۸ میلی‌متر و میانگین بارش ریزمقیاس‌شده حوضه برای هر یک از مدل‌های AR4 برای دوره ۱۹۹۶-۲۰۰۰ به ترتیب ۶۱۲/۶۵، ۹۳/۴۵، ۵۵۶/۵۵۷ و ۵۰۵/۱۰ میلی‌متر است.


میانگین بارش مشاهداتی ایستگاه اسلام‌آباد غرب (شکل ۸) برای دوره ۱۹۹۶-۲۰۰۰ ۴۳۷/۷ میلی‌متر و میانگین بارش ریزمقیاس‌شده حوضه برای هر یک از مدل‌ها یعنی CSIROMK3.5، HADCM3، CGCMT63 و NCARCCSM برای دوره ۱۹۹۶-۲۰۰۰ به ترتیب ۴۰۲/۳۱، ۳۹۶/۷۴، ۴۲۲/۵۷ و ۴۱۷/۴۶ میلی‌متر است؛ و برای ایستگاه کرمانشاه (شکل ۹) میانگین بارش مشاهداتی برای دوره ۱۹۹۶-۲۰۰۰ ۳۳۱/۶۴ میلی‌متر است و



شکل ۸. مقایسه بارش مشاهداتی ایستگاه اسلام‌آباد غرب با بارش شبیه‌سازی شده مدل‌ها در دوره صحت‌سنجی




شکل ۹. مقایسه بارش مشاهداتی ایستگاه کرمانشاه با بارش شبیه‌سازی شده مدل‌ها در دوره صحت‌سنجی




شکل ۱۰. مقایسه بارش مشاهداتی ایستگاه روانسر با بارش شبیه‌سازی شده مدل‌ها در دوره صحت‌سنجی

است. همچنین مطابق با شکل ۱۲ میانگین بارش مشاهداتی حوضه برای دوره ۱۹۹۶-۲۰۰۰ ۴۱۱ میلی‌متر است و میانگین بارش ریزمقیاس‌شده حوضه برای هر یک از مدل‌های AR4 یعنی CSIROMK3.5، CGCMT63، HADCM3 و NCRCCSM برای دوره ۱۹۹۶-۲۰۰۰ به ترتیب ۴۹۵، ۵۴۰، ۴۸۶ و ۴۳۷ میلی‌متر است.

طبق نتایج شکل ۱۱ میانگین دمای مشاهداتی برای کل حوضه برای دوره ۱۹۹۶-۲۰۰۰ ۱۴/۸۳ درجه سانتی‌گراد است و میانگین دمای ریزمقیاس‌شده حوضه برای هر یک از مدل‌های AR4 یعنی CGCMT63، HADCM3، CSIROMK3.5، NCRCCSM برای دوره ۱۹۹۶-۲۰۰۰ به ترتیب ۱۴/۵۰، ۱۴/۴۸، ۱۴/۰۴ و ۱۴/۵۲ درجه سانتی‌گراد



شکل ۱۱. مقایسه دمای مشاهداتی کل حوضه با دمای شبیه‌سازی شده حاصل از خروجی مدل‌های AR4 در دوره صحت‌سنجی



شکل ۱۲. مقایسه بارش مشاهداتی کل حوضه با بارش شبیه‌سازی شده حاصل از خروجی مدل‌ها AR4 در دوره صحت‌سنجی

جدول ۵. ارزیابی عملکرد مدل‌ها در شبیه‌سازی دمای میانگین حوضه در دوره صحت‌سنجی (۱۹۹۶-۲۰۰۰)

مدل‌ها	AME	MAE	RMSE	R _{Sqr}
CSIROMK3.5	۲/۱۵	۱/۰۷	۱/۲۳	۰/۹۸۰
CGCMT63	۱/۹۵	۰/۹۹۰	۱/۱۵	۰/۹۹۱
HADCM3	۲/۱۳	۰/۹۱۳	۱/۰۸	۰/۹۸۶
NCRCCSM3	۱/۹۹	۰/۸۱۰	۰/۹۸۰	۰/۹۹۱

جدول ۶. ارزیابی عملکرد مدل‌ها در شبیه‌سازی بارش میانگین حوضه در دوره صحت‌سنجی (۱۹۹۶-۲۰۰۰)

مدل‌ها	AME	MAE	RMSE	RSqr
CSIROMK3.5	۳۵/۳۸	۱۳/۲۸	۱۷/۲۰	۰/۷۴۸
CGCM3T63	۳۷/۳۷	۱۴/۸۰	۱۸/۱۱	۰/۷۶۷
HADCM3	۳۸/۷۷	۱۴/۳۰	۱۷/۸۷	۰/۷۳۰
NCARCCSM3	۴۴/۳۲	۱۰/۲۶	۱۶/۵۵	۰/۷۰۷

بحث و نتیجه‌گیری

پدیده تغییر اقلیم و تأثیرات آن به عنوان یکی از چالش‌های مهم پیش رو در بخش‌های کشاورزی و رطوبت خاک و منابع آب و در نهایت، در ویژگی‌های فرسایش‌پذیری خاک است. افزایش غلظت گازهای گلخانه‌ای در جو با توجه به فعالیت‌های انسانی منجر به گرم شدن کره زمین و عدم تعادل انرژی جهانی شده است. برای اثبات تأثیرات تغییرات اقلیمی در مقیاس محلی و منطقه‌ای بر رواناب‌ها و پارامترهای اقلیمی، سناریوهای مختلفی طراحی، ارائه و به کار گرفته شده است که هر یک در محدوده مورد بررسی قابل تأیید، اثبات و یا رد است.

در محدوده مورد بررسی هم به عنوان یکی از محدوده‌های متأثر از تغییرات رخ داده، با پیش‌فرض تأثیر تغییرات اقلیمی، از یکی از مدل‌های معتبر استفاده شد و نتایج قابل تأملی به دست آمد. مطابق با ارزیابی عملکرد مدل‌های ارائه شده در جدول‌های ۵ و ۶ و با استفاده از ضرایب حداکثر خطای مطلق (AME)، میانگین قدر مطلق خطا (MAE)، جذر میانگین مربعات (RMSE) و ضریب تبیین (RSqr)، مشخص شد که در بین مجموعه مدل AR4، به طور میانگین مدل NCARCCSM3 بهترین عملکرد را در شبیه‌سازی پارامترهای اقلیمی دمای حوضه قره‌سو دارد. این مدل همراه با CGCM3T63 کمترین اختلاف را با پارامتر اقلیمی دمای مشاهداتی دارند که با نتایج ویلیام [۱۸] که محدوده مورد بررسی این محقق نیز مانند محدوده مورد بررسی در این تحقیق یک محدوده کوهستانی است، مطابقت دارد. در حالی که مدل CGCM3T63 کمترین اختلاف را با پارامتر اقلیمی بارش مشاهداتی گودرزی دارند [۱۹]. این مطلب نشان می‌دهد روابط استفاده شده در مدل‌های AR4 متفاوت، به یکدیگر نزدیک‌اند که این عامل باعث کاهش عدم قطعیت در خروجی‌های این مدل‌های جدید (۲۰۰۷) نسبت به مدل‌های قدیمی‌تر گروه ATR (۲۰۰۱) می‌شود. بنابراین

دلیل اصلی استفاده از مجموع مدل‌های AR4 همین امر بوده است [۲۰]. همچنین نتایج نشان داد مدل CSIROMK3.5 و NCARCCSM3 بیشترین اختلاف را به ترتیب با پارامترهای اقلیمی دما و بارش مشاهداتی دارند. طبق نتایج شبکه عصبی ضریب تبیین برای دو پارامتر اقلیمی دما و بارش به طور میانگین به ترتیب ۰/۹۷ و ۰/۷۳ برای کل حوضه به دست آمد که نشان‌دهنده دقت شبکه عصبی در شبیه‌سازی این پارامتر دارد، ولی با توجه به نتایج مشخص شد که داده‌های دمای میانگین شبیه‌سازی شده برای سناریوی A2 همبستگی بهتری با داده‌های مشاهداتی (در مقایسه با داده‌های بارندگی) داشته‌اند؛ به این دلیل است که تغییرپذیری دما نسبت به بارش کمتر است، چراکه دما یک متغیر پیوسته است و کمتر تحت تأثیر ناهنجاری‌های زمانی قرار می‌گیرد، در حالی که بارش به دلیل شرایط طبیعی و تغییرپذیری زیاد مکانی آن یک متغیر گسسته است؛ که با نتایج پژوهش تاعه سمرومی و همکاران، صمدی و گودرزی و همکاران (۲۰۱۵) مطابقت دارد [۲۱، ۲۲ و ۱۹].

در نهایت می‌توان به این نتیجه رسید که تغییرات اقلیمی در کل دنیا و در محدوده‌های مختلف کشور یک امر کاملاً جدی است و تأثیرگذار در پارامترهای اقلیمی و منابع آبی در مقیاس محلی است [۲۳-۲۶] و باید در مدیریت آب همواره مد نظر قرار گیرد.

منابع

- [1].Huang J, Zhang J, Zhang Z, Xu C,Wang B, Yao J. Estimation of future precipitation change in the Yangtze River basin by using statistical downscaling method. *Stoch Env Res Risk*.2016;25(6):781-792.
- [2].Shahkarami N, Masah bovani S, Morid S, And Golmokhtari, h. Uncertainty analysis models coupled atmosphere-ocean general -Grdsh -Atmsfr on temperature and precipitation scenarios of climate change on river basins, the technical workshop on climate change impacts on water resources management. Iranian National Committee on Irrigation and Drainage. 2017.

- [3]. Kamal A, Masah boani A. Evaluation of uncertainty AOGCM-AR4 models and hydrological models to estimate the temperature, rainfall and runoff Gharehsou affect climate change, *Journal of Water*. 2011;5 (9): 50-39.
- [4]. Abbasids F, Babaeian A, Habibi Now Khandan M, Golimokhtari L, Malboosi SH, And Askari SH. Evaluation of the effects of future climate change on precipitation and temperature, with the help of model SCENGEN MAGICC-. *Study of physical geography*. 2009;20(72): 109-91.
- [5]. Hayhoe K, Wake C.P, Huntington T.G, Luo L, Schwartz M.D, Sheffield J, Wood E, Anderson B, Bradbury J, DeGaetano A, Troy T.J, Wolfe D. Past and future changes in climate and Hydrological indicators in the US Northeast. *J. Clim Dyn*. 2014.2(28):381-407.
- [6]. Chobdar, A. The monthly reservoir inflow forecasting Shahid Madani under the influence of climatic elements by using artificial neural networks. PhD thesis - specialization. *Physical Geography, University of Tabriz*. 2007.
- [7]. Asghari Moghaddam A, norani V, Nadiry AS. Tabriz plain rainfall modeling using artificial neural networks. *Tabriz University of Agricultural Knowledge*. 2014.18(1): 15-1.
- [8]. Hoshmand K, D. Esmaeili, K., Sanaeinejad, S. Simulating the effects of climate change using CPAP evaluation model In the water resources of the watershed of the Salman Farsi dams , Iran *Irrigation and Drainage Journal*, 2019, 13(2): 258-243.
- [9]. Kalaki, F., Shokri, V., Ramazani, H. Simulating the effects of climate change using climate models CMIP5, CMIP6 on runoff using the model SWAT. A case study of Bakhtegan watershed. *Iranian Water Resources Research Journal*, 2022. 17(3): 359-345.
- [10]. Azarnivan, H and Brati , A. Simulation and prediction of climatic ranges of temperature and precipitation in arid regions. A case study of Minab plain, *Gegraphic Journal*, 2021, 18(66): 127-110.
- [11]. IPCC-TG CIA. Guidelines on the use of scenario data for climate impact and adaptation assessment. Carter. T.R.M. Hulme and M. Lal (Eds.). Version 1.69pp. Intergovernmental Panel on Climate Change, Task Group on Scenarios for Climate Impact Assessment. 1999.
- [12]. IPCC. Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change Intergovernmental Panel on Climate Change Cambridge. United Kingdom and New York. USA.. 2013
- [13]. Hosseini S. A. Estimation of maximum temperatures in Ardabil city using artificial neural network theory, Thesis Master of Physical Geography, University researcher Ardabil. 2017.
- [14]. Menhaj M.B. Fundamentals of Neural Networks (Computational Intelligence), Nshrdanshgah center, Amir Kabir, Third Edition, 2014. p. 712.
- [15]. Demuth H. Beale M. Neural Network Toolbox Users Guide Copyright 1992-2002. By the Math Works. Inc. 2011. Version 4.840pp.
- [16]. Eslah, P. Analysis of return on SASW tests using artificial neural networks. Thesis in Civil Engineering, Faculty of Engineering, University of Urmia. 2014.
- [17]. Khalili N, Khodashenas S, Davari k. Precipitation forecasting using artificial neural networks. Conference on Water Resources Management. 2011.
- [18]. Williams M. and B Lazar. Climate Change in Western Ski Areas: Potential Changes In the Timing of Wet Avalanches and Snow Quality for the Aspen Ski area in the Years 2030 and 2100. *Cold Regions Science and Technology*. 2008; 12(51). 219-228.
- [19]. Godarzi A. M. T, dastorani S, Masah bovani and A Talebi. Performance evaluation of rainfall-runoff model in forecasting floods IHACRES city (Case Study: Heart-Yazd Grand River watershed. The first national conference on urban flood management. Tehran. 2015.
- [20]. Kamal A, Masah boani A. Ompare uncertainty and AOGCM-AR4 AOGCM-TAR models of climate change impact on runoff in Gharehsou, *Physics of the Earth and space*. 2012; 38 (3): 188-175.
- [21]. Tae Semiromi S, Moradi H.R, Khodagholi, R. Simulation and forecasting of climatic variables you multiple linear model SDSM by general circulation models of the atmosphere (case study watershed time Nishapur). *Journal of humans and the environment*. 2014; 15(28): 14-29.
- [22]. Samadi S. Z, Masah bovani S, Mahdavi, R. Choose a small scale predictor variable for the statistical data on temperature and rainfall Karkhe watershed. Proceedings of the Fifth National Conference on Science and Management Engineering (sustainable management of natural disasters). University of Agricultural Sciences and Natural Resources Sari. 2015.

- [23].Ghorbani M, Darbandi S, Asadi E,Samadian M.Simulation of Parameters Affecting the River Flow Trend using the IHACRES Rainfall-runoff Model in Future Periods (Case Study: Zolachai River).Ecohydrology.2021;8(1):177-193.
- [24].Ebrahimi R,Eslamian S, Zareian M. Predicting the effects of climate change on groundwater resources using artificial intelligence methods (Case study: Talesh plain). Journal of water and irrigation management.2022;2(3):561-579.
- [25].Shahida E, Ehteshamib M, Salari M.Application of Multi-Layer Artificial Neural Networks for Forecasting Groundwater Level(Case study: Yolo County, California). Journal of Environmental Sciences Studies (JESS). 2023: 8(1),: 6270-6281.
- [26]. Nobre P, Sandro F. Tedeschi V, Silva J, Bottino M, Baptista da Silva M, Neto O, Figueroa S, Bonatti, Paulo J, Kubota Y, Fernandez J, Giarolla E, Vial J and Nobre,C. Assessing the performance of climate change simulation results from BESM-OA2.5 compared with a CMIP5 model ensemble.Geosci. Model Dev.,2020: 13: 2277–2296.