

ارزیابی خطا و عدم قطعیت در ریزمقیاس گردانی SDSM و شبکه عصبی مصنوعی (برخی از ایستگاه‌های شمالی کشور)

مهدی احمدی^۱ و باقر قرمزچشمه^{۲*}

^۱ دانشجوی دکتری گروه جنگل، مرتع و آبخیزداری، دانش منابع طبیعی محیط زیست، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران و ^۲ استادیار، پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ پذیرش: ۱۳۹۸/۰۵/۲۲

تاریخ دریافت: ۱۳۹۷/۰۸/۱۷

چکیده

در دهه‌های گذشته در نتیجه فعالیت‌های انسانی و طبیعی، میزان گازهای گلخانه‌ای در اتمسفر افزایش یافته و در نتیجه، دمای کره زمین روند افزایشی به خود گرفته است. برای مدیریت منابع آب، کشاورزی و در نتیجه ایجاد امنیت غذایی نیاز به آگاهی از وضعیت اقلیمی دوره آتی است که در حال حاضر معتبرترین ابزار برای تولید سناریوهای اقلیمی، مدل‌های سه بعدی جفت شده اقیانوس-اتمسفر گردش عمومی جو است. برای استفاده از این داده‌ها لازم است به‌وسیله تکنیک‌های مختلف در سطوح ایستگاهی ریزمقیاس گردانی شوند. مدل‌های مختلفی در جهت ریزمقیاس گردانی وجود دارد که هر یک دارای معایب و مزایایی هستند. هدف از انجام مطالعه، مقایسه دو روش خطی و غیرخطی ریزمقیاس گردانی است. در روش خطی، از مدل SDSM و در روش غیرخطی به کمک برنامه‌نویسی در نرم‌افزار متلب انجام پذیرفت. برای بررسی خطا از میانگین خطا ماهانه و سالانه و برای مقادیر حدی از واریانس و برای بررسی عدم قطعیت از آزمون من‌ویتنی در سطح ۹۵ درصد استفاده شد. نتایج نشان داد که در بررسی میانگین ماهانه به‌ترتیب در ایستگاه قائم‌شهر، بابلسر، قرآن طالار و بندپی در مدل SDSM به‌ترتیب ۰/۷۵، ۱۲، ۱۱ و هفت، در مدل شبکه عصبی مصنوعی سه، دو، ۲۶ و چهار و در میانگین سالانه به‌ترتیب نه، ۱۴۶، ۱۴۱ و ۸۷ در مدل SDSM و در مدل شبکه عصبی مصنوعی ۴۵، ۳۲، ۳۲۱، ۴۸ میلی‌متر خطا (افزایشی و کاهش) وجود دارد. نتایج عدم قطعیت در ایستگاه‌های قائم‌شهر، بابلسر، قرآن طالار و بندپی برای ۱۲ ماه هر ایستگاه در مدل SDSM به‌ترتیب هشت، سه، شش و چهار و در شبکه عصبی مصنوعی به‌ترتیب چهار، دو، دو و سه پذیرفته شد. در مطالعات تغییر اقلیم بر رواناب و عدم قطعیت و زمانی که داده کم وجود دارد، باید از مدل SDSM و در زمانی که بررسی سیلاب و برآورد جریان کمینه و بیشینه هدف مطالعه است، بهتر است، از مدل شبکه عصبی مصنوعی استفاده کرد.

واژه‌های کلیدی: بررسی سیلاب، برنامه‌نویسی، تغییر اقلیم، شبیه‌سازی، HadCM₃

مقدمه

فسیلی، تغییر کاربری اراضی و افزایش جمعیت جهان و به تبع آن، گسترش روزافزون فعالیت‌های صنعتی برای تأمین رفاه و نیازهای جمعیت کره زمین، موجب افزایش غلظت گازهای گلخانه‌ای به‌ویژه دی اکسید

با توجه به این‌که طبیعت، توانایی خودپالایی دارد و می‌تواند تا حدودی آثار مخرب موجود در طبیعت را از بین ببرد، ولی استفاده بیش از حد از سوخت‌های

تغییرات آب و هوایی نقش مؤثری دارد، به طوری که امروزه وقتی صحبت از مباحث تغییر اقلیم می‌شود، بیشتر نظرها به سمت انسان و فعالیت‌های بشری معطوف می‌شود. این امر به طور عمده به علت افزایش مصرف سوخت‌های فسیلی، شهرنشینی، جنگل‌زدایی و بیابان‌زایی است (Kamali، ۲۰۱۰؛ Mashae و Kamali، Boani، ۲۰۱۱ و ۲۰۱۲). مدل‌های گردش عمومی جو-اقیانوس (AOGCM)، بهترین اطلاعات درباره پاسخ جو به افزایش تمرکز گازهای گلخانه‌ای را می‌توانند فراهم کنند. این مدل‌ها وابسته به زمان و دارای شبیه‌سازی‌های عددی سه بعدی شامل حرکات جوی تبادلات گرمایی و اندرکنش‌های یخ و اقیانوس و خشکی هستند (Vicuna و Dracup، ۲۰۰۵). با توجه به افزایش میزان دی اکسید کربن و به تبع آن، وقوع گرمایش جهانی و تأثیر آن بر منابع آب ملی و منطقه‌ای، بررسی تأثیر تغییرات اقلیم در برنامه‌ریزی‌های منابع آب ضروری به نظر می‌رسد. ارتباط تنگاتنگی بین چرخه هیدرولوژی و سامانه اقلیمی وجود دارد. هر تغییری در اقلیم، روی عناصر هیدرولوژی اثر می‌گذارد. رواناب، آبدهی رودخانه‌ها، آب‌های زیرزمینی و شدت سیلاب و خشکی، همگی متأثر از بارش و دما (از مهمترین عناصر اقلیمی) هستند، یکی از ایرادات مدل گردش عمومی و اقیانوسی، درشت‌مقیاس بودن خروجی این مدل‌هاست. برای برطرف کردن این مشکل نیاز به ریزمقیاس گردانی خروجی این مدل‌ها است (Samadi و همکاران، ۲۰۱۰). به طور کلی دو روش برای ریزمقیاس گردانی وجود دارد: ۱- ریزمقیاس گردانی دینامیکی و ۲- ریزمقیاس گردانی آماری. در ایران، به دلیل این‌که به منبع مدل گردش عمومی جو و اقیانوس در دسترس نیست نمی‌توان از روش ریزمقیاس گردانی دینامیکی استفاده کرد. مطالعات مختلفی در زمینه تغییر اقلیم در ایران انجام شده است، ولی به طور کلی، بیشتر این مطالعات در مناطق جنوبی کشور به خصوص حوضه قره‌سو انجام شده است. طبق مطالعات انجام داده شده در ایران (Ahmadi، GhremezCheshmeh، ۲۰۱۴؛ در ایران و در نیوزلند Hasshemi و همکاران، ۲۰۰۹؛ Hasshemi و همکاران، ۲۰۱۱) عملکرد مدل SDSM

کربن در چند دهه اخیر شده است. هیأت بین‌الدول تغییر اقلیم IPCC که در سال ۱۹۸۸ به وسیله سازمان هواشناسی جهان (WMO) و برنامه محیط زیست سازمان ملل (UNEP) تأسیس شد، وظیفه شناخت تمام جنبه‌های پدیده تغییر اقلیم را عهده‌دار است. مطالعات نشان می‌دهد، با حضور گازهای گلخانه‌ای، دمای زمین ۳۳ درجه سانتی‌گراد گرم‌تر از شرایط بدون این گازها است (IPCC، ۱۹۸۸). بر این اساس، در صورت افزایش میزان گازهای گلخانه‌ای در جو زمین، بخش بیشتری از انرژی خورشیدی در زمین نگهداری می‌شود و این امر، سبب افزایش دمای کره زمین خواهد شد. این گرم شدن به نوبه خود بر اقلیم زمین تأثیر گذاشته و پدیده تغییر اقلیم را سبب می‌شود (IPCC، ۱۹۸۸ و ۲۰۰۷). گرم شدن کره زمین از اواخر قرن نوزدهم آغاز شده و انتظار می‌رود که در سال‌های آینده نیز ادامه پیدا کند. افزایش دما، انکار ناپذیر است و به روش‌های گوناگونی از قبیل برداشت‌های محلی و ماهواره‌ای اندازه‌گیری شده و ذوب یخچال‌ها و بالا آمدن سطح آب‌های آزاد نیز گواه محکمی بر وجود آن است. دلیل اصلی این افزایش رویدادها، افزایش غلظت گازهای گلخانه‌ای مانند دی اکسید کربن و متان در جو است که از پیامدهای فعالیت‌های گوناگون انسان از قبیل مصرف سوخت‌های فسیلی و جنگل‌زدایی به شمار می‌رود (IPCC، ۱۹۹۹ و ۲۰۰۴). تغییر اقلیم می‌تواند موجب تغییر مقادیر میانگین یا تغییرپذیری سایر خصوصیات پارامترهای اقلیمی شود. از میان پارامترهای اقلیمی که تحت تأثیر تغییر اقلیم قرار می‌گیرند، می‌توان به پارامترهای دما، بارش، باد، تابش و غیره اشاره کرد که به دلیل تغییرپذیری طبیعی یا در نتیجه فعالیت‌های بشر در آن‌ها، تغییراتی ایجاد شده است (IPCC، ۲۰۰۱). بر اساس تخمین تجمع گازهای گلخانه‌ای در گزارش هیأت بین‌الدول تغییر اقلیم، افزایش دمایی معادل ۱/۱ تا ۴/۶ درجه سانتی‌گراد تا سال ۲۱۰۰ میلادی پیش‌بینی می‌شود. مقدار گرم‌شدن زمین طی ۱۰۰ سال آینده، بیش از آن چه طی ۱۰۰۰۰ سال گذشته رخ داده است، خواهد بود (Morid و Mashae Boani، ۲۰۰۵؛ Vaseghi، ۲۰۱۰). علاوه بر نقش عوامل طبیعی در تغییرات اقلیمی، بشر نیز در شدت و وسعت

که در مطالعات باید به این دو امر توجه کرد. هدف از انجام مطالعه، بررسی دقت مدل‌های خطی و غیرخطی در ریزمقیاس گردانی داده‌های بارش، دمای کمینه و بیشینه روزانه است.

مواد و روش‌ها

منطقه پژوهش: برای انجام پژوهش از دو ایستگاه سینوپتیک و دو ایستگاه باران‌سنجی استفاده شد (جدول ۱). ایستگاه‌های مورد مطالعه در منطقه شمالی ایران که دارای شرایط متغیر اقلیمی است (دامنه شمالی و دامنه جنوبی البرز).

را بهتر از مدل‌های دیگر دانسته، Dibike و همکاران (۲۰۰۶) و Dibike و همکاران (۲۰۰۷) در کانادا به مقایسه مدل SDSM و TFLN پرداخته و عملکرد شبکه عصبی را در برآورد بارش بهتر معرفی کرده است، Abebe و Kebede (۲۰۱۷) به مقایسه دو مدل ریزمقیاس گردانی پرداخته است و الگوریتم مدل SDSM را مورد بررسی قرار داده است و عملکرد الگوریتم مدل را بسیار خوب دانسته است. با توجه به مطالعات انجام داده شده، می‌توان نتیجه‌گیری کرد که میزان خطا و عدم قطعیت کاملاً به منطقه مطالعاتی بستگی و به دقت انتخاب متغیرهای پیش‌بینی کننده

جدول ۱- مشخصات ایستگاه‌های مورد استفاده (فرایند بارش)

ایستگاه	نوع ایستگاه	طول جغرافیایی درجه، دقیقه	عرض جغرافیایی درجه، دقیقه	ارتفاع از سطح دریا به فوت	سال آماری (مورد استفاده در تحقیق)
بابلسر	سینوپتیک	۵۲ ۳۹	۳۶ ۴۳	۸۵	۲۰۰۱-۱۹۶۱
قائم‌شهر	سینوپتیک	۵۲ ۴۶	۳۶ ۲۷	۱۳۶	۲۰۰۱-۱۹۸۴
قرآن‌طالار	وزارت نیرو	۵۲ ۴۷	۳۶ ۱۸	۳۷۷	۱۳۸۴-۱۳۴۸
بندی	وزارت نیرو	۵۲ ۳۷	۳۶ ۱۸	۶۹۳	۱۳۸۴-۱۳۵۴

در منطقه مطالعاتی شرایط محلی حاکم است که بر اقلیم منطقه به‌خصوص در فصل پاییز بسیار تاثیرگذار است. علت انتخاب چهار ایستگاه نامبرده عبارتند از (۱) دو ایستگاه سینوپتیک بابلسر و قائم‌شهر یکی از دو ایستگاه سینوپتیک است که در بیشتر مطالعات تغییر اقلیم به‌عنوان ایستگاه شاهد از آن استفاده می‌شود و (۲) دو ایستگاه بندی و قرآن‌طالار نیز دو ایستگاه باران‌سنجی هستند که دارای شرایط متغیر اقلیمی که تحت تاثیر دو جبهه هوایی شمالی و جنوبی البرز است که اثرات آن به‌خصوص در فصل پاییز کاملاً مشهود و به‌گونه‌ای است که مدل‌های ریزمقیاس گردانی را به چالش می‌کشند.

مدل گردش عمومی جو و اقیانوس: مدل HadCM₃ یکی از مدل‌های AOGCM است که در مطالعات تغییر اقلیم به‌خصوص در ایران استفاده فراوانی شده است و نسبت به سایر مدل‌ها دارای خطای کمتر و پاسخ‌گویی بهتر نسبت به پارامتر جوی است. مدل HadCM₃ دارای سلول ۲/۵ درجه عرض جغرافیایی و

۳/۷۵ طول جغرافیایی است که به‌طور کلی سطح جهان را با تعداد ۹۶×۷۳ سلول پوشانده است. برای ریزمقیاس گردانی از دو مدل SDSM و شبکه عصبی مصنوعی استفاده شد (Ahmadi و همکاران، ۲۰۱۴b).

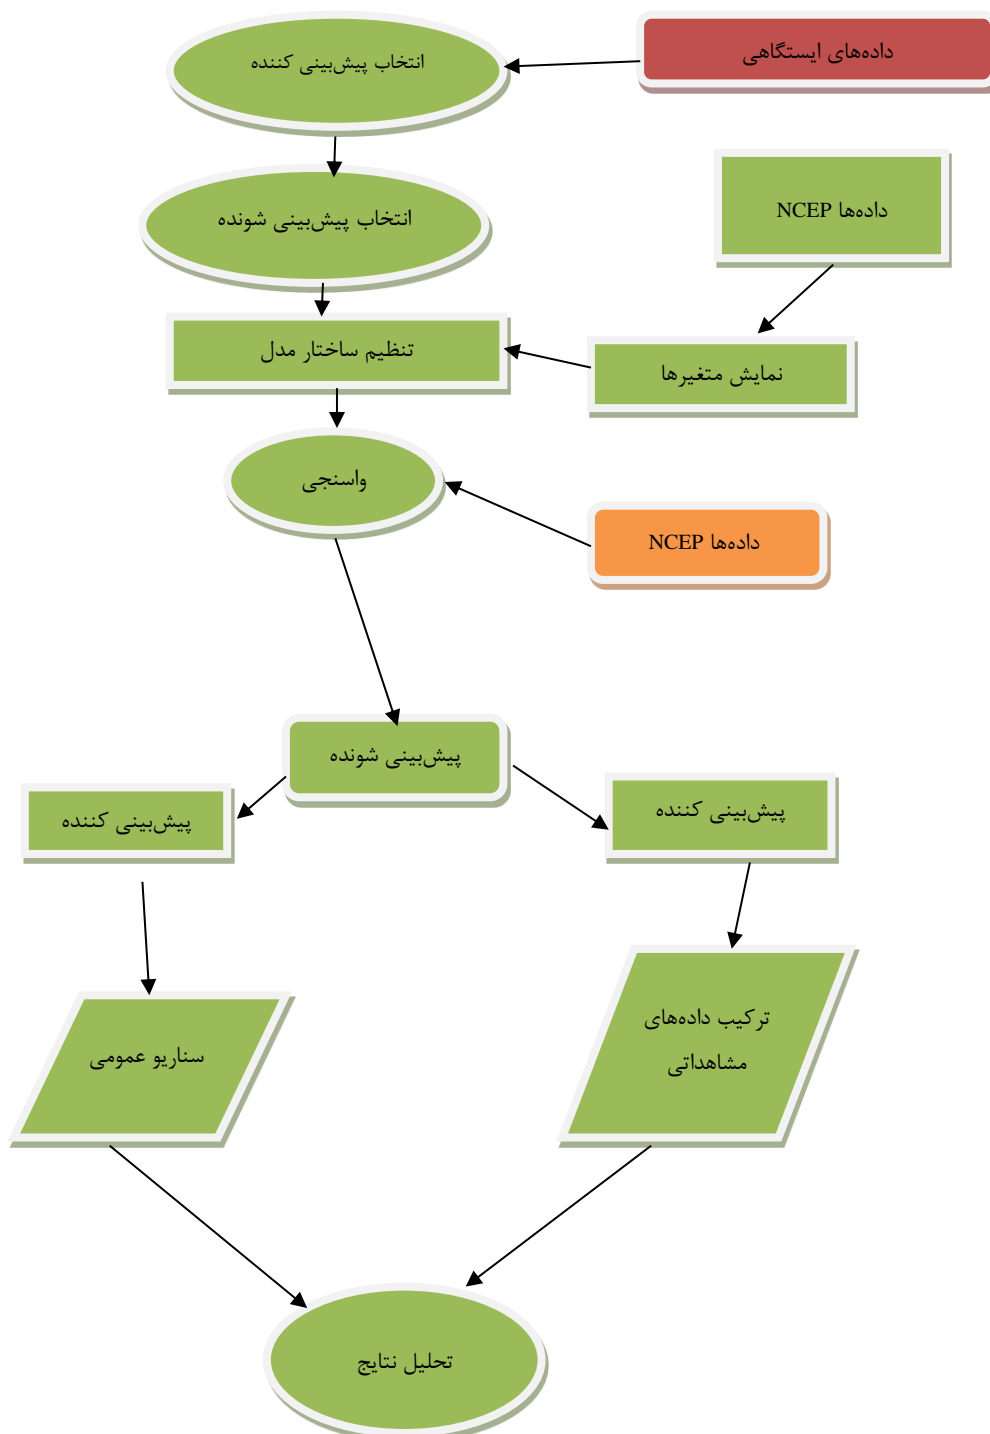
ریزمقیاس گردانی خطی: SDSM روشی است که بهترین توضیح هیبریدی را ارائه می‌کند و در مطالعات مختلفی در جهان مانند مطالعات سیلاب، منابع آب، محیط زیست و غیره، بسیار کاربرد دارد و نتایج حاصل از آن، رضایت‌بخش بوده است (Rasuli و همکاران، ۲۰۱۴؛ Ahmadi و همکاران، ۲۰۱۳). مدل SDSM جزء روش‌های آماری رگرسیون خطی است. به‌عبارت دیگر، مدل مذکور بر پایه روابط آماری تکنیک‌های رگرسیونی چندگانه خطی بین متغیرهای بزرگ‌مقیاس و متغیرهای مشاهداتی محلی پایه‌گذاری شده است. SDSM، یک روش نمونه‌برداری مجدد شرطی و دو مرحله‌ای است، بدین‌صورت که ابتدا مدل، متغیر پیش‌بینی کننده را با استفاده از روش رگرسیونی ترکیبی و یک روش مولد هواشناسی تصادفی

در منطقه مطالعاتی شرایط محلی حاکم است که بر اقلیم منطقه به‌خصوص در فصل پاییز بسیار تاثیرگذار است. علت انتخاب چهار ایستگاه نامبرده عبارتند از (۱) دو ایستگاه سینوپتیک بابلسر و قائم‌شهر یکی از دو ایستگاه سینوپتیک است که در بیشتر مطالعات تغییر اقلیم به‌عنوان ایستگاه شاهد از آن استفاده می‌شود و (۲) دو ایستگاه بندی و قرآن‌طالار نیز دو ایستگاه باران‌سنجی هستند که دارای شرایط متغیر اقلیمی که تحت تاثیر دو جبهه هوایی شمالی و جنوبی البرز است که اثرات آن به‌خصوص در فصل پاییز کاملاً مشهود و به‌گونه‌ای است که مدل‌های ریزمقیاس گردانی را به چالش می‌کشند.

مدل گردش عمومی جو و اقیانوس: مدل HadCM₃ یکی از مدل‌های AOGCM است که در مطالعات تغییر اقلیم به‌خصوص در ایران استفاده فراوانی شده است و نسبت به سایر مدل‌ها دارای خطای کمتر و پاسخ‌گویی بهتر نسبت به پارامتر جوی است. مدل HadCM₃ دارای سلول ۲/۵ درجه عرض جغرافیایی و

داده‌ها برای واسنجی و ۳۰ درصد از داده‌ها برای صحت‌سنجی استفاده شد، برای نمونه در ایستگاه بابل‌سر داده‌ها از سال ۱۹۶۱ تا ۱۹۹۰ برای واسنجی و از سال ۱۹۹۰ تا ۲۰۰۱ (وجود داده‌های NCEP) برای صحت‌سنجی استفاده شد و در نهایت شبیه‌سازی با توجه به سناریو A2 مدل HadCM₃ برای دوره آتی انجام شد.

ریزمقیاس می‌کند، سپس، متغیرها در محل ایستگاه‌ها مجدداً تولید می‌شوند. در واقع، SDSM هیبریدی از روش مولدهای هواشناسی استوکاستیکی و توابع تغییر شکل یافته است (Ghermez Cheshmeh, ۲۰۱۲). به‌طور کلی، شکل ۱ روند مدل SDSM را نشان می‌دهد. برای انجام واسنجی و صحت‌سنجی داده‌ها را به دو دسته با توجه به این نکته که ۷۰ درصد از



شکل ۱- روند کار مدل SDSM

مربعات خطا و ضریب پیرسون انتخاب شد و خروجی شامل بارش است.

برای بررسی خطا و عملکرد دو مدل از میانگین واریانس ماهانه، استفاده شد. به طوری که ابتدا میانگین هر ماه برای هر سال محاسبه و اختلاف با مقدار مشاهده‌ای و در نهایت میانگین سالانه به دست آمد و نتایج مورد ارزیابی قرار گرفت (روابط ۱ و ۲) و برای بررسی عدم قطعیت به علت این که بارش یک پارامتر ناپیوسته است از آزمون من-ویتنی استفاده شد (سطح ۹۵ درصد).

$$Bias = \frac{\sum(Q_o - Q_m)}{n} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum(Q_o - Q_m)^2}{n}} \quad (2)$$

که در آن، Q_o مقدار مشاهداتی، Q_m مقدار برآوردی و N تعداد داده‌ها است.

نتایج و بحث

با بررسی میانگین مدل SDSM در چهار ایستگاه مطالعاتی، در شکل ۳ بیشترین خطا برای ایستگاه بندپی و کمترین خطا برای ایستگاه قائمشهر مشاهده شد. در هر چهار ایستگاه مطالعاتی بیشترین خطا در ماه سپتامبر و فصل پاییز به دست آمد. خطاهای مدل در چهار ایستگاه از یک روند مشابه پیروی کرده و ذکر این نکته حائز اهمیت است که احتمالاً شرایط محلی در فصل پاییز تاثیرگذار بوده است. میانگین ماهانه به ترتیب در ایستگاه قائمشهر، بابلسر، قرآن‌طالار و بندپی به ترتیب برابر با ۰/۷۵، ۱۲، ۱۱ و هفت میلی‌متر بیش‌برآورد داشت. با بررسی خطای شبکه عصبی مصنوعی در شکل ۳ بیشترین خطا در ایستگاه قرآن‌طالار و کمترین خطا در ایستگاه بابلسر رخ داده است. به طوری که هر چه قدر میزان داده اولیه برای آموزش مدل بیشتر باشد، مدل عملکرد مناسب‌تری از خود نشان می‌دهد و میزان وزن‌دهی آن بهتر صورت می‌گیرد. بیشترین خطا در شبکه عصبی مصنوعی در ایستگاه‌های مطالعاتی در فصل پاییز مشخص شده است. میانگین ماهانه در ایستگاه بابلسر و بندپی به ترتیب دو و چهار میلی‌متر کم‌برآورد و در ایستگاه قائمشهر و قرآن‌طالار به ترتیب سه و ۲۶ میلی‌متر بیش‌برآورد داشته است. Samadi و همکاران (۲۰۱۰)


شبکه عصبی مصنوعی: در این پژوهش، به منظور طراحی شبکه عصبی مصنوعی، از شبکه پس‌انتشار^۱ و تابع انتقال LOGSIG و تانژانت سیگموئید^۲ به علت نتایج بهتر نسبت به سایر شبکه‌ها (Samadi و همکاران ۲۰۱۰؛ Kia، ۲۰۱۲)، و نیز به علت اجرای خوب و مناسب در نرم‌افزار متلب استفاده شد. الگوریتم مورد استفاده در این شبکه، الگوریتم لونیگ-مارکوآرت^۳ بود. این الگوریتم به چند دلیل مورد استفاده قرار گرفت که عبارت‌اند از: الف- الگوریتم پیشنهاد شده در نرم‌افزار متلب، ب- سرعت یادگیری بالا و ج- دقت قابل ملاحظه و به کمینه‌رسیدن خطا برای الگوریتم در بسیاری از موارد، سرعت بالای آن در تخمین توابع، در نهایت تعداد نرون و ساختار شبکه مشخص و شبیه‌سازی انجام شد (Maitha و همکاران ۲۰۱۱) و برای آموزش شبکه از پیش‌فرض نرم‌افزار استفاده شد. برای نوشتن برنامه از پایه خود نرم‌افزار متلب به کمک دستور NFTOOL کدهای اصلی شبکه عصبی در دسترس قرار گرفت و در نهایت به کمک دستور RBF (شبکه عصبی شعاعی) کدهای اصلی برنامه با شبکه پس‌انتشار ترکیب شد. در برنامه‌نویسی این پژوهش از شبکه عصبی شعاعی الهام گرفته شد، با این تفاوت که تعداد ساختار به دو و تعداد نرون‌های بین چهار تا ۲۴ تغییر داده شد، به طوری که مدل برای هر متغیر ۴۰ بار اجرا و میزان خطا و میانگین مربعات خطا برای هر تکرار به دست آمد و در نهایت بهترین ساختار و شبکه انتخاب شد (شکل ۲). به طور کلی، می‌توان گفت که در هر چهار ایستگاه ساختار دو لایه بهتر از ساختار یک لایه پاسخگو است و به ترتیب تعداد نرون‌ها در ایستگاه بابلسر، قائمشهر، قرآن‌طالار، بندپی به ترتیب (۱۰، ۱۲)، (۱۳، ۲۴)، (۱۵، ۲۰) و (۲۳، ۳) است (عدد اول داخل پرانتز تعداد نرون‌های لایه یک و عدد دو تعداد نرون‌های لایه دو است). ورودی مدل شامل پنج الی چهار متغیر منتخب (فشار متوسط سطح دریا، رطوبت ویژه در ۸۵۰، قدرت جریان در ۸۵۰، واگرایی در ۸۵۰ و دما در ارتفاع دو متری) که از طریق همبستگی و میانگین

¹ Feed forward

² Sigmoid

³ Levenberg-Marquardt

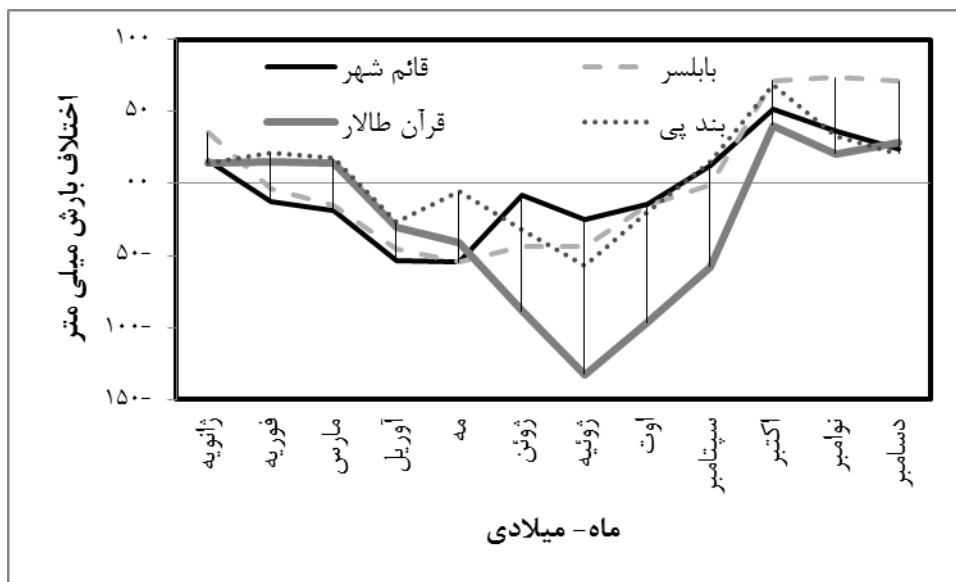
در حوضه قره‌سو خطای ۲۴ میلی‌متر برای مدل SDSM و همکاران (۲۰۱۴) خطای مشابه به‌دست آورده است. در حوضه قرآن طالار در مدل شبکه عصبی مصنوعی



شکل ۲- ساختار دو لایه مدل شبکه عصبی مصنوعی



شکل ۳- میانگین مربعات خطا مدل SDSM




شکل ۴- میانگین مربعات خطا شبکه عصبی مصنوعی

است. به‌خصوص، در فصل پاییز این فرایند بسیار حائز اهمیت است. در مدل شبکه عصبی مصنوعی فرایندهای رخ داده نشان داد، شکل ۶ که روند آن


با بررسی واریانس مدل SDSM در شکل ۵، برآورد مقادیر حدی به‌جزء ماه ژوئن و سپتامبر دچار بیش‌برآورد و در مابقی ماه‌ها کم‌برآورد صورت گرفته

افزایش مقدار واریانس در داده‌ها می‌شود، در حالی که در حوضه کرخه بدین‌گونه نیست. Ghermezcheshmeh و همکاران (۲۰۱۳) اختلاف ۴۰ درصدی در پذیرش واریانس مشاهده‌ای را به‌عنوان مینا پذیرفته‌اند که در فصل‌های بهار و تابستان و ژانویه و فوریه بدین‌گونه در هر دو مدل است.

کاملاً مشابه با مدل SDSM است با این تفاوت که در ایستگاه قرآن‌طلالار در تعدادی از ماه‌ها دچار بیش‌برآورد در نتایج شده است. Samadi و همکاران (۲۰۱۰) به نتایج مشابه رسیدند، با این تفاوت که در ایستگاه مورد مطالعه، در پژوهش بارش‌های حدی در مقادیر بالا بسیار فراوان است که این موضوع باعث



شکل ۵- واریانس مدل SDSM




شکل ۶- واریانس شبکه عصبی مصنوعی


میلی‌متر بیش‌برآورد به‌دست آمد (شکل ۷). نتایج سالانه در مدل شبکه عصبی مصنوعی شکل ۸ بهترین عملکرد در ایستگاه بابلسر ۳۲ میلی‌متر کم‌برآورد حاصل شد و در ایستگاه بندپی ۴۸ میلی‌متر کم‌برآورد

با بررسی میانگین سالانه خطای ایستگاه‌ها، ایستگاه قائم‌شهر بهترین عملکرد را با میانگین ماهانه نه میلی‌متر بیش‌برآورد، در سایر ایستگاه‌ها به‌ترتیب در بابلسر، قرآن‌طلالار و بندپی برابر با ۱۴۶، ۱۴۱ و ۸۷

و در قرآن طالار و بابلسر به ترتیب ۳۲۱ و ۴۵ میلی‌متر
بیش‌برآورد حاصل شد. Samadi و همکاران (۲۰۱۰)
اختلاف ۶۰۰ میلی‌متری در بارش سالانه خود گزارش
کرده‌اند.



شکل ۷- اختلاف بارش سالانه در مدل SDSM



شکل ۸- اختلاف بارش سالانه در مدل شبکه عصبی مصنوعی

نتایج و بحث

هدف از این پژوهش، مقایسه عملکرد دو مدل ریزمقیاس گردانی در حوزه‌های آبخیز شمال کشور بوده است. برای انجام پژوهش، از دو مدل رگرسیون خطی و غیرخطی استفاده شد. مدل SDSM یک مدل رگرسیونی خطی است که در تحقیقات مختلف

با بررسی آزمون من-ویتنی در سطح ۹۵ درصد در جدول ۲، در مدل SDSM به ترتیب در ایستگاه قائم‌شهر، بابلسر، قرآن طالار و بندپی به ترتیب نتایج در هشت، سه، شش و چهار ماه و در مدل شبکه عصبی مصنوعی به ترتیب در چهار، دو، دو و سه پذیرفته شد و در مابقی ماه‌ها فرض صفر پذیرفته نشد.

مدل SDSM عملکرد مناسب‌تری داشته است، ولی در مدل شبکه عصبی مصنوعی در ایستگاه بندپی کاملاً شرایط را بهتر از مدل SDSM نشان داد. در نتایج میانگین ماهانه عملکرد مدل شبکه عصبی مصنوعی به جز ایستگاه قائم‌شهر در مابقی ایستگاه‌ها عملکرد مناسب‌تری نسبت به مدل SDSM دارد. به‌طور کلی، می‌توان گفت که در بررسی مطالعات روند، دوره و تغییرات فصلی بهتر است، از مدل SDSM استفاده کرد، ولی در نتایج سالانه بهتر است، از مدل شبکه عصبی مصنوعی استفاده شود. ذکر این نکته الزامی است که مدل شبکه عصبی مصنوعی تحت تاثیر کمیت و کیفیت داده‌های حدی است، به‌طوری که اگر طول دوره آماری و پیش‌پردازش بر روی داده‌های خام صورت گیرد، بهتر است که از مدل شبکه عصبی مصنوعی استفاده شود.

عملکرد مناسبی دارد (Hashemi و همکاران، ۲۰۱۱؛ Kamali، ۲۰۱۰) و برای مدل غیرخطی از نرم‌افزار متلب (نسخه ۲۰۱۲) و برنامه‌نویسی زنجیره‌ای (Maitha و همکاران، ۲۰۱۱) تحت شبکه انجام شد. برای بررسی خطا از MBE ماهانه برای اختلاف بارش مشاهداتی و برآوردی و برای مقادیری حدی از واریانس، برای بررسی عدم قطعیت به‌دلیل ناپیوسته بودن بارش از آزمون من-ویتنی در سطح ۹۵ درصد استفاده شد. علت انتخاب منطقه شمال کشور، به این علت بود که این منطقه دارای بارش‌های فصلی و مقادیر حدی است که برای مدل‌ها یک چالش محسوب می‌شود.

با بررسی نتایج در میانگین‌های ماهانه، عملکرد مدل SDSM بسیار بهتر از مدل شبکه عصبی مصنوعی به‌دست آمد، به‌طوری که در تغییرات روند

جدول ۲- نتایج آزمون من-ویتنی در مدل SDSM و شبکه عصبی مصنوعی

نام ایستگاه	SDSM			ANN			نام ایستگاه
	قائم‌شهر	بابلسر	قرآن‌تالار	بندپی	قائم‌شهر	بابلسر	
ژانویه	۰/۰۵۹	۰/۰۰۹	۰/۱۸۸	۰/۰۰۷	۰/۰۵۱	۰	۰/۰۱۳
فوریه	۰/۶۷۳	۰/۰۰۸	۰/۵۲۸	۰/۰۳۹	۰/۱۴۳	۰/۶۶۰	۰/۰۰۶
مارس	۰/۹۸۸	۰/۱۸۹	۰/۳۱۴	۰/۰۰۸	۰/۰۴۴	۰/۰۰۹	۰/۰۷۹
آوریل	۰/۰۰۱	.	۰/۰۰۳	۰/۰۰۶	.	.	.
مه	۰/۰۳۷	.	۰/۳۷۶	۰/۳۸۰	.	.	۰/۳۱۴
ژوئن	۰/۱۱۱	.	۰/۰۱۷	۰/۰۰۹	۰/۰۳۴	.	۰/۰۰۲
ژوئیه	۰/۰۰۶	.	۰/۰۰۱	.	۰/۰۰۷	.	.
اوت	۰/۵۸۴	۰/۲۰۶	۰/۱۵۱	۰/۵۰	۰/۱۷۱	۰/۰۰۹	۰/۰۱۹
سپتامبر	۰/۶۵۰	.	.	.	۰/۳۰۶	۰/۵۰۷	۰/۲۷۲
اکتبر	۰/۷۶۷	۰/۲۹۳	۰/۴۴۴	۰/۷۷۰	.	.	۰/۰۱۳
نوامبر	۰/۴۰۶	.	.	۰/۹۲۷	۰/۰۰۸	.	۰/۰۰۲
دسامبر	۰/۰۰۹	.	۰/۰۱۰	۰/۰۱۰	۰/۰۲۲	.	۰/۰۲۰

طرف می‌شود که در پژوهش انجام شده در بازه صفر و یک برای موضوع بالا استفاده شده است. به‌طور کلی می‌توان گفت که در بررسی واریانس‌ها عملکرد مدل شبکه عصبی مصنوعی بهتر از مدل SDSM بوده است. با بررسی نتایج سالیانه در مدل SDSM در ایستگاه قائم‌شهر و قرآن‌تالار عملکرد مدل بهتر از شبکه عصبی مصنوعی و در مابقی ایستگاه عملکرد مدل شبکه عصبی مصنوعی بهتر از مدل SDSM است. ولی به‌طور کلی، می‌توان گفت که مدل شبکه

با بررسی واریانس‌ها به‌علت این‌که شبکه عصبی مصنوعی از طریق وزن‌دهی پارامترها را پیش‌بینی می‌کند، در مقادیر حدی به‌خصوص حد پایین، بهتر از مدل SDSM عمل می‌کند. در حالی‌که مدل SDSM در برآورد مقادیر میانگین بسیار بهتر از مدل شبکه عصبی مصنوعی کارایی داشت. باید اذعان داشت که مدل شبکه عصبی مصنوعی به‌خصوص در مقادیر حدی در داده پرت بسیار حساس بوده، باعث ایجاد خطا در مدل می‌شود که این امر با نرمال‌سازی بر

به‌طور کلی، در پژوهش انجام شده می‌توان به این نتیجه رسید، اگر هدف مطالعه، تغییر اقلیم به‌صورت فصلی و ماهانه است و طول دوره آماری کم بوده و پیش‌پردازش بر روی داده‌ها انجام داده نشده باشد و هدف از انجام مطالعه، در نظر گرفتن بارش‌های حد واسط و هدف مطالعه اثر تغییر اقلیم بر روی رواناب و سیل، به‌خصوص روندیابی جریان و در نهایت اگر بررسی عدم قطعیت باشد، بهتر است، از مدل SDSM استفاده کرد. در حالی که اگر هدف از انجام مطالعه بررسی جریان‌های کمینه و بیشینه و تعیین میزان دقیق مقدار سیل است، در تحلیل‌های سالانه بهتر است، از مدل شبکه عصبی مصنوعی استفاده کرد. پیشنهاد می‌شود که در تحقیقات آینده از مدل ASD و سایر الگوریتم‌های متلب و کمک‌گرفتن از برنامه‌نویسی در ریزمقیاس گردانی در بهبود نتایج استفاده کرد.

عصبی مصنوعی در برآورد میانگین سالانه تا حدودی بهتر از مدل شبکه عصبی مصنوعی عمل کرده است. عدم قطعیت عملکرد مدل SDSM بهتر از مدل شبکه عصبی مصنوعی است، به‌طوری که در ۴۸ آزمون من-ویتنی انجام شده به‌ترتیب در سطح ۹۵ درصد در مدل SDSM و شبکه عصبی مصنوعی ۲۱ و ۱۱ ماه نتایج پذیرفته شد و در مابقی فرض صفر قبول نشد. Ahmadi و همکاران (۲۰۱۴) در حوضه قرآن‌طالار به نتایج مشابه رسیده‌اند. Samadi (۲۰۱۰) در زیرحوضه قره‌سو عملکرد شبکه عصبی مصنوعی را نامطلوب دانسته است. Dibike و Coulibaly (۲۰۰۶)، به مقایسه دو مدل SDSM و شبکه عصبی مصنوعی پرداخته است و بیان کرده که در داده‌های روزانه عملکرد مدل شبکه عصبی مصنوعی بهتر از مدل SDSM است.

منابع مورد استفاده

1. Abebe, A. and A. Kebede. 2017. Assessment of climate impacts on the water resources of Megech River Catchment, Abbay Basin, Ethiopia. *Open Journal of Modern Hydrology*, 2017: 141-152.
2. Ahmadi, M. 2014. Analyzing impact of climate change on annual discharge in Qorantalar Watershed, MSc Thesis, University of Kashan, 120 page (in Persian).
3. Ahmadi, M., H. Ghasemiye and B. Ghermezcheshmeh. 2014a. The effect of climate change on the annual discharge catchment area Quran TALAR. 2nd National Conference on Water Crisis, University of Shahrekord, 8 pages (in Persian).
4. Ahmadi, M., H. Ghasemiye and B. Ghermezcheshmeh. 2014b. Evaluation of down scaling statistical in rainfall-runoff models. 2nd National Conference on Water Crisis, University of Shahrekord, 8 pages (in Persian).
5. Ahmadi, M., H. Ghasemiye and B. Ghermezcheshmeh. 2014c. Analyzing downscaling statistical annual and monthly in SDSM. 2nd National Conference on Water Crisis, University of Shahrekord, 8 pages (in Persian).
6. Rasuli, A., A. Rezaei, A. Massah and B. Ghermezcheshmeh. 2014. Investigation impact of morpho-climate parameters on accuracy of LARS-WG model, Iran. *Watershed Management Science and Engineering*, 8(24): 14-23 (in Persian).
7. Ghermezcheshmeh, B., A. Rasuli and A. Khiorshidost. 2013. Uncertainty analyzing of neural network in downscaling of Hadcm3 data with bootstrap confidence interval method. *Watershed Engineering and Management*, 7(2015): 12-31 (in Persian).
8. Dibike, B.Y. and P. Coulibaly. 2006. Temporal neural network for downscaling variability extremes. *Neural Networks*, 19: 135-144.
9. Dibike, Y.B., P. Gachon, A. St-hilaire, T.B. Quarda and V. Ngu Yen. 2007. Uncertainty analysis of statistically downscaled temperature and precipitation regimes in Northern Canada. *Theoretical and Applied Climatology*, 91: 149-170.
10. Ghermezcheshmeh, B. 2012. AOGCM uncertainty assessment of downscaled models by analyzing temperature and precipitation elements, case study: Orumiyeh Lake Basin. University of Tabriz, 192 pages (in Persian).
11. IPCC-DDC, 1988. <http://ipcc-ddc.cru.uea.ac.uk>.
12. IPCC-TGCI. 1999. Guidelines on the use of scenario data for climate impact and adaptation assessment. Intergovernmental Panel on Climate Change, Task Group on Scenarios for Climate Impact Assessment, 69 pages.

13. IPCC. 2001. Climate Change 2001. The Science of Climate Change. Contribution of Working Group I to the Second Assessment Report of the Intergovernmental Panel on Climate Change, Cambridge University Press, Cambridge, 572 pages.
14. Hashemi, M.Z., A.Y. Shamsedin and B.W. Melville. 2009. Comparison of SDSM and LARS-WG for simulation and downscaling of extreme precipitation events in a watershed. *Stochastic Environmental Research and Risk Assessment*, 25: 475-484.
15. Kamali, A. and A. Mashaeboni. 2011. AOGCM-AP4 uncertainty assessment models and hydrologic models to estimate the effects of climate change temperature and precipitation and runoff. *Iran Water Research Journal*, 2: 12-22 (in Persian).
16. Kamali, A. 2010. Assess the impact of climate change on runoff under the impact of uncertainty AOGCM-AP4 models and small-scale methods of case study Gharesoo Basin. MSc University of Tehran, 95 pages (in Persian).
17. Kamali, A. and A. Mashaeboni. 2012. The impact of climate fluctuations on runoff with the involvement of uncertainty hydrological models. *Journal of Soil and Water*, 5: 920-931 (in Persian).
18. Kia, M. 2012. Neural network in MATLAB. Qian Academic Publishing, 400 pages (in Persian).
19. Maitha, H., A. Shamsi, A. Assi and A. Hejase. 2011. Using MATLAB to develop artificial neural network models for predicting global solar radiation in Al Ain City, UAE. *Engineering Education and Research Using MATLAB*, 11: 220-238
20. Mashaeboni, A. and S. Morid. 2005. The effects of climate change on Zayandeh Rood Esfahan. *Journal of Science and Technology of Agriculture and Natural Resources*, 4: 17-27 (in Persian).
21. Vaseghi, R. 2010. The effect of AOGCM outputs of runoff Gharesoo. MSc Thesis, Islamic Azad University, Sciences and Researched Branch, Tehran, 100 pages (in Persian).