

بررسی عدم قطعیت مدل شبکه عصبی در ریزمقیاس گردانی HadCM3 با روش فاصله اطمینان بوت استرپ

باقر قرمزچشمه^{۱*}، علی اکبر رسولی^۲، مجید رضائی بنفشه^۳، علیرضا مساح بوانی^۴ و علی محمد خورشید دوست^۵
^۱ دانشجوی دکتری، دانشکده جغرافیا و برنامه‌ریزی، دانشگاه تبریز، ^۲ استاد، دانشکده جغرافیا و برنامه‌ریزی، دانشگاه تبریز، ^۳ دانشیار،
دانشکده جغرافیا و برنامه‌ریزی، دانشگاه تبریز، ^۴ دانشیار، پردیس ابوریحان، دانشگاه تهران

تاریخ پذیرش: ۱۳۹۳/۰۵/۱۱

تاریخ دریافت: ۱۳۹۳/۰۴/۱۰

چکیده

در روش‌های ریزمقیاس گردانی آماری که بر اساس رابطه بین داده‌های گردش عمومی اتمسفری- اقیانوسی و هر یک از متغیرهای اقلیمی (بارش، دمای کمینه، دمای بیشینه) ایجاد می‌شود، دوره آتی آن متغیر اقلیمی شبیه‌سازی می‌شود. از آنجایی که در شبیه‌سازی، تمامی عوامل رخ داد، یک متغیر در مدل وارد نمی‌شود، لذا برآورد به‌وجود آمده همراه با خطا و یا عدم قطعیت می‌باشد. خروجی مدل‌های ریزمقیاس گردانی به‌عنوان ورودی در مدل‌های منابع آب و کشاورزی وارد شده و در صورتی که این ورودی‌ها دارای خطا باشند، خروجی مدل‌های ذکر شده نیز با عدم قطعیت بیشتری مواجه خواهد شد. شناخت مقدار خطا و یا عدم قطعیت هر مدل در قضاوت و اطمینان به نتایج به‌دست آمده ضروری است. در این تحقیق سعی شده است، عدم قطعیت ریزمقیاس گردانی مدل‌های GCM با شبکه عصبی در ایستگاه‌های شمال غرب کشور بررسی شود. بدین منظور، مدل شبکه عصبی اجراء و برای هر یک از ماه‌های سال، دمای کمینه، بیشینه و بارش با داده‌های NCEP واسنجی، ارزیابی و سپس، با داده‌های HadCM3 مقادیر فوق شبیه‌سازی شد. داده‌های روزانه مشاهده‌ای هر ماه در دوره (۲۰۰۱-۱۹۶۱) تهیه و در هر ایستگاه و هر ماه با روش بوت استرپ فاصله اطمینان ۹۹ درصد استخراج شد. سپس متوسط ماهانه دوره هر یک از متغیرهای اقلیمی برآورد شده به‌وسیله شبکه عصبی محاسبه شد. برای این منظور از دو معیار میانگین و واریانس داده‌ها استفاده شد. در هر ماه هرگاه میانگین یا واریانس برآورد شده در محدوده اطمینان قرار گیرد، برآورد به‌دست آمده دارای اطمینان است. برای مقایسه نتایج از تعداد ایستگاه-ماه استفاده شد. نتایج نشان داد که میانگین دمای بیشینه در ۱۴ ایستگاه-ماه در محدوده اطمینان واقع شدند. تحلیل ماهانه آن نیز نشان داد، دقت شبکه عصبی در تابستان کم بوده و عدم قطعیت بالاتری نسبت به فصول دیگر دارد. در شبیه‌سازی دمای کمینه بر اساس این معیار ۱۸ ایستگاه-ماه در محدوده اطمینان واقع شد. دقت شبکه عصبی در تابستان برای برآورد دمای کمینه کم و دارای عدم قطعیت در اغلب ایستگاه‌ها بود. به‌طوری که در ماه‌های ژوئن و آگوست در هیچ یک از ایستگاه‌ها برآورد به‌دست آمده در محدوده اطمینان قرار نگرفت. محدوده اطمینان بارش به‌دلیل ماهیت تغییرات زیاد آن نسبت به دما بسیار بالا بوده و تا بیش از ۵۰ درصد بارش متوسط ماه نیز در برخی ایستگاه‌ها رسید. باتوجه به دامنه اطمینان بالای بارش، در ۵۳ مورد ایستگاه-ماه در محدوده اطمینان قرار گرفتند.

واژه‌های کلیدی: بارش، تغییر اقلیم، دما، شمال غرب، مدل منابع آب و کشاورزی

مقدمه

گردانی آماری در دنیا (Wilby و همکاران، ۲۰۰۵؛ Khan و همکاران، ۲۰۰۶؛ Dibik و Coulibaly، ۲۰۰۶) انجام شده است.

از آنجائی که مدل‌های AOGCMs (این مدل‌ها از منابع مختلف با تفکیک اتمسفریک متفاوت و برای دوره‌های زمانی مختلف توسعه پیدا کرده‌اند) فرآیند فیزیکی پیچیده‌ای را که در سامانه زمین-اتمسفر-اقیانوس در حال وقوع می‌باشد و همچنین، سناریوهای انتشار که بر اساس شرایط نامعلوم اجتماعی-اقتصادی، تکنولوژی و ... آینده استوار شده‌اند، را توصیف می‌کنند، لذا ممکن است، سناریوهای به‌دست آمده از مدل‌های اقلیمی و سناریوهای انتشار مختلف برای رخدادهای متغیرهای اقلیمی بیشینه، تفاوت محسوسی با هم داشته باشند. بنابراین، مدل‌های بررسی‌کننده اثر تغییر اقلیم که بر اساس خروجی مدل‌های AOGCM توسعه پیدا می‌کنند، مشمول عدم قطعیت‌هایی خواهند بود. این عدم قطعیت‌ها به دلیل دانش ناقص ناشی از اطلاعات ناکافی یا عدم فهم درست و کامل از فرآیندهای بیوفیزیکی یا نبود منابع تحلیلی می‌باشد. برای مثال می‌توان به ساده سازی فرآیندهای پیچیده نقل و انتقالات در اتمسفر و اقیانوس، فرضیات نادرست در مورد فرآیندهای اقلیمی، محدودیت‌های وضوح مکانی و زمانی در شبیه‌سازی به‌وسیله مدل‌ها که منجر به عدم تطابق نتایج با تغییر اقلیم منطقه‌ای می‌شود، اشاره کرد. همچنین، عدم قطعیت‌هایی ناشناخته، به دلیل پیچیدگی ذاتی سامانه زمین و عدم توانایی ما در پیش‌بینی شرایط اقتصادی-اجتماعی آینده و رفتار جوامع انسانی در یک رویه مشخص، نیز وجود دارد (IPCC، ۲۰۰۷؛ New و Hulme، ۲۰۰۰؛ Prudhomme و همکاران، ۲۰۰۳؛ Stainforth و همکاران، ۲۰۰۷؛ Wilby و Harris، ۲۰۰۶).

پژوهش‌های زیادی در زمینه توسعه و مقایسه روش‌های ریزمقیاس گردانی انجام گرفته است که در بعضی موارد تفاوت محسوسی بین داده‌های تولید شده به‌وسیله روش‌های مختلف وجود دارد. ساختار متفاوت روش‌های ریزمقیاس گردانی و اطلاعات متفاوت از شرایط بارش منطقه‌ای باعث شده تا مطالعات تغییر اقلیم با عدم قطعیت دیگری ناشی از ریزمقیاس

تغییرات اقلیمی قادر است، توزیع منابع آب کره زمین را عمیقاً تغییر داده، از این‌رو تولیدات کشاورزی و صنایع مرتبط را به شدت تحت تأثیر خود قرار دهد. شناخت این تغییرات به برنامه‌ریزی منابع آب در آینده کمک شایانی می‌کند. برای بررسی تغییرات اقلیمی آینده، باید از مدل‌های سه بعدی جفت شده اقیانوسی-اتمسفری گردش عمومی جو^۱ (AOGCM) استفاده شود. با استناد بر این مدل‌ها، می‌توان معادلات دینامیکی حرکت توده‌های هوا را حل نمود (Wilby و Harris، ۲۰۰۶؛ Mitchell، ۲۰۰۳). مدل‌های AOGCM سامانه اقلیم را بر اساس ویژگی‌های فیزیکی، شیمیایی و بیولوژیک اجزاء آن و بازخورد متقابل بین آن‌ها، به‌صورت روابط ریاضی توصیف می‌کنند. پیش‌بینی وضعیت آینده نیز با تولید سناریوهای اقلیمی بر مبنای میزان افزایش گازهای گلخانه‌ای امکان‌پذیر می‌شود. معتبرترین این مدل‌ها در شبکه‌های سه بعدی با مقیاس مکانی افقی ۲۵۰ تا ۶۰۰ کیلومتر و ۱۰ تا ۲۰ لایه در جو و ۳۰ لایه در اقیانوس معادلات دینامیکی را حل می‌نمایند. با توجه به دقت مکانی پائین نتایج آن‌ها به‌طور مستقیم در تحلیل‌های منابع آب کاربرد نداشته، باید ریزمقیاس شوند^۲ (TGCI، ۲۰۰۷).

به‌طور کلی دو روش دینامیکی و آماری برای ریزمقیاس گردانی وجود دارد که مدل‌های مختلفی مبتنی بر آن‌ها به‌وجود آمده است. در روش‌های آماری بین عوامل خروجی مدل‌های AOGCM و عناصر اقلیمی مانند بارش و دما در مقیاس روزانه رابطه برقرار می‌شود. با توجه به این‌که عوامل خروجی مدل‌ها نماینده میانگین کل یک سلول (در مدل HadCM₃) ابعاد ۳/۷۵ در ۲/۵ درجه طول و عرض جغرافیایی می‌باشد، لذا دقت تعمیم مکانی مدل‌ها برای ایستگاه‌هایی که در نقاط مختلف یک سلول واقع شده‌اند، می‌تواند متفاوت باشد. تاکنون تحقیقات زیادی در خصوص دقت مدل‌های آماری ریزمقیاس

¹ Atmospheric-Ocean General Circulation Model

² Task Group on Scenarios for Climate Impact Assessment (TGCI)

متغیر تصادفی برآورد می‌کنند که این متغیر تصادفی می‌تواند عوامل برآورد شده به‌وسیله مدل‌های ارزیابی‌کننده اثر تغییر اقلیم (مانند مدل‌های تحلیل فراوانی) یا خروجی سناریوی تغییر اقلیم به‌دست آمده از مدل‌های AOGCM باشد. در هر دو حالت با داشتن تابع چگالی برازش شده، احتمال رخداد سناریوی اقلیمی و یا سناریوی تغییر اقلیم در آینده با استفاده از تئوری‌های احتمالاتی به‌دست می‌آید. نکته مهمی که این روش‌ها با آن مواجه هستند، حجم نمونه متغیر تصادفی است که به آن تابع چگالی برازش داده می‌شود. هرچه متغیر تصادفی از حجم نمونه‌ی بالاتری برخوردار باشد، برازش تابع چگالی با دقت و صحت بیشتری انجام می‌شود. با توجه به تعداد محدود مدل‌های AOGCMs در شبیه‌سازی اقلیم آینده، تعداد سناریوهای تغییر اقلیم کمتر از مقداری خواهند بود که بتوان به خروجی آن‌ها توزیع مناسبی برازش داد.

تاکنون، در خصوص بررسی عدم قطعیت اثرات تغییر اقلیم تحقیقات زیادی صورت گرفته و در آن فرض شده است که عدم قطعیت‌ها در مدل‌های GCM و سناریوهای افزایش گازهای گلخانه‌ای بررسی شده‌اند. ولی در خصوص منابع عدم قطعیت مدل‌های ریزمقیاس گردانی کمتر توجه شده است (Chen و همکاران، ۲۰۱۳) که در ادامه به برخی از تحقیقات صورت گرفته در خصوص عدم قطعیت مدل‌های ریزمقیاس گردانی پرداخته می‌شود.

Chen و همکاران (۲۰۱۳) عدم قطعیت شش روش تجربی که شامل دو روش تناسبی و چهار روش مبتنی بر اصلاح انحراف (Bias correction) می‌باشند را بررسی کردند. همچنین، چهار مدل RCM^۶ نیز مورد ارزیابی قرار گرفت. نتایج نشان داد که تفاوت چندان بین مدل‌های دینامیکی و تجربی مشاهده نشد، ولی مدل‌های دینامیکی، به مقدار جزئی عدم قطعیت بیشتری نشان دادند. در خصوص مدل‌های تجربی، بین روش تناسبی و روش‌های اصلاح انحراف، اختلاف عدم قطعیت بیشتری مشاهده شد و در بین روش‌های اصلاح انحراف این کمتر به‌دست آمد.

گردانی داده‌های اقلیمی مواجه باشد. بنابراین با توجه به نوع کاربرد و داده‌های موجود می‌توان یک روش ریزمقیاس نمایی مناسبی را انتخاب کرد تا عدم قطعیت ناشی از آن به کمینه برسد و حجم محاسبات کاهش یابد. به‌طوری‌که برخی از پژوهشگران به ارزیابی مدل‌های ریزمقیاس گردانی پرداختند و به‌خصوص روش‌های آماری را مقایسه کردند. در این خصوص Khan و همکاران (۲۰۰۶) سه مدل آماری ریزمقیاس گردانی^۱ LARS-WG^۲ و ANN^۳ برای عوامل هواشناسی مدل‌های AOGCM شامل بارش روزانه، دمای کمینه و بیشینه روزانه به‌کار بردند. آن‌ها عدم قطعیت سه مدل فوق را برای متوسط ماهانه و واریانس عوامل ریزمقیاس شده روزانه و مقادیر مشاهده‌ای در هر ماه در سطح ۹۵ درصد اطمینان بررسی کردند. نتایج تحقیق آن‌ها نشان داد که مدل SDSM بیشترین دقت و شبکه عصبی کمترین را داشته و مدل LARS-WG دقت متوسطی دارد. Dibikey و Coulibaly (۲۰۰۶)، در منطقه شمال کبک^۴ دقت روش شبکه عصبی مصنوعی به‌نام TFLN^۵ را بررسی کردند. برای این منظور از داده‌های CGCM2 استفاده و برای ریزمقیاس گردانی دو روش SDSM و TFLN به‌کار بردند و نتایج آن‌ها نشان داد که روش TFLN به‌خصوص ریزمقیاس گردانی بارش روزانه از دقت خیلی بیشتری برخوردار است. لازم به ذکر است، TFLN و RNN (Recurrent N.N) دو گروه مهم شبکه اصلی دینامیک محسوب می‌شوند که استفاده فراوانی در تحلیل‌های سری زمانی دارند (Coulibaly و همکاران، ۲۰۰۱).

در تجزیه و تحلیل عدم قطعیت‌ها، روش‌های پارامتریک (مانند روش‌های مونت کارلو؛ Prudhomme و همکاران، ۲۰۰۳) و ناپارامتریک (برآوردگر چگالی کرنل؛ Solaiman و Simonovic، ۲۰۱۱) به‌طور رایج مورد استفاده قرار می‌گیرند. هر دو روش بر اساس اصول متفاوت، یک تابع چگالی احتمال را برای یک

^۱ Statistical Down Scaling Model

^۲ Long Ashton Research Station Weather Generator

^۳ Artificial Neural Network

^۴ Quebec

^۵ Time lagged feed-forward Networks

^۶ Regional Climate Model

ایستگاه‌های سینوپتیک می‌باشد که آماری طولانی مدت باشند. از کل ایستگاه‌های منطقه بر اساس طول دوره آماری هشت ایستگاه برای این منظور مناسب تشخیص داده شد که در شکل ۱، موقعیت آن‌ها آورده شده است. متغیرهای اقلیمی فوق با استفاده از داده‌های HadCM3 و به روش شبکه عصبی ریزمقیاس شدند.

مدل شبکه عصبی: یک شبکه عصبی یک ابزار محاسباتی است که در گروه هوش محاسباتی جای می‌گیرد. این ابزار، از طبیعت الهام گرفته شده و برای آن روابط ریاضی تعریف شده است که بر اساس رفتار یک سلول عصبی کار می‌کند. در سال‌های اخیر، این ابزار در علوم مختلف راه یافته، جایگزین روش‌های محاسباتی تجربی دیگر در علوم مختلف شده است. این مدل، برای منظورهای مختلف مانند طبقه‌بندی داده‌ها به گروه‌های همسان پیش‌بینی یک متغیر و یا مدل‌سازی داده‌ها استفاده می‌شود. معمولاً به منظور ایجاد یک رابطه بین پیش‌بینی کننده‌های مدل‌های GCM و پیش‌بینی شونده یک متغیر اقلیمی از شبکه عصبی می‌توان استفاده کرد. مدل‌های مختلفی برای شبکه عصبی توسعه یافته که به سه دسته MLP، PSO، و RBF تقسیم می‌شوند. در مباحث برآورد متغیرهای اقلیمی و هیدرولوژی Rezaei و همکاران (۲۰۰۷) و Khorshidoost و همکاران (۲۰۱۲)، از مدل MLP استفاده نموده‌اند و در این پژوهش نیز از این مدل استفاده شد.

ابتدا سری زمانی داده‌های دمای کمینه و بیشینه روزانه و همچنین، بارش روزانه برای هر یک از ایستگاه‌های منتخب آماده شد. برای هر یک از ایستگاه‌ها طول دوره آماری ۴۱ ساله در نظر گرفته و برای هر ماه از ابتداء سال ۱۹۶۱ تا آخر ۲۰۰۱ یک سری زمانی روزانه به دست آمد. به طوری که سری زمانی ماه فوریه ۱۱۵۸ داده (روز)، ماه‌های ۳۰ روزه (آوریل، ژوئن، سپتامبر و نوامبر) ۱۲۳۰ داده (روز) و هفت ماه باقی‌مانده ۱۲۷۱ داده (روز) تهیه شد. لازم به ذکر است که در برخی از روزها دما به صورت محدود فاقد داده بودند که با روش خود همبستگی و استفاده از ایستگاه‌های همسایه بازسازی شدند.

Ahmed و همکاران (۲۰۱۳)، یک روش آماری و اصلاح انحراف (SDBC^۱) برای ریزمقیاس گردانی شش مدل GCM و چهار مدل RCM استفاده کردند. آن‌ها پنج معیار مقادیر حدی دمای کمینه، بیشینه و بارش روزانه برای این منظور مدنظر قرار دادند. نتایج نشان داد که داده‌های ریزمقیاس شده همراه با اصلاح انحراف و مقایسه با عدم اصلاح انحراف از دقت بیشتری برخوردار است و نتیجه گرفتند که استفاده از مدل‌های دینامیکی به‌عنوان یک مدل واسط بین GCMها و RCMها، دقت نهایی را به‌طور محسوسی بهبود نمی‌دهد. Ebrahim و همکاران (۲۰۱۳) عدم قطعیت مرتبط با ریزمقیاس گردانی مدل‌های LARS-WG، SDSM و شبکه عصبی مصنوعی را به‌منظور بررسی اثرات تغییر اقلیم در هیدرولوژی رودخانه بلس در اتیوپی مورد بررسی قرار دادند. نتایج تحقیق آن‌ها نشان داد که سری زمانی بارش و دما به نوع مدل ریزمقیاس گردانی حساس می‌باشند. تحلیل ترکیب‌های مختلف (Ensembles) مدل SDSM (خروجی مدل فوق به‌عنوان ورودی مدل‌های هیدرولوژیکی می‌باشد و هر Ensemble مدل یک خروجی متفاوت خواهد داشت. با ورود این خروجی‌ها در مدل هیدرولوژیکی خروجی مدل نیز تغییر خواهد کرد) نشان داد که دامنه تغییرات دبی متوسط سالانه به ازاء Ensemble‌های مختلف بین شش درصد افزایش تا هشت درصد کاهش نسبت به متوسط Ensembleها رخ می‌دهد.

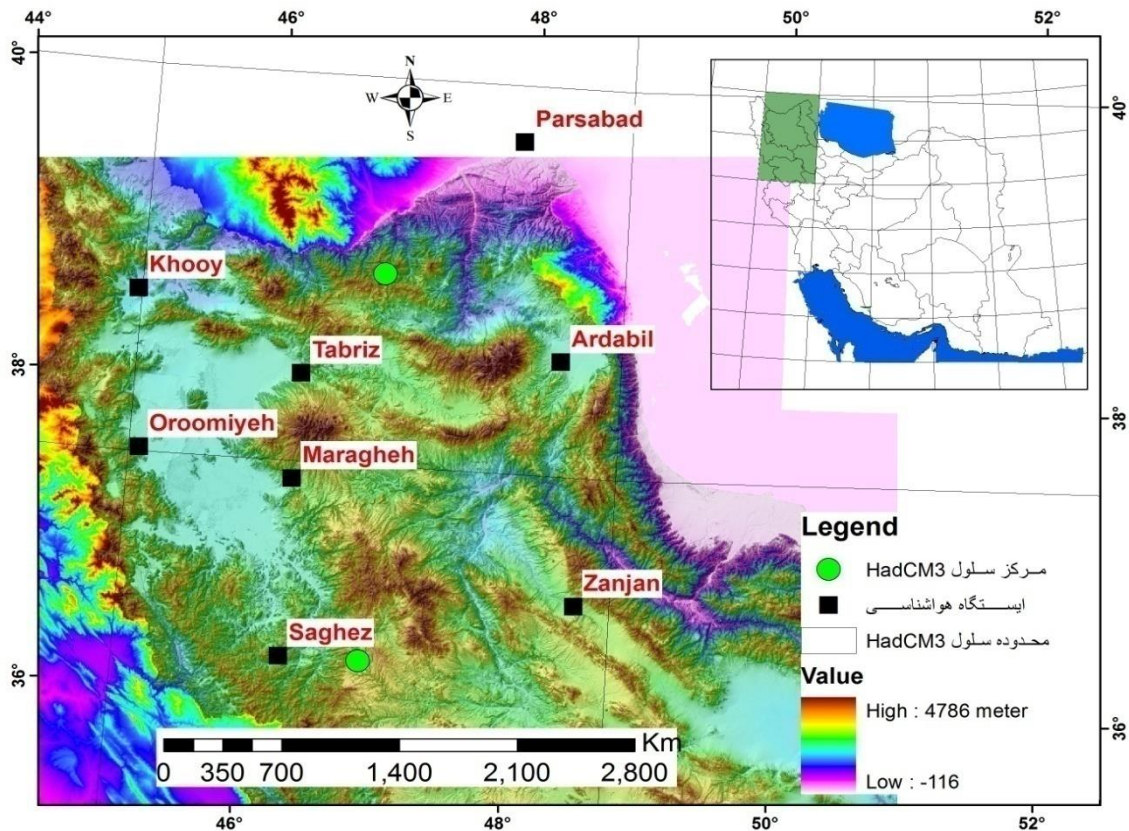
این پژوهش سعی بر آن دارد که دقت مدل ریزمقیاس گردانی شبکه عصبی را با روش فاصله اطمینان بوت استرپ^۲ عدم قطعیت متغیرهای اقلیمی دمای کمینه، دمای بیشینه و بارش را در هر ماه مورد ارزیابی قرار دهد.

مواد و روش‌ها

منطقه تحقیق شمال غرب ایران شامل استان‌های آذربایجان شرقی، آذربایجان غربی، اردبیل، کردستان و زنجان می‌باشد. برای ریزمقیاس گردانی متغیرهای اقلیمی دمای کمینه، بیشینه و بارش روزانه، نیاز به

^۱ Statistical Down Scaling Bias Correction

^۲ Bootstrap



شکل ۱- منطقه مورد پژوهش

دمای بیشینه) همبستگی ایجاد شد. همچنین، بین کلیه پیش‌بینی‌کننده‌ها نیز همبستگی داخلی برقرار شد و پیش‌بینی‌کننده‌هایی که با یکدیگر همبستگی داخلی داشتند، حذف شد. در نهایت حدود پنج پیش‌بینی‌کننده مهم انتخاب شد. در جدول ۱، در هر ایستگاه و برای هر متغیر پیش‌بینی شونده، پیش‌بینی‌کننده‌های منتخب آمده است.

داده‌های HadCM₃ شامل ۲۶ داده روزانه از عوامل سینوپتیک می‌باشد که از مرکز هدلی دریافت شد. از آنجایی که همه عوامل سینوپتیکی فوق با متغیر اقلیمی رابطه ندارند و نمی‌توان آن‌ها را در مدل وارد نمود، باید عوامل مهم انتخاب شوند. برای این منظور، رابطه بین پیش‌بینی‌کننده‌های HadCM₃ (۲۶ مورد) و هر یک از متغیرهای اقلیمی (بارش، دمای کمینه و

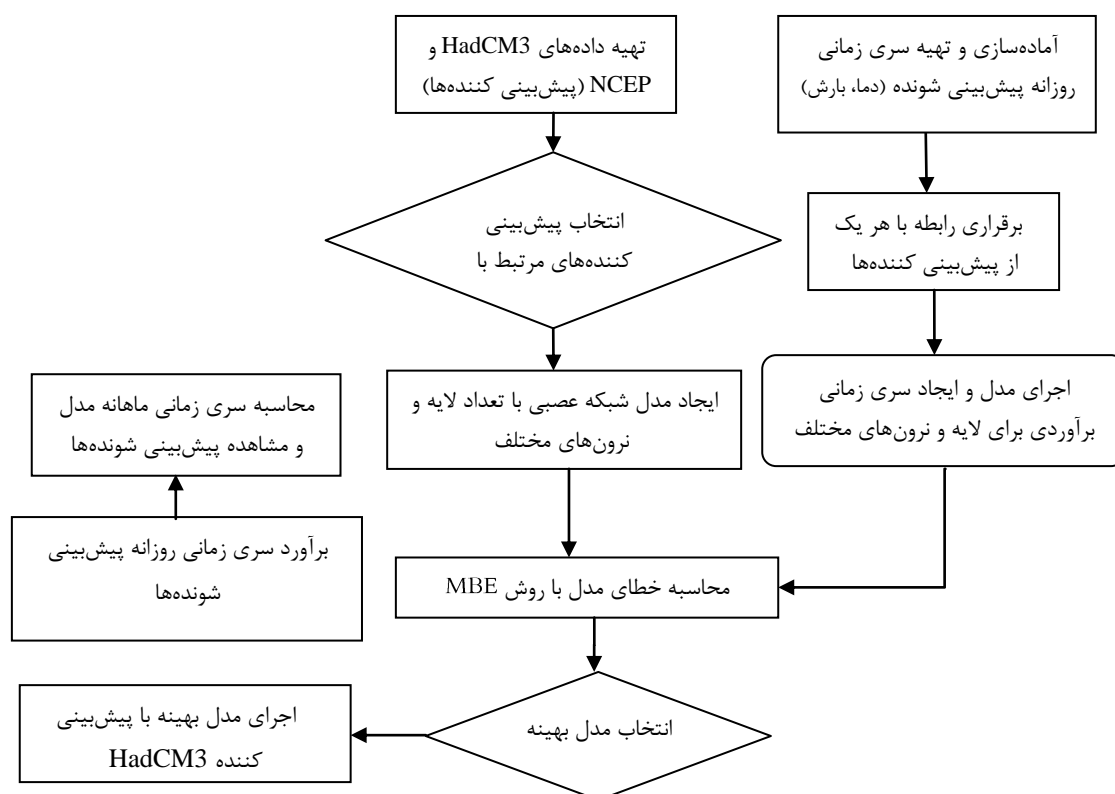
جدول ۱- متغیرهای پیش‌بینی شونده مهم برای هر یک از متغیرهای دما و بارش (Ghermezcheshmeh, ۲۰۱۴)

ایستگاه	دمای بیشینه	دمای کمینه	بارش
اردبیل	Temp, Shum, P500, P5-v	Temp, Shum, P500, P8-z, P-v	R850, R500, P8-z, P-z
مرآغه	Temp, Shum, P500, P8-z, P-z	Temp, Shum, P500, R850, P-z	Temp, Rhum, R850, P8-zh, P5-f
پارس‌آباد	Temp, Shum, P500, P8-z, P-v	Temp, Shum, P500, P8-z, P5-f	P-z, P5-z, P500, P8-z, P5-f
تبریز	Temp, Rhum, P500, P5-z, P-u	Temp, Shum, P500, P8-z, P-u	P-u, Rhum, P500, P8-f, P-z
زنجان	Temp, Shum, P500, P-zh, P5-u	Temp, P500, P5-u, P5-v, P-z	P5-f, Shum, P8-u, P8-z, P5-z
سقز	Temp, Shum, P500, P8-zh, P-z	Temp, Shum, MsIP, P-zh, P5-v	P-u, R850, P500, P8-v, P5-z
ارومیه	Temp, Shum, P500, P8-z, P-z	Temp, Shum, P500, P8-z, P5-f	P5-f, Shum, R500, P5-v, P5-z
خوی	Temp, Shum, P500, P5-z, P-v	Temp, Shum, P500, P8-z, P-v	P-u, Shum, P5-v, P5-f, P5-z

Temp متوسط دما در ارتفاع دو متری، P500 ژئو پتانسیل ۵۰۰ هکتوپاسکال، Shum رطوبت ویژه سطحی، P5-v سرعت نصف النهاری در ۵۰۰ هکتوپاسکال، P8-z تاوانی در ۸۵۰ هکتوپاسکال، R850 رطوبت ویژه یا نسبی در ۸۵۰ هکتوپاسکال، P-z حالت گردابی سطحی، Rhum رطوبت نسبی سطحی، P5-f قدرت جریان در ۵۰۰ هکتوپاسکال، P8-zh واگرایی در ۸۵۰ هکتوپاسکال، P-v سرعت نصف النهاری سطحی، P8-f قدرت جریان در ۸۵۰ هکتوپاسکال، P-zh واگرایی سطحی، P5-u سرعت مداری در ۵۰۰ هکتوپاسکال، P5-z تاوانی در ۵۰۰ هکتوپاسکال، P5-v

عصبی اجرا شد. برای این منظور، ابتدا سری زمانی پیش‌بینی کننده‌های منتخب و پیش‌بینی شونده (به‌عنوان مثال دمای بیشینه) تصادفی و سپس ۷۰ درصد برای آموزش، ۱۵ درصد برای اعتباریابی و ۱۵ درصد بقیه برای آزمون مدل در نظر گرفته شد. پس از اجرای مدل رابطه رگرسیونی هر یک از موارد فوق و کل داده‌ها برای مقادیر برآوردها با مشاهده‌ای برقرار شد. فرآیند ریزمقیاس گردانی در شکل ۲ ارائه شده است.

شبکه عصبی در محیط نرم‌افزار Matlab اجرا شد. از آنجایی که طراحی شبکه عصبی اهمیت زیادی داشته و دقت مدل به طراحی درست شبکه بستگی دارد، برای طراحی مناسب کد نویسی صورت گرفت. در این کد نویسی برای استخراج بهترین مدل تعداد ۴۴ حالت مختلف تعداد لایه و نرون طراحی شد. سپس هر مدل اجرا و دقت مدل با استفاده از میانگین خطا (MBE) محاسبه شد. سپس مدلی که کمترین خطا را داشت، برای ریزمقیاس گردانی داده‌های GCM لحاظ شد. پس از انتخاب نرون و لایه بهینه، شبکه



شکل ۲- فلوچارت ریزمقیاس گردانی با شبکه عصبی

داده‌ها و به تعداد داده‌های هر سری، نمونه گرفته می‌شود. این عمل، معمولاً هزار بار (Efron و Tibshirani, ۱۹۹۳) تکرار شده و برای هر تکرار یک متوسط و یک واریانس محاسبه می‌شود. سپس فاصله اطمینان هزار تکرار محاسبه می‌شود.

در این پژوهش، برای محاسبه فاصله اطمینان به روش بوت استرپ از نرم‌افزار R استفاده شد. برای این منظور ابتداء سری زمانی متغیرهای اقلیمی (بارش، دمای کمینه و بیشینه) در هر ماه تهیه شد. به‌طور

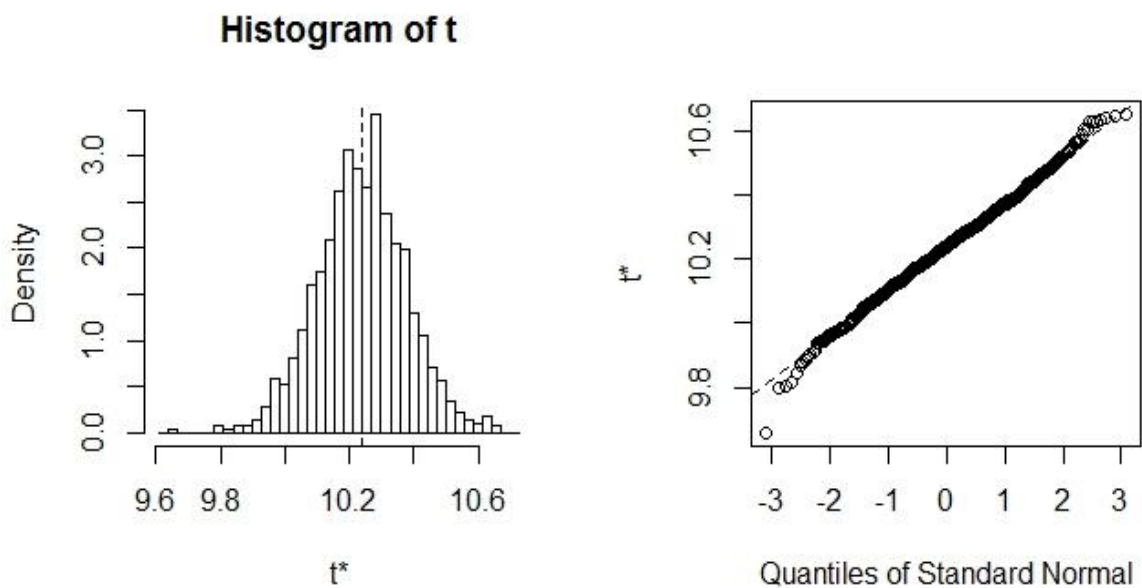
فاصله اطمینان بوت استرپ: بوت استرپ (Efron و Tibshirani, ۱۹۹۳) یک روش نمونه‌گیری با جایگزینی محسوب شده، جزء زیر مجموعه روش مونت کارلو (Dehghani, ۲۰۰۹) می‌باشد. با این تفاوت که در روش مونت کارلو، برای داده‌های ورودی، یک توزیع مناسب برازش شده، سپس نمونه‌های زیادی به‌صورت تصادفی با احتمالات مختلف انتخاب و بر اساس توزیع به‌دست آمده مقادیر واقعی متغیر محاسبه می‌شود. ولی در این روش، نمونه‌گیری از خود

چارک‌های استاندارد نرمال میانگین و واریانس دمای کمینه آوریل ایستگاه زنجان در شکل ۳ آورده شده است.

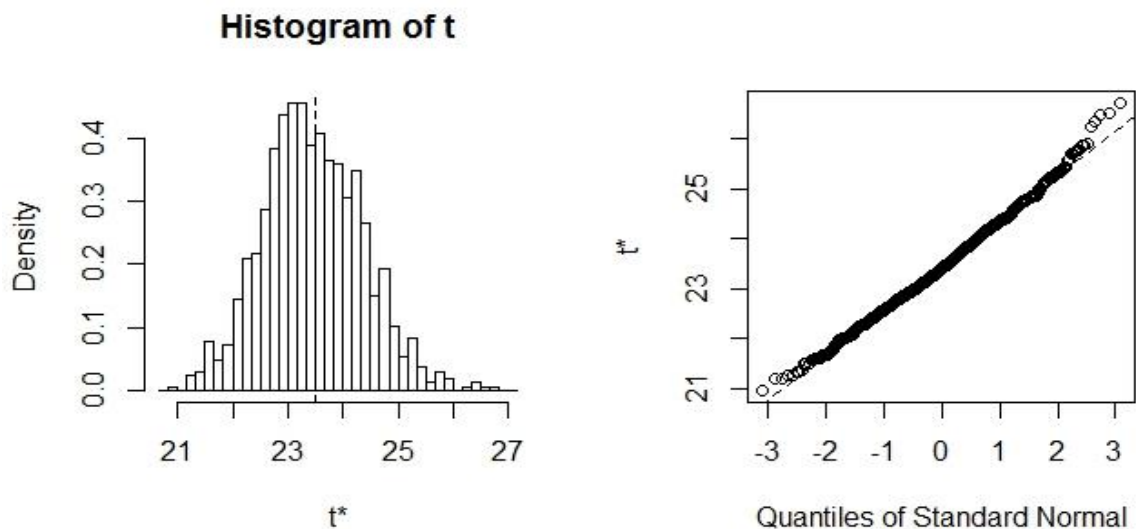
برای تحلیل دقت شبکه عصبی با روش فوق، از معیار ایستگاه-ماه (Ghermezcheshmeh, ۲۰۱۴) استفاده شد. به طوری که در هشت ایستگاه و ۱۲ ماه سال، ۹۶ حالت ممکن رخ داده و از این تعداد هر چند مورد که در فاصله اطمینان واقع شود، بیانگر دقت مدل می‌باشد.

که در یک دوره ۴۱ ساله، سری زمانی ماه فوریه ۱۱۵۸ داده، ماه‌های ۳۰ روز ۱۲۳۰ و ماه‌های ۳۱ روزه ۱۲۷۱ داده به دست آمد. سپس در محیط نرم‌افزار R کد نویسی صورت گرفت و برای هر ایستگاه، هر ماه متغیر فاصله اطمینان و واریانس محاسبه شد. به طوری که در مجموع در هر ایستگاه ۳۶ مرتبه فاصله اطمینان میانگین و ۳۶ مرتبه فاصله اطمینان واریانس محاسبه شد. در مجموع، هشت ایستگاه ۵۷۶ فاصله اطمینان محاسبه شد. برای نمونه، نمودار فراوانی t و

الف) میانگین



ب) واریانس



شکل ۳- نمودار فراوانی t و چارک‌های استاندارد نرمال میانگین و واریانس دمای کمینه آوریل ایستگاه زنجان

نتایج و بحث

فاصله اطمینان برای میانگین و واریانس متغیرهای دمای بیشینه، کمینه و بارش مشاهده‌ای به‌عنوان نمونه برای ایستگاه تبریز در شکل ۴ آمده است. هرگاه مقادیر برآوردی مدل‌ها در محدوده اطمینان داده‌های مشاهده‌ای قرار گیرد، بیانگر اطمینان در سطح اعتماد مورد نظر می‌باشد و در صورتی که خارج از محدوده باشد، بیانگر عدم اطمینان به مقدار برآوردی است. از آنجایی که متغیر دما، جزء کم نوسان‌ترین داده اقلیمی محسوب می‌شود و به همین دلیل محدوده اطمینان آن کم می‌باشد؛ هرچه محدوده اطمینان یک متغیر بالاتر باشد، نوسانات آن بیشتر می‌باشد. به‌طور مثال، دامنه اطمینان دمای بیشینه حدود یک درجه سانتی‌گراد، ولی فاصله بارش در برخی از ماه‌ها ممکن است به بیش از ۵۰ میلی‌متر برسد.

بر این اساس، میانگین دمای بیشینه ایستگاه تبریز در اوایل سال، دارای عدم قطعیت بالا بوده ولی در نیمه دوم اغلب در محدوده فاصله اطمینان قرار گرفت. فاصله اطمینان واریانس داده‌ها اختلاف زیادی با مقادیر برآوردی مدل نشان داد و تنها در دو ماه ژوئن و سپتامبر در محدوده فاصله اطمینان واریانس مشاهده‌ای واقع شد. میانگین دمای کمینه همانند دمای بیشینه دقت خوبی را به‌خصوص در ماه‌های ژانویه و فوریه نشان نداد (شکل ۴ب).

فاصله اطمینان واریانس مشاهده‌ای دمای کمینه همانند کلیه ایستگاه‌ها در تابستان نسبت به دوره سرما کمتر به‌دست آمد. واریانس مدل، جز در ماه‌های آوریل، ژوئیه و ژوئن در بقیه ماه‌ها خارج از محدوده اطمینان واقع شده و در ماه‌های ژانویه و فوریه، فاصله از محدوده اطمینان آن بسیار زیاد بوده و عدم قطعیت آن بالا به‌دست آمد. میانگین بارش مدل در اغلب ماه‌ها به‌خصوص در نیمه دوم سال در محدوده فاصله اطمینان مقادیر مشاهده‌ای قرار گرفت و فقط در فصل بهار، مدل کم برآورد و خارج از محدوده اطمینان واقع شد. ولی در خصوص واریانس، مدل عملکرد خوبی نداشته و جز تابستان در بقیه ماه‌ها در خارج از محدوده اطمینان واقع شد (شکل ۴ج). در بقیه

ایستگاه‌ها نیز تقریباً نتایج مشابه به‌دست آمد.

برای تحلیل دقت شبکه عصبی در ریزمقیاس گردانی عناصر اقلیمی، تعداد ایستگاه-ماه‌هایی که در محدوده اطمینان واقع شده بودند، ملاک عمل قرار گرفت که در جدول ۲ آمده است. از ۹۶ مورد ایستگاه-ماه، میانگین دمای بیشینه در مجموع ۱۴ مورد در محدوده اطمینان واقع شدند. تحلیل ماهانه آن نیز نشان داد که فصل تابستان عدم قطعیت مدل دو ماه ژوئیه و اوت هیچ یک از هشت ایستگاه در محدوده اطمینان واقع نشدند. لازم به ذکر است که در تابستان نوسانات دمایی کمتر از فصول دیگر بوده، در نتیجه محدوده فاصله اطمینان آن نسبت به فصول دیگر کمتر می‌باشد. به همین دلیل، با وجود خطای کمتر برآورد دما در تابستان، کمتر در محدوده اطمینان واقع شدند.



دقت مدل در برآورد دمای کمینه در ۱۸ مورد در محدوده اطمینان قرار گرفت. در این خصوص نیز در تابستان برآورد دمای کمینه دارای عدم قطعیت در اغلب ایستگاه‌ها بود. به‌طوری که در جدول ۲ آمده است، در ماه‌های ژوئن و آگوست در هیچ یک از ایستگاه‌ها، برآورد به‌دست آمده در محدوده اطمینان قرار نگرفت. در فصل بهار مدل دقت بهتری را نسبت به بقیه فصول نشان داد. به‌طوری که برآورد سه ایستگاه در محدوده اطمینان واقع شد. در فصل پاییز نیز تا حدودی مدل از دقت مناسب برخوردار بوده و در ماه‌های دسامبر و اکتبر دو ایستگاه با دقت مناسب برآورد شدند.

برآوردهای Samadi و همکاران (۲۰۱۳)، در تابستان با عدم قطعیت بیشتری نسبت به بقیه فصول برخوردار بود که با نتایج این تحقیق همخوانی دارد. محدوده اطمینان بارش به‌دلیل ماهیت تغییرات زیاد آن نسبت به دما بسیار بالا بوده و تا بیش از ۵۰ درصد بارش متوسط ماه نیز ممکن است، برسد که در شکل (۳ج) به‌خوبی قابل مشاهده است. به همین دلیل، امکان قرار گرفتن بارش برآوردی در محدوده اطمینان بیشتر می‌شود. به‌طوری که در ۵۳ مورد ایستگاه-ماه بارش برآوردی در محدوده اطمینان قرار گرفتند که در


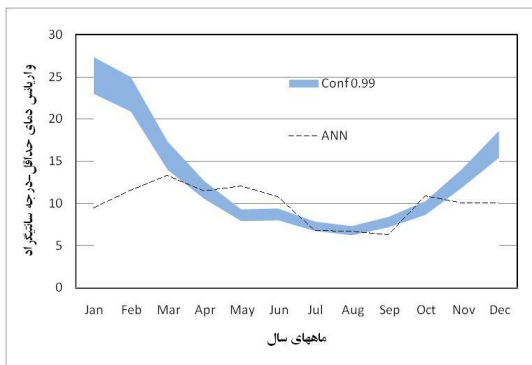
Coulibaly (۲۰۰۶) نیز دقت شبکه عصبی را در برآورد بارش نسبت به بقیه مدل‌ها بهتر دانستند. البته آن‌ها از روش TFLN برای شبیه‌سازی استفاده کرده بودند.

جدول ۲ آمده است. نتایج به دست آمده نشان داد که دقت مدل شبکه عصبی در برآورد دمای کمینه و بیشینه از دقت خوبی برخوردار نبوده که با نتایج Khan و همکاران (۲۰۰۶) همخوانی نشان داد. مدل در خصوص بارش، عملکرد بهتری داشته و Dibike و



الف) دمای بیشینه



ب) دمای کمینه



ج) بارش



شکل ۴- فاصله اطمینان ۹۹ درصد میانگین و واریانس دمای بیشینه مشاهداتی با روش بوت استرپ و مقادیر برآوردی شبکه عصبی در ایستگاه تبریز

جدول ۲- تعداد ایستگاه‌های هر ماه که در محدوده اطمینان ۹۹ درصد به روش بوت استرپ قرار گرفته‌اند

ماه میلادی	میانگین			واریانس		
	دمای بیشینه	دمای کمینه	بارش	دمای بیشینه	دمای کمینه	بارش
ژانویه	۲	۱	۶	۰	۰	۵
فوریه	۰	۰	۲	۰	۰	۳
مارس	۱	۳	۴	۰	۰	۱
آوریل	۰	۳	۲	۲	۳	۱
مه	۳	۳	۵	۴	۱	۱
ژوئن	۱	۰	۴	۱	۱	۴
ژوئیه	۰	۲	۳	۰	۱	۶
اوت	۰	۰	۳	۱	۱	۶
سپتامبر	۲	۲	۳	۲	۰	۵
اکتبر	۱	۲	۸	۵	۱	۵
نوامبر	۲	۰	۸	۳	۱	۱
دسامبر	۲	۲	۵	۱	۰	۶
سال	۱۴	۱۸	۵۳	۱۹	۹	۴۴

نتیجه‌گیری

در این تحقیق، برای ارزیابی دقت مدل شبکه عصبی در ریزمقیاس گردانی داده‌های GCM، از روش فاصله اطمینان بوت استرپ استفاده شد. بر اساس این معیار، میانگین دمای بیشینه و دمای کمینه کمتر در محدوده اطمینان واقع شدند، ولی میانگین بارش در بیش از ۵۰ درصد ایستگاه-ماه‌ها در محدوده اطمینان واقع شد. تحلیل ماهانه آن نیز نشان داد که فصل تابستان عدم قطعیت مدل کم بوده و عدم قطعیت بالاتری را نشان داد. بر این اساس، شبکه عصبی به‌طور کلی در برآورد دمای کمینه و بیشینه از توانایی خوبی برخوردار نبوده، اغلب برآوردها در خارج از محدوده اطمینان واقع شد. تحلیل فصلی بارش نشان داد که

مدل در فصل پائیز عملکرد خوبی داشته، در ماه‌های اکتبر و نوامبر کلیه ایستگاه‌ها با برآورد مناسب همراه بوده و در محدوده اطمینان واقع شدند. ولی تحلیل واریانس آن بیانگر عدم توانایی مدل در برآورد مقادیر حدی است. تحلیل واریانس دمای کمینه و بیشینه نیز بیانگر عملکرد ضعیف مدل شبکه عصبی در شبیه‌سازی مقادیر حدی بود. در حال حاضر استفاده از روش‌های بوت استرپ در تحلیل‌های آماری رایج شده و در خصوص تحلیل اطمینان روش‌های ریزمقیاس گردانی آماری کاربردی شده است. به‌طوری که Samadi و همکاران (۲۰۱۳) همچنین، Chen و همکاران (۲۰۱۳) از این روش برای ارزیابی نتایج خود استفاده کردند.

منابع مورد استفاده

- Ahmed, K.F., G. Wang, J. Silander, A.M. Wilson, J.M. Allen, R. Horton and R. Anyah. 2013. Statistical downscaling and bias correction of climate model outputs for climate change impact assessment in the U.S. north-east. *Global and Planetary Change*, 100: 320–332.
- Chen, J., F.P. Brissettea, D. Chaumontb and M. Braunb. 2013. Performance and uncertainty evaluation of empirical downscaling methods in quantifying the climate change impacts on hydrology over two North American river basins. *Journal of Hydrology*, 479(4): 200–214.

3. Coulibaly, P., F. Anctil, R. Aravena and B. Bobée. 2001. ANN modeling of water table depth fluctuations. *Water Resources Research*, 37: 885-896.
4. Dehghani., M. 2009. Uncertainty analysis of streamflow drought forecasting. MSc Thesis, Islamic Azad University, 108 pages (in Persian).
5. Dibike, B.Y. and P. Coulibaly. 2006. Temporal neural networks for downscaling variability and extremes. *Neural Networks*, 19: 135-144.
6. Ebrahim, G.Y., A. Jonoski, A. Griensven and G.D. Baldassarre. 2013. Downscaling technique uncertainty in assessing hydrological impact of climate change in the Upper Beles River Basin, Ethiopia. *Journal of Hydrology Research*, 44(2): 37-44.
7. Efron, B. and R.J. Tibshirani. *Statistics and Applied Probability* 1993. An introduction to the bootstrap, monographs on statistics and applied probability. Chapman and Hall, London, 436 pages.
8. Ghermezcheshmeh. B. 2014. Assessment of downscaling GCM models uncertainty by analyzed on temperature and precipitation, case study: Urmia lake basin. PhD Thesis, Tabriz University, 186 pages (in Persian).
9. Intergovernmental Panel on Climate Change (IPCC). 2007. Summary for policy makers climate change: the physical science basis. Cambridge University Press, 881 pages.
10. Khan, M.S., P. Coulibly and Y. Dibike. 2006. Uncertainty analysis of statistical downscaling methods. *Journal of Hydrology*, 319: 357-382.
11. Khorshiddoost, A.M., M. Nassaji Zavareh and B. Ghermezcheshmeh. 2012. Reconstruction of maximum and minimum temperature daily time series using nearest neighborhood and neural network methods, case study: west of Tehran. *Journal of Geographical Space*, 12(38): 197-214 (in Persian).
12. Mitchell, T.D. 2003. Pattern scaling: an examination of the accuracy of the techniques for describing future climates. *Climate Change*, 60: 217-242.
13. New, M. and M. Hulme. 2000. Representing uncertainty in climate change scenarios: a Monte Carlo approach. *Integrated Assessment*, 1: 203-213.
14. Prudhomme, Ch., D. Jakob and C. Svensson. 2003. Uncertainty and climate change impact on the flood regime of small UK catchments. *Journal of Hydrology*, 277: 1-23
15. Rezaei, A., M. Mahdavi, L. Karo, S. Faiznia and M.H. Mahdian. 2007. Regional modeling of maximum discharges using artificial neural network in sub-basins of Sefid Rood. *Journal of Water and Soil Science*, 11(1A): 25-39 (in Persian).
16. Samadi, S., A.M.E. Wilson and H. Moradkhani. 2013. Uncertainty analysis of statistical downscaling models using Hadly Center Coupled Model. *Theoretical and Applied Climatology*, 113(3-4): 673-690.
17. Solaiman T.A. and S.P. Simonovic. 2011. Quantifying uncertainties in the modelled estimates of extreme precipitation events at upper Thames River Basin. Water Resources Research Report, No. 067, Facility for Intelligent Decision Support, Department of Civil and Environmental Engineering, London, Ontario, Canada, 64 pages.
18. Stainforth, D.A., T.E. Downing, R.W.A. Lopez and M. New. 2007. Issues in the interpretation of climate model ensembles to inform decisions. *Philosophical Transactions of the Royal Society A*, 365: 2163-2177.
19. Task Group on Scenarios for Climate Impact Assessment (TG CIA). 2007. General guidelines on the use of scenario data for climate impact and adaptation assessment. Carter, T.R., Version 2, 71 pages, Intergovernmental Panel on Climate Change. Task Group on Scenarios for Climate Impact Assessment (TG CIA).
20. Wilby, R.L. and I. Harris. 2006. A framework for assessing uncertainties in climate change impacts: low flow scenarios for the River Thames, UK. *Water Resources Research*, 42(2): 12-22.
21. Wilby, R.L., T.M.L. Wigley, D. Conway, P.D. Jones, B.C. Hewitson, J. Main and D.S. Wilks. 2005. Statistical downscaling of general circulation model output: a comparison of methods. *Water Resources Research*, 34: 2995-3008.

Uncertainty analyzing of Neural Network in downscaling of HadCM3 data with bootstrap confidence interval method

Bagher Ghermezcheshmeh^{*1}, Aliakbar Rasuli², Majid Rezaei-Banafsheh³, Alireza Massah⁴ and Alimohammad Khorshiddoost⁵

¹ PhD student, Faculty of Geography and Planning, University of Tabriz, Iran, ^{2 and 5} Professor, Faculty of Geography and Planning, University of Tabriz, Iran, ³ Assistant Professor, Faculty of Geography and Planning, University of Tabriz, Iran and ⁴ Assistant Professor, University of Tehran, Iran

Received: 01 July 2014

Accepted: 02 August 2014

Abstract

In the statistical downscaling methods which is based on the relationship between AOGCMs data and ground based climatic variables (such as rain and temperature), the future period of those variables are simulated. Since in the simulation, all effective parameters cannot be modeled, estimated values suffers from be uncertainty. The outputs of downscaling models are used as inputs to agriculture and water resources models; therefore, identifying the models inputs' error or uncertainty is essential to realize the reliability of obtained results. In this research, an attempt is made to investigate the uncertainty of Artificial Neural Network (ANN) as a downscaling model in a case study in the northwest of Iran. For this purpose, precipitation, minimum and maximum temperature variables were used in the designed ANN model, and the NCEP data was employed for its calibration and validation. The HadCM3 was the selected AOGCM in this study. Observed daily time series were gathered at all stations in the study period and on the basis of bootstrap method the 99% confidence interval was calculated for all the variables. In the next step, the simulated (downscaled) mean and variance of the variables by the ANN model, compared to the calculated confidence interval. To compare the results, the criterion of the number of station-month was used. The results showed that the average maximum temperature at 14 station-months were within the confidence interval. The results of monthly analysis showed that the accuracy of ANN model in summer was low and its uncertainty is more than the other seasons. In the simulation of minimum temperature based on this criterion, 18 station-months were within the confidence interval. The accuracy of ANN to estimate the minimum temperature in summer was low with high uncertainty in almost all the stations. Moreover, in June and August in any of the stations estimated values were not within the confidence interval. Due to the high variability of rainfall in relation to temperature, confidence range was very high, and in some stations was more than 50% of average monthly precipitation. Because of the high confidence rang of precipitation, in 53 Stations-month cases were within the confidence interval.

Key words: Climate change, Northwest, Rain, Temperature, Water resources and agriculture models

* Corresponding authors: baghergh@Gmail.com