

مقایسه عملکرد دو مدل SDSM و شبکه‌های عصبی مصنوعی در پیش‌بینی تغییرات دمای حداقل (ایستگاه موردی: ارومیه) حسین عساکره^۱، سلماز مطلبی‌زاد^{۲*}

۱. استاد آب و هواشناسی، دانشگاه زنجان، زنجان، ایران.
۲. استادیار جغرافیا و برنامه‌ریزی روستایی، دانشگاه تبریز، دانشکده جغرافیا و برنامه‌ریزی، تبریز، ایران.

دریافت: ۹۵/۱۰/۲۸ پذیرش: ۹۶/۰۳/۲۷

چکیده

تغییرات آب و هوایی اشاره به تغییرات در میانگین یا تنوع در ویژگی‌های آب و هوایی دارد که همچنان نیز در حال حاضر برای دوره‌های طولانی ادامه خواهد داشت که نتیجه تغییر طبیعی و فعالیت‌های انسانی است. در پژوهش حاضر به منظور شبیه‌سازی تغییرات دمای حداقل از داده‌های دمای حداقل و مدل‌های گردش عمومی جو استفاده شد و بررسی عملکرد مدل‌ها با ضریب همبستگی و ریشه میانگین مربعات خطا صورت گرفت. در این مطالعه سال ۱۹۶۱-۱۹۹۰ به عنوان سال پایه و بررسی تغییرات دما در سانتی‌گرادی آینده دمای حداقل در سه دوره ۲۰۱۱-۲۰۴۱، ۲۰۴۰-۲۰۷۰ و ۲۰۷۱-۲۰۹۹ انجام گرفت. نتایج پژوهش نشان داد که در سانتی‌گرادی آینده دماهای حداقل روندی کاهشی دارند. دماهای حداقل برآورد شده در دوره شبیه‌سازی برای دوره پایه برآورد مدل SDSM و شبکه عصبی مصنوعی در ماه ژانویه ۱/۸ و ۲/۳ درجه سانتی‌گراد نسبت به داده مشاهده شده اختلاف داشته است. در ژانویه براساس برآوردهای دو مدل در سال‌های ۲۰۱۱-۲۰۴۰ دما به میزان ۳/۳ درجه سانتی‌گراد افزایش دما برای سال‌های ۲۰۴۱ تا ۲۰۷۰ حدود ۴/۷ و برای بازه زمانی ۲۰۷۱ تا ۲۰۹۹ حدود ۵/۰۵ درجه افزایش خواهد یافت. براساس این تحقیق مدل SDSM نسبت به شبکه عصبی نتایج نزدیک به واقعیت را نشان داد.
واژگان کلیدی: تغییر اقلیم، شبکه عصبی مصنوعی، مدل SDSM، دمای حداقل، ارومیه.

۱- مقدمه

در قرن بیست و یکم تغییرات آب و هوایی یکی از بزرگ‌ترین تهدیدات زیست‌محیطی برای جهان در نظر گرفته شده است. تغییرات در آب و هوای فرین با توجه به اثرات منفی بیشتر بر جامعه انسانی و محیط طبیعی نسبت تغییرات در میانگین آب و هوا تخمین زده می‌شود (محمود و بابل^۱، ۲۰۱۴: ۵۶). بر پایه گزارش چهارم هیأت بین الدول تغییر اقلیم که با عنوان گزارشات ارزیابی تغییر اقلیم انتشار یافته است، افزایش جهانی دما و رخداد تغییر اقلیم با بهره‌گیری از داده‌های اندازه‌گیری شده دمای سطح خشکی‌ها و آب‌های جهان تأیید شده است (آی‌پی‌سی‌سی^۲، ۲۰۱۴: ۳۲). اولین اثر تغییر اقلیم روی عناصر اتمسفری به ویژه درجه حرارت و بارش است، سپس با توجه به ارتباط بین عناصر اتمسفری و اکوسیستم‌های زمینی، منابع آب، پوشش گیاهی، خاک و همچنین زندگی انسان تحت تأثیر این پدیده قرار خواهد گرفت؛ بنابراین بررسی روند متغیرهای اتمسفری مانند دما از اهمیت ویژه‌ای برخوردار است (آبکار و همکاران، ۱۳۹۲: ۱۴). موضوع روند دما و به خصوص حداقل دما در بسیاری از مطالعات مربوط به اثرات تغییر اقلیم مورد توجه بوده است. بیشتر مطالعات و بررسی‌ها نشان می‌دهد چه در دوره مشاهداتی و داده‌های ثبت شده دما و چه در خروجی مدل‌های گردش عمومی جو یک روند افزایشی در دما مشاهده می‌شود. نکته مهم در این زمینه نرخ افزایش شدیدتر در دمای حداقل نسبت به دمای حداکثر است (محمودی و همکاران، ۱۳۹۵: ۳۵۴)؛ بنابراین پیش‌بینی بلندمدت متغیرهای اقلیمی جهت اطلاع از میزان تغییرات آن‌ها و در نظر گرفتن تمهیدات لازم به منظور تعدیل اثرات سوء ناشی از تغییرات اقلیمی مورد توجه بسیاری از مجامع علمی جهانی قرار گرفته است. بر همین اساس مدل‌های گردش عمومی جو^۳ توسعه یافته‌اند (کویان^۴ و همکاران، ۲۰۰۴). هر چند که این مدل‌ها در مقیاس فضایی اتمسفری و قاره‌ای نتایج معناداری را به نمایش می‌گذارند و بخش بزرگی از پیچیدگی سیستم کره زمین را ترکیب می‌کنند، اما ذاتاً قادر نیستند که دینامیک و اشکال با شبکه ریزمقیاس‌تر محلی را به نمایش گذارند (ویگلی^۵ و همکاران، ۱۹۹۰؛ شارما^۶ و همکاران، ۲۰۰۷؛ کارتر^۷ و همکاران، ۱۹۹۴)؛ بنابراین ارزیابی تأثیر تغییرات در مقیاس محلی نیازمند رویکردی است

^۱ Mahmood & Babel

^۲ IPCC

^۳ General Circulation Model (GCM)

^۴ Qian

^۵ Wigley

^۶ Sharma

^۷ Carter



تا شکاف موقتی و فضایی بین متغیرهای اقلیمی بزرگ مقیاس و متغیرهای هواشناسی با مقیاس محلی را پر کند که در این مورد رویکرد اساسی همان تکنیک‌های ریزمقیاس گردانی هستند (ویلیبی^۱ و همکاران، ۲۰۰۲). امروزه مدل‌های گردش عمومی جو قوی‌ترین ابزار برای تولید سناریوهای اقلیمی است (صالح‌پورجم، ۱۳۹۳: ۶۷). در واقع مدل‌های گردش عمومی هیچ‌گاه نمی‌توانند مستقیم برای پیش‌بینی‌های منطقه‌ای یا نقطه‌ای استفاده شوند که به دو دسته آماری و دینامیکی تقسیم می‌شوند (شمسی‌پور، ۲۰۱۳). معتبرترین ابزار جهت ریزمقیاس گردانی داده‌های GCM به ویژه در کشور ما استفاده از روش‌های آماری است (گودرزی و همکاران، ۱۳۹۴: ۱۲). از جمله مدل‌های ریزمقیاس نمایی آماری که امروزه مورد استفاده قرار می‌گیرد مدل SDSM است (صمدی و همکاران، ۱۳۹۳: ۱۹). مدل SDSM از مدل‌های ریزمقیاس نمایی تابع انتقالی آماری است (ویلیبی^۲ و داوسون^۳، ۲۰۰۷: ۳) که به عنوان پرکاربردترین مدل ریزمقیاس نمایی در سطح جهان شناخته شده است (کالیبلی^۴ و دیکبی^۵، ۲۰۰۵: ۳۰۷).

با توجه به تحقیقات صورت گرفته و پیشینه مطالعاتی می‌توان به پژوهش در رابطه با متغیرهای اقلیمی اشاره کرد که از جمله هارپام^۶ و همکاران (۲۰۰۵: ۳۱۲) با استفاده از مدل‌های شبکه عصبی و مدل SDSM مقدار بارندگی را پیش‌بینی کردند، نتایج حاکی از عملکرد بهتر مدل شبکه عصبی مصنوعی بودند. صمدی^۷ و همکاران (۲۰۱۱: ۱۹) پژوهشی را با عنوان بررسی توانایی مدل ریزمقیاس گردانی SDSM در پیش‌بینی شبیه‌سازی برای تشخیص آب و هوا در استان خراسان انجام دادند؛ نتایج آن حاکی از توانایی خوب برای شبیه‌سازی پیش‌بینی شونده‌ها مانند حداقل و حداکثر دما و بارش وجود دارد و تفاوت معنی‌داری با ۰/۵ خطاهای بحرانی وجود ندارد. تاتسومی^۸ و همکاران (۲۰۱۴: ۱۲۰) اثرات تغییرات آب و هوایی را بر دماهای حداقل و حداکثر روزانه دما و ابرناکی در منطقه شیکوکو با رویکرد مدل ریزمقیاس نمایی آماری بررسی کردند. طی این بررسی نتایج آن نشان داد که برازش خطی منفی بین تغییرات در TMAX و در ابرناکی در زمستان دارای معنی‌داری بودند، در حالی که رابطه بین دو تغییر در تابستان آشکار

^۱ Wilby

^۲ Wilby

^۳ Dawson

^۴ Coulibaly

^۵ Dibike

^۶ Harpham

^۷ Samadi

^۸ Tatsumi

نمود. در پژوهشی دیگر، محمود و بابل (۵۶:۲۰۱۴) با مطالعه تغییرات آینده در درجه حرارت‌های فرین با استفاده از مدل ریزمقیاس گردانی (SDSM) در منطقه مرزی حوضه رودخانه جهلوم به این نتیجه رسیدند که در این حوضه تغییرات در دماهای فرین در آینده تحت سناریوی A2 و B2 با مدل SDSM افزایش تعداد روزها و شب‌های گرم در مقابل روزها و شب‌های سرد در هر سه دوره آینده (۲۰۱۱-۲۰۴۱ و ۲۰۴۱-۲۰۷۰ و ۲۰۷۰-۲۰۹۹) کاهش را پیش‌بینی کرده است. گلچا^۱ و مولونگو^۲ (۵:۲۰۱۶) با تولید سناریو برای بارش و دما در مقیاس محلی با استفاده از SDSM در حوضه رودخانه وامی روو در تانزانیا به این نتیجه رسیدند متوسط حداکثر درجه حرارت ماهانه در سانی‌گرادی ۲۰۲۰ و ۲۰۸۰ با روند افزایش ۰/۲ تا ۰/۵ درجه سانتی‌گراد و حداقل درجه حرارت در طول مدت مشابه روند کاهشی ۰/۴- تا ۱/۵- درجه سانتی‌گراد خواهد داشت. صمدی نقاب و همکاران (۳۱:۱۳۹۰) در مطالعه‌ای که انجام دادند با به‌کارگیری مدل جهت ریزمقیاس نمایی داده‌های بارش و دما مطالعه موردی پیش‌بینی‌های اقلیمی ایستگاهی در ایران نشان دادند که بین مقادیر ریزمقیاس شده بارش، دمای کمینه و بیشینه و مقادیر واقعی آن‌ها تفاوت معناداری با خطای بحرانی ۰/۵ وجود ندارد. سبحانی و همکاران (۴۷:۱۳۹۴) با بررسی کارایی الگوهای ریزمقیاس نمایی آماری SDSM و LARS-WG در شبیه‌سازی متغیرهای هواشناسی در حوضه آبریز دریاچه ارومیه الگوی SDSM را در دو ایستگاه بررسی کردند و دریافتند که کمینه و بیشینه دمای روزانه عملکرد بهتری نسبت به الگوی LARS-WG دارد. مقالات متعددی در ایران و در جهان در این زمینه از جمله مطالعات پژوهشگرانی مانند رجبی^۳ و شعبانلو^۴ (۲۰۱۳)، هونگ^۵ و همکاران (۲۰۱۲)، عباس‌نیا^۶ و همکاران (۲۰۱۶)، قرمزچشمه و همکاران (۱۳۹۲)، سلاجقه و همکاران (۱۳۹۵)، گلکار و همکاران (۱۳۸۸)، دستجردی و حسینی (۱۳۸۹) و... است که با استفاده از ریزمقیاس نمایی SDSM و شبکه عصبی مصنوعی انجام شده است. شبکه‌های عصبی مصنوعی که زیر مجموعه سیستم‌های هوشمند هستند قادرند با تکنیک‌های قوی آموزشی، خصوصیات سیستم را از داده‌های وسیع موجود به دست آورند. این روش در نیل به اهداف علمی چون هواشناسی که دارای سیستم‌های غیرخطی و پیچیده‌ای هستند کاربردهای زیادی دارد (صلاحی و همکاران، ۶۰:۱۳۸۹). در این تحقیق سعی می‌شود تا متغیر اقلیمی دمای حداقل روزانه ایستگاه ارومیه با دو مدل ریزمقیاس نمایی آماری SDSM و

^۱ Gulacha

^۲ Mulungu

^۳ Rajabi

^۴ Shabanlou

^۵ Huang

^۶ Abbasnia



شبکه عصبی مصنوعی با استفاده از مدل گردش عمومی جو (Hadcm3) تحت سناریوهای A2 و B2 شبیه‌سازی شده و پیش‌بینی صورت گیرد، همچنین کارایی مدل‌ها و عملکرد هردوی آن‌ها مورد بررسی قرار گیرد.

۲- مواد و روش‌ها

موقعیت مورد مطالعه در این پژوهش ایستگاه سینوپتیک شهرستان ارومیه است که در طول جغرافیایی ۴۵ درجه و ۳ دقیقه شرقی و عرض جغرافیایی ۳۷ درجه و ۴۰ دقیقه شمالی با ارتفاع ۱۳۲۸ متر واقع شده است (www.irimo.ir). از دو نوع داده برای مدل SDSM و شبکه عصبی مصنوعی استفاده شد که عبارتند از:

۱- داده دمای حداقل روزانه برای دوره آماری ۱۹۶۱-۲۰۱۵ استفاده گردید که از سازمان هواشناسی اخذ شد.

۲- داده‌های مدل جهانی گردش عمومی Hadcm3^۱ تحت سناریوهای A2 و B2 مورد

استفاده قرار گرفت (داده‌های مرکز ملی پیش‌بینی متغیرهای محیطی کانادا^۲

<http://ccds-dscc.ec.gc.ca>).

این مدل اولین بار در سال ۲۰۰۲ توسط ویلی و همکاران تحت عنوان نسخه ۲/۱ ارائه شد. این مدل از نوع مدل‌های توابع انتقالی است. در واقع بهترین هیبریدی از مدل‌های آماری به حساب می‌آید و تاکنون کارایی آن در نقاط مختلف جهان مورد ارزیابی قرار گرفته است، به‌طوری‌که نسبت به سایر مدل‌های ریزمقیاس‌نمایی نتایج رضایت‌بخشی را ارائه نموده است. مدل قادر است در هر مرحله اجرا بین ۱ تا ۱۰۰ بار داده‌ها را شبیه‌سازی کند (آبکار و همکاران، ۱۳۹۲: ۵). در این پژوهش با استفاده از مدل ریزمقیاس‌نمایی آماری SDSM و شبکه عصبی مصنوعی دمای حداقل روزانه شبیه‌سازی شده و عملکرد هر دو مدل مورد ارزیابی و مقایسه قرار گرفت. ریزمقیاس‌نمایی داده‌های مشاهداتی روزانه و پیش‌بینی‌کننده‌ها و پیش‌بینی‌کننده‌های بزرگ مقیاس حاصل از گردش عمومی جو (Hadcm3) پس از آماده‌سازی داده‌های مشاهداتی و کنترل کیفیت داده‌های آن‌ها انجام شد. ریزمقیاس‌نمایی متغیرهای اقلیمی در مدل SDSM به ترتیب زیر انجام می‌گیرد: ۱- آماده‌سازی داده‌های پیش‌بینی‌شونده و پیش‌بینی‌کننده‌های بزرگ‌مقیاس، ۲- کنترل کیفی داده‌ها و تغییر شکل داده‌ها، ۳- انتخاب

¹ Hadley Center for Climate Prediction

² The National Center for Environmental Prediction

بهترین متغیرهای پیش‌بینی‌کننده، ۴- کالیبره نمودن مدل، ۵- تولید مولد هواشناسی با استفاده از پیش‌بینی‌کننده مشاهداتی، ۶- آنالیز آماری، ۷- خروجی گرافیکی مدل و ۸- تولید سناریو اقلیمی با بهره‌گیری از پیش‌بینی‌کننده‌های اقلیمی مدل (سلاجقه و همکاران، ۱۴:۱۳۹۵). از داده‌های ۳۰ ساله داده‌های مرکز ملی پیش‌بینی متغیرهای محیطی^۱ از سال ۱۹۶۱-۱۹۹۰ که شامل ۲۶ متغیر مستقل اتمسفری است برای کالیبره کردن و ارزیابی مدل استفاده شد و مدل در مرحله ارزیابی به تعداد ۵ تا ۱۰۰ بار شبیه‌سازی شد و هر یک از این شبیه‌سازی‌ها براساس شاخص‌های ضریب همبستگی و میانگین مربعات خطا مورد ارزیابی قرار گرفت و تعداد شبیه‌سازی‌های مورد نظر که جهت بهینه‌سازی مدل بودند انتخاب شد و بر این اساس شبیه‌سازی بهینه برای پارامتر مورد نظر که ۳۵ بود برای دوره‌های آتی به کار گرفته شد. در آخرین مرحله ارزیابی که با استفاده از داده‌های Hadcm3 تحت سناریوهای A2 و B2 برای شبیه‌سازی در ۴ دوره سی‌ساله انجام گرفت دوره پایه ۱۹۶۱-۱۹۹۰ و دهه ۲۰ (۲۰۱۱-۲۰۴۰) و دهه ۵۰ (۲۰۴۱-۲۰۷۰) و دهه ۸۰ (۲۰۷۱-۲۰۹۹) در نظر گرفته شد. در ابتدا در هر دو مدل ریزمقیاس‌نمایی SDSM و شبکه عصبی مصنوعی با توجه به قرار گرفتن ایستگاه ارومیه در پیکسل‌های مشخص شده در Hadcm3، پیکسل مورد نظر انتخاب شد. در مراحل بعدی همبستگی بین متغیرهای پیش‌بینی‌شونده^۲ (دمای حداقل) و پیش‌بینی‌کننده‌ها^۳ که شامل ۲۶ متغیر داده‌های جوی بودند محاسبه شده و متغیرهای مستقل از بین ۲۶ متغیر انتخاب شدند. مشخصات انتخاب شده برای مطالعه در مدل SDSM و شبکه عصبی مصنوعی در جداول ۱ و ۲ نشان داده شده است. با توجه به این‌که متغیرهای پیش‌بینی‌کننده می‌تواند روابط مختلفی با داده‌های پیش‌بینی‌شونده داشته باشد؛ بنابراین متغیرهایی حائز اهمیت هستند که دارای بالاترین ضریب همبستگی و پایین‌ترین خطا باشند. با توجه به این امر متغیرهای پیش‌بینی‌کننده انتخاب شدند. این کار با محاسبه سه شاخص ضریب همبستگی کلی^۴ و ضریب همبستگی جزئی^۵ و درصد کاهش همبستگی جزئی^۶ صورت گرفت و بالاترین همبستگی و کمترین درصد کاهش همبستگی جزئی پیش‌بینی‌کننده‌ها انتخاب شد. درصد کاهش همبستگی جزئی مطلق توسط ضریب همبستگی مطلق بین یک پیش‌بینی‌شونده و پیش‌بینی‌کننده و ضریب همبستگی جزئی بین پیش‌بینی‌شونده و پیش‌بینی‌کننده با استفاده از رابطه (۱) به دست می‌آید (محمود و بابل، ۱۴:۵۶).

^۱ National Centers for Environmental Prediction (NCEP)

^۲ Perdictand

^۳ Perdetector

^۴ Pearson Correlation Coefficient

^۵ Partial Correlation Coefficient

^۶ Percentage Reduction



$$PR = \frac{Pr - R}{R} \quad (1)$$

PR = درصد کاهش همبستگی جزئی با توجه به ضریب همبستگی؛

R = ضریب همبستگی بین پیش‌بینی‌کننده و پیش‌بینی‌شونده؛

جدول ۱ ویژگی‌های مدل گردشی عمومی جو به عنوان ورودی به مدل SDSM و شبکه عصبی مصنوعی

مدل گردش عمومی جو	پیکسل ایستگاه ارومیه	هیأت بین الدولی تغییر اقلیم	گزارشات ویژه سناریوهای انتشار	توصیف	تفکیک مکانی	Reference
HADCM3	طول	۱۳	IPCC4	A2	رشد سریع اقتصادی	۲/۵×۳/۷۵ Met Office, Hadley Center for Climate Prediction & Research (HCCPR), United Kingdom
	عرض	۲۰		B2	پایداری محیط زیست جهانی	

جدول ۲ ضریب همبستگی متغیرهای پیش‌بینی‌کننده با دمای حداقل در ایستگاه ارومیه

ردیف	پیش‌بینی‌کننده (NCEP)	توصیف	همبستگی کلی	همبستگی جزئی	درصد کاهش همبستگی جزئی
۱	ncepmslpas	میانگین فشار سطح دریا	-۰/۷۷۱	-۰/۷۰۸	-۰/۰۸
۲	ncepp500as	ارتفاع ژئوپتانسیل هکتوپاسکال	۰/۸۰۲	۰/۷۶۷	-۰/۰۴
۳	nceptempas	میانگین دمای ۲ متری سطح زمین	۰/۹۲۸	۰/۸۰۱	-۰/۱۳

از میان متغیرهای داده‌های مرکز ملی پیش‌بینی متغیرهای محیطی، ۳ متغیر میانگین فشار سطح دریا و ارتفاع ژئوپتانسیل ۵۰۰ هکتوپاسکال و میانگین دما در ارتفاع ۲ متری که دارای بالاترین همبستگی با متغیر وابسته (دمای حداقل) به عنوان ورودی در مدل SDSM و شبکه عصبی مصنوعی انتخاب شدند. در مطالعه حاضر برای عملکرد مدل ریزمقیاس نمایی و شبکه عصبی مصنوعی از دو شاخص ضریب همبستگی و ریشه میانگین مربعات خطا^۱ برای اعتبارسنجی مدل‌ها استفاده شد که معادلات آن به شرح روابط (۲،۳) است: (ونگ و همکاران، ۲۰۱۲: ۱۱۴؛ اباسنیا^۲ و همکاران، ۲۰۱۶: ۵۲).

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (۲)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (۳)$$

میزان کمترین خطای مربعات و همبستگی به‌دست‌آمده از مدل SDSM به ترتیب برابر با ۲/۹۷ و ۰/۹۳٪ است و با توجه به این امر پارامتر مناسب برای شبیه‌سازی انتخاب شد. شبکه‌های عصبی مصنوعی به عنوان شبیه‌سازی تجربی برای نخستین بار از تعیین رابطه ریاضی توانایی مغز انسان به وسیله مک کالچ و پیتر ارائه گردیدند (رضایی و همکاران، ۱۳۹۴: ۸). در واقع مدل ساده شده‌ای از مغز انسان است که توانایی رخ دادن فرآیندها و ترکیبات دلخواه غیرخطی برای ارتباط بین ورودی و خروجی‌های هر سیستمی را داراست، همچنین این شبکه با داده‌های موجود طی فرآیند یادگیری آموزش داده می‌شود و به منظور پیش‌بینی در آینده استفاده می‌گردد (عرفانیان و همکاران، ۱۳۹۱: ۳). شبکه عصبی انتخاب شده برای تحلیل داده‌ها و پیش‌بینی دمای حداقل متشکل از لایه ورودی، میانی و خروجی است که معماری آن بر مبنای ارتباطات بین نرون‌ها در لایه‌های مختلف است. در تخمین تعداد نرون‌ها شبکه مورد نظر با تعداد نرون‌های مختلف آزمایش شد و سرانجام شبکه با تعداد ۲ نرون انتخاب شد. در کل روش و قانون

^۱ Root Mean Square Error

^۲ Wang

^۳ Abbasnia



خاصی برای انتخاب و تعبیه تعداد مناسب نرون‌های لایه‌های پنهان وجود ندارد و این کار بسته به تجربه و مهارت کاربر شبکه عصبی و از طریق آزمون و خطا انجام می‌شود (قویدل رحیمی، ۱۳۸۹: ۷۰). داده‌های میانگین فشار سطح دریا و ارتفاع ژئوپتانسیل ۵۰۰ هکتوپاسکال و میانگین دمای ۲ متری سطح زمین به عنوان ورودی شبکه و دمای حداقل ایستگاه ارومیه به عنوان خروجی در نظر گرفته شد. مراحل طراحی و پیاده‌سازی شبکه عصبی عبارت از ۱- گردآوری و پیش‌پردازش داده‌های مورد نیاز برای شبکه عصبی، ۲- تعیین نوع و ساختار مناسب برای شبکه عصبی و ایجاد شبکه کارآمد، ۳- آموزش دادن شبکه با قسمتی از داده‌های گردآوری شده (مرحله آموزش)، ۴- آزمایش شبکه آموزش داده شده با باقی‌مانده داده‌ها (مرحله آزمون)، ۵- در صورت قابل قبول بودن نتیجه آزمون، ذخیره شبکه و در غیر این صورت تکرار مرحله ۲ تا ۴ (دستجردی و حسینی، ۱۳۸۹: ۲۱) است. پارامترهای ورودی به شبکه به سه بخش آموزش و ارزیابی و تست تقسیم شده که ۷۰٪ داده‌ها برای مجموعه آموزش و ۱۵٪ داده‌ها به منظور ارزیابی شبکه همراه با عمل یادگیری و آموزش در شبکه و ۱۵٪ بقیه داده‌ها برای تست شبکه در نظر گرفته شد. نتایج خروجی شبکه در مراحل آموزش و ارزیابی و تست در جدول ۳ نشان داده شده است. شبکه انتخاب شده با یک لایه پنهان و ۲ نرون نسبت به تعداد نرون‌های دیگر مطلوبیت بیشتری داشت.

جدول ۳ نتایج خروجی شبکه عصبی در مرحله آموزش و ارزیابی و تست

نتایج	همبستگی	ریشه میانگین مربعات خطا
آموزش	۰/۹۳	۰/۰۶
ارزیابی	۰/۹۳	۰/۸
تست	۰/۹۳	۰/۲

همان‌طور که ملاحظه می‌شود براساس ضریب همبستگی و میانگین مربعات خطا شبکه مورد نظر به صورت یک لایه پنهان با ۲ نرون در این لایه و تابع سیگموئید و یک لایه خروجی همراه با تابع مشخص شده که به صورت خطی است در نظر گرفته شد.

۲-۱- الگوریتم لونبرگ-مارکوئرت

از میان روش‌های مختلف آموزش به روش پس انتشار خطا، الگوریتم لونبرگ مارکوئرت دارای همگرایی سریع در آموزش شبکه‌های با اندازه متوسط است، الگوریتم پس انتشار خطا، وزن‌های

شبکه و مقادیر بایاس‌های مختلف آموزش را در جهتی تغییر می‌دهد که تابع عملکرد با سرعت بیشتری کاهش یابد (گلایی و همکاران، ۱۳۹۲: ۱۳).

۲-۲- الگوریتم گرادیان نزولی^۱

الگوریتم استاندارد گرادیان نزولی فقط از تقریب محلی شیب سطح کارآمدی در تعیین بهترین جهت حرکت وزن‌ها برای رسیدن به کمترین خطا، استفاده می‌کند. این روش معمولاً از مشتقات دوم و یا تقریبی از آن‌ها برای تصحیح وزن‌ها استفاده می‌نماید (گلایی و همکاران، ۱۳۹۲: ۱۳).

۲-۳- الگوریتم قانون گذاری بیزی^۲

به‌روزرسانی مقادیر وزن و بایاس‌ها را مطابق با بهینه‌سازی لونبرگ-مارکوئرت به حداقل می‌رساند. الگوریتم ترکیبی از مربعات خطاها و وزن‌ها را کمینه می‌کند، پس از آن ترکیب صحیح تولید به شبکه که به خوبی قابل تعمیم باشد تعیین می‌کند، این فرآیند استنباط یا تعمیم بیزی نامیده می‌شود (آگاروال^۳ و همکاران، ۲۰۰۵: ۴).

شبکه با سه الگوریتم لونبرگ مارکوئرت و الگوریتم گرادیان نزولی و الگوریتم قانونگذاری بیزی آموزش داده شد. میزان خطای میانگین مربعات در سه الگوریتم یادگیری به ترتیب ۲/۹۱- ۲/۹۷-۲/۹۳ برای الگوریتم‌های لونبرگ مارکوئرت و الگوریتم گرادیان نزولی و الگوریتم قانونگذاری بیزی به دست آمد. با توجه به کمترین خطا در این راستا از شبکه پس انتشار خطا و با الگوریتم یادگیری مارکوئرت- لونبرگ برای آموزش شبکه استفاده شد. براساس آزمون‌های مورد بررسی، بهترین تکنیک یادگیری از میان سه الگوریتم یادگیری لونبرگ مارکوئرت انتخاب شد، زیرا این الگوریتم سرعت بالا، دقت بالا و خطای کمتری نسبت به مدل‌های دیگر دارد.

۳- نتایج و بحث


به منظور پیش‌بینی دمای حداقل در ایستگاه سینوپتیک ارومیه در دوره‌های آتی از مدل ریزمقیاس نمایی SDSM و شبکه عصبی مصنوعی بهره گرفته شد. در شبکه عصبی مصنوعی همان‌طور که بیان شد شبکه با سه الگوریتم لونبرگ مارکوئرت و الگوریتم گرادیان نزولی و الگوریتم قانون گذاری بیزی و براساس تعداد نرون‌های مختلف که از ۱ نرون شروع شده و تا ۲۰

¹ Scaled Conjugate Gradient

² Bayesian Regularization

³ Aggarwal

نرون مورد آزمون قرار گرفت و با توجه به نتایج به دست آمده شبیه‌سازی در شبکه عصبی مصنوعی صورت گرفت و نتایج حاصل از شبکه عصبی مصنوعی با نتایج شبیه‌سازی مدل SDSM مورد مقایسه قرار گرفت. همان‌طور که در شکل ۱ مشاهده می‌شود مقایسه تغییرات دمای حداقل در دوره پایه در داده‌های مشاهداتی و داده‌های شبیه‌سازی شده توسط مدل SDSM و شبکه عصبی مصنوعی در بازه زمانی ۱۹۶۱-۱۹۹۰ نشان داده شده است. دمای حداقل برآورد شده در دوره شبیه‌سازی شده برای دوره پایه برآورد مدل SDSM و شبکه عصبی مصنوعی در ماه ژانویه ۱/۸ و ۲/۳ درجه سانتی‌گراد نسبت به داده مشاهده شده اختلاف داشته است. در دومین ماه زمستان اختلاف دمای شبیه‌سازی شده با داده مشاهده‌ای در دو مدل مورد نظر به ترتیب ۱/۴ و ۱/۹ درجه سانتی‌گراد رسیده که در این ماه نیز حداقل دما کاهش دما را در پی داشته است. نتایج شبکه عصبی افزایش دمای بیشتری را نسبت به مدل SDSM در دوره پایه ۱۹۶۱-۱۹۹۰ نشان می‌دهد. برآورد مدل SDSM به داده‌های واقعی نزدیک‌تر بوده است.




شکل ۱ مقایسه دمای حداقل مشاهداتی و شبیه‌سازی شده آینده در مدل SDSM و شبکه عصبی مصنوعی در بازه زمانی ۱۹۶۱-۱۹۹۰ (ایستگاه ارومیه)

۳-۱- پیش‌بینی تغییرات دمای حداقل در ایستگاه ارومیه با استفاده از مدل SDSM و شبکه عصبی مصنوعی در سانتی‌گرادی آتی

مقایسه بین مقدار میانگین ماهانه دمای حداقل مشاهداتی و شبیه‌سازی شده ایستگاه ارومیه طی دوره واسنجی ۱۹۶۱-۱۹۹۰ و دوره‌های ارزیابی ۲۰۱۱-۲۰۴۱، ۲۰۴۱-۲۰۷۰، ۲۰۷۰-۲۰۷۱-۲۰۹۹ با استفاده از مدل گردش عمومی جو (HadCM3) و براساس سناریوهای A2، B2 در شبکه عصبی مصنوعی و مدل SDSM در شکل ۳ نشان داده شده است. چگونگی وارد کردن خروجی سناریوها به شبکه عصبی بدین صورت بود که بعد از این‌که معلوم شد ۲۶ متغیر NCEP با داده‌های ایستگاهی همبستگی بالایی داشته از میان متغیرهای مورد نظر متغیرهای فشار سطح دریا و ارتفاع ژئوپتانسیل متر ۵۰۰ هکتوپاسکال و میانگین دمای ۲ متری انتخاب شد که داده‌های مورد نظر پس از انتخاب شدن به محیط نرم‌افزار متلب وارد شده و در مرحله بعد پس از آموزش عملیات شبیه‌سازی اجرا شد. بررسی و تحلیل تغییرات روند دمای حداقل در ایستگاه ارومیه نشان می‌دهد که در دوره پایه ۱۹۶۱-۱۹۹۰ (الف) براساس سناریوی A2 و B2 در مدل SDSM و شبکه عصبی در ماه ژانویه دمای حداقل برآورد شده توسط دو سناریوی مورد نظر به نسبت دمای حداقل یکسانی را نشان می‌دهند، ولی نسبت به داده مشاهده‌ای اختلاف دارند و حدود ۲/۶ درجه سانتی‌گراد در مدل SDSM و ۲/۸ درجه در شبکه عصبی دمای بیشتری را تخمین زده‌اند و همین روند در ماه فوریه با کاهش ۲/۲ درجه‌ای نسبت به داده مشاهده‌ای نشان داده شده است. در ماه‌های آوریل و می دمای حداقل برآورده شده در مدل SDSM توسط سناریوهای A2 و B2 دمای کمتری را نسبت به مدل شبکه عصبی مصنوعی و داده‌های مشاهداتی نشان می‌دهد و با داده‌های مشاهده‌ای حدود ۱/۹ درجه تفاوت دمایی دارند، ولی در ماه جولای در هر دو مدل نسبت به داده مشاهده‌ای اختلاف جزئی یک‌صدم درجه‌ای دارند. در ماه آگوست دو سناریوی مدل SDSM نیم درجه اختلاف دما با مشاهده شده دارند و بیشتر از داده واقعی برآورده کرده است، اما مدل شبکه عصبی نزدیک به واقعیت را نشان می‌دهد به طوری که این اختلاف یک‌دهم درجه بیشتر از داده واقعی است که افزایش دما را می‌توان در این ماه مشاهده کرد. در ماه نوامبر در سناریوهای A2 و B2 داده‌های برآورد شده کمتر از مقدار واقعی است و به صورت خیلی ناچیز این تغییرات در دماهای شبیه‌سازی شده توسط مدل‌ها دیده می‌شود. همان‌طور که ملاحظه می‌شود بیشترین روند تغییرات دماهای حداقل در ایستگاه ارومیه در ماه‌های ژانویه و فوریه نسبت به داده‌های واقعی مشاهده شد. نتایج به دست آمده برای دهه دوم ۲۰۱۱-۲۰۴۰ (ب) نشان‌دهنده این است که به طور متوسط دمای حداقل نسبت به دوره پایه براساس سناریوهای A2 و B2 در مدل SDSM و شبکه عصبی در دوره زمانی ۲۰۱۱-۲۰۴۰ میلادی در ماه‌های ژانویه و فوریه در هر دو مدل براساس دو سناریوی مورد نظر تقریباً ۳/۳ درجه تفاوت دمایی با داده‌های مشاهده‌ای دارد. بر این اساس می‌توان گفت طی بررسی انجام شده در این دهه روند تغییرات دمای حداقل



نشان داده که از میزان دماهای حداقل در ایستگاه ارومیه کاسته شده است. در این دهه میزان دمای حداقل در ماه‌های ذکر شده کاهش زیادی خواهد داشت. در ماه‌های ژوئن و جولای و آگوست و سپتامبر بین ۱/۵ تا ۲/۵ درجه تغییرات دمایی حداقل دماها با مقادیر برآورده شده توسط مدل SDSM و شبکه عصبی مصنوعی دیده می‌شود که حاکی از برآورد بیشتر مدل SDSM نسبت به شبکه است. تفاوت مقادیر برآوردی مدل SDSM با داده واقعی تقریباً به ۲ درجه سانتی‌گراد براساس سناریوهای مورد نظر می‌رسد و شاهد افزایش ۲ درجه‌ای دما در این ماه‌ها در آینده نه‌چندان دور براساس مدل SDSM خواهیم بود. میانگین ماهانه مقادیر برآورد شده توسط مدل SDSM و شبکه عصبی مصنوعی نشان می‌دهد که تغییر دماهای حداقل در ایستگاه ارومیه در این دهه براساس سناریوهای مورد نظر به ۱/۵ درجه سانتی‌گراد خواهد رسید. در دهه ۲۰۴۱-۲۰۷۰ (ج) روند کاهش دما در دماهای حداقل ماه‌های ژانویه و فوریه براساس دو سناریوی A2 و B2 با مدل‌های بررسی شده به ترتیب ۴/۷ و ۳/۹ درجه سانتی‌گراد خواهد رسید که نتایج هر دو مدل تقریباً بیان‌کننده همین مطلب است. هر دو مدل با داده مشاهده‌ای اختلاف دما دارد و بیش برآوردی هر دو مدل را در این ماه‌ها نشان می‌دهد و به نحوی می‌توان بیان کرد که با شبیه‌سازی صورت گرفته در این ماه‌ها روند دماهای حداقل تغییر خواهد کرد. در این دهه براساس سناریوی A2 و B2 مدل SDSM و شبکه عصبی در ماه‌های ژوئن، جولای و آگوست دمای حداقل افزایشی تقریباً ۳/۷ درجه‌ای در ایستگاه ارومیه وجود خواهد داشت و ماه سپتامبر افزایش تقریباً ۲ درجه‌ای خواهد بود. در این دهه تغییر میانگین ماهانه دماهای حداقل پیش‌بینی شده حاکی از آن است که دماهای حداقل به طور متوسط به میزان ۲/۵ درجه سانتی‌گراد تغییر را نشان خواهند داد. نتایج بررسی انجام شده برای سال‌های ۲۰۷۱-۲۰۹۹ (د) نشان می‌دهد که افزایش دما براساس سناریوها در دماهای حداقل بیشتر خواهد شد. روند کاهشی دماهای حداقل همچنان ادامه خواهد یافت و با این روند می‌توان گفت در آینده‌ای نه‌چندان دور شاهد زمستان‌ها و فصول سرد کمتری خواهیم بود و شرایط دمایی روزبه‌روز در این ایستگاه تغییر خواهد کرد. با توجه به فصول مختلف سال دماهای حداقل افزایش متفاوتی خواهند داشت. دماهای حداقل به طور متوسط در ماه‌های فصل بهار و تابستان و پاییز و زمستان به ترتیب کاهش تغییرات دماهای حداقل در ایستگاه ارومیه تقریباً در حدود ۴/۱، ۶/۲، ۳/۳، ۵/۰۵ درجه‌ای خواهد بود که می‌توان گفت که شاهد افزایش دما در دهه سوم در دماهای کم در ایستگاه ارومیه خواهیم بود. بررسی میزان تغییرات میانگین ماهانه مقادیر پیش‌بینی شده توسط دو مدل نشان می‌دهد که میزان تغییرات تقریباً در حدود ۳/۹ درجه سانتی‌گراد در دهه ۲۰۷۱-۲۰۹۹ خواهند بود.



شکل ۳ مقایسه میانگین ماهانه دهه‌ای مقادیر مشاهداتی با سناریوهای شبیه‌سازی شده A2 و B2 در ایستگاه ارومیه، الف- مدل SDSM و شبکه عصبی مصنوعی (۱۹۶۱-۱۹۹۰)، ب- مدل SDSM و شبکه عصبی مصنوعی (۲۰۱۱-۲۰۴۰)، ج- مدل SDSM و شبکه عصبی مصنوعی (۲۰۴۱-۲۰۷۰)، د- مدل SDSM و شبکه عصبی مصنوعی (۲۰۷۱-۲۰۹۹)

در این پژوهش نتایج خروجی به دست آمده از دو مدل با سناریوهای یاد شده تقریباً نتایج یکسانی را با اندکی تفاوت نسبت به هم نشان دادند. هرچند مدل SDSM نسبت به داده‌های مشاهده‌ای در بعضی ماه‌ها با واقعیت تفاوت کمی داشته، اما نتایج شبیه‌سازی آن به داده‌های واقعی نزدیک بود و هر دو مدل در بعضی ماه‌ها بیش برآوردی و کم برآوردی براساس دو سناریو را نشان می‌دهند. نتایج دو سناریو کاهش دماهای حداقل را در ایستگاه ارومیه توسط مدل‌های به کار گرفته شده در دوره‌های آتی نسبت به دوره پایه را بیان می‌کنند. در بین سانتی‌گرادی مورد مطالعه دهه ۲۱۰۰ بیشترین کاهش در دماهای حداقل را نسبت به دوره پایه براساس مدل‌ها نشان داد که هرچه به سال‌های آینده نزدیک‌تر می‌شویم دماهای حداقل کمتری را در ایستگاه



مورد نظر شاهد خواهیم بود. با توجه به مسائل بیان شده روند تغییرات دمایی در این ایستگاه با مقادیر پیش‌بینی شده نشان داد دماهای حداقل در ایستگاه مورد نظر تغییر خواهند کرد؛ چه بسا که این روند، روند نزولی دماهای حداقل را در پی داشته باشد و همچنان که نتایج مورد بررسی کم شدن دماهای حداقل را در فصول سرد و افزایش دما را در سال‌های نچندان دور تأیید می‌کنند.

۴- نتیجه‌گیری

مقایسه یافته‌های این پژوهش در شبیه‌سازی متغیر اقلیمی دمای حداقل ایستگاه ارومیه نشان داد که یافته‌های این تحقیق با نتایج مطالعات مشابه سایر پژوهشگران در زمینه مطالعات ریزمقیاس نمایی مدل SDSM با نتایج مطالعات سبحانی و همکاران (۱۳۹۴)، گودرزی و همکاران (۱۳۹۴)، قاسمی فر و همکاران (۱۳۹۶)، سلاجقه و همکاران (۱۳۹۶) ایشان به این نتیجه دست یافتند که مدل SDSM دارای توانائی مناسب در شبیه‌سازی دمای حداقل است. شبکه عصبی مصنوعی با مطالعات هوشیار و همکاران (۱۳۹۱) همسو بوده و نتایج حاصل از این تحقیق را مبنی بر عملکرد بهتر و مطلوب مدل SDSM در ریزمقیاس نمایی دمای حداقل از مدل شبکه‌های عصبی مصنوعی تأیید می‌نمایند و عدم قطعیت کمتر این مدل را نشان می‌دهد که دارای فرآیند شبیه‌سازی وقت‌گیر و پیچیده است. تغییر اقلیم می‌تواند باعث تغییرات زمانی و مکانی متغیرهای اقلیمی شود. خصوصیات این متغیرها می‌تواند اثرات زیان باری بر اجزای اکوسیستم داشته باشد. با توجه به آنچه که ارائه شد در مطالعه حاضر خروجی‌های حاصل از مدل‌های SDSM و شبکه عصبی مصنوعی با توجه به دو سناریوی A2 و B2 برای شبیه‌سازی دماهای حداقل در ایستگاه ارومیه در سال‌های آتی مورد بررسی قرار گرفت. نتایج حاصل از این مطالعه نشان داد که دو مدل مورد نظر تقریباً شبیه‌سازی‌های یکسانی را در دو سناریو انجام داده‌اند. مدل SDSM و شبکه عصبی مصنوعی در ماه ژانویه به ترتیب افزایش دما در حدود ۱/۸ و ۲/۳ و نیز در فوریه ۱/۴، ۱/۹ درجه که نسبت به مقادیر مشاهده‌ای در دماهای حداقل در دوره پایه ۱۹۶۱-۱۹۹۰ محاسبه شده است. در ماه‌های بعدی اختلاف ناچیزی در هر دو مدل با داده‌های مشاهداتی مشاهده شد. در دوره ۲۰۱۱-۲۰۴۰ دمای ماه‌های ژانویه در سناریوی A2 و B2 در مدل SDSM و شبکه عصبی مصنوعی به ترتیب افزایش دما به طور متوسط ۳/۲، ۴/۰۶، ۱/۴، ۴/۳ و در فوریه در این سناریوها به ترتیب ۳/۲، ۲/۷، ۳/۴، ۲/۹ درجه سانتی‌گراد نسبت به دوره پایه خواهد بود. در سی سال دوم ارزیابی سناریوی A2 برآورد مدل SDSM و شبکه عصبی مصنوعی نسبت به داده مشاهداتی دوره پایه به طور متوسط افزایش ۴/۷ درجه‌ای در ماه ژانویه اتفاق خواهد افتاد که شاهد گرم شدن هوا در این ماه خواهیم بود. در نهایت دماهای

سرد کمتری نسبت به دوره‌های پیشین روی خواهد داد. در دهه آخر روند افزایشی دماها در ایستگاه ارومیه در دماهای حداقل دیده می‌شود و می‌توان گفت که براساس شبیه‌سازی‌های انجام‌شده توسط دو سناریوی مورد نظر افزایش دما را در دماهای حداقل در ایستگاه ارومیه در پی خواهد داشت. دو مدل نتایج مشابهی را در شبیه‌سازی انجام داده‌اند، هر چند که در بعضی مواقع هر دو اختلافی را نسبت به هم داشتند، اما مدل SDSM برآوردی نزدیک به واقعیت را در پی داشت. این نتایج می‌تواند دست کم شرایط اقلیمی احتمالی باشد که در آینده بر اقلیم کنونی ما پدید می‌آیند.

منابع

- آبکار، علی‌جان؛ حبیب‌نژاد، محمود؛ سلیمانی، کریم و نقوی، هرمزد (۱۳۹۲). بررسی میزان کارایی مدل SDSM در شبیه‌سازی شاخص‌های دمایی در مناطق خشک و نیمه‌خشک. فصل‌نامه علمی و پژوهشی مهندسی آبیاری و آب، ش ۱۴، صص ۱-۱۷.
- ایلدرومی، علیرضا؛ زارع‌ایبانه، حمید و بیات‌ورکشی، مریم (۱۳۹۱). برآورد بارش به کمک شبکه عصبی مصنوعی با داده‌های هواشناسی غیربارشی در سه منطقه شیراز، مشهد و کرمان. نشریه علمی پژوهشی جغرافیا و برنامه‌ریزی، ش ۴۳، صص ۲۱-۴۰.
- خوشحال دستجردی، جواد و حسینی، سید محمد (۱۳۸۹). کاربرد شبکه عصبی مصنوعی در شبیه‌سازی عناصر اقلیمی و پیش‌بینی سیکل خشک‌سالی (مطالعه موردی: استان اصفهان). مجله جغرافیا و برنامه‌ریزی محیطی، ش ۳، صص ۱۰۷-۱۲۰.
- حلبیان، امیرحسین، دارند، محمد (۱۳۹۱). پیش‌بینی بارش اصفهان با استفاده از شبکه‌های عصبی مصنوعی. نشریه تحقیقات کاربردی علوم جغرافیایی، ش ۲۶، صص ۴۸-۶۲.
- خوش‌اخلاق، فرامرز؛ غریبی، ابراهیم و شفیعی، ذلیخا (۱۳۹۰). نگرشی بر تغییرات حداقل‌های مطلق دما در پهنه ایران زمین. مجله جغرافیا و برنامه‌ریزی محیطی، ش ۲، صص ۱۹۹-۲۱۶.
- رضایی، مریم؛ نهتانی، محمد؛ مقدم‌نیا، علیرضا؛ آبکار، علیجان و رضایی، معصومه (۱۳۹۴). مقایسه روش‌های شبکه عصبی مصنوعی و SDSM در ریزمقیاس کردن اندازه بارش سالانه شبیه‌سازی شده با HadCM3. مجله مهندسی آب، ش ۸، صص ۱-۱۶.
- سبحانی، بهروز؛ اصلاحی، مهدی و بابائیان، ایمان (۱۳۹۵). کارایی الگوهای ریزمقیاس‌نمایی آماری SDSM و LARS-WG در شبیه‌سازی متغیرهای هواشناسی در حوضه آبریز دریاچه ارومیه. پژوهش‌های جغرافیایی طبیعی، ش ۴۷، صص ۴۹۹-۵۱۶.
- سلاجقه، علی؛ رفیعی‌ساردوئی، الهام؛ مقدم‌نیا، علیرضا؛ ملکیان، آرش؛ عراقی‌نژاد، شهاب خلیقی سیگارودی، شهرام و صالح‌پورجم، امین (۱۳۹۵). پیش‌بینی متغیرهای اقلیمی توسط مدل



چندگانه خطی SDSM در دوره آینده برپای سناریو A2. نشریه مدیریت بیابان، ش ۷، صص ۲۵-۱۲.

صالح پورجم، امین؛ محسنی ساروی، محسن؛ بذرافشان، جواد و خلیقی سیگارودی، شهرام (۱۳۹۴). بررسی اثر تغییر اقلیم بر ویژگی‌های خشکسالی دوره آینده با کاربرد مدل گردش عمومی جو (مطالعه موردی: شمال غربی ایران). مجله مرتع و آبخیزداری، ش ۴، صص ۵۳۷-۵۴۸.

صلاحی برومند، حسینی سیداسعد؛ شائق مغانلو، حسین و سبحانی، بهروز (۱۳۸۹). پیش‌بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی (مطالعه موردی: شهرستان اردبیل). فصل‌نامه تحقیقات جغرافیایی، ش ۳، صص ۷۸-۵۹.

صمدی نقاب، سینا؛ خورشیددوست، علی محمد؛ حبیبی نوخندان، مجید و زابل عباسی، فاطمه (۱۳۹۰). به‌کارگیری مدل SDSM جهت ریزمقیاس نمایی داده‌های GCM بارش و دما مطالعه موردی: پیش‌بینی‌های اقلیمی ایستگاهی در ایران. نشریه پژوهش‌های اقلیم‌شناسی، ش ۵، صص ۶-۲-۱۲.

صلاحی برومند، حسینی، سیداسعد؛ شائق مغانلو، حسین و سبحانی، بهروز (۱۳۸۹). پیش‌بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی (مطالعه موردی: شهرستان اردبیل). تحقیقات جغرافیایی، ش ۳، صص ۷۸-۵۷.

عرفانیان، مریم؛ انصاری، حسین و علیزاده، امین (۱۳۹۱). پیش‌بینی بارش و دمای متوسط ماهانه با استفاده از الگوهای پیوند از دور به کمک شبکه‌های عصبی مصنوعی (مطالعه موردی: ایستگاه سینوپتیک مشهد). مطالعات جغرافیایی مناطق خشک، ش ۱۱، صص ۷۳-۵۳.

گودرزی مسعود؛ صلاحی برومند، حسینی اسعد (۱۳۹۴). ارزیابی عملکرد مدل‌های ریزمقیاس گردانی LARS-WG و SDSM در شبیه‌سازی تغییرات اقلیمی در حوضه آبریز دریاچه ارومیه. مجله علوم و مهندسی آبخیزداری/ایران، ش ۳۱، صص ۲۳-۱۱.

قویدل رحیمی، یوسف (۱۳۸۸). آشکارسازی آماری اثر گرمایش جهانی بر ناهنجاری‌های بارش سالانه جلفا با استفاده از شبکه‌های عصبی مصنوعی، مجله جغرافیا و برنامه‌ریزی محیطی، ش ۲۱، صص ۸۸-۶۵.

قرمزچشمه، باقر؛ رسولی، علی‌اکبر؛ رضائی‌بنفشه، مجید؛ مساح‌بوانی، علیرضا و خورشیددوست، علی محمد (۱۳۹۲). بررسی اثر عوامل مورفو-اقلیمی بر دقت ریزمقیاس گردانی مدل SDSM. نشریه علمی پژوهشی مهندسی و مدیریت آبخیز، ش ۲، صص ۱۶۴-۱۵۵.

قاسمی‌فر، الهام؛ علیجانی، بهلول و سلیقه، محمد (۱۳۹۵). بررسی تغییرات دمایی سواحل جنوبی دریای خزر با استفاده از سه مدل LARSWG، SDSM و مدل شبکه عصبی مصنوعی. جغرافیای طبیعی، ش ۳۴، صص ۴۱-۲۳.

گلکار، فروغ؛ فرهمند، علیرضا و فرهمند، فاطمه (۱۳۸۸). بررسی کاربرد شبکه عصبی مصنوعی در پیش‌بینی بارش منطقه شیراز. همایش ملی مدیریت بحران/آب، صص ۱-۱۰.

گلایی، محمدرضا؛ آخوندعلی، علی محمد و رادمنش، فریدون (۱۳۹۲). مقایسه عملکرد الگوریتم‌های مختلف شبکه عصبی مصنوعی در مدل‌سازی بارندگی فصلی مطالعه موردی؛ ایستگاه‌های منتخب استان خوزستان، نشریه تحقیقات کاربردی علوم جغرافیایی، ش ۳۰، صص ۱۵۱-۱۶۹.

هوشیار، محمود؛ حسینی، سیداسعد و مسگری، ابراهیم (۱۳۹۱). مدل‌سازی دماهای حداقل شهرستان ارومیه با استفاده از مدل‌های رگرسیونی خطی و غیرخطی چندگانه و شبکه‌های عصبی مصنوعی. اندیشه جغرافیایی، ش ۱۲، صص ۱-۳۳.

- Abkar, A., Habibnejad, M., Solimani, K., Naghvi, H. (2013). Evaluation of SDSM Performance in Simulating Temperature Indices in Arid and Semi-arid Regions, Mashhad and Kerman Regions. *the Iranian Society of Irrigation & Water Engineering*, 4(14), 1-17. (in Persian)
- Ildoromi, A., Zareabyaneh, H., Bayatvarkeshy, M. (2013). Rainfall Estimation with Artificial Neural Network Based on Non-Rainfall Weather Data in Shiraz, Mashhad and Kerman Regions. *Geography and Planning*, 17(43), 21-40. (in Persian)
- Khoshhal dastjerdi, J., Hosseini, S. (2010). Application of Artificial Neural Network in Climatic Elements Simulation and Drought Cycle Predication (Case Study: Isfahan Province). *Geography and Environmental Planning*, 21(3), 107-120. (in Persian)
- Halbian, A., Darand, M. (2011). Forecasting of Isfahan Precipitation Using Artificial Neural Networks. *Applied Research of Geographic Sciences*, 12(26), 48-62. (in Persian).
- Gharibi, E., Khoshakhlagh, F., Shafiei, Z. (2011). The Study of the Lowest Temperature Changes in Iran. *Geography and Environmental Planning*, 22(2), 199-216. (in Persian)
- Rezaee, M., Nahtaj, M., Moghadamniya, A., Abkar, A., Rezaee, M. (2015). Comparison of Artificial Neural Network and SDSM Methods in the Downscaling of Annual Rainfall in the HadCM3 Modelling (Case Study: Kerman, Ravar and Rabor), 8(24), 25-40. (in Persian)
- Sobhani, B., Eslahi, M., Babaeian, I. (2015). Efficiency of Statistical Downscaling Models of SDSM and LARS-WG in the Simulation of Meteorological Parameters in Lake Urmia Basin. *Physical Geography Research Quarterly*, 47(4), 499-516. doi: 10.22059/jphgr.2015.56046. (in Persian)
- Salajegheh, A., Rafiei Sardooei, E., Moghaddamnia, A., Malekian, A., Aragheinejad, S., Khalighi Sigaroodi, S., Salehpourjam, A. (2016). Prediction of Climatic Variables using Statistical Downscaling Model (SDSM) in Future under Scenario A2. *Desert Management*, 4(7), 12-25. (in Persian)
- Salehpour jam, A., Mohseni Saravi, M., Bazrafshan, J., Khalighi, S. (2015). Investigation of Climate Change Effect on Drought Characteristics in the Future Period using the HadCM3 model (Case Study: Northwest of Iran). *Range and*



- Watershed Managment*, 67(4), 537-548. doi: 10.22059/jrwm.2015.53472. (in Pershian)
- Boromand, S., Hosseini, A., SHaeghi, H., Sobhani, B (2009) Prediction of Maximum Temperatures Using Artificial Neural Network Model (Case Study: Ardabil City), *Geographic Research*, 25(3)59-78. (in Pershian)
- Samadi, S., Habibi Nokhandan, M., Zabol Abbasi, F. (2013). Using SDSM Model to Downscaling Precipitation and Temperature GCM Data for Study Station Climate Predictions over Iran. *Climate Research*, 1390(5), 57-68. (in Pershian)
- Salahi, B., Hosseini, S., Shaeghi Moghanlo, H., Sobhani, B. (2009). Prediction of Maximum Temperatures Using Artificial Neural Network Model (Case Study: Ardabil City). *Geographical Research*, 25(3), 57-78. (in Pershian)
- Arfanian, M., Ansari, H., Alizadeh, A. (2011). Precipitation and Monthly Average Temperature Prediction Using Distant Graft Patterns Using Artificial Neural Networks (Case study: Synoptic Station of Mashhad). *Geographical Studies of Arid Regions*, 3(11), 53-73. (in Pershian)
- Goodarzi M, salahi B, hosseini A. Performance Analysis of LARS-WG and SDSM Downscaling Models in Simulation of Climate Changes in Urmia Lake Basin. *Jwmseir*. 2016; 9(31):11-23 URL: <http://jwmsei.ir/article-1-600-en.html>. (in Pershian)
- Ghavidel Rahimi, Y. (2010). The Statistical Detection of the Global Warming Impact on Fluctuations of Annual Precipitation in Jolfa Station Using Artificial Neural Networks. *Geography and Environmental Planning*, 21(2), 65-82. (in Pershian)
- Ghermezcheshmeh, B., Rasuli, A., Rezaei-Banafsheh, M., Massah, A., Khorshiddoost, A. (2015). Uncertainty Analyzing of Neural Network in Downscaling of HadCM3 Data with Bootstrap Confidence Interval Method. *Watershed Engineering and Management*, 7(3), 306-316. doi: 10.22092/ijwmse.2015.101638. (in Pershian)
- Ghasemifar, E., Alijani, B., Salighe, M. (2017). Investigation of Climate Change on the Southern Coastal of the Caspian Sea Using SDSM, LARS-WG and Artificial Neural Network, 9(34), 23-41. (in Pershian)
- Golkar, F., Farahmand, A., Farahmand, F. (2008). An Investigation on Application of Artificial Neural Network in Shiraz Precipitation. *National Conference on Water Crisis Management*, (1), 1-10. (in Pershian)
- Golabi, M., Akhondali, A., Radmanesh, F. (2012). Comparison of Performance of Different Artificial Neural Network Algorithms in Seasonal Rainfall Modeling Case study; Selected Stations in Khuzestan Province. *Applied Research of Geographic Sciences*, 13(30), 151-169. (in Pershian)
- Houshyar, M., Hosseini, A., Mesgari, E. (2012). Modeling of Urmia Township Minimum Temperatures Through Linear and Nonlinear Multiple Regression and Artificial Neural Networks Models. *Geographic Thought*, 6(12), 1-33. (in Pershian)

- Abbasnia, M., Tavousi, T. and Khosravi., M. (2016) Assessment of Future Changes in the Maximum Temperature at Selected Stations in Iran Based on HADCM3 and CGCM3 Models. *Asia-Pac. J. Atmos. Sci.* 52(4), 371-377. <https://doi.org/10.1007/s13143-016-0006-z>.
- Aggarwal, K. Singh., Y. Chandra., P. and Puri., M. (2005) Bayesian Regularization in a Neural Network Model to Estimate Lines of Code Using Function Points. *Computer Sciences* 1. (4): 505-509. DOI: 10.3844/jcssp.2005.505.509.
- Carter, T. R., & Kenkyū, K. K. K. C. K. (1994). IPCC Technical Guidelines for Assessing Climate Change Impacts and Adaptations: Part of the IPCC Special Report to the First Session of the Conference of the Parties to the UN Framework Convention on Climate Change. *London. Department of Geography*, University College London.
- Dibike, Y., Coulibaly, P. (2005). Hydrological Impact of Climate Change in the Saguenay watershed: Comparison of Downscaling Methods and Hydrologic models. *Hydrology*. 307, 145–163. <https://doi.org/10.1016/j.jhydrol.2004.10.012>.
- Harpham, H., and Wibly, R.L. (2005). Multi-site Down Scaling of Heavy Daily Precipitation Occurrence and Amount. *Hydrology*. (312), 235-255. <https://doi.org/10.1016/j.jhydrol.2005.02.020>.
- Huang ., J. Zhang.,J. Zhang.,Z and Shanlei., S. Yao., J. (2016) Simulation of Extreme Precipitation Indices in the Yangtze River Basin by Using Statistical Downscaling Method (SDSM). *Theor Appl Climatol*. 108(2012):325–343.<https://doi.org/10.1007/s00704-011-0536-3>.
- IPCC., (2014). Summary for Policymakers. In: Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. [Field, C.B., V.R. Barros, D.J.Dokken, K.J. Mach, M.D. Mastrandrea, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B.Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White (eds.)]. *Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA*, pp. 1-32.
- Metekiya., M. Gulacha., M .,M. Mulungu., M. (2016). Generation of Climate Change Scenarios for Precipitation and Temperature at Local Scales Using SDSM in Wami-Ruvu River Basin Tanzania. *Physics and Chemistry of the Earth Physics*. (2016) 1-11. <https://doi.org/10.1016/j.pce.2016.10.003>.
- Mahmood, R., Babel, M. (2014) Future Changes in Extreme Temperature Events using the statistical downscaling model (SDSM) in the trans-boundary region of the Jhelum River Basin. *Weather and Climate Extremes*. 5-6 (2014) 56–66. <https://doi.org/10.1016/j.wace.2014.09.001>.
- Qian, B., Gameda, S., Hayhoe, H., De Jong, R., & Bootsma, A. (2004). Comparison of LARS-WG and AAFC-WG Stochastic Weather Generators for Diverse Canadian climates. *Climate Research*, 26(3), 175-191. <http://www.jstor.org/stable/e24868719>.



- Rajabi, A., Shabanlou, S. (2013) The Analysis of Uncertainty of Climate Change by Means of SDSM Model Case Study: Kermanshah. *World Applied Sciences*. 23(10): 1392-1398. DOI: 10.5829/idosi.wasj.2013.23.10.3152.
- Samadi, S., Wilson, C. A. M. E. Moradkhani, H. (2013). Uncertainty Analysis of Statistical Downscaling Models Using Hadley Centre Coupled Model. *Theoretical Applied Climatology*. 114, 673–690. <https://doi.org/10.1007/s00704-013-0844-x>.
- Samadi, S., Ehteramian, K. Sari Sarraf., B. (2013). SDSM Ability in Simulate Predictors for Climate Detecting over Khorasan Province. *Procedia Social and Behavioral Sciences*. 19(2011). 741–749. <https://doi.org/10.1016/j.sbspro.2011.05.193>.
- Sharma, D., Gupta, A. D., & Babel, M. S. (2007). Spatial Disaggregation of Bias-Corrected GCM Precipitation for Improved Hydrologic Simulation: Ping River Basin, Thailand. *Hydrology and Earth System Sciences Discussions*, 11(4), 1373-1390.
- Shamsipoor, A. (2013). Climate Modeling Theory and Methods, Tehran University Press: p.294. (in Persian)
- Tatsumi, K., Oizumi, T, Yamashiki, y. (2015). Effects of Climate Change on Daily Minimum and Maximum Temperatures and Cloudiness in the Shikoku Region: a Statistical Downscaling Model Approach. *Theor Appl Climatol*. (2015) 120:87–98. <https://doi.org/10.1007/s00704-014-1152-9>.
- Wilby, R. L., Dawson, W., C. (2007). SDSM 4.2- A Decision Support Tool for the Assessment of Regional Climate Change Impacts, SDSM Manual Version 4.2. *Environment Agency of England and Wales*. 94 pp.
- Wilby, R.L., Dawson, C.W., and Barrow, E.M. (2002) A Decision Support Tool for the Assessment of Regional Climate Change Impacts. *Environmental Modelling & Software*. 17: 147–159. [https://doi.org/10.1016/S1364-8152\(01\)00060-3](https://doi.org/10.1016/S1364-8152(01)00060-3).
- Wang, H., G., Yu, Z., Mei, R. (2012). Assessing Future Climate Changes and Extreme Indicators in East and South Asia Using the RegCM4 Regional Climate Model. *Climate Change*. 114 (2), 301–317. <https://doi.org/10.1007/s10584-012-0411-y>.
- Wigley, T., M. L., Jones, P. D., Briffa, K. R., & Smith, G. (1990). Obtaining Sub-grid-scale Information from Coarse-resolution General Circulation Model Output. *Geophysical Research: Atmospheres*, 95(D2), 1943-1953. DOI: 10.1029/JD095iD02p01943.
- www.irimo.ir.