

مقایسه روشهای شبکه‌ی عصبی مصنوعی و SDSM در ریزمقیاس کردن اندازه‌ی بارش سالانه‌ی شبیه‌سازی شده با HadCM3

(مطالعه‌ی موردی: کرمان، راور و رابر)

مریم رضائی^۱، محمد نهتانی^{۲*}، علیرضا مقدم‌نیا^۳، علیجان آبکار^۴ و معصومه رضائی^۵
تاریخ دریافت: ۹۲/۹/۲۹ تاریخ پذیرش: ۹۴/۳/۲۴

چکیده

امروزه این باور وجود دارد که فعالیتهای انسانی، از جمله تغییر در پوشش و کاربری اراضی، موجب افزایش غلظت گازهای گلخانه‌ای می‌گردد، که پیامد آن برهم خوردن توازن کارمایه، گرم شدن اتمسفر، و در نهایت پدیده‌ی تغییر اقلیم می‌باشد. پیش‌بینی بارندگی یکی از مهمترین مسائل در برنامه‌ریزی و مدیریت منابع آب می‌باشد. در این پژوهش، اندازه‌ی بارندگی ایستگاههای کرمان، راور و رابر با استفاده از خروجیهای شبیه HadCM3، تحت نمایشنامه‌ی A2، و از طریق شبیه‌های ریزمقیاس کننده‌ی SDSM و شبکه‌ی عصبی مصنوعی، برای سه دوره‌ی ۲۰۳۹-۲۰۱۰، ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰ میلادی پیش‌بینی شده است. ابتدا دوره‌ی آماری ۲۰۰۱-۱۹۷۱، به عنوان دوره‌ی پایه انتخاب شد. در ادامه، با توجه به معیارهای آماری، نتایج حاصل از دو شبیه مورد ارزیابی و مقایسه قرار گرفتند. یافته‌ها بیانگر عملکرد بالاتر شبیه شبکه‌ی عصبی در ایستگاههای کرمان و راور می‌باشند. اندازه‌ی بارندگی سالانه در ایستگاههای کرمان، راور و رابر تا سال ۲۰۹۹، در شبیه شبکه‌ی عصبی به ترتیب ۱۲/۸۶، ۱۱/۶۸ و ۱۱/۳۹٪ و در شبیه SDSM ۰/۸۹، ۱۸/۴۸ و ۱/۵۵٪ نسبت به دوره‌ی پایه کاهش می‌یابند. **واژه‌های کلیدی:** بارندگی، تغییر اقلیم، ریزمقیاس کردن، شبیه HadCM3.

^۱ - دانش آموخته کارشناسی ارشد، گروه مرتع و آبخیزداری، دانشگاه زابل.

^۲ - استادیار، گروه مرتع و آبخیزداری دانشگاه زابل

^۳ - دانشیار، گروه احیای مناطق خشک و کوهستانی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران

^۴ - کارشناس ارشد مرکز تحقیقات کشاورزی و منابع طبیعی استان کرمان

^۵ - مربی گروه مهندسی برق و کامپیوتر، دانشگاه سیستان و بلوچستان

* نویسنده مسوول مقاله: m_nohtani@yahoo.com

مقدمه

بارش یکی از مهمترین داده‌های ورودی به سامانه‌های آبشناسی محسوب می‌شود، در این بین، شبیه‌های مفهومی و آماری زیادی برای پیش‌بینی و پیش‌آگاهی متغیرهای اقلیمی مورد استفاده قرار گرفته اند (فتاحی و همکاران، ۱۳۸۷). بررسیها نشان می‌دهند که کمترین تغییر در میزان بارش و دما ضربه‌های شدیدی را به بخشهای کشاورزی و اقتصادی وارد می‌کنند (عباسی و همکاران، ۱۳۸۹). اثرات تغییر اقلیم بر منابع آب به عنوان موضوعی چالش برانگیز در بسیاری از مناطق خشک دنیا مطرح بوده و توجه بسیاری از پژوهشگران را در دهه‌های اخیر به خود معطوف ساخته است. انتظار می‌رود که تغییر در متوسط فراسنجهای اقلیمی، بویژه دما و بارندگی، تأثیر قابل توجهی بر منابع آب در دسترس آینده بگذارد (آشفته و حداد، ۱۳۹۲). بهره برداری بهینه از نظام‌های منابع آب از یکسو، رسالت، حفظ و پیش‌بینی وضعیت آینده‌ی آن به منظور استفاده نسل‌های آینده از طرف دیگر، باعث گردیده است که در سالهای اخیر استفاده از روشهای پیش‌بینی منابع آب مورد تأکید قرار گیرد (اعلمی و همکاران، ۱۳۹۳).

از این رو، پیش‌بینیهای اقلیمی برای استفاده در برنامه‌ریزیهای کلان کشور، بویژه در رابطه با بلایای طبیعی، ضروری به نظر می‌رسند. شبیه‌های گردش عمومی جو^۱، شبیه‌های سه بعدی می‌باشند که بر اساس نمایشنامه‌های مختلف اقلیمی به منظور شبیه‌سازی اثر گازهای گلخانه‌ای بر آب و هوای حال حاضر کره زمین توسعه داده شده و قادرند تا تغییرات اقلیمی آینده کره زمین را پیش‌بینی کنند (زو، ۱۹۹۹). شبیه‌های گردش عمومی جو در مراکز مختلف اجرا شده‌اند، که از جمله می‌توان به شبیه HadCM3^۲، در مرکز تحقیقات و پیش‌بینی اقلیم Hadley انگلستان اشاره نمود (صلاح الدین و همکاران، ۱۳۹۲).

یکی از محدودیتهای اصلی در استفاده از خروجیهای اقلیمی شبیه‌های چرخه عمومی این است که دقت تجزیه‌ی مکانی و زمانی آنها با دقت مورد نیاز

شبیه‌های منطقه‌ای و آبشناسی مطابقت ندارد. دقت مکانی این شبیه‌ها در حدود ۲۰۰ کیلومتر است، که این دقت خصوصاً برای بررسی مناطق کوهستانی و فراسنجهای اقلیمی نظیر دما و بارش مناسب نمی‌باشد (ویلیبی و دتینجر، ۲۰۰۰). پس از گزینش شبیه گردش عمومی جو برای محدوده‌ی مطالعاتی لازم است که خروجیهای این شبیه برای دوره‌ی پیش‌بینی، ریزمقیاس^۳ شده و در مقیاس ایستگاهی درآیند (مدرسی و همکاران، ۱۳۹۰).

ویلیبی و داسون (۲۰۰۸) کلیه روشهای ریزمقیاس نمایی را در چهار گروه پویا، سینوپتیکی، آماری و تابع انتقالی طبقه‌بندی کرده‌اند. شبیه‌های پویا و سینوپتیکی جهت شبیه‌سازی متغیرهای اقلیمی نیاز به رایانه و ابزاری پیچیده دارند. متداولترین روش ریزمقیاس کردن بهره‌جویی از تابع انتقال است که روشی وایزی بوده و بر روابط کمی مستقیم بین متغیرهای در برگیرنده‌ی اطلاعات اقلیمی بزرگ مقیاس (پیش‌بینی کننده) و متغیرهای اقلیمی (پیش‌بینی شونده) از طریق روابط وایزی تکیه دارد (آبکار و همکاران، ۱۳۹۲). تاکنون روشهای وایزی خطی، غیرخطی و شبکه‌های عصبی مصنوعی، به منظور بررسی پیوند بین متغیرهای پیش‌بینی کننده و پیش‌بینی شونده و روابط حاکم بر آنها به کار گرفته شده‌اند. در پژوهش حاضر، سعی شد تا داده‌های شبیه HadCM3، برای شبیه‌سازی بارش سالانه-ی ایستگاههای سینوپتیک کرمان، و باران سنجی راور و رابر با استفاده از شبیه‌های ریزمقیاس نمایی SDSM^۴ و شبکه عصبی مصنوعی^۵ ریزمقیاس شده، و عملکرد آنها مورد ارزیابی و مقایسه قرار گیرد. شبیه SDSM یکی از شبیه‌های ریزمقیاس نمایی آماری بوده، و دلیل انتخاب آن در پژوهش حاضر، باصرفه بودن، سادگی و سرعت بالا در فرآیند ریزمقیاس‌سازی ناحیه‌ای می‌باشد (زو، ۱۹۹۹)، و (ویلیبی و داوسون، ۲۰۰۸). شبیه شبکه‌ی عصبی مصنوعی مبنی بر روش ریزمقیاس نمایی، و بر پایه‌ی روابط ریاضی استوار بوده، و به دلیل توانایی بالا در فراهم کردن روابط غیرخطی بین پیش‌بینی کننده و پیش‌بینی

³ downscaling

⁴ statistical downscaling model

⁵ artificial neural network

¹ general circulation model

² hadley centre coupled model, version 3

مواد و روشها

منطقه‌ی مورد مطالعه

استان کرمان با مساحتی حدود ۱۷۵۶۹ کیلومتر مربع بین ۲۵ درجه و ۵۵ دقیقه تا ۳۲ درجه عرض شمالی، و ۵۳ درجه و ۲۶ دقیقه تا ۵۹ درجه و ۲۹ دقیقه طول شرقی، از نصف النهار گرینیچ قرار گرفته است. این استان با در بر گرفتن حدود ۱۱ درصد از مساحت کل کشور ناحیه‌ی وسیعی را از بخش جنوب شرقی فلات مرکزی ایران پوشانده، و بدان واسطه کلیه‌ی واکنشهای پیچیده و خشن طبیعی مربوط به شرایط آب و هوایی خشک را دارا می‌باشد. از آن جا که دو سوم این سرزمین را کوهها می‌پوشانند، وجود گستره‌ی وسیع ارتفاعات از نفوذ و تسلط کامل شرایط کویری بر پهنه‌ی کرمان تا حد قابل ملاحظه‌ای کاسته است. رودهای استان عبارتند از: هلیل‌رود، نساء، آدوری، تهرود، گراغان، دهبکری در شهرستان بم؛ سیرچ، شهداد، چهارفرسخ، راور، قدرونی در شهرستان کرمان، شور در شهرستان جیرفت، آب بخشا، لاله زار، چاری در شهرستان بردسیر؛ تنگوبیه در سیرجان؛ دهنه راوز در رفسنجان و گیودری که از کوههای پاریز در سیرجان سرچشمه می‌گیرد. این استان، به رغم تنوع اقلیمی، از نظر منابع آب و اندازه‌ی بارندگی جزء مناطق فقیر کشور محسوب شده، و منابع عمده‌ی تأمین آب در منطقه از عهد کهن تا به امروز آبهای زیرزمینی بوده اند. از نظر تقسیمات آب‌شناسی، این محدوده، در چهار حوضه‌ی آبخیز اصلی کشور که شامل حوضه آبخیز باتلاق بافت، باتلاق گاوخونی، حاشیه کویرلوت و حوضه آبخیز جازموریان قرار دارد (بریم نژاد و یزدانی، ۱۳۸۳). در پژوهش حاضر مطالعه در مورد ایستگاههای کرمان و راور با اقلیم گرم و خشک و رابر با اقلیم کوهستانی و سرد و خشک (غضنفرپور و همکاران، ۱۳۹۲)، انجام گرفته است. مشخصات و موقعیت جغرافیایی ایستگاههای مذکور در جدول ۱ و شکل شماره-۱ (۱)، ارائه شده اند.

شونده کاربردی گسترده یافته است (احمدی باصری و همکاران، ۱۳۹۳). نگاهی اجمالی به مطالعات انجام شده در زمینه‌ی پیش‌بینی بارندگی نشان می‌دهد که مطالعات بسیاری در مناطق مختلف جهان با استفاده از شبیه‌های مختلف انجام شده اند، از جمله هارفام و ویلی (۲۰۰۵)، با استفاده از شبیه‌های شبکه‌ی عصبی مصنوعی و شبیه SDSM، اندازه‌ی بارندگی را در انگلستان پیش‌بینی نمودند، نتایج حاکی از عملکرد بهتر شبیه شبکه‌ی عصبی مصنوعی بودند.

خان و همکاران (۲۰۰۶)، برای ریزمقیاس کردن متغیرهایی مانند بارندگی و دما سه شبیه LARS-WG، SDSM و شبکه‌ی عصبی مصنوعی را مورد آزمون قرار دادند. نتایج حاکی از آن بودند که شبیه SDSM نسبت به دیگر شبیه‌ها از کارایی بالاتری برخوردار است.

آکسوی و داهامشه (۲۰۰۹)، با استفاده از شبکه‌های عصبی مصنوعی بارش ماهانه‌ی اردن را پیش‌بینی کرده، و نتایج را با وایازی چند متغیره مقایسه نمودند. نتایج نشان دادند که شبکه‌های عصبی مصنوعی نتایج بهتری را نسبت به وایازی چند متغیره ارائه می‌کنند. صمدی و مساح بوانی (۱۳۸۷)، به منظور ریزمقیاس نمایی داده‌های شبیه گردش عمومی جو از روشهای شبکه عصبی مصنوعی و SDSM استفاده کردند. نتایج نشان دادند که برای ریزمقیاس کردن بارش، روش شبکه‌ی عصبی مصنوعی نسبت به روش SDSM موفقتر بوده است.

فاتحی مرج و مهدیان (۱۳۸۸)، برای پیش‌بینی بارش پاییزه در حوضه‌ی دریاچه ارومیه، از شبیه‌های شبکه عصبی و وایازی چند متغیره خطی استفاده کردند. نتایج بررسی نشان دادند که شبیه غیرخطی با استفاده از شاخصهای اقلیمی مورد استفاده بارش پاییزه را با دقت بیشتری پیش‌بینی می‌کند.

فلاح قاله‌ری و همکاران (۱۳۸۹)، با کاربرد منطق فازی و وایازی چند متغیره به پیش‌بینی بارش بهاره‌ی خراسان پرداختند. نتایج نشان می‌دهند که سامانه استنباط فازی و روش وایازی می‌توانند در بیشتر سالها بارش بهاره را با دقت قابل قبولی پیش‌بینی نمایند.

جدول ۱- مشخصات ایستگاه‌های مورد بررسی.

نوع ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع (m)	دوره آماری
سینوپتیک کرمان	۵۶°۵۸'	۳۰°۱۵'	۱۷۵۴/۸	۱۹۷۱-۲۰۰۱
باران‌سنجی رابر	۵۶°۵۵'	۲۹°۱۸'	۲۳۵۰	۱۹۷۱-۲۰۰۱
باران‌سنجی راور	۵۶°۵۳'	۳۱°۱۵'	۱۲۹۰	۱۹۷۱-۲۰۰۱



شکل ۱- موقعیت جغرافیایی ایستگاه‌های مورد بررسی.

روش تحقیق

برای بررسی اثر تغییر اقلیم، فراسنج اقلیمی بارندگی در دهه‌های آینده ۲۰۳۹-۲۰۱۰، ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰، با استفاده از نتایج خروجی شبیه‌گردش عمومی HadCM3 تحت نمایشنامه‌ی A2، از گروه نمایشنامه‌های انتشار گازهای گلخانه‌ای شبیه‌سازی شد. شبیه HadCM3، یک شبیه GCM (جفت شده‌ی جو-اقیانوسی) است که در مرکز تحقیقاتی HCCPR^۱، در انگلیس اجرا گردیده به وسیله‌ی گردون و همکاران (۲۰۰۰)، ارائه شده است، مشخصات شبیه در جدول (۲) ارائه شده‌اند. داده‌های آن به صورت گروه‌های زمانی روزانه برای متغیرهای بارندگی، دمای حداکثر، میانگین و

دمای حداقل می‌باشد. پس از انتخاب شبیه‌گردش عمومی جو برای محدوده‌ی مطالعاتی لازم است که خروجی‌های آن برای دوره‌ی پیش‌بینی ریزمقیاس شده، و در مقیاس ایستگاهی درآیند (مدرسی و همکاران، ۱۳۹۰).

جدول ۲- مشخصات شبیه HadCM3 (آشفته و مساح بوانی، ۱۳۸۹).

دقت مکانی (طول × عرض) (درجه)	دوره شبیه‌سازی گازهای گلخانه‌ای و ذرات معلق در گذشته	نمایشنامه‌های شبیه‌سازی شده SRES
۲/۵×۳/۷۵	CO ₂ : ۱۸۶۰-۱۹۸۹	A1,A2,B1,B2

از آن جا که مهمترین ورودی این شبیه‌ها میزان انتشار گازهای گلخانه‌ای در دوره‌های آتی بوده، و از طرفی تعیین میزان انتشار این گازها در دوره‌های آتی بطور

¹ Hadley Center for Climate Prediction and Research

کرده باشد. پس از انتخاب این متغیر میتوان از آن برای ریز مقیاس کردن داده‌های بارش ایستگاههای مطالعاتی به کار برد. شبیه ریز مقیاس نمایی آماری (SDSM) برای شبیه‌سازی داده‌های اقلیمی در یک ایستگاه خاص در شرایط حال حاضر و آینده تحت تأثیر پدیده‌ی تغییر اقلیم به کار می‌رود، و از روشهای آماری وایازی به منظور ریز مقیاس کردن استفاده می‌نماید. داده‌های آن به صورت گروه‌های زمانی روزانه برای یک گروه از متغیرهای اقلیمی مانند بارندگی، حداقل و حداکثر دما و سایر فراسنجهای جوی می‌باشد. در این شبیه برای هر ماه از سال یک وایازی خطی چند متغیره بین متغیر پیش‌بینی کننده‌ی بزرگ مقیاس (NCEP) و متغیر پیش‌بینی شونده‌ی محلی تدوین می‌گردد (شاه نقی و همکاران، ۱۳۸۹). در این پژوهش از داده‌های مشاهداتی NCEP، جهت تدوین شبیه‌های ماهانه و از خروجیهای شبیه HadCM3 جهت پیش‌بینی مقدار متغیر با استفاده از نرم‌افزار SDSM، استفاده شده است. در این شبیه برای فرایند ریز مقیاس نمودن برای هر ماه از سال، یک وایازی خطی چند متغیره میان تعداد معدودی از متغیرهای پیش‌بینی کننده بزرگ مقیاس (متغیرهای مستقل)، و پیش‌بینی شونده در مقیاس محلی، همچون بارش و دما توسعه می‌یابد (رجبی، ۱۳۹۰). مراحل کار شبیه بطور خلاصه شامل هفت بخش می‌باشد. ۱- تنظیم کیفیت و تبدیل داده‌ها: در این مرحله وضعیت داده‌های پیش‌بینی شونده^۵ (وابسته)، ایستگاه مطالعاتی از نظر تعداد، داده‌های بیشینه، کمینه و تعداد داده‌های مفقوده و... مدیریت می‌گردد. ۲- انتخاب متغیرهای مستقل مناسب: هدف از این مرحله کمک به کاربر در یافتن پیش‌بینی کننده‌هایی با قویترین ارتباط با پیش‌بینی شونده‌ها می‌باشد. ۳- واسنجی^۶ شبیه: در این مرحله، شبیه‌های آماری سالانه، فصلی و ماهانه با به کارگیری داده‌های پیش‌بینی شونده و پیش‌بینی کننده روزانه ساخته شده و در پرونده معیاری با پسوند PAR. ذخیره می‌شوند. ۴- تولید داده‌های هواشناسی زمان حاضر با استفاده از متغیرهای مستقل مشاهده‌ای: در این گام ابتدا پرونده‌ی ورودی با پسوند PAR. به شبیه معرفی

قطعی امکان پذیر نیست، از این رو نمایشنامه‌های مختلفی، که در برگیرنده‌ی چگونگی تغییرات این گازها در آینده می‌باشند، ارائه شده اند، که نمایشنامه‌های انتشار^۱ نامیده می‌شوند (آشفته و مساح بوانی، ۱۳۸۹). هیات بین الدول تغییر اقلیم^۲، در سال ۱۹۹۸ سری جدید سناریوهای انتشار را با نام SRES ارائه داد، که در این تحقیق از بین آنها گروه SRES با نامهای A1، A2، B1 و B2 نمایشنامه‌ی انتشار A2، که معرف شرایط اقتصادی- اجتماعی می‌باشد، استفاده شده است. ویژگیهای نمایشنامه‌ی انتشار A2، بر صنعتی شدن و رشد گروه کشورها بدون توجه به محیط زیست و انتشار گازهای گلخانه‌ای تأکید می‌کند، و این موضوع به واقعیت‌های جهان امروز ما نزدیکتر است. از طرفی در سطح دنیا، برای بررسی اثرات تغییر اقلیم بر منابع آب، کشاورزی، آبشناسی و اثرات زیست محیطی از این نمایشنامه استفاده می‌کنند (شاه نقی و همکاران، ۱۳۹۰). در این پژوهش، با استفاده از شبیه‌های شبکه عصبی مصنوعی و وایازی خطی چند متغیره SDSM، میزان بارش سالانه‌ی استان کرمان ریز مقیاس شد و عملکرد آنها، مورد ارزیابی و مقایسه قرار گرفت.

برای استخراج روابط کمی بین متغیرهای اتمسفری بزرگ مقیاس و متغیرهای محلی می‌بایست متغیرهای پیش‌بینی کننده^۳ از پایگاه داده NCEP^۴، استخراج شوند؛ جدول ۳، فهرست کاملی را از پیش‌بینی کننده‌ها نشان می‌دهد. این داده‌ها شامل ۲۶ متغیر اتمسفری است که در شبکه‌هایی به ابعاد حدود ۲۵۰ در ۲۵۰ کیلومتر، که دارای ارزش یکسانی می‌باشند، قرار دارند. این آمار، داده‌های شبکه بندی شده می‌باشند که بر روی شبکه‌های GCM درون‌یابی شده، و در روش ریز مقیاس نمایی وایازی به عنوان متغیر مستقل مورد استفاده قرار می‌گیرند. متغیری برای انجام مطالعات حائز اهمیت است که اولاً بتواند روند قابل قبولی را با داده‌های ریز مقیاس منطقه در دوره مشاهداتی داشته، و ثانیاً شبیه گردش عمومی جو، آن متغیر را به خوبی در دوره‌ی مشاهداتی شبیه‌سازی

¹ emission scenario

² Intergovernmental Panel on Climate Change (IPCC)

³ predictor

⁴ National Centers for Environmental Prediction

⁵ Predictand

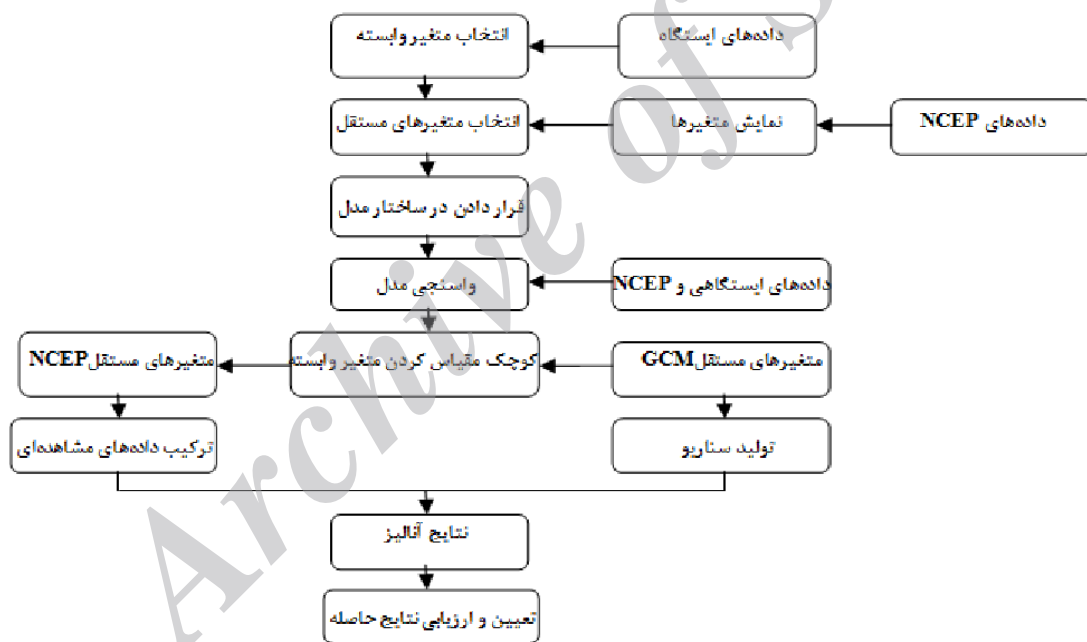
⁶ Calibration

(۱۹۴۳) ارائه گردیدند. آنها سامانه‌های قابل تطبیقی می‌باشند که با ساختن یک شبیه روابط بین ورودیها و خروجیها را پیدا می‌کنند. در شبیه شبکه‌ی عصبی مصنوعی، نکته مهم دیگر بهنجار کردن داده‌ها است. ورود داده‌ها به صورت بهنجار به شبکه خطا را کاهش می‌دهد. طریقه‌ی محاسبه به شرح زیر می‌باشد:

$$N = 0.8 \times \left[\frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \right] + 0.1 \quad (1)$$

که در آن N ، داده بهنجار شده، X_i داده‌های مشاهده شده، X_{\min} حداقل داده‌های مشاهده شده و X_{\max} حداکثر داده‌های مشاهده شده می‌باشد.

می‌شود، که با زدن بر روی گزینه Weather Generator این مرحله آغاز می‌گردد. ۵- تحلیل آماری داده‌های مشاهده شده؛ تحلیل داده شامل بررسی مقادیر میانگین، بیشینه، کمینه داده‌ها و ... در مقیاس‌های گوناگون سالانه، فصلی و ماهانه، به وسیله شبیه انجام می‌شود. ۶- نمایش هندسی خروجی شبیه ۷- تولید داده‌های هواشناسی آینده، که در این مرحله با استفاده از پرونده‌ی واسنجی با پسوند PAR. و داده‌های شبیه گردش عمومی، داده‌های هواشناسی برای دهه‌های آینده تولید می‌شود (ویلیبی و داسون، ۲۰۰۸). شکل (۲) مراحل فرایند ریزمقیاس نمایی، و تولید نمایشنامه‌ی اقلیمی نرم‌افزار SDSM را نشان می‌دهد. شبکه‌های عصبی مصنوعی به عنوان یک شبیه تجربی برای اولین بار از تعیین رابطه ریاضی توانایی مغز انسان به وسیله مک کالچ و پیترز



شکل ۲- مراحل فرآیند ریزمقیاس نمایی و تولید نمایشنامه‌ی اقلیمی شبیه SDSM.

جدول ۳- فهرست متغیرهای NCEP..

ردیف	متغیر	ردیف	متغیر
۱	فشار سطح صفر	۱۴	سرعت مداری سطحی
۲	قدرت جریان هوای سطحی	۱۵	حالت گردابی سطحی
۳	سرعت نصف النهاری سطحی	۱۶	واگرایی سطحی
۴	جهت باد سطحی در ارتفاع ۵۰۰ هکتوپاسکال	۱۷	سرعت مداری در ارتفاع ۵۰۰ هکتوپاسکال
۵	قدرت جریان هوا در ارتفاع ۵۰۰ هکتوپاسکال	۱۸	حالت گردابی در ارتفاع ۵۰۰ هکتوپاسکال
۶	سرعت نصف النهاری در ارتفاع ۵۰۰ هکتوپاسکال	۱۹	جهت باد در ارتفاع ۵۰۰ هکتوپاسکال
۷	ژئوپتانسیل در ارتفاع ۵۰۰ هکتوپاسکال	۲۰	واگرایی در ارتفاع ۵۰۰ هکتوپاسکال
۸	قدرت جریان هوا در ارتفاع ۸۵۰ هکتوپاسکال	۲۱	سرعت مداری در ارتفاع ۸۵۰ هکتوپاسکال
۹	سرعت نصف النهاری در ارتفاع ۸۵۰ هکتوپاسکال	۲۲	حالت گردابی در ارتفاع ۸۵۰ هکتوپاسکال
۱۰	ژئوپتانسیل در ارتفاع ۸۵۰ هکتوپاسکال	۲۳	جهت باد در ارتفاع ۸۵۰ هکتوپاسکال
۱۱	واگرایی در ارتفاع ۸۵۰ هکتوپاسکال	۲۴	رطوبت نسبی در ارتفاع ۵۰۰ هکتوپاسکال
۱۲	رطوبت نسبی در ارتفاع ۸۵۰ هکتوپاسکال	۲۵	رطوبت نسبی سطحی
۱۳	رطوبت ویژه سطحی	۲۶	میانگین دما در ارتفاع ۲ متری

محرك خطی^۴، اشاره نمود. نحوه اتصالات نرون‌ها و چگونگی تنظیم وزن‌ها که به آن الگوریتم یادگیری گفته می‌شود، منجر به نتایج متفاوتی از شبکه می‌گردد. یکی از مهم‌ترین انواع شبکه‌های عصبی، شبکه‌های عصبی پیش‌سو می‌باشد. پیش‌سو بودن به این معناست که نرونهای مصنوعی در لایه‌های متوالی قرار گرفته‌اند و خروجی (علامت) خود را رو به جلو می‌فرستند. الگوریتم آموزشی که در این نوع شبکه‌ها استفاده می‌شود، معمولاً الگوریتم پس‌انتشار^۵ می‌باشد (ماریر و دندی، ۲۰۰۰). الگوی آموزشی باید تا حد امکان کل فضای داده‌ها را پوشش دهد تا قابلیت تعمیم شبکه افزایش یابد، و پس از تعمیم شبکه به سرعت بتواند به ازای هر ورودی، خروجی متناظر با آن را ارائه نماید. واژه‌ی پس‌انتشار به معنای این است که خطاها به سمت عقب در شبکه تغذیه می‌شوند تا وزن‌ها را اصلاح کنند، و پس از آن، مجدداً ورودی مسیر پیش‌سوی خود تا خروجی را تکرار نمایند. الگوریتم لونیبرگ-مارکوات^۶، از سال ۱۹۹۳ تا به امروز به عنوان سریعترین و متداولترین روش آموزش شبکه‌های عصبی شناخته شده است که برای بهینه سازی غیرخطی بر مبنای قانون حداقل مربعات عمل می‌کند (اخلاقی و اصلاح، ۱۳۸۴؛ طلوعی و همکاران، ۱۳۹۰) و یکی از

در مرحله بعد پس از آموزش، عملیات شبیه‌سازی با دستور زیر اجرا شد:

$$a = \text{sim}(\text{net}, p) \quad (2)$$

تابع sim ، یک شبکه را شبیه سازی می‌کند. این تابع شبکه و بردار ورودی را به عنوان ورودی شبکه دریافت نموده و خروجی شبکه را برمی‌گرداند (خسروی و شکیب، ۱۳۸۹). پرسپترون‌های تک لایه‌ای فقط می‌توانند الگوهای را شناسایی و طبقه بندی کنند که به صورت خطی قابل جداسازی باشند. برای طبقه‌بندی الگوهای پیچیده از پرسپترون چندلایه ای استفاده می‌شود. در عمل می‌توان نشان داد که یک شبکه‌ی عصبی با سه لایه می‌تواند بازدهی مشابه با شبکه‌های با لایه‌های بیشتر داشته باشد؛ بنابراین، از آن جا که افزایش تعداد لایه‌ها، الگوریتم یادگیری را پیچیده‌تر می‌کند، مرسوم است که از شبکه‌های عصبی با سه لایه (ورودی، پنهان و خروجی) استفاده گردد. برای انتقال خروجیهای هر لایه به لایه‌ی بعدی، آن را از یک تابع محرک^۱ عبور می‌دهند. نرون‌ها می‌توانند از توابع محرک متفاوتی جهت تولید خروجی استفاده کنند، که از رایج ترین آنها می‌توان به توابع لگاریتم سیگموئیدی^۲، تابع تانژانت سیگموئیدی^۳ و تابع

⁴ purelin

⁵ Back-propagation

⁶ Levenberg-Marquardt Algorithm

¹ transfer function

² log sigmoid

³ tan sigmoid

ضریب MAE:

هر چه مقدار ضریب میانگین خطای مطلق رابطه‌ی (۴) به صفر نزدیکتر باشد، نشان دهنده‌ی نزدیکتر بودن مقادیر مشاهده شده و پیش‌بینی شده به یکدیگر، و دقیقتر بودن جواب‌ها می‌باشد.

$$MAE = \sum_{k=1}^k \left| \frac{X_k - Y_k}{k} \right| \quad (۴)$$

ضریب تبیین:

معیار دیگری که برای ارزیابی کارایی شبیه در این پژوهش به کار رفت، ضریب تبیین می‌باشد، که مقدار آن از صفر تا یک تغییر کرده و به صورت رابطه‌ی (۵) ارائه می‌شود:

$$R^2 = \frac{\sum_{k=1}^k (X_k Y_k)}{\sum_{k=1}^k ((X_k)^2 \sum (Y_k)^2)} \quad (۵)$$

در تمامی روابط فوق، X_k مقادیر مشاهده شده، Y_k مقادیر پیش‌بینی شده و k تعداد داده‌ها می‌باشند.

نتایج و بحث

در پژوهش حاضر، با تغییر تعداد لایه‌های پنهان و ترونه‌های مربوطه، و همچنین توابع محرک مختلف، شبکه‌های عصبی مختلف مورد آزمون قرار گرفتند، در نهایت، بهترین ساختار برای پیش‌بینی بارش ایستگاه سینوپتیک کرمان، و ایستگاههای باران سنجی راور و رابر ایجاد شد.

ایستگاه سینوپتیک کرمان

از میان متغیرهای NCEP، رطوبت نسبی در ارتفاع ۸۵۰ هکتوپاسکال^۳ و رطوبت نسبی سطحی^۴، بالاترین همبستگی را با متغیر وابسته (بارش) دارا بوده و به عنوان ورودی به شبیه‌های SDSM و شبکه‌ی عصبی مصنوعی وارد شدند. از داده‌های دوره‌ی ۱۹۸۵-۱۹۷۱ برای واسنجی (آموزش)، و از دوره‌ی ۲۰۰۱-۱۹۷۱ برای اعتبارسنجی (آزمون) شبیه استفاده شد. در مرحله‌ی بعد، با استفاده از خروجیهای شبیه SDSM، و شبکه‌ی عصبی

الگوریتمهای پرکاربرد می‌باشد، زیرا آموزش شبکه را بسیار سریع انجام داده، و سطح خطای موجود را حداقل می‌سازد. در واقع، این الگوریتم برای افزایش سرعت یادگیری شبکه طراحی شده است (بهریزی خزاعی و همکاران، ۱۳۸۷).

چون قوانین خاصی برای آموزش و طراحی شبکه‌های عصبی موجود نیست، بنابراین مجبوریم که چندین ساختار را مورد آزمایش قرار داده، و با انجام تکرارهای متعدد، اثر تغییر این فراسنجه‌ها بر عملکرد شبکه‌ها بررسی کرده، و در نهایت ضرایبی را که نتایج مناسبتری دارند، برای آموزش شبکه به شبیه معرفی کنیم (خوشحال دستجردی و حسینی، ۱۳۸۹). انتخاب معماری در شبکه‌های عصبی با روش سعی و خطا می‌باشد؛ بدین منظور، ترکیبات مختلفی از تعداد لایه‌های پنهان، تعداد ترونه‌های لایه‌ی پنهان، تابع محرک لایه‌های پنهان و خروجی و الگوریتم آموزشی در نظر گرفته شده و ترکیبی که بهترین خروجی را داشته باشد از طریق سعی و خطا، انتخاب می‌گردد (فرخ نیا و مرید، ۱۳۸۸؛ فتح آبادی و همکاران؛ ۱۳۸۷؛ باقر زاده چهره، ۱۳۸۴).

ارزیابی کارایی شبیه‌ها

برای ارزیابی کارایی شبیه‌ها، از معیارهای آماری مجذور میانگین مربعات خطا^۱، میانگین خطای مطلق^۲ و ضریب تبیین استفاده شد.

ضریب RMSE:

معیار مجذور میانگین مربعات خطا، با استفاده از رابطه‌ی (۳) تعیین می‌شود:

$$RMSE = \sqrt{\frac{\sum_{k=1}^k (X_k - Y_k)^2}{n}} \quad (۳)$$

اندازه‌ی اختلاف از رابطه‌ی (۳) هر قدر کمتر باشد، نشان دهنده‌ی شبیه‌سازی خوب شبیه، و مقادیر اختلاف زیاد بیانگر عدم کارایی آن می‌باشند. بهترین مقدار برای مجذور میانگین مربعات خطا برابر صفر است (مهاجر و همکاران، ۱۳۹۰).

³ Relative humidity at 850 h Pa

⁴ Near surface relative humidity

¹ root mean square error

² mean absolute error

ارزیابی کارایی شبیه‌های SDSM و شبکه‌ی عصبی مصنوعی ایستگاه کرمان

به منظور ارزیابی کارایی و دقت شبیه‌های SDSM و شبکه‌ی عصبی مصنوعی، از معیارهای ارزیابی میانگین خطای مطلق، مجذور میانگین مربعات خطا و ضریب تبیین استفاده شد. نتایج در جدول ۵ ارائه شده‌اند. همان گونه که نتایج معیارهای آماری ارزیابی کارایی شبیه‌ها در جدول نشان می‌دهند، شبیه شبکه‌ی عصبی در پیش‌بینی بارش ایستگاه کرمان از توانایی بالاتری نسبت به شبیه SDSM برخوردار است.

جدول ۵- معیارهای آماری ارزیابی کارایی شبیه‌های شبکه عصبی مصنوعی و SDSM ایستگاه‌های مورد بررسی.

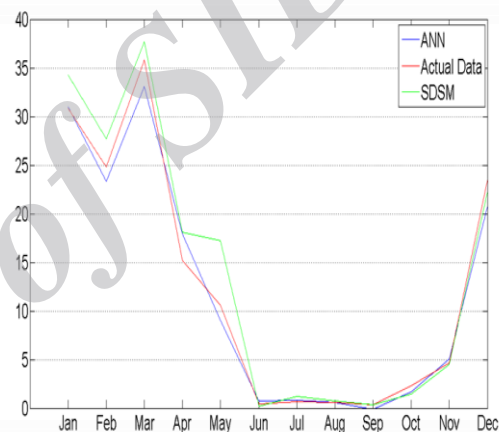
ایستگاه	ANN			SDSM		
	R^2	RMSE	MAE	R^2	RMSE	MAE
کرمان	۰/۹۹۷	۱/۵۳	۱/۱۱	۰/۹۹۴	۲/۵۶	۱/۷۵
راور	۰/۹۷	۲/۳۹	۱/۷۹	۰/۹۵	۲/۷۹	۲/۱۵
رابر	۰/۹۶	۳/۶	۱/۰	۰/۹۸	۹/۴۶	۶/۰۹

پیش‌بینی اندازه‌ی بارندگی سالانه شهر کرمان با استفاده از شبیه شبکه‌ی عصبی مصنوعی

بارندگی سالانه برآوردی دوره‌های آتی شهر کرمان به وسیله‌ی شبیه شبکه‌ی عصبی مصنوعی در شکل ۴(الف) نشان داده شده است. تحلیل روند تغییرات بارش نشان می‌دهد که در دوره‌ی ۲۰۷۰-۲۰۹۹، بیشترین کاهش میزان بارندگی در ماه ژانویه، و بیشترین افزایش بارندگی در ماه نوامبر رخ خواهد داد. بارندگی در دوره‌های ۲۰۳۹-۲۰۱۰، ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰ به ترتیب حدود ۱۶/۶۵٪ یا ۲/۴۷، ۹/۷۶٪ یا ۱۴/۶۱ و ۱۲/۸۶٪ یا ۱۹/۲۶ میلی‌متر نسبت به دوره پایه روند نزولی خواهد داشت.

مصنوعی، تغییرات فراسنج اقلیمی بارش در سه دوره‌ی زمانی آینده ۲۰۳۹-۲۰۱۰، ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰ شبیه‌سازی شدند. مشخصات شبکه‌ی عصبی مصنوعی به کار رفته در ایستگاه کرمان در جدول ۴ ارائه شده‌اند.

شکل شماره‌ی (۳)، مقایسه کارایی شبیه‌های شبکه عصبی مصنوعی و SDSM را در پیش‌بینی بارندگی دوره‌ی پایه‌ی ایستگاه سینوپتیک کرمان، نشان می‌دهد. همان گونه که در شکل مشخص شده است، بین شبیه‌های شبکه‌ی عصبی مصنوعی و SDSM، شبیه شبکه عصبی مصنوعی در پیش‌بینی بارندگی دوره‌ی پایه بهتر عمل نموده، و مقادیر مشاهداتی و شبیه‌سازی شده به وسیله‌ی شبیه بسیار به هم نزدیک می‌باشند.




شکل ۳- مقایسه کارایی شبیه‌های شبکه عصبی مصنوعی (خط آبی) و SDSM (خط سبز) در پیش‌بینی بارندگی دوره پایه (خط قرمز) ایستگاه کرمان

جدول ۴- مشخصات شبکه عصبی مصنوعی پیش‌رو (Feed Forward) به کار رفته در ایستگاه‌های مورد بررسی.

نام ایستگاه	تعداد لایه‌های پنهان	تعداد لایه‌های خروجی	تعداد لایه‌های ورودی	نوع لایه‌های پنهان	نوع لایه‌های خروجی
کرمان	۳-۵	۱	۱	سیگموئید	خطی
راور	۳-۵	۱	۱	سیگموئید	خطی
رابر	۳-۸	۱	۱	سیگموئید	خطی

روند افزایشی، در سپتامبر بدون تغییر و بقیه ماههای سال روند کاهشی خواهد داشت. میزان بارندگی سالانه ایستگاه سینوپتیک کرمان در دوره‌های زمانی (۲۰۳۹-۲۰۱۰)، (۲۰۶۹-۲۰۴۰) و (۲۰۹۹-۲۰۷۰) به ترتیب حدود (۱/۱۰۳٪) یا ۱/۵، (۱/۳۷٪) یا ۲/۱ و (۱/۸۹٪) یا ۱/۳ میلی‌متر نسبت به دوره پایه کاهش خواهد یافت.



پیش‌بینی اندازه‌ی بارندگی سالانه‌ی شهر کرمان با استفاده از شبیه SDSM

بارندگی سالانه برآوردی شهر کرمان به وسیله‌ی شبیه SDSM در دوره‌ی پایه و آینده در شکل ۴ (ب) نشان داده شده است. تحلیل روند تغییرات بارش نشان می‌دهد میزان بارندگی در ماههای آوریل، می، نوامبر و دسامبر



شکل ۴- مقایسه میزان بارندگی سالانه مشاهده‌ای و شبیه‌سازی شده دوره‌های آتی به وسیله‌ی شبیه شبکه عصبی مصنوعی (الف) و شبیه SDSM (ب) ایستگاه کرمان.

و در نهایت، تابع محرک لایه‌های پنهان از نوع تانژانت سیگموئید، و تابع انتقال لایه خروجی از نوع خطی، انتخاب شدند و تعداد نرونها به کار رفته در لایه‌های پنهان به ترتیب ۵ و ۳ می‌باشد. مقادیر بارندگی مشاهده‌ای و پیش‌بینی شده دوره‌ی پایه با استفاده از شبیه‌های شبکه عصبی مصنوعی و شبیه SDSM در شکل شماره‌ی (۵) نشان داده شده‌اند. همان‌طور که در شکل مشخص است، نتایج جدول ۵ نیز مؤید است، انطباق بین بارندگی مشاهده‌ای با بارندگی شبیه‌سازی شده به وسیله‌ی شبیه شبکه‌ی عصبی مصنوعی بیشتر است، و این نشان از توانایی بالاتر شبیه شبکه‌ی عصبی مصنوعی در شبیه‌سازی بارندگی راور نسبت به شبیه SDSM دارد.

ایستگاه باران‌سنجی راور

در ایستگاه راور، متغیر رطوبت نسبی سطحی، بالاترین همبستگی را با بارش دارا بود و به عنوان متغیر مستقل به شبیه‌ها وارد شد. دوره‌ی ۲۰۰۱-۱۹۷۱ به عنوان دوره‌ی پایه در نظر گرفته شد. از داده‌های دوره‌ی ۱۹۸۵-۱۹۷۱ برای واسنجی (آموزش)، و از دوره‌ی ۲۰۰۱-۱۹۷۱ برای اعتبارسنجی آزمون شبیه استفاده شد.



شبکه‌ی عصبی مصنوعی استفاده شده برای ایستگاه باران‌سنجی راور (جدول ۴) از نوع شبکه‌های پیش‌رو با دو لایه‌ی پنهان، و تابع آموزش لونیگ-مارکوات می‌باشد. تابع محرکهای مختلفی شامل تانژانت سیگموئید^۱، لوگ سیگموئید^۲، خطی^۳ و تابع آستانه‌ای دو مقدار حدی^۴ در شبکه‌ی عصبی مورد استفاده به کار رفت،

¹ tansig
² logsig
³ purlin
⁴ hardlim

میزان بارندگی در دوره‌های زمانی ۲۰۳۹-۲۰۱۰، ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰ میلادی به ترتیب حدود ۱/۳۱، ۶/۵۱ و ۸/۶۱ میلی‌متر یا ۱/۷۷، ۸/۸۳ و ۱۱/۶۸٪ نسبت به دوره پایه کاهش می‌یابد.

پیش‌بینی میزان بارندگی سالانه‌ی ایستگاه باران سنجی راور با استفاده از شبیه‌سازی SDSM


اندازه‌ی بارندگی سالانه‌ی ایستگاه باران سنجی راور با استفاده از شبیه‌سازی SDSM پیش‌بینی شد (شکل ۶، ب). نتایج نشان دادند که بارندگی در ماه‌های ژوئن، اوت و سپتامبر روند افزایشی، و در بقیه ماه‌های سال روند کاهشی دارد. بطور متوسط، میزان بارندگی در دوره‌های زمانی ۲۰۳۹-۲۰۱۰، ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰ میلادی به ترتیب حدود ۳/۱۸، ۹/۸۰ و ۱۳/۶۳ میلی‌متر یا ۴/۳۰، ۱۳/۳۰ و ۱۸/۴۸٪ نسبت به دوره‌ی پایه کاهش یافته است.



شکل ۵- مقایسه کارایی شبیه‌های شبکه عصبی مصنوعی (خط آبی) و SDSM (خط سبز) در پیش‌بینی بارندگی دوره پایه (خط قرمز) ایستگاه راور.

پیش‌بینی اندازه‌ی بارندگی سالانه‌ی ایستگاه باران سنجی راور با استفاده از شبیه‌سازی شبکه‌ی عصبی مصنوعی

به وسیله‌ی شبکه‌ی عصبی مصنوعی، میزان بارندگی سالانه شبیه‌سازی شده دوره‌های آتی ایستگاه باران سنجی راور پیش‌بینی شد (شکل ۶، الف). تحلیل روند تغییرات بارش نشان می‌دهد که در دوره‌ی ۲۰۷۰-۲۰۹۹، بیشترین کاهش میزان بارندگی در ماه مارس، و بیشترین افزایش بارندگی در ماه دسامبر رخ خواهد داد. بطور متوسط،



شکل ۶- مقایسه میزان بارندگی سالانه مشاهده‌ای و شبیه‌سازی شده دوره‌های آتی به وسیله‌ی شبیه‌سازی شبکه عصبی مصنوعی (الف) و شبیه‌سازی SDSM (ب) ایستگاه راور.

باران سنجی راور از طریق شبیه‌های SDSM و شبکه‌ی عصبی مصنوعی محاسبه شده و با داده‌های مشاهده‌ای مورد مقایسه قرار گرفته است (شکل ۷). مشخصات شبکه‌ی عصبی مصنوعی به کار رفته در ایستگاه راور در جدول ۴ ارائه شده‌اند.

ایستگاه باران سنجی راور

در ایستگاه راور، از میان متغیرهای NCEP، رطوبت نسبی در ارتفاع ۸۵۰ هکتوپاسکال، و سرعت نصف النهاری در ارتفاع ۵۰۰ هکتوپاسکال^۱، بالاترین همبستگی را با متغیرهای وابسته دارا بوده، و به عنوان ورودی در شبیه‌ها قرار گرفتند. جهت بررسی اثرات تغییر اقلیم در دوره‌های آتی، اندازه‌ی بارندگی دوره‌ی پایه برای ایستگاه


^۱ 500 hPa meridional velocity

پیش‌بینی اندازه‌ی بارندگی سالانه‌ی ایستگاه باران سنجی رابر با استفاده از شبیه‌سازی شبکه‌ی عصبی مصنوعی

میزان بارندگی شبیه‌سازی شده شهر رابر در دوره‌های آبی به وسیله‌ی شبیه‌سازی شبکه‌ی عصبی مصنوعی در شکل شماره ۸ (الف)، نشان داده شده است. بطور متوسط، میزان بارندگی محاسبه شده به وسیله‌ی نمایشنامه A2، در دوره‌ی زمانی ۲۰۳۹-۲۰۱۰، حدود ۲/۹ میلی‌متر یا ۰/۱۸۸٪، نسبت به دوره‌ی پایه افزایش یافته است، و در دوره‌های زمانی ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰ میلادی به ترتیب حدود ۴/۲۶٪ یا ۳/۹۸٪ و ۱۱/۳۹٪ یا ۳۷/۳۶ میلی‌متر نسبت به دوره پایه کاهش در میزان بارندگی سالانه دیده می‌شود.

پیش‌بینی میزان بارندگی سالانه‌ی ایستگاه باران سنجی رابر با استفاده از شبیه SDSM

با استفاده از شبیه SDSM، میزان بارندگی سالانه‌ی شهر رابر پیش‌بینی شد (شکل ۸، ب). میزان بارندگی در فصول زمستان و بهار، سیر نزولی و در فصول تابستان و پاییز روند افزایشی دارد. بطور متوسط، میزان بارندگی محاسبه شده به وسیله‌ی نمایشنامه A2، در دوره‌های زمانی ۲۰۳۹-۲۰۱۰، ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰ میلادی به ترتیب حدود ۳/۸۳، ۳/۹۴ و ۵/۸۰ میلی‌متر یا ۱/۴۹، ۱/۸۳ و ۱/۵۵٪ نسبت به دوره پایه کاهش یافته است.




شکل ۷- مقایسه کارایی شبیه‌های شبکه عصبی مصنوعی (خط آبی) و SDSM (خط سبز) در پیش‌بینی بارندگی دوره پایه (خط قرمز) ایستگاه رابر.

ارزیابی کارایی شبیه‌های SDSM و شبکه‌ی عصبی مصنوعی ایستگاه رابر

با استفاده از معیارهای آماری، عملکرد و کارایی شبیه‌های SDSM، و شبکه‌ی عصبی مصنوعی در شبیه‌سازی بارش رابر، مورد ارزیابی قرار گرفت، نتایج در جدول ۵ ارائه شده اند.

مقایسه معیارهای آماری ارزیابی کارایی شبیه‌ها را در ایستگاه باران سنجی رابر نتایج نشان می‌دهد، که بارش پیش‌بینی شده به وسیله‌ی شبیه SDSM اختلاف معنی‌داری با داده‌های مشاهداتی (واقعی) ندارد، و برآوردهای شبیه مذکور در این منطقه، به واقعیت نزدیکتر بوده و از کارایی بالاتری نسبت به شبیه شبکه‌ی عصبی مصنوعی برخوردار است.



شکل ۸- مقایسه میزان بارندگی سالانه مشاهداتی و شبیه‌سازی شده دوره‌های آبی به وسیله‌ی شبیه شبکه عصبی مصنوعی (الف) و شبیه SDSM (ب) ایستگاه رابر.

نتیجه‌گیری

روشهای مختلفی جهت ریزمقیاس نمودن خروجی شبیه‌های گردش عمومی جو وجود دارند، که هرکدام از منطق خاصی پیروی می‌کند. از این رو، می‌توان انتظار داشت که استفاده از روشهای مختلف نتایج متفاوتی را به دنبال داشته باشد که یکی از مهمترین دلایل آن عدم قطعیت روشهای مدنظر است، زیرا در مطالعات تغییر اقلیم، منابع عدم قطعیت مختلفی بر نتایج نهایی تأثیر می‌گذارند. این منابع عدم قطعیت عبارتند از: عدم قطعیت مربوط به نمایشنامه‌های تغییر اقلیم، عدم قطعیت مربوط به شبیه‌های GCM، عدم قطعیت روشهای ریزمقیاس نمودن، و عدم قطعیت شبیه‌های شبیه‌سازی.

نتایج معیارهای آماری ارزیابی کارایی شبیه‌های شبکه‌ی عصبی مصنوعی و شبیه SDSM، نشان دادند که توانایی این شبیه‌ها در شبیه‌سازی بارش ایستگاههای کرمان، راور و رابر نسبتاً قابل قبول بوده و با داده‌های مشاهداتی تقریباً مطابقت دارد. با توجه به این که روند بارش غیرخطی است، شبکه‌های عصبی مصنوعی با قابلیت اعتماد بیشتر زمانی و توانایی پیش‌بینی روندهای غیرخطی، و همچنین فرایندهایی که شناخت کاملی از چگونگی رخداد آنها وجود ندارد جایگاه ویژه‌ای دارد (بهر روزی خزایی و همکاران ۱۳۸۶). تخمینهای روش شبکه‌ی عصبی مصنوعی در دو ایستگاه کرمان و راور، که دارای اقلیم مشابه گرم و خشک می‌باشند، در مقایسه با تخمینهای شبیه‌یابی خطی SDSM از دقت بالاتری برخوردارند. نتایج شبیه‌سازی پژوهش حاضر بیانگر کاهش میزان بارندگی سالانه کرمان، راور و رابر تا سال ۲۱۰۰ می‌باشند. این نتایج نشان می‌دهند که میزان بارندگی دوره‌های آتی تفاوت محسوسی با شرایط فعلی خواهد داشت و از روند کاهشی برخوردار است که در توافق با نتایج تحقیقات صورت گرفته به وسیله‌ی سرافروزه و همکاران (۱۳۹۱)، مقدم و همکاران (۱۳۹۱)، سیاری و همکاران (۱۳۹۰)، مساح بوانی و مرید (۱۳۸۴)، ژانگ و همکاران (۲۰۰۵)، آلیسون و همکاران (۲۰۰۴) می‌باشد.

روند نزولی میانگین بارش، باعث ایجاد تغییراتی مهم در کیفیت و کمیت منابع آب خواهد شد، این مهم لزوم تغییرات برنامه‌ریزی را در بهره‌برداری از منابع آب مشخص

می‌کند. برنامه‌های آینده باید به گونه‌ای باشند که تغییرات پیش‌رو اثرات زیانبار کمتری را متوجه بخش آب در این استان از کشورمان کند. لازم است هم‌اکنون تدابیری در جهت اصلاح نظام آبیاری، روشهای کاهش تبخیر، و استفاده مجدد از فاضلاب اتخاذ گردد. توصیه می‌گردد که سازمانهای مدیریتی، که در جایگاه تصمیم‌گیری مسائل مربوط به منابع آب استان قرار دارند، با شناسایی حوضه‌های مهم و تجهیز آنها با ابزار دقیق اندازه‌گیری و ثبت اطلاعات، زمینه‌ی پژوهش بیشتر و دسترسی به آمار واقعیت را فراهم سازند. همچنین، استفاده از روشهایی که در آن فراسنجهای شبکه‌ی عصبی و عصبی-فازی با استفاده از الگوریتم ژنتیک^۱ بهینه‌سازی شوند نیز حائز اهمیت است؛ این امر می‌تواند باعث کاهش خطا، افزایش سرعت محاسبات و دقت فرایند شبیه‌سازی بارش شود.

منابع

۱. آبکار، ع.، م. حبیب‌نژاد، ک. سلیمانی. و ه. نقوی. ۱۳۹۲. بررسی کارایی شبیه SDSM در شبیه‌سازی شاخص‌های دمایی در مناطق خشک و نیمه‌خشک. فصلنامه علمی پژوهشی مهندسی منابع آبیاری و آب. ۴(۱۴): ۱-۱۷.
۲. آشفته، پ.، و ا. حداد. ۱۳۹۲. ارائه رویکرد احتمالاتی ارزیابی اثرات تغییر اقلیم بر منابع آب. مجله مهندسی منابع آب. ۶(۱۹): ۵۱-۶۶.
۳. آشفته، پ.، و مساح بوانی. ع.ر. ۱۳۸۹. تأثیر تغییر اقلیم بر دبی‌های حداکثر، مطالعه موردی: حوضه آیدوغموش، آذربایجان شرقی. مجله علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک. ۱۴(۵۳): ۲۵-۳۹.
۴. احمدی باصری، ن.، ا. شیروانی. م.ج. ناظم‌السادات، ۱۳۹۳. کاربرد شبیه شبکه عصبی مصنوعی در خرد مقیاس نمودن برون داده‌های شبیه GCM برای پیش‌بینی بارش در پهنه جنوبی ایران. نشریه آب و خاک. ۲۸(۵): ۱۰۳۷-۱۰۴۷.
۵. اخلاقی، ت. و پ. اصلاح. ۱۳۸۴. تحلیل برگشتی در آزمایش SASW با استفاده از شبکه‌های عصبی

- مصنوعی. دومین کنگره ملی مهندسی عمران، ۲۳-۲۰ اردیبهشت ماه، دانشگاه علم و صنعت.
۶. اعلمی، م. ت.، ب. آقا بالایی. م. ح. احمدی، و س. فرزین. ۱۳۹۳. تخصیص بهینه‌ی نظام‌های منابع آب با استفاده از سامانه‌ی پویا. مجله مهندسی منابع آب. ۷(۲۳): ۹۹-۱۰۰.
۷. باقر زاده چهره، ک. ۱۳۸۴. ارزیابی علامت‌های هواشناسی در پیش‌بینی خشکسالی با استفاده از شبکه‌های عصبی مصنوعی در استان تهران. پایان نامه دوره کارشناسی ارشد، دانشگاه تربیت مدرس، گروه عمران. ص ۱۲۴.
۸. بریم نژاد و. و س.، یزدانی. ۱۳۸۳. تحلیل پایداری در مدیریت منابع آب در بخش کشاورزی با استفاده از برنامه‌ریزی کگروه، مطالعه موردی: استان کرمان. نشریه پژوهش و سازندگی در زراعت و باغبانی. ۶۳: ۲-۱۶.
۹. بهروزی خزاعی، ن. ت.، توکلی. ر. امیری چایجان و م. ه. خوش تقاضا، ۱۳۸۷. کاربرد شبکه‌های عصبی مصنوعی در در پیش‌بینی محتوای رطوبتی در طی فرآیند خشک کردن انگور. مجموعه مقالات پنجمین کنگره ملی مهندسی ماشین‌های کشاورزی و مکانیزاسیون، ۶-۷ شهریور ماه، دانشگاه فردوسی مشهد. ۹ ص.
۱۰. خسروی، م. و ه. شکیبا. ۱۳۸۹. پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی به منظور مدیریت سیل: مورد منطقه ایرانشهر. مجموعه مقالات چهارمین کنگره بین‌المللی جغرافیادانان جهان اسلام، ۲۷-۲۵ فروردین ماه، دانشگاه سیستان و بلوچستان. ۲۱ ص.
۱۱. خوشحال دستجردی، ج. و م. حسینی. ۱۳۸۹. کاربرد شبکه عصبی مصنوعی در شبیه‌سازی عناصر اقلیمی و پیش‌بینی سیکل خشکسالی (مطالعه موردی: استان اصفهان). مجله جغرافیا و برنامه‌ریزی محیطی. ۲۱(۳۹): ۱۰۷-۱۲۰.
۱۲. رجبی، ا. ۱۳۹۰. تحلیل عدم قطعیت تغییر اقلیم به وسیله‌ی شبیه SDSM در کرمانشاه. چهارمین کنفرانس مدیریت منابع آب ایران، ۱۳ و ۱۴ اردیبهشت ماه، دانشگاه صنعتی امیر کبیر. ۱۲ ص.
۱۳. سرافروزه، ف. م.، جلالی، ط.، جلالی، و ا. جمالی، ۱۳۹۱. ارزیابی اثرات تغییر اقلیم آینده بر مصرف آب محصول گندم در تبریز. فصلنامه علمی پژوهشی فضای جغرافیایی دانشگاه آزاد اسلامی واحد اهر. ۱۲(۳۷): ۸۱-۹۶.
۱۴. سیاری، ن. ا.، علیزاده، م. بنایان اول، ع. فریدحسینی، و حسامی کرمانی م. ر.، ۱۳۹۰. مقایسه دو شبیه‌گردش عمومی جو (HadCM3, CGCM2) در پیش‌بینی فراسنجهای اقلیمی و نیاز آبی گیاهان تحت تغییر اقلیم، مطالعه موردی: حوضه کشف رود. نشریه آب و خاک. ۲۵(۴): ۹۱۲-۹۲۵.
۱۵. شاه نقی، ن. م.، پارسی نژاد، ش.، عراقی نژاد، و ف. میرزایی، ۱۳۸۹. تأثیرات پتانسیل تغییر اقلیم بر تبخیر و تعرق، مطالعه موردی: دشت مشهد. اولین همایش ملی مدیریت منابع آب اراضی ساحلی، ۱۸-۱۷ آذر ماه، دانشگاه علوم کشاورزی و منابع طبیعی ساری. ۱۰ ص.
۱۶. شاه نقی، ن. م.، پارسی نژاد. ش.، و، عراقی نژاد. ف. میرزایی. ۱۳۹۰. تغییر اقلیم و تأثیر آن بر منابع و مصارف آب. چهارمین کنفرانس مدیریت منابع آب ایران، ۱۴-۱۳ اردیبهشت ماه، دانشگاه صنعتی امیر کبیر، ۱۱ ص.
۱۷. صلاح الدین، م. ذ.ا.، خانی تملیه، باطنی، م. م. و ن. مرتضوی. ۱۳۹۲. پیش‌بینی بارش و دما در حوضه دریاچه ارومیه با استفاده از شبیه HadCM3. دوازدهمین همایش ملی آبیاری و کاهش تبخیر کرمان، ۵ و ۶ شهریورماه، دانشگاه شهید باهنر کرمان.
۱۸. صمدی، س. ز. و ع. مساح بوانی. ۱۳۸۷. معرفی روش شبکه عصبی مصنوعی و SDSM به منظور کوچک مقیاس کردن آماری داده‌های دما و بارندگی. سومین کنفرانس مدیریت منابع آب ایران، ۲۳-۲۵ مهر ماه، دانشگاه تبریز. ۹ ص.
۱۹. طلوعی، س. ع. حسین‌زاده دلیر. م. ع. قربانی، ا. فاخری فرد. و ف. سلماسی. ۱۳۹۰. تخمین زمانی و مکانی بار معلق رودخانه آجی‌چای با استفاده از زمین

۲۸. مدرسی، ف، ش، عراقی نژاد، ک، ابراهیمی. و م، خلقی. ۱۳۹۰. بررسی اثر تغییر اقلیم بر میزان آبدهی سالانه رودخانه‌ها آزمون‌های آماری، مطالعه موردی: رودخانه گرگانرود. نشریه آب و خاک، ۲۵ (۶): ۱۳۶۵-۱۳۷۷.
۲۹. مقدم، س، ذ، خانی تملیه. م، باطنی. و م، منتصری. ۱۳۹۱. تأثیر پیامدهای تغییر اقلیم بر پیامدهای هواشناسی و آبشناسی (مطالعه موردی دریاچه ارومیه). اولین کنفرانس ملی راهکارهای دستیابی به توسعه پایدار، ۱۶ و ۱۷ اسفند ماه. تهران.
۳۰. مهسافر، ح، ر، مکنون. و ب، ثقفیان. ۱۳۹۰. اثرات تغییر اقلیم بر بیلان آبی دریاچه ارومیه. مجله تحقیقات منابع آب ایران. ۷ (۱): ۳۷-۵۸.
31. Aksoy, H., and A. Dahamsheh, 2009. Artificial neural network models for forecasting monthly precipitation in Jordan. *Stoch Environ Res Risk Assess.* 23: 917-931.
32. Alison, L. K., G.J. Richard and S. R. Nicholas 2004. RCM rainfall for UK flood frequency estimation Climate change results. *J Hydrol.* 318: 163-172.
33. Gordon, C., C., Cooper, C.A., Senior, H., Banks, J. M., Gregory, T.C., Johns, J.F. Mitchell, and R. A., Wood. 2000. The simulation of SST, sea ice extents and ocean heat transports in a version of the Hadley Centre coupled model without flux adjustments. *Clim Dy.* 16: 147-168.
34. Harpham, C., and R. L. Wilby. 2005. Multi-site downscaling of heavy daily precipitation occurrence and amounts. *J Hydrol.* 312: 235-255.
35. Khan, MS, P., Coulibaly. and Y. b., Dibike. 2006. Uncertainty analysis of statistical downscaling methods. *J Hydrol.* 319: 357-382.
36. Marier, H.R., and G.C., Dandy. 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and application. *Environ. Mode. and Soft.* 15: 101-124.
- آمار و شبکه عصبی مصنوعی. نشریه دانش آب و خاک. ۲۱ (۴): ۹۳-۱۰۴.
۲۰. عباسی، ف، ش، ملبوسیان، ا، بابائیان. و م، اثمیری. ۱۳۸۹. پیش‌بینی تغییرات اقلیمی خراسان جنوبی در دوره ۲۰۳۹-۲۰۱۰ میلادی با استفاده از ریزمقیاس نمایی آماری خروجی شبیه ECHO-G. نشریه آب و خاک (علوم و صنایع کشاورزی). ۲۴ (۲): ۲۱۸-۲۳۳.
۲۱. ح، غضنفرپور. م، کمانداری. و م، محمدی سلیمانی. ۱۳۹۲. تأثیر عوامل جغرافیایی در الگوی مساکن روستایی استان کرمان. فصل‌نامه جغرافیا و برنامه‌ریزی شهری چشم انداز زاگرس. ۵ (۱۸): ۱۲۵-۱۴۲.
۲۲. فاتحی مرج، ا و م. ح، مهدیان. ۱۳۸۸. پیش‌بینی بارش پاییزه با استفاده از شاخص‌های آنسو به روش شبکه عصبی در حوضه دریاچه ارومیه. مجله پژوهش‌های آبخیزداری (پژوهش و سازندگی). ۸۴: ۴۲-۵۲.
۲۳. فاتحی، ا، ع، صداقت کردار. و م، دلاور. ۱۳۸۷. پیش‌بینی بلند مدت بارش با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی: جنوب غرب ایران). مجله پژوهش و سازندگی در منابع طبیعی. ۸۰: ۴۴-۵۰.
۲۴. فتح‌آبادی، ا، ع، سلاجقه، و م، مهدوی. ۱۳۸۷. پیش‌بینی دبی رودخانه با استفاده از روش نوروفازی و شبیه‌های گروه زمانی. مجله علمی پژوهشی علوم و مهندسی آبخیزداری ایران. ۲ (۵): ۲۱-۲۷.
۲۵. فرخ‌نیا، ا. و س، مرید. ۱۳۸۸. تحلیل عدم قطعیت شبیه‌های شبکه عصبی و نوروفازی در پیش‌بینی جریان رودخانه. نشریه تحقیقات منابع آب ایران. ۵ (۳): ۱۴-۲۷.
۲۶. فلاح قاله‌ری، غ، و ج، خوشحال. و م، حبیبی نونندان. ۱۳۸۹. کاربرد منطق فازی و وایازی چند متغیره در پیش‌بینی بلندمدت بارش بهاره، مطالعه موردی: استان خراسان رضوی. مجله علمی پژوهشی علوم و مهندسی آبخیزداری ایران، ۱۲: ۳۷-۵۲.
۲۷. مساح بوانی، ع. و س، مرید. ۱۳۸۴. اثرات تغییر اقلیم بر جریان رودخانه زاینده رود. مجله علوم و فنون کشاورزی و منابع طبیعی. ۹ (۴): ۱۷-۲۷.

- surface change. Kluwer Academic Publishers, the Netherlands. 120 P.
40. Xu, C.Y. 1999. From GCMs to river flow: A review of downscaling methods and hydrologic modeling approaches. *Prog phys Geogr* 23: 229-249.
41. Zhang, X, W., Liu. Z, Li. and J. Chen, 2005. Trend and uncertainty analysis of simulated climate change impacts with multiple GCMs and emission scenarios method. *Clim Res.* 28: 109-122.
37. McCulloch, W.S. and W. Pitts. 1943. A logic calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.* 5: 115-133.
38. Wilby, R.L. and C.W. Dawson. 2008. Using SDSM Version 4.2- A decision support tool for the assessment of regional climate change impacts. User manual. 94 P.
39. Wilby, R.L. and M. D. Dettinger, 2000. Stream flow changes in Sierra Nevada, California, simulated using a statistically downscaled general circulation model scenario of climate change: Linking climate change to land

Archive of SID