



ارزیابی کارایی مدل شبکه عصبی مصنوعی برای ریزمقیاس‌نمایی و پیش‌بینی بلندمدت متغیرهای اقلیمی

ابراهیم امیدوار^۱، مریم رضایی^۲ و عبدالله پیرنیا^۳

۱- استادیار دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، (نویسنده مسوول: ebrahimomidvar@kashanu.ac.ir)

۲- دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشگاه کاشان

۳- دانش‌آموخته دکتری علوم و مهندسی آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی ساری

تاریخ دریافت: ۹۶/۳/۱۷ تاریخ پذیرش: ۹۷/۷/۲۱

چکیده

مدل‌های گردش عمومی به‌عنوان منبع اصلی شبیه‌سازی اقلیم، دارای شبکه محاسباتی با ابعاد بزرگ بوده و قادر به ارائه اطلاعات قابل اعتماد برای مدل‌سازی هیدرولوژیکی نمی‌باشند. برای پرداختن و رفع چنین محدودیت‌هایی از روش ریزمقیاس‌نمایی استفاده می‌شود. در پژوهش حاضر، شبیه‌سازی اثر تغییر اقلیم بر رفتار بارش و دمای ایستگاه سینوپتیک سیرجان در استان کرمان، مورد ارزیابی قرار گرفت. در ابتدا عملکرد مدل شبکه عصبی مصنوعی به‌منظور ریزمقیاس‌نمایی متغیرهای اقلیمی پیش‌بینی‌شده توسط مدل گردش عمومی CanESM2 مورد آزمون قرار گرفت. در ادامه با استفاده از مناسب‌ترین مدل‌ها مقادیر دما و بارندگی متوسط ماهانه برای دوره‌های آتی تحت سناریوی RCP 4.5 پیش‌بینی و بررسی گردیدند. نتایج نشان داد که برای متغیر دما ساختار مدل شبکه عصبی با تعداد ۲ لایه پنهان، ۸ نرون، تابع محرک تانژانت و لوگ‌سیگموئید و همچنین الگوریتم آموزش لونیبرگ-مارکوات دارای بیشترین کارایی و مقادیر RMSE، NS و R^2 به ترتیب برابر با ۰/۹۷۳، ۰/۹۱۷ و ۰/۹۱۷ بوده است. همچنین برای متغیر بارش نیز ساختاری با تعداد ۲ لایه، ۸ نرون، تابع محرک تانژانت و لوگ‌سیگموئید و الگوریتم آموزش لونیبرگ-مارکوات عملکرد مناسب‌تری داشت و مقادیر RMSE، NS و R^2 به ترتیب برابر با ۲/۸۶۷، ۲/۸۴۹ و ۰/۹۲۴ می‌باشند. سایر نتایج نشان داد که تا سال ۲۰۹۹، میانگین دما در سناریوی RCP 4.5، ۳ درجه سانتی‌گراد افزایش خواهد یافت و بیشترین افزایش مربوط به ماه اگوست به مقدار ۴/۹ و کمترین افزایش مربوط به ماه آوریل به مقدار ۱/۸ می‌باشد. نتایج، همچنین افزایش قابل توجه در میزان بارش ژوئیه تا نوامبر و کاهش بارش در ماه‌های مارس و می را نشان داد. با این وجود در مقیاس سالانه، تغییری در میزان بارندگی رخ نخواهد داد.

واژه‌های کلیدی: شبکه عصبی مصنوعی، مدل‌های گردش عمومی، گزارش پنجم IPCC، بارش، دما، سیرجان

مقدمه

(۱۷). در زمینه اثرات تغییرات اقلیمی روی میزان بارش و دما، پژوهش‌های بسیاری در سراسر جهان انجام شده است، که می‌توان به تحقیقات زیر اشاره نمود: ناستوس و همکاران (۱۹) طی مطالعه‌ای با استفاده از شبکه عصبی مصنوعی (ANNs) به پیش‌بینی حداکثر بارش روزانه در آتن یونان پرداختند. در نهایت نتایج تجزیه و تحلیل ایشان نشان داد که مدل ANN دارای عملکرد نسبتاً رضایت‌بخشی ($R^2=0/482$ ، $IA=0/871$) و $RMSE=16/4$) برای پیش‌بینی بارش روزانه می‌باشد. وو و همکاران (۲۶)، از مدل شبکه عصبی مصنوعی برای پیش‌بینی بارش در بانکوک تایلند استفاده کردند، نتایج حاکی از روند افزایشی برای بارش در فصول بارانی تا پایان قرن بیست و یکم در بانکوک بود. سانتوس و همکاران (۲۴)، از دو مدل ANN و رگرسیون چندمتغیره خطی برای تخمین بارش در امریکای جنوبی استفاده نمودند. نتایج حاکی از عملکرد بهتر مدل شبکه عصبی نسبت به مدل رگرسیون چندمتغیره خطی بود و در هر دو مدل نتایج بیانگر کاهش بارش زمستان و افزایش بارش در فصل تابستان بود. همچنین کامپوزانو و همکاران (۳)، از سه مدل ANN، SDSM و رگرسیون بردار پشتیبان حداقل مربعات (LS-SVM) برای ریزمقیاس‌نمودن بارش ماهانه در حوزه رودخانه‌ای Paute در اکوادور جنوبی استفاده نمودند. نتایج نشان داد دو مدل ANN و LS-SVM عملکرد تقریباً مشابهی داشته و نسبت به مدل SDSM عملکرد بالاتری داشتند. در داخل کشور نیز مهدی‌زاده و همکاران (۱۴)، اثرات تغییر اقلیم بر میزان بارش را در ایستگاه

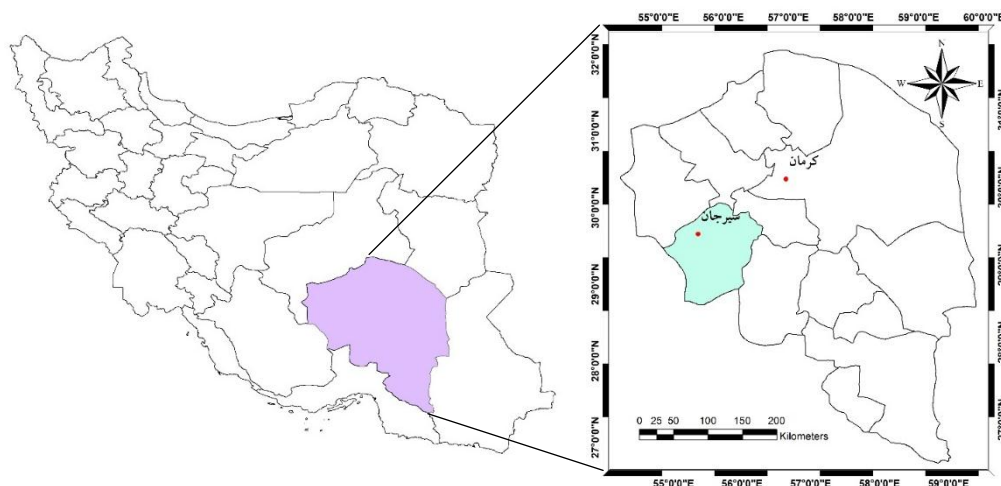
مدل‌های گردش عمومی جو، تغییرات بلندمدت آب و هوایی و یا تغییرات اقلیمی بخش‌های مختلف جهان را شبیه‌سازی می‌کنند (۴). علی‌رغم پیشرفت سریع و روزافزون این مدل‌ها، استفاده مستقیم از داده‌های شبیه‌سازی شده حاصله از آن‌ها برای مطالعات مستقیم در مقیاس‌های زمانی و مکانی قابل استفاده نیست و این موضوع، جزء محدودیت‌ها و ضعف‌های این مدل‌ها به شمار می‌آید (۱۶). برای پرداختن و رفع چنین محدودیت‌هایی، روش ریزمقیاس‌نمایی به‌طور گسترده‌ای در سراسر جهان به‌منظور شبیه‌سازی سری زمانی بارش و دما برای مطالعات تأثیرات تغییرات اقلیمی در مقیاس ایستگاهی و منطقه‌ای مورد استفاده قرار می‌گیرند (۲۳). مدل CanESM2 یک مدل جامع و جفت‌شده و چهارمین نسل از مدل‌های گردش عمومی جفت‌شده (CGCM4) است و جزء سری مدل‌های CMIP5 و گزارش پنجم هیئت بین‌الدول تغییر اقلیم می‌باشد (۱). شبکه‌های عصبی مصنوعی در حال حاضر در همه پدیده‌ها، به‌ویژه در موارد غیرخطی به‌کار می‌روند و در مسائل ریزمقیاس‌نمایی نیز از ارزش زیادی برخوردار می‌باشند. در پژوهش حاضر به‌منظور ریزمقیاس‌نمایی پارامترهای بارش و دما در ایستگاه سینوپتیک سیرجان، شبکه عصبی پرسپترون چندلایه (MLP) مورد استفاده قرار خواهد گرفت. ایده مدل شبکه عصبی مصنوعی از عملکرد مغز انسان سرچشمه گرفته است و دارای انواع مختلفی است که محبوب‌ترین آن شبکه‌های عصبی پرسپترون چندلایه می‌باشد

کاهش می یابد و نرخ تغییرات بر اساس سناریوی RCP 8.5 شدیدتر می باشد. پیرنیا و همکاران (۲۱) برای تولید داده ها دما و بارندگی در دوره های آتی به منظور مدل سازی رواناب، از مدل ریزمقیاس نمایی SDSM تحت سناریوهای RCP 4.5، RCP 4.5 و RCP 8.5 استفاده کردند و دریافتند که دما و بارندگی در دوره های آتی به ترتیب افزایش و کاهش خواهد یافت. نظر به اهمیت و لزوم پیش بینی پارامترهای هواشناسی کشور در شرایط تغییر اقلیم و مقایسه این پارامترها با شرایط حاضر، در این پژوهش سعی می شود داده های مدل CanESM2 تحت سناریوی RCP 4.5، جهت شبیه سازی میانگین بارش و دمای ماهانه دوره های آتی ایستگاه سینوپتیک سیرجان، با استفاده از مدل شبکه عصبی مصنوعی ریزمقیاس گردیده و عملکرد این مدل مورد ارزیابی قرار گیرد. باتوجه به اینکه پیش بینی بلندمدت پارامترهای اقلیمی نیاز به آمار طولانی مدت و قابل اعتماد دارد، لذا ایستگاه سینوپتیک سیرجان به دلیل دارا بودن آمار طولانی مدت به عنوان نماینده منطقه اقلیمی خشک، در پژوهش حاضر انتخاب گردید.

مواد و روش ها منطقه مورد مطالعه

شهرستان سیرجان در جنوب شرقی ایران و در استان کرمان، در طول جغرافیایی $41^{\circ} 55'$ و عرض جغرافیایی $28^{\circ} 29'$ و در ارتفاع $1739/4$ متر از سطح دریا قرار گرفته است. این منطقه، نماینده منطقه اقلیمی خشک می باشد (۱۱). موقعیت جغرافیایی ایستگاه مذکور در شکل شماره ۱، ارائه شده است.

کریم ایشان و رباط قریبل در حوضه سد گلستان مورد بررسی قرار داده و از مدل ریزمقیاس نمایی شبکه عصبی مصنوعی برای پیش بینی بارش استفاده کردند. نتایج ایشان نشان داد که تا سال ۲۱۰۰، میانگین بارش ماهانه در ایستگاه کریم ایشان در فصل پاییز و زمستان تا ۴۳ میلی متر افزایش و در بهار و تابستان تا ۲۳ میلی متر کاهش و در ایستگاه رباط قریبل در فصل پاییز و زمستان تا ۳۲ میلی متر افزایش و در بهار و تابستان تا ۱۱ میلی متر کاهش خواهد یافت. همچنین ستاری و نهرین (۲۵)، با استفاده از مدل های هوشمند شبکه های عصبی مصنوعی، برنامه ریزی ژنتیک و مدل درختی M5، مقادیر حداکثر بارش روزانه را در ایستگاه های اهر و جلفا پیش بینی نمودند. در دو ایستگاه اهر و جلفا، هر سه روش مذکور ضمن رقابت با یکدیگر نتایج نسبتاً دقیقی را جهت پیش بینی حداکثر بارش روزانه در ماه موردنظر در منطقه ارائه می کنند ولی روش برنامه ریزی ژنتیک در دو ایستگاه مذکور بهترین نتایج را نشان داد. فلاح قالهیری و شاکری (۷)، کاربرد شبکه های عصبی مصنوعی را در پیش بینی بارش زمستانه استان خراسان رضوی مورد بررسی قرار دادند. آن ها پس از شناسایی سیگنال های مؤثر بر بارش منطقه، مدل را در دوره ۱۹۹۷-۱۹۷۰ آموزش داده و در پایان، پیش بینی بارش را در دوره ۲۰۰۷-۱۹۹۸ انجام دادند. نتایج ایشان نشان داد شبکه های عصبی مصنوعی قادرند بارش را با دقت قابل قبولی پیش بینی نمایند. نظری شریبان و همکاران (۲۰) به منظور پیش بینی داده های اقلیمی، از مدل ریزمقیاس نمایی SDSM و بر اساس خروجی های مدل اقلیمی CanESM2 تحت سناریوهای جدید RCP 2.6، RCP 4.5 و RCP 8.5 استفاده کردند. نتایج آنها نشان داد که دما افزایش و بارندگی



شکل ۱- موقعیت مکانی ایستگاه سیرجان در استان کرمان و ایران
Figure 1. Sirjan station position in Kerman province and Iran

سناریوهای پیشنهادی در چهار حالت ۲.۶، ۴.۵، ۶ و ۸.۵ می باشند. سناریوهای RCP نشان دهنده محرکه های تابشی هستند و در میان آنها سناریوی RCP 2.6 سناریوهای انتشار و محرکه های تابشی کم (تقریباً مشابه با سناریوهای B1 یا

ریزمقیاس نمایی داده های اقلیمی
با شروع دهه ۲۰۱۰ و در پنجمین گزارش ارزیابی (AR5)^۱ هیئت بین الدولی تغییر اقلیم (IPCC)، CMIP5^۲ سناریوهای جدید RCPs^۳ را به جای سناریوهای SRES^۴ پیشنهاد داد که

1- Fifth Assessment Report
3- Coupled Model Intercomparison Project 5
5- Special Report on Emissions Scenarios

2- International Panel on Climate Change
4- Representative Concentration Pathways

با توجه به وجود برخی محدودیت‌ها در استفاده از داده‌های مدل‌های GCM در ارتباط با استفاده از سناریوهای گزارش پنجم، در این تحقیق از داده‌های مدل CanESM2^۱ استفاده شده است. مدل CanESM2 یک مدل جامع و جفت‌شده و چهارمین نسل از مدل‌های گردش عمومی جفت‌شده^۲ (CGCM4) است و جزء سری مدل‌های CMIP5 و گزارش پنجم هیئت بین‌الدول تغییر اقلیم می‌باشد (۱). مشخصات این مدل در جدول ۱ نشان داده شده است.

B2 و سناریوی RCP 8.5 محرکه‌های تابشی و سناریوهای انتشار زیاد (تقریباً مشابه با سناریوهای A1 یا A2) را نشان می‌دهند. همچنین سناریوهای RCP 4.5 و RCP 6 حالت متوسط دارند (۱۸،۲۲). در این تحقیق برای تحلیل آینده از میان سناریوهای معرفی شده توسط پنجمین گزارش ارزیابی IPCC (AR5)، دو سناریوی RCP 2.6 و RCP 8.5 برای دوره زمانی ۲۰۲۰-۲۰۴۹ انتخاب شدند.

جدول ۱- مشخصات مدل CanESM2 (۱)

| نام مدل | قدرت تفکیک اتمسفری (درجه) (طول×عرض) | قدرت تفکیک اقیانوسی (درجه) (طول×عرض) | گروه موسس | دوره شبیه‌سازی تاریخی/آینده | سناریوهای شبیه‌سازی | مرجع |
|----------------|-------------------------------------|--------------------------------------|----------------|-----------------------------|----------------------------|------|
| CanESM2 (2010) | ۲۸۱°×۲۸۱° | ۱۰۹۴°×۱۰۹۴° | (CCCMA) کانادا | ۲۰۰۵-۲۱۰۰/۱۸۵-۲۱۰۶ | RCP 2.6, RCP 4.5 و RCP 8.5 | (۱) |

مثال‌هایی می‌باشد که به‌طور مکرر به شبکه ارائه می‌گردد (۶). شبکه عصبی مورد استفاده در پژوهش حاضر، شبکه پرسپترون پیش‌خور با الگوریتم پس انتشار خطا می‌باشد. **شبکه عصبی پرسپترون چندلایه (MLP)** شبکه عصبی پرسپترون، یک شبکه پیش‌خور چندلایه، شامل یک ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. گره‌های ورودی، اطلاعات را از بیرون دریافت می‌کنند و نتایج از طریق نرون‌های لایه خروجی شبکه حاصل می‌گردد. پیش‌خور بودن به این معناست که نرون‌های مصنوعی در لایه‌های متوالی قرار گرفته‌اند و خروجی (سیگنال) خود را رو به جلو می‌فرستند. الگوریتم آموزشی که در این نوع شبکه‌ها استفاده می‌شود، معمولاً الگوریتم پس انتشار خطا می‌باشد (۱۵). الگوریتم پس انتشار خطا، از مطرح‌ترین الگوریتم‌های آموزش شبکه‌های MLP است که در آن داده خروجی با داده هدف مقایسه و میزان خطا محاسبه می‌شود، سپس خطای محاسبه شده به لایه‌های پیشین انتقال می‌یابد و ضرایب وزنی اصلاح می‌گردد (۳۱).

استانداردسازی داده‌ها

اولین مرحله قبل از ورود داده‌ها به شبکه عصبی مصنوعی، استاندارد نمودن آن‌ها می‌باشد. ورود داده‌ها به‌صورت خام، سرعت و دقت شبکه را کاهش می‌دهد، لذا لازم است داده‌های ورودی به شبکه استاندارد گردند. در پژوهش حاضر، برای نرمال کردن داده‌ها بین ۰/۱ و ۰/۹ از رابطه (۱) استفاده شده است (۹).

$$N = 0.8 \times \frac{X_i - X_{min}}{X_{max} - X_{min}} + 0.1 \quad (۱)$$

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

معماری شبکه‌های عصبی

معماری مناسب به معنی انتخاب بهینه تعداد لایه‌ها، تعداد نرون‌ها در هر لایه و نوع تابع حرکت هر نرون است، که معماری بهینه شبکه عصبی مصنوعی مبتنی بر مجموعه داده‌ها و ویژگی‌های آن‌ها است (۵).

در این تحقیق از داده‌های روزانه بارندگی و دمای میانگین استفاده شده است. بدین منظور داده‌های NCEP خروجی‌های مدل CanESM2 تحت سناریوی RCP 4.5 مورد ارزیابی قرار گرفت. جهت استفاده از مدل ریزمقیاس‌نمایی شبکه عصبی مصنوعی و استفاده از سناریو RCP 4.5، برای ارزیابی عملکرد مدل ذکر شده، دوره آماری ۲۰۰۰-۱۹۷۱ در نظر گرفته شد. اما برای مقایسه داده‌های تولید شده در آینده با داده‌های زمان حال، دوره ۲۰۱۲-۱۹۸۰ به‌عنوان دوره پایه در نظر گرفته شد. داده‌های NCEP، شامل ۲۶ متغیر جوی است (۱۷) و در روش ریزمقیاس‌نمایی به عنوان متغیر مستقل مورد استفاده قرار می‌گیرند. روش‌های ریزمقیاس‌نمایی بین متغیرهای پیش‌بینی‌کننده بزرگ‌مقیاس (NCEP) و پیش‌بینی شونده (بارش و دما) رابطه ایجاد می‌کنند. در مرحله بعد از میان متغیرهای ذکر شده، متغیرهایی که در تدوین مدل‌های ماهانه به‌کار می‌روند، انتخاب شدند. انتخاب این متغیرها براساس آزمون همبستگی بین متغیرهای وابسته دما و بارش و همچنین هریک از متغیرهای مستقل NCEP انجام شد و متغیرهایی که از نظر آماری دارای همبستگی معنی‌دار بالا بودند، انتخاب شدند. در ادامه با استفاده از مدل شبکه عصبی مصنوعی، داده‌ها مورد آموزش و آزمون قرار گرفته و در نهایت طی این مرحله از کار با استفاده از داده‌های مدل میزان بارش و دما برای دو دوره‌ی سی ساله ۲۰۴۰-۲۰۶۹ و ۲۰۹۹-۲۰۷۰ پیش‌بینی شد.

مدل شبکه عصبی مصنوعی

در این تحقیق به‌منظور ریزمقیاس‌نمایی داده‌های تولید شده توسط مدل CanESM2 از مدل‌های شبکه عصبی پرسپترون چند لایه استفاده شد که در ذیل ساختار و نحوه مدل‌سازی آن تشریح می‌گردد. شبکه‌های عصبی مصنوعی یکی از شاخه‌ها و تکنیک‌های هوش مصنوعی و برگرفته از ساختار مغز انسان می‌باشند که از تعداد زیادی واحد، که موسوم به نرون است، تشکیل شده‌اند. شبکه‌های عصبی مصنوعی، قادر به تشخیص، یادگیری و پیش‌بینی روابط پیچیده میان کمیت‌ها هستند. یکی از شاخصه‌های برجسته شبکه‌های عصبی این است که تنظیمات شبکه براساس

تعداد نرون‌های لایه‌های مخفی

تعداد نرون لایه ورودی و خروجی به ترتیب بر اساس تعداد داده‌های ورودی و خروجی مدل تعیین می‌شود. در مورد تعداد نرون‌های لایه میانی (پنهان)، مبنای خاصی وجود نداشته و معمولاً با روش سعی و خطا به نحوی انتخاب می‌گردد که خطای شبکه حداقل شود (۲).

الگوریتم‌های آموزشی

الگوریتم‌های آموزشی شبکه عصبی دارای پارامترهای متفاوتی هستند و حساسیت‌های مختلفی نسبت به این پارامترها نشان می‌دهند و عملکرد یک شبکه عصبی به میزان زیادی به انتخاب پارامترهای آن بستگی دارد. در این پژوهش از الگوریتم آموزش پس‌انتشار خطا استفاده شد که خود شامل چندین زیر گروه است. هر یک از این زیر گروه‌ها نیز روش‌های بهینه‌سازی متفاوتی مانند لوبنبرگ-مارکوات، گرادیان نزولی و گوسی-نیوتن و... دارند.

تابع محرک

در شبکه‌های عصبی، برای انتقال خروجی‌های هر لایه به لایه بعدی، از یک تابع محرک استفاده می‌شود. توابع محرک، انواع مختلفی شامل تابع خطی، تابع لوگ سیگموئید، تابع تانژانت سیگموئید و هیپربولیک و ... دارند (۱۲). در پژوهش حاضر از توابع لوگ سیگموئید، تانژانت سیگموئید و خطی استفاده گردید.

آموزش و آزمون (تست) در شبکه عصبی مصنوعی

در مدل شبکه عصبی مصنوعی داده‌ها به دو دسته آموزش و آزمون تقسیم می‌شوند. در آموزش شبکه عصبی، وزن اتصالات مختلف به گونه‌ای محاسبه می‌گردد که با اعمال هر بردار ورودی از سری آموزشی، شبکه بتواند خروجی متناظر را با میزان خطای مشخص تولید نماید (۱۰). پس از اینکه هر شبکه با استفاده از داده‌های آموزش تعلیم داده شد، داده‌های آزمون نیز برای ارزیابی و آزمون شبکه استفاده می‌شود (۲۸).

در تحقیق حاضر به منظور ساخت شبکه، از کدنویسی در محیط نرم‌افزار MATLAB 2009 استفاده شد. پس از استاندارد نمودن داده‌ها، مقدار ۷۰ درصد از آن‌ها برای آموزش (داده‌های دوره ۱۹۹۱-۱۹۷۱) و ۳۰ درصد از داده‌ها برای آزمون (داده‌های دوره ۲۰۰۰-۱۹۹۲) در نظر گرفته شد. همان‌گونه که در بخش‌های قبل اشاره شد در مدل شبکه عصبی مصنوعی می‌توان با استفاده از روش سعی و خطا در انتخاب نوع تابع محرک، الگوریتم آموزشی، تعداد لایه‌های پنهان و تعداد نرون‌های لایه‌های پنهان تجدیدنظر نمود. در صورت کارایی بهتر شبکه، آن شبکه به عنوان شبکه بهینه

انتخاب می‌گردد، در غیر این صورت، همه مراحل تکرار می‌گردد تا شبکه به جواب بهینه و مطلوب دست یابد.

معیارهای ارزیابی عملکرد مدل

منظور از ارزیابی مدل، به دست آوردن میزان خطای مدل با توجه به داده‌های ورودی داده شده به مدل جهت آموزش و بر اساس معیارهای مختلف محاسبه خطا می‌باشد. در این تحقیق جهت ارزیابی عملکرد مدل از معیارهای مجذور میانگین مربعات خطا (RMSE)، ضریب ناش-ساتکلیف (NS) و ضریب تبیین استفاده شد. کم بودن میزان خطای RMSE و بالابودن ضریب تبیین و ضریب کارایی نش-ساتکلیف بیان‌گر دقت قابل قبول مدل و ملاک برتری آن خواهد بود (۳).

نتایج و بحث

شبیه‌سازی و پیش‌بینی دما

از بین ۲۶ پارامتر بزرگ‌مقیاس NCEP، ۵ پارامتر نهایی ژئوپتانسیل در ارتفاع فشاری ۵۰۰ هکتوپاسکال، جهت باد در ارتفاع فشاری ۵۰۰ هکتوپاسکال، میانگین دما در ارتفاع ۲ متری، رطوبت نسبی در ۵۰۰ هکتوپاسکال و رطوبت نسبی در ۸۵۰ هکتوپاسکال که همبستگی بیشتری با دمای میانگین ماهانه سیرجان داشتند، انتخاب و به عنوان ورودی (متغیر مستقل) به مدل شبکه عصبی مصنوعی وارد شدند. نتایج مربوط به کارایی بهترین ساختار ارائه شده توسط هر الگوریتم در جدول ۲ ارائه شده است. با توجه به این نتایج، الگوریتم‌های گرادیان نزولی با مومنتوم (GDM) و گرادیان نزولی (GD) نسبت به سایر الگوریتم‌ها ضعیف‌ترین بودند و الگوریتم پس‌انتشار لوبنبرگ-مارکوات (LM) دارای بالاترین عملکرد و کمترین خطا در آموزش بود. جلالی و همکاران (۸) نیز کارایی بالاتر این الگوریتم را در مقایسه با سایر الگوریتم‌ها نشان دادند. پس از انتخاب مناسب‌ترین الگوریتم آموزش برای شبکه، به منظور تعیین بهترین ساختار برای شبکه پرسپترون پیشخور، ساختارهای مختلف با تعداد لایه‌ها و نرون‌های مختلف در هر لایه بررسی گردید. همچنین شبکه با تعداد تکرار ثابت ۱۰۰۰ و الگوریتم لوبنبرگ-مارکوات آموزش داده شد. در جدول ۳ برخی از نتایج مربوط کارایی حالات مختلف معماری شبکه ارائه گردیده است. نتایج جدول ۳ نشان داد با افزایش تعداد نرون در لایه پنهان، خطا کاهش می‌یابد، در حالی که اگر تعداد نرون‌های لایه پنهان، بیش از ۱۰ عدد باشد، خطا افزایش و از دقت مدل شبکه عصبی کاسته می‌شود.

جدول ۲- مقایسه کارایی بهترین ساختارهای به‌دست آمده شبکه عصبی مصنوعی در الگوریتم‌های مختلف پس‌انتشار
Table 2. Comparison of performance the best structures of artificial neural network in various backpropagation algorithm

| الگوریتم‌های پس‌انتشار* | RMSE | | NS | | R ² | |
|-------------------------|--------|--------|-----------|--------|----------------|-----------|
| | آموزش | تست | دوره پایه | تست | آموزش | دوره پایه |
| LM | + /۳۴۸ | + /۴۲۳ | + /۳۱۸ | + /۹۴۲ | + /۹۶۸ | + /۹۷۸ |
| GD | ۸/۵۳۵ | ۸/۶۸۵ | ۸/۲۹ | - /۰۲۵ | - /۲۱ | - /۷۵۰ |
| GDM | ۱۰/۳۲ | ۱۰/۴۸ | ۱۰/۳۵ | - /۱۴ | - /۰۸۶ | - /۷۱ |
| GDA | ۱/۲۸۳ | ۱/۳۶۷ | ۱/۴۲۶ | ۰/۹۱۷ | ۰/۹۳۲ | ۰/۸۵۹ |
| GDX | - /۸۷۲ | - /۸۹۶ | - /۸۴ | - /۹۳ | - /۹۳۴ | - /۸۹۲ |
| CGF | ۰/۸۹ | - /۸۴۹ | - /۸۷۶ | - /۹۴۵ | - /۹۵ | - /۹۳۴ |
| CGP | - /۷۹۷ | - /۷۸۲ | - /۷۶۷ | - /۹۱ | - /۹۱۸ | - /۹۲۵ |
| CGB | - /۶۲۳ | - /۶۴۵ | - /۶۷۴ | ۰/۹۲۸ | ۰/۹۴۷ | ۰/۹۴۹ |
| SCG | - /۵۸۹ | - /۵۹۳ | - /۵۶ | - /۹۲۳ | - /۹۲۸ | ۰/۹ |
| BFGS | - /۵۲۹ | - /۵۲ | - /۴۹۸ | - /۹۵۲ | - /۹۴۲ | - /۹۵۲ |
| OSS | - /۷۵۳ | - /۶۷۵ | - /۶۳ | - /۹۴۳ | - /۹۳۱ | ۰/۹ |
| RP | ۰/۵۱۲ | ۰/۵ | - /۵۲۶ | - /۹۵۱ | - /۹۶۳ | - /۹۴ |

*: LM: لونبرگ-مارکوات، GD: گرادیان نزولی، GDM: گرادیان نزولی با مومنتوم، GDA: گرادیان نزولی با lr تطبیقی، GDX: گرادیان نزولی با مومنتوم و lr تطبیقی، CGF: گرادیان مزدوج فلجر - پاول، CGP: گرادیان مزدوج پولاک - ریبر، CGB: گرادیان مزدوج پاول - بیل، SCG: گرادیان مزدوج مدرج، BFGS: گوسی نیوتن، OSS: یک گام متقاطع، RP: ارتجاعی

جدول ۳- نتایج الگوریتم لونبرگ-مارکوات با لایه‌های پنهان و نرون‌های مختلف برای شبیه‌سازی دما
Table 3. The results of Levenberg-Marquardt algorithm with different numbers of hidden layers and neurons for temperature simulation


| مدل | تعداد لایه پنهان | تعداد نرون لایه اول | تعداد نرون لایه دوم | RMSE | | | NS | | | R ² | |
|-----------|------------------|---------------------|---------------------|---------------|---------------|---------------|---------------|---------------|---------------|----------------|---------------|
| | | | | آموزش | تست | پایه | آموزش | تست | پایه | آموزش | تست |
| ۱ | ۱ | ۲ | -- | ۰/۵۹۷ | ۰/۷ | ۰/۶۵۹ | ۰/۹۵۴ | ۰/۹۵۱ | ۰/۹۴۹ | ۰/۸۹ | - /۸۹۲ |
| ۲ | ۱ | ۴ | -- | ۰/۶۴۱ | ۰/۷۲۴ | ۰/۶۲۷ | ۰/۹۵۱ | ۰/۹۴۹ | ۰/۹۵۷ | ۰/۸۸۱ | - /۸۹ |
| ۳ | ۱ | ۶ | -- | ۰/۵۷۶ | ۰/۷۱۲ | ۰/۶۲۷ | ۰/۹۴۷ | ۰/۹۳۸ | ۰/۹۳۹ | ۰/۸۹۳ | - /۸۹۷ |
| ۴ | ۱ | ۸ | -- | ۰/۵۲۷ | ۰/۵۳۹ | ۰/۵۱۲ | ۰/۹۵۹ | ۰/۹۶۴ | ۰/۹۵۶ | ۰/۸۸۸ | - /۸۹۶ |
| ۵ | ۱ | ۱۰ | -- | ۰/۴۸۲ | ۰/۴۷۹ | ۰/۴۵۳ | ۰/۹۶۶ | ۰/۹۷ | ۰/۹۶۷ | ۰/۹۱ | - /۹۰۹ |
| ۶ | ۱ | ۱۲ | -- | ۰/۴۵۰ | ۰/۴۳ | ۰/۴۳۸ | ۰/۹۶۵ | ۰/۹۶۹ | ۰/۹۷۱ | ۰/۸۹۸ | - /۹۱۳ |
| ۷ | ۱ | ۱۴ | -- | ۰/۴۷۲ | ۰/۴۵۰ | ۰/۴۴۸ | ۰/۹۶ | ۰/۹۶۴ | ۰/۹۶۴ | ۰/۹۰۷ | - /۹۰۵ |
| ۸ | ۱ | ۱۶ | -- | ۰/۵۷۹ | ۰/۵۵۹ | ۰/۵۳۵ | ۰/۹۳۹ | ۰/۹۵۱ | ۰/۹۵۸ | ۰/۸۶۷ | - /۸۸۳ |
| ۹ | ۱ | ۱۸ | -- | ۰/۵۲۹ | ۰/۵۱۹ | ۰/۵۲ | ۰/۹۴۹ | ۰/۹۵۴ | ۰/۹۵۵ | ۰/۸۸۹ | - /۸۸۴ |
| ۱۰ | ۲ | ۲ | ۲ | ۰/۵۸۲ | ۰/۵۴۹ | ۰/۵۴۶ | ۰/۹۵۴ | ۰/۹۶۸ | ۰/۹۶۷ | ۰/۸۹۸ | - /۹۰۷ |
| ۱۱ | ۲ | ۴ | ۴ | ۰/۵۲۶ | ۰/۵۱۳ | ۰/۴۸۷ | ۰/۹۵۹ | ۰/۹۵۷ | ۰/۹۶۲ | ۰/۹۰۶ | - /۹۱۴ |
| ۱۲ | ۲ | ۴ | ۶ | ۰/۶۱۲ | ۰/۶۲۸ | ۰/۶۲۴ | ۰/۹۶۴ | ۰/۹۷۲ | ۰/۹۷۳ | ۰/۹ | - /۹۰۵ |
| ۱۳ | ۲ | ۶ | ۶ | ۰/۶۷۳ | ۰/۶۳۹ | ۰/۶۶۷ | ۰/۹۶۵ | ۰/۹۷۶ | ۰/۹۵۴ | ۰/۸۹۳ | - /۹۰۸ |
| ۱۴ | ۲ | ۸ | ۸ | ۰/۵۷۶ | ۰/۵۶۹ | ۰/۵۴۲ | ۰/۹۵۱ | ۰/۹۵۶ | ۰/۹۶۴ | ۰/۹۰۲ | - /۸۹۶ |
| ۱۵ | ۲ | ۸ | ۲ | ۰/۵۵۶ | ۰/۵۴۷ | ۰/۵۷۲ | ۰/۹۵۷ | ۰/۹۶۷ | ۰/۹۷۴ | ۰/۸۸۱ | - /۸۹۴ |
| ۱۶ | ۲ | ۸ | ۴ | ۰/۴۹۵ | ۰/۴۸۴ | ۰/۴۹۲ | ۰/۹۶۲ | ۰/۹۷۵ | ۰/۹۵۹ | ۰/۹۱ | - /۹۱۱ |
| ۱۷ | ۲ | ۸ | ۶ | ۰/۴۵۷ | ۰/۵۷۶ | ۰/۵۱۴ | ۰/۹۶۶ | ۰/۹۷۱ | ۰/۹۶۹ | ۰/۸۹۲ | - /۸۹۶ |
| ۱۸ | ۲ | ۸ | ۸ | + /۴۱۷ | + /۶۵۷ | + /۳۸۷ | + /۹۶۴ | + /۹۷۴ | + /۹۷۳ | + /۹ | + /۹۱۷ |
| ۱۹ | ۲ | ۱۰ | ۶ | ۰/۴۹۲ | ۰/۹۸۴ | ۰/۵۲۴ | ۰/۹۶۱ | ۰/۹۷۵ | ۰/۹۶۴ | ۰/۸۸۵ | - /۸۹۴ |
| ۲۰ | ۲ | ۱۰ | ۱۰ | ۰/۵۳۷ | ۰/۵۵۴ | ۰/۵۷۹ | ۰/۹۴۱ | ۰/۹۵۲ | ۰/۹۶۳ | ۰/۹۱ | ۰/۹ |
| ۲۱ | ۲ | ۱۲ | ۲ | ۰/۴۸۲ | ۰/۴۵۳ | ۰/۵۲۱ | ۰/۹۶۲ | ۰/۹۷ | ۰/۹۶۸ | ۰/۹ | - /۹۱۱ |
| ۲۲ | ۲ | ۱۴ | ۸ | ۰/۴۳۸ | ۰/۴۴۵ | ۰/۴۸۱ | ۰/۹۶۸ | ۰/۹۷۵ | ۰/۹۵۶ | ۰/۸۹۲ | - /۸۹۷ |

در نهایت همان‌گونه که در بخش روش انجام پژوهش ذکر شد، پس از انجام مراحل آزمون و خطا مدل مناسب شبکه عصبی مصنوعی پرسپترون پیش‌خور چندلایه با تعداد نرون، لایه پنهان، توابع محرک و الگوریتم آموزش مناسب برای داده‌های ماهانه دمای ایستگاه سیرجان ساخته شد که قسمتی از این نتایج در جداول ۲ و ۳ ارائه شد. با توجه به نتایج این جدول، مدل ۱۸ با بالاترین مقدار NS (۰/۹۷۳) و

همچنین کمترین مقدار RMSE (۰/۳۸۷) برای دوره پایه به عنوان مناسب‌ترین مدل انتخاب شد. این یافته‌ها به‌خصوص در مورد معیارهای NS و R² حاکی از آن است که مدل شماره ۱۸ الگوی تغییرات دمای منطقه مطالعاتی را به خوبی شبیه‌سازی نموده است. مشخصات مدل ساخته شده (مدل ۱۸) در جدول شماره ۴، ارائه شده است.

جدول ۴- مشخصات مدل شبکه عصبی مصنوعی ساخته شده برای داده‌های دمای ماهانه ایستگاه سینوپتیک سیرجان
 Table 4. Characteristics of created artificial neural network model for monthly temperature data of synoptic station of Sirjan

| نوع شبکه عصبی | تعداد نرون | تابع محرک لایه‌های پنهان اول و دوم | تابع محرک لایه خروجی | الگوریتم آموزشی |
|--------------------------|------------|------------------------------------|----------------------|-----------------|
| پرسپترون پیش‌خور سه‌لایه | ۸-۸ | تانژانت و لوگ سیگموئید | خطی | لونیگ-مارکوات |




شکل ۲- مقایسه دمای میانگین ماهانه مشاهداتی و شبیه‌سازی شده توسط مناسب‌ترین مدل شبکه عصبی مصنوعی، در دو دوره آموزش (الف) و آزمون (ب)

Figure 2- Comparison of mean observed and simulated temperature data with the most appropriate ANN model of two train (A) and test (B) periods

تغییرات بلندمدت میانگین دمای ماهانه سیرجان می‌باشد. این نتایج حاکی از آن است که در کلیه ماه‌های سال روند افزایشی در میزان دما در دوره (۲۰۷۰-۲۰۹۹) نسبت به دوره پایه وجود دارد و بیشترین افزایش دما مربوط به ماه اگوست به میزان ۴/۹ درجه سانتی‌گراد و در ماه آوریل کمترین افزایش حدود ۱/۸ درجه سانتی‌گراد مشاهده شد. در مقیاس سالانه میانگین دمای محاسبه شده در دوره‌های زمانی (۲۰۴۰-۲۰۶۹) و (۲۰۷۰-۲۰۹۹) میلادی به ترتیب به مقدار ۱/۷ و ۳ درجه سانتی‌گراد نسبت به دوره پایه افزایش یافته است. بسیاری از مطالعات نیز نشان دادند که در دوره‌های آینده دور و تا سال ۲۱۰۰، افزایش دما بارزتر از دوره‌های آتی نزدیک تر می‌باشد. همچنین نشان دادند که افزایش دما بر اساس سناریوی RCP 4.5، شرایط متوسطی را نسبت به دو سناریوی RCP 2.6 و RCP 8.5 دارد (۲۰، ۲۱، ۲۹).

همان‌گونه که در شکل‌های ۲-الف و ب، مشخص است مدل شبکه عصبی مصنوعی در هر دو دوره آموزش و آزمایش نتایج قابل قبولی را ارائه کرده و اختلاف مقادیر شبیه‌سازی شده دما و داده‌های مشاهداتی کم و قابل اغماض است که این موضوع، بیان‌گر کارایی خوب مدل، در پیش‌بینی میانگین دمای ماهانه سیرجان می‌باشد. در ادامه میانگین ماهانه دمای منطقه در آینده از مدل فوق محاسبه شد. نهایتاً این مقادیر با میانگین ماهانه دمای مشاهداتی (۱۹۸۰-۲۰۱۲) مورد مقایسه قرار گرفت (شکل ۳).

در ادامه، پارامتر دما برای دو دوره آتی (۲۰۴۰-۲۰۶۹) و (۲۰۷۰-۲۰۹۹)، شبیه‌سازی و نتایج آن در شکل ۳ نشان داده شد. شکل ۳، تغییرات میانگین دمای ماهانه پیش‌بینی شده دوره‌های آتی توسط مدل شبکه عصبی مصنوعی را نسبت به دوره پایه (۱۹۸۰-۲۰۱۲) نشان می‌دهد که بیان‌گر محدوده



شکل ۳- مقایسه میانگین دمای ماهانه در دوره حال (۱۹۸۰-۲۰۱۲) و آینده
Figure 3. Comparison of mean temperature in the present (1980-2012) and future periods

پس‌انتشار بهینه، سیزده الگوریتم پس‌انتشار با یکدیگر مقایسه شد و همچنین توابع محرک و لایه‌های پنهان مختلف مورد بررسی قرار گرفت. به‌منظور خلاصه‌سازی در ارائه مطالب مقاله از ارائه جداول نتایج صرف‌نظر گردید و خصوصیات شبکه عصبی بهینه ایجاد شده نهایی برای پیش‌بینی بارش سیرجان در جدول ۵، ذکر گردید. همچنین نتایج حاصل از ارزیابی مدل بهینه شبکه عصبی مصنوعی ساخته شده در جدول شماره ۶، ارائه شده است.

شبیه‌سازی و پیش‌بینی بارش

پس از بررسی میزان همبستگی بین متغیر بارش و پارامترهای NCEP، پارامترهای میانگین دما در ارتفاع ۲ متری، رطوبت نسبی در ۵۰۰ هکتوپاسکال و رطوبت نسبی در ۸۵۰ هکتوپاسکال به عنوان ورودی (متغیر مستقل) به مدل شبکه عصبی مصنوعی وارد شدند. برای پیش‌بینی بارش نیز همان‌طور که در بخش پیش‌بینی دما (۴-۱-۱)، ذکر شد، به منظور ساخت شبکه بهینه عصبی و انتخاب الگوریتم

جدول ۵- مشخصات مدل شبکه عصبی مصنوعی ساخته شده برای داده‌های بارش ماهانه ایستگاه سینوپتیک سیرجان


Table 5. Characteristics of created artificial neural network model for monthly precipitation data of synoptic station of Sirjan

| نوع شبکه عصبی | تعداد نرون | تابع محرک لایه‌های پنهان اول و دوم | تابع محرک لایه خروجی | الگوریتم آموزشی |
|--------------------------|------------|------------------------------------|----------------------|-----------------|
| پرسپترون پیش‌خور سه‌لایه | ۶-۸ | تانژانت و لوگ سیگموئید | خطی | لونیبرگ-مارکوات |

جدول ۶- معیارهای عملکرد مدل برای پیش‌بینی مقادیر بارش ایستگاه سینوپتیک سیرجان

Table 6. Performance statistical criteria for ANN model in forecasting precipitation of synoptic station of Sirjan


| R ² | | | NS | | | RMSE | | |
|----------------|-------|-------|-------|-------|-------|-------|------|-------|
| آموزش | تست | پایه | آموزش | تست | پایه | آموزش | تست | پایه |
| ۰/۹۲۴ | ۰/۷۸۳ | ۰/۸۲۷ | ۰/۸۴۹ | ۰/۷۸۵ | ۰/۸۱۴ | ۲/۸۶۷ | ۴/۳۸ | ۳/۴۵۲ |



شکل ۴- مقایسه بارش مشاهداتی و شبیه‌سازی شده توسط مناسب‌ترین مدل شبکه عصبی مصنوعی، در دو دوره آموزش (الف) و آزمون (ب)
Figure 4- Comparison of mean observed and simulated precipitation data with the most appropriate ANN model of two train (A) and test (B) periods

نتایج این تحقیق، عملکرد پایین تر مدل را نشان دادند که البته این تفاوت می‌تواند به دلیل این باشد که تحقیق ایشان در مورد بارش روزانه بوده و مقادیر خطا در مقیاس‌های زمانی کوتاه‌تر بیشتر می‌گردد. نتایج حاصل از پیش‌بینی مدل شبکه عصبی مصنوعی با استفاده از سناریوی RCP 4.5، در شکل ۵ ارائه شد.

با توجه به نمودارهای مربوط به شکل ۴، میانگین بارش پیش‌بینی شده با استفاده از مدل شبکه عصبی مصنوعی، تطابق خوبی با داده‌های مشاهده شده داشتند و عملکرد رضایت‌بخش مدل را در پیش‌بینی بارش، نشان می‌دهد. این نتایج با یافته‌های فلاح قاهره‌ی و شاکری (۷) که به دقت قابل قبول این مدل‌ها در شبیه‌سازی بارش اشاره کرده بودند مطابقت کامل داشته است. برخی مطالعات (۱۹) در مقایسه با



شکل ۵- مقایسه بارندگی ماهانه دوره حال (۱۹۸۰-۲۰۱۲) و آینده
Figure 5. Comparison of monthly precipitation in the present (1980-2012) and future periods

با این وجود در مقیاس ماهانه و درون سالی تغییرات قابل توجه است. به‌طوریکه در برخی ماه‌ها مانند ژوئیه تا نوامبر، افزایش شدید و در برخی ماه‌ها مانند مارس و می، کاهش شدید بارندگی را نسبت به زمان حال شاهد هستیم. ارزیابی پارامترهای هیدرو- اقلیمی در مقیاس درون‌سالی

در نهایت میانگین بارش تا سال ۲۰۹۹، توسط مدل شبکه عصبی، شبیه‌سازی گردید (شکل ۵). بر طبق داده‌های مشاهده شده و داده‌های به‌دست آمده از سناریوی RCP 4.5، میزان بارندگی سالانه در دوره‌های (۲۰۴۰-۲۰۶۹) و (۲۰۹۹-۲۰۷۰) تغییری نسبت به زمان حال (۱۹۸۰-۲۰۱۲) نداشت.

به‌عنوان ورودی مدل ارائه شد و شبیه‌سازی دما و بارش در دوره‌های آتی صورت گرفت. نتایج مربوط به مدل‌سازی شبکه عصبی مصنوعی نشان داد که مدل‌های نهایی ارائه شده برای بارش و دما دارای کارایی بالایی در شبیه‌سازی این دو متغیر طی دوره‌های مختلف پیش‌بینی می‌باشند. سایر نتایج این تحقیق نشان داد تحت سناریوی RCP 4.5 بارش با روش ریزمقیاس‌نمایی آماری شبکه عصبی مصنوعی میانگین دما در هر دو دوره روند افزایشی مشاهده گردید. اگرچه پیش‌بینی شد که بارش سیرجان در دوره (۲۰۷۰-۲۰۹۹) نسبت به زمان حال تغییری نشان نداده است، اما بطور کلی بارش‌های فصل زمستان و اوایل بهار، کاهش و بارش‌های تابستانه افزایش خواهد یافت. همچنین میانگین دما در دوره ذکرشده، ۳ درجه سانتیگراد، نسبت به دوره پایه افزایش می‌یابد که همزمانی این دو فرآیند با یکدیگر کاهش بارش‌های به صورت برف و افزایش بارش‌های سیل‌آسا و سهمگین را به‌دنبال خواهد داشت که می‌تواند باعث کاهش ذخیره و تأمین منابع آبی زمستانه و همچنین افزایش خسارات ناشی از وقوع بارش‌های سیل‌آسا گردد. افزایش دما نیز کاهش دوره رشد محصولات زراعی را به‌دنبال خواهد داشت، بنابراین لازم است مسئولین و برنامه‌ریزان، راهکارهای لازم برای کاهش پیامدها و سازگاری با شرایط آب و هوایی جدید را اتخاذ نمایند.

(Inta-Annual)، دید بهتر و دقیق‌تری را از چگونگی تغییرات نشان می‌دهد و بررسی این پارامترها تنها در مقیاس برون‌سالی (Inter-Annual) درک کاملی را از تغییرات بازگو نمی‌کند (۱۳، ۲۱، ۲۹، ۲۷). در این مطالعه نیز مشاهده شد که علیرغم عدم تغییر مقادیر بارندگی در مقیاس سالانه، این پارامتر در مقیاس ماهانه و درون‌سالی تغییرات قابل توجی را دارد و این مسئله با در نظر گرفتن ماه‌ها و فصول مرطوب یا خشک، اهمیت بالایی در مدیریت منابع آب منطقه خواهد داشت.

به‌دلیل افزایش انتشار گازهای گلخانه‌ای انتظار می‌رود که پدیده تغییر اقلیم در دوره‌های آتی رخ دهد. با توجه به کاربرد روزافزون شبکه عصبی مصنوعی در منابع آب و هیدرولوژی، در این پژوهش، به‌منظور پیش‌بینی و تحمین اثرات تغییر اقلیم بر روی میزان میانگین دما و بارش ایستگاه سیتوپتیک سیرجان، از شبکه عصبی مصنوعی استفاده شد. به‌منظور تهیه سناریوهای اقلیمی در آینده از خروجی‌های مدل گردش عمومی CanESM2 تحت سناریوی انتشار RCP 4.5 و روش ریزمقیاس‌نمایی و بکارگیری مدل شبکه عصبی مصنوعی استفاده گردید. با استفاده از مدل پرسپترون پیش‌خور چندلایه (MLP) با الگوریتم پس‌انتشار خطا (BP) و با در نظر گرفتن برخی از پارامترهای مؤثر در پیش‌بینی،

منابع

1. Arora, V.K., J.F. Scinocca, G.J. Boer, J.R. Christian, K.L. Denman and G.M. Flato. 2011. Carbon emission limits required to satisfy future representative concentration pathways of greenhouse gases. *Geophysical Research Letters*, 38(5): 1-6.
2. Banihabib, M.E., K. Hasani and A.R. Massah Bavani. 2016. Assessment of Climate Change Effects on Shahcheraghi Reservoir Inflow. *Journal of water and soil*, 30(1): 1-14.
3. Campozano, L., D. Tenelanda, E. Sanchez, E. Samaniego and J. Feyen. 2016. Comparison of Statistical Downscaling Methods for Monthly Total Precipitation: Case Study for the Paute River Basin in Southern Ecuador. *Advances in Meteorology*, 13 pp.
4. Chun, K.P., H.S. Wheeler, A. Nazemi and M.N. Khaliq. 2013. Precipitation downscaling in Canadian Prairie Provinces using the LARS-WG and GLM approaches. *Canadian Water Resources Journal*, 38(4): 311-332.
5. Da Silva, I.N., D.H. Spatti, R.A. Flauzino, L. Liboni and S.F. Reis Alves. 2017. *Artificial Neural Networks A Practical Course*. Springer International Publishing Switzerland, 309pp.
6. De Beule, M., E. Maes, O. De Winter, W. Vanlaere and R. Van Impe. 2007. Artificial neural networks and risk stratification: A promising combination. *Mathematical and Computer Modelling*, 46: 88-94.
7. Falahghalohri, GH. and F. Shakeri. 2016. The application of Artificial Neural Networks in the rainfall prediction. *Iranian Journal of Watershed Management Science and Engineering*, 9(31): 98-110.
8. Jalali, M., A. Pirnia, K. Solaimani and M. Habibnejad Roushan. 2015. Investigation of Artificial Neural Network in prediction of Stream Flow (Case study: Ghareh Aghaj, Fars province). *Journal of Engineering Biaban Ecosystem*, 4(6): 15-26.
9. Kan, G.C.H., Q. Li. Yao. Z. Li., Z. Yu, Z. Liu, L. Ding, X. He. and K. Liang. 2015. Improving event-based rainfall-runoff simulation using an ensemble artificial neural network based hybrid data-driven model. *Stochastic Environmental Research and Risk Assessment*, 29(5): 1345-1370.
10. Kermani, B.G., S.S. Schiffman and H. Troy Nagle. 2005. Performance of the Levenberg-Marquardt neural network training method in electronic nose applications. *Sensors and Actuators*, 110: 13-22.
11. Khamchin Moghaddam, F. and H. Rezaee Pajand. 2009. Criticising de martonne regionalization method according to linear moments for maximum daily precipitation in Iran. *Journal of Technical Engineering*, 2(2): 93-103.
12. Kumar Mann, A., D.A. Jayadevi and A. Pappachen James. 2016. A Survey of Memristive Threshold Logic Circuits. *Ieee Transactions On Neural Networks And Learning Systems*, 13 pp.
13. Ling, H., H. Xu and J. Fu. 2014. Changes in intra-annual runoff and its response to climate change and human activities in the headstream areas of the Tarim River Basin; China. *Quatern. Int.* 336: 158-170.
14. Mahdi zadeh, S., M. Meftah halghi, S. Seyyed Ghasemi and A. Mosaedi. 2011. Study of precipitation variation due to climate change (Case study: Golestan dam basin). *Journal of water and soil conservation*, 18(3): 117-132.

15. Maier, 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. *Environmental Modeling and Software*, 15: 101-124.
16. Meehl, G., C. Covey, T. Delworth, M. Latif, B. McAvaney, J. Mitchell, R. Stouffer and K. Taylor. 2007. The WCRP CMIP3 Multi-Model Dataset: a New Era in Climate Change Research. *Bulletin of the American Meteorological Society*, 88: 1383-1394.
17. Meena, P.K., D. Khare and M.K. Nema. 2016. Constructing the downscale precipitation using ANN model over the Kshipra river basin, Madhya Pradesh. *Journal of Agrometeorology*, 18(1): 113-119.
18. Muhire, I. and F. Ahmed. 2016. Spatiotemporal trends in mean temperatures and aridity index over Rwanda. *Theoretical and Applied Climatology*, 123(1-2): 399-414
19. Nastos, P.T., A.G. Paliatsos, K.V. Koukouletsos, I.K. Larissi and K.P. Moustiris. 2014. Artificial neural networks modeling for forecasting the maximum daily total precipitation at Athens, Greece. *Atmospheric Research*, 144: 141-150.
20. Nazari Sharbian, M., M. Taherioun and A. Ahmadi. 2016. Prediction of climate change effects on nutrient of watershed (Case study: Mahabad dam basin). The ninth conference of civil engineering, 10 and 11 May 2016, Ferdowsi Mashhad university.
21. Pirnia, A., K. Solaimani, M. Habibnejad Roshan and A. Besalatpour. 2017. Investigation of land use and climate change impacts on green and blue water resources in the Haraz River Basin of northern Iran, PhD thesis, Agriculture Sciences and Natural Resources of Sari.
22. Plattner, G.K. and T.F. Stocker. 2010. From AR4 to AR5: New Scenarios in the IPCC Process. Workshop Report, 2010.
23. Poitras, V., L. Sushama, F. Seglenieks, M.N. Khaliq and E. Soulis. 2011. Projected Changes to Streamflow Characteristics over Western Canada as Simulated by the Canadian RCM. *Journal of Hydrometeorology*, 12(6): 1395-1413.
24. Santos, T.S., J.R. Chicholikar and L.S. Rathore. 2013. Artificial neural networks and multiple linear regression model using principal components to estimate rainfall over South America, *Current science*, pp: 2083-2094.
25. Sattari, M.T. and F. Nahrain. 2014. Monthly rainfall prediction using Artificial Neural Networks and M5 model tree (Case study: Stations of Ahar and Jolfa). *Irrigation & Water Engineering*, 4(14): 83-98.
26. Vu, M.T., T.H. Aribarg, S. Supratid and S. Raghavan. 2015. Statistical downscaling rainfall using artificial neural network: significantly wetter Bangkok. *Theor Appl Climatol*, pp: 1-15.
27. Wang, H., L. Chen and X. Yu. 2015. Distinguishing human and climate influences on stream flow changes in Luan River basin in China; *Catena*, 136: 182-188.
28. Yesilkanat, C.M., Y. Kobya, H. Tas, km and U. Çevik. 2017. Spatial interpolation and radiological mapping of ambient gamma dose rate by using artificial neural networks and fuzzy logic methods. *Journal of Environmental Radioactivity*, (175-176): 78-93.
29. Zhang, D., X.B. Liu, Q. Zhang, K. Liang and C. Liu. 2016. Investigation of factors affecting intra-annual variability of evapotranspiration and stream flow under different climate conditions; *Journal of Hydrology*, 543: 759-769.
30. Zhang, Y., Q. You, C. Chen and J. Ge. 2016. Impacts of climate change on stream flows under RCP scenarios: A case study in Xin River Basin, China. *Atmospheric Research*, 178: 521-534.
31. Zoqi, M.J. and M. Saeedi. 2010. Modeling Leachate Generation Using Artificial Neural Networks. *Journal of water and waste water*, 22(1): 76-84.

Performance Evaluation of Artificial Neural Network Models for Downscaling and Predicting of Climate Variables

Ebrahim Omidvar¹, Maryam Rezaei² and Abdollah Pirnia³

1- Assistance Profosser, Department of Natural Resources and Earth Sciences, University of Kashan.

(Corresponding author: ebrahimomidvar@kashanu.ac.ir)

2- Ph.D. Student in Watershed Management Engineering and Science, University Of Kashan

3- Ph.D. in Watershed Management Engineering and Science, Sari Agriculture and Natural Resource University

Received: 7 June,2017 Accepted: 13 Oct,2018

Abstract

Atmosphere–ocean coupled global climate models (GCMs) are the main source to simulate the climate of the earth climate. The computational grid of the GCMs is coarse and so, they are unable to provide reliable information for hydrological modelling. To eliminate such limitations, the downscaling methods are used. The present study is focused on simulating the impact of climate change on the behavior of precipitation and temperature of Sirjan synoptic station in Kerman Province. At first, the capability of artificial neural network to downscaling of climate variables that predicted by CanESM2 is tested. Then, using the most appropriate models, the mean monthly temperature and precipitation amounts forecast for future periods under RCP 4.5 scenario. Results of this study for monthly temperature downscaling indicated that the artificial neural network with 2 hidden layer, 8 neurons, with Tangent and Log sigmoid activation function was the best model, so that RMSE, NS and R^2 were 0.387 , 0.973 and 0.917 respectively. Also, for precipitation variable, the structure with 2 hidden layer feed forward perceptron, 8 neurons, Tangent and Log sigmoid activation function and Levenberg-Marquardt algorithm had better performance, so that RMSE, NS and R^2 were 2.867, 0.849 and 0.924, respectively. Results indicate that until 2099, amount of monthly mean temperature under RCP 4.5 emission scenario will be increased by 3 (°C) and the highest increase is predicted for August by 3.9 (°C) and a lower increase in April by 1.8 (°C). The results also showed considerable increase of precipitation for June to November and noticeable decrease for March and May months. However, no change occure in annaul scale (inter-annual).

Keywords: Artificial Neural Network, General Circulation Model, Fifth Assessment Report of IPCC, Precipitation, Temperature, Sirjan