



ارزیابی کارایی مدل شبکه عصبی مصنوعی برای ریزمقیاس نمایی 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 مسؤول: ebrahimomidvar@kashanu.ac.ir)

^۲- دانشجوی دکترای علوم و مهندسی آبخیزداری، دانشگاه کاشان

^۳- دانش آموخته دکترای علوم و مهندسی آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی ساری

تاریخ پذیرش: ۹۶/۳/۱۷

تاریخ پذیرش: ۹۷/۷/۲۱

چکیده

مدل‌های گردش عمومی به عنوان منبع اصلی شبیه‌سازی اقلیم، دارای شبکه محاسباتی با ابعاد بزرگ بوده و قادر به ارائه اطلاعات قابل اعتماد برای مدل سازی هیدرولوژیکی نمی‌باشند. برای پرداختن و رفع چنین محدودیت‌هایی از روش ریزمقیاس نمایی استفاده می‌شود. در پژوهش حاضر، شبیه‌سازی اثر تغییر اقلیم به منظور ریزمقیاس نمایی متغیرهای استان کرمان، مورد ارزیابی قرار گرفت. در ابتدا عملکرد مدل شبکه عصبی مصنوعی به منظور ریزمقیاس نمایی متغیرهای اقلیمی پیش‌بینی شده 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 تائزانت و لوگ سیگموئید و همچنین الگوریتم آموزش لونبرگ-مارکوات دارای بیشترین کارایی و مقادیر RMSE، NS و R^2 به ترتیب برابر با 0.973 , 0.987 و 0.917 بوده است. همچنین برای متغیر بارش نیز ساختاری با تعداد ۲ لایه، ۸ نرون، تابع محرک تائزانت و لوگ سیگموئید و الگوریتم آموزش لونبرگ-مارکوات عملکرد مناسب‌تری داشت و مقادیر RMSE، NS و R^2 به ترتیب برابر با 0.849 , 0.867 و 0.924 می‌باشد. سایر نتایج نشان داد که تا سال 2090 ، میانگین دما در سناریوی 4.5 درجه سانتی گراد افزایش خواهد یافت و بیشترین افزایش مربوط به مقدار $9/4$ و کمترین افزایش مربوط به سال آوریل به مقدار $1/8$ 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

(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 ($R^2=0.871$, $IA=0.871$ 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. ناستوس 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 SDSM, ANN و رگرسیون بردار پشتیبان حافظ مربعات (LS-SVM) برای ریزمقیاس نمودن 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 تغییرات اقلیمی بر میزان بارش را در ایستگاه

مقدمه

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 ریزمقیاس نمایی به طور گسترده‌ای در سراسر جهان به منظور 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^۱ (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 به کار می‌روند و در مسائل ریزمقیاس نمایی نیز از ارزش زیادی برخوردار می‌باشند. در پژوهش حاضر به منظور ریزمقیاس نمایی 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

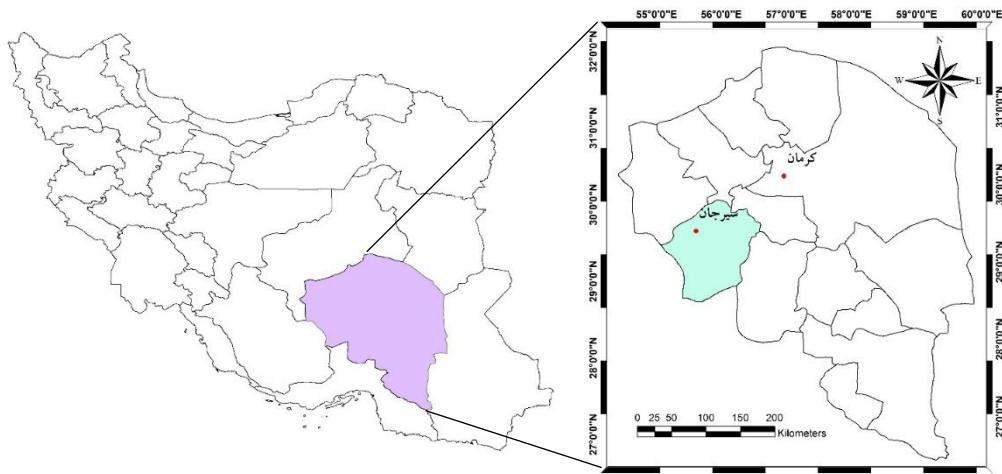
RCP 8.5 کاهش می‌یابد و نرخ تغییرات بر اساس سناریوی RCP 8.5 شدیدتر می‌باشد. پیرنیا و همکاران (۲۱) برای تولید داده‌ها دما و بارندگی در دوره‌های آتی بهمنظور مدل‌سازی رواناب، از مدل ریزمقیاس نمایی SDSM تحت سناریوهای RCP 4.5 و RCP 4.5 و RCP 8.5 استفاده کردند و دریافتند که دما و بارندگی در دوره‌های آتی بهترتیب افزایش و کاهش خواهد یافت. نظر به اهمیت و لزوم پیش‌بینی پارامترهای هواشناسی کشور در شرایط تغییراقلیم و مقایسه این پارامترها با شرایط حاضر، در این پژوهش سعی می‌شود داده‌های مدل SDSM تحت سناریوی RCP 4.5، جهت شبیه‌سازی میانگین بارش و دمای ماهانه دوره‌های آتی ایستگاه سینوپتیک سیرجان، با استفاده از مدل شبکه عصبی مصنوعی ریزمقیاس گردیده و عملکرد این مدل مورد ارزیابی قرار گیرد. با توجه به اینکه پیش‌بینی بلندمدت پارامترهای اقلیمی نیاز به آمار طولانی مدت و قابل اعتماد دارد، لذا ایستگاه سینوپتیک سیرجان بهدلیل دارا بودن آمار طولانی مدت به عنوان نماینده منطقه اقلیمی خشک، در پژوهش حاضر انتخاب گردید.

مواد و روش‌ها

منطقه مورد مطالعه

شهرستان سیرجان در جنوب‌شرقی ایران و در استان کرمان، در طول جغرافیایی $41^{\circ}55'$ و عرض جغرافیایی $28^{\circ}29'$ در ارتفاع $1739\frac{3}{4}$ متر از سطح دریا قرار گرفته است. این منطقه، نماینده منطقه اقلیمی خشک می‌باشد (۱۱). موقعیت جغرافیایی ایستگاه مذکور در شکل شماره ۱، ارائه شده است.

کریم‌ایشان و ریاط قربیل در حوضه سد گلستان مورد بررسی قرار داده و از مدل ریزمقیاس نمایی شبکه عصبی مصنوعی برای پیش‌بینی بارش استفاده کردند. نتایج ایشان نشان داد که تا سال ۲۱۰۰، میانگین بارش ماهانه در ایستگاه کریم‌ایشان در فصل پائیز و زمستان تا ۴۳ میلی‌متر افزایش و در بهار و تابستان تا ۲۳ میلی‌متر کاهش و در ایستگاه ریاط قربیل در فصل پائیز و زمستان تا ۳۲ میلی‌متر افزایش و در بهار و تابستان تا ۱۱ میلی‌متر کاهش خواهد یافت. همچنین ستاری و نهرین (۲۵)، با استفاده از مدل‌های هوشمند شبکه‌های عصبی مصنوعی، برنامه‌ریزی ژنتیک و مدل درختی M5، مقادیر حداکثر بارش روزانه را در ایستگاه‌های اهر و جلفا پیش‌بینی نمودند. در دو ایستگاه اهر و جلفا، هر سه روش مذکور ضمن رقابت با یکدیگر نتایج نسبتاً دقیقی را جهت پیش‌بینی حداکثر بارش روزانه در ماه موردنظر در منطقه ارائه می‌کنند ولی روش برنامه‌ریزی ژنتیک در دو ایستگاه مذکور بهترین نتایج را نشان داد. فالاح قاله‌بر و شاکری (۷)، کاربرد شبکه‌های عصبی مصنوعی را در پیش‌بینی بارش زمستانه استان خراسان رضوی مورد بررسی قرار دادند. آن‌ها پس از شناسایی سیگال‌های مؤثر بر بارش منطقه، مدل را در دوره ۱۹۷۰-۱۹۷۷ آموزش داده و در پایان، پیش‌بینی بارش را در دوره ۱۹۹۸-۲۰۰۷ انجام دادند. نتایج ایشان نشان داد شبکه‌های عصبی مصنوعی قادرند بارش را با دقت قابل قبولی پیش‌بینی نمایند. نظری شریان و همکاران (۲۰) به منظور پیش‌بینی داده‌های اقلیمی، از مدل ریزمقیاس نمایی CanESM2 و بر اساس خروجی‌های مدل اقلیمی RCP 8.5 و RCP 4.5، ایستگاه جدید ۲.۶ در شکل شماره ۱، ارائه تقدیری از تغییرات اقلیمی ایستگاه مذکور در شکل شماره ۱، ارائه استفاده کردند. نتایج آنها نشان داد که دما افزایش و بارندگی



شکل ۱- موقیت 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 و ۸.۵ می‌باشند. سناریوهای RCP نشان‌دهنده حرکت‌های تابشی هستند و در میان آنها سناریوی ۲.۶ RCP سناریوهای انتشار و حرکت‌های تابشی کم (تقریباً مشابه با سناریوهای B1 یا

ریزمقیاس نمایی داده‌های اقلیمی با شروع دهه ۲۰۱۰ و در پنجمین گزارش ارزیابی^۱ (AR5) هیئت بین‌الدولی تغییر اقلیم^۲ (IPCC^۳) سناریوهای CMIP5 جدید RCP^۴ را به جای سناریوهای SRES^۵ 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 CMIP5^۲ (CGCM4) است و جزء سری مدل‌های CMIP5^۳ گزارش پنجم هیئت بین‌الدول تعییر اقلیمی باشد (۱). مشخصات این مدل در جدول ۱ نشان داده شده است.

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

جدول ۱- مشخصات مدل (۱) CanESM2

Table 1. Characteristics of CanESM2 model (1)

نام مدل	طول × عرض (درجه)	قدر تغییر اقیانوسی (درجه)	گروه موسس	دوره شیوه‌سازی تاریخی / آینده	سناریوهای شیوه‌سازی	مرجع
CanESM2 (2010)	۲۸۱°×۲۸۱°	۱.۴۱°×۰.۹۴°	(CCCMA) کانادا	۲۰۰۵-۱۸۵۰/۲۱۰۰-۲۰۰۶	RCP 4.5, RCP 2.6 و RCP 8.5	(۱)

مثال‌هایی می‌باشد که به طور مکرر به شبکه ارائه می‌گردد (۶). شبکه عصبی مورد استفاده در پژوهش حاضر، شبکه پرسپترون پیشخور با الگوریتم پس انتشار خطای (MLP) است. شبکه عصبی پرسپترون چندلایه (MLP) شامل یک ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. گرهای 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 (سینگل) خود را رو به جلو می‌فرستند. الگوریتم آموزشی که در این نوع شبکه‌ها استفاده می‌شود، معمولاً الگوریتم پس انتشار می‌باشد (۱۵). الگوریتم پس انتشار خطای، از مطریح ترین الگوریتم‌های آموزش شبکه‌های MLP است که در آن داده خروجی با داده هدف مقایسه و میزان خطای 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 به صورت 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 ۰/۰ و ۰/۱ از رابطه (۱) استفاده شده است (۹).

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

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

معماری شبکه‌های عصبی

معماری مناسب به معنی انتخاب بهینه تعداد لایه‌ها، تعداد نرون‌ها در هر لایه و نوعتابع 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 و خروجی‌های مدل تحت سناریوی CanESM2 مورود ارزیابی قرار گرفت. جهت استفاده از مدل ریزمقیاس نمایی شبکه عصبی مصنوعی و استفاده از سناریوی RCP 4.5 برای ارزیابی عملکرد مدل ذکر شده، دوره آماری ۱۹۷۱–۲۰۰۰ در نظر گرفته شد. اما برای مقایسه داده‌های تولید شده در آینده با داده‌های زمان حال، دوره آماری ۱۹۸۰–۲۰۱۲، داده‌های NCEP، شامل به عنوان دوره پایه در نظر گرفته شد. داده‌های ۲۶ متغیر جوی است (۱۷) و در روش ریزمقیاس نمایی به عنوان متغیر مستقل مورد استفاده قرار می‌گیرند. روش‌های ریزمقیاس نمایی بین متغیرهای پیش‌بینی کننده 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 به کار 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 معنی دار 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 ۲۰۷۰–۲۰۹۹ پیش‌بینی شد.

مدل شبکه عصبی مصنوعی

در این تحقیق به منظور ریزمقیاس نمایی داده‌های تولید شده توسط مدل CanESM2 از مدل‌های شبکه عصبی پرسپترون چند لایه استفاده شد که در ذیل ساختار و نحوه مدل سازی 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 بر جسته شبکه‌های عصبی این است که تنظیمات شبکه براساس

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 خطای می‌باشد. در این تحقیق جهت ارزیابی عملکرد مدل از معیارهای مذکور میانگین مربعات خطای (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 بزرگ مقایس NCEP، ۵ پارامتر نهایی ژئوپتانسیل در ارتفاع فشاری ۵۰۰ هکتوپاسکال، میانگین دما در ارتفاع ۲ متری، رطوبت نسبی در ۵۰۰ هکتوپاسکال و رطوبت سلسلی در ۸۵۰ هکتوپاسکال که همبستگی بیشتری با دمای میانگین ماهانه سیرجان داشته‌ند، 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 لونبرگ-مارکوآت (LM) دارای بالاترین عملکرد و کمترین خطای در آموزش بود. جالی 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 لونبرگ-مارکوآت 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 نرون‌های لایه پنهان، خطای کاهش می‌یابد، در حالی که اگر تعداد نرون‌های لایه پنهان، پیش از ۱۰ عدد باشد، خطای افزایش و از دقت مدل شبکه عصبی کاسته می‌شود.

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 خطای 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 خطای استفاده شد که خود شامل چندین زیر گروه است. هر یک از این زیر گروه‌ها نیز روش‌های بهینه‌سازی متفاوتی مانند لونبرگ-مارکوآت، گرادیان نزولی و گوسی-نیوتون ... 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 ۱۹۷۱-۱۹۹۱) و ۳۰ درصد از داده‌ها برای آزمون (داده‌های دوره ۱۹۹۲-۲۰۰۰) در نظر گرفته شد. همان‌گونه که در بخش‌های قبل اشاره شد در مدل شبکه عصبی مصنوعی می‌توان با استفاده از روش سعی و خطای انتخاب نوع تابع محرک، الگوریتم آموزشی، تعداد لایه‌های پنهان و تعداد نرون‌های لایه‌های پنهان تجدیدنظر نمود. در صورت کارائی بهتر شبکه، آن شبکه به عنوان شبکه بهینه

جدول ۲- مقایسه کارایی بهترین ساختارهای بدست آمده شبکه عصبی مصنوعی در الگوریتم‌های مختلف پس انتشار

Table 2. Comparison of performance the best structures of artificial neural network in various backpropagation algorithm										الگوریتم‌های پس انتشار*
	R ²			NS			RMSE			الگوریتم‌های پس انتشار*
تست	دوره پایه	آموزش	دوره پایه	تست	آموزش	دوره پایه	تست	آموزش		
+/۹۷۸	+/۹۷	+/۹۶۱	+/۹۸	+/۹۶۸	+/۹۴۲	+/۳۱۸	+/۴۲۳	+/۳۴۸	LM	
-/۷۵۰	-/۷۴۲	-/۶۹۴	-/۱۵	-/۲۱	-/۰۲۵	۸/۲۹	۸/۶۸۵	۸/۵۲۵	GD	
-/۷۱	-/۶۵۰	-/۶۷۵	-/۰۵۹	-/۰۸۶	-/۱۴	۱۰/۳۵	۱۰/۴۸	۱۰/۲۲	GDM	
-/۸۵۹	-/۸۴۵	-/۸۲۷	-/۹۲۸	-/۹۳۲	-/۹۱۷	۱/۴۲۶	۱/۳۶۷	۱/۲۸۳	GDA	
-/۸۹۲	-/۸۸۴	-/۸۸۹	-/۹۳۱	-/۹۳۴	-/۹۳	-/۸۴	-/۸۹۶	-/۸۷۲	GDX	
-/۹۳۴	-/۹۳۷	-/۹۴۱	-/۹۵۶	-/۹۵	-/۹۴۵	-/۸۷۶	-/۸۴۹	-/۸۹	CGF	
-/۹۲۵	-/۹۱۸	-/۸۹۹	-/۹۲۵	-/۹۱۸	-/۹۱	-/۷۶۷	-/۷۸۲	-/۷۹۷	CGP	
-/۹۴۹	-/۹۳۶	-/۹۳۲	-/۹۵	-/۹۴۷	-/۹۲۸	-/۶۷۴	-/۶۴۵	-/۶۲۳	CGB	
-/۹	-/۸۹۶	-/۸۸۱	-/۹۲۴	-/۹۲۸	-/۹۲۳	-/۵۶	-/۵۹۳	-/۵۸۹	SCG	
-/۹۵۲	-/۹۶۴	-/۹۲۷	-/۹۴۸	-/۹۴۲	-/۹۵۲	-/۴۹۸	-/۵۲	-/۵۲۹	BFGS	
-/۹	-/۸۸۴	-/۸۷۹	-/۹۳۸	-/۹۳۱	-/۹۴۳	-/۶۳	-/۶۷۵	-/۷۵۳	OSS	
-/۹۴	-/۹۳۷	-/۹۲۹	-/۹۶۹	-/۹۶۳	-/۹۵۱	-/۵۲۶	-/۵	-/۵۱۲	RP	

*: LM: لونبرگ-مارکوات، GD: گرادیان نزولی، GDM: گرادیان نزولی با مومتووم، GDX: گرادیان نزولی با Ir تطبیقی، GDA: گرادیان نزولی با مومتووم، Ir تطبیقی، CGF: گرادیان نزولی با مومتووم، Ir تطبیقی، CGP: گرادیان نزولی با مومتووم، Ir تطبیقی، CGB: گرادیان مزدوج پولاک - ریبر، SCG: گرادیان مزدوج پاول - بیل، BFGS: گوئی نیوتون، OSS: یک گام مقاطعه، RP: ارجاعی

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

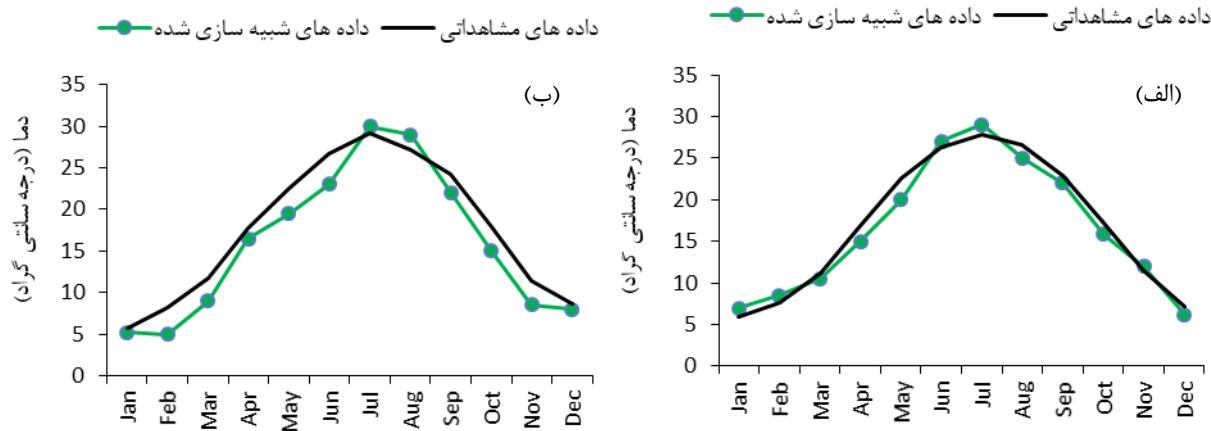
مدل	تعداد پنهان	تعداد لایه اول	تعداد نرون لایه اول	تعداد نرون لایه دوم	RMSE			NS			R ²		
					پایه	تست	آموزش	پایه	تست	آموزش	پایه	تست	آموزش
۱	۲	--	۲	۱	-/۸۹۲	+/۸۸۹	+/۸۹	-/۹۴۹	+/۹۵۱	+/۹۵۴	-/۶۵۹	-/۷	+/۵۹۷
۲	۴	--	۴	۱	-/۸۹	+/۸۸۷	+/۸۸۱	-/۹۵۷	+/۹۵۱	+/۹۵۷	-/۷۲۴	-/۷۲۴	+/۶۴۱
۳	۶	--	۶	۱	-/۸۹۷	+/۸۹۵	+/۸۹۳	-/۹۳۹	+/۹۳۸	+/۹۴۷	-/۶۲۷	-/۷۱۲	+/۵۷۶
۴	۸	--	۸	۱	-/۸۹۶	+/۸۸۴	+/۸۸۸	-/۹۵۶	+/۹۵۴	+/۹۵۹	-/۵۱۲	-/۵۳۹	+/۵۲۷
۵	۱۰	--	۱۰	۱	-/۹۰۹	-/۹۱۱	-/۹۱	-/۹۵۷	-/۹۷	-/۹۶۶	-/۴۵۳	-/۴۷۹	-/۴۸۲
۶	۱۲	--	۱۲	۱	-/۹۱۳	-/۹۰۶	-/۸۸۸	-/۹۷۱	-/۹۶۹	-/۹۶۵	-/۴۳۸	-/۴۳	-/۴۵۰
۷	۱۴	--	۱۴	۱	-/۹۰۵	-/۹۱	-/۹۰۷	-/۹۵۴	-/۹۶۴	-/۹۶	-/۴۴۸	-/۴۵۰	-/۴۷۲
۸	۱۶	--	۱۶	۱	-/۸۸۳	-/۸۷۸	-/۸۷	-/۹۵۸	-/۹۵۱	-/۹۳۹	-/۵۲۵	-/۵۵۹	-/۵۷۹
۹	۱۸	--	۱۸	۱	-/۸۹۴	-/۸۸۲	-/۸۸۹	-/۹۵۵	-/۹۴۹	-/۹۴۹	-/۵۳	-/۵۱۹	-/۵۲۹
۱۰	۲	۲	۲	۱۰	-/۹۰۷	-/۸۹۴	-/۸۹۸	-/۹۵۷	-/۹۶۸	-/۹۵۴	-/۵۴۶	-/۵۴۹	-/۵۸۲
۱۱	۴	۴	۴	۲	-/۹۱۴	-/۹	-/۹۰۶	-/۹۵۲	-/۹۵۷	-/۹۵۹	-/۴۸۷	-/۵۱۳	-/۵۲۶
۱۲	۶	۶	۶	۲	-/۹۰۵	-/۹۱۲	-/۹	-/۹۷۳	-/۹۷۲	-/۹۶۴	-/۶۲۴	-/۶۲۸	-/۶۱۲
۱۳	۶	۶	۶	۲	-/۹۰۸	-/۸۹۷	-/۸۹۳	-/۹۵۴	-/۹۷۶	-/۹۶۵	-/۶۶۷	-/۶۳۹	-/۶۷۳
۱۴	۸	۸	۸	۶	-/۸۹۶	-/۹۱۷	-/۹۰۲	-/۹۵۴	-/۹۵۱	-/۹۵۱	-/۵۴۲	-/۵۶۹	-/۵۷۶
۱۵	۸	۸	۸	۲	-/۸۹۴	-/۸۸۸	-/۸۸۱	-/۹۷۴	-/۹۶۷	-/۹۵۷	-/۵۷۲	-/۵۴۷	-/۵۵۶
۱۶	۴	۴	۴	۲	-/۹۱۱	-/۸۹۸	-/۹۱	-/۹۵۹	-/۹۷۵	-/۹۶۲	-/۴۹۲	-/۴۸۴	-/۴۹۵
۱۷	۶	۶	۶	۲	-/۸۹۶	-/۸۸۹	-/۸۹۲	-/۹۵۹	-/۹۷۱	-/۹۶۶	-/۵۱۴	-/۵۷۶	-/۴۵۷
۱۸	۸	۸	۸	۲	+/۹۱۷	+/۹۱	+/۹	+/۹۷۳	+/۹۷۴	+/۹۶۴	+/۳۸۷	+/۶۵۷	+/۴۱۷
۱۹	۶	۶	۶	۲	-/۸۹۴	-/۸۹۱	-/۸۸۵	-/۹۶۴	-/۹۷۵	-/۹۶۱	-/۵۲۴	-/۹۸۴	-/۴۹۲
۲۰	۱۰	۱۰	۱۰	۲	-/۹	-/۸۸۵	-/۹۱	-/۹۶۳	-/۹۵۲	-/۹۴۱	-/۵۷۹	-/۵۵۴	-/۵۳۷
۲۱	۱۲	۱۲	۱۲	۲	-/۹۱۱	-/۸۹۷	-/۹	-/۹۶۸	-/۹۷	-/۹۶۲	-/۵۲۱	-/۴۵۳	-/۴۸۲
۲۲	۱۴	۱۴	۱۴	۲	-/۸۹۷	-/۹	-/۸۹۲	-/۹۵۶	-/۹۷۵	-/۹۶۸	-/۴۸۱	-/۴۴۵	-/۴۳۸

(۰/۹۱۷) R² و همچنین کمترین مقدار RMSE 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.

در نهایت همان‌گونه که در بخش روش پژوهش ذکر شد، پس از انجام مراحل آزمون و خطا مدل مناسب شبکه عصبی مصنوعی پرسپترون پیش‌خور چندلایه با تعداد نرون، لایه پنهان، توابع محرك 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)

جدول ۴- مشخصات مدل شبکه عصبی مصنوعی ساخته شده برای داده‌های ماهانه ایستگاه سینوپتیک سیرجان

نوع شبکه عصبی	تعداد نمون	تابع محرك لایه‌های پنهان اول و دوم	الگوریتم آموزشی
تازانگ و لوگ سیگموئید	۸-۸	خطی	لوبنرگ-مارکوات



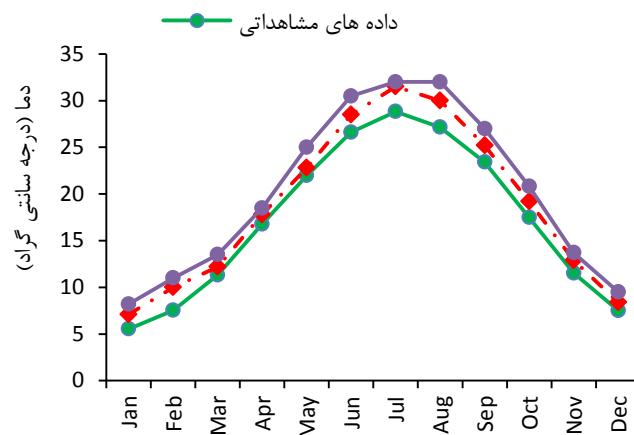
شکل ۲- مقایسه دمای میانگین ماهانه مشاهداتی و شبیه‌سازی شده توسط مناسب‌ترین مدل شبکه عصبی مصنوعی، در دو دوره آموزش (الف) و آزمون (ب)

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

تفصیرات 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 درجه‌سانتی گراد و در ماه آوریل کمترین افزایش حدود ۱/۸ درجه سانتی گراد 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 سانتی گراد نسبت به دوره پایه افزایش یافته است. بسیاری از مطالعات نیز نشان دادند که در دوره های آینده دور و تا سال ۲۱۰۰، افزایش دما بازتر از دوره های آتی نزدیک تر میباشد. همچنین نشان دادند که افزایش دما بر اساس سناریوی RCP ۴.۵، شرایط متوسطی را نسبت به دو سناریوی RCP 2.6 و RCP 8.5 دارد (۲۰۲۱،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، بیان گر کارائی 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 بیان گر 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

پس انتشار بهینه، سیزده الگوریتم پس انتشار با یکدیگر مقایسه شد و همچنین توابع محرك و لایه‌های پنهان مختلف مورد بررسی قرار گرفت. به منظور خلاصه‌سازی در ارائه مطالعه 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

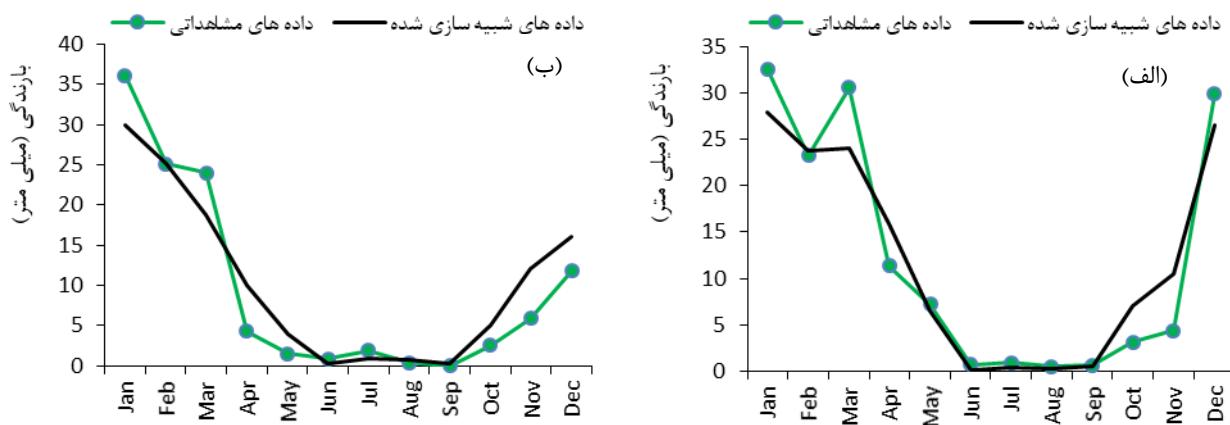
پس از بررسی میزان همبستگی بین متغیر بارش و پارامترهای NCEP، پارامترهای میانگین دما در ارتفاع ۲۰۰ متری، رطوبت نسبی در ۵۰۰ هکتوپاسکال و رطوبت نسبی در ۸۵۰ هکتوپاسکال به عنوان ورودی (متغیر مستقل) به مدل شبکه عصبی مصنوعی وارد شدند. برای پیش‌بینی بارش نیز همان طور که در بخش پیش‌بینی دما (۱-۴)، ذکر شد، به منظور ساخت شبکه بهینه عصبی و انتخاب الگوریتم

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

نوع شبکه عصبی	تعداد نرون	تابع محرك لایه پنهان اول و دوم	تابع محرك لایه خروجي	تایپ	آموزشی
پرسپترون پیش خور سه لایه	۸-۶	تائزانت و لوگ سیگموئید	خطی	لونبرگ- مارکوات	الگوریتم آموزشی

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

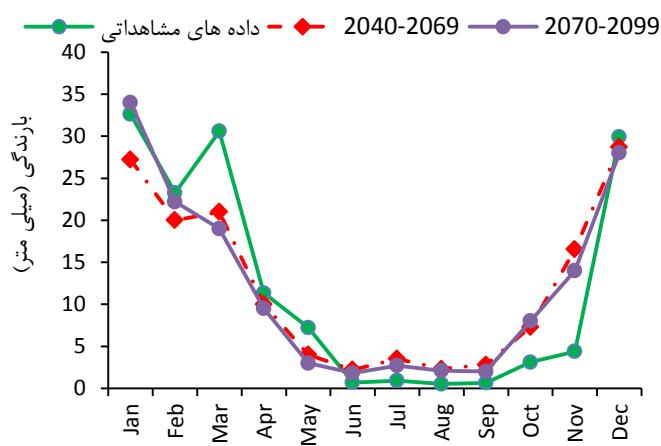
R ²			NS			RMSE		
پایه	تست	آموزش	پایه	تست	آموزش	پایه	تست	آموزش
۰/۹۲۴	۰/۷۸۳	۰/۸۲۷	۰/۸۴۹	۰/۷۸۵	۰/۸۱۴	۲/۸۶۷	۴/۳۸	۳/۴۵۲



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 پایین‌تر 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 فلاخ قالهری 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. به طوریکه 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 درون سالی

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

به عنوان ورودی مدل ارائه شد و شبیه‌سازی دما و بارش در دوره‌های آتی صورت گرفت. نتایج مربوط به مدل سازی 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 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 (۲۰۷۰-۰۹۹) 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 ذکر شده، 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 به دنبال 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 به دنبال 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 درون سالی تغییرات قابل توجهی را دارد و این مسئله با در نظر گرفتن ماهها و فصول مرتبط یا خشک، اهمیت بالایی در مدیریت منابع آب منطقه خواهد داشت.

به دلیل افزایش انتشار گازهای گلخانه‌ای انتظار می‌رود که پدیده تغییراقلیم در دوره‌های آتی رخ دهد. با توجه به کاربرد روزافزون شبکه عصبی مصنوعی در منابع آب و هیدرولوژی، در این پژوهش، به منظور پیش‌بینی و تحمین اثرات تغییراقلیم بروی میزان میانگین دما و بارش ایستگاه سیتوپتیک سیرجان، از شبکه عصبی مصنوعی استفاده شد. به منظور 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 پس انتشار خطأ (BP) و با درنظر گرفتن برخی از پارامترهای مؤثر در پیش‌بینی،

منابع

- 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.
- Banhabib, 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.
- 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.
- Chun, K.P., H.S. Wheater, A. Nazemi and M.N. Khalil. 2013. Precipitation downscaling in Canadian Prairie Provinces using the LARS-WG and GLM approaches. *Canadian Water Resources Journal*, 38(4): 311-332.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.

- ۸۹
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. Moustris. 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 Mashad 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. Khalil 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. Taskin 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. Saeeidi. 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 0.587, 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 ($^{\circ}$ C) and the highest increase is predicted for August by 3.9 ($^{\circ}$ C) and a lower increase in April by 1.8 ($^{\circ}$ C). The results also showed considerable increase of precipitation for June to November and noticeable decrease for March and May months. However, no change occurs in annual scale (inter-annual).

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