دانشگاه علوم کشاورزی و منابع طبیعی ساری
پژوهشنامه مدیریت حوزه آبخیز

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 دکترای علوم و مهندسی آبخیزداری، دانشگاه کاشان
۳- دانش‌آموخته دکترای 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 ریزمقیاس نمایی 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 لونبرگ-مارکوات دارای بیشترین کارایی و مقادیر RMSE، NS و R^2 به ترتیب برابر با ۰/۳۸۷، ۰/۹۷۳ و ۰/۹۱۷ بوده است. همچنین برای متغیر بارش نیز ساختاری با تعداد ۲ لایه، ۸ نرون، تابع محرک تانژانت و لوگ سیگموئید و الگوریتم آموزشی لونبرگ-مارکوات عملکرد مناسب‌تری داشت و مقادیر RMSE، NS و R^2 به ترتیب برابر با ۲/۸۶۷، ۰/۸۴۹ 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 ٤/۹ 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

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 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[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 به‌کار می‌روند و در مسائل ریزمقیاس نمایی نیز از ارزش زیادی برخوردار می‌باشند. در پژوهش حاضر به‌منظور 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 (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 شبکهٔ 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 عمکرد نسبتاً رضایت‌بخشی (R^2=۰/۴۸۲، IA=۰/۸۷۱ و RMSE=۱۶/۴) 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 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 تغییراقلیم بر میزان بارش را در ایستگاه

1- Fourth-generation Coupled Global Climate Model

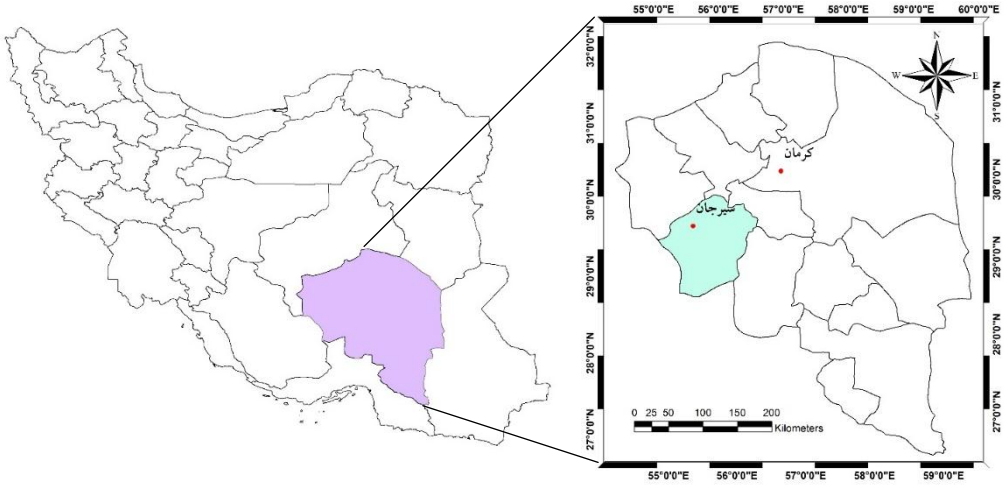
[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]

کریم‌ایشان و رباط 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 کریم ایشان در فصل پائیز و زمستان تا ۴۳ میلی‌متر افزایش و در بهار و تابستان تا ۲۳ میلی‌متر کاهش و در ایستگاه رباط 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. فلاح قالهری و شاکری (۷)، کاربرد شبکه‌های عصبی مصنوعی را در پیش‌بینی بارش زمستانه استان خراسان رضوی مورد بررسی قرار دادند. آن‌ها پس از شناسایی سیگنال‌های مؤثر بر بارش منطقه، مدل را در دوره ۱۹۹۷-۱۹۷۰ آموزش داده و در پایان، پیش‌بینی بارش را در دوره ۲۰۰۷-۱۹۹۸ انجام دادند. نتایج ایشان نشان داد شبکه‌های عصبی مصنوعی قادرند بارش را با دقت قابل قبولی پیش‌بینی نمایند. نظری‌شربیان و همکاران (۲۰) به منظور پیش‌بینی داده‌های اقلیمی، از مدل ریزمقیاس نمایی SDSM و بر اساس خروجی‌های 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 کاهش می یابد 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، 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 CanESM2 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. باتوجه 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 به‌عنوان 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 ′۴۱ °۵۵ و عرض جغرافیایی ′۲۸ °۲۹ و در ارتفاع ۱۷۳۹/۴ 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.



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

ریزمقیاس‌نمایی داده‌های اقلیمی

با شروع دهه ۲۰۱۰ و در پنجمین گزارش ارزیابی[1] (AR5) هیئت بین‌الدولی تغییر اقلیم[2] (IPCC)، CMIP5[3] سناریوهای جدید RCPs[4] را به جای سناریوهای SRES[5] پیشنهاد داد که سناریوهای پیشنهادی در چهار حالت ۲.۶، ۴.۵، ۶ و ۸.۵ می‌باشند. سناریوهای RCP نشان‌دهنده محرکه‌های تابشی هستند و در میان آنها سناریوی RCP 2.6 سناریوهای انتشار و محرکه‌های تابشی کم (تقریبا مشابه با سناریوهای B1 یا

1- Fifth Assessment Report
2- International Panel on Climate Change
3- Coupled Model Intercomparison Project 5
4- Representative Concentration Pathways
5- Special Report on Emissions Scenarios

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]

B2) و سناریوی RCP 8.5 محرکه‌های تابشی و سناریوهای انتشار زیاد (تقریبا 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 ۲۰۴۹-۲۰۲۰ انتخاب شدند.

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[1] استفاده شده است. مدل CanESM2 یک مدل جامع و جفت‌شده و چهارمین نسل از مدل‌های گردش عمومی جفت‌شده[2] (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.

جدول ۱- مشخصات مدل CanESM2 (۱)

Table 1. Characteristics of CanESM2 medel (1)

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)	۲.۸۱°×۲.۸۱°	۱.۴۱°×۰.۹۴°	(CCCMA)، کانادا	۲۰۰۶-۲۱۰۰/۱۸۵۰-۲۰۰۵	RCP 2.6، RCP 4.5 و RCP 8.5	(۱)

در این تحقیق از داده‌های روزانه بارندگی و دمای میانگین استفاده شده است. بدین منظور داده‌های NCEP و خروجی‌های مدل CanESM2 تحت سناریوی RCP 4.5 مورد ارزیابی قرار گرفت. جهت استفاده از مدل ریزمقیاس نمایی 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 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 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 ۲۰۶۹-۲۰۴۰ و ۲۰۹۹-۲۰۷۰) پیش‌بینی شد.

مدل شبکه عصبی مصنوعی

در این تحقیق به‌منظور ریزمقیاس نمایی 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 مثال‌هایی می‌باشد که به‌طور مکرر به شبکه ارائه می‌گردد (۶). شبکه عصبی مورد استفاده در پژوهش حاضر، شبکه پرسپترون پیشخور با الگوریتم پس انتشارخطا 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 پس‌انتشار می‌باشد (۱۵). الگوریتم پس‌انتشار 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).

$$N = 0.8 \times \left[\frac{X_i - X_{min}}{X_{max} - X_{min}}\right] + 0.1 \qquad \text{رابطه (۱)}$$

که در آن N، داده استاندارد شده، Xi، داده‌های مشاهده شده، Xmin، حداقل داده‌های مشاهده شده و Xmax، حداکثر داده‌های مشاهده شده می‌باشد.

معماری شبکه‌های عصبی

معماری مناسب به‌معنی انتخاب بهینهٔ تعداد لایه‌ها، تعداد نرون‌ها در هر لایه و نوع تابع حرکت هر نرون است، که معماری بهینه شبکهٔ عصبی مصنوعی مبتنی‌بر مجموعهٔ داده‌ها و ویژگی‌های آن‌ها است (۵).

1- Second generation Canadian Earth System model

2- Fourth-generation Coupled Global Climate Model

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]

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 لونبرگ-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 به‌گونه‌ای 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 به‌منظور 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 کارائی بهتر شبکه، آن شبکه به عنوان شبکه بهینه انتخاب می‌گردد، در غیر این صورت، همهٔ مراحل تکرار می‌گردد تا شبکه به جواب بهینه و مطلوب دست یابد.

معیارهای ارزیابی عملکرد مدل

منظور از ارزیابی مدل، به‌دست 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 نسلبی 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 لونبرگ-مارکوآت (LM) دارای بالاترین عملکرد و کمترین خطا در آموزش بود. جلالی و همکاران (۸) نیز کارایی بالاتر این الگوریتم را در مقایسه با سایر الگوریتم ها نشان دادند. پس از انتخاب مناسب‌ترین الگوریتم آموزش برای شبکه، به‌منظور 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 نرون در لایه پنهان، خطا کاهش می‌یابد، در حالی‌که اگر تعداد نرون‌های لایه پنهان، بیش از ۱۰ عدد باشد، خطا افزایش و از دقت مدل شبکه عصبی کاسته می‌شود.

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]

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	آموزش	تست	دوره پایه	آموزش	تست	دوره پایه
LM	**۰/۳۴۸**	**۰/۴۲۳**	**۰/۳۱۸**	**۰/۹۴۲**	**۰/۹۶۸**	**۰/۹۸**	**۰/۹۶۱**	**۰/۹۷۸**	**۰/۹۷**
GD	۸/۵۳۵	۸/۶۸۵	۸/۲۹	۰/۰۲۵	۰/۲۱	۰/۱۵	۰/۶۹۴	۰/۷۵۰	۰/۷۴۲
GDM	۱۰/۳۲	۱۰/۴۸	۱۰/۳۵	۰/۱۴	۰/۰۸۶	۰/۰۵۹	۰/۶۷۵	۰/۶۵۰	۰/۷۱
GDA	۱/۲۸۳	۱/۳۶۷	۱/۴۲۶	۰/۹۱۷	۰/۹۳۲	۰/۹۲۸	۰/۸۲۷	۰/۸۴۵	۰/۸۵۹
GDX	۰/۸۷۲	۰/۸۹۶	۰/۸۴	۰/۹۳	۰/۹۳۴	۰/۹۳۱	۰/۸۸۹	۰/۸۸۴	۰/۸۹۲
CGF	۰/۸۹	۰/۸۴۹	۰/۸۷۶	۰/۹۴۵	۰/۹۵	۰/۹۵۶	۰/۹۴۱	۰/۹۳۷	۰/۹۳۴
CGP	۰/۷۹۷	۰/۷۸۲	۰/۷۶۷	۰/۹۱	۰/۹۱۸	۰/۹۲۵	۰/۸۹۹	۰/۹۱۸	۰/۹۲۵
CGB	۰/۶۲۳	۰/۶۴۵	۰/۶۷۴	۰/۹۲۸	۰/۹۴۷	۰/۹۵	۰/۹۳۲	۰/۹۳۶	۰/۹۴۹
SCG	۰/۵۸۹	۰/۵۹۳	۰/۵۶	۰/۹۲۳	۰/۹۲۸	۰/۹۲۴	۰/۸۸۱	۰/۸۹۶	۰/۹
BFGS	۰/۵۲۹	۰/۵۲	۰/۴۹۸	۰/۹۵۲	۰/۹۴۲	۰/۹۴۸	۰/۹۲۷	۰/۹۶۴	۰/۹۵۲
OSS	۰/۷۵۳	۰/۶۷۵	۰/۶۳	۰/۹۴۳	۰/۹۳۱	۰/۹۳۸	۰/۸۷۹	۰/۸۸۴	۰/۹
RP	۰/۵۱۲	۰/۵	۰/۵۲۶	۰/۹۵۱	۰/۹۶۳	۰/۹۶۹	۰/۹۲۹	۰/۹۳۷	۰/۹۴

*: 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 فلچر – پاول، CGP: گرادیان مزدوج پولاک – ریبر، CGB: گرادیان مزدوج پاول – بیل، SCG: گرادیان مزدوج مدرج، BFGS: گوسی نیوتن، OSSS: یک گام متقاطع، RP: ارتجاعی

جدول ۳- نتایج الگوریتم لونبرگ–مارکوآت 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

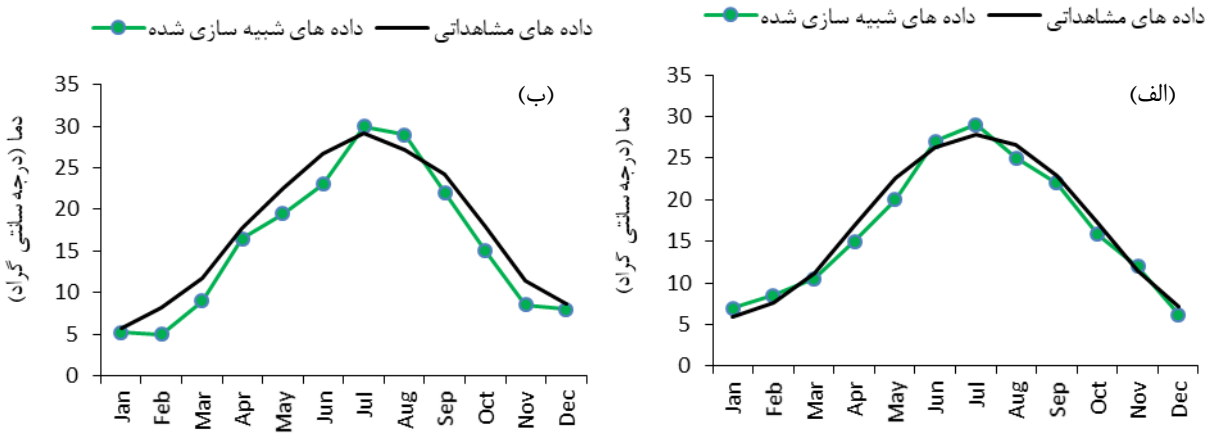
مدل	تعداد لایه پنهان	تعداد نرون لایه اول	تعداد نرون لایه دوم	RMSE			NS			R^2		
				آموزش	تست	پایه	آموزش	تست	پایه	آموزش	تست	پایه
۱	۱	۲	--	۰/۵۹۷	۰/۷	۰/۶۵۹	۰/۹۵۴	۰/۹۵۱	۰/۹۴۹	۰/۸۹	۰/۸۸۹	۰/۸۹۲
۲	۱	۴	--	۰/۶۴۱	۰/۷۲۴	۰/۶۲۷	۰/۹۵۱	۰/۹۴۹	۰/۹۵۷	۰/۸۸۱	۰/۸۸۷	۰/۸۹
۳	۱	۶	--	۰/۵۷۶	۰/۷۱۲	۰/۶۲۷	۰/۹۴۷	۰/۹۳۸	۰/۹۳۹	۰/۸۹۳	۰/۸۹۵	۰/۸۹۷
۴	۱	۸	--	۰/۵۲۷	۰/۵۳۹	۰/۵۱۲	۰/۹۵۹	۰/۹۶۴	۰/۹۵۶	۰/۸۸۸	۰/۸۸۴	۰/۸۹۶
۵	۱	۱۰	--	۰/۴۸۲	۰/۴۷۹	۰/۴۵۳	۰/۹۶۶	۰/۹۷	۰/۹۶۷	۰/۹۱	۰/۹۱۱	۰/۹۰۹
۶	۱	۱۲	--	۰/۴۵۰	۰/۴۳	۰/۴۳۸	۰/۹۶۵	۰/۹۶۹	۰/۹۷۱	۰/۸۹۸	۰/۹۰۶	۰/۹۱۳
۷	۱	۱۴	--	۰/۴۷۲	۰/۴۵۰	۰/۴۴۸	۰/۹۶	۰/۹۶۴	۰/۹۶۴	۰/۹۰۷	۰/۹۱	۰/۹۰۵
۸	۱	۱۶	--	۰/۵۷۹	۰/۵۵۹	۰/۵۳۵	۰/۹۳۹	۰/۹۵۱	۰/۹۵۸	۰/۸۶۷	۰/۸۷۸	۰/۸۸۳
۹	۱	۱۸	--	۰/۵۲۹	۰/۵۱۹	۰/۵۳	۰/۹۴۹	۰/۹۵۴	۰/۹۵۵	۰/۸۸۹	۰/۸۸۲	۰/۸۹۴
۱۰	۲	۲	۲	۰/۵۸۲	۰/۵۴۹	۰/۵۴۶	۰/۹۵۴	۰/۹۶۸	۰/۹۶۷	۰/۸۹۸	۰/۸۹۴	۰/۹۰۷
۱۱	۲	۴	۴	۰/۵۲۶	۰/۵۱۳	۰/۴۸۷	۰/۹۵۹	۰/۹۵۷	۰/۹۶۲	۰/۹۰۶	۰/۹	۰/۹۱۴
۱۲	۲	۴	۶	۰/۶۱۲	۰/۶۲۸	۰/۶۲۴	۰/۹۶۴	۰/۹۷۲	۰/۹۷۳	۰/۹	۰/۹۱۲	۰/۹۰۵
۱۳	۲	۶	۶	۰/۶۷۳	۰/۶۳۹	۰/۶۶۷	۰/۹۶۵	۰/۹۷۶	۰/۹۵۴	۰/۸۹۳	۰/۸۹۷	۰/۹۰۸
۱۴	۲	۶	۸	۰/۵۷۶	۰/۵۶۹	۰/۵۴۲	۰/۹۵۱	۰/۹۵۶	۰/۹۶۴	۰/۹۰۲	۰/۹۱۷	۰/۸۹۶
۱۵	۲	۸	۲	۰/۵۵۶	۰/۵۴۷	۰/۵۷۲	۰/۹۵۷	۰/۹۶۷	۰/۹۷۴	۰/۸۸۱	۰/۸۸۸	۰/۸۹۴
۱۶	۲	۸	۴	۰/۴۹۵	۰/۴۸۴	۰/۴۹۲	۰/۹۶۲	۰/۹۷۵	۰/۹۵۹	۰/۹۱	۰/۸۹۸	۰/۹۱۱
۱۷	۲	۸	۶	۰/۴۵۷	۰/۵۷۶	۰/۵۱۴	۰/۹۶۶	۰/۹۷۱	۰/۹۶۹	۰/۸۹۲	۰/۸۸۹	۰/۸۹۶
۱۸	**۲**	**۸**	**۸**	**۰/۴۱۷**	**۰/۶۵۷**	**۰/۳۸۷**	**۰/۹۶٤**	**۰/۹۷٤**	**۰/۹۷۳**	**۰/۹**	**۰/۹۱**	**۰/۹۱۷**
۱۹	۲	۱۰	۶	۰/۴۹۲	۰/۹۸۴	۰/۵۲۴	۰/۹۶۱	۰/۹۷۵	۰/۹۶۴	۰/۸۸۵	۰/۸۹۱	۰/۸۹۴
۲۰	۲	۱۰	۱۰	۰/۵۳۷	۰/۵۵۴	۰/۵۷۹	۰/۹۴۱	۰/۹۵۲	۰/۹۶۳	۰/۹۱	۰/۸۸۵	۰/۹
۲۱	۲	۱۲	۲	۰/۴۸۲	۰/۴۵۳	۰/۵۲۱	۰/۹۶۲	۰/۹۷	۰/۹۶۸	۰/۹	۰/۸۹۷	۰/۹۱۱
۲۲	۲	۱۴	۸	۰/۴۳۸	۰/۴۴۵	۰/۴۸۱	۰/۹۶۸	۰/۹۷۵	۰/۹۵۶	۰/۸۹۲	۰/۹	۰/۸۹۷

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 R^2 (۰/۹۱۷) و همچنین کمترین مقدار RMSE (۰/۳۸۷) برای دوره پایه به عنوان مناسب‌ترین مدل انتخاب شد. این یافته‌ها به‌خصوص در مورد معیارهای NS و R^2 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.

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]

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	لونبرگ-مارکوات

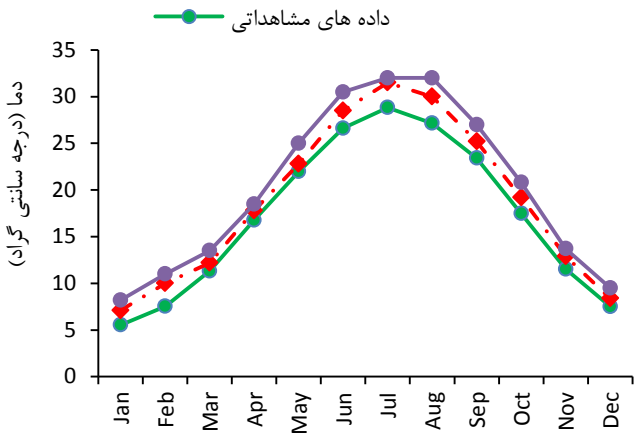


شکل ۲- مقایسه دمای میانگین ماهانه مشاهداتی و شبیه‌سازی شده توسط مناسب‌ترین مدل شبکه عصبی مصنوعی، در دو دوره آموزش (الف) و آزمون (ب)
Figure 2- Comparison of mean observed and simulated temperature data with the most appropriate ANN model of two train (A) and test (B) periods

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 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 (۲۰۱۲-۱۹۸۰) مورد مقایسه قرار گرفت (شکل ۳).

در ادامه، پارامتر دما برای دو دوره آتی (۲۰۶۹-۲۰۴۰) و (۲۰۹۹-۲۰۷۰)، 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 (۲۰۱۲-۱۹۸۰) نشان می‌دهد که بیان‌گر محدوده 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 (۲۰۹۹-۲۰۷۰) نسبت به دوره پایه وجود دارد و بیشترین افزایش دما مربوط به ماه اگوست به میزان ۴/۹ درجه‌سانتی‌گراد و در ماه آوریل کمترین افزایش حدود ۱/۸ درجه سانتی‌گراد مشاهده شد. در مقیاس سالانه میانگین دمای محاسبه شده در دوره‌های زمانی (۲۰۶۹-۲۰۴۰) و (۲۰۹۹-۲۰۷۰) 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 دوره های آینده دور و تا سال ۲۱۰۰، افزایش دما بارزتر از دوره های 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).

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]



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

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 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.

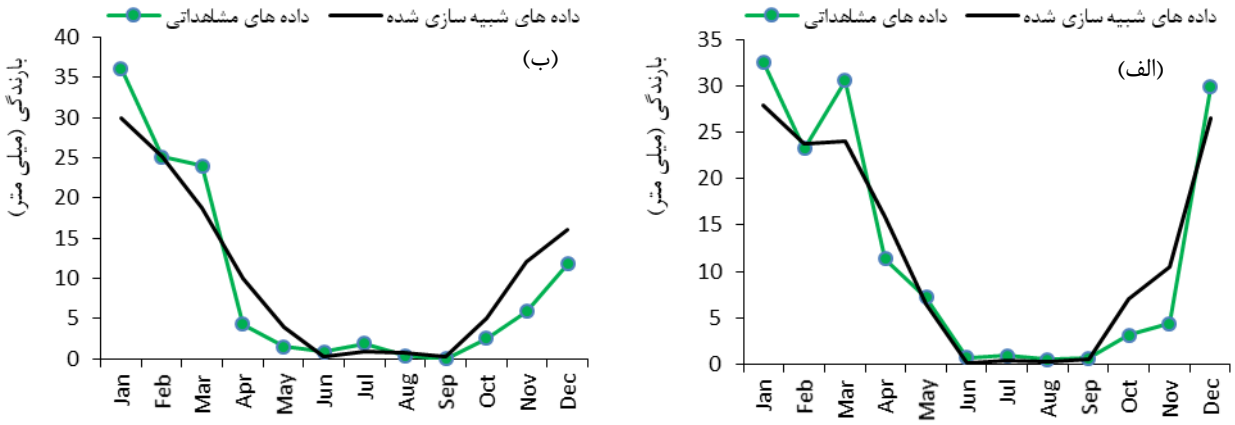
جدول ۵- مشخصات مدل شبکه عصبی مصنوعی ساخته شده برای داده‌های بارش ماهانه ایستگاه سینوپتیک سیرجان
Table 5. Characteristics of created artificial neural network model for monthly precipitation data of synoptic station of Sirjan

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	لونبرگ- 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

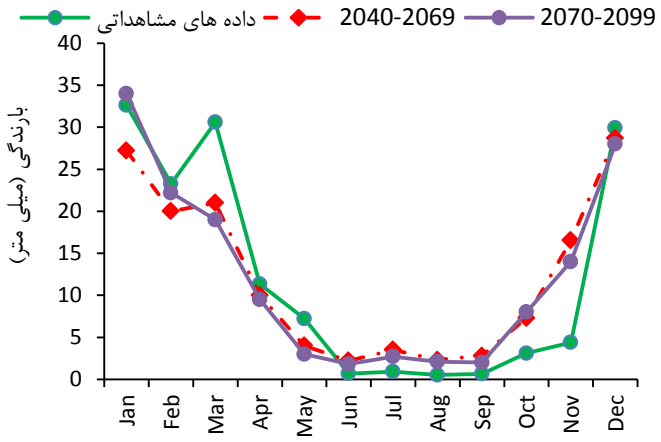
RMSE			NS			R^2		
آموزش	تست	پایه	آموزش	تست	پایه	آموزش	تست	پایه
۳/۴۵۲	۴/۳۸	۲/۸۶۷	۰/۸۱۴	۰/۷۸۵	۰/۸۴۹	۰/۸۲۷	۰/۷۸۳	۰/۹۲۴

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]



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

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 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 نتایج این تحقیق، عملکرد پایین تر مدل را نشان دادند که البته این تفاوت می‌تواند به‌دلیل 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.



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

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 (۲۰۶۹-۲۰۴۰) و (۲۰۹۹-۲۰۷۰) تغییری نسبت به زمان حال (۲۰۱۲-۱۹۸۰) نداشت. 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

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]

(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 تغییراقلیم 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 تغییراقلیم برروی 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 ریزمقیاس نمایی و بکارگیری مدل شبکه عصبی مصنوعی استفاده گردید. با استفاده از مدل پرسپترون پیش‌خور چندلایه (MLP) با الگوریتم پس‌انتشار خطا (BP) و با درنظرگرفتن برخی از پارامترهای مؤثر در پیش‌بینی، 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 با روش ریزمقیاس نمایی آماری شبکه عصبی مصنوعی میانگین دما در هر دو دوره روند افزایشی مشاهده گردید. اگرچه پیش‌بینی شد که بارش سیرجان در دوره (۲۰۹۹-۲۰۷۰) 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 درجه‌سانتیگراد، 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 بدنبال خواهد داشت، بنابراین لازم است مسئولین و برنامه‌ریزان، راهکارهای لازم برای کاهش پیامدها و سازگاری با شرایط آب وهوایی جدید را اتخاذ نمایند.

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. Wheater, 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.

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]

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 notrient of watershed (Case study: Mahabad dam basin). The ninth conference of civil engineering, 10 and 11 May 2016, Ferdouwsi 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. 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¸kın 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.

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]

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

Ebrahim Omidvar[1], Maryam Rezaei[2] and Abdollah Pirnia[3]

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

[Downloaded from jwmr.sanru.ac.ir on 2026-11-03]
[DOR: 20.1001.1.22516174.1397.9.18.5.9]
[DOI: 10.29252/jwmr.9.18.80]