

صص ۸۰-۶۷

پیش‌بینی بارش فصلی با حداقل متغیرهای اقلیمی مطالعه موردی: ایستگاه کرمان

فاطمه بیاتانی*

دانشجوی دکتری اقلیم‌شناسی، دانشگاه حکیم سبزواری، ایران

غلام‌عباس فلاح فاله‌ری

دانشیار اقلیم‌شناسی، دانشگاه حکیم سبزواری، سبزوار، ایران

الهام فهیمی‌نژاد

دانشجوی دکتری اقلیم‌شناسی، دانشگاه حکیم سبزواری، سبزوار، ایران

تاریخ دریافت: ۱۳۹۷/۴/۲۳ تاریخ پذیرش: ۱۳۹۸/۱/۱۸

چکیده

پیش‌بینی بارش و برآورد نزولات جوی، یکی از مهم‌ترین پارامترهای اقلیمی در حوزه مدیریت منابع آبی، از اهمیت ویژه‌ای برخوردار است؛ بنابراین در این مقاله، امکان کاربرد شبکه عصبی در برآورد بارش با حداقل پارامترهای اقلیمی مورد بررسی قرار گرفت. به این منظور از شبکه عصبی پرسپترون چند لایه با قانون پس انتشار خطا و الگوریتم سیگموئید همراه با داده‌های میانگین رطوبت نسبی (HR_{mean})، کمینه رطوبت نسبی (HR_{min})، بیشینه رطوبت نسبی (HR_{max})، میانگین دما (T_{mean})، کمینه دما (T_{min})، بیشینه دما (T_{max})، میانگین فشار (P_{mean})، کمینه فشار (P_{min}) و بیشینه فشار (P_{max}) ماه اکتبر ایستگاه هواشناسی سینوپتیک کرمان، طی دوره آماری ۱۹۶۹-۲۰۱۴ به‌عنوان ورودی مدل استفاده گردید. نتایج نشان داد در صورت کمبود پارامترهای اقلیمی، تنها با اندازه‌گیری T_{mean} و T_{min} می‌توان با خطایی معادل ۹/۸ میلی‌متر، برآورد مناسبی از بارش با استفاده از شبکه‌های عصبی مصنوعی در ایستگاه کرمان به دست آورد.

واژگان کلیدی: بارش، تابع فعالیت خطی، تابع فعالیت سیگموئید، شبکه عصبی مصنوعی، قانون آموزش پس انتشار خطا.

مقدمه

بارش یکی از عناصر مهم اقلیمی در تمام نقاط جهان از جمله مناطق خشک و نیمه‌خشک می‌باشد (ناصری ۱۳۸۲: ۲۲). در سال‌های اخیر شبکه‌های عصبی مصنوعی در زمینه‌های مختلف پژوهش‌های اقلیمی استفاده شده است (حلبیان و دارند ۱۳۹۱: ۵۴). در حدود پنجاه سال پیش پژوهشگران اولین مدل الکترونیکی از سلول‌های عصبی را طراحی و ایجاد

* Email: bayatanifateme@gmail.com

کردند (زاهدی، ۱۳۸۰: ۳). دستاوردهای اخیر در کاربرد ابزار هوش مصنوعی رویکردهای نو و متعددی را در مدل‌سازی گشوده است (صداقت کردار و فتاحی ۱۳۸۷: ۶۲). نتایج پژوهش (وانگ^۱ و همکاران، ۲۰۰۸: ۷۰۹) نشان داد که مدل توسعه یافته شبکه‌های عصبی مصنوعی برای پیش‌بینی زمان واقعی بارش در بانکوک تایلند مناسب است. روش‌های رگرسیون چند متغیره و شبکه‌های عصبی مصنوعی پس انتشار خطا برای پیش‌بینی بارش و دمای حوضه رودخانه مانتارو مقایسه شد (کارین، ۲۰۱۰: ۵۹). از شبکه‌های عصبی مصنوعی برای پیش‌بینی بارش اسکندریه مصر استفاده گردید. نتایج مطالعه آن‌ها نشان داد که مدل شبکه‌های عصبی مصنوعی مناسب و دقیق است (شفیعی^۲ و همکاران، ۲۰۱۱: ۱۳۱۱). از شبکه‌های عصبی مصنوعی و تجزیه و تحلیل رگرسیون چندگانه برای پیش‌بینی بارش فصلی بهار ویکتوریا در استرالیا با استفاده از داده‌های شاخص نوسان جنوبی و دوقطبی اقیانوس هند استفاده گردید و در نهایت مشاهده شد که مدل شبکه‌های عصبی مصنوعی در مقایسه با مدل رگرسیون چندگانه از خطای پایین‌تری برخوردار است و تجزیه و تحلیل‌های آماری نشان از پتانسیل بالای مدل شبکه‌های عصبی مصنوعی در پیش‌بینی بارش با استفاده از داده‌های شاخص‌های پیوند از دور در مقیاس بزرگ می‌باشند (مکانیک^۳ و همکاران، ۲۰۱۳: ۱۵)، (الهاشمی، ۲۰۱۴: ۲۰۷۵)، به بررسی کارایی سه مدل شبکه‌های عصبی مصنوعی (NNA)، مدل سری‌های زمانی (ARIMA) و مدل رگرسیون خطی چندگانه (RLM) در پیش‌بینی بارش ماهانه منطقه کرکوک در کشور عراق طی دوره زمانی ۲۰۰۸-۱۹۷۰ پرداخت. نتایج نشان داد که مدل شبکه‌های عصبی مصنوعی (NNA)، ابزار پیش‌بینی برای پیش‌بینی بارش ماهانه نسبت به دو مدل نامبرده از کارایی بالاتری برخوردار است. در مطالعه دیگر شبکه‌های عصبی مصنوعی به‌خوبی روند بارش ماهانه را در ایستگاه مشهد پیش‌بینی کردند (خلیلی، ۱۳۸۵: ۱۲). شبکه‌های عصبی- فازی بارش خراسان رضوی را در ۷۰ درصد سال‌ها با دقت قابل قبولی پیش‌بینی کردند (فلاح قاهری و همکاران، ۱۳۸۷: ۱۳۵). از مدل شبکه‌های عصبی برای تخمین عمق بارندگی روزانه ایستگاه‌های باران سنجی در فارس و بخشی از کهکیلویه و بویراحمد استفاده شد. نتایج نشان داد روش کریجینگ و شبکه‌های عصبی مناسب‌ترین روش برای این منظور است (پولادی، ۱۳۸۱: ۵۴). طی پژوهشی دقت شبکه‌های عصبی مصنوعی بازگشتی نارکس و پرسپترون در پیش‌بینی بارش روزانه در استان کرمان مورد ارزیابی قرار گرفت. نتایج نشان داد شبکه عصبی بازگشتی نارکس در مقایسه با شبکه عصبی پرسپترون از کارایی بالاتر جهت پیش‌بینی بارش روزانه برخوردار است (امیدوار و همکاران، ۱۳۹۴: ۷۵). با توجه به بی‌نظمی‌های بارش در مناطق خشک، در این مقاله با استفاده از مدل شبکه‌های عصبی مصنوعی و رگرسیون خطی چندگانه به پیش‌بینی بارش زمستانه ایستگاه کرمان پرداخته شد.

¹ - Wang

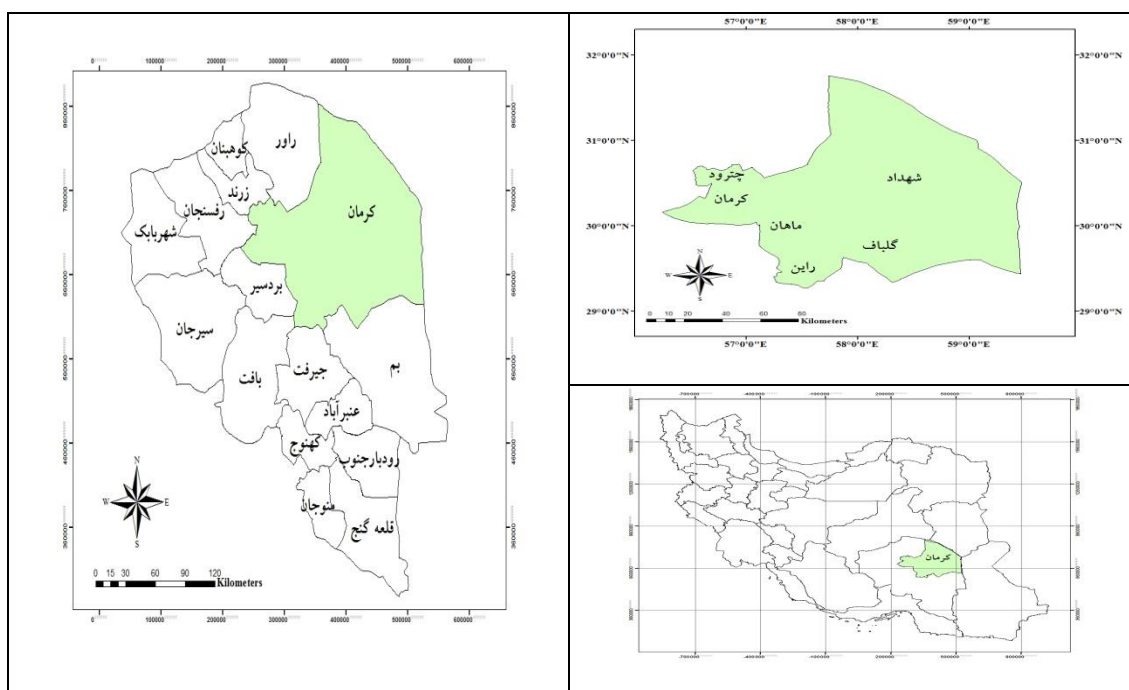
² - Shafie

³ - Mekanik

داده‌ها و روش‌ها

منطقه مورد مطالعه

داده‌های هواشناسی مورد نیاز برای انجام این پژوهش، از ایستگاه هواشناسی سینوپتیک کرمان، با مختصات جغرافیایی ۳۰ درجه و ۱۵ دقیقه عرض شمالی و ۵۶ درجه و ۵۸ دقیقه طول شرقی که در ارتفاع ۱۷۵۳/۸ متری از سطح دریا واقع است، به دست آمده است (شکل ۱). اقلیم منطقه مورد مطالعه جزو مناطق خشک می‌باشد. مقدار میانگین سالانه دمای هوا در ایستگاه مورد مطالعه ۱۵/۹ درجه سانتی‌گراد و مقدار بارندگی آن ۱۴۸ میلی‌متر در سال است.



مأخذ: نگارندگان

شکل ۱: موقعیت جغرافیایی منطقه مورد مطالعه در استان و کشور

داده‌های مورد استفاده در این پژوهش شامل میانگین رطوبت نسبی (RH_{mean})، کمینه رطوبت نسبی (RH_{min})، بیشینه رطوبت نسبی (RH_{max})، میانگین دما (T_{mean})، کمینه دما (T_{min})، بیشینه دما (T_{max})، میانگین فشار (P_{mean})، کمینه فشار (P_{min}) و بیشینه فشار (P_{max}) مربوط به ماه اکتبر (به دلیل همبستگی بالا در مقطع زمانی مورد نظر جهت پیش‌بینی بارش فصل زمستان) است که از اداره کل هواشناسی استان کرمان در دوره آماری ۲۰۱۴-۱۹۶۹ میلادی به دست آمده است.

روش پژوهش

در بررسی‌های اقلیمی هر چه دوره آماری طولانی‌تر باشد، پژوهش از ارزش بالاتری بهره‌مند خواهد بود (فرج زاده و دارند ۱۳۸۸: ۴۸)؛ بنابراین در این پژوهش از آمار ایستگاه همدید کرمان که قدیمی‌ترین آمار بارش را در استان کرمان دارا است، استفاده شده است. با توجه به آمار فصلی هواشناسی موجود، ۷۰ درصد داده‌ها برای آموزش شبکه و ۳۰ درصد داده‌ها برای تست مدل‌های طراحی شده در نظر گرفته شد.

ابتدا آزمون همگنی ران تست در محیط نرم‌افزار SPSS بر روی داده‌ها اعمال شد. نتایج بیانگر تصادفی بودن داده‌ها در سطح ۵ درصد می‌باشد. سپس با استفاده از روش ضریب همبستگی در نرم‌افزار SPSS به بررسی ارتباط بین عناصر اقلیمی دما، رطوبت نسبی، فشار و بارش پرداخته شد. بیشترین میزان همبستگی بارش با مینیمم دما و میانگین دما بوده است.

ورود داده‌ها به صورت استاندارد، میزان خطای شبکه را کاهش می‌دهد (نورسیس^۱، ۲۰۰۶: ۱۰۶). در این پژوهش برای استاندارد سازی داده‌ها از رابطه زیر استفاده شد:

$$N_i = 0.8 \left[\frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right] + 0.1 \quad [1]$$

در رابطه فوق، N_i مقادیر استاندارد شده، x_i مقادیر واقعی، x_{\min} کمینه مقادیر واقعی و x_{\max} بیشینه مقادیر واقعی است. بعد از استاندارد کردن داده‌ها، به پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی اقدام شد. برای طراحی مدل‌های شبکه عصبی مصنوعی از نرم‌افزار Qnet2000 استفاده شد.

انتخاب معماری در شبکه‌های عصبی با روش سعی و خطا است (باقر زاده، ۱۳۸۴: ۴۶). یکی از مهم‌ترین گام‌ها در پیشبرد رضایت‌بخش مدل پیش‌بینی، انتخاب متغیرهای ورودی مناسب می‌باشد (اکسوی^۲ و همکاران ۲۰۰۸: ۷۹۲). از آنجا که هدف این پژوهش پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی در شرایط کمبود داده‌های اقلیمی است، بنابراین در طراحی مدل‌ها، تعداد پارامترهای ورودی به تدریج کاهش یافت و ۵ ترکیب بردار ورودی به شرح جدول ۱ در نظر گرفته شد. لازم به ذکر است که در این پژوهش، از تابع فعالیت سیگموئید در لایه پنهان استفاده گردید. به منظور به دست آوردن بهترین آرایش شبکه، طراحی مدل‌ها ابتدا با یک لایه پنهان و سپس با ۲ لایه پنهان انجام شد. برای بررسی اثر ترم مومنتم، ۳ مقدار ۰/۷، ۰/۸ و ۰/۹ برای آن در نظر گرفته شد. از آنجا که تغییر در تعداد گره‌های لایه‌های پنهان، می‌تواند تأثیر به سزایی در دقت خروجی شبکه بگذارد، بنابراین برای تعیین مناسب‌ترین تعداد گره در لایه‌های پنهان، تعداد گره‌ها نیز بین ۱۰-۱ گره تغییر داده شد. با توجه به مطالب ذکر شده، در نهایت ۳۰۰ مدل (۵ ترکیب بردار ورودی × تعداد ۲-۱ لایه پنهان × ۳ حالت مومنتم × تعداد ۱۰-۱ گره در لایه‌های پنهان) با هدف حصول مناسب‌ترین ترکیب و آرایش شبکه، برای برآورد بارش با استفاده از شبکه‌های عصبی مصنوعی طراحی گردید.

¹ - Norusis

² - Aksoy


جدول ۱: ترکیب متغیرهای ورودی در مدل‌های طراحی شده

نام مدل	پارامترهای ورودی به مدل
مدل ۱	$T_{mean}, mT_{ax}, mT_{in}, HR_{mean}, RH_{max}, mHR_{in}, P_{mean}, mP_{ax}, mP_{in}$
مدل ۲	$T_{mean}, mT_{ax}, mT_{in}, HR_{mean}, mHR_{ax}, mHR_{in}$
مدل ۳	$T_{mean}, mT_{ax}, mT_{in}, P_{mean}, mP_{ax}, mP_{in}$
مدل ۴	$T_{mean}, mT_{ax}, mT_{in}$
مدل ۵	T_{mean}, mT_{in}

مأخذ: نگارندگان

شبکه‌های عصبی مصنوعی

شبکه عصبی مانند مغز انسان از مجموعه‌ای از سلول‌های عصبی (نرون‌ها) تشکیل شده است (نوری و همکاران ۱۳۹۲: ۱۷۵). مهم‌ترین مزیت شبکه‌های عصبی نسبت به سیستم‌های هوشمند دیگر قدرت یادگیری شبکه از محیط پیرامون است. (خسروی و شکبیا ۱۳۹۱: ۵). شکل ۲، مدل یک نرون چند ورودی را نشان می‌دهد.



شکل ۲: مدل ریاضی یک نرون چند ورودی (فلاح قاله‌ری و همکاران ۱۳۸۷: ۴).

سه جز یک نرون چند ورودی عبارتند از: الف) مجموعه سیناپس‌ها که هر یک با وزن مربوط مشخص می‌شوند. ب) یک جمع کننده برای جمع سیگنال‌های ورودی که از طریق سیناپس‌های نرون وزن دار می‌شود. ج) یک تابع فعالیت جهت محدود سازی دامنه خروجی نرون به کار می‌رود. ورودی خالص net و خروجی y مطابق روابط (۲) و (۳) محاسبه می‌شوند:

$$net_j = \sum_{i=1}^k X_i W_{ji} + b \quad [2]$$

$$y_j = g(net_j) \quad [3]$$

که در آن X_1, X_2, \dots, X_k سیگنال‌های ورودی، $W_{j1}, W_{j2}, \dots, W_{jk}$ وزن‌های سیناپسی جمع شونده به نرون‌ها در لایه پنهان، W_{ji} مقدار وزنی است که به نرون i ام لایه ورودی اختصاص داده می‌شود تا بر اساس آن نرون j ام لایه میانی به دست آید، net_j تأثیر تجمعی همه نرون‌های متصل به نرون j ام و آستانه داخلی نرون j ام، g تابع فعالیت، b آستانه خارجی که از آن بایاس یاد می‌شود و در مقدار ثابت ۱ ضرب می‌گردد و y_j سیگنال خروجی نرون می‌باشند (میثاقی ۱۳۸۲، ۱۴۵).

مدل رگرسیون خطی چندگانه

واژه رگرسیون به معنای بازگشت است و نشان می‌دهد که مقدار یک متغیر به متغیر دیگری بر می‌گردد. این رابطه ممکن است از نوع خطی و یا غیر خطی باشد. تابعی که ارتباط بین متغیرهای مستقل و وابسته را بیان می‌کند، به تابع رگرسیون موسوم است. در واقع تحلیل رگرسیون داده، روشی برای مدل‌سازی و تحلیل داده‌های عددی است. داده‌ها شامل مقدارهایی برای متغیر وابسته و یک یا چند متغیر مستقل هستند. هدف از تحلیل رگرسیون، بیان متغیر وابسته به شکل تابعی از متغیرهای مستقل، ضرایب و مقدارهای خطاست. مقدارهای خطا، متغیرهایی تصادفی هستند که تغییرات توضیح داده نشده در مقدار متغیرهای مستقل نشان می‌دهند (فریدمن ۲۰۰۵: ۱۴۸).

$$y = b_0 + b_1(x_1) + b_2(x_2) + \dots + b_p(x_p) \quad [4]$$

در این معادله پارامترهای b_1, b_2, \dots, b_p ضرایب رگرسیون هستند b_0 مقدار ثابت رگرسیون است. x متغیر مستقل و y متغیر وابسته است.

در این پژوهش، داده‌ها به همان صورت که وارد مدل شبکه‌های عصبی شدند، وارد مدل رگرسیون نیز شدند. بدین صورت که ورودی‌های مدل شبکه عصبی که به آن‌ها اشاره گردید، متغیرهای مستقل و خروجی شبکه (بارش) متغیر وابسته در نظر گرفته شد.

معیارهای ارزیابی عملکرد شبکه در مرحله آموزش و تست

الف- ضریب همبستگی^۱

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{S_x S_y} \quad [5]$$

در رابطه فوق، r_{xy} ضریب همبستگی بین متغیرهای x و y ، n تعداد مشاهدات، S_x انحراف معیار مشاهدات x و S_y انحراف معیار مشاهدات y است (حافظ‌نیا، ۱۳۸۹: ۲۸۰).

ب- ریشه میانگین مربعات خطا^۲

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad [6]$$

در رابطه فوق، n تعداد داده‌ها و y_i و \hat{y}_i به ترتیب مقدار مشاهده شده و برآورد شده در نقطه i ام است.

¹- The correlation coefficient

²- Root mean square error

ج- میانگین قدر مطلق خطا^۱

$$MAE = \frac{\sum_{i=1}^N |Z(x_i) - \hat{Z}(x_i)|}{N} \quad [7]$$

در رابطه فوق، MAE میانگین قدر مطلق خطا، $Z(x_i)$ و $\hat{Z}(x_i)$ به ترتیب مقادیر مشاهده شده و برآورد شده متغیر در نقطه i و n تعداد مشاهدات می باشد.

یافته‌ها

ساختار سری زمانی بارش بیان کننده تغییر بارش نسبت به زمان و تأثیر عوامل اقلیمی (دما، رطوبت، فشار و غیره) در تغییرات بارش است. برای مدل سازی، بایستی پارامترهای مناسب، از بین اطلاعات اقلیمی غیر بارشی انتخاب شوند. رابطه مجموع بارش فصل زمستان با استفاده از آزمون همبستگی پیرسون نسبت به پارامترهای اقلیمی مختلف در ماه‌های قبل از فصل زمستان مورد بررسی قرار گرفت. بررسی ارتباط بین بارش فصل زمستان و پارامترهای اقلیمی ماه‌های قبل نشان می‌دهد که همبستگی معناداری بین پارامترهای غیر بارشی ماه اکتبر و بارش فصل زمستان وجود دارد که نتایج آن در جدول ۲ نشان داده شده است.

جدول ۲: همبستگی پیرسون میان بارش و عوامل اقلیمی

میزان همبستگی	متغیر اقلیمی	
-۰/۷۱	حداقل	دما (درجه سانتی گراد)
-۰/۳۶	حداکثر	
-۰/۷۴	میانگین	
-۰/۲۳	حداقل	رطوبت (درصد)
-۰/۲۵	حداکثر	
-۰/۲۸	میانگین	
۰/۱۶	حداقل	فشار (هکتوپاسکال)
۰/۲۰	حداکثر	
۰/۱۳	میانگین	

مأخذ: نگارندگان

نتایج جدول ۲ نشان می‌دهد که دمای حداقل و میانگین دمای ماه اکتبر در مقایسه با دیگر عوامل اقلیمی همبستگی بالاتری را با بارش فصل زمستان دارند. در تأیید نتایج این جدول، ایلدرومی و همکاران (۱۳۹۲: ۳۰) نیز نقش عوامل دمایی را بر بارش‌های رخ داده در منطقه خراسان، کرمان و شیراز گزارش ۷؛ دند. در جدول ۳ مناسب‌ترین ساختار شبکه عصبی در قالب ۵ مدل مختلف آورده شده است. نتایج به دست آمده برای ۵ ترکیب اولیه، در جدول ۳ منظور گردیده است. از آنجا که هدف، بررسی عملکرد شبکه تحت شرایط کمبود متغیر اقلیمی است، بنابراین در انتخاب پارامترهای بردار ورودی سعی شده است تا حد امکان از عناصری استفاده شود که ضریب همبستگی بالاتری با مقدار بارش دارند. سپس

¹-Mean absolute error

داده‌ها به همان صورت که وارد مدل شبکه عصبی شده بودند، وارد مدل رگرسیون خطی چندگانه نیز شدند؛ بنابراین با توجه به جدول ۱ با استفاده از مدل ۵ تنها با T_{min} و T_{mean} ماه اکتبر می‌توان میزان بارش فصل زمستان را برآورد نمود. همان‌طور که در جدول ۲ مشاهده می‌گردد، مدل ۵ با ۲ ورودی و خطایی برابر با ۵/۶ میلی‌متر در دوره تست توانسته است نتایج بهتری را نسبت به سایر مدل‌ها ارائه دهد. نتایج همچنین نشان می‌دهد که در اکثر موارد با افزایش ترم مومنتم، مقدار خطا کاهش می‌یابد. از طرف دیگر، نتایج به دست آمده از تغییر در تعداد لایه‌های پنهان شبکه‌های طراحی شده نیز منجر به تصمیم‌گیری در رابطه با برتری یک لایه و یا دو لایه پنهان نشد و تنها بستگی به پارامترهای ورودی به شبکه دارد. این در حالی است که در مطالعات زیادی با فرض کارایی بالاتر یک لایه پنهان و البته اجرای سریع‌تر مدل، تنها از یک لایه پنهان استفاده گردیده است (وانگ و همکاران ۲۰۰۸: ۷۱۱، چائوهان و شریواستوا، ۲۰۰۹: ۸۳۲). البته در این پژوهش که هدف کاربرد شبکه‌های عصبی در پیش‌بینی بارش در شرایط کمبود داده‌های اقلیمی است، مدل ۵ با یک لایه پنهان و تنها دو پارامتر ورودی (میانگین دما و مینیمم دما)، نتایج نسبتاً رضایت‌بخشی داده است. نتایج مدل رگرسیون خطی چندگانه در جدول ۴ نشان داده شده است. با مقایسه نتایج جدول ۳ و ۴ می‌توان به این نتیجه رسید که مدل شبکه‌های عصبی مصنوعی با خطای کمتر و ضریب تعیین بالاتر نسبت به مدل رگرسیون خطی چندگانه از دقت بالاتری در پیش‌بینی و تشخیص رابطه بین پارامترهای اقلیمی برخوردار است.

جدول ۳: مقایسه نتایج شبکه‌های طراحی شده بر مبنای پارامترهای ورودی

نام شبکه	ساختار بهینه	ترم مومنتم	RMSE(%)		R^2		MAE(%)	
			تست	آموزش	تست	آموزش	تست	آموزش
مدل ۱	۹-۱۰-۵-۱	۰/۹	۱۱/۶	۱۵/۸	۰/۷۹	۰/۸۶	۹/۲	۱۳
مدل ۲	۶-۲-۸-۱	۰/۸	۲۱	۲۴/۹	۰/۶۵	۰/۷۹	۱۵/۸	۱۸/۶
مدل ۳	۶-۳-۵-۱	۰/۹	۱۳/۷	۲۱/۳	۰/۸۳	۰/۸۴	۱۰/۶	۱۴/۶
مدل ۴	۸-۴-۱-۱	۰/۹	۸/۷	۱۲/۳	۰/۸۹	۰/۸۵	۷/۵	۱۱/۴
مدل ۵	۲-۲-۱	۰/۹	۵/۶	۹/۸	۰/۹۱	۰/۸۹	۴/۶	۸/۹

مأخذ: نگارندگان


اعداد ساختار شبکه، به ترتیب از چپ به راست تعداد گره‌های لایه ورودی، لایه پنهان و لایه خروجی می‌باشد.
 $RMSE$ = ریشه میانگین مربعات خطا، MAE = حداکثر مطلق خطا.

جدول ۴: نتایج مدل رگرسیون خطی چندگانه.

مدل ۵			
MAE(%)	R^2	RMSE(%)	
۱۳/۵	۰/۶۱	۱۷/۶	آموزش
۱۵/۷	۰/۵۵	۲۱	تست

مأخذ: نگارندگان


شکل ۳ نتایج حاصل از اجرای مدل ۵ را در مقایسه با بارش مشاهده شده توسط مدل شبکه عصبی و رگرسیون خطی چندگانه نشان می‌دهد. همان‌طور که ملاحظه می‌شود، شبکه عصبی مصنوعی نسبت به روش رگرسیون خطی چندگانه توانایی نسبتاً خوبی در شبیه‌سازی بارش منطقه داشته است.



مأخذ: نگارندگان

شکل ۳: مقایسه نتایج شبیه‌سازی شده توسط دو مدل شبکه عصبی و رگرسیون خطی با داده‌های واقعی (داده‌های آموزش)

شکل ۴ مقادیر بارش مشاهده شده و شبیه‌سازی شده توسط مدل شبکه عصبی را نشان می‌دهد. ضریب همبستگی بین داده‌های مشاهده شده و پیش‌بینی شده در مدل پنج، $0/۸۹$ است که نشان‌دهنده دقت نسبتاً بالای مدل در تخمین و پیش‌بینی بارش است.



مأخذ: نگارندگان

شکل ۴: تغییرات بارش شبیه‌سازی شده نسبت به بارش مشاهده شده در مدل شبکه عصبی (داده‌های آموزش).

ایلدرومی و همکاران (۱۳۹۳: ۳۰) با انتخاب اطلاعات پارامترهای دما، رطوبت و دمای نقطه شبنم به‌عنوان ورودی شبکه عصبی و اطلاعات بارش ۵۰ ساله ایستگاه کرمان موفق به پیش‌بینی بارش با ضریب همبستگی $0/۸۸$ و حداقل خطای ۱۹% شدند. در مطالعه‌ای دیگر امیدوار و نبوی زاده (۱۳۹۳) با در نظر گرفتن ۷ متغیر ورودی موفق به پیش‌بینی بارش در ایستگاه کرمان با ضریب همبستگی $0/۹۰$ شدند. در حالی که نتایج این مطالعه در محدوده ایستگاه کرمان تنها با دو پارامتر حداقل دما و میانگین دما ماهانه (ماه اکتبر) با ضریب همبستگی $0/۹۱$ و خطای $۵/۶$ برای پیش‌بینی بارش فصل زمستان قابل کاربرد است.

برای ارزیابی میزان دقت مدل انتخاب شده، از روش اعتبارسنجی استفاده شده است. روش اعتبارسنجی حذفی جهت ارزیابی دقت برآورد مشخصه‌ها، شبیه‌سازی و انتخاب بهترین مدل و کشف داده‌های پرت استفاده می‌شود. ایده اصلی، حذف داده و استفاده از دیگر داده برای شبیه‌سازی داده حذف شده است. سپس مقدار داده حذف شده به محل خود بازگردانده می‌شود و این عمل برای داده‌های بعدی نیز تکرار می‌شود. بدین ترتیب برای کلیه داده‌ها شبیه‌سازی صورت می‌گیرد و می‌توان دقت مدل را ارزیابی کرد. جدول ۵ نتایج ارزیابی انجام شده توسط روش صحت‌سنجی حذفی را در دوره آموزش نشان می‌دهد. همان‌طور که بیان شد، مدل ۵ با دو ورودی و خطای ۹/۸ میلی‌متر، بهترین مدل مورد استفاده قرار گرفت. نتایج بررسی‌های انجام شده بر روی این دو مدل در دوره تست در جدول ۶ و شکل ۵ نشان داده شده است.

جدول ۵: صحت‌سنجی داده‌های دوره آموزش.

آل	مقادیر مشاهده شده	مقادیر شبیه سازی شده	مقادیر صحت‌سنجی شده	سال	مقادیر مشاهده شده	مقادیر شبیه سازی شده	مقادیر صحت‌سنجی شده
۱۹۶۹	۷۴/۹۸	۶۸/۵۴	۸۸	۱۹۸۵	۵۶	۶۵/۵	۶۴/۵
۱۹۷۰	۸۹/۵۸	۷۵/۴	۹۲/۶	۱۹۸۶	۸۲/۳	۷۰/۸	۸۲
۱۹۷۱	۱۱۵/۸۶	۱۳۰/۲	۱۰۶/۴	۱۹۸۷	۲۶/۸	۱۶/۱۲	۲۹/۲
۱۹۷۲	۱۲۶	۱۱۴/۷۶	۹۸/۸	۱۹۸۸	۸۸/۱۲	۷۴	۸۶
۱۹۷۳	۸۸/۱۲	۸۱/۳	۹۲/۷	۱۹۸۹	۶۱/۸۴	۷۱/۳	۵۶/۷
۱۹۷۴	۱۳۰/۴۶	۱۲۰/۴	۱۰۵	۱۹۹۰	۶۰/۳۸	۷۱/۷۵	۵۸/۷
۱۹۷۵	۶۱/۸۴	۶۸/۶	۷۹	۱۹۹۱	۱۳۴/۸۴	۱۲۹	۱۲۶/۸
۱۹۷۶	۱۲۴/۶۲	۱۱۶/۷	۱۰۷	۱۹۹۲	۸۲/۳	۷۷/۷	۷۸
۱۹۷۷	۸۶/۶۶	۷۴/۵	۹۳/۴	۱۹۹۳	۱۲۶	۱۲۳/۵	۱۳۵/۳
۱۹۷۸	۷۴/۹۸	۷۸	۷۸/۶	۱۹۹۴	۵۱/۶	۶۱/۳	۶۰/۲
۱۹۷۹	۱۰۸/۵۶	۱۰۴/۴	۹۶/۸	۱۹۹۵	۱۰۱/۲۶	۹۴/۶	۹۹
۱۹۸۰	۱۰۵/۶۴	۹۵/۷	۹۸	۱۹۹۶	۱۱۷/۳۲	۱۰۵/۶	۱۱۳/۴
۱۹۸۱	۱۲۴/۶۲	۱۳۴/۹	۱۱۲	۱۹۹۷	۸۹/۵۸	۸۳/۲	۹۴/۴
۱۹۸۲	۸۸/۱۲	۷۳	۹۵/۸	۱۹۹۸	۷۹/۳۶	۶۹/۸	۹۳/۶
۱۹۸۳	۱۱۰	۱۱۷	۱۲۱/۴۵	۱۹۹۹	۱۴۳/۶	۱۳۷/۶	۱۱۸/۴
۱۹۸۴	۹۶	۱۰۰	۸۴/۷	۲۰۰۰	۵۰/۱۶	۵۴/۷	۵۳/۷

مأخذ: نگارندگان


بررسی نتایج هر دو مدل نشان می‌دهد اختلاف بارش مشاهده شده و شبیه‌سازی شده در محدوده قابل قبولی قرار دارد و مدل‌ها توانسته‌اند بارش را با خطای قابل قبولی شبیه‌سازی نمایند. لازم به ذکر است اختلاف بارش مشاهده شده و شبیه‌سازی شده در بدترین حالت بیش از ۱۴ میلی‌متر نیست.

جدول ۶: پیش‌بینی بارش منطقه مورد مطالعه در مدل شبکه عصبی در دوره تست

سال	مقادیر دیدبانی شده	مقادیر پیش‌بینی شده
۲۰۰۱	۵۴/۵	۵۸
۲۰۰۲	۵۸/۹	۶۵
۲۰۰۳	۷۳/۵	۷۶
۲۰۰۴	۶۰/۴	۷۱/۶

۷۷/۹	۷۶/۴	۲۰۰۵
۵۶/۳	۵۱/۶	۲۰۰۶
۸۲/۷	۹۶/۹	۲۰۰۷
۲۹/۶	۳۸/۵	۲۰۰۸
۷۰	۶۰/۴	۲۰۰۹
۳۱	۲۹/۷	۲۰۱۰
۱۲۲	۱۰۸/۶	۲۰۱۱
۹۸/۴	۸۵/۲	۲۰۱۲
۵۵/۵	۴۴/۳	۲۰۱۳
۱۱۶/۴	۱۱۲/۹	۲۰۱۴


مأخذ: نگارندگان



مأخذ: نگارندگان

شکل ۵: مقایسه نتایج پیش‌بینی شده توسط دو مدل شبکه عصبی و رگرسیون خطی با داده‌های واقعی (در دوره تست).


شکل ۶ مقادیر بارش پیش‌بینی شده را در مقابل داده‌های مشاهده شده نشان می‌دهد. ضریب همبستگی بین داده‌های مشاهده شده و مقادیر پیش‌بینی شده در مدل ۵ در دوره تست ۰/۹۱ است.



مأخذ: نگارندگان

شکل ۶: تغییرات مقادیر بارش پیش‌بینی شده نسبت به مقادیر مشاهده شده در مدل شبکه عصبی (در دوره تست).

شکل ۷ نمودار پراکندگی باقیمانده‌ها را نسبت به زمان نشان می‌دهد. در صورت برازش مناسب مدل، باید باقیمانده‌ها به صورت تصادفی پراکنده شده باشند؛ به عبارت دیگر باقیمانده‌ها باید دارای توزیع نرمال باشند. با توجه به این شکل مشاهده می‌شود که باقی مانده‌ها دارای توزیع نرمال می‌باشند.



مأخذ: نگارندگان

شکل ۷: نمودار پراکندگی مقادیر باقیمانده‌ها در مدل ۵ (دوره تست)

نرم‌افزار *Qnet 2000* قادر است اهمیت نسبی متغیرهای شرکت کننده در مدل‌ها را محاسبه نماید. با بررسی این مقادیر می‌توان درجه اهمیت هر یک از پارامترهای ورودی را تعیین نمود. نتایج بررسی‌های انجام شده در جدول ۷ نشان داده شده است. نتایج این جدول نیز حاکی از اهمیت زیاد فاکتورهای کمینه دما و میانگین دما در تعیین میزان خروجی مدل (بارش زمستانه) می‌باشد. با توجه به نتایج جدول‌های ۲ و ۷، مشاهده می‌شود که با افزایش تعداد پارامترهای ورودی میزان خطای مدل افزایش می‌یابد و با کاهش تعداد پارامترهای ورودی دقت مدل افزایش یافته است.

جدول ۷: اهمیت نسبی متغیرهای ورودی در بهترین ساختار هر ترکیب (درصد).

نام مدل	ساختار بهینه	مونتیم	P _{min}	P _{max}	P _{mean}	minT	T _{max}	T _{mean}	minRH	RH _{max}	RH _{mean}
مدل ۱	۹-۱۰-۵-۱	۰/۹	۳/۱	۴/۸	۲/۶	۲۵/۳	۱۱	۲۸/۶	۵/۸	۷/۶	۱۱/۴
مدل ۲	۶-۲-۸-۱	۰/۸	۴/۶	۵/۴	۳/۲	۳۵/۴	۱۹/۲	۳۲/۲			
مدل ۳	۶-۳-۵-۱	۰/۹				۳۱/۸	۱۵/۶	۲۸/۲	۵/۷	۶/۳	۱۳/۸
مدل ۴	۸-۴-۱-۱	۰/۹				۲۲	۴۱/۵	۳۶/۶			
مدل ۵	۲-۲-۱	۰/۹					۵۲/۴	۴۷/۶			

مأخذ: نگارندگان

نتیجه‌گیری

بارش پدیده‌ای پیچیده و غیرخطی است و پارامترهای هواشناسی بسیاری در برآورد آن مؤثرند. از طرف دیگر محدودیت‌هایی از قبیل نبود اطلاعات این پارامترها در مقیاس زمانی و مکانی مناسب، سبب شده است تا امکان برآورد دقیق آن میسر نباشد. در این پژوهش سعی شد تا با تدوین مدلی مناسب، با بیشینه دقت، کمترین خطا و

با حداقل پارامترهای اقلیمی، تخمینی درست از بارش منطقه مورد مطالعه ارائه شود. با توجه به نتایج ارائه شده، در صورت فقدان پارامترهای اقلیمی، شبکه‌های عصبی مصنوعی قادرند تنها با استفاده از کمینه و میانگین دما، بارش فصل زمستان ایستگاه کرمان را برآورد نمایند. این در حالی است که با وارد نمودن پارامترهای بیشتر، دقت برآورد کاهش می‌یابد. به‌طور کلی می‌توان گفت پیش‌بینی مدل با مقادیر واقعی اختلاف ناچیزی دارد و مقدار آن در بدترین حالت به بیش از ۱۴ میلی‌متر نمی‌رسد. نتایج این پژوهش نشان داد مدل‌های تدوین شده قادر هستند رفتار بارندگی منطقه را تشخیص دهند. لازم به ذکر است امکان افزایش دقت مدل‌ها با افزایش سال‌های آماری در آینده میسر خواهد بود.

منابع

- ۱- امیدوار، کمال. نبوی زاده، معصومه. ثمره، قاسم. (۱۳۹۴): ارزیابی دقت شبکه عصبی مصنوعی بازگشتی نارکس در پیش‌بینی بارش روزانه در استان کرمان، فصل‌نامه جغرافیای طبیعی، سال ۸، شماره ۲۷، صص ۹۰-۷۳.
- ۲- امیدوار، کمال. نبوی‌زاده، معصومه. (۱۳۹۳): پیش‌بینی بارش استان کرمان با شبکه‌های عصبی مصنوعی (مطالعه موردی: کرمان، بافت و میانده جیرفت)، مجله جغرافیا و توسعه ناحیه‌ای، سال ۱۲، شماره ۲۳، صص ۲۱۴-۱۹۷.
- ۳- ایلدرومی، علی‌رضا. زارع ابیانه، حمید. بیات ورکشی، مریم. (۱۳۹۲): برآورد بارش به کمک شبکه عصبی مصنوعی با داده‌های هواشناسی غیر بارشی در سه منطقه شیراز، مشهد و کرمان، نشریه علمی-پژوهشی جغرافیا و برنامه‌ریزی (دانشکده جغرافیا)، سال ۱۷، شماره ۴۳، صص ۴۰-۲۱.
- ۴- باقر زاده چهره، کیارش. (۱۳۸۴): ارزیابی سیگنال‌های هواشناسی در پیش‌بینی خشک‌سالی با استفاده از شبکه‌های عصبی مصنوعی در استان تهران، پایان‌نامه دوره کارشناسی ارشد، استاد راهنما: سعید مرید، دانشگاه تربیت مدرس، دانشکده کشاورزی، گروه عمران.
- ۵- پولادی، امید. (۱۳۸۱): مقایسه عملکرد شبکه عصبی مصنوعی با سایر روش‌ها در برآورد مکانی بارندگی روزانه، پایان‌نامه دوره کارشناسی ارشد، استاد راهنما: محمدجواد عابدینی، دانشگاه شیراز، دانشکده مهندسی، گروه عمران.
- ۶- زاهدی، رضا. (۱۳۸۰): کاربردهای صنعتی منطق و شبکه‌های عصبی فازی. چاپ دوم، تهران، انتشارات انستیتو ایزابران.
- ۷- حافظ نیا، محمدرضا. (۱۳۸۹): مقدمه‌ای بر روش تحقیق در علوم انسانی. تهران، انتشارات سمت.
- ۸- حلبیان، امیرحسین. دارند، محمد. (۱۳۹۱): پیش‌بینی بارش اصفهان با استفاده از شبکه‌های عصبی مصنوعی، نشریه تحقیقات کاربردی علوم جغرافیایی، سال ۱۲، شماره ۲۶، صص ۶۳-۴۷.
- ۹- خسروی، محمود. شکیب، هانیه. (۱۳۸۹): پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی به‌منظور مدیریت سیل: مورد منطقه ایرانشهر، چهارمین کنگره بین‌المللی جغرافیدانان جهان اسلام، زاهدان، ایران.
- ۱۰- خلیلی، نجمه. خداشناس، سعید رضا. داوری، کامران. (۱۳۸۵): پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی، مجموعه مقالات دومین کنفرانس مدیریت منابع آب دانشگاه صنعتی اصفهان.
- ۱۱- صداقت کردار، عبدالم... فتاحی، ابراهیم. (۱۳۸۷): شاخص‌های پیش‌آگاهی خشک‌سالی در ایران، مجله جغرافیا و توسعه. سال ۱۱، شماره ۶، صص ۷۶-۵۹.

- ۱۲- فرج‌زاده اصل، منوچهر. دارند، محمد. (۱۳۸۸): مقایسه روش‌های رگرسیون خطی و شبکه عصبی مصنوعی در پیش‌بینی میزان مرگ و میر به‌عنوان تابعی از دمای هوا (مطالعه موردی: تهران). مجله تحقیقات نظام سلامت حکیم، جلد ۱۲، شماره ۳، صص ۴۵-۵۳.
- ۱۳- فلاح قاله‌ری، غلام‌عباس. موسوی بایگی، محمد. حبیبی نوخندان، مجید. (۱۳۸۷): پیش‌بینی بارش فصلی بر اساس الگوهای سینوپتیکی با استفاده از سیستم استنباط فازی- عصبی تطبیقی (ANFIS)، پژوهش‌های جغرافیای طبیعی، شماره ۶۶، صص ۱۴۰-۱۲۱.
- ۱۴- میثاقی، فرهاد. (۱۳۸۲): توسعه الگوریتم ترکیبی زمین آمار و شبکه‌های عصبی مصنوعی به‌منظور استخراج توزیع مکانی بارندگی، پایان‌نامه دوره کارشناسی ارشد، استاد راهنما: کورش محمدی، دانشگاه تربیت مدرس، دانشکده کشاورزی، گروه مهندسی کشاورزی.
- ۱۵- نصری، محسن. (۱۳۸۲): پیش‌بینی بارندگی در دامنه زمان و مکان با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک، پایان‌نامه دوره کارشناسی ارشد، استاد راهنما: کیوان اصغری، دانشگاه صنعتی اصفهان، دانشکده عمران، گروه عمران.
- ۱۶- نوری، سمیرا. فلاح قاله‌ری، غلام‌عباس. ثنایی نژاد، سید حسین. (۱۳۹۲): مدل‌سازی تبخیر-تعرق گیاه پتانسیل با استفاده از شبکه عصبی مصنوعی با حداقل متغیرهای اقلیمی در ایستگاه سینوپتیک مشهد، نشریه پژوهش‌های حفاظت آب‌و‌خاک، سال ۲۰، شماره ۵، صص ۱۶۳-۱۷۸.
- ۱۷- نورسیس، ماریجا. (۲۰۰۶): آموزش آنالیز آماری داده‌ها در SPSS، ترجمه اکبر فتوحی و فریبا اصغری (۱۳۸۳)، چاپ دوم، تهران، انتشارات کانون نشر علوم.

- 18- Abdul Muttaleb Alhashimi, SH. (2014): Prediction of Monthly Rainfall In Kirkuk Using Artificial Neural Network and Time Series Models, Journal of Engineering and Development 18: 782-803.
- 19- Aksoy, H. Guven, A. Aytek, A. Yuce, MI and Unal, NE. (2008): Discussion of Generalized Regression Neural Network for Evapotranspiration Modeling, Hydrol, Sci, 52: 825-831.
- 20- Chauhan, S and Shrivastava, RK. (2009): Performance Evaluation of Reference Evapotranspiration Estimation Using Climate Based Methods and Artificial Neural Network, Water Resour, Manage, 23: 825-837.
- 21- Friedman, NJ. Velho, HF and Ramizer, MCV. (2005): Artificial Neural Network for Rainfall Forecasting Applied to The Sao Paulo Region, J. Hydrology, 301:146-162.
- 22- Hung, N.Q.M.S. Babel S. Weesakul, k and Tripathi, NK. (2008): An Artificial Neural Network Model for Rainfall Forecasting in Bangkok Thailand, Hydrology and Earth Sciences Discussion, 5: 183-218.
- 23- Karen, A.L.S. (2010): Comparison of Adaptive Methods Using Multivariate Regression Splines (MARS) and Artificial Neural Networks Backpropagation (ANNB) for The Forecast of Rain and Temperatures in The Mantaro River Basin, Hydrology Days: 58-68.
- 24- Mekanik, F. Imteaz, M.A. Goto-Trinidad, S and Elmahdi, A. (2013): Multiple Regression and Artificial Neural Network for Long-Term Rainfall Forecasting Using Large Scale Climate Modes, Journal of Hydrology 503: 11-21.
- 25- Shafie, AHA, El-Shafie Hasan, GEI, Mazoghi A, Shehata and Mohd Taha, R (2011): Artificial Neural Network Technique for Rainfall Forecasting Applied to Alexandria. Egypt, International Journal of the Physical Sciences 6: 1306-1316.
- 26- Wang, YM, Traer, S and Kerh, T (2008): Neural Network Approach for Estimating Reference Evapotranspiration From Limited Climatic Data in Burkina Faso, WSEAS Transactions on Computers 7: 704-713.