

مجله جغرافیا و توسعه ناحیه‌ای، سال دوازدهم، شماره بیست و سوم، پاییز و زمستان ۱۳۹۳

پیش‌بینی بارش روزانه استان کرمان با شبکه‌های عصبی مصنوعی (مطالعه موردی: کرمان، بافت و میانده جیرفت)

کمال امیدوار (استاد اقلیم‌شناسی گروه جغرافیا، دانشگاه یزد، یزد، ایران، نویسنده مسئول)

komidvar@yazd.ac.ir

معصومه نبوی‌زاده (کارشناس ارشد اقلیم‌شناسی در برنامه‌ریزی محیطی، دانشگاه یزد، یزد، ایران)

mnabavi93@yahoo.com

چکیده

اهداف: هدف این پژوهش، پیش‌بینی بارش روزانه با استفاده از آمار روزانه هواشناسی ایستگاه‌های کرمان، بافت و میانده جیرفت، طی دوره مشترک آماری ۲۳ ساله (۲۰۱۲-۱۹۸۹) می‌باشد.

روش: برای دست‌یافتن به هدف تحقیق، به آموزش شبکه‌های عصبی مصنوعی با ساختار پرسپترون چندلایه و شبکه عصبی تابع پایه شعاعی پرداخته شد. ترکیب‌های مختلف پارامترهای کمینه دما، بیشینه دما، میانگین دما، رطوبت نسبی، سرعت و جهت باد و نیز میانگین فشار، به عنوان ورودی‌های شبکه‌های عصبی مصنوعی و بارش روزانه به عنوان خروجی شبکه درنظر گرفته شدند.

یافته‌ها / نتایج: نتایج نشان داد شبکه‌های عصبی مصنوعی پایه تابع شعاعی از دقت بسیار بیشتر و خطای کمتری نسبت به شبکه عصبی پرسپترون، برای تخمین بارش روزانه در هر سه ایستگاه برخوردار هستند.

نتیجه‌گیری: در بهترین ترکیب با پارامترهای کمینه و بیشینه و حداقل دما و رطوبت نسبی، سرعت و جهت باد و نیز میانگین فشار در ایستگاه کرمان با ضریب همبستگی ۰/۹۰۷ و جذر میانگین مربعات خطای ۰/۰۱۴، بهترین مدل پیش‌بینی بارش در این تحقیق شناخته شدند.

کلیدواژه‌ها: پیش‌بینی بارش، شبکه عصبی پرسپترون، شبکه عصبی تابع پایه شعاعی، کرمان، بافت، میانده جیرفت.

۱. مقدمه

کشور ایران با موقعیت جغرافیایی و اقلیم خاصی که دارد، سهم اندکی از ریزش‌های جوی به عنوان منبع اصلی تأمین کننده آب دارد. میانگین بارندگی سالانه در ایران، ۲۴۰ میلی‌متر؛ یعنی، یک‌سوم مقدار میانگین بارندگی جهان (۸۶۰ میلی‌متر) است که در تقسیم‌بندی جهانی، جزو اقلیم‌های خشک و نیمه-خشک می‌باشد (صداقت، ۱۳۸۵، ص. ۳۰).

بارندگی یکی از پیچیده‌ترین و اتفاقی‌ترین پدیده‌های طبیعی می‌باشد. درواقع، تأثیر عوامل محسوس و غیرمحسوس به قدری در ایجاد حادثه دخیل است که این روند را از صورت نظامی قانونمند به صورت ساختاری پیچیده سوق داده است. از جمله روش‌های کارآمد که امروزه برای پیش‌بینی بارش به عنوان یک فرایند نامنظم اهمیت دارد، شبکه‌های عصبی مصنوعی ANN^۱ است که به عقیده کارشناسان، علت اصلی پذیرش و استفاده روزافروزن از آن، قدرت و سرعت زیاد در شیوه‌سازی فرایند‌هایی است که درک و شناخت درستی از آن وجود ندارد یا بررسی آنها با دیگر روش‌های موجود، بسیار دشوار و وقت‌گیر می‌باشد (قلی-زاده و دارند، ۱۳۸۸، ص. ۵۳). در این بررسی سعی شده است تا در سه ایستگاه کرمان، بافت و میانده جیرفت، توسط شبکه‌های عصبی توابع شعاعی^۲ و شبکه‌های عصبی پر سپترون^۳، به شیوه‌سازی و تخمین بارش پرداخته شود و سپس، مقایسه‌ای بین پاسخ دو شبکه ذکر شده انجام گیرد تا مشخص گردد کدام شبکه کارایی و دقیق‌تر و خطای کمتری در پیش‌بینی بارش روزانه ایستگاه‌های مورد مطالعه دارد.

۲. پیشینه تحقیق

در سرمیان ایران، بارش به عنوان مهم‌ترین عنصر اقلیمی، همواره از پیچیدگی‌های خاصی برخوردار بوده است؛ به طوری که محققان بسیاری کوشیده‌اند تا در تحقیقات خود به تبیین دقیق این تغییرپذیری‌ها در حوزه‌های مختلف پردازنند.

با توجه به اهمیت این موضوع، پژوهش‌های بسیاری در این زمینه انجام شده‌اند که در ادامه برخی از آن‌ها بیان می‌گردند. جایاوردن، فرناندو، و Zhou^۴ (۱۹۹۷، ص. ۱۷۳)، برای پیش‌بینی سیل در رودخانه میجر چین

1. Artificial Neural Networks
2. Radial Basis Function
3. Perceptron Neural Network
4. Jayawardena , Fernando, & Zhou

به بررسی شبکه‌های RBF و MLP پرداختند و به این نتیجه رسیدند که RBF نسبت به پرسپترون با سرعت و دقت بیشتری سیل را پیش‌بینی می‌کند.

مقصود و ریاض خان و آیجی^۱ (۲۰۰۴، ص. ۱۱۴) به پیش‌بینی سرعت باد، رطوبت نسبی و دما برای ۲۴ ساعت آینده در کانادا و ساسکاچوان جنوبی با استفاده از مدل‌های پیش‌بینی شبکه‌های عصبی پرداختند و به این نتیجه دست یافتند که مدل RBF نسبت به MLP و ERNN برای پیش‌بینی سرعت باد، رطوبت نسبی و دما دقت بیشتری دارد.

سان‌نانم و ساب حاجینی^۲ (۲۰۱۱، ص. ۹۶۲) به ارزیابی اقلیم و پیش‌بینی کارآمد آب و هوای استفاده از RBF پرداختند. آن‌ها به این نتیجه رسیدند که این شبکه با دقت حدود ۸۷/۴۹٪ به پیش‌بینی پرداخته است. شریورتایاو کارماکار و کووار^۳ (۲۰۱۲، ص. ۱۷) با استفاده از شبکه‌های عصبی RBF و PB، به پیش‌بینی رفتار نامنظم باران موسومی در دوره آماری بلندمدت ۱۹۲۳ تا ۲۰۱۲ در منطقه‌ای در هند پرداختند. آن‌ها به این نتیجه دست یافتند که RBF از توانایی بسیار زیادی برای پیش‌بینی فرایند نامنظم برخوردار است.

دهقانی، پیری، حسام، و دهقانی (۱۳۸۹، ص. ۵۵) با استفاده از شبکه‌های عصبی مصنوعی پرسپترون چندلایه، تابع پایه شعاعی RBF و المانی به تخمین تبخیر روزانه از تشت تبخیر پرداخت. وی برتری تخمین شبکه‌های عصبی مصنوعی را نسبت به روش‌های تجربی تأیید نمود.

کاکوئی، مسیحی، و شیرانی (۱۳۹۱، ص. ۱۵۰) به کاربرد شبکه‌های عصبی RBF و PNN در تعیین رخسارهای یکی از میدان‌های گازی جنوب ایران پرداختند و توانمندی زیاد این شبکه‌ها را در تعیین رخسارهای تأیید کردند.

در این زمینه پژوهش‌های مشابه دیگری از جمله نعمتی و رعنایی (۱۳۸۶)، اژدرپور (۱۳۸۷)، حلیان (۱۳۸۸)، خوشحال دستجردی (۱۳۸۹)، افخمی، دستورانی، ملکی‌نژاد، و میین (۱۳۸۹)، خسروی و شکیبا (۱۳۸۹)، بنی‌حیب، ولی‌پور، و بهبهانی (۱۳۹۰)، خلیلی، خداشناس، دواری، و موسوی بایگی (۱۳۸۹)

1. Maqsood, Riaz Khan, & Ajith

2 .Santhanam & Subhajini

3. Shrivastava, Karmakar, & Kowar

HAL, BROOKS, و DAZL^۱ (۱۹۹۹)، HUNG, BABEL، WEESAKUL، و TRIPATHI^۲ (۲۰۰۸)، DIAKONENCU^۳ (۲۰۰۸)، SITI و WIBOWO^۴ (۲۰۱۲)، انجام شده‌اند.

۳. روش شناسی تحقیق

۳.۱. روش تحقیق

برای پیش‌بینی بارش روزانه، از دو نوع شبکه عصبی پرسپترون و شبکه عصبی تابع پایه شعاعی استفاده گردید. بدین‌منظور، از داده‌های بارش روزانه ایستگاه‌های منتخب کرمان (کرمان، بافت و میانده جیرفت) در یک دوره آماری مشترک ۲۳ ساله از ۱۹۸۹ تا ۲۰۱۲ استفاده شد که ۸۵۸۵ داده روزانه، شامل پارامترهای کمینه و بیشینه و میانگین دما به درجه سلسیوس، رطوبت نسبی به درصد، سرعت و جهت باد به متر بر ثانیه، میانگین فشار به هکتوپاسکال، به عنوان سیگنال‌های ورودی و بارش روزانه به عنوان خروجی شبکه تعیین شدند (جدول ۱). شایان ذکر است که در ایستگاه‌های ذکر شده، ترکیبات مختلفی از سیگنال‌های ورودی تهیه شدند و به مدل معرفی گردیدند که با احتساب همه اشکال ترکیب، ۳۵ مدل ترکیبی ایجاد شد (جدول ۲). در اینجا برای کوتاه‌شدن مطلب، از ۳۵ مدل ترکیبی، فقط مدل‌هایی که توانسته‌اند مقدار R^2 و بیشتر را کسب کنند، نشان داده می‌شوند (جدول‌های ۳ و ۴). در نهایت، ترکیب و شبکه عصبی بهینه انتخاب گردیدند.

جدول ۱ - معرفی پارامترهای اقلیمی ورودی و خروجی شبکه‌های عصبی مورد مطالعه


مأخذ: نگارنده‌گان، ۱۳۹۲

پارامترهای اقلیمی	علامت اختصاری	پارامترهای اقلیمی	علامت اختصاری	پارامترهای اقلیمی
بارش (خروجی)	P	سرعت باد (ورودی)	FF	
کمینه دما (ورودی)	T_{\min}	جهت باد (ورودی)	DD	
بیشینه دما (ورودی)	T_{\max}	میانگین فشار (ورودی)	P_{mean}	
میانگین دما (ورودی)	T_{mean}	رطوبت نسبی (ورودی)	RH	

1. Hall , Brooks, & Doswell
2. Hung , Babel, Weesakul, & Tripathi
3. Diaconescu
4. Siti & Wibowo

۳. منطقه موردمطالعه

استان پهناور کرمان با وسعت ۱۸۱۷۱۴ کیلومترمربع در جنوب شرقی فلات ایران واقع شده است و به لحاظ وسعت، مقام اول دارد. از نظر طول جغرافیایی، استان کرمان درین نصف‌النهارات $۳۰^{\circ} ۳۶' ۰۰''$ تا $۵۴^{\circ} ۳۰' ۰۰''$ و عرض جغرافیایی، درین مدارات $۳۲^{\circ} ۲۲' ۰۰''$ تا $۳۶^{\circ} ۰۰' ۰۰''$ شمالی، واقع شده است. ایستگاه‌های موردمطالعه در این تحقیق، کرمان، بافت و میانده جیرفت می‌باشند (شکل ۱). شهر کرمان ۱۷۵۳/۸ متر از سطح دریا ارتفاع دارد و جزو مناطق خشک است. شهرستان بافت ۲۲۸۰ متر از سطح دریا ارتفاع دارد و جزو مناطق کوهستانی و مرتفع‌ترین شهر استان است. شهرستان جیرفت، با ارتفاع ۶۰۱ متر از سطح دریا، جزو مناطق گرمسیری در استان محسوب می‌شود. علت انتخاب این سه ایستگاه، آب‌وهوای متفاوت‌شان است تا تأثیر این تفاوت در خروجی شبکه‌های عصبی مشاهده شود.



شکل ۱ - موقعیت جغرافیایی ایستگاه‌های موردمطالعه

مأخذ: نگارندگان، ۱۳۹۲

جدول ۲- مدل‌های ورودی ساخته شده

مأخذ: نگارندگان، ۱۳۹۲

شماره شبکه	پارامترهای بردار ورودی
۱	$P = f(T_{min} + T_{max})$
۲	$P = f(T_{min} + T_{mean})$
۳	$P = f(T_{min} + RH)$
۴	$P = f(T_{min} + FF)$
۵	$P = f(T_{min} + DD)$
۶	$P = f(T_{min} + Pre_{mean})$
۷	$P = f(T_{max} + T_{mean})$
۸	$P = f(T_{max} + RH)$
۹	$P = f(T_{max} + FF)$
۱۰	$P = f(T_{max} + DD)$
۱۱	$P = f(T_{max} + Pre_{mean})$
۱۲	$P = f(T_{mean} + RH)$
۱۳	$P = f(T_{mean} + FF)$
۱۴	$P = f(T_{mean} + DD)$
۱۵	$P = f(T_{mean} + Pre_{mean})$
۱۶	$P = f(RH + FF)$
۱۷	$P = f(RH + DD)$
۱۸	$P = f(RH + Pre_{mean})$
۱۹	$P = f(FF + DD)$
۲۰	$P = f(FF + Pre_{mean})$
۲۱	$P = f(T_{min} + T_{max} + T_{mean})$
۲۲	$P = f(T_{min} + T_{max} + RH)$
۲۳	$P = f(T_{min} + T_{max} + FF)$
۲۴	$P = f(T_{min} + T_{max} + DD)$
۲۵	$P = f(T_{min} + T_{max} + Pre_{mean})$
۲۶	$P = f(T_{min} + T_{max} + T_{mean} + RH)$
۲۷	$P = f(T_{min} + T_{max} + T_{mean} + FF)$
۲۸	$P = f(T_{min} + T_{max} + T_{mean} + DD)$
۲۹	$P = f(T_{min} + T_{max} + T_{mean} + Pre_{mean}))$
۳۰	$P = f(T_{min} + T_{max} + T_{mean} + RH + FF)$
۳۱	$P = f(T_{min} + T_{max} + T_{mean} + RH + DD)$
۳۲	$P = f(T_{min} + T_{max} + T_{mean} + RH + Pre_{mean})$
۳۳	$P = f(T_{min} + T_{max} + T_{mean} + RH + FF + DD)$
۳۴	$P = f(T_{min} + T_{max} + T_{mean} + RH + FF + Pre_{mean})$
۳۵	$P = f(T_{min} + T_{max} + T_{mean} + RH + FF + DD + Pre_{mean})$

۴. مبانی نظری تحقیق

در چند سال اخیر، پیدایش و توسعه هوش محاسباتی که استخراج هوش، دانش و الگوریتم محاسبات عددی و ارائه روزآمد داده‌های عددی است، علاقه بسیاری در میان پژوهشگران ایجاد کرده است؛ به گونه‌ای که در علوم مختلف وارد شده است و کاربردهای متعددی دارد. مؤلفه‌های اصلی هوش محاسباتی، شامل شبکه‌های عصبی مصنوعی، منطق فازی^۱ و الگوریتم ژنتیک است که شبکه‌های عصبی مصنوعی، ساختار و عملکرد سلول‌های عصبی طبیعی، منطق فازی استنتاج تقریبی و الگوریتم ژنتیک را شبیه‌سازی می‌کنند (اژدرپور، ۱۳۸۷، ص. ۲۵).

۴.۱. شبکه عصبی چندلایه پرسپترون (MLP)

این نوع مدل ANN همراه با الگوریتم پس انتشار خطأ، یکی از پرکاربردترین انواع شبکه عصبی است که می‌توانند یک نگاشت غیرخطی را با دقت دلخواه انجام دهند؛ به این صورت که خروجی‌های واقعی با خروجی‌های دلخواه مقایسه می‌شوند و وزن‌ها به وسیله الگوریتم پس انتشار، به صورت تحت نظارت تنظیم می‌گردند تا الگوی مناسب به وجود آید (جایاوردن و همکاران، ۱۹۹۷، ص. ۱۷۳).

۴.۲. شبکه با تابع پایه شعاعی (RBF)

شبکه‌های تابع پایه شعاعی از نوع شبکه‌های پیشرو همراه با یک لایه میانی هستند. در این روش، اغلب، تابع محرک در لایه میانی، تابع گوسین و در لایه خروجی، تابع خطی است. در اینجا، فرایند آموزش توسط روش‌های یادگیری رقابتی^۲ یا روش خوش‌ابزاری^۳ انجام می‌گیرد. در اینجا، پارامترهای شبکه شامل دو پارامتر «عدد گسترش»^۴ و «عدد هدف»^۵ است. با تغییر این پارامترها، می‌توان عملکرد شبکه را بهبود بخشید. تفاوت عمده این شبکه با شبکه‌های پس انتشار خطأ در این است که دارای یک لایه میانی هستند و توابع محرک نرون‌ها، توابع شعاعی همراه با مرکز و عرض خاصی می‌باشند (کاکوئی و همکاران، ۱۳۹۱، ص. ۱۵۰).

-
- 1. Fuzzy logic
 - 2. Competitive Learning
 - 3. Kmean, Clustering)
 - 4. Spread Number
 - 5. Goal Number

علاوه بر این، برخلاف شبکه پس انتشار خطای مجموع وزن دار نرون‌های رسیده به نرون لایه میانی به عنوان ورودی تابع تحریک محاسبه می‌شوند، در اینجا فاصله بین هر الگو با بردار مرکز هر نرون در لایه میانی، به عنوان ورودی تابع تحریک شعاعی محاسبه می‌شوند. در فضای چند بعدی، سطح آستانه نرون‌های لایه میانی به صورت توابع گوسی است که بیشترین مقدار را در مرکز دارد. با افزایش فاصله از مرکز، پاسخ به سمت صفر میل می‌کند. بدليل انتخاب تابع گوسی در نرون‌های لایه میانی، این شبکه مسائل دسته‌بندی را به خوبی حل می‌کند؛ زیرا، به صورت شعاعی می‌تواند الگوها را برابر روی دواير متعدد مرکزی تقسیم نماید و بردارهای مختلف با فاصله‌های یکسان از مرکز را در یک دسته قرار دهد. خطی بودن توابع تحریک نرون‌های خروجی، از تفاوت‌های دیگر این شبکه با شبکه پس انتشار خطای است و به همین دليل می‌توان از الگوریتم‌های بهینه‌سازی خطای استفاده کرد که سرعت پردازش را زیاد می‌کنند و همچنین، از افتادن در چاله‌های موضعی جلوگیری می‌کنند (دهقانی و همکاران، ۱۳۸۹، ص. ۵۶).

۴.۳. توابع انتقال مورد استفاده

تابع مورد استفاده در شبکه عصبی MLP، تابع سیگموئید و در شبکه عصبی RBF، تابع گوسی هستند. در لایه خروجی هر دو شبکه، از تابع همانی (خطی) استفاده گردید.

۵. یافته‌های تحقیق

در این تحقیق، در شبکه عصبی MLP، فرایند آموزش با هدف شبیه‌سازی بارش با تعداد چرخش^۱ ۱۰۰۰ بار انجام گرفت. میزان نرون‌های لایه مخفی متناسب با n^2 طراحی شد که n ، متناسب با تعداد عوامل ورودی به مدل می‌باشد و در RBF، دو پارامتر عدد گسترش، ϵ و عدد هدف، صفر هستند. درنهایت، برای ارزیابی نتایج از دو عامل جذر ضریب کارائی^۲ (R) و مجدول میانگین مربعات خطای (RMSE)^۳ استفاده گردید. برای ۳۵ مدل ترکیبی، مجدول میانگین مربعات خطای و ضریب همبستگی برای ارزیابی تأثیر آنها محاسبه شدند.

1. Epoch

2. Coefficient of efficiency

3. Root Mean Square Error

۱. ارزیابی نتایج شبکه عصبی MLP


در این نوع شبکه، مدل‌هایی که توانسته‌اند ضریب همبستگی 0.77 و بیشتر را به دست آورند، به عنوان ورودی‌های مؤثر معرفی می‌شوند که رطوبت نسبی از تأثیر زیادی برخوردار است (جدول ۳).

۲. بهترین ترکیب MLP در ایستگاه‌های مورد مطالعه

در ایستگاه کرمان، بهترین مدل، MLP34 است که با ترکیب کمینه دما، بیشینه دما، میانگین دما، رطوبت نسبی، جهت باد و میانگین فشار، ضریب همبستگی 0.70 را کسب کرده است. بیشترین ضریب کسب شده در دو ایستگاه دیگر، مدل MLP33 با ترکیب کمینه دما، بیشینه دما، میانگین دما، رطوبت نسبی، جهت و سرعت باد است. با افزایش میزان ورودی‌های تأثیرگذار، دقت شبکه افزایش یافته است (جدول ۳). در ایستگاه کرمان، این نوع شبکه خطای کمتری را نسبت به دو ایستگاه دیگر کسب کرده است و به این دلیل است که در این ایستگاه، افت و اخیز بارش کمتر از دو ایستگاه دیگر است (شکل ۲).

۳. ارزیابی نتایج شبکه عصبی RBF

بهترین مدل ترکیبی RBF در ایستگاه کرمان، RBF35 مشاهده شد. با میزان $R^2 = 0.907$ و RMSE $= 0.14$ ، با ترکیب رطوبت نسبی، کمینه و بیشینه دما، میانگین دما، جهت و سرعت باد و نیز میانگین فشار، در این تحقیق شناخته شد (جدول ۴). در بافت نیز مدل RBF35 با همان ترکیب بالا به عنوان مدل برتر $R = 0.874$ و RMSE $= 0.205$ ، این ایستگاه شناسایی شد. در ایستگاه میانده جیرفت نیز RBF34 با ترکیب رطوبت نسبی، کمینه و بیشینه دما، میانگین دما، جهت باد و میانگین فشار، $R = 0.82$ و RMSE $= 0.036$ ، بهترین سیگنال‌های ورودی این ایستگاه شناخته شد. در کرمان، بهترین عامل که باعث زیاد شدن کارایی شبکه شد، رطوبت نسبی می‌باشد که با ترکیب با پارامتر دما بهترین کارایی را داشته است (جدول ۴). در بافت، علاوه بر رطوبت نسبی، جهت باد و میانگین فشار در ترکیب با رطوبت، باعث بالارفتن میزان کارایی شبکه شدند. در میانده جیرفت، عامل سرعت باد باعث کاهش کارایی شده است و جهت باد و رطوبت نسبی از عوامل تأثیرگذار بوده‌اند. در این شبکه، با افزایش میزان ورودی‌های تأثیرگذار، دقت شبکه افزایش یافته است (جدول ۴). تا حد زیادی میزان خطای این شبکه نسبت به دو شبکه دیگر بسیار کم است (شکل ۲). نمونه اعداد پیش‌بینی شده بارش روزانه، همان خروجی شبکه RBF نیز نشان‌دهنده دقت زیاد است (جدول ۵).



شکل ۲- مقایسه خطای بین دو شبکه موردآزمون؛ یعنی، RBF و MLP

مأخذ: نگارندگان، ۱۳۹۲.

جدول ۳- نتایج شبکه عصبی پرسپترون سه لایه در ایستگاه‌های موردمطالعه^۱

مأخذ: نگارندگان، ۱۳۹۲

نام شبکه	کرمان		بافت		میانده جیرفت	
	R	RMSE	R	RMSE	R	RMSE
MLP3	۰/۶۴۹	۱/۴۶	۰/۶۲۱	۲/۶۶	۰/۰۵	۲/۷۷
MLP8	۰/۶۰۰	۱/۴۵	۰/۶۲۱	۲/۶۶	۰/۰۷۶	۲/۳۹
MLP12	۰/۶۷۲	۱/۴۱	۰/۶۱۴	۲/۷۴	۰/۰۱۶	۲/۰۰
MLP16	۰/۵۸۵	۱/۰۷	۰/۶۴۱	۲/۷۱	۰/۶۱	۲/۰
MLP20	۰/۶۷۸	۱/۴۷	۰/۰۰۳	۳/۳	*	۲/۸۲
MLP21	۰/۴۷۳	۱/۶۲	۰/۶۰۴	۲/۸۹	۰/۰۱۳	۲/۷۱
MLP22	۰/۴۸۳	۱/۷	۰/۶۷۸	۲/۴۲	۰/۰۲۳	۲/۷۹

۱. علامت * به این معنی است که شبکه اجرا نشده است. قسمت‌های رنگی بهترین مدل در جدول می‌باشند.

MLP26	۰/۸۱	۱/۴۲	۰/۶۵۵	۲/۶	۰/۶۳۳	۲/۴۲
MLP27	۰/۷۰۱	۱/۴۲	۰/۶۶۸	۲/۵۸	۰/۰۵۷	۲/۸
MLP30	۰/۸۱	۱/۳۸	۰/۶۶	۲/۶	۰/۶۴۰	۲/۰۳
MLP31	۰/۷۷۲	۱/۴۲	۰/۷۲۱	۲/۴	۰/۵۸۲	۲/۶۶
MLP32	۰/۷۶۷	۱/۴۱	۰/۷۴	۲/۴۵	۰/۰۷	۲/۸۱
MLP33	۰/۷۷	۱/۴۱	۰/۷۲۹	۲/۷۵	۰/۷۱۸	۲/۵
MLP34	۰/۷	۱/۳۹	۰/۶۷	۲/۳۱	۰/۶۲۸	۲/۴۵
MLP35	۰/۸۹	۱/۳۹	۰/۷۱۸	۲/۴۵	۰/۶۶۹	۲/۰۲

جدول ۴ - نتایج شبکه‌های عصبی توابع پایه شعاعی مورداًزمون در ایستگاه‌های مورد مطالعه


ماخذ: نگارندگان، ۱۳۹۲

نام شبکه	کرمان		بافت		میانده جیرفت	
	R	RMSE	R	RMSE	R	RMSE
RBF3	۰/۷۴۴	۰/۰۳۱	۰/۲۴۳	۰/۰۰۹	۰/۷۵۲	۰/۰۳۱۶
RBF8	۰/۷۵۳	۰/۰۴۴	۰/۷۱۷	۰/۰۲۶	۰/۷۳۳	۰/۰۳
RBF12	۰/۷۶۴	۰/۰۱	۰/۷۱	۰/۰۵	۰/۷۴۳	۰/۰۳۱۶
RBF16	۰/۶۹۹	۰/۰۳۱۶	۰/۷۲۲	۰/۱۶۴	۰/۷۶۹	۰/۰۲
RBF17	۰/۷۶	۰/۰۱	۰/۷۴۶	۰/۰۸۸	*	*
RBF18	۰/۷۹۱	۰/۰۳۱۶	۰/۶۹۴	۰/۰۸	۰/۷۶۳	۰/۰۳۱۶
RBF21	۰/۰۳۷	۰/۰۱	۰/۶۱۱	۰/۰۳۵	۰/۵۸۱	۰/۰۲۲۳
RBF22	۰/۸	۰/۰۶۰	۰/۷۷۴	۰/۰۳۹	۰/۷۸۵	۰/۰۳۱
RBF23	۰/۵۶	۰/۰۵۴۷	۰/۶۳۹	۰/۰۳۷	۰/۶۵۴	۰/۰۳۱
RBF24	۰/۷۳۷	۰/۰۴۸	۰/۷۸۷	۰/۰۷۷	*	*
RBF26	۰/۸۰۸	۰/۰۶	۰/۷۸۵	۰/۰۷۶	۰/۷۹۳	۰/۰۲۲۶
RBF27	۰/۰۶۳	۰/۰۳۱	۰/۶۳۴	۰/۰۶۱	۰/۶۰۱	۰/۰۲۴
RBF28	۰/۷۴۹	۰/۰۳۱	۰/۶۹۳	۰/۰۷۲۱	*	*
RBF29	۰/۰۶۹	۰/۰۱۰۰	۰/۶۴۸	۰/۰۷	۰/۷۴۱	۰/۰۱۴۱
RBF30	۰/۸۲۱	۰/۰۲۶	۰/۸۱۲	۰/۰۸	۰/۸۳۷	۰/۰۱۹۲
RBF31	۰/۸۷۸	۰/۰۵	۰/۸۵	۰/۱۰۰	*	*
RBF32	۰/۸۱۴	۰/۰۲۳	۰/۸۰۵	۰/۰۹۱۶	۰/۸۴۰	۰/۰۱۴
RBF33	۰/۸۹۲	۰/۰۱	۰/۸۶	۰/۰۳۰	*	*
RBF34	۰/۸۶۶	۰/۰۹	۰/۸۲۷	۰/۰۳۸۷	۰/۸۲	۰/۰۳۶
RBF35	۰/۹۰۷	۰/۰۱۴	۰/۸۷۴	۰/۲۰۵	*	*


۵. ۴. شبیه‌سازی بارش با MLP و RBF

بین داده‌های پیش‌بینی شده^۱ (خروجی شبکه) و داده‌های واقعی^۲ (میزان بارش روزانه)، به ترتیب توسط MLP و RBF در سه ایستگاه یادشده، شبیه‌سازی شد و سپس، همپوشانی‌ها مشخص گردیدند (شکل‌های ۳ تا ۸). (بازه زمانی روزهایی که در شکل‌های ۳ تا ۸ و جدول ۵ وجود دارد، به لحاظ کثرت داده‌های گزینشی است).

همپوشانی‌ها، در شبکه عصبی RBF، در هر سه ایستگاه، بسیار دقیق‌تر از MLP هستند (شکل‌های ۶ تا ۸).




شکل ۳ - مقایسه نتایج شبکه عصبی (Expected) با داده‌های واقعی (Observed) در مدل MLP34 کرمان و ضریب همبستگی بین آنها
ماخذ: نگارندگان، ۱۳۹۲




شکل ۴ - مقایسه نتایج شبکه عصبی (Expected) و داده‌های واقعی (Observed) در مدل MLP33 بافت و ضریب همبستگی بین آنها
ماخذ: نگارندگان، ۱۳۹۲

1. Expected
2. Observed




شکل ۵ - مقایسه نتایج شبکه عصبی (Expected) و داده‌های واقعی (Observed) در مدل MLP33 میانده
جیرفت و ضریب همبستگی بین آنها

مأخذ: نگارندگان، ۱۳۹۲




شکل ۶- مقایسه نتایج شبکه عصبی (Expected) و داده‌های واقعی (Observed) در مدل RBF35 کرمان
و ضریب همبستگی بین آنها

مأخذ: نگارندگان، ۱۳۹۲



شکل ۷- مقایسه نتایج شبکه عصبی (Expected) و داده‌های واقعی (Observed) در مدل RBF35 بافت و
ضریب همبستگی بین آنها

مأخذ: نگارندگان، ۱۳۹۲



شکل ۸- مقایسه نتایج شبکه عصبی (Expected) و داده‌های واقعی (Observed) در مدل RBF33 میانده

جیرفت و ضریب همبستگی بین آنها

مأخذ: نگارندگان، ۱۳۹۲

جدول ۵- خروجی شبکه توسط بهترین مدل RBF و بارش واقعی در ایستگاه کرمان

مأخذ: نگارندگان، ۱۳۹۲

سال	ماه	بروز	بررسی واقعی	RBF35 بررسی شبکه	سال	ماه	بروز	بررسی واقعی	RBF35 بررسی شبکه
۱۹۹۵	۲	۱	۰	۰/۰۵	۲۰۰۷	۲	۱	۰	۰/۱۶
۱۹۹۶	۲	۱	۰	۰/۰۵	۲۰۰۸	۲	۱	۰	۰/۰۷
۱۹۹۷	۲	۱	۰	۰/۰۵	۲۰۰۹	۲	۱	۱	۱/۴۸
۱۹۹۸	۲	۱	۰	۰/۰۵	۲۰۱۰	۲	۱	۰	۰/۰۶
۱۹۹۹	۲	۱	۰	۰/۰۵	۲۰۱۱	۲	۱	۴۱	۴۱/۰۰
۲۰۰۰	۲	۱	۰	۰/۰۵	۲۰۱۲	۲	۱	۷۴	۷۶/۲
۲۰۰۱	۲	۱	۰	۰/۰۵	۲۰۱۲	۱۲	۲	۱۷۱	۱۷/۱۰
۲۰۰۲	۲	۱	۰	۰/۰۵	۲۰۱۲	۱۲	۲	۰	۰/۰۰
۲۰۰۳	۲	۱	۰	۰/۰۵	۲۰۱۲	۱۲	۲	۰	۰/۰۵
۲۰۰۴	۲	۱	۰	۰/۰۶	۲۰۱۲	۱۲	۲	۰	۰/۰۶
۲۰۰۵	۲	۱	۰	۰/۰۷	۲۰۱۲	۱۲	۳	۰	۰/۰۶
۲۰۰۶	۲	۱	۰	۰/۰۵	۲۰۱۲	۱۲	۳	۰	۰/۰۶

۶. نتیجه‌گیری و پیشنهادها

نتایج حاصل از این مطالعه نشان داد شبکه‌های عصبی RBF، از توانمندی بسیار زیادی برای شبیه‌سازی و پیش‌بینی بارش برخوردار هستند. میزان خطای کمتر و همبستگی بالاتر این شبکه دلیل این گفته می‌باشد. در هر سه ایستگاه، رطوبت نسبی از عوامل مؤثر در دقت خروجی شبکه بوده است. بهترین مدل ترکیبی در این مطالعه، در ایستگاه کرمان، مدل 35 RBF با $R = 0.907$ و $RMSE = 0.014$ با ترکیب رطوبت نسبی، کمینه و بیشینه دما، میانگین دما، جهت و سرعت باد و میانگین فشار شناخته شد که نشان‌دهنده دقت زیاد پیش‌بینی بارش در این مدل می‌باشد. در بافت نیز مدل 35 RBF با همان ترکیب بالا به عنوان مدل برتر با ضریب همبستگی یا $R = 0.874$ و $RMSE = 0.205$ در این ایستگاه شناسایی شد و در ایستگاه میانده جیرفت نیز RBF 33 با ترکیب رطوبت نسبی، کمینه و بیشینه دما، میانگین دما، جهت و سرعت باد، ($R = 0.882$ و $RMSE = 0.036$) بهترین سیگنال‌های ورودی این ایستگاه شناخته شد. در ایستگاه کرمان، بهترین عامل که باعث بالارفتن کارایی شبکه می‌شود، عامل رطوبت نسبی است که با ترکیب با پارامتر دما بهترین کارایی را دارد که در مدل‌های $10, 14, 17, 18, 22, 26, 30$ تا 30 (R کسب شده بالای 0.8)، این موضوع به خوبی نمایان است. همچنین، با افزایش میزان ورودی‌های تأثیرگذار، دقت شبکه افزایش یافته است.. در بافت، علاوه بر رطوبت نسبی، جهت باد و میانگین فشار در ترکیب با رطوبت، باعث بالارفتن میزان کارایی شبکه شدند که در مدل‌های $16, 22, 30$ و 32 در شبکه RBF در این ایستگاه، نشان داده شده‌اند. در میانده جیرفت نیز عامل سرعت باد باعث کاهش کارایی شده است و جهت باد و رطوبت نسبی از عوامل تأثیرگذار بوده‌اند (مدل‌های $5, 10, 14, 17, 19, 24, 28, 31$ و 35).

بارش روزانه توسط MLP و RBF در کرمان، بافت، میانده جیرفت شبیه‌سازی شد. همپوشانی بین داده‌های پیش‌بینی شده و واقعی در شبکه RBF در هر سه ایستگاه، بسیار دقیق‌تر از شبکه MLP است. با توجه به نتایج شبیه‌سازی مشخص است که با وجود یکسان‌بودن نمونه‌های ورودی - خروجی به کاررفته در تعلیم هر دو، شبکه عصبی از نوع RBF بهتر تعلیم دیده است و دارای عملکرد بسیار بهتری می‌باشد؛ دلیل امر این است که شبکه عصبی پرسپترون، توانایی پیش‌بینی دقیق مجموعه داده‌هایی که با زمان تغییر می‌کنند را ندارد (مثل بارندگی‌های مناطق خشک).

نتایج شبکه‌های عصبی RBF نشان داد شبکه‌های عصبی از دقت کافی برای پیش‌بینی و تخمین بارش برخوردار هستند. همچنین، با توجه به جدول (۵)، نمونه داده‌ها تخمین زده شد و با مقایسه آن‌ها با حالت‌های واقعی، دقت و برتری شبکه‌های عصبی در مدل‌سازی بارش تأیید گردید.

شبکه‌های RBF برای آموزش، نیاز به تعداد نرون‌های زیادی دارند. عملکرد این شبکه‌ها نیز در صورت استفاده از تعداد بردارهای آموزشی زیاد، به بهترین وجه انجام می‌شود. در این شبکه‌ها، برخلاف شیوه رایج در شبکه‌های دیگر، به تمام فضای ورودی به‌طور یکسان پاسخ داده نمی‌شود. در اینجا، ابتدا مرکز فضای ورودی محاسبه می‌شود و سپس، به ورودی‌هایی که به اندازه کافی به این مرکز نزدیک باشند، پاسخ داده می‌شود. بهمین دلیل، در مقابل افت و خیزهای بارش مقاوم می‌باشد. همانطورکه در این تحقیق مشاهده شد، عملکرد این شبکه در هر سه ایستگاه، از میزان خطای کم و دقت مناسبی برخوردار بوده است.

هر سال سیل و بارندگی‌های رگباری و خشکسالی‌های اخیر در مناطق بافت، جیرفت و سایر مناطق جنوبی، خسارات مالی و جانی برای کشاورزان و دامداران منطقه به‌همراه دارند. با توجه به این مطلب، توصیه می‌گردد تا سازمان‌های مربوط به منابع آب، از نتایج پیش‌بینی و مدل‌سازی فرایند بارش توسط شبکه بهینه این تحقیق، برای برنامه‌ریزی جهت مدیریت ریسک استفاده نمایند.

کتابنامه

۱. اژدرپور، م. (۱۳۸۷). پیش‌بینی رابطه بارش رواناب به روش شبکه عصبی مصنوعی در حوضه آبریز رودخانه اعظم هرات (پیان‌نامه کارشناسی ارشد متشرنشده). دانشگاه یزد، یزد، ایران.
۲. افخمی، ح.، دستورانی، م. ت.، ملکی‌نژاد، ح.، و میین، م. ح. (۱۳۸۹). بررسی تأثیر عناصر اقلیمی بر افزایش دقت روش شبکه عصبی مصنوعی در پیش‌بینی خشکسالی منطقه یزد. علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، ۱۴ (۳۹)، ۵۱-۱۵۸.
۳. بنی‌حییب، م. ا.، ولی‌پور، م.، و بهبهانی، م. ر. (۱۳۸۹). مدل شبکه عصبی برای بررسی همبستگی روزانه بین ایستگاه‌ها در پیش‌بینی جریان ورودی به سد دز. مجله پژوهش آب ایران، ۴ (۷)، ۳۲-۲۵.
۴. حلیان، ا. م. (۱۳۸۸). پیش‌آگاهی و برآورد بارش یزد با استفاده از شبکه عصبی مصنوعی. نشریه تحقیقات کاربردی علوم جغرافیا، ۱۱ (۱۴)، ۲۸-۸.

۵. خسروی، م.، و شکیبا، ه. (۱۳۸۹). پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی به منظور مدیریت سیل ایرانشهر. *مجموعه مقالات چهارمین کنگره بین‌المللی جغرافیا انان جهان اسلام* (صص. ۲۱۲)، تبریز: انتشارات دانشگاه تبریز.
۶. خلیلی، ن.؛ خداشناس، س.، ر.، داوری، ک.، موسوی بایگی، م.، (۱۳۸۹)، پیش‌بینی بارش روزانه با شبکه‌های عصبی مصنوعی، مطالعه موردی: ایستگاه سینوپتیک مشهد. *پژوهش‌های آبخیزداری*، ۲۳(۴)، ۸-۱۵.
۷. خوشحال‌دستجردی، ج. (۱۳۸۹). کاربرد شبکه عصبی مصنوعی در شبیه‌سازی عناصر اقلیمی و پیش‌بینی سیکل خشکسالی استان اصفهان. *مجله جغرافیا و برنامه‌ریزی محیطی*، ۲۱(۳۹)، ۱۷۰-۱۲۰.
۸. دهقانی، ا.ا، پیری، م.، حسام، م.، و دهقانی، ن. (۱۳۸۹). تخمین تبخیر روزانه از تشت تبخیر با استفاده از سه شبکه عصبی پرسپترون چندلایه، تابع پایه شعاعی و المانی. *مجله پژوهش‌های حفاظت آب و خاک*، ۲۰(۱۷)، ۴۹-۶۹.
۹. صداقت، م. (۱۳۸۳). *منابع و مسائل آب در ایران*. تهران: انتشارات دانشگاه پیام نور.
۱۰. قلی‌زاده، م.ح.، و دارند، م. (۱۳۸۸). پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مورد تهران). *مجله پژوهش‌های جغرافیای طبیعی*، ۷۱، ۶۳-۵۱.
۱۱. کاکوئی، ع.ا، مسیحی، م.، و شیرانی، م. (۱۳۹۱). کاربرد شبکه‌های عصبی RBF و PNN در تعیین رخساره‌های یکی از میدان‌های گازی جنوب ایران. *نشریه علوم زمین*، ۲۱(۸۴)، ۱۵۲-۱۴۹.
۱۲. نعمتی، م.، و رعنایی، ا. (۱۳۸۹). بررسی عملکرد شبکه‌های عصبی مصنوعی در پیش‌بینی احتمال خشکسالی و ترسالی محدوده شهرستان مشهد با توجه به آمار بارندگی. *مجموعه مقالات همایش ملی الگوهای توسعه پایدار در مدیریت آب* (صص. ۶۲۷-۶۳۶)، مشهد: انتشارات شرکت مهندسین مشاور مهاب ثامن.
13. Diaconescu, E. (2008).The use of NARX neural networks to predict chaotic time series. *Wseas Transactions on Computer Research*, 3(3), 182-191.
14. Hall, T., Brooks, H.E., & Doswell, C. A. (1999). Precipitation forecasting using a neural network. *Weather and Forecasting*, 14, 338-345.
15. Hung, N. Q., Babel, M.S., Weesakul, S., & Tripathi, N. K. (2008). An artificial neural network model for rainfall forecasting in Bangkok, Thailand. *Hydrology and Earth System Sciences Discussions*, 5(1), 183-218.
16. Jayawardena, A. W., Fernando, D. A. K., & Zhou, M. C. (1997). Comparison of multilayer perceptron and radial basis function networks as tools for flood

- forecasting. In G.H. Leavwsley(Ed.),*Proceedings of the conference held at Anaheim*(pp. 173-265). California: IAHS Publ.
17. Maqsood, I., Riaz Khan, M., & Ajith, A. (2004). An ensemble of neural networks for weather forecasting. *Neural Computing & Applications*, 13(2), 112-122.
18. Santhanam, T., & Subhajini, A.C. (2011). An efficient weather forecasting system using Radial Basis Function Neural Network. *Journal of Computer Science*, 7(7), 962-966.
19. Siti, H.A., & Wibowo, A. (2011). Neural networks based on nonlinear time series regression for water level forecasting of Dungun River. *Journal of Computer Science*, 8(9), 1506-1513.
20. Shrivastava, G., Karmakar, S., & Kowar, M.M. (2012). Application of artificial neural networks in weather forecasting: A comprehensive literature review. *International Journal of Computer Applications*, 51(18), 17-29.