

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 میانه جیرفت)

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

komidvar@yazd.ac.ir

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

mnabavi93@yahoo.com

چکیده

اهداف: هدف این پژوهش، پیش‌بینی بارش روزانه با استفاده از آمار روزانه هواشناسی ایستگاه‌های کرمان، بافت و میانه 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، به‌عنوان ورودی‌های شبکه‌های عصبی مصنوعی و بارش روزانه به‌عنوان خروجی شبکه در نظر گرفته شدند.

یافته‌ها/ نتایج: نتایج نشان داد شبکه‌های عصبی مصنوعی 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، میانه جیرفت.

۱. مقدمه

کشور ایران با موقعیت جغرافیایی و اقلیم خاصی که دارد، سهم اندکی از ریزش‌های جوی به‌عنوان منبع اصلی تأمین‌کننده 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. در واقع، تأثیر عوامل محسوس و غیرمحسوس به‌قدری 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 به‌عنوان یک فرایند نامنظم اهمیت دارد، شبکه‌های عصبی مصنوعی ANN^۱ است که به‌عقیده کارشناسان، علت اصلی پذیرش و استفاده روزافزون از آن، قدرت و سرعت زیاد در شبیه‌سازی 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 پرسپترون^۳، به شبیه‌سازی و تخمین بارش پرداخته شود و سپس، مقایسه‌ای بین پاسخ دو شبکه ذکر شده انجام گیرد تا مشخص گردد کدام شبکه کارایی و دقت بیشتر و خطای کمتری در پیش‌بینی بارش روزانه ایستگاه‌های مورد مطالعه دارد.

۲. پیشینه تحقیق

در سرزمین ایران، بارش به‌عنوان مهم‌ترین عنصر اقلیمی، همواره از پیچیدگی‌های خاصی برخوردار بوده است؛ به‌طوری‌که محققان بسیاری کوشیده‌اند تا در تحقیقات خود به تبیین دقیق این تغییرپذیری‌ها در حوزه‌های مختلف پردازند.

با توجه به اهمیت این موضوع، پژوهش‌های بسیاری در این زمینه انجام شده‌اند که در ادامه برخی از آن‌ها بیان می‌گردند. جایاوردنا، فرناندو، و ژو^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 آجی^۱ (۲۰۰۴، ص. ۱۱۴) به پیش‌بینی سرعت باد، رطوبت نسبی و دما برای ۲۴ ساعت آینده در کانادا و ساسکاتچوان جنوبی با استفاده از مدل‌های پیش‌بینی شبکه‌های عصبی پرداختند و به این نتیجه دست یافتند که مدل RBF نسبت به ERNN و MLP، برای پیش‌بینی سرعت باد، رطوبت نسبی و دما دقت بیشتری دارد.

سان‌تانم و ساب حاجینی^۲ (۲۰۱۱، ص. ۹۶۲) به ارزیابی اقلیم و پیش‌بینی کارآمد آب‌وهوا با استفاده از RBF پرداختند. آن‌ها به این نتیجه رسیدند که این شبکه با دقت حدود ۸۷/۴۹٪ به پیش‌بینی پرداخته است. شریورتایو و کارماکار و کووار^۳ (۲۰۱۲، ص. ۱۷) با استفاده از شبکه‌های عصبی RBF و PB، به پیش‌بینی رفتار نامنظم باران موسمی 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 رخساره‌های یکی از میدان‌های گازی جنوب ایران پرداختند و توانمندی زیاد این شبکه‌ها را در تعیین رخساره‌ها تأیید کردند.

در این زمینه پژوهش‌های مشابه دیگری از جمله نعمتی و رعنائی (۱۳۸۶)، اژدرپور (۱۳۸۷)، حلیان (۱۳۸۸)، خوشحال‌دستجردی (۱۳۸۹)، افخمی، دستورانی، ملکی‌نژاد، و مبین (۱۳۸۹)، خسروی و شکیا (۱۳۸۹)، بنی‌حبیب، ولی‌پور، و بهبهانی (۱۳۹۰)، خلیلی، خدانشناس، دواری، و موسوی بایگی (۱۳۸۹)،

1. Maqsood, Riaz Khan, & Ajith

2. Santhanam & Subhajini

3. Shrivastava, Karmakar, & Kowar

هال، بروکس، و دازل^۱ (۱۹۹۹)، هونگ، بیبل، ویزاکول، و تریپاسی^۲ (۲۰۰۸)، دیاکونزو^۳ (۲۰۰۸)، سیتی و ویبوو^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. بدین منظور، 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، به‌عنوان سیگنال‌های ورودی و بارش روزانه به‌عنوان 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 مدلی که توانسته‌اند مقدار R ، $0/6$ 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

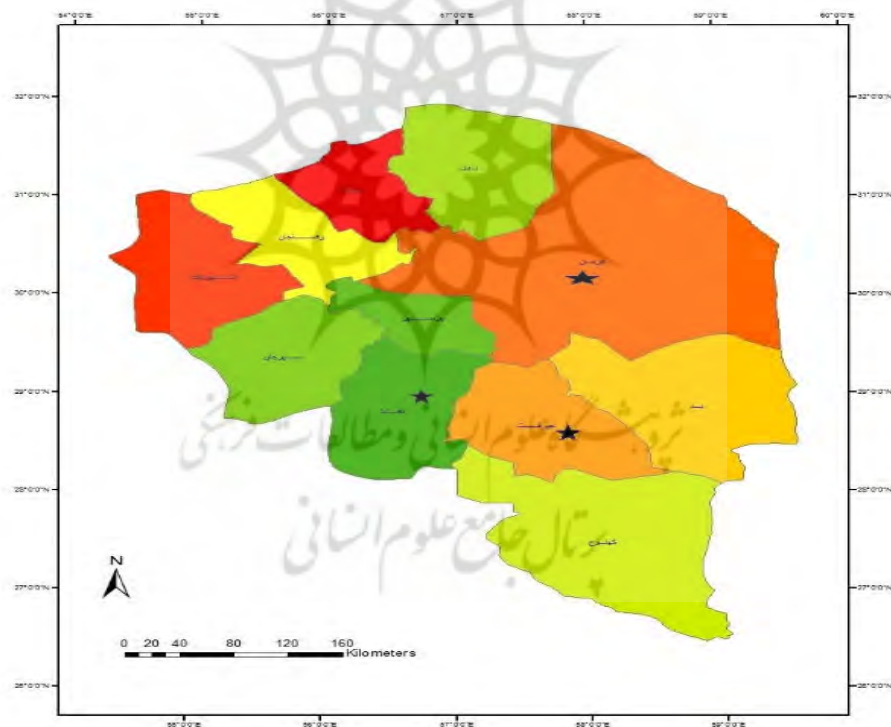
مأخذ: نگارندگان، ۱۳۹۲

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

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

۲.۳. منطقه مورد مطالعه

استان پهناور کرمان با وسعت ۱۸۱۷۱۴ کیلومتر مربع در جنوب شرقی فلات ایران واقع شده است و به لحاظ وسعت، مقام اول دارد. از نظر طول جغرافیایی، استان کرمان در بین نصف‌النهارات $30^{\circ} 33'$ تا $54^{\circ} 30'$ شرقی و از نظر عرض جغرافیایی، در بین مدارات $26^{\circ} 32' 8''$ تا 32° شمالی، واقع شده است. ایستگاه‌های مورد مطالعه در این تحقیق، کرمان، بافت و میانه جیرفت می‌باشند (شکل ۱). شهر کرمان $1753/8$ متر از سطح دریا ارتفاع دارد و جزو مناطق خشک است. شهرستان بافت 2280 متر از سطح دریا ارتفاع دارد و جزو مناطق کوهستانی و مرتفع‌ترین شهر استان است. شهرستان جیرفت، با ارتفاع 601 متر از سطح دریا، جزو مناطق گرمسیری در استان محسوب می‌شود. علت انتخاب این سه ایستگاه، آب‌وهوای متفاوت است تا تأثیر این تفاوت در خروجی شبکه‌های عصبی مشاهده شود.



شکل ۱- موقعیت جغرافیایی ایستگاه‌های مورد مطالعه

مأخذ: نگارندگان، ۱۳۹۲

جدول ۲- مدل‌های ورودی ساخته‌شده

مأخذ: نگارندگان، ۱۳۹۲

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

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 (ازدرپور، ۱۳۸۷، ص. ۲۵).

۴.۱. شبکه عصبی چندلایه پرسپترون (MLP)

این نوع مدل ANN همراه با الگوریتم پس‌انتشار خطا، یکی از پرکاربردترین انواع شبکه عصبی است که می‌تواند 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 پس‌انتشار، به صورت تحت‌نظارت تنظیم می‌گردند تا الگوی مناسب به وجود آید (جایاوردنا 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 خوشه‌ابزاری^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 پس‌انتشار خطا 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 خطا که مجموع وزن دار نرون‌های رسیده به نرون لایه میانی به- عنوان ورودی تابع تحریک محاسبه می شوند، در اینجا فاصله بین هر الگو با بردار مرکز هر نرون در لایه میانی، به عنوان ورودی تابع تحریک شعاعی محاسبه می شوند. در فضای چندبعدی، 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 می کند. به دلیل انتخاب تابع گوسی در نرون‌های لایه میانی، این شبکه مسائل دسته بندی را به خوبی حل می کند؛ زیرا، به صورت شعاعی می تواند الگوها را بر روی دوایر متحدالمرکزی 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 خطا است و به همین دلیل می توان از الگوریتم‌های بهینه سازی خطی استفاده کرد که سرعت پردازش را زیاد می کنند و همچنین، از افتادن در چاله‌های موضعی جلوگیری می کنند (دهقانی و همکاران، ۱۳۸۹، ص. ۵۶).

۴.۳. توابع انتقال مورد استفاده

توابع 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 شبیه سازی بارش با تعداد چرخش^۱ ۱۰۰۰ بار انجام گرفت. میزان نرون‌های لایه مخفی متناسب با $n2$ طراحی شد که n ، متناسب با تعداد عوامل ورودی به مدل می باشد و در RBF، دو پارامتر عدد گسترش، ϵ و عدد هدف، صفر هستند. در نهایت، برای ارزیابی نتایج از دو عامل جذر ضریب کارایی^۲ (R) و مجذور میانگین مربعات خطا (RMSE)^۳ استفاده گردید. برای ۳۵ مدل ترکیبی، مجذور میانگین مربعات خطا و ضریب همبستگی برای ارزیابی تأثیر آن‌ها محاسبه شدند.

1. Epoch
2. Coefficient of efficiency
3. Root Mean Square Error

۵.۱. ارزیابی نتایج شبکه عصبی MLP

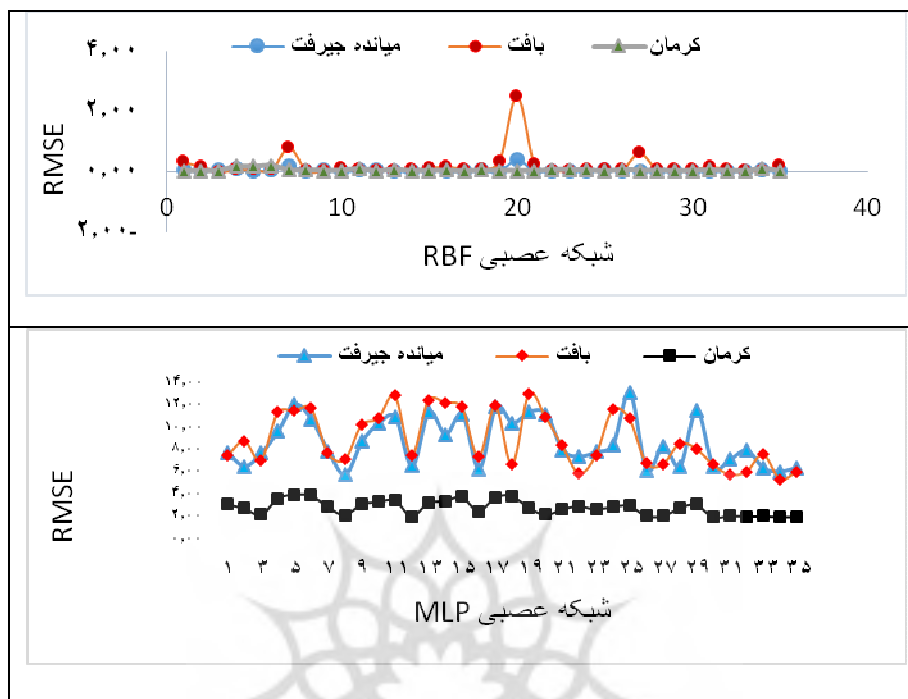
در این نوع شبکه، مدل‌هایی که توانسته‌اند ضریب همبستگی 0.7 و بیشتر را به دست آورند، به عنوان ورودی‌های مؤثر معرفی می‌شوند که رطوبت نسبی از تأثیر زیادی برخوردار است (جدول ۳).

۵.۲. 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 0.7 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، افت‌واخیز بارش کمتر از دو ایستگاه دیگر است (شکل ۲).

۵.۳. ارزیابی نتایج شبکه عصبی RBF

بهترین مدل ترکیبی RBF در ایستگاه کرمان، RBF35 مشاهده شد. با میزان R ، 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 ، 0.882 و $RMSE$ ، 0.336 ، بهترین سیگنال‌های ورودی این ایستگاه شناخته شد. در کرمان، بهترین عامل که باعث زیاد شدن کارایی شبکه شد، رطوبت نسبی می‌باشد که با ترکیب 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). تاحدزادی 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 مورد مطالعه^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	۰/۵۵	۲/۷۷
MLP8	۰/۶۵۵	۱/۴۵	۰/۶۲۱	۲/۶۶	۰/۶۷۶	۲/۳۹
MLP12	۰/۶۷۲	۱/۴۱	۰/۶۱۴	۲/۷۴	۰/۵۱۶	۲/۵۵
MLP16	۰/۵۸۵	۱/۵۷	۰/۶۴۱	۲/۷۱	۰/۶۱	۲/۵
MLP20	۰/۶۷۸	۱/۴۷	۰/۰۰۳	۳/۳	*	۲/۸۲
MLP21	۰/۴۷۳	۱/۶۲	۰/۶۰۴	۲/۸۹	۰/۵۱۳	۲/۷۱
MLP22	۰/۴۸۳	۱/۷	۰/۶۷۸	۲/۴۲	۰/۶۲۳	۲/۷۹

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

MLP26	۰/۶۸۱	۱/۴۲	۰/۶۵۵	۲/۶	۰/۶۳۳	۲/۴۲
MLP27	۰/۶۵۱	۱/۴۲	۰/۶۶۸	۲/۵۸	۰/۵۵۷	۲/۸۸
MLP30	۰/۶۸۱	۱/۳۸	۰/۶۶	۲/۶	۰/۶۴۵	۲/۵۳
MLP31	۰/۶۷۲	۱/۴۲	۰/۷۲۱	۲/۴	۰/۵۸۲	۲/۶۶
MLP32	۰/۶۶۷	۱/۴۱	۰/۶۷۴	۲/۴۵	۰/۵۷	۲/۸۱
MLP33	۰/۶۷۷	۱/۴۱	۰/۷۲۹	۲/۷۵	۰/۷۱۸	۲/۵
MLP34	۰/۷	۱/۳۹	۰/۶۶۷	۲/۳۱	۰/۶۲۸	۲/۴۵
MLP35	۰/۶۸۹	۱/۳۹	۰/۷۱۸	۲/۴۵	۰/۶۶۹	۲/۵۲

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

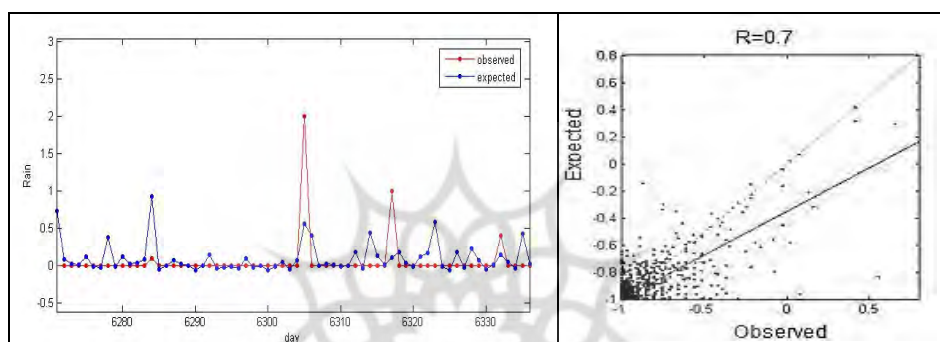
مأخذ: نگارندگان، ۱۳۹۲

نام شبکه	کرمان		بافت		میانده جیرفت	
	R	RMSE	R	RMSE	R	RMSE
RBF3	۰/۷۴۴	۰/۰۳۱	۰/۲۴۳	۰/۰۰۰۹	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	۰/۷۶۶	۰/۰۱	۰/۷۴۶	۰/۰۸۸	*	*
RBF18	۰/۶۹۱	۰/۰۳۱۶	۰/۶۹۴	۰/۰۸	۰/۷۶۳	۰/۰۳۱۶
RBF21	۰/۵۳۷	۰/۰۱	۰/۶۱۱	۰/۲۳۵	۰/۵۸۱	۰/۰۲۲۳
RBF22	۰/۸	۰/۰۶۵	۰/۷۷۴	۰/۰۳۹	۰/۷۸۵	۰/۰۳۱
RBF23	۰/۵۶	۰/۰۵۴۷	۰/۶۳۹	۰/۰۳۷	۰/۶۵۴	۰/۰۳۱
RBF24	۰/۶۳۷	۰/۰۴۸	۰/۶۸۷	۰/۰۷۷	*	*
RBF26	۰/۸۰۸	۰/۰۶	۰/۷۸۵	۰/۰۷۶	۰/۷۹۳	۰/۰۲۳۶
RBF27	۰/۵۶۳	۰/۰۳۱	۰/۶۳۴	۰/۰۶۱	۰/۶۵۱	۰/۰۲۴
RBF28	۰/۶۴۹	۰/۰۳۱	۰/۶۹۳	۰/۰۷۲۱	*	*
RBF29	۰/۵۶۹	۰/۰۱۵۵	۰/۶۴۸	۰/۰۷	۰/۶۴۱	۰/۰۱۴۱
RBF30	۰/۸۲۱	۰/۰۲۶	۰/۸۱۲	۰/۰۸	۰/۸۳۷	۰/۰۱۹۲
RBF31	۰/۸۷۸	۰/۰۵	۰/۸۵	۰/۱۵۵	*	*
RBF32	۰/۸۱۴	۰/۰۲۳	۰/۸۰۵	۰/۰۹۱۶	۰/۸۴۵	۰/۰۱۴
RBF33	۰/۸۹۲	۰/۰۱	۰/۸۶	۰/۰۳۵	*	*
RBF34	۰/۸۶۶	۰/۰۹	۰/۸۲۷	۰/۰۳۸۷	۰/۸۸۲	۰/۰۳۶
RBF35	۰/۹۰۷	۰/۰۱۴	۰/۸۷۴	۰/۲۰۵	*	*

۵. 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 وجود دارد، به دلیل 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

مأخذ: نگارندگان، ۱۳۹۲

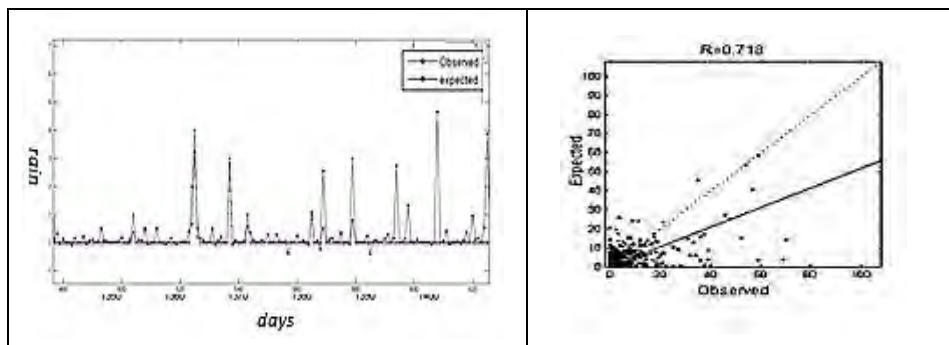


شکل ۴ - مقایسه نتایج شبکه عصبی (Expected) و داده‌های واقعی (Observed) در مدل MLP33 بافت و

ضریب همبستگی بین آنها

مأخذ: نگارندگان، ۱۳۹۲


1. Expected
2. Observed



شکل ۵- مقایسه نتایج شبکه عصبی (Expected) و داده‌های واقعی (Observed) در مدل MLP33 میانه

جیرفت و ضریب همبستگی بین آنها

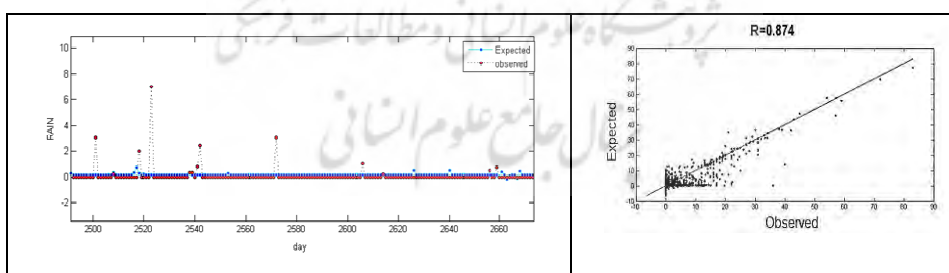
مأخذ: نگارندگان، ۱۳۹۲



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

و ضریب همبستگی بین آنها

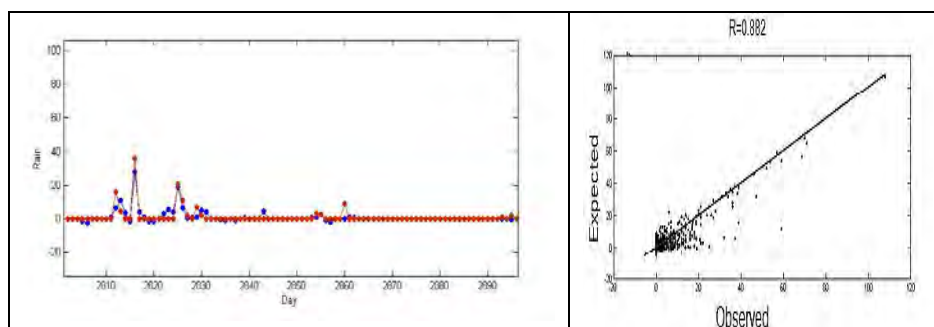
مأخذ: نگارندگان، ۱۳۹۲



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 میانه

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	روز	بارش واقعی	بارش پیش‌بینی RBF35	سال	ماه	روز	بارش واقعی	بارش پیش‌بینی RBF35
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	۶۴	۶۶۲
۲۰۰۱	۲	۱	۰	۰/۰۵	۲۰۱۲	۱۲	۲	۱۶/۱	۱۶/۱۰
۲۰۰۲	۲	۱	۰	۰/۰۵	۲۰۱۲	۱۲	۲	۰	۰/۰۵
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 RBF 35 با $R=0.907$ و با $RMSE=0.014$ 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 RBF 35 با همان ترکیب بالا به‌عنوان مدل برتر با ضریب همبستگی $R=0.874$ و $RMSE=0.205$ در این ایستگاه شناسایی شد و در ایستگاه میانه جیرفت نیز RBF 33 با ترکیب رطوبت نسبی، کمینه و بیشینه دما، میانگین دما، جهت و سرعت باد، $R=0.882$ و $RMSE=0.336$ 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 ۳، ۸، ۱۲، ۱۷، ۱۸، ۲۲، ۲۶ تا ۳۰ (R کسب‌شده بالای ۰/۸)، این موضوع به‌خوبی 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 ۲۳، ۱۶، ۳۰ و ۳۲ در شبکه RBF در این ایستگاه، نشان داده شده‌اند. در میانه جیرفت نیز عامل سرعت باد باعث کاهش کارایی شده است و جهت باد و رطوبت نسبی از عوامل تأثیرگذار بوده‌اند (مدل‌های ۵، ۱۰، ۱۴، ۱۷، ۱۹، ۲۴، ۲۸، ۳۱ و ۳۵).

بارش روزانه توسط MLP و RBF در کرمان، بافت، میانه 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 یکسان بودن نمونه‌های ورودی - خروجی به‌کاررفته 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. به همین دلیل، در مقابل افت و خیزهای بارش مقاوم می‌باشد. همانطور که 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 به همراه 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 (پایان‌نامه کارشناسی ارشد منتشر نشده). دانشگاه یزد، یزد، ایران.
۲. افخمی، ح.، دستورانی، م. ت.، ملکی‌نژاد، ح.، و مبین، 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. بنی‌حیب، 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. حلییان، ا. م. (۱۳۸۸). پیش‌آگاهی و برآورد بارش یزد با استفاده از شبکه عصبی مصنوعی. نشریه تحقیقات کاربردی علوم جغرافیا، ۱۱ (۱۴)، ۸-۲۸.

۵. خسروی م.، و شکبیا، ه. (۱۳۸۹). پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی به‌منظور مدیریت سیل ایران‌شهر. *مجموعه مقالات چهارمین کنگره بین‌المللی جغرافیدانان 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 آب‌بخیزداری*، 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 تخییر روزانه از تشت تخییر با استفاده از سه شبکه عصبی پرسپترون چندلایه، تابع پایه شعاعی و المانی. *مجله پژوهش‌های حفاظت آب و خاک*، ۱۷(۲)، 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 رعنائی، ا. (۱۳۸۶). 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 مهندسی مشاور مهتاب نامن.
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*, 144, 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. *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. 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.
20. Siti, H. A., & Wibowo, A. (2011). Neural networks based nonlinear time series regression for water level forecasting of Dungun river. *Journal of Computer Science*, 8(9), 1506-1513.

