

مدل سازی بارندگی ماهیانه به کمک شبکه عصبی مصنوعی پرسپترون چندلایه مطالعه موردی؛ ایستگاه‌های استان کردستان

مهنا تاج‌نسائی^۱، احسان جعفری‌ندوشن^۲

۱- گروه مهندسی عمران، واحد بیجار، دانشگاه آزاد اسلامی، بیجار، ایران

۲- استادیار گروه مهندسی عمران، واحد بیجار، دانشگاه آزاد اسلامی، بیجار، ایران

mtajnesaie@yahoo.com

خلاصه

بارش یکی از مهمترین و پیچیده‌ترین مسائل هیدرولوژی مورد توجه بسیاری از محققین است. این پدیده تحت تاثیر عوامل متعددی قرار داشته و همین امر سبب دشواری پیش‌بینی آن به کمک روش‌های متداول آماری است. یکی دیگر از مشکلات اساسی بررسی بارش، کمبود دوره‌های آماری مربوط به بارندگی در اکثر مناطق کشور است. بنابراین با توجه به اهمیت بارندگی در بسیاری از مطالعات اقلیمی و مدیریت منابع آب و همچنین کمبود اطلاعات در بیشتر مناطق کشور از جمله استان کردستان، در این پژوهش سعی در بکارگیری شبکه عصبی مصنوعی در مدل‌سازی بارندگی در این استان گردیده است. به همین منظور با در نظر گرفتن یک دوره‌ی آماری ۲۴ ساله برای سه ایستگاه سنندج، سقز و بیجار در استان کردستان، با دوره آماری طولانی‌تر نسبت به سایر ایستگاه‌ها، از شبکه عصبی مصنوعی MLP و نرم‌افزار MATLAB بهره‌گرفته و با سه روش آموزش مختلف داده‌ها تعلیم داده شدند. نتایج بررسی حاکی از بهینه‌بودن مدل پرسپترون چندلایه با شیوه‌ی آموزشی ممتد در تمامی ایستگاه‌ها می‌باشد.

کلمات کلیدی: مدل‌سازی بارندگی استان کردستان، شبکه عصبی مصنوعی پرسپترون، آموزش ممتد، آموزش مجذور گرادبان، آموزش مارکوات-لونبرک.

۱. مقدمه

بارندگی یکی از اجزای اصلی چرخه‌ی هیدرولوژی است که به عوامل متعدد اقلیمی وابسته است. بارندگی در مدیریت منابع آب به ویژه در مناطق خشک و نیمه خشک نقش اساسی داشته و مدل‌سازی این متغیر هیدرولوژیکی گامی بسیار مهم در راستای برنامه‌ریزی بهتر منابع آب و کشاورزی خواهد بود [۱]. بارش یکی از مهمترین داده‌های ورودی به سیستم‌های هیدرولوژیکی محسوب می‌شود که مطالعه و اندازه‌گیری آن در اکثر موارد برای مطالعات رواناب، آبهای زیرزمینی، سیلاب، رسوب و ... لازم می‌باشد [۲]. در دهه‌های اخیر با توجه به رشد جمعیت جهان و همچنین افزایش مصرف سرانه آب، کمبود آب شیرین قابل استحصال به معضلی جهانی تبدیل گشته است. از این رو با توجه به محدود بودن منابع آب، مدیریت صحیح و بهینه‌ترین وظیفه سیاستگذاران و مهندسين منابع آب می‌باشد. [۳]. در بسیاری از مطالعات اقلیمی و مدیریت منابع آب، مدل‌های هیدرولیکی، پیش-بینی سیلاب، مطالعات تغییر اقلیم، برآورد بیلان آب، برنامه‌ریزی‌های آبیاری و مانند آن، وجود داده‌های بارندگی و به خصوص توزیع مکانی آن (نقشه-های هم‌بارش)، اهمیت ویژه‌ای دارند. روش‌های مختلفی برای برآورد منطقه‌ای بارندگی در سطوح وسیع وجود دارد که از جمله مهمترین آنها، می‌توان به روش‌های زمین‌آماري اشاره کرد [۴]. در چند دهه اخیر، اغلب محققان برای پیش‌بینی و مدل‌سازی فرآیندهای هواشناختی و هیدرولوژیکی و تعیین خصوصیات سیلاب‌ها و خشکسالی‌ها از Auto رگرسیون چندمتغیره و مدل‌های زمین‌آمار استفاده کرده‌اند [۵، ۶، ۷]. این مدل‌ها در اغلب موارد نمی‌تواند به خوبی مسایل پیچیده اقلیمی-هیدرولیکی را تحلیل نمایند و ضروری است، مدل‌هایی با کارایی بیشتر به منظور پیش‌بینی پدیده‌ای غیرخطی و پیچیده معرفی شوند [۸]. بدین خاطر متخصصان و دانشمندان علم هیدرولوژی و سایر رشته‌های مرتبط در پی ایجاد مدل‌هایی مناسب، به منظور پیش‌بینی بهنگام این حوادث شده‌اند. ظهور تئوری‌های توانمندی، همچون الگوریتم‌های فازی شبکه عصبی و فیلتر آلمن، تحولی عظیم در تحلیل رفتار سیستم‌های دینامیک در علوم مختلف مربوط به آب ایجاد کرده است [۹]. شبکه‌های عصبی مصنوعی در چند دهه اخیر برای مدل‌سازی سیستم‌های پیچیده و غیرخطی قابلیت بسیار بالایی از خود نشان داده است. با توجه به محدودیت‌هایی از قبیل نبود اطلاعات بارش در مقیاس‌های مکانی و زمانی

و پیچیدگی‌های یاد شده عملاً استفاده از مدل‌هایی با مبنای فیزیکی مقدور نیست. امروزه شبکه‌های عصبی از ابزارهای جدیدی است که در سیستم‌های غیرخطی و نامعین که روابط بین اجزا و پارامترهای سیستم به خوبی شناخته شده و توصیف‌پذیر نمی‌باشند، قادر به تحلیل و شبیه‌سازی می‌باشند [۱۰]. چندی است که با پیشرفت‌های چشمگیر در زمینه‌های مختلف هوش مصنوعی از جمله شبکه‌های عصبی مصنوعی، توجه بسیاری از محافل علمی جهان در زمینه‌های مختلف علمی و مهندسی به این مقوله معطوف شده است. در همین راستا هیدرولوژیست‌ها نیز بر آن شدند تا فرایندهای پیچیده هیدرولوژیکی را با این تکنیک شبیه‌سازی کنند [۱۱]. به باور پژوهشگران، ANN به دو دلیل عمده در تحلیل مسائل ناشناخته و پیچیده، عملکرد خوبی از خود نشان می‌دهد، اول اینکه با برخورداری از قابلیت تشخیص الگو، رابطه‌ی خوبی بین ورودی و خروجی داده‌ها برقرار می‌کند. همچنین در قیاس با دیگر الگوها، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی از خود نشان می‌دهد [۱۲].

هاستینراس و همکاران (۱۹۹۵، ۱۵۱۱) از شبکه‌های عصبی مصنوعی جهت پیش‌بینی ریزش‌های جوی جنوب آفریقا در فصل تابستان استفاده کردند. نتایج ایشان نشان داد که تجزیه و تحلیل بارش در ارتباط با شاخص نوسان جنوبی تنها با روند غیرخطی شبکه‌های عصبی مصنوعی قابل پیش‌بینی است [۱۳]. هال و همکاران (۱۹۹۷، ۳۳۸) با بکارگیری گروه‌های متصل شبکه‌ای به پیش‌بینی بارندگی پرداختند، که مسیر ورودی و خروجی با مسیرهای بهم پیوسته عصبی سازماندهی شده بود و نشان دادند که میزان همبستگی بین بارش واقعی و بارش پیش‌بینی شده توسط شبکه‌های عصبی برابر با ۹۵ درصد می‌باشد. توکار و سنتون (۱۹۹۹، ۲۳۲) با استفاده از شبکه عصبی به پیش‌بینی بارش پرداختند نتایج نشان داد که مدل رواناب-بارش حاصل از شبکه‌های عصبی مصنوعی در مقایسه با دیگر روش‌های آماری دقت بیشتری داشته و زمان کمتری برای برازش مدل صرف می‌شود [۱۴]. کاوازوس (۱۷۱۸، ۲۰۰) با استفاده از شبکه‌های عصبی مصنوعی به پیش‌بینی بارش روزانه در منطقه موردنظر می‌باشد. ترافالیس و همکاران (۲۰۰۲، ۷۷۵) از شبکه‌های عصبی مصنوعی با معماری‌های مختلف مقادیر بارش را پیش‌بینی کردند [۱۵]. ایشان از داده‌های بارش رادار به عنوان داده‌های ورودی شبکه استفاده کردند و نتایج حاصل از برازش شبکه‌های عصبی مصنوعی با بعضی از روش‌های دیگر از جمله رگرسیون خطی و پولی نومیال مقایسه کردند و به این نتیجه رسیدند که شبکه‌های عصبی دقت بیشتری نسبت به دیگر روش‌ها دارد [۲]. ماریا و همکاران (۲۰۰۵) به کمک مدل‌های شبکه عصبی مصنوعی و رگرسیونی بارش منطقه سائوپولو برزیل را پیش‌بینی کردند. ایشان نشان دادند که برآورد دو مدل مذکور برای منطقه مورد مطالعه بسیار دقیق است [۱۶]. بوستامی و همکاران (۲۰۰۷) بارش و سطح آب را در بوداپ مالتزی با استفاده از تکنیک شبکه‌های عصبی مصنوعی پیش‌بینی کردند. نتایج ایشان نشان داد که شبکه‌های عصبی مصنوعی با دقت ۹۶/۴ درصد قابلیت پیش‌بینی بارش را در رودخانه مورد مطالعه دارد. هونگ و همکاران به کمک یکسری پارامترهای هواشناسی با بهره‌گیری از مدل‌های شبکه‌های عصبی مصنوعی به پیش‌بینی بارش در بانکوک پرداختند [۱]. جاتوپادھیای (۲۰۰۷، ۳۶۹) با استفاده از مدل پروسپترون چندلایه در شبکه‌های عصبی مصنوعی بارش فصلی هند را پیش‌بینی کرد. هونگ و همکاران (۲۰۰۸، ۱۸۳) به کمک یکسری پارامترهای هواشناسی با بهره‌گیری از مدل‌های شبکه عصبی مصنوعی به پیش‌بینی بارش پرداخت [۲]. داهامشه و آکسوی (۲۰۰۹) با استفاده از شبکه‌های عصبی مصنوعی بارش ماهانه مناطق خشک اردن را پیش‌بینی و برای این کار از الگوریتم پس‌انتشار رو به جلو استفاده و نتایج را با رگرسیون چند متغیره مقایسه کردند. نتایج نشان داد که شبکه‌های عصبی مصنوعی نتایج بهتری را نسبت به رگرسیون چند متغیره ارائه می‌کند. وانگ و شینگ (۲۰۱۰) بارش ژینگ ژوی چین را به کمک رگرسیون عمومی شبکه‌های عصبی پیش‌بینی کردند. نتایج حاکی از خطای پیش‌بینی کمتر رگرسیون عمومی شبکه‌های عصبی نسبت به شبکه‌های مصنوعی انتشار به عقب می‌باشد. کارین (۲۰۱۰) روش‌های رگرسیون چندمتغیره اسپیلین و شبکه‌های عصبی مصنوعی انتشار به عقب را برای پیش‌بینی بارش و دمای حوضه رودخانه مانارو مقایسه کرد. شافعی و همکاران (۲۰۱۱) از شبکه‌های عصبی مصنوعی برای پیش‌بینی بارش اسکندریه مصر استفاده و مدل شبکه‌های عصبی مصنوعی و مدل رگرسیون چندمتغیره را با هم مقایسه کردند. نتایج نشان داد که مدل شبکه‌های عصبی مصنوعی مناسبتر و دقیقتر است [۱]. کارآموز و همکاران (۱۳۸۵) بارش بلندمدت را با استفاده از سیگنال‌های هواشناسی و شبکه عصبی در جنوب شرقی ایران پیش‌بینی نمودند که نشان می‌دهد در ۷۰ درصد از سال‌ها، پیش‌بینی در دامنه تعریف شده قرار دارد [۱]. خلیلی (۱۳۸۵) با استفاده از شبکه‌های عصبی مصنوعی بارش ماهانه ایستگاه سینوپتیک مشهد را مطالعه کرد. نتایج نشان داد که شبکه‌های عصبی مصنوعی به خوبی روند بارش ماهانه را در ایستگاه مذکور پیش‌بینی می‌کند [۲]. مسیبی‌برزی و همکاران (۱۳۸۵) با استفاده از روش شبکه‌های عصبی مصنوعی و داده‌های ۵۲ سال یک ایستگاه سینوپتیک مدلی برای پیش‌بینی بارندگی ماهانه به دست آوردند. نتایج نشان داد این مدل قادر است میزان بارندگی ماهانه را با دقت قابل قبولی پیش‌بینی کند [۱۷]. گلایی و همکاران (۱۳۹۲) شبکه‌های MLP و RBF را با تغییراتی در تعداد لایه‌های میانی، تعداد نرون‌ها و الگوریتم‌های آموزش MOM و LM و CG به منظور پیش‌بینی بارش فصلی برای سه ایستگاه منتخب استان خوزستان به کار گرفتند. با توجه به استفاده از الگوریتم‌های آموزش مختلف مشاهده گردید که در هر سه ایستگاه الگوریتم لونبرگ - مارکواریت بهترین الگوریتم آزمایش بوده و همچنین با نرمال کردن داده‌ها می‌توان به نتایج بهتری جهت پیش‌بینی دست پیدا کرد [۱]. در این پژوهش قابلیت روش موردنظر در مدل‌سازی پدیده‌ی بارش در استان کردستان

مورد ارزیابی قرار گرفته است. اقلیم کردستان متأثر از توده‌های هوای گرم و مرطوب مدیترانه‌ای است که این توده‌ها موجب بارندگی‌های موقت در بهار و ریزش برف در زمستان می‌شود. جریان‌های آب و هوایی متأثر از اقیانوس اطلس و دریای مدیترانه که عامل عمده جوی در ایران به‌شمار می‌آیند، در عبور از کردستان و برخورد با ارتفاعات زاگرس، بخش قابل توجهی از رطوبت خود را به شکل باران و برف از دست می‌دهند به طوری که میانگین ریزش‌های سالانه در ارتفاعات کردستان حدود ۵۰۰ میلی‌متر گزارش شده است.

۲. معرفی منطقه مورد مطالعه

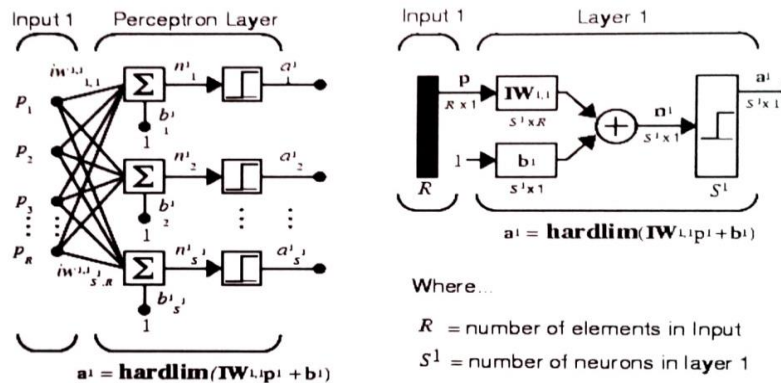
استان کردستان از استان‌های غربی ایران با ۲۸,۲۰۳ کیلومتر مربع مساحت است. این استان که در دامنه‌ها و دشت‌های پراکنده سلسله جبال زاگرس میانی قرار گرفته، از شمال به استان‌های آذربایجان غربی و زنجان، از شرق به همدان و زنجان، از جنوب به استان کرمانشاه و از غرب به کشور عراق محدود است. این استان به‌طور کلی تحت تأثیر دو جریان عمده هوای گرم و سرد قرار دارد و اقلیم‌های گوناگونی را به‌وجود می‌آورد. بیشترین میزان بارش جوی در ناحیه غربی استان حدود هشتصد میلی‌متر در سال، کمترین میزان بارندگی در ناحیه شرقی حدود چهارصد میلی‌متر در سال و در قسمت مرکزی استان نزدیک به پانصد میلی‌متر در سال است. جهت مدل‌سازی بارندگی فصلی در استان کردستان از میان ایستگاه‌های سینوپتیک موجود، سه ایستگاه که دارای دوره‌ی آماری طولانی‌تری نسبت به سایر ایستگاه‌ها می‌باشند، انتخاب شدند. این سه ایستگاه شامل ایستگاه سنندج، سفز و بیجار بوده که مشخصات جغرافیایی و آماری بارندگی ماهانه آنها مطابق جدول ۱ می‌باشد. طولانی‌ترین دوره‌ی آماری ۵۱ سال بین سال‌های ۱۹۶۰ تا ۲۰۱۰ بوده و مربوط به ایستگاه سنندج می‌باشد و کوتاه‌ترین دوره ۲۴ سال بین سال‌های ۱۹۸۸ تا ۲۰۱۰ و مربوط به ایستگاه بیجار می‌باشد. بنابراین طول دوره‌ی آماری مشترک بین این سه ایستگاه، دوره‌ی ۲۴ ساله مربوط به سال‌های ۱۹۸۸ تا ۲۰۱۰ در نظر گرفته شد.

جدول ۱- مشخصات جغرافیایی و آماری بارندگی ماهانه ایستگاه‌های منتخب

ایستگاه	طول	عرض	ارتفاع	حداکثر بارندگی	حداقل بارندگی	میانگین بارندگی
سنندج	47° 00' E	35° 20' N	1373.4 m	73.0 mm	0.0 mm	37.49 mm
سفز	46° 16' E	36° 15' N	1522.8 m	86.0 mm	0.0 mm	40.6 mm
بیجار	47° 37' E	35° 53' N	1883.4 m	51.0 mm	0.0 mm	28.28 mm

۳. شبکه عصبی مصنوعی

شبکه عصبی مصنوعی در واقع، مدل ساده شده‌ای از مغز انسان است که توانایی رخدادن فرآیندها و ترکیبات دلخواه غیرخطی برای ارتباط بین ورودی و خروجی‌های هر سیستمی را داراست، این شبکه با داده‌های موجود طی فرآیند یادگیری، آموزش داده می‌شود و به منظور پیش‌بینی در آینده استفاده می‌گردد. نرون‌های شبکه عصبی در حقیقت، شکل بسیار ساده از نرون‌های بیولوژیک هستند، ولی از توانایی کمتری نسبت به آنها برخوردارند [۹]. در دهه اخیر استفاده از شبکه‌های عصبی مصنوعی در شاخه‌های مختلف علوم مهندسی از جمله مهندسی آب رواج بسیاری یافته است، که دلیل این امر قابلیت این روش‌ها در شبیه‌سازی و تخمین توابع غیرخطی با دقت مناسب می‌باشد. در واقع شبکه‌های عصبی مصنوعی قادرند با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در بطن داده‌ها را فراگیرند (Toth et al., 2000). یکی از پر استفاده‌ترین این شبکه‌ها در مهندسی آب پرسپترون‌های چند لایه (MLP) با الگوریتم پس انتشار خطا (BP) می‌باشد (Coulibaly et al., 1999) [۳]. یک شبکه پرسپترون با چند نرون، به ازای هر نرون دارای یک مرز تصمیم بوده و با یک نرون توانایی طبقه‌بندی بردارهای ورودی را در دو دسته دارا می‌باشد. این در حالیست که یک شبکه پرسپترون با s نرون دارای توانایی طبقه‌بندی بردارهای ورودی در 2^s دسته می‌باشد. شبکه‌های پرسپترون از آن جهت که توانایی مناسبی جهت تکامل یافتن به وسیله‌ی بردارهای ورودی را دارند، بسیار شایان توجه می‌باشند. این شبکه‌ها مخصوصاً در حل مسائل ساده طبقه‌بندی بسیار مناسب هستند. این نوع شبکه عصبی در حل مسائل، بسیار سریع و قابل اطمینان است. شمایی از این شبکه در شکل (۱) نشان داده شده است. Wij در این شبکه به معنی میزان قدرت اتصال بین [امین ورودی با i امین ورودی است] [۱۸].



شکل ۱- معماری پرسپترون

منحصر به فردترین ویژگی شبکه عصبی که آن را در زمره روش‌های محاسباتی هوش مصنوعی قرار می‌دهد، آموزش‌پذیر بودن شبکه است. رفتار سیستم‌های آموزش‌پذیر توسط الگوریتم‌های بازگشتی بیان می‌شود. فرآیند یادگیری شبکه عصبی با تغییر و اصلاح در مقادیر ماتریس وزن‌ها و بردارهای بایاس آن صورت می‌پذیرد [۱۹]. در این تحقیق برای آموزش داده‌ها از میان شیوه‌های مختلف آموزش، سه شیوه متمم، گرادیان مزدوج و مارکورات-لونبرگ انتخاب، عملکرد آنها مقایسه و شیوهی آموزش بهینه تعیین گردید.

۳-۱ داده‌های ورودی و خروجی شبکه

داده‌های مورد نیاز جهت مدل‌سازی بارش با توجه به پدیده‌های مؤثر بر بارندگی از سایت هواشناسی تهیه اقدامات لازم نظیر نرمال‌سازی روی آنها صورت گرفت. هدف از نرمال‌سازی داده‌ها، کاهش از خطای مدل‌سازی شبکه است. وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. از این رو داده‌های ورودی به شبکه باید نرمال شوند. در این تحقیق برای نرمال‌سازی داده‌ها در بازه‌ی صفر و یک از رابطه‌ی (۱) بهره گرفته شد. که در این رابطه X_i مقدار نرمال شده داده، X مقدار واقعی، X_{\max} و X_{\min} به ترتیب مقادیر حداقل و حداکثر داده‌ها می‌باشد.

$$x_i = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

داده‌های مربوط به عواملی که احتمال تاثیر آنها بر روی پدیده‌ی مورد نظر وجود دارد برای تعیین الگوی ورودی مناسب به شبکه انتخاب گردید. در این میان داده‌های ورودی شامل شش نرون میانگین دمای نقطه‌ی شبنم، متوسط دمای میانگین روزانه، متوسط حداقل رطوبت نسبی، متوسط فشار، اختلاف دمای حداقل و حداکثر و متوسط حداکثر دما بوده و داده‌ی خروجی شامل نرون بارندگی ماهیانه می‌باشد.

۳-۲ شاخص‌های ارزیابی مدل‌ها

به منظور ارزیابی عملکرد شبکه در این تحقیق، از چهار شاخص آماری ضریب همبستگی (Correlation Coefficient)، ریشه میانگین مربعات خطا (Root Mean Square Error)، میانگین قدر مطلق خطا (Mean Absolute Error) و میانگین مجذور خطا (Mean Square Error) استفاده شده است. ضریب همبستگی (CORR) بیان‌کننده میزان همبستگی بین نتایج پیش‌بینی شده مدل و داده‌های واقعی می‌باشد که بر اساس رابطه (۲) محاسبه می‌شود. بدیهی است که هر چه مقدار آن به یک نزدیکتر باشد، نشان‌دهنده نزدیکی بیشتر مقادیر پیش‌بینی شده به مقادیر واقعی است [۲۰].

$$CORR = \frac{\sum_{i=1}^n (x_i^o - \bar{x}^o)(x_i^p - \bar{x}^p)}{\sqrt{\sum_{i=1}^n (x_i^o - \bar{x}^o)^2 \sum_{i=1}^n (x_i^p - \bar{x}^p)^2}} \quad (2)$$

شاخص RMSE یک شاخص پرکاربرد برای اندازه‌گیری اختلافات بین مقادیر پیش‌بینی شده یک متغیر و مقادیر واقعی مشاهده شده می‌باشد. این شاخص ابزار مناسبی برای اندازه‌گیری دقت مدل پیش‌بینی بوده، طبق رابطه‌ی (۳) محاسبه شده و مقدار ایده‌آل آن صفر می‌باشد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i^o - \bar{x}^o)^2}{n}} \quad (3)$$

میانگین قدر مطلق خطا (MAE) نیز یک کمیت برای اندازه‌گیری میزان نزدیکی مقادیر پیش‌بینی شده و خروجی‌های واقعی مدل‌ها بوده و مطابق با رابطه (۴) محاسبه می‌گردد. نزدیک بودن مقدار این شاخص به صفر دلالت بر وجود خطای کمتر دارد.

$$MAE = \frac{\sum_{i=1}^n |x_i^o - x_i^p|}{n} \quad (4)$$

میانگین مربعات خطا (MSE) نیز مطابق رابطه (۵) محاسبه شده و مقدار ایده‌آل آن صفر می‌باشد.

$$MSE = \frac{\sum_{i=1}^n (x_i^o - x_i^p)^2}{n} \quad (5)$$

که در روابط فوق، x_i^o پارامتر مشاهده شده (Observed)، x_i^p پارامتر پیش‌بینی شده (Predicted) و n تعداد داده‌هاست.


۴. تحلیل نتایج

در این مطالعه با استفاده از اطلاعات مشاهداتی در ایستگاه‌های سینوپتیک سنندج، بیجار و سقز در استان کردستان، با دوره‌ی آماری مشترک ۲۴ ساله، بارندگی ماهیانه سه ایستگاه به کمک شبکه عصبی مصنوعی مدل‌سازی گردید. برای این منظور داده‌های بارش ماهیانه سه ایستگاه توسط شبکه‌های عصبی مصنوعی، MLP و شیوه‌های آموزش مختلف با یک و دو لایه مخفی و با نرون‌های متفاوت آموزش و ارزیابی شدند و پس از مدل‌سازی‌های صورت گرفته، تعداد لایه‌های مخفی، تعداد نرون‌های موجود در هر لایه مخفی و شیوه‌ی آموزش بهینه جهت مدل‌سازی بارندگی ماهیانه هر ایستگاه انتخاب گردید. از میان داده‌های موجود ۷۰ درصد داده‌ها جهت آموزش و مابقی داده‌ها جهت کنترل مورد استفاده قرار گرفتند. این فرآیند در محیط نرم‌افزار MATLAB انجام شد. نتایج به دست آمده از مدل‌سازی توسط شبکه عصبی پرسپترون چندلایه با سه شیوه‌ی آموزشی ممتنم، گرادیان مزدوج و مارکورات-لونبرگ برای ایستگاه سنندج در جدول (۲)، برای ایستگاه بیجار در جدول (۳) و برای ایستگاه سقز در جدول (۴) آورده شده است. چهار شاخص موردنظر جهت ارزیابی نتایج نیز در جداول آورده شده است. با توجه به نتایج به دست آمده شیوه، تعداد لایه مخفی و تعداد نرون لایه مخفی به عنوان حالت بهینه در نظر گرفته شد که ضریب همبستگی بالاتری نسبت به سایر موارد را داراست. بنابراین منحنی پراکندگی بارندگی ماهیانه ایستگاه سنندج در شکل (۲)، ایستگاه بیجار در شکل (۳) و ایستگاه سقز در شکل (۴) نمایش داده شده است.

جدول ۲- نتایج مدل‌سازی بارندگی ماهیانه جهت انتخاب مدل بهینه در ایستگاه سنندج

شاخص RMSE	شاخص MSE	شاخص MAE	شاخص R ²	آموزش RMSE	آموزش MSE	آموزش MAE	آموزش R ²	تعداد نرون لایه مخفی دوم	تعداد نرون لایه مخفی اول	آموزش شیوه	نوع شبکه
۰/۰۹۲۲	۰/۰۰۸۵	۰/۰۶۱۴	۰/۸۵۹۷	۰/۰۸۸۱	۰/۰۰۷۷	۰/۰۵۸۷	۰/۸۶۳۶	-	-	Momentum	Multiplayer Perceptron
۰/۰۱۰۱	۰/۰۱۰	۰/۰۷۰۲	۰/۸۲۷۷	۰/۰۰۸۸	۰/۰۰۷۷	۰/۰۶۰۵	۰/۸۶۴۶	-	۳		
۰/۰۹۶۴	۰/۰۰۹۲	۰/۰۶۴۸	۰/۸۴۲۹	۰/۰۸۶۰	۰/۰۰۷۴	۰/۰۵۵۷	۰/۸۷۰۲	۳	۳		
۰/۱۱۷	۰/۰۱۲۵	۰/۰۷۲۳	۰/۷۸۸۸	۰/۰۷۷۴	۰/۰۰۶۰	۰/۰۵۱۴	۰/۸۹۶۳	-	-	Conjugate Gradient	
۰/۱۲۰۹	۰/۰۱۴۶	۰/۰۷۲۳	۰/۷۹۸۸	۰/۰۷۳۰	۰/۰۰۵۳	۰/۰۴۸۳	۰/۹۰۷۱	-	۳		
۰/۱۰۶۳	۰/۰۱۱۳	۰/۰۶۹۵	۰/۸۰۷۳	۰/۰۷۵۴	۰/۰۰۵۷	۰/۰۴۹۵	۰/۹۰۲۰	۳	۳	Lvenberg Marquardt	
۰/۱۳۶۲	۰/۰۱۸۵	۰/۰۸۲۱	۰/۶۸۳۵	۰/۰۳۹۳	۰/۰۰۱۵	۰/۰۲۵۰	۰/۹۷۴۴	-	-		
۰/۱۷۴۲	۰/۰۳۰۳	۰/۱۰۶۳	۰/۶۹۰۹	۰/۰۵۰۷	۰/۰۰۲۶	۰/۰۲۹۰	۰/۹۵۷۰	-	۳		
۰/۱۸۱۲	۰/۰۳۲۸	۰/۱۰۰۷	۰/۶۶۱۱	۰/۰۳۴۹	۰/۰۰۱۲	۰/۰۱۹۰	۰/۹۷۷۰	۳	۳		

با توجه به نتایج صحت‌سنجی مدل‌های ساخته شده در ایستگاه سنندج، مدل پرسپترون بدون لایه مخفی با روش آموزشی ممتنم و ضریب همبستگی $R^2=0.8597$ برای مدل‌سازی بارش ماهیانه در این ایستگاه بهینه می‌باشد. منحنی پراکندگی این مدل در شکل (۲) نشان داده شده است.




شکل ۲- منحنی پراکندگی مقادیر پیش بینی شده بارش ماهیانه ایستگاه سنج در مقابل مقادیر مشاهده شده $R^2=0.8597$

جدول ۳- نتایج مدل سازی بارندگی ماهیانه جهت انتخاب مدل بهینه در ایستگاه بیجار

شاخص RMSE	شاخص MSE	شاخص MAE	شاخص R^2	آموزش RMSE	آموزش MSE	آموزش MAE	آموزش R^2	تعداد نرون لایه مخفی دوم	تعداد نرون لایه مخفی اول	آموزش شبکه	نوع شبکه
۰/۱۰۴۳	۰/۰۱۰۸	۰/۰۸۱۵	۰/۶۶۹۵	۰/۱۲۰۰	۰/۰۱۴۴	۰/۰۸۰۶	۰/۸۴۳۱	-	-	Momentum	Multiplayer Perceptron
۰/۱۱۴۴	۰/۰۱۳۰	۰/۰۸۸۴	۰/۶۸۸۰	۰/۱۲۰۸	۰/۰۱۴۶	۰/۰۸۲۱	۰/۸۳۲۸	-	۳		
۰/۱۲۰۰	۰/۰۱۴۴	۰/۰۹۶۳	۰/۶۶۶۵	۰/۱۱۹۲	۰/۰۱۴۱	۰/۰۸۱۹	۰/۸۳۸۲	۳	۳	Conjugate Gradient	
۰/۱۱۰۶	۰/۰۱۲۲	۰/۰۸۷۸	۰/۶۶۲۲	۰/۱۱۶۶	۰/۰۱۳۶	۰/۰۷۷۶	۰/۸۴۵۳	-	-		
۰/۱۰۷۶	۰/۰۱۱۶	۰/۰۸۷۱	۰/۷۱۳۷	۰/۱۱۵۶	۰/۰۱۳۳	۰/۰۷۷۷	۰/۸۴۸۹	-	۱	Lvenberg Marquardt	
۰/۱۴۴۷	۰/۰۲۰۹	۰/۱۱۷۱	۰/۶۱۸۸	۰/۱۰۳۸	۰/۰۱۰۷	۰/۰۶۸۸	۰/۸۸۰۷	۱	۱		
۰/۱۰۳۸	۰/۰۱۰۸	۰/۰۸۰۴	۰/۷۱۴۹	۰/۰۶۷۰	۰/۰۰۴۵	۰/۰۴۵۸	۰/۹۵۱۷	۳	۳	Lvenberg Marquardt	
۰/۳۱۴۵	۰/۰۹۸۹	۰/۲۳۵۸	۰/۵۰۴۸	۰/۰۵۷۲	۰/۰۰۳۳	۰/۳۹۳۵	۰/۹۶۵۳	-	۳		
۰/۱۴۲۱	۰/۰۰۲۰	۰/۱۱۶۸	۰/۵۰۳۴	۰/۰۶۸۹	۰/۰۰۴۸	۰/۰۴۶۵	۰/۹۴۹۱	-	-		

نتایج مربوط به صحت سنجی مدل های ساخته شده در ایستگاه بیجار، حاکی از عملکرد بهینه ی مدل پرسپترون با دو لایه مخفی که هر لایه دارای سه نرون بوده و روش آموزشی ممتنم و ضریب همبستگی $R^2=0.7149$ برای مدل سازی بارش ماهیانه در این ایستگاه می باشد. خاطر نشان می شود که مدل پرسپترون با یک لایه مخفی شامل یک نرون و شیوه ی آموزشی گرادیان مزدوج با $R^2=0.7137$ نیز به همراه مدل قبلی می تواند مدل مناسبی برای ایستگاه بیجار باشد. منحنی پراکندگی مربوط به این مدل در شکل (۳) نشان داده شده است.




شکل ۳- منحنی پراکندگی مقادیر پیش بینی شده بارش فصلی ایستگاه بیجار در مقابل مقادیر مشاهده شده $R^2=0.7149$

جدول ۴- نتایج مدل سازی بارندگی ماهیانه جهت انتخاب مدل بهینه در ایستگاه سقر

شاخص RMSE	شاخص MSE	شاخص MAE	شاخص R ²	آموزش RMSE	آموزش MSE	آموزش MAE	آموزش R ²	تعداد نرون لایه مخفی دوم	تعداد نرون لایه مخفی اول	آموزش شیوه	نوع شبکه
۰/۰۹۳۹	۰/۰۰۸۳	۰/۰۶۳۴	۰/۸۵۳۴	۰/۰۸۶۷	۰/۰۰۷۵	۰/۰۵۷۴	۰/۸۶۸۶	-	۳	Momentum	Multiplayer Perceptron
۰/۰۹۴۶	۰/۰۰۸۹	۰/۰۶۵۷	۰/۸۵۶۵	۰/۰۸۸۱	۰/۰۰۷۸	۰/۰۵۶۳	۰/۸۶۳۷	-	-		
۰/۰۹۹۰	۰/۰۰۹۸	۰/۰۶۹۳	۰/۸۳۶۶	۰/۰۸۷۸	۰/۰۰۷۶	۰/۰۵۹۳	۰/۸۶۷۵	۳	۳		
۰/۱۲۸۳	۰/۰۱۶۴	۰/۰۶۸۸۲	۰/۷۴۶۷	۰/۰۶۷۳۷	۰/۰۰۴۵۳	۰/۰۴۳۱۲	۰/۹۹۸۲	-	-	Conjugate Gradient	
۰/۰۱۷۰	۰/۰۱۳۹	۰/۰۶۳۲	۰/۷۹۳۶	۰/۰۴۵۸	۰/۰۰۲۱	۰/۰۳۲۱	۰/۹۵۹۳	۷	۷		
۰/۰۷۹۹	۰/۰۰۶۴	۰/۰۵۲۷	۰/۸۵۲۳	۰/۰۴۹۹	۰/۰۰۲۵	۰/۰۳۴۷	۰/۹۵۱۶	-	۳	Lvenberg Marquardt	
۰/۱۳۴۳	۰/۰۱۸۰	۰/۰۷۴۳	۰/۷۳۳۳	۰/۰۳۷۱	۰/۰۱۳۸	۰/۰۲۴۶	۰/۹۷۳۵	-	۳		
۰/۱۲۴۷	۰/۰۱۵۵	۰/۰۷۷۷	۰/۶۸۴۴	۰/۰۳۰۶	۰/۰۰۰۹	۰/۰۲۱۲	۰/۹۸۲۰	۲	۲		
۰/۱۵۷۷	۰/۰۲۴۸	۰/۰۸۴۸	۰/۷۰۸۷	۰/۰۲۸۵	۰/۰۰۸۱	۰/۰۱۷۸	۰/۹۸۴۳	۳	۳		

در ارتباط با ایستگاه سقر نیز با مشاهده نتایج موجود در جدول مربوطه مدل پرسپترون بدون لایه مخفی با شیوه آموزشی ممتنم و $R^2=0.8565$ به عنوان مدل بهینه انتخاب و منحنی مربوط به پراکندگی آن در شکل (۴) نشان داده شده است.



شکل ۴- منحنی پراکندگی مقادیر پیش بینی شده بارش فصلی ایستگاه سقر در مقابل مقادیر مشاهده شده $R^2=0.8565$

۵. نتیجه گیری

با توجه نتایج مربوط به صحت سنجی مدل های ساخته شده، در ایستگاه سنندج، مدل پرسپترون بدون لایه مخفی با روش آموزشی ممتنم و ضریب همبستگی $R^2=0.8597$ ، در ایستگاه بیجار مدل پرسپترون با دو لایه مخفی که هر لایه دارای سه نرون بوده و روش آموزشی ممتنم و ضریب همبستگی $R^2=0.7149$ و در ایستگاه سقر نیز مدل پرسپترون بدون لایه مخفی با شیوه آموزشی ممتنم و $R^2=0.8565$ مدل بهینه ای جهت مدل سازی بارندگی ماهیانه در سه ایستگاه استان می باشد. همچنین با بررسی نتایج به دست آمده می توان گفت، مدل پرسپترون با یک لایه مخفی شامل یک نرون و شیوه آموزشی گرادیان مزدوج با $R^2=0.7137$ به موازات مدل قبلی می تواند مدل مناسبی برای ایستگاه بیجار باشد. بنابراین در مجموع، نتایج این بررسی حاکی از بهینه بودن مدل پرسپترون چند لایه با شیوه آموزشی ممتنم در تمامی ایستگاه ها بوده، این مدل در ایستگاه های سنندج و سقر ضریب همبستگی بالاتری در مقایسه با ایستگاه بیجار دارد. دلیل این مسئله پراکندگی بیش از اندازه ای داده های بیجار در مقایسه با داده های دو ایستگاه دیگر است.

۶. مراجع

۱. گلابی. م. ر.، آخوندعلی. ع. م.، رادمنش. ف.، ۱۳۹۲، مقایسه عملکرد الگوریتم های مختلف شبکه عصبی مصنوعی در مدل سازی بارندگی فصلی مطالعه موردی؛ ایستگاههای منتخب استان خوزستان، نشریه تحقیقات کاربردی علوم جغرافیایی سال سیزدهم، شماره ۳۰، پاییز ۹۲.
۲. قلی زاده. م. ح.، دارند. م.، ۱۳۸۸، پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی (مورد: تهران)، پژوهش های جغرافیای طبیعی، شماره ۷۱، بهار ۱۳۸۸.
۳. رضوی. س. س.، کارآموز. م.، ۱۳۸۲، استفاده از شبکه های عصبی مصنوعی در پیش بینی ماهانه جریان رودخانه. مجموعه مقالات دهمین کنفرانس دانشجویی عمران، تهران، دانشگاه صنعتی امیر کبیر.
۴. نادى. م.، جامعی. م.، بذرافشان. ج.، جنت رستمی. س.، ۱۳۹۱، ارزیابی روش های مختلف درون یابی داده های بارندگی ماهانه و سالانه (مطالعه ی موردی استان خوزستان، پژوهش های جغرافیای طبیعی، سال ۴۴، شماره ۴، زمستان ۱۳۹۱).
۵. منهاج. م. ب.، ۱۳۸۴، مبانی شبکه های عصبی هوش محاسباتی، جلد اول، مرکز نشر پروفیسور حسایی.
۶. رضایی. ع.، ۱۳۸۳، مدل سازی منطقه ای دبی های اوج زیر حوزه های آبخیز سفیدرود با استفاده از شبکه عصبی مصنوعی، پایان نامه دکتری در علوم و مهندسی آبخیز، دانشکده منابع طبیعی، دانشگاه تهران.
۷. کارآموز. م.، عراقی نژاد. ش.، ۱۳۸۴، هیدرولوژی پیشرفته، انتشارات دانشگاه صنعتی امیر کبیر، تهران، ایران.
8. Kim. T., Valdes, J.B., 2003. *Nonlinear model for drought forecasting based on conjunction of wavelet transforms and neural networks*, *Journal of Hydro. Eng. ASCE*, Volume 8(6), PP: 319-328.
۹. خوشحال دستجردی. ج.، حسینی. ی. م.، ۱۳۸۹، کاربرد شبکه عصبی مصنوعی در شبیه سازی عناصر اقلیمی و پیش بینی سیکل خشکسالی (مطالعه موردی استان اصفهان)، مجله جغرافیا و برنامه ریزی محیطی، سال ۲۱، شماره پیاپی ۳۹، شماره ۳، پاییز ۱۳۸۹.
10. Kohzadi, N., Boyd, M. S., Kaastra, I., Kermanshahi, B.S. and Scuse, D. 1995. *Neural networks for forecasting: an introduction*. *Canadian Journal networks of Agricultural Economics*, 43: 463-474.
۱۱. اکبرپور. م.، رهنما. م. ب.، بارانی. غ. ع.، ۱۳۸۲، مقایسه ی شبکه ی عصبی مصنوعی و مدل HEC-HMS در فرایند بارندگی - رواناب، چهارمین کنفرانس هیدرولیک ایران، دانشکده مهندسی دانشگاه شیراز، آبان ۱۳۸۹.
۱۲. اسکندری نیا. ع. ر.، نظریور. ه.، احمدی. م. ض.، تیموری. م.، مشفق. م. د.، ۱۳۹۰، بررسی تاثیر عامل پیشین در برآورد جریان رودخانه توسط شبکه عصبی مصنوعی (مطالعه ی موردی: رودخانه بختیاری)، پژوهشنامه مدیریت حوزه آبخیز سال دوم، شماره ۳، بهار و تابستان ۱۳۹۰.
13. Hastenrath, S., Greischar, L., Vanheerden, J., 1995, *Prediction of the summer rainfall over South-Africa*. *International Journal of climate*. 8(6). 1511-1518.
14. Tokar, A. S., Santon, P. A., 1999, *Rainfall-Runoff modeling using artificial neural networks*, *Journal of Hydrologic Engineering*, 3, 232-239.
15. Trafalis, TB., White, A., Santosa, B., Richman, M. B., 2002, *Data mining techniques for improved WSR-88D rainfall estimation*, *Computers in Industrial Engineering*, 43, 775-786.
16. Maria, C., Haroldo, F., Ferreira, N., 2005, *Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region*, *Journal of Hydrology*, No. 301, pp.146-162.
۱۷. مسیبی برزی. م.، پورشهابی. ش.، حسامی کرمانی. م.، ۱۳۸۵، پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی، دومین کنفرانس مدیریت منابع آب، اصفهان، دانشگاه صنعتی اصفهان، انجمن علوم و مهندسی منابع آب ایران.
۱۸. کیا. س. م.، ۱۳۹۰، شبکه های عصبی در MATLAB، چاپ چهارم، ویرایش دوم، انتشارات کیان رایانه سبز، تهران، ایران.
۱۹. منهاج. م. ب.، ۱۳۸۷، مبانی شبکه های عصبی هوش محاسباتی، جلد اول، چاپ پنجم، انتشارات دانشگاه صنعتی امیر کبیر، تهران، ایران.
۲۰. خلیلی. ن.، خداشناس. س.، داوری. ک.، ۱۳۸۵، پیش بینی بارش با استفاده از شبکه های عصبی مصنوعی، دومین کنفرانس مدیریت منابع آب.