

ارزیابی کاربرد شبکه عصبی مصنوعی و بهینه‌سازی آن با روش الگوریتم ژنتیک در تخمین داده‌های بارش ماهانه (مطالعه موردی: منطقه کردستان)

همایون فقیه^{۱*}

(تاریخ دریافت: ۱۳۸۷/۱۲/۱۳؛ تاریخ پذیرش: ۱۳۸۸/۸/۳۰)

چکیده

برآورد توزیع مکانی بارش برای اجرای طرح‌های مطالعات منابع آب، خشک‌سالی، طرح‌های آمایش سرزمین، محیط زیست، آبخیزداری و طرح‌های جامع کشاورزی ضروری می‌باشد. تغییرات زیاد مقدار بارش در نقاط مختلف، کمبود ایستگاه‌های اندازه‌گیری و پیچیدگی ارتباط بارش با پارامترهای اثرگذار بر آن، اهمیت توسعه روش‌های کارآمد را در برآورد توزیع مکانی بارش دو چندان می‌نماید. شبکه عصبی مصنوعی به عنوان یک روش نوین، در مدل‌سازی و پیش‌بینی فرآیندهایی که برای شناخت و توصیف دقیق آنها راه حل و رابطه صریحی وجود نداشته، موفق بوده است. این تحقیق با هدف بررسی کارایی شبکه عصبی مصنوعی در برآورد مکانی بارش ماهانه انجام گرفت. بدین منظور شبکه عصبی با ساختار پرسپترون چند لایه برای تدوین مدل برآورد مکانی بارش در پنج ایستگاه سینوپتیک و باران‌سنگی، واقع در استان کردستان، به کار گرفته شد. برای طراحی ساختار مدل در هر ایستگاه، با تغییر پارامترهای قابل تنظیم، (شامل تابع انتقال، قانون آموزش، مقدار مومنتم، تعداد لایه پنهان، تعداد نرون لایه پنهان و تعداد الگوها)، شبکه‌های عصبی مختلف ساخته و اجرا شد. در هر مرور، ساختاری که کمترین مقدار جذر میانگین مربعات خطأ (RMSE) را داشت به عنوان مدل نهایی انتخاب گردید. از آنجا که انتخاب هر یک از پارامترهای متغیر شبکه عصبی مستلزم آزمون و خطاهای مکرر و در نتیجه آموزش تعداد زیادی شبکه با ساختار مختلف بود، از روش الگوریتم ژنتیک برای بهینه‌یابی این پارامترها استفاده شد و کارایی این روش در بهینه‌سازی شبکه عصبی بررسی گردید. نتایج نشان داد، شبکه عصبی در مدل‌سازی و برآورد مکانی بارش ماهانه از دقت بالایی برخوردار است. هم‌چنین تلفیق آن با الگوریتم ژنتیک، برای بهینه‌سازی شرایط اجرای شبکه عصبی، مثبت ارزیابی گردید و روش تلفیقی در اکثر موارد برتری خود را نسبت به اجرای شبکه عصبی بدون بهینه‌سازی نشان داد. دقیق‌ترین مدل در همه ایستگاه‌های مورد مطالعه، با استفاده از تابع انتقال سیگموئید و قانون آموزش لونبرگ مارکوارت حاصل گردید. در مدل‌های منتخب، مقدار ضریب تبیین (R^2) بین مقادیر خروجی مدل و داده‌های مشاهده شده در ایستگاه، برابر با ۰/۸۶، ۰/۸۹، ۰/۹۴ و ۰/۹۴ به دست آمد.

واژه‌های کلیدی: بارش، شبکه عصبی مصنوعی، الگوریتم ژنتیک

۱. کارشناس ارشد تأسیسات آبیاری، مرکز تحقیقات کشاورزی و منابع طبیعی استان کردستان

*: مسئول مکاتبات، پست الکترونیکی: hfaghih54@gmail.com

مقدمه

به عقب خطأ و داده‌های بارندگی ماهانه جهت پیش‌بینی بارش ماهانه، در مجارستان و اوکراین، استفاده نمودند. نتایج تحقیق آنها نشان داد، داده‌های آموزشی و آزمایشی جورش‌دگی و انطباق خوبی با داده‌های واقعی دارند و این روش در پیش‌بینی بارش، دارای حداکثر توانایی است. رامیرز و همکاران (۲۲) کاربرد روش شبکه عصبی مصنوعی را در پیش‌بینی بارش، برای سائوپائولو، بررسی کردند. نتایج بررسی آنها نشان داد، پیش‌بینی‌های این روش نسبت به دیگر روش‌ها از دقت بالاتر و صحت بیشتری برخوردار است. عابدینی و پولادی (۷) عملکرد مدل‌های شبکه عصبی مصنوعی را در تخمین مکانی بارندگی روزانه، در منطقه فارس و بخشی از استان کهکیلویه و بویراحمد، ارزیابی کردند و نتایج آن را با روش زمین آمار کریجینگ Inverse (Kriging) و روش‌های سنتی، شامل عکس فاصله (Nearest neighbor)، مقایسه (distance) و نزدیک‌ترین همسایه (nearest neighbor) نمودند. نتایج حاصل از تحقیق آنها، بر دقيق بودن روش‌های کریجینگ و شبکه عصبی مصنوعی دلالت داشت. جهانگیر (۵) کارآمدی شبکه عصبی مصنوعی را در شبیه‌سازی فرآیند بارش-رواناب، در حوضه کارده، بررسی کرد و با استفاده از شبکه پرسپترون چند لایه، فرآیند بارش-رواناب را با دقت خوبی تخمین زد.

الگوریتم ژنتیک (GA)

الگوریتم ژنتیک، یک روش برای حل مسائل بهینه‌سازی می‌باشد که اساس آن بر انتخاب، بقاء و تکامل در محیط‌های طبیعی استوار است. روش الگوریتم ژنتیک را می‌توان برای انواع مسائل بهینه‌یابی که مناسب برای روش‌های استاندارد بهینه‌سازی نیستند، استفاده نمود. هم‌چنین این روش در مسائلی که در آنها تابع هدف ناپیوسته، غیرقابل مشتق‌گیری، آماری، بسیار غیرخطی و یا دارای مقادیر بهینه موضعی باشد، به کار برده می‌شود (۱۹). مطالعه الگوریتم ژنتیک در اواسط دهه ۱۹۷۰ توسط هولند آغاز شد (۲۱). بعد از آن، گلدبُرگ (۱۹) معرفی کامل و دقیقی از این روش ارائه داد. ونگ (۲۴) و فرانچینی

تعیین توزیع مکانی بارش برای اجرای طرح‌های مطالعات منابع آب، خشک‌سالی، طرح‌های جامع کشاورزی، محیط زیست، آبخیزداری و طرح‌های آمایش سرزمین ضروری می‌باشد (۱۲). برآورد توزیع مکانی بارش بهویژه در انجام مطالعات بیلان آب و ارزیابی دبی‌های سیلانی حوضه آبخیز دارای نقش اساسی می‌باشد. در مدل‌های بارش-رواناب توزیع مکانی بارندگی برای تخمین هرچه دقیق‌تر میانگین بارندگی حوضه مورد نیاز است (۸). تغییرات زیاد مقدار بارش در نقاط مختلف، کمبود ایستگاه‌های اندازه‌گیری و پیچیدگی ارتباط بارش با پارامترهای اثرگذار بر آن، اهمیت توسعه روش‌های کارآمد را در برآورد توزیع مکانی بارش دو چندان می‌نماید (۲).

شبکه عصبی مصنوعی (ANN) (Artificial Neural Network) شبکه عصبی مصنوعی به عنوان یک روش نوین، در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و غیرماندگار فرآیندهایی که برای شناخت و توصیف دقیق آنها راه حل و رابطه صریحی وجود ندارد، عملکرد خوبی از خود نشان داده است. شبکه عصبی با برخورداری از قابلیت تشخیص الگو، رابطه خوبی بین داده‌های ورودی و خروجی برقرار می‌کند. این روش در قیاس با دیگر روش‌ها، حساسیت کمتری نسبت به وجود خطأ در اطلاعات ورودی دارد. مدل‌های شبکه عصبی مصنوعی با آموزشی که دیده‌اند، می‌توانند، بدون ایجاد رابطه صریح ریاضی، رفتار سیستم را پیش‌بینی کنند (۶ و ۱۰). اکنون این شبکه‌ها با ساختارهای متنوع و وسیع، در بسیاری از علوم، از جمله مهندسی آب، گسترش یافته‌اند.

فرنج و همکاران (۱۸) بارندگی در یک مکان و یک ساعت بعد را با استفاده از روش شبکه عصبی مصنوعی و اطلاعات توزیع مکانی و زمانی بارندگی پیش‌بینی کردند. احمد و سیموونیک (۱۳) از شبکه‌های عصبی سه لایه با خاصیت انتشار

از آمار موجود در این ایستگاه‌ها مجداً برآورد و نتایج آنها با داده‌های مشاهده شده و واقعی مقایسه گردید.

مواد و روش‌ها

الف) محدوده مطالعه و منابع داده‌ها

محدوده مورد مطالعه این تحقیق استان کردستان، واقع در شمال غرب ایران، انتخاب شده است. برای تدوین مدل برآورد مکانی بارش ماهانه در پنج مکان مختلف، از آمار بارش ماهانه در ۲۴ ایستگاه باران‌سنگی و ۵ ایستگاه سینوپتیک این استان، که دارای یک دوره زمانی مشترک ۱۷ ساله آماری (۱۳۸۶-۱۳۷۰) بودند، به عنوان داده‌های واقعی استفاده شد. موقعیت کلی ایستگاه‌های مورد استفاده، در شکل ۱ ملاحظه می‌گردد.

ب) روش شبکه عصبی مصنوعی

در اغلب مدل‌های شبکه عصبی مصنوعی، از مدل ریاضی سلول عصبی که نرون یا پرسپترون (Perceptron) نامیده می‌شود، استفاده می‌گردد. نرون کوچک‌ترین واحد سازنده شبکه عصبی است. هر شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه میانی تشکیل شده است. در داخل هر یک از لایه‌های فوق، تعدادی نرون قرار دارند که با اتصالات وزن دار به هم مربوط می‌شوند. طی فرآیند آموزش شبکه، این وزن‌ها به طور پیاپی تغییر می‌کنند تا خطای کمترین مقدار خود برسد. برای انتقال خروجی‌های هر لایه به لایه‌های بعدی معمولاً از توابع انتقال (Transfer Functions) خطی، تائزانت هیپربولیک (Sigmoid Hyperbolic (Tanh)) و سیگموئیدی (Tangent Hyperbolic (Tanh)) استفاده می‌شود. توپولوژی هر شبکه، وضعیت نسبی (تعداد، گروه‌بندی و اتصالات) سلول‌ها را در شبکه نشان می‌دهد. توپولوژی در واقع سیستم اتصال تبادلاتی نرون‌ها به یکدیگر است که توأم با نرم‌افزار مربوطه (یعنی روش ریاضی جریان اطلاعات و محاسبه وزن‌ها) نوع عملکرد شبکه عصبی را تعیین می‌کند. ساده‌ترین نوع شبکه، دارای توپولوژی پیش‌خور (Feed Forward) می‌باشد که در آن جریان اطلاعات همیشه از ورودی

(۱۷) برای کالیبره کردن مدل بارندگی - رواناب از الگوریتم ژنتیک استفاده کردند. دندی (۱۶) روش تکامل یافته‌ای از الگوریتم ژنتیک برای بهینه‌سازی شبکه ذخیره آب ارائه و از آن برای بهینه‌سازی شبکه ذخیره آب نیویورک استفاده کرد. مقایسه آن با سایر روش‌های بهینه‌سازی شبکه ذخیره آب، نشانگر برتری الگوریتم ژنتیک بود. مهبد و همکاران (۱۱) عوامل هیدرولیکی خاک را در منطقه با جگاه شیراز، به روش معکوس و با استفاده از روش بهینه‌یابی الگوریتم ژنتیک تخمین زدند که نتایج حاصل از بهینه‌یابی، اختلاف کمی با نتایج اندازه‌گیری شده داشت. ثمره هاشمی و بارانی (۴) از این روش برای بهینه‌سازی عملکرد سدهای چندمنظوره استفاده کردند و نتیجه تحقیق آنها نشان داد که روش الگوریتم ژنتیک در بهینه‌سازی سیستم‌های منابع آب، به خصوص زمانی که سیستم چند منظوره، چند مخزنی و پیچیده باشد، بسیار سودمند است. پرورش ریزی و همکاران (۳) تلفیق شبکه عصبی مصنوعی و الگوریتم ژنتیک را برای بهینه‌سازی شرایط اجرای شبکه عصبی، در برآورد پارامترهای پرش هیدرولیکی، مثبت ارزیابی کردند و نتایج تحقیق آنها نشان‌دهنده برتری روش تلفیقی، نسبت به اجرای شبکه عصبی مصنوعی بدون بهینه‌سازی، بود.

باتوجهه به موفقیت روش شبکه عصبی مصنوعی در مدل‌سازی و برآورد فرآیندهای پیچیده و هم‌چنین عملکرد مناسب الگوریتم ژنتیک در بهینه‌سازی مسائل مختلف مهندسی آب، در اینجا دو فرضیه مطرح می‌گردد. ۱- شبکه عصبی مصنوعی می‌تواند با دقت مناسبی مقدار بارش ماهانه یک مکان را به کمک آمار ایستگاه‌های مجاور آن برآورد نماید؟ ۲- الگوریتم ژنتیک در بهینه‌یابی و انتخاب پارامترهای متغیر شبکه عصبی مصنوعی، که به روش آزمون و خطای تعیین می‌شوند، مفید است و کاربرد آن در این زمینه موجب بهبود عملکرد و افزایش دقت شبکه عصبی مصنوعی خواهد شد؟ برای پاسخ دادن به دو فرضیه فوق، با استفاده از این دو روش، مدل برآورد مکانی بارش برای پنج ایستگاه سینوپتیک و باران‌سنگی تدوین گردید. به وسیله این مدل‌ها، مقدار بارش ماهانه برای ۳۰ درصد



رونده آموزش نیز در سرعت یادگیری و دقیق شبکه عصبی مؤثر می‌باشد. معمولاً یکی از دو روند آموزش الگو به الگو (Epochs) و آموزش گروهی (Batch) در تدوین مدل‌های شبکه عصبی به کار می‌رود (۱).

ج) الگوریتم ژنتیک

روش الگوریتم ژنتیک، یک الگوریتم جستجوی موازی براساس انتخاب طبیعی اصلاح و نظریه تکامل داروین می‌باشد. در این روش سعی بر مدل‌سازی ریاضی نظام انتخاب طبیعی است. در طبیعت عملگرهای ژنتیکی بسیاری دخیل می‌باشند اما در الگوریتم ژنتیک این عملگرهای عبارتند از: به‌گرینی، تولید مثل (Mutation)، تلاقي (Cross over) و پرش (Reproduction) (۹). تفاوت عمده این روش با دیگر روش‌های جستجو این است که به جای تمرکز بر یافتن مقادیر تک تک نقاطی که ممکن است مجموعه جواب را تشکیل بدنهند، با جمعیتی از نقاط کدگذاری شده سر و کار دارد (۱۹). در این روش صرفاً از مقادیر تابع هدف (Fitness Function)، که باید در ابتدا به طور واضح و به وسیله ترکیبی از تمامی اهداف مورد نظر تعریف گردد، برای هدایت جستجو استفاده می‌شود و نیاز به دانستن نحوه تغییرات

به خروجی است. تopolوژی شبکه‌های چند لایه پرسپترون Learning (Multilayer Perceptron, MLP) با قانون آموزش (Back Propagation of Error) (Rule)، که دارای الگوریتم‌های مختلف آموزش، از قبیل شبیه مزدوج (Momentum) (Conjugate Gradient, CG)، مومنتم (Conjugate Gradient, CG) و لونبرگ (Levenberg Marquardt, LM) می‌باشد، تکمیل می‌شود.

قبل از به کار بردن مدل شبکه عصبی، وزن‌ها و اریب‌های ارتباط دهنده نرون‌های شبکه تعیین می‌شوند. به همین منظور تمام داده‌ها برای تدوین ساختار مدل به سه گروه تقسیم می‌شوند (۱۵). اولین گروه داده‌ها، به عنوان داده‌های آموزش (Training Data)، برای تعیین وزن‌ها و اریب‌های شبکه به کار می‌رود. دومین گروه از داده‌ها، که داده‌های اعتباری (Validation Data) نامیده می‌شوند، برای ارزیابی نتایج مرحله آموزش و تصمیم‌گیری در خصوص توقف آموزش شبکه استفاده می‌شوند. تعیین دقت مدل، و یا به عبارتی آزمون با استفاده از سومین گروه داده‌ها، یعنی داده‌های آزمون (Testing Data) که در تدوین مدل استفاده نشده‌اند، انجام می‌شود. در آموزش شبکه‌های عصبی علاوه بر روش آموزش،

صفر نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است. این معیار از رابطه زیر به دست می‌آید.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n ((y_{est})_i - (y_{obs})_i)^2}{n}} \quad [2]$$

میانگین خطای مطلق (MAE) (Mean Absolute Error (MAE)) این معیار از رابطه ۳ به دست می‌آید. مقدار MAE از صفر تا بینهایت تغییر می‌نماید. هر چه مقدار MAE کمتر و به صفر نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است. در رابطه‌های ۲ و ۳، تعریف پارامترها مانند رابطه ۱ می‌باشد.

$$MAE = \frac{\sum_{i=1}^n |(y_{est})_i - (y_{obs})_i|}{n} \quad [3]$$

ه) روش تحقیق

داده‌های ورودی و خروجی مدل‌ها

ابتدا داده‌های بارش ماهانه هریک از پنج ایستگاه، که تدوین مدل برآورده مکانی بارش برای آنها مدنظر بود، به صورت ستونی وارد یک پوشه (File) مجزا از صفحه گسترده اکسل (Desired Data) شد و به عنوان داده‌های مطلوب (Excel) برای مدل تعریف شدند. سپس داده‌های بارش ماهانه ایستگاه‌های مجاور هر ایستگاه، به صورت ستونی وارد پوشه مربوط به آن ایستگاه گردید و تحت عنوان داده‌های ورودی (Input Data) برای مدل تعریف شدند. به طور کلی ارتباط بین ورودی‌ها و خروجی مدل به صورت رابطه ۴ قابل ارائه است.

$$y_t = f((x_t)_1, \dots, (x_t)_n) \quad [4]$$

که در آن، y_t مقدار بارش در یک محل (یا ایستگاه) در ماه t ، x_t بارش ماهانه ایستگاه مجاور آن محل در ماه t و n تعداد ایستگاه مجاور می‌باشد.

بعد از مشخص نمودن داده‌های ورودی و مطلوب هر مدل، که در جدول ۱ ارائه شده است، عمل چیدن تصادفی (Randomization) رდیف‌ها روی صفحه گسترده انجام گردید.

متغیرها (مثل مشتق تابع هدف) نیست (۳). روندnamای این روش در شکل ۲ ترسیم شده است.

د) معیارهای آماری

برای ارزیابی دقت مدل‌های تدوین شده با شبکه عصبی و هم‌چنین مقایسه آنها با مدل‌های بهینه‌سازی شده با الگوریتم ژنتیک، از معیارهای آماری ضریب تبیین (R^2)، جذر میانگین مربعات خطأ (RMSE)، و میانگین خطای مطلق (MAE) استفاده شده است.

ضریب تبیین (R^2) (Coefficient of Determination (R^2))

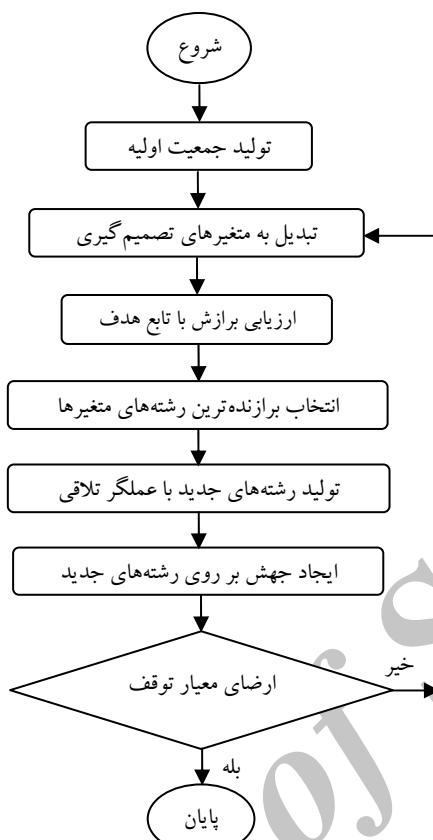
ضریب همبستگی (Coefficient of Correlation (R)) نشان‌دهنده میزان همبستگی بین مقادیر برآورده شده توسط مدل و مقادیر واقعی می‌باشد. این ضریب را می‌توان از رابطه ۱ محاسبه کرد. مقدار (R^2) ضریب تبیین نامیده می‌شود. برای استفاده از معادلات رگرسیون در هیدرولوژی مقدار قابل قبول $R^2 > 0.36$ توصیه شده است. مقدار این ضریب همواره بین صفر و ۱ قرار داشته و هر چه مقدار آن به ۱ نزدیک‌تر باشد، نشان دهنده عملکرد بهتر مدل است.

$$R = \frac{\sum_{i=1}^n ((y_{obs})_i - (\bar{y}_{obs})) \times ((y_{est})_i - (\bar{y}_{est}))}{\sqrt{\sum_{i=1}^n ((y_{obs})_i - (\bar{y}_{obs}))^2 \sum_{i=1}^n ((y_{est})_i - (\bar{y}_{est}))^2}} \quad [1]$$

در رابطه ۱، y_{obs} مقادیر مشاهده شده (واقعی)، \bar{y}_{obs} میانگین مقادیر مشاهده شده، y_{est} مقادیر برآورده شده (خروجی مدل)، \bar{y}_{est} میانگین مقادیر برآورده شده و n تعداد داده‌ها می‌باشد.

جذر میانگین مربعات خطأ (RMSE) (Root Mean Square of (RMSE)) (Error)

این معیار دقت مدل را براساس تفاضل بین مقادیر واقعی و مقادیر برآورده شده ارزیابی می‌کند و هرچه مقدار آن کمتر و به



شکل ۲. روند نمای الگوریتم ژنتیک

جدول ۱. پارامترهای ورودی و مطلوب در مدل‌های تدوین شده با شبکه عصبی و شبکه عصبی بهینه‌سازی شده با الگوریتم ژنتیک

مدل	داده‌های مطلوب*		تعداد
	وارش ماهانه ایستگاه	وارش ماهانه ایستگاه	
۱	آغبلاغ	حسن تیمور	۸
۲	سنندج	قلعه‌شیخان	۷
۳	مظفرآباد	سریش آباد	۵
۴	دیواندره	نجف آباد	۴
۵	سقز	سرچشمہ	۶
	بارش ماهانه ایستگاه	بارش ماهانه ایستگاه	
	پارامترهای لایه ورودی*	پارامترهای لایه ورودی*	

*: شایان ذکر است در این جدول به اختصار از نام ایستگاه به جای بارش ماهانه ایستگاه استفاده شده است.

اینجا نتایج به دست آمده در دو بخش مجزا، با عنوان‌های شبکه عصبی مصنوعی و شبکه عصبی بهینه‌سازی شده با الگوریتم رُنتیک، ارائه شده است.

الف) شبکه عصبی مصنوعی (ANN)

انتخاب مقدار مومنت

در حالت کلی نمی‌توان نظر قطعی در مورد مقدار مومنت، که یکی از پارامترهای یادگیری در قانون آموزش مومنت می‌باشد، بیان نمود. انتخاب مقدار مومنت، که همواره کوچک‌تر از یک است، به صورت آزمون و خطا انجام می‌گیرد (۱۰). برای تعیین مناسب‌ترین مقدار مومنت، مدل‌های مختلف شبکه عصبی، که در آنها مقدار مومنت $0/1, 0/2, 0/3, 0/4, 0/5, 0/6, 0/7, 0/8, 0/9, 0/95, 0/99$ و ۱ در نظر گرفته شد، با استفاده ازتابع انتقال تائزانت هیپربولیک و قانون آموزش مومنت اجرا و مقدار جذر میانگین مربعات خطای برای این شبکه‌ها محاسبه شد (جدول ۲). هم‌چنین به منظور مقایسه عملکرد دوتابع انتقال تائزانت هیپربولیک و سیگموئید، شبکه‌های دیگری با مقادیر مومنت مختلف و با استفاده ازتابع انتقال سیگموئید آموزش داده شد که نتایج مقدار (RMSE) برای آنها در جدول ۳ ارائه شده است. با بررسی جدول‌های ۲ و ۳ ملاحظه می‌گردد که، اگر در طراحی ساختار شبکه عصبی از قانون آموزش مومنت استفاده شود، تابع انتقال تائزانت هیپربولیک در تدوین مدل‌ها عملکرد بهتری نسبت به تابع سیگموئید خواهد داشت. در مجموع تا این مرحله، بهترین مدل از نظر دقیقت برای ایستگاه‌های آغلاغ، سنتدج، مظفرآباد، دیواندره و سقز وقته که از تابع تائزانت هیپربولیک و به ترتیب مقدار مومنت $0/8, 0/7, 0/6, 0/5, 0/4, 0/3, 0/2, 0/1$ استفاده شد، به دست آمد (به ترتیب ساختارهای ۸، ۷، ۶ و ۹).

تابع انتقال و قانون آموزش

در این مرحله برای انتخاب نوع تابع انتقال و قانون آموزش مناسب، شبکه‌های عصبی مختلف، با تغییر تابع انتقال و قانون

در ادامه ۵۵ درصد از ردیف‌های هر ستون برای آموزش، ۱۵ درصد برای ارزیابی و ۳۰ درصد برای آزمون جدا شدند. در تدوین مدل‌ها، علاوه بر آمار این پنج ایستگاه، از آمار ماهانه مقدار بارش در ۲۴ ایستگاه مجاور آنها نیز استفاده گردید. در این تحقیق به طور کلی از ۴۸۹۶ داده برای تدوین پنج مدل استفاده شد.

تدوین مدل و انتخاب ساختار شبکه عصبی مصنوعی

در این تحقیق از مدل شبکه عصبی مصنوعی با ساختار پیش‌خور چند لایه برای برآوردن مکانی مقدار بارش ماهانه در ایستگاه‌های آغلاغ، سنتدج، مظفرآباد، دیواندره و سقز استفاده گردید. در طراحی ساختار مدل هر یک از ایستگاه‌ها، ابتدا تعداد نرون‌های لایه‌های ورودی و خروجی به ترتیب با توجه به تعداد متغیرهای ورودی (ایستگاه‌های مجاور) و خروجی مدل (ایستگاه مطلوب) انتخاب شد (جدول ۱). سپس برای انتخاب پارامترهای قابل تنظیم و در نتیجه تعیین بهترین ساختار شبکه عصبی، تعداد زیادی شبکه عصبی با ساختار مختلف طراحی و ارزیابی گردید. این شبکه‌های عصبی با تغییر پارامترهای قابل تنظیم، شامل تابع انتقال، قانون یادگیری، مقدار مومنت، تعداد لایه میانی، تعداد نرون‌های لایه میانی، تعداد الگوها و متغیرهای ورودی، ساخته و اجرا شدند. دقیقت این شبکه‌ها به وسیله معیارهای آماری محاسبه شده در مرحله آزمون، بررسی گردید و در نهایت شبکه‌ای که نزدیک‌ترین نتیجه را با واقعیت داشت به عنوان شبکه اصلی انتخاب شد. از آنجا که انتخاب هر یک از پارامترهای متغیر شبکه عصبی مستلزم آزمون و خطاهاست مکرر و در نتیجه آموزش تعداد زیادی شبکه با ساختار مختلف بود، در ادامه از روش الگوریتم رُنتیک برای بهینه‌سازی تعدادی از این پارامترها استفاده شد. بدین وسیله کارایی این روش در بهینه‌سازی شبکه عصبی، در زمینه برآوردن مکانی بارش، بررسی گردید.

نتایج و بحث

در این بررسی از نرم‌افزار Neurosolutions5 برای تدوین مدل‌های شبکه عصبی و انجام محاسبات استفاده گردید که در

جدول ۲. مقدار جذر میانگین مربعات خطأ (برحسب میلی متر) در شبکه‌های آموزش یافته با استفاده از تابع تائزانت هیپربولیک و مقادیر مختلف مومنت

ساختار	تابع انتقال	قانون آموزش	مقدار مومنت	تعداد لایه پنهان	نرون	حداکثر الگوها	جذر میانگین مربعات خطأ (mm)		ایستگاه	آغاز		
							سنتنج	مظفرآباد				
							سنتنج	مظفرآباد	دیواندره	سقز		
۱۶/۶۵	۱۶/۵۱	۸/۴۴	۱۳/۵۴	۱۶/۷۷	۱۰۰۰	۴	۱	۰/۱	مومنت	تائزانت هیپربولیک		
۱۶/۲۰	۱۶/۹۰	۸/۱۲*	۱۳/۷۳	۱۷/۱۲	۱۰۰۰	۴	۱	۰/۲	مومنت	تائزانت هیپربولیک		
۱۷/۵۳	۱۶/۱۷	۸/۲۵	۱۴/۳۲	۱۸/۰۳	۱۰۰۰	۴	۱	۰/۳	مومنت	تائزانت هیپربولیک		
۱۶/۰۳	۱۵/۸۱	۸/۵۱	۱۴/۱۴	۱۷/۷۹	۱۰۰۰	۴	۱	۰/۴	مومنت	تائزانت هیپربولیک		
۱۷/۲۲	۱۶/۰۳	۸/۲۳	۱۴/۰۰	۱۶/۴۰	۱۰۰۰	۴	۱	۰/۵	مومنت	تائزانت هیپربولیک		
۱۵/۸۱	۱۵/۷۵*	۸/۲۲	۱۴/۸۶	۱۷/۳۱	۱۰۰۰	۴	۱	۰/۶	مومنت	تائزانت هیپربولیک		
۱۷/۳۹	۱۶/۱۶	۸/۴۰	۱۳/۲۲*	۱۵/۸۰	۱۰۰۰	۴	۱	۰/۷	مومنت	تائزانت هیپربولیک		
۱۶/۰۳	۱۸/۳۲	۸/۴۸	۱۳/۶۴	۱۵/۰۳*	۱۰۰۰	۴	۱	۰/۸	مومنت	تائزانت هیپربولیک		
۱۵/۵۵*	۱۶/۱۴	۸/۷۶	۱۳/۹۹	۱۷/۶۴	۱۰۰۰	۴	۱	۰/۹	مومنت	تائزانت هیپربولیک		
۱۵/۷۸	۲۱/۴۵	۱۰/۹۴	۱۷/۲۳	۱۵/۶۵	۱۰۰۰	۴	۱	۰/۹۵	مومنت	تائزانت هیپربولیک		
۱۵/۶۸	۲۵/۸۸	۹/۸۸	۱۹/۷۶	۱۶/۲۴	۱۰۰۰	۴	۱	۰/۹۹	مومنت	تائزانت هیپربولیک		
۴۲/۱۱	۲۶/۱۰	۲۱/۲۷	۲۵/۸۱	۲۲/۱۸	۱۰۰۰	۴	۱	۱	مومنت	تائزانت هیپربولیک		

*: نشان‌دهنده کمترین مقدار جذر میانگین مربعات خطأ در هر ستون می‌باشد.

جدول ۳. مقدار جذر میانگین مربعات خطأ (برحسب میلی متر) در شبکه‌های آموزش یافته با استفاده از تابع انتقال سیگموئید و مقادیر مختلف مومنت

ساختار	تابع انتقال	قانون آموزش	مقدار مومنت	تعداد لایه پنهان	نرون	حداکثر الگوها	جذر میانگین مربعات خطأ (mm)		ایستگاه	آغاز		
							سنتنج	مظفرآباد				
							سنتنج	مظفرآباد	دیواندره	سقز		
۴۱/۲۲	۲۶/۰۸	۱۶/۷۲	۲۶/۲۹	۲۷/۷۴	۱۰۰۰	۴	۱	۰/۱	مومنت	تائزانت هیپربولیک		
۳۸/۰۵	۲۳/۵۳	۱۸/۷۱	۱۷/۳۹	۳۰/۱۹	۱۰۰۰	۴	۱	۰/۲	مومنت	تائزانت هیپربولیک		
۳۴/۵۱	۲۵/۷۰	۱۶/۵۶	۱۷/۶۰	۲۷/۳۴	۱۰۰۰	۴	۱	۰/۳	مومنت	تائزانت هیپربولیک		
۴۰/۱۳	۲۱/۵۸	۱۳/۰۰	۱۹/۶۵	۲۶/۰۲	۱۰۰۰	۴	۱	۰/۴	مومنت	تائزانت هیپربولیک		
۲۷/۰۸	۱۹/۸۲	۱۱/۷۵	۱۵/۳۴	۲۲/۳۵	۱۰۰۰	۴	۱	۰/۵	مومنت	تائزانت هیپربولیک		
۳۳/۰۱	۱۸/۸۴	۱۰/۱۷	۱۳/۶۲*	۱۸/۷۹	۱۰۰۰	۴	۱	۰/۶	مومنت	تائزانت هیپربولیک		
۲۲/۳۲	۱۷/۴۱	۹/۸۳	۱۴/۲۶	۱۷/۹۹	۱۰۰۰	۴	۱	۰/۷	مومنت	تائزانت هیپربولیک		
۲۰/۹۸	۱۶/۲۳*	۹/۸۱	۱۴/۱۲	۱۶/۸۷	۱۰۰۰	۴	۱	۰/۸	مومنت	تائزانت هیپربولیک		
۱۹/۴۱	۱۶/۹۸	۹/۰۸	۱۳/۸۱	۱۶/۶۶	۱۰۰۰	۴	۱	۰/۹	مومنت	تائزانت هیپربولیک		
۱۷/۸۰*	۱۷/۱۲	۸/۶۵	۱۴/۳۴	۱۸/۳۷	۱۰۰۰	۴	۱	۰/۹۵	مومنت	تائزانت هیپربولیک		
۱۸/۸۱	۲۰/۲۷	۸/۶۱*	۱۳/۷۸	۱۶/۳۹*	۱۰۰۰	۴	۱	۰/۹۹	مومنت	تائزانت هیپربولیک		
۲۴/۹۰	۲۲/۳۳	۱۲/۱۹	۴۲/۶۰	۲۴/۹۹	۱۰۰۰	۴	۱	۱	مومنت	تائزانت هیپربولیک		

*: نشان‌دهنده کمترین مقدار جذر میانگین مربعات خطأ در هر ستون می‌باشد.

جدول ۶ ارائه شده است. مشاهده می‌شود که کمترین مقدار جذر میانگین مربعات خطای هر پنج ایستگاه با تعداد ۴ نرون در لایه پنهان حاصل می‌شود (ساختار ۲۸).

آنالیز حساسیت

تأثیر ترکیب‌های مختلف از متغیرهای ورودی بر مقدار خطای آخرین ارزیابی مدل‌های تدوین شده بود. با اجرای آنالیز حساسیت (Sensitivity Analysis) برای هر مدل شبکه عصبی، می‌توان داده‌های ورودی غیر مرتبط (Irrelevant Inputs) را شناسایی و حذف کرد. حذف این داده‌ها هزینه جمع‌آوری داده‌ها را کاهش و در اغلب موارد دقت مدل را افزایش می‌دهد. آنالیز حساسیت نسبت به میانگین برای مدل‌های تدوین شده، توسط نرم‌افزار به کار رفته در این تحقیق، اجرا گردید (شکل ۳). با انجام این آنالیز در هر ایستگاه، داده‌های ورودی (یا به عبارتی پارش ماهانه ایستگاه‌هایی) که مدل حساسیت کمتری نسبت به آنها نشان داد، مشخص و حذف شد. بعد از حذف این داده‌ها، مدل شبکه عصبی با ترکیب جدید متغیرهای ورودی برای هر ایستگاه تدوین و پارامترهای متغیر آن جداً بهینه‌سازی شد. داده‌های ورودی حذف شده بعد از انجام آنالیز حساسیت، ساختار و نتایج آماری آموزش شبکه‌ها بعد از حذف داده‌ها در جدول ۷ ارائه شده است. با مقایسه نتایج آماری آموزش شبکه قبل و بعد از حذف داده ورودی (جدول ۶ و ۷)، ملاحظه می‌گردد که در همه ایستگاه‌ها با حذف داده ورودی دقت مدل افزایش می‌یابد. بنابراین در پنج ایستگاه مورد بررسی، حذف و تغییر در ترکیب داده‌های ورودی توصیه می‌شود.

تا این قسمت تعیین بهترین ساختار و طراحی دقیق‌ترین مدل شبکه عصبی برای پنج ایستگاه مورد بررسی تشریح گردید. ساختار بهترین مدل شبکه عصبی و نتیجه اجرای آن برای هر ایستگاه در جدول ۸ ارائه شده است. هم‌چنین مقادیر بارش ماهانه برآورد شده توسط مدل نهایی در مقابل داده‌های مشاهده شده برای هر یک از ایستگاه‌ها در شکل ۴ ترسیم شده است. در

آموزش، ساخته و اجرا شد که ساختار و نتایج آماری اجرای آنها در جدول ۴ ارائه شده است. با بررسی این جدول مشاهده می‌شود که برای پنج ایستگاه مورد بررسی، کمترین مقدار RMSE و در نتیجه بهترین مدل از نظر دقت با استفاده ازتابع انتقال سیگموئید و قانون آموزش لونبرگ مارکوارت حاصل می‌شود. در تدوین مدل‌هایی که در ساختار آنها از قانون آموزش مومنتم استفاده می‌شود، لازم است مقدار مومنتم، به نحوی که مدل دارای بیشترین دقت باشد، تعیین گردد. این عمل برای دو تابع انتقال به کار رفته در این تحقیق، در مرحله قبل انجام شد.

تعداد لایه میانی یا لایه پنهان (Hidden Layer)

برای یافتن بهترین تعداد لایه پنهان، شبکه‌های عصبی مختلف، با تعداد ۱ تا ۴ لایه پنهان، ساخته و اجرا شد. در آموزش این شبکه‌ها از تابع انتقال و قانون آموزش انتخاب شده در مرحله قبل استفاده گردید. از نتایج آماری آموزش این شبکه‌ها (جدول ۵) مشاهده می‌شود که با افزایش تعداد لایه پنهان از ۱ به ۴، در هر پنج ایستگاه مقدار جذر میانگین مربعات خطای (RMSE) کاهش نمی‌یابد و کمترین مقدار آن با همان یک لایه پنهان حاصل می‌شود. بنابراین تا این مرحله برای هر پنج ایستگاه، شبکه‌های عصبی با یک لایه پنهان به عنوان بهترین ساختار درنظر گرفته شد (ساختار ۲۸).

تعداد نرون‌های لایه پنهان

تعداد نرون‌ها (یا عناصر پردازشگر (Processing Elements, PEs)) در لایه پنهان به طوری که شبکه کمترین خطای داشته باشد، به روش آزمون و خطای تعیین می‌شود. به منظور یافتن بهترین تعداد نرون لایه پنهان، مدل‌های شبکه عصبی با ساختار ۱ تا ۱۲ نرون در لایه پنهان اجرا و معیارهای آماری محاسبه گردید. در اجرای این شبکه‌ها از همان داده‌های ورودی اولیه و تابع انتقال، قانون آموزش و تعداد لایه پنهان مناسب، که در مراحل قبل انتخاب شدند، استفاده گردید. نتایج آماری آموزش این شبکه‌ها در

جدول ۴. مقدار جذر میانگین مربعات خطأ (برحسب میلی‌متر) در شبکه‌های عصبی آموزش یافته با استفاده از تابع انتقال و قانون آموزش مختلف

جدر میانگین مربعات خطأ (mm)							ساختار	تابع انتقال	قانون آموزش	تعداد لایه پنهان	نرون لایه پنهان	حداکثر الگوها	سنندج	مظفرآباد	دیواندره	سقز	ایستگاه
۱۵/۰۵	۱۵/۷۵	۸/۱۲	۱۳/۲۲	۱۵/۰۳	۱۰۰۰	۴	۱	مومنت	تائزانت هیپربولیک	**							
۱۹/۵۰	۱۵/۹۱	۹/۵۸	۱۸/۰۲	۱۸/۶۹	۱۰۰۰	۴	۱	شیب مزدوج	تائزانت هیپربولیک	۲۵							
۱۵/۲۳	۱۵/۱۲	۸/۳۲	۱۵/۴۹	۱۹/۵۰	۱۰۰۰	۴	۱	لوبرگ مارکوارت	تائزانت هیپربولیک	۲۶							
۱۷/۸۰	۱۶/۲۳	۸/۶۱	۱۳/۶۲	۱۶/۳۹	۱۰۰۰	۴	۱	مومنت	سیگموئید	***							
۱۶/۱۹	۱۸/۴۰	۸/۷۵	۱۴/۳۹	۱۵/۳۲	۱۰۰۰	۴	۱	شیب مزدوج	سیگموئید	۲۷							
۱۴/۲۷*	۱۴/۹۶*	۷/۹۱*	۱۲/۳۶*	۱۴/۲۷*	۱۰۰۰	۴	۱	لوبرگ مارکوارت	سیگموئید	۲۸							

*: نشان‌دهنده کمترین مقدار جذر میانگین مربعات خطأ در هر ستون می‌باشد. ** و ***: به ترتیب جدول‌های ۲ و ۳ ملاحظه شود.

جدول ۵. مقدار جذر میانگین مربعات خطأ (برحسب میلی‌متر) در شبکه‌های آموزش یافته با تعداد مختلف لایه پنهان

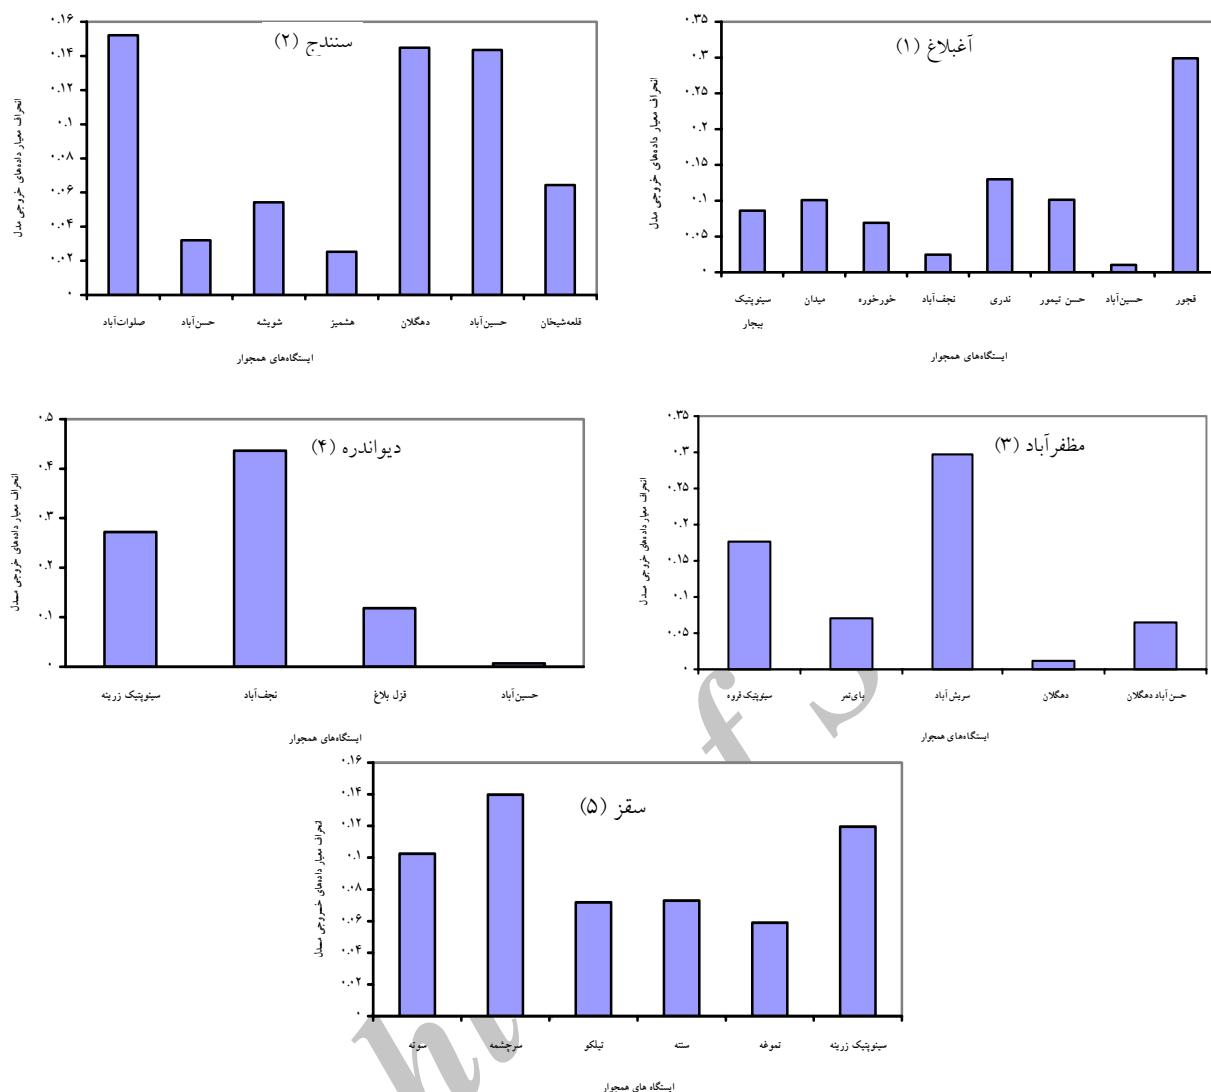
جدر میانگین مربعات خطأ (mm)							ساختار	تابع انتقال	قانون آموزش	تعداد لایه پنهان	نرون لایه پنهان	حداکثر الگوها	سنندج	مظفرآباد	دیواندره	سقز	ایستگاه
۱۴/۲۷*	۱۴/۹۶*	۷/۹۱*	۱۲/۳۶*	۱۴/۲۷*	۱۰۰۰	۴	۱	LM	سیگموئید	۲۸							
۱۸/۱۴	۱۶/۴۴	۸/۹۹	۱۸/۰۱	۱۵/۰۱	۱۰۰۰	۴	۲	LM	سیگموئید	۲۹							
۱۶/۴۹	۱۶/۱۸	۹/۱۴	۱۳/۲۲	۱۹/۴۵	۱۰۰۰	۴	۳	LM	سیگموئید	۳۰							
۱۵/۸۲	۲۷/۶۹	۸/۸۴	۱۷/۲۱	۱۴/۷۶	۱۰۰۰	۴	۴	LM	سیگموئید	۳۱							

*: نشان‌دهنده کمترین مقدار جذر میانگین مربعات خطأ در هر ستون می‌باشد. LM: نشانه اختصاری قانون آموزش لوبرگ مارکوارت است.

جدول ۶. مقدار جذر میانگین مربعات خطأ (برحسب میلی‌متر) در شبکه‌های عصبی تدوین شده با تعداد نرون‌های مختلف در لایه پنهان

جدر میانگین مربعات خطأ (mm)							ساختار	تابع انتقال	قانون آموزش	تعداد لایه پنهان	نرون لایه پنهان	حداکثر الگوها	سنندج	مظفرآباد	دیواندره	سقز	ایستگاه
۱۵/۹۳	۱۶/۱۱	۸/۷۱	۱۳/۱۰	۱۵/۲۵	۱۰۰۰	۱	۱	LM	سیگموئید	۳۲							
۱۶/۴۲	۱۶/۹۲	۸/۵۸	۱۵/۵۴	۱۷/۸۸	۱۰۰۰	۲	۱	LM	سیگموئید	۳۳							
۱۴/۳۷	۱۷/۴۲	۸/۲۷	۱۵/۸۹	۱۸/۶۱	۱۰۰۰	۳	۱	LM	سیگموئید	۳۴							
۱۴/۲۷*	۱۴/۹۶*	۷/۹۱*	۱۲/۳۶*	۱۴/۲۷*	۱۰۰۰	۴	۱	LM	سیگموئید	۲۸**							
۱۵/۳۱	۲۱/۴۷	۸/۷۲	۱۵/۲۵	۲۰/۹۲	۱۰۰۰	۵	۱	LM	سیگموئید	۳۵							
۱۶/۸۴	۱۵/۵۸	۹/۴۷	۱۲/۸۲	۱۸/۰۶	۱۰۰۰	۶	۱	LM	سیگموئید	۳۶							
۱۷/۲۴	۱۶/۴۸	۷/۹۲	۱۷/۹۴	۱۷/۰۴	۱۰۰۰	۷	۱	LM	سیگموئید	۳۷							
۲۱/۱۳	۱۶/۰۰	۹/۳۶	۱۵/۹۸	۱۶/۲۶	۱۰۰۰	۸	۱	LM	سیگموئید	۳۸							
۲۰/۳۱	۱۵/۸۸	۱۱/۸۹	۱۶/۱۲	۱۷/۸۹	۱۰۰۰	۹	۱	LM	سیگموئید	۳۹							
۱۹/۱۴	۱۹/۱۴	۸/۴۹	۱۲/۶۶	۱۸/۷۲	۱۰۰۰	۱۰	۱	LM	سیگموئید	۴۰							
۱۹/۷۲	۱۵/۲۰	۸/۰۷	۱۲/۸۸	۱۷/۵۹	۱۰۰۰	۱۱	۱	LM	سیگموئید	۴۱							
۲۳/۰۴	۱۸/۱۸	۹/۵۱	۱۳/۵۵	۱۹/۱۲	۱۰۰۰	۱۲	۱	LM	سیگموئید	۴۲							

*: نشان‌دهنده کمترین مقدار جذر میانگین مربعات خطأ در هر ستون می‌باشد. **: جدول ۵ ملاحظه شود.



شکل ۳. نتایج انجام آنالیز حساسیت مدل شبکه عصبی در پنج ایستگاه مورد بررسی این تحقیق

یابی شدند که در مرحله آزمون شبکه عصبی، نتایج برآورده شده توسط مدل، یا داده‌های خروجی (Output Data)، بهترین برازش را با داده‌های واقعی، یا داده‌های مطلوب، داشته باشند. برای اجرای این بهینه‌سازی، در الگوریتم ژنتیک از تلاقی دو نقطه‌ای با احتمال $0/9^0$ و جهش یکنواخت (Uniform Mutation) با احتمال $0/1^0$ استفاده گردید و تعداد تکرار $1,000$ ، تعداد جمعیت 40 و حداقل نسل تولید شده 100 در نظر گرفته شد.

پارامترهای مناسب شبکه‌های عصبی بهینه‌سازی شده و نتایج آماری اجرای این شبکه‌ها در جدول ۹ ارائه شده است. با بررسی جدول‌های ۸ و ۹ ملاحظه می‌شود که بهینه‌سازی

این شکل برای نمایش نتایج آماری آموزش شبکه نهایی در مرحله آزمایش مدل از علامت اختصاری NN استفاده شده است. با بررسی نتایج می‌توان نتیجه‌گیری نمود که روش شبکه عصبی در خصوص برآورده مکانی بارش ماهانه در هر پنج ایستگاه (به ویژه دو ایستگاه مظفرآباد و سنندج) عملکرد بسیار خوبی داشته است.

ب) شبکه عصبی بهینه‌سازی شده با الگوریتم ژنتیک در این تحقیق پارامترهای شبکه عصبی، شامل متغیرهای ورودی و تعداد نمونه‌ها در لایه پنهان، با الگوریتم ژنتیک به نحوی بهینه-

جدول ۷. داده‌های ورودی حذف شده بعد از انجام آنالیز حساسیت، ساختار و نتایج آماری آموزش شبکه‌ها بعد از حذف داده‌ها

مدل	ایستگاه	تعداد ورودی حذف شده	(ورودی‌های حذف شده) بارش ماهانه ایستگاه‌های	ساختار شبکه عصبی					
				تعداد نرون آموزش	تعداد لایه آموزش	قانون الگو	حداکثر پنهان	تعداد لایه پنهان	RMSE (mm)
۱	آغبلاغ	۲	حسین‌آباد نجف‌آباد	۶	سیگموئید	LM	۱۰۰۰	۱	۱۳/۵۳
۲	سنندج	۴	حسن‌آباد شویشه قلعه‌شیخان	۳	سیگموئید	LM	۱۰۰۰	۱	۱۱/۲۵
۳	مظفرآباد	۳	حسن‌آباد بای‌تمر دهگلان	۲	سیگموئید	LM	۱۰۰۰	۱	۷/۹۰
۴	دیواندره	۲	حسن‌آباد قزل‌بلاغ	۲	سیگموئید	LM	۱۰۰۰	۱	۱۴/۱۹
۵	سقز	۳	تموغه تیلکو	۳	سیگموئید	LM	۱۰۰۰	۱	۱۳/۳۱

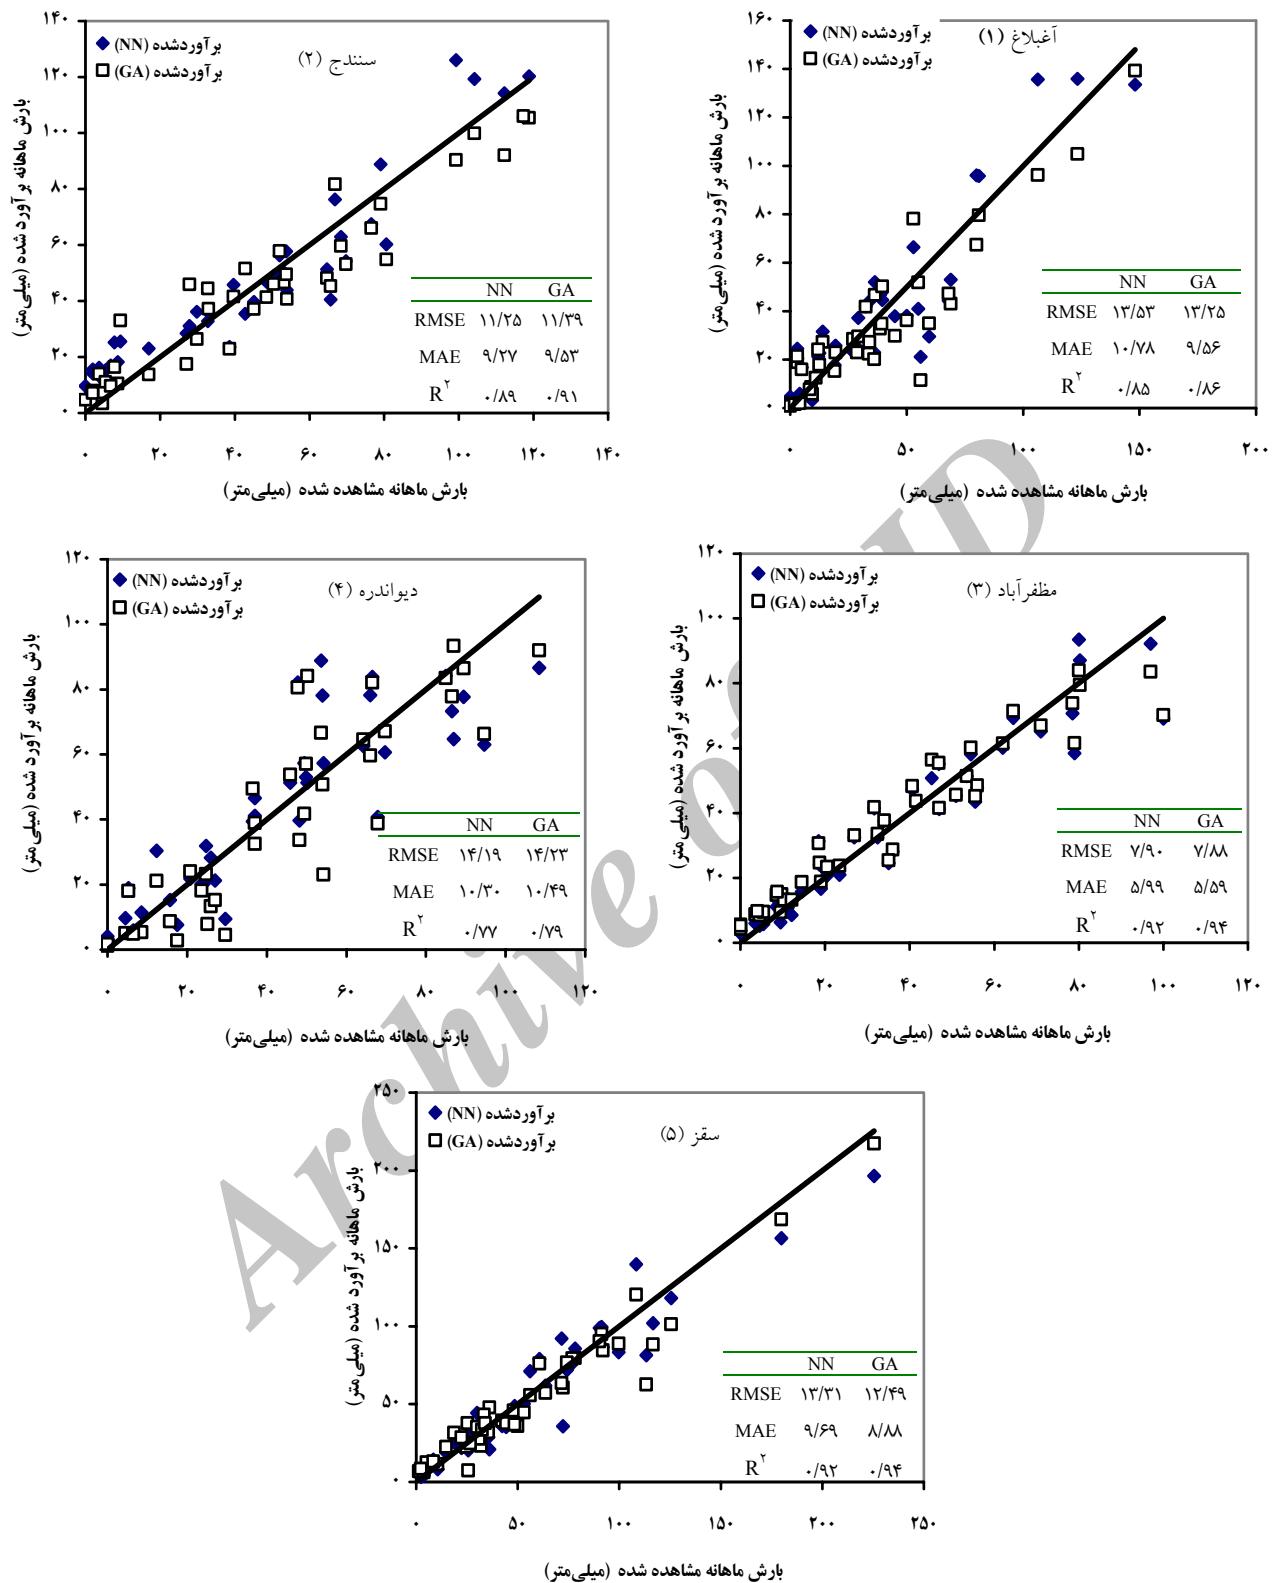
*: شایان ذکر است در این جدول به اختصار از نام ایستگاه به جای بارش ماهانه ایستگاه استفاده شده است. LM: نشانه اختصاری قانون آموزش لوینبرگ مارکوارت است.

جدول ۸. ساختار بهترین مدل شبکه عصبی و نتایج آماری اجرای آن در هر ایستگاه

ایستگاه	تعداد ورودی	تعداد نرون خروجی	تعداد لایه پنهان	تعداد لایه پنهان	تابع انتقال	قانون آموزش	حداکثر تکرار	بهترین تکرار	نتایج آماری		
									R ^r	MAE (mm)	RMSE (mm)
آغبلاغ	۶	۴	۱	۱	سیگموئید	LM	۱۰۰۰	۹۹۹	۰/۸۵	۱۰/۷۸	۱۳/۵۳
سنندج	۳	۲	۱	۱	سیگموئید	LM	۱۰۰۰	۲۲۳	۰/۸۹	۹/۲۷	۱۱/۲۵
مظفرآباد	۲	۴	۱	۱	سیگموئید	LM	۱۰۰۰	۹۱۴	۰/۹۲	۵/۹۹	۷/۹۰
دیواندره	۲	۴	۱	۱	سیگموئید	LM	۱۰۰۰	۷۳۵	۰/۷۷	۱۰/۳۰	۱۴/۱۹
سقز	۳	۴	۱	۱	سیگموئید	LM	۱۰۰۰	۴۰۹	۰/۹۲	۹/۶۹	۱۳/۳۱

جدول ۹. پارامترهای شبکه عصبی بهینه‌سازی شده با الگوریتم ژنتیک و نتایج آماری اجرای شبکه

مدل	ایستگاه	تابع انتقال	قانون آموزش	متغیرهای ورودی (بهینه‌یابی شده)						نتایج آماری			
				R ^r	MAE (mm)	RMSE (mm)	بهترین تکرار	حداکثر تکرار	تعداد نرون	تعداد لایه پنهان	تعداد لایه پنهان	تعداد	باresh ماهانه ایستگاه‌های
۱	آغبلاغ	سیگموئید	LM	حسن‌تیمور	قجر	بیجار	حسن‌تیمور	۲۲۳	۱۰۰۰	۴	۱	۹/۵۶	۱۳/۲۵
۲	سنندج	سیگموئید	LM	صلوات‌آباد			صلوات‌آباد	۱۰۰۰	۱۰۰۰	۴	۱	۹/۵۳	۱۱/۳۹
۳	مظفرآباد	سیگموئید	LM	سریش‌آباد	قروه	دهگلان	سریش‌آباد	۱۰۰۰	۱۰۰۰	۲	۱	۵/۵۹	۷/۸۸
۴	دیواندره	سیگموئید	LM	زرینه	قرزل‌بلاغ		قرزل‌بلاغ	۱۰۰۰	۱۰۰۰	۴	۱	۱۰/۴۹	۱۴/۲۳
۵	سقز	سیگموئید	LM	سرچشمہ	سته		سرچشمہ	۱۰۰۰	۱۰۰۰	۶	۱	۸/۸۸	۱۲/۴۹



شکل ۴. پردازش و نتایج آماری بارش ماهانه مشاهده شده و برآورده شده با استفاده از شبکه عصبی (NN) و شبکه عصبی بهینه‌سازی شده با الگوریتم ژنتیک (GA)

داد که در مسئله برآورد مکانی بارش ماهانه نیز، دقیق‌ترین مدل در همه ایستگاه‌های مورد مطالعه، با استفاده از تابع انتقال سیگموئید و قانون آموزش لونبرگ مارکوارت حاصل می‌شود. هم‌چنین بررسی‌ها نشان داده است که با افزایش اطلاعات ورودی عملکرد شبکه افزایش می‌یابد (۱۴). اما نتایج این تحقیق نشان داد، استفاده از اطلاعات (یا متغیر) ورودی بیش از حد (بهینه) می‌تواند موجب کاهش دقت مدل شود. بنابراین توصیه می‌گردد با انجام آنالیز حساسیت و یا با استفاده از روش الگوریتم ژنتیک ترکیب مناسب متغیرهای ورودی انتخاب گردد. در استان کردستان از ۱۰۱ ایستگاه (سینوپتیک، باران‌سنجد و اقلیم شناسی) متعلق به سازمان هواشناسی تنها ۱۳ ایستگاه دارای آمار بارش بیش از ۲۰ سال می‌باشد و از این ۱۳ ایستگاه فقط ۸ ایستگاه دارای آمار بارش ۳۰ سال و بیشتر از آن است که این تعداد ایستگاه برای انجام برنامه‌ریزی بلند مدت و مدیریت بهینه منابع آب در منطقه‌ای با وسعت ۲۸۲۰۳ کیلومترمربع بسیار کم می‌باشد. علاوه بر این، بنا به دلایل متعدد ایستگاه‌های منطقه دارای خلاء‌های آماری فراوان می‌باشند. بر این اساس برای افزایش دقت مطالعات باید آمار تعدادی از ایستگاه‌ها در منطقه تطویل و بازسازی گردد. اما کم بودن تعداد ایستگاه‌های مبنای، استفاده از روش‌های معمول برآورد داده‌های هواشناسی و هیدرولوژیکی را با مشکل مواجه نموده است، به طوری که برآوردهای به دست آمده به وسیله آنها از دقت کمی برخوردار می‌باشند. نتایج این تحقیق در مورد روش شبکه عصبی مصنوعی نشان داد، این روش نسبت به وجود تعداد ایستگاه در یک منطقه حساسیت کمی دارد. بنابراین در شرایطی که تعداد ایستگاه‌ها در یک منطقه کم است، می‌توان به وسیله این روش داده‌های مورد نیاز را با دقت مناسب، در ایستگاه‌هایی که دارای آمار ناقص و یا کوتاه مدت می‌باشند، تخمین زد.

بیشتر مطالعات مربوط به استفاده از شبکه‌های عصبی در پیش‌بینی و برآورد بارش، به کاربرد شبکه‌های پرسپترون پیش‌خور چند لایه مربوط می‌شود که با نتایج خوبی همراه بوده‌اند (۷ و ۱۳). نتایج به دست آمده در این تحقیق نیز نشان

شبکه عصبی با الگوریتم ژنتیک، در ایستگاه‌های آغلاغ، مظفرآباد و سقر موجب افزایش دقت مدل شده و بر عکس در دو ایستگاه سنتنچ و دیواندره، بهینه‌سازی شبکه به مقدار بسیار کمی موجب کاهش دقت مدل شده است. از آنجا که در ایستگاه‌های سنتنچ و دیواندره نیز شبکه‌های بهینه‌سازی شده از دقت مناسبی برای برآورد مکانی بارش برخودار می‌باشند می‌توان نتیجه‌گیری نمود که الگوریتم ژنتیک روش مناسبی برای بهینه‌سازی شبکه عصبی در خصوص برآورد مکانی بارش می‌باشد. در شکل ۴، نتایج برآورد شده توسط شبکه بهینه‌سازی شده در مقابل داده‌های مشاهده شده، برای هر ایستگاه در مرحله آزمایش مدل، ترسیم شده است. در این شکل برای نمایش نتایج آماری روش تلفیقی (شبکه عصبی و الگوریتم ژنتیک) از علامت اختصاری GA استفاده شده است. مشاهده می‌شود که این روش در برآورد مکانی بارش ماهانه از توانایی بالایی برخوردار است و داده‌های برآورد شده توسط آن دارای جور شدگی و انطباق بسیار خوبی با داده‌های واقعی می‌باشند.

نتیجه‌گیری

در ارائه نتایج سعی بر این بود که کارایی شبکه عصبی مصنوعی و تأثیر بهینه‌سازی پارامترهای آن از طریق الگوریتم ژنتیک، در برآورد مکانی بارش بررسی شود. به طور کلی می‌توان گفت که در این مسئله نیز، مانند بسیاری از مسائل مهندسی، شبکه عصبی مصنوعی موفق است. هم‌چنین تلفیق آن با الگوریتم ژنتیک، برای بهینه‌سازی شرایط اجرای شبکه عصبی، مثبت ارزیابی می‌شود و در اکثر موارد روش تلفیقی برتری خود را نسبت به اجرای شبکه عصبی بدون بهینه‌سازی نشان می‌دهد.

از آنجا که مشتق تابع سیگموئید بر حسب مقدار خود تابع قابل بیان می‌باشد، در اغلب موارد از این تابع به عنوان تابع انتقال استفاده می‌شود (۱۰). هم‌چنین تحقیقات نشان داده است که قانون آموزش لونبرگ مارکوارت برای اکثر کاربردها نتایج دقیق و سریعی نسبت به سایر قانون‌های روش آموزش انتشار به عقب خط ارائه می‌دهد (۲۰ و ۲۳). نتایج این تحقیق نشان

عصبی، نظری شبکه چند جزئی در مورد این مسئله به کار رود و نتایج با هم‌دیگر مقایسه گردد. هم‌چنین مقایسه نتایج شبکه‌های عصبی با روش‌های زمین آمار و روش‌های سنتی، شامل عکس فاصله و نزدیک‌ترین همسایه، نیز قابل توصیه است.

دهنده توانایی بالای این نوع شبکه عصبی مصنوعی برای تدوین مدل برآورده مکانی بارش ماهانه در منطقه مورد مطالعه می‌باشد. اما شایان ذکر است که شبکه‌های عصبی دارای ساختارهای متنوعی می‌باشند، بنابراین توصیه می‌شود انواع دیگر شبکه‌های

منابع مورد استفاده

۱. اسماعیلی ورکی، م. امید و م. ح. امید. ۱۳۸۴. برآورد مشخصات هیدرولیکی واگرا با استفاده از شبکه عصبی مصنوعی. علوم کشاورزی ایران (۱۲): ۳۲-۲۱.
 ۲. بهمنی، ع.، ش. ابراهیمی و س. ا. قلی‌نژاد. ۱۳۸۵. تهیه مدل ANN بارش - رواناب در حوضه‌های آبریز و بررسی قابلیت تعمیم‌پذیری آن برای ایستگاه‌های مجاور. دومین کنفرانس مدیریت منابع آب ایران. ۳ و ۴ بهمن، دانشگاه صنعتی اصفهان.
 ۳. پرورش ریزی، ع.، ص. کوچکزاده و م. ح. امید. ۱۳۸۵. برآورد مشخصات پرش هیدرولیکی متحرک با کاربرد شبکه عصبی مصنوعی و روش تلفیقی شبکه عصبی - الگوریتم ژنتیک. علوم کشاورزی ایران (۳۷): ۱۹۶-۱۸۷.
 ۴. ثمره هاشمی، م. و غ. ع. بارانی. ۱۳۸۴. مقایسه نتایج استفاده از الگوریتم ژنتیک در بهینه‌سازی عملکرد سدها. مجموعه مقالات دومین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک، ۳ و ۴ اسفند، دانشگاه شهید باهنر کرمان، صفحات ۴۲۶-۴۲۰.
 ۵. جهانگیر، ع. ۱۳۸۴. شبیه‌سازی فرآیند بارش - رواناب با استفاده از شبکه عصبی مصنوعی (ANN) و مقایسه HEC-HMS در حوضه معرف کارده. پایان‌نامه کارشناسی ارشد، دانشکده کشاورزی، دانشگاه مازندران.
 ۶. زارع زاده مهریزی، م. و ا. فراق. ۱۳۸۶. پیش‌بینی جریان رودخانه در با استفاده از شبکه عصبی مصنوعی. مجموعه مقالات نهمین سمینار سراسری آبیاری و کاهش تبخیر، دانشگاه شهید باهنر کرمان.
 ۷. عابدینی، م. ج. و ا. پولادی. ۱۳۸۲. مقایسه عملکرد شبکه عصبی مصنوعی با سایر روش‌ها در برآورد مکانی بارندگی روزانه. مجموعه مقالات ششمین کنفرانس بین‌المللی مهندسی عمران، ۱۵ تا ۱۷ اردیبهشت، دانشگاه صنعتی اصفهان.
 ۸. کوهیان افضل، ف. و ج. پرهمت. ۱۳۸۵. برآورد توزیع مکانی بارش با استفاده از شبکه‌های عصبی مصنوعی چندجزئی. دومین کنفرانس مدیریت منابع آب ایران، ۳ و ۴ بهمن، دانشگاه صنعتی اصفهان.
 ۹. منعم، م. ج. ۱۳۷۶. استفاده از روش ژنتیکی در مدل مشابه سازی شبکه‌های آبیاری (ICSS-POM) برای بهینه‌سازی عملکرد آنها. مجموعه مقالات اولین کنفرانس هیدرولیک ایران، صفحات ۳۱۹-۳۰۸.
 ۱۰. منهاج، م. ب. ۱۳۸۴. مبانی شبکه‌های عصبی (هوش محاسباتی). جلد اول، مرکز نشر پرسور حسابی.
 ۱۱. مهدی، م.، ش. زند پارسا، ع.، سپاسخواه، س. ع. ا. موسوی و م. کمپانی زارع. ۱۳۸۶. تخمین توابع هیدرولیکی خاک به روش معکوس با استفاده از الگوریتم ژنتیک در شرایط مزرعه. مجموعه مقالات نهمین سمینار سراسری آبیاری و کاهش تبخیر، دانشگاه شهید باهنر کرمان.
 ۱۲. مهدوی، م. ۱۳۷۷. هیدرولوژی کاربردی. جلد اول، انتشارات دانشگاه تهران.
13. Ahmad, S. and S. P. Simonovic. 2000. Developing Runoff Hydrology Using Artificial Neural Networks. University of Western Ontario, Canada, 17 pp.
14. Chuan, C. S. 1997. Weather prediction using artificial neural network. J. Hydrol. 230: 101-119.
15. Coulibaly, P., F. Anctil and B. Bobee. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. J. Hydrol. 230: 214-257.

16. Dandy, G. C., A. R. Simpson, and L. J. Murphy. 1996. An Improved Genetic Algorithm for Pipe Network Optimization. *Water Resour. Res.* 32(2): 449–458.
17. Franchini, M. 1996. Use of a Genetic Algorithm combined with a local Search method for the automatic Calibration of Conceptual Rainfall-Runoff Models. *Hydrol. Sci. J.* 41(1): 21-39.
18. French, M. N., W. F. Krajewski and R. R. Cuykendall. 1992. Rainfall Forecasting in Space and Time Using a Neural Network. *J. Hydrol.* 137: 1-31.
19. Goldberg, D.E. 1989. *Genetic Algorithm in Search Optimization and Machine Learning*. Addison-Wesley, Reading, Massachusetts, USA.
20. Hagan, M. T. and M. B. Menhaj. 1994. Training feed forward networks with the Marquardt algorithm. *IEEE Trans. on Neural Networks* 5: 989-993.
21. Holland, J. H. 1975. *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. Ann Arbor, University of Michigan Press., USA.
22. Ramirez, M. C. V., H. F. C. Velho and N. J. Ferreira. 2005. Artificial neural network technique for rainfall forecasting applied to the São Paulo region. *J. Hydrol.* 301: 146-162.
23. Tan, Y. and A. Van Cauwenbergh. 1999. Neural-Network-Based d-step-ahead predictors for nonlinear systems with time delay. *Eng. Appl. of Artificial Intell.* 12: 21-25.
24. Wang, Q. J. 1991. The genetic algorithm and its application to calibrating conceptual rainfall-runoff models. *Water Resour. Res.* 27(9): 2476-2471.