

پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مورد: تهران)

دکتر محمد حسین قلی‌زاده* - استادیار دانشگاه کردستان
محمد دارند - دانشجوی دکتری آب و هواشناسی دانشگاه اصفهان

پذیرش مقاله: ۱۳۸۷/۱۰/۲۵ تأیید نهایی: ۱۳۸۸/۱۱/۲۰

چکیده

گسترش سریع استفاده از شبکه‌های عصبی مصنوعی (ANN^۱) به عنوان مدل تجربی و کارآمد در علوم مختلف از جمله هواشناسی و اقلیم‌شناسی نشان دهنده ضرورت ارزش بالای مطالعه این مدل‌هاست. پیش‌بینی بارش برای اهداف مختلفی نظیر برآورد سیلاب، خشکسالی، مدیریت حوضه آبریز، کشاورزی و ... دارای اهمیت بسیاری است. هدف این مقاله پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی در شهر تهران می‌باشد. در این تحقیق از داده‌های بارش ماهانه طی دوره آماری ۵۳ سال (۱۹۵۱-۲۰۰۳) و شبکه‌های عصبی مصنوعی به عنوان یک روش غیر خطی جهت پیش‌بینی بارش استفاده شده است. نتایج این تحقیق بعد از آزمون شبکه با لایه‌های پنهان و با ضرایب یادگیری مختلف نشان داد که استفاده از شبکه‌های عصبی مصنوعی با یک پرسپترون ۲ لایه پنهان با ضریب یادگیری ۰/۱ و مومنتم ۰/۷ مدل نسبتاً بهتری را ارائه می‌کند. ضریب همبستگی بین مقادیر واقعی ماهانه بارش و پیش‌بینی شده توسط شبکه بدون ترکیب با الگوریتم ژنتیک برابر با ۰/۸۸ و ضریب تعیین برابر با ۰/۷۷ می‌باشد. همچنین بعد از آموزش مجدد شبکه و آزمون شبکه با لایه‌های پنهان و ضرایب مختلف یادگیری در ترکیب با الگوریتم ژنتیک نشان داد که ترکیب شبکه با ویژگی‌های مذکور با الگوریتم ژنتیک باعث کاهش خطا و افزایش سرعت محاسبات شده و مدل بهتری را ارائه می‌کند. ضریب همبستگی بین مقادیر واقعی ماهانه بارش و پیش‌بینی شده توسط شبکه برابر با ۰/۹۱ و ضریب تعیین برابر با ۰/۸۳ می‌باشد.

کلیدواژه‌ها: بارش، پیش‌بینی، شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک، تهران.

مقدمه

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. شبکه‌های عصبی مصنوعی به عنوان یک مدل تجربی برای اولین بار از فرموله کردن توانایی‌های مغز انسان توسط مک کالچ و پیترس^۲ (۱۹۴۳، ۱۱۵) ارائه گردید. شبکه‌های عصبی مصنوعی گسترش خود را مدیون تلاشهای هاپل‌فیلد در دو دهه اخیر می‌باشند (هایکین^۳، ۱۹۹۴). کراس^۴ و همکاران (۱۹۹۵، ۱۰۷۵) در مقاله مروری در مورد مبانی شبکه‌های عصبی اشاره می‌کنند که شبکه‌های عصبی مصنوعی که اغلب شبکه‌های عصبی خوانده می‌شود به عنوان یک مدل تشخیص روندهای ناپارامتری و غیر خطی می‌تواند روابط غیر خطی پیچیده یا لایه‌های پنهان بین متغیرهای وابسته و مستقل را پیدا کند و با دقت بهتری نسبت به روش‌های آماری از جمله روش رگرسیونی عمل نماید. ناماسیویام^۵ و همکاران (۲۰۰۱، ۱۲۳) نشان دادند که اگر بین پارامترهای مورد بررسی رابطه غیر خطی آشکاری وجود نداشته باشد، شبکه عصبی نمی‌تواند در مقایسه با رگرسیون نتیجه بهتری را ارائه دهد. قبلاً برای پیش‌بینی بارش و سربهای زمانی از روش رگرسیون خطی استفاده می‌شد. لاپدیس و فاربر^۶ (۱۹۸۷) در یک گزارشی نشان دادند شبکه‌های عصبی کاربردهای زیادی در پیش‌بینی سربهای زمانی دارند. در سالهای اخیر استفاده از شبکه‌های عصبی مصنوعی برای

* E-mail: haman_suna@yahoo.com

^۱- Artificial Neural Networks

^۲- McCulloch and Pitts

^۳- Haykin

^۴- Cross

^۵- Namasivayam

^۶- Lapedis and Farber

مدلسازی بارش توسط محققین فراوانی بکار گرفته شده است (ناوونه و سیکاتو^۷، ۱۹۹۴، ۳۰۵). به نظر می‌رسد که اولین سیستم تخمین مکانی - زمانی بارندگی با استفاده از شبکه‌های عصبی مصنوعی را فرنچ و همکاران^۸ در سال ۱۹۹۲ ارائه کردند. پس از فرنچ در سال ۱۹۹۴، توما و ایگاتا^۹ با بکارگیری یک شبکه سه لایه ای به پیش بینی بارندگی پرداختند. هاستینراس و همکاران^{۱۰} (۱۹۹۵، ۱۵۱۱) از شبکه‌های عصبی مصنوعی جهت پیش بینی 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 غیر خطی شبکه‌های عصبی مصنوعی قابل پیش بینی است. هال و همکاران^{۱۱} (۱۹۹۷، ۳۳۸) با بکارگیری گروه‌های متصل شبکه ای به پیش بینی بارندگی پرداختند، که مسیر ورودی و خروجی با گروه‌های بهم پیوسته عصبی سازماندهی شده بود و نشان دادند که میزان همبستگی بین بارش واقعی و بارش پیش بینی شده توسط شبکه‌های عصبی برابر با ۹۵ درصد می‌باشد.

توکار و سنتون^{۱۲} (۱۹۹۹، ۲۳۲) با استفاده از شبکه عصبی به پیش بینی 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 برآزش مدل صرف می‌شود. کوازوس (۲۰۰۰، ۱۷۱۸) با استفاده از شبکه‌های عصبی مصنوعی به پیش بینی بارش روزانه بالکان پرداخت و نشان داد که شبکه‌های عصبی مصنوعی ابزار سودمندی برای پیش بینی بارش روزانه در منطقه مورد نظر می‌باشد.

ترافالیس و همکاران^{۱۳} (۲۰۰۲، ۷۷۵) از شبکه‌های عصبی مصنوعی با معماری‌های مختلف مقادیر بارش را پیش بینی کردند. ایشان از داده‌های بارش رادار به عنوان داده‌های ورودی شبکه استفاده کردند و نتایج حاصل از برآزش 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. حسامی^{۱۴} و همکاران (۲۰۰۴، ۱۰۷) از شبکه‌های عصبی مصنوعی برای کالیبره کردن تخمین بارش با استفاده از داده‌های هواشناسی رادار استفاده کردند و به این نتیجه رسیدند که تابع لیونبرگ - می‌تواند تابع قابل قبولی برای کالیبره کردن تخمین داده‌های بارش رادار باشد. ماریا^{۱۵} و همکاران (۲۰۰۵، ۱۴۶) به کمک مدل‌های شبکه عصبی مصنوعی و رگرسیونی بارش منطقه سائوپولو برزیل را پیش‌بینی کردند. ایشان نشان دادند که نتایج و برآورد دو مدل مذکور برای منطقه مورد مطالعه بسیار دقیق است. چاتوپادهیای^{۱۶} (۲۰۰۷، ۳۶۹) با استفاده از مدل پرسپترون چند لایه در شبکه‌های عصبی مصنوعی بارش فصلی هند را پیش‌بینی کرد. در یک مطالعه‌ی دیگر بوستامی^{۱۷} و همکاران (۲۰۰۷، ۱۰) بارش و سطح آب را در بوداپ مالزی با استفاده از تکنیک شبکه‌های عصبی مصنوعی پیش‌بینی کردند. نتایج ایشان نشان داد که شبکه‌های عصبی مصنوعی با دقت ۹۶/۴ درصد قابلیت پیش بینی بارش را در رودخانه مورد مطالعه دارد. هونگ^{۱۸} و همکاران (۲۰۰۸، ۱۸۳) به کمک یکسری پارامترهای هواشناسی با بهره‌گیری از مدل‌های شبکه‌های عصبی مصنوعی به پیش بینی بارش پرداخت.

آکسوی و داهامشه^{۲۰} (۲۰۰۹، ۹۱۷) با استفاده از مدل شبکه‌های عصبی مصنوعی بارش ماهانه اردن را پیش بینی کردند. نتایج ایشان نشان داد که در سه ایستگاه مورد مطالعه با توجه به معیارهای مورد نظر نظیر ضریب تعیین میانگین مربع خطاها و غیره بهترین مدل، مدل انتشار پس انتشار روبه جلو می‌باشد. در مطالعه‌ای دیگر داهامشه و آکسوی^{۲۱} (۲۰۰۹، ۳۲۵) با استفاده از شبکه‌های عصبی مصنوعی بارش ماهانه مناطق خشک اردن را پیش بینی کردند. ایشان برای انجام این کار از مدل و الگوریتم پس انتشار رو به جلو استفاده کردند و نتایج را با رگرسیون چند متغیره مقایسه کردند. نتایج نشان داد که شبکه‌های عصبی مصنوعی

7- Navonne and Ceccatto

8- French et al

9- Tohma, and Igata

10- Hastenrath and Greischar

11- Hall et al

12- Tokar and Santon

13- Trafalis

14- Hessami

15- Ievenberg-Marquardt

16- Maria

17- Chattopadhyay

18- Bustami

19- Hung

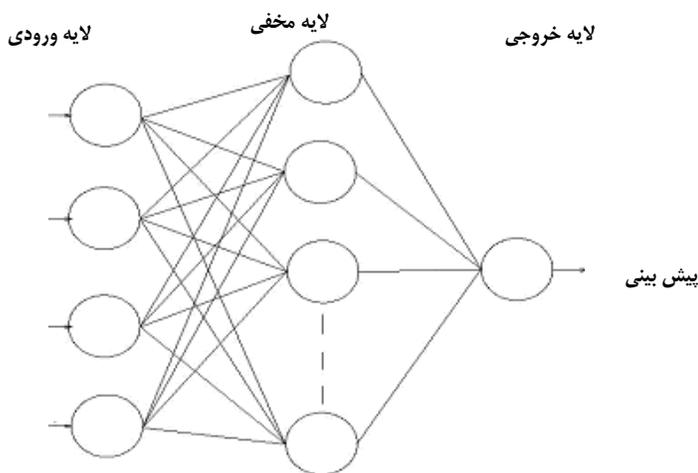
20- Aksoy and Dahamsheh

21- Dahamsheh and Aksoy

نتایج بهتری را نسبت به رگرسیون چند متغیره ارائه می‌کند. در ایران، شمس (۱۳۸۲) در پایان‌نامه خود کاربرد شبکه عصبی مصنوعی در تجزیه زمانی بارندگی را مورد تجزیه و تحلیل قرار داده است. میثاقی (۱۳۸۲) از توسعه الگوریتم ترکیبی زمین آمار و شبکه‌های عصبی مصنوعی بمنظور استخراج توزیع مکانی بارندگی استفاده کرد و به این نتیجه رسید که روش‌های زمین آماری و تخمینگرهای کریجینگ و کوکریجینگ نتایج برتری را نشان می‌دهد. احمدی (۱۳۸۲) به طبقه‌بندی تغییرات بارش بوشهر با استفاده از شبکه‌های عصبی مصنوعی مبتنی بر مدل خود سازمانده کوهونن پرداخت و به این نتیجه رسید که روش شبکه‌های عصبی مصنوعی می‌تواند برای بیشتر پارامترهای اقلیمی و با بازه زمانی بلندتر به کار رود. خلیلی (۱۳۸۵) با استفاده از شبکه‌های عصبی مصنوعی بارش ماهانه ایستگاه سینوپتیک مشهد را مطالعه کرد. نتایج نشان داد که شبکه‌های عصبی مصنوعی بخوبی روند بارش ماهانه را در ایستگاه مذکور پیش‌بینی کند. هدف اصلی این مقاله پیش‌بینی مقادیر بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی در شهر تهران می‌باشد.

مشخصات شبکه عصبی

اساس شبکه‌های عصبی مصنوعی در واقع شبیه سازی و مدل سازی تفکر مغز انسان از طریق سلولهای عصبی می‌باشد. هر سلول عصبی به عنوان یک واحد پردازشگر عددی عمل می‌کند. نرونهاى شبکه با هم در ارتباط بوده و به صورت موازی کار می‌کنند. شکل ۱ ساختار شبکه عصبی مصنوعی را نشان می‌دهد.



شکل ۱- مدل شبکه عصبی برای پیش بینی

الگوریتم پس انتشار^{۲۲} (BP)

یکی از پر کاربردترین مدل‌های شبکه عصبی، مدل پرسپترون چندلایه است که روی الگوریتم پس انتشار، پایه گذاری شده است. اساس آموزش الگوریتم پس انتشار به این صورت است که وزن‌های اولیه ارتباطی به صورت تصادفی انتخاب می‌گردند. با فرض وجود N نمونه آموزشی که هر نمونه n ورودی و l خروجی داشته باشد، بردار ورودی به صورت $X_j = (X_{1j}, \dots, X_{nj})$ و بردار خروجی به صورت $B_j = (B_{1j}, \dots, B_{lj})$ که $1 \leq j \leq N$ ، تعریف می‌گردد. فرآیند آموزش با استفاده از دو گام زیر اتفاق می‌افتد.

۱- انتشار به جلو^{۲۳}: بردار ورودی X_j به لایه ورودی فرستاده می‌شود و یک بردار خروجی $O_j = (O_{1j}, \dots, O_{lj})$ براساس وزن‌های جاری $W = (W_{1l}, \dots, W_{nl})$ ایجاد می‌گردد. مقدار O_j با مقدار خروجی واقعی یعنی B_j مقایسه شده و تابع خطای

²²- Back propagation

²³- Forward propagation

E تولید می‌شود.

$$E = \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^N (B_{ij} - O_{ij})^2 \quad (1)$$

۲- انتشار خطا به عقب^{۲۴}: در این گام، خطای بدست آمده از معادله ۱ بوسیله رابطه زیر روی وزن‌ها توزیع می‌گردد.

$$\Delta W_{nl} = -\frac{\partial E}{\partial W_{nl}} \eta \quad (2)$$

ضریب $0 < \eta < 1$ پارامتری است که همگرایی نرخ الگوریتم را کنترل می‌نماید.

این دو مرحله آنقدر ادامه می‌یابد تا مقدار E به مقدار کوچک از پیش تعیین شده‌ای همگرا گردد. در حقیقت شبکه، با توزیع خطای بدست‌آمده (در هر مرحله) روی وزن‌های قبلی و تکرار این عملیات، آموزش می‌بیند. به تعداد این تکرارها اصطلاحاً اپاک^{۲۵} و به روشی که خطاها را به طور معکوس (رو به عقب) روی وزن‌ها توزیع می‌نماید دلتا بار دلتا^{۲۶} گفته می‌شود. الگوریتم پس انتشار^{۲۷} توضیح داده شده در بالا برای مسائل واقعی اغلب بسیار کند است. به منظور غلبه بر این مشکل از الگوریتم ژنتیک^{۲۸} برای انتخاب بهترین وزن‌های اولیه الگوریتم انتشار به عقب استفاده می‌گردد.

ترکیب الگوریتم ژنتیک با شبکه‌های عصبی

یکی از روش‌هایی که برای بهینه‌سازی چند متغیری استفاده می‌شود، الگوریتم ژنتیک است. شکل مدرن الگوریتم ژنتیک در سال ۱۹۶۰ بوجود آمد. الگوریتم ژنتیک توانایی این را دارد که محدوده وسیعی از مسائل بهینه سازی پیچیده را فقط با استفاده از سه عملیات ژنتیکی ساده (انتخاب، تقاطع و جهش) و براساس استفاده از پارامترهای کدبندی شده به جای خود پارامترها، حل نماید. الگوریتم ژنتیک به چندین نکته در فضای تحقیق به طور همزمان توجه می‌نماید و شانس همگرایی به یک بهینه موضعی را کاهش می‌دهد (جویدیت^{۲۹}، ۱۹۹۰). مزیت این روش این است که علاوه بر زمان اجرای کم با یک بار اجرای برنامه می‌توان به تمام نقاط بهینه رسید و کار طراح در تصمیم‌گیری بسیار آسان می‌شود. روش کار به این صورت است که ابتداء جمعیتی به صورت کاملاً تصادفی ایجاد می‌شود. این جمعیت، شامل تعدادی کروموزوم می‌باشد که هر کروموزوم یک جواب مساله است و با کدبرداری نمودن آن می‌توان مقدار هر متغیر را بدست آورد. این جمعیت به دو بخش تقسیم می‌گردد، بخش ثابت و بخش متغیر. سپس از این جمعیت، جمعیت اولیه کوچکتری به صورت تصادفی انتخاب می‌گردد. جمعیت انتخاب شده بر اساس تابع برازندگی رتبه‌بندی می‌شود و براساس رتبه، کروموزوم‌های برتر انتخاب می‌گردند. همچنین یکی از کروموزوم‌های برتر بدون تغییر به مرحله بعد (نسل بعد) راه می‌یابد که به این عمل نخبه‌گرایی می‌گویند. سپس جمعیت جدید ایجاد می‌شود و حلقه‌ی داخلی فلوچارت تا رسیدن به معیار همگرایی که می‌تواند طی تعداد مشخصی نسل باشد، تکرار می‌گردد. مراحل و نحوه عمل الگوریتم ژنتیک در شکل ۲ نشان داده شده است.

مواد و روش‌ها

از لحاظ موقعیت مکانی شهر تهران در ۳۵ درجه و ۳۵ دقیقه تا ۳۵ درجه و ۴۸ دقیقه عرض شمالی و ۵۱ درجه و ۱۷ دقیقه تا ۵۱ درجه و ۳۳ دقیقه طول شرقی در کوهپایه‌های جنوبی رشته کوه‌های البرز گسترده شده است. مساحت شهر تهران حدود ۸۰۰ کیلومتر مربع می‌باشد. ارتفاع شهر در جنوب در فرودگاه مهرآباد ۱۲۰۰ متر و در شمال به ۲۰۰۰ متر می‌رسد. شکل ۳ نشان دهنده منطقه مورد مطالعه می‌باشد. در این تحقیق از داده‌های ماهانه بارش ایستگاه سینوپتیک تهران طی دوره آماری ۱۹۵۱-۲۰۰۳ استفاده شده است. در شهر تهران تنها ایستگاه مذکور دارای آماری بلند مدت و بالای ۵۰ سال می‌باشد. به همین دلیل از داده‌های ایستگاه‌های دیگر استفاده نشده است. جهت پیش بینی بارش از شبکه عصبی مصنوعی و الگوریتم ژنتیک استفاده شد.

²⁴ - Error Back propagation

²⁵ - Epoch

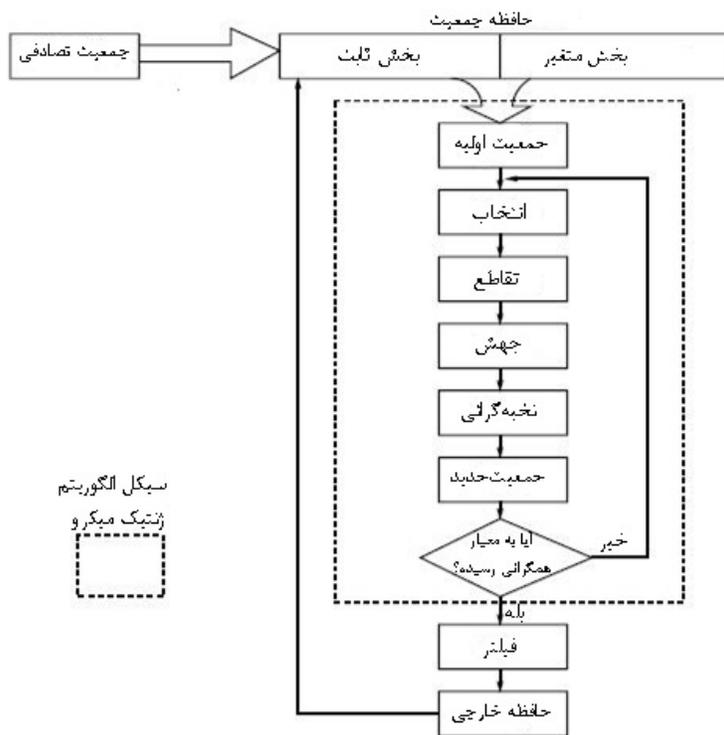
²⁶ - DeltaBarDelta

²⁷ - Backup Propagation Algorithm

²⁸ - Genetic Algorithm

²⁹ - Judith

در این مقاله ابتدا کل داده‌های مورد استفاده در شبکه به دو قسمت مجزای تقسیم شد که نیمی از داده‌ها برای آموزش شبکه و نیمی دیگر از داده‌ها جهت آزمون داده‌ها اختصاص داده شد. تابع تان اکسون^{۳۰} که تابع معروفی در روش انتشار پس انتشار است، به عنوان تابع تحریک استفاده شده است. این تابع، بازه هر نرون را میان دو مقدار ۱- و ۱ که همان ضریب همبستگی می‌باشد، فشرده می‌نماید. ضریب همبستگی، بیان کننده مقداری است که میزان رابطه میان خروجی شبکه با مقدار واقعی را مشخص می‌نماید.



شکل ۲. نحوه عمل الگوریتم ژنتیک

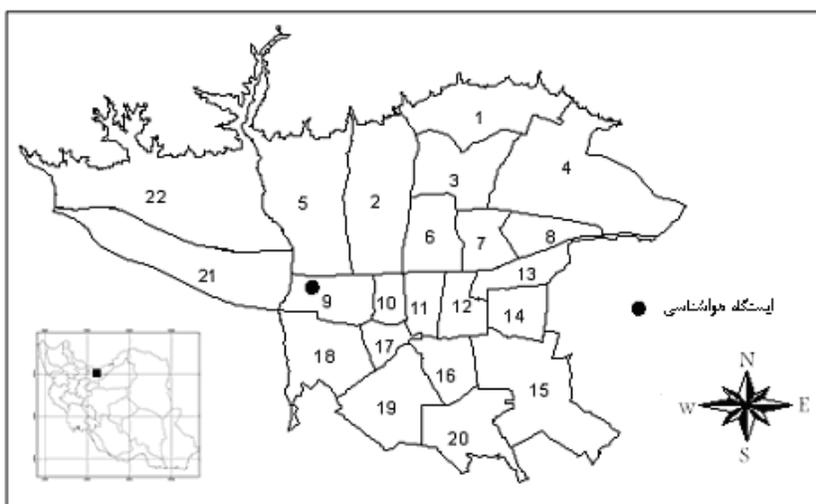
این ضریب از ۱- تا ۱ تغییر می‌نماید. مقدار ۱ برای ضریب همبستگی به این معنا است که خروجی با مقدار واقعی کاملاً تطابق دارد و ۱- به این معنا است که خروجی و مقدار واقعی کاملاً معکوس هم عمل می‌نمایند. شبکه‌ای با قابلیت مناسب جهت پیش‌بینی مسائل غیرخطی فراهم می‌آورد و برای آموزش شبکه عصبی از نرم‌افزار NeuroSolutions برای مت لب استفاده شده است. فرمت داده‌ها بصورت نوت پد و متنی (txt) است. روش کار به این صورت است که سال و تعداد ماهها یک بار به عنوان پارامتر ورودی و پارامتر میانگین ماهانه بارش به عنوان خروجی در نظر گرفته شدند. به منظور کاهش خطای پیش‌بینی، سعی و خطا روی پارامترهای شبکه، انجام شد و در نهایت پارامترها به صورت زیر تنظیم شدند. برای آموزش شبکه از مدل پرسپترون چندلایه^{۳۱} استفاده شد که در جدول ۱ آمده است. تعداد لایه‌های مخفی^{۳۲} برای آموزش شبکه برابر با ۲ و از روش آموزش دلتا بار دلتا با ضریب یادگیری ۰/۱ که سرعت تطبیق وزن‌های میان نرون‌ها را کنترل می‌نماید یا به عبارتی در واقع طول گام‌ها را در هر بار اصلاح پارامترهای شبکه مشخص می‌کند استفاده شد. تابع تحریک تان اکسون، تعداد نرون‌های لایه مخفی^{۳۳} برای آموزش شبکه برابر با ۲ و ضریب مومنتوم که یکی از پارامترهای اصلی آموزش است که نسبت تاثیر وزن‌های قبلی به وزن‌های جدید را مشخص می‌نماید برابر با ۰/۷ و تعداد اپاک یک هزار (۱۰۰۰) استفاده شد. یک مدل شبکه عصبی سه لایه‌ای، شامل

³⁰ -TanhAxon
³¹ - Multilayer perceptron
³² - Hidden Layer
³³ - Processing Element

لایه ورودی، لایه خروجی و لایه مخفی مانند شکل ۱ ایجاد گردید. شبکه یک بار بدون ترکیب با الگوریتم ژنتیک و بار دیگر در ترکیب با الگوریتم ژنتیک آموزش داده شد.

جدول شماره ۱- پارامترهای شبکه آموزش داده شده پس از سعی و خطا

مدل و یا نوع شبکه	پرسپترون چند لایه ای
تعداد لایه‌های مخفی	۲
روش آموزش	دلتا بار دلتا
ضریب یادگیری	۰/۱
تابع تحریک یا فشردگی	تان اکسون
تعداد نرون‌های لایه مخفی	۲
تعداد	۱۰۰۰
مومنتم	۰/۷



شکل ۳- نقشه موقعیت ایستگاه مورد مطالعه

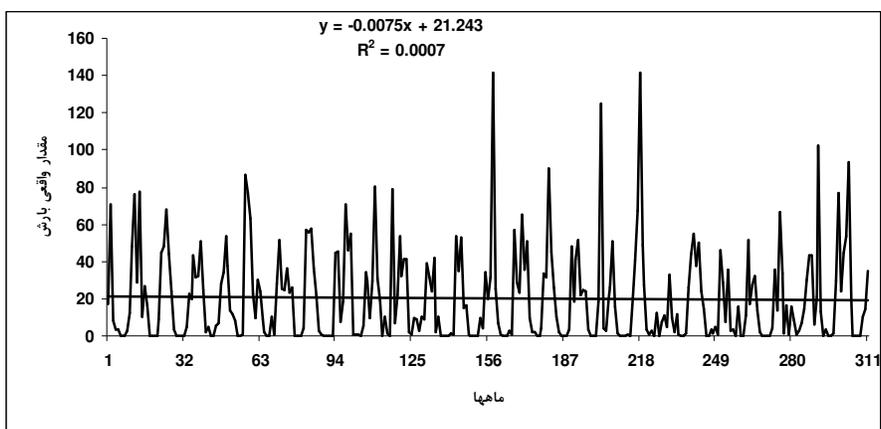
یافته‌های تحقیق

همانطور که در شکل ۴ و ۵ نشان داده شده است روند بارش ماهانه در شهر تهران (ایستگاه تهران) غیر خطی است. بنابراین نمی‌توان از مدل‌های آماری که کاربرد آنها برای پیش بینی روندهای خطی است استفاده کرد. همانطور که نشان داده شده است استفاده از مدل رگرسیون خطی و پولی نومیال به عنوان یک روش نیمه خطی در چنین مواردی نتیجه قابل قبولی را ارائه نمی‌کند. برای گریز از این مشکل باید از مدل‌های استفاده کرد که توانایی پیش بینی روندهای غیرخطی را دارند. یکی از این مدل‌های پیش بینی روندهای غیرخطی شبکه‌های عصبی مصنوعی می‌باشد. نتایج آموزش شبکه با نمونه‌هایی که به صورت منظم قرار گرفته‌اند (منظور از نمونه‌های منظم، افزایش و یا کاهش منظم پارامترهای نمونه است) نشان می‌دهد که در این حالت شبکه پس از آموزش نسبت به حالتی که در آن نمونه‌ها به صورت تصادفی انتخاب می‌شوند نتیجه‌ی بهتری را ارائه می‌دهد. شکل ۶ میزان حداقل مجذور متوسط خطاها را نشان می‌دهد. حداقل مجذور متوسط خطاها ($MMSE^{34}$) برای شبکه بدون ترکیب با الگوریتم ژنتیک برابر با ۰/۰۴ می‌باشد. مقایسه داده‌های ماهانه بارش ایستگاه تهران با میزان پیش بینی شده توسط

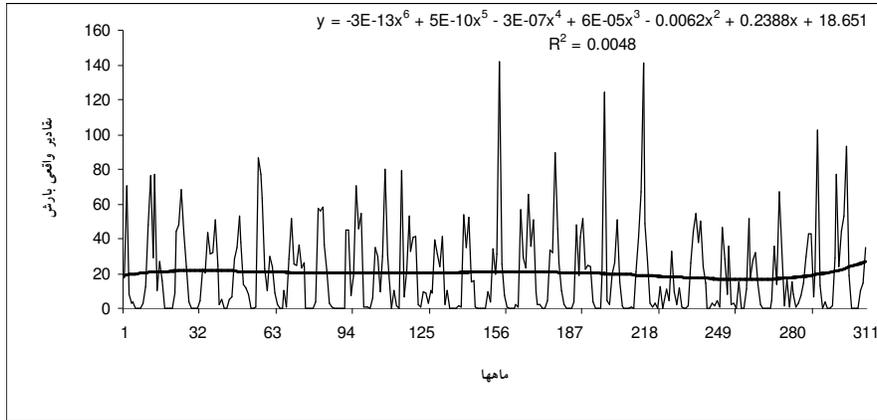
³⁴ - Minimum mean square error

شبکه را بدون ترکیب با الگوریتم ژنتیک در شکل ۷ نشان داده شده است. همانطور که مشخص است شبکه عصبی مصنوعی توانسته است که روند غیر خطی میزان بارش را با توجه به آموزشی که به شبکه داده شده است را پیدا کند. شکل ۸ پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش‌بینی شده توسط شبکه بدون ترکیب با الگوریتم ژنتیک را نشان می‌دهد که ضریب بدست آمده برابر با $0/88$ و ضریب تعیین برابر با $0/77$ می‌باشد. جدول ۲ مقادیر پیش‌بینی شده ماهانه بارش توسط شبکه بدون ترکیب با الگوریتم ژنتیک بعد از آموزش شبکه در سال 2004 و 2005 بدون مقادیر واقعی داده‌های بارش را نشان می‌دهد. همانطور که ملاحظه می‌شود مقادیر پیش‌بینی شده توسط شبکه نیز روند غیر خطی دارد. به این صورت که در ماه‌های سرد سال مقادیر بارش به دلیل ورود سیستم‌های برون حاره‌ای و امواج بادهای غربی همراه با سیستم‌های ناپایدار افزایش می‌یابد و در ماه‌های گرم سال برعکس این حالت اتفاق می‌افتد.

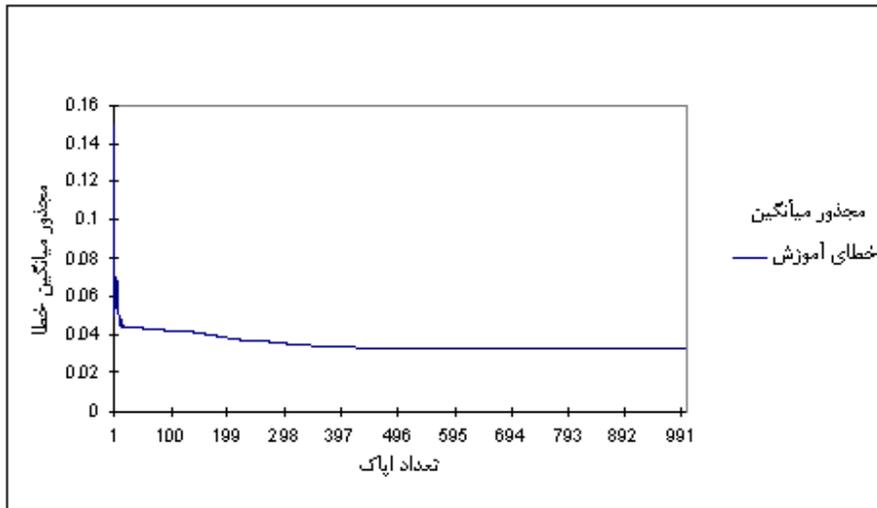
همانطور که اشاره شد الگوریتم پس انتشار برای مسائل واقعی اغلب بسیار کند عمل می‌کند. جهت غلبه بر این مشکل از الگوریتم ژنتیک برای انتخاب بهترین وزن‌های اولیه استفاده می‌شود. به عبارتی دیگر با استفاده از شبکه عصبی و ترکیب آن با الگوریتم ژنتیک می‌توان سریعتر به نتیجه رسید و علاوه بر آن دقت را افزایش داد و به نتیجه بهتری دست یافت. لازم به ذکر است که مشخصات آموزش شبکه در ترکیب با الگوریتم ژنتیک دقیقاً همان خصوصیات آموزش شبکه بدون ترکیب با الگوریتم ژنتیک می‌باشد. شکل ۹ میزان حداقل مجذور متوسط خطاها را نشان می‌دهد. حداقل مجذور متوسط خطاها برای شبکه در ترکیب با الگوریتم ژنتیک برابر با $0/03$ می‌باشد. مقایسه مقادیر ماهانه بارش با میزان پیش‌بینی شده توسط شبکه را بدون ترکیب با الگوریتم ژنتیک را در شکل ۱۰ نشان داده شده است. همانطور که مشخص است شبکه عصبی مصنوعی توانسته است که روند غیر خطی میزان بارش را با توجه به آموزشی که به شبکه داده شده است بهتر از آموزش شبکه بدون ترکیب با الگوریتم ژنتیک را پیدا کند. شکل ۱۱ پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش‌بینی شده توسط شبکه در ترکیب با الگوریتم ژنتیک را نشان می‌دهد که برابر با $0/91$ و ضریب تعیین برابر با $0/83$ می‌باشد. می‌توان گفت که آموزش شبکه عصبی مصنوعی در داده‌های منظم شده، همراه با الگوریتم ژنتیک برای پیش‌بینی مقادیر ماهانه بارش نسبت به حالتی که در آن شبکه بدون بهره‌گیری از الگوریتم ژنتیک شبکه آموزش داده می‌شود، نتیجه بهتری را ارائه دهد. جدول ۳ مقادیر پیش‌بینی شده ماهانه بارش توسط شبکه در ترکیب با الگوریتم ژنتیک در سال 2004 و 2005 بدون مقادیر واقعی داده‌های بارش را نشان می‌دهد. همانطور که ملاحظه می‌شود مقادیر پیش‌بینی شده توسط شبکه در ترکیب با الگوریتم ژنتیک نیز مثل داده‌های واقعی بارش و داده‌های پیش‌بینی توسط شبکه بدون ترکیب با الگوریتم ژنتیک روند غیر خطی دارد.



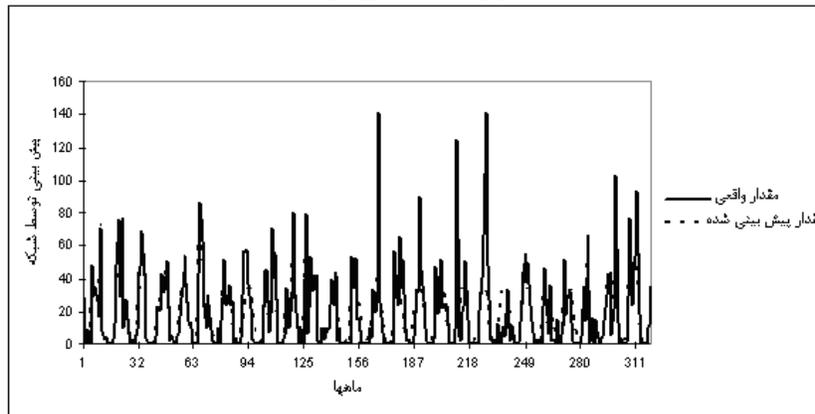
شکل ۴- استفاده از روش رگرسیون خطی برای پیش‌بینی مقادیر ماهانه بارش



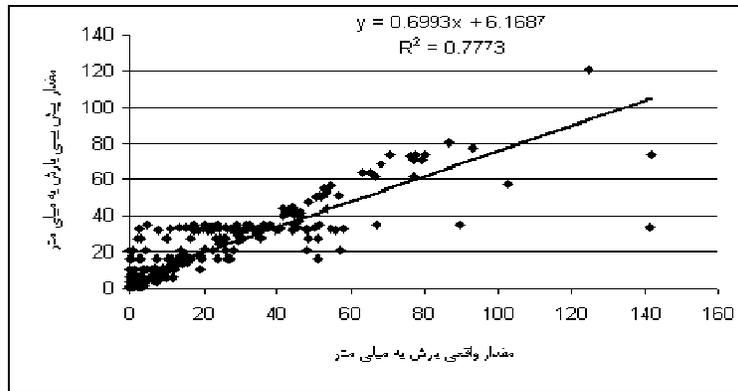
شکل ۵- استفاده از روش نیمه خطی پولی نومیال درجه شش برای پیش بینی مقادیر ماهانه بارش



شکل ۶- میزان حداقل مجدور متوسط خطاها



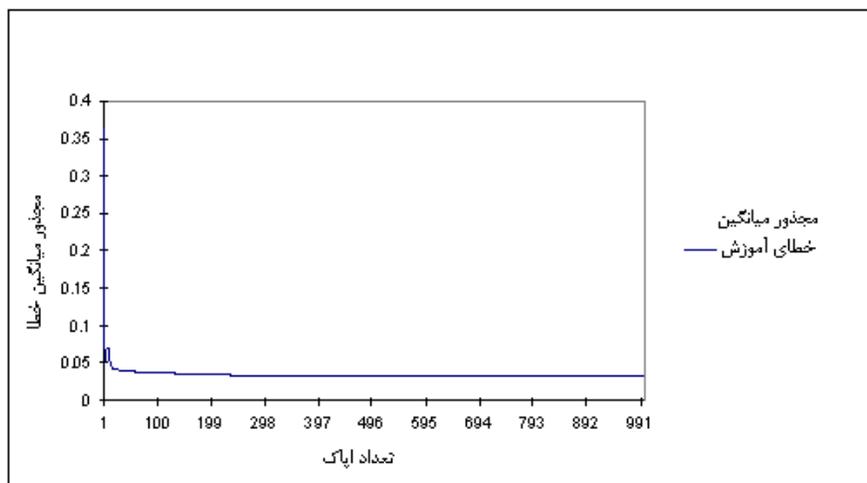
شکل ۷- مقایسه مقادیر واقعی ماهانه بارش با میزان بارش پیش بینی شده شبکه



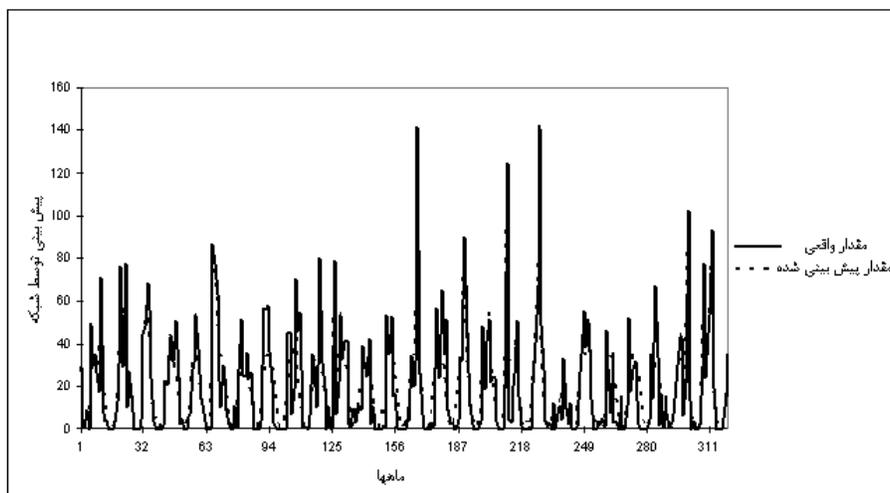
شکل ۸- پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش‌بینی شده توسط شبکه بدون ترکیب با الگوریتم ژنتیک

جدول ۲. مقادیر پیش‌بینی شده توسط شبکه بعد از آموزش شبکه بدون ترکیب با الگوریتم ژنتیک

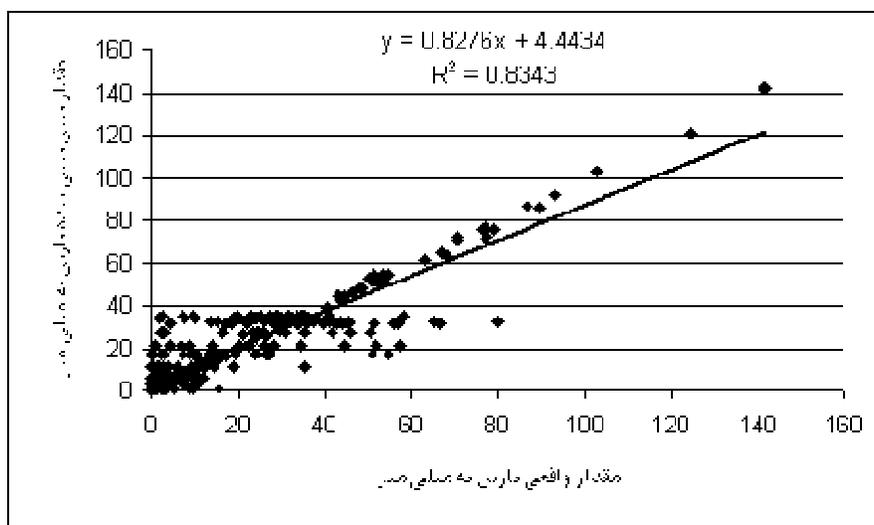
مقادیر پیش‌بینی شده و واقعی بارش توسط شبکه در سال ۲۰۰۵		مقادیر پیش‌بینی شده و واقعی بارش توسط شبکه در سال ۲۰۰۴		داده‌های ورودی به شبکه بدون مقادیر واقعی بارش			
واقعی	پیش‌بینی شده	واقعی	پیش‌بینی شده				
۵۰	۳۵/۰۷	۶۸/۴	۳۵/۰۷	۱	۲۰۰۵	۱	۲۰۰۴
۴۷	۳۸/۵۲	۸/۸	۳۸/۵۴	۲	۲۰۰۵	۲	۲۰۰۴
۴۷/۲	۳۸/۳۱	۷۹/۵	۳۸/۳۳	۳	۲۰۰۵	۳	۲۰۰۴
۲۱/۳	۳۰/۶۹	۴۹/۵	۳۰/۶۹	۴	۲۰۰۵	۴	۲۰۰۴
۳۲/۹	۱۶/۷۲	۱۰/۷	۱۶/۷۶	۵	۲۰۰۵	۵	۲۰۰۴
۰/۱	۵/۸۷	۰/۳	۵/۹۲	۶	۲۰۰۵	۶	۲۰۰۴
۰	۱/۷۶	۱۵/۷	۱/۹۰	۷	۲۰۰۵	۷	۲۰۰۴
۸/۱	۱/۸۷	۰	۱/۹۸	۸	۲۰۰۵	۸	۲۰۰۴
۰	۵/۰۸	۰	۵/۲۵	۹	۲۰۰۵	۹	۲۰۰۴
۰	۱۱/۹۸	۳	۱۲/۴۰	۱۰	۲۰۰۵	۱۰	۲۰۰۴
۳۳/۳	۲۳/۷۸	۴۳/۹	۲۳/۹۰	۱۱	۲۰۰۵	۱۱	۲۰۰۴
۳۲/۸	۴۰/۸۴	۳۱/۹	۴۱	۱۲	۲۰۰۵	۱۲	۲۰۰۴



شکل ۹- میزان حداقل مجدور متوسط خطای شبکه در ترکیب با الگوریتم ژنتیک



شکل ۱۰- مقایسه مقادیر واقعی ماهانه بارش با مقادیر بارش پیش بینی شده شبکه در ترکیب با الگوریتم ژنتیک



شکل ۱۱- پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش بینی شده توسط شبکه در ترکیب با الگوریتم ژنتیک

جدول ۳. مقادیر پیش بینی شده توسط شبکه در ترکیب با الگوریتم ژنتیک بعد از آموزش شبکه

مقادیر پیش بینی شده و واقعی بارش توسط شبکه در سال ۲۰۰۵		مقادیر پیش بینی شده و واقعی بارش توسط شبکه در سال ۲۰۰۴		داده‌های ورودی به شبکه بدون مقادیر واقعی بارش			
واقعی	پیش بینی شده	واقعی	پیش بینی شده				
۵۰	۳۵/۳۱	۶۸/۴	۳۵/۶۱	۱	۲۰۰۵	۱	۲۰۰۴
۴۷	۳۸/۲۰	۸/۸	۳۸/۴۳	۲	۲۰۰۵	۲	۲۰۰۴
۴۷/۲	۳۷/۰۱	۷۹/۵	۳۷/۵۶	۳	۲۰۰۵	۳	۲۰۰۴
۲۱/۳	۲۹/۵۰	۴۹/۵	۲۹/۹۳	۴	۲۰۰۵	۴	۲۰۰۴
۳۲/۹	۱۶/۲۱	۱۰/۷	۱۶/۳۷	۵	۲۰۰۵	۵	۲۰۰۴
۰/۱	۵	۰/۳	۵/۰۷	۶	۲۰۰۵	۶	۲۰۰۴
۰	۰/۲۳	۱۵/۷	۰/۲۷	۷	۲۰۰۵	۷	۲۰۰۴
۸/۱	۰	۰	۰	۸	۲۰۰۵	۸	۲۰۰۴
۰	۲/۱۵	۰	۲/۸۸	۹	۲۰۰۵	۹	۲۰۰۴
۰	۱۰	۳	۱۰/۲۹	۱۰	۲۰۰۵	۱۰	۲۰۰۴
۳۳/۳	۲۲/۱۰	۴۳/۹	۲۲/۸۱	۱۱	۲۰۰۵	۱۱	۲۰۰۴
۳۲/۸	۳۸	۳۱/۹	۳۸/۳۸	۱۲	۲۰۰۵	۱۲	۲۰۰۴

نتیجه گیری

بارش یکی از مهمترین داده‌های ورودی به سیستم‌های هیدرولوژیکی محسوب می‌شود. با توجه به اهمیت بارش برای کشور خشکی مانند ایران تا کنون پژوهش‌های اندکی درباره پیش بینی بارش کشور انجام گرفته است. روند بارش غیر خطی است بنابراین استفاده از مدل رگرسیون خطی و پولی نومیال به عنوان یک روش نیمه خطی در چنین مواردی نتیجه قابل قبولی را ارائه نمی‌کند. برای گریز از این مشکل باید از مدل‌های استفاده کرد که توانایی پیش بینی روندهای غیرخطی را دارند. یکی از این مدل‌های پیش بینی روندهای غیرخطی شبکه‌های عصبی مصنوعی می‌باشد. نتایج این مطالعه بعد از آزمون شبکه با لایه‌های پنهان و با ضرایب یادگیری مختلف نشان داد که استفاده از شبکه‌های عصبی مصنوعی با یک پرسپترون ۲ لایه پنهان با ضریب یادگیری ۰/۱ و مومنتم ۰/۷ در حالتی که نمونه‌ها بصورت منظم قرار گرفته مدل نسبتاً بهتری را ارائه می‌کند بدین معنی که داده‌های پیش‌بینی شده بارش ماهانه توسط شبکه با چنین ساختار و معماری، بیشتر با واقعیت انطباق دارد. ضریب همبستگی بین مقادیر واقعی ماهانه بارش و پیش بینی شده توسط شبکه بدون ترکیب با الگوریتم ژنتیک برابر با ۰/۸۸ و ضریب تعیین برابر با ۰/۷۷ می‌باشد همچنین آموزش مجدد شبکه با لایه‌های پنهان و ضرایب مختلف یادگیری در ترکیب با الگوریتم ژنتیک نشان داد که ترکیب شبکه با ویژگی‌های مذکور با الگوریتم ژنتیک باعث کاهش خطا و افزایش سرعت محاسبات شده و مدل بهتری را ارائه می‌کند. بطور کلی می‌توان گفت که شبکه عصبی به خوبی رابطه غیر خطی بین مقادیر ماهانه بارش را با توجه به آموزش شبکه با خصوصیات ذکر شده، پیش بینی می‌کند. در این حالت ضریب همبستگی بین مقادیر واقعی ماهانه بارش و پیش بینی شده توسط شبکه برابر با ۰/۹۱ و ضریب تبیین برابر با ۰/۸۳ می‌باشد. با ترکیب الگوریتم ژنتیک و شبکه عصبی سرعت تحلیل و دقت فرآیند افزایش می‌یابد به عبارتی دیگر میزان خطا کاهش می‌یابد. با توجه به پیش بینی مقادیر بارش توسط شبکه با استفاده از داده‌های واقعی، می‌توان گفت که مقادیر بارش در تهران روندی غیرخطی داشته و مقادیر این روند طی دوره مورد مطالعه افزایش یا کاهش خاصی را نشان نمی‌دهد. به عبارت دیگر روند مقادیر بارش تهران طی دوره مورد مطالعه دارای ناهنجاریهای اندکی بوده است. در مجموع می‌توان گفت که پدیده‌های اقلیمی نظیر بارش، دما، تبخیر و تعرق و فشار و ... دارای روند غیر خطی می‌باشند. به عبارتی دیگر در طی زمان تغییر می‌کنند. بنابراین برای پیش بینی و برآورد آنها به نظر می‌رسد که شبکه‌های عصبی مصنوعی بهتر از مدل‌های دیگر عمل می‌کند. دلیل برتری این روش نسبت به مدل‌های دیگر غیرخطی بودن مدل است که برای پیش بینی پدیده‌های مذکور مناسب می‌باشد. میزان ضریب همبستگی و ضریب تبیین بالا بین مقادیر واقعی و برآورد شده توسط مدل دلیلی بر این ادعاست.

منابع

- Ahmadi S., 2003, **Classification of rainfall variations in Boshehr by using artificial neural networks based on self organizing Map(SOM)**, M.Sc Thesis, Supervisor Bohlol Allijani, physical Geography(climatology) Department, Tarbiat Moallem University.
- Shams Sh., 2003, **artificial Disaggregation via neural networks**, M.Sc Thesis, Supervisor Keyvan Asghari, civil engineering Department, university of Isfahan.
- Mesaghe F., 2003, development of a combined algorithm of geostatistics and artificial neural networks for spatial estimation of rainfall distribution, M.Sc Thesis, Supervisor Korosh Mohammadi, Irrigation and drainage engineering Department, university of Tarbiat Modares.
- khalili N., 2006, **Forecasting precipitation with artificial neural networks**, M.Sc Thesis, Supervisor Saeed Reza Khodashenas, water engineering Department , Ferdowsi university of Mashhad.
- Aksoy, Hafzullah., Ahmad, Dahamsheh., 2009, **Artificial neural network models for forecasting precipitation in Jordan**, Stoch Environ Res Risk Assess, No.23, pp.917-931.
- Bustami, Rosmina., Nabil, Bessaih., Charles Bong., Suhaila Suhaili, 2007, **Artificial Neural Network For Precipitation and Water Level Predictions of Bedup River**, International Journal of Computer Science, No.34, pp10-16.
- Cavazos, T., 2000, **using self-organizing maps to investigate extreme climate event: an application to wintertime precipitation in the Balkans**, Journal of climate, No. 13, pp. 1718-1732.
- Chattopadhyay, S., 2007, **Feed forward artificial neural network model to predict the average summer-monsoon rainfall in India**, Acta Geophysical, No. 55(3), pp. 369-382.

- Cross, SS., Harrison, RF., Kennedy, RL., 1995, **Introduction to neural networks**. Lancet , No.346, pp.1075 –9.
- Dahamsheh, Ahmad., Hafzullah, Aksoy., (2009), **Artificial neural network models for forecasting intermittent monthly precipitation in arid regions**, Royal Meteorology Society, No. 16, pp.325-337.
- French, M.N., Krajewski, W.F., Cuykendal, R.R., 1992, **Rainfall forecasting in space and time using a neural networks**. Journal of Hydrology, No.21,137:1-37.
- Hall, T., Brooks, H.E., Doswell, C. A.,1999, **Precipitation forecasting using a neural network**, **Weather and Forecasting**, No. 144, pp. 338-345.
- Hastenrath, S, Greischar, L., 1995, **Prediction of the summer rainfall over South Africa**, Journal of Climate, No.8, pp.1511-1518.
- Haykin, S.,1994, **Neural network: A comprehensive foundation**, MacMillan College Publishing Co, New York.
- Hessami, M., Anctil, F., Viau, AA., 2004, **Selection of an Artificial Neural Network. Model for the Post calibration of Weather Radar Rainfall Estimation**, Journal of Data Science, No. 2, pp. 107–124.
- Hung, NQ., Babel, MS., Weesakul, S., Tripathi, NK., 2008, **An artificial neural network model for rainfall forecasting in Bangkok, Thailand**, Hydrology and Earth System Sciences Discussions, No. 5, pp. 183–218.
- Judith, E.D., 1990, **Neural Network Architectures**, VAN NOSTRAND REINHOLD, New York.
- Lapedes, A., Farber, R.,1987, **Non-linear signal processing using neural networks**. Technical Report no, LAUR- 2662 Los Alamos National Laboratory, Los Alamos,NM.
- 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.
- McCulloch, WS., Pitts, W., 1943, **A logic calculus of the ideas immanent in nervous activity**, Bull of Math Biophys, No.5, pp. 115-133.
- Namasivayam A., Waldemar A., 2001, **Comparison of the prediction of extremely low birth weight neonatal mortality by regression analysis and by neural networks**, Early Human Development, No. 65, pp.123- 137.
- Navonne, HD., Ceccatto HA., 1994, **Predicting Indian monsoon rainfall: a neural network approach**, Climate Dynamics, No.10, pp. 305-312.
- Tohma, S., Igata, S.,1994, **Rainfall estimation from GMS imagery data using neural networks**, Hydraulic engineering software, No.1, pp.121-130.
- Tokar, A. S., Santon, P.A.,1999, **Rainfall-Runoff modeling using artificial neural networks**, Journal of Hydrologic Engineering, No.3, pp. 232-239.
- Trafalis, TB., White, A., Santosa, B., Richman, MB., 2002, **Data mining techniques for improved WSR-88D rainfall estimation**. Computers in Industrial Engineering, No. 43, pp. 775–786.