

مقایسه عملکرد الگوریتم های مختلف شبکه عصبی مصنوعی در مدل سازی بارندگی فصلی مطالعه موردی؛ ایستگاه های منتخب استان خوزستان

دریافت مقاله: ۹۱/۵/۱۶ پذیرش نهایی: ۹۲/۵/۲۴

صفحات: ۱۵۱-۱۶۹

محمدرضا گلابی: کارشناسی ارشد مهندسی منابع آب، دانشگاه شهید چمران اهواز^۱

Email: hamid_golabi65@yahoo.com

علی محمد آخوندعلی: استاد گروه هیدرولوژی و منابع آب، دانشگاه شهید چمران اهواز

Email: aliakh@scu.ac.ir

فریدون رادمنش: استادیار گروه هیدرولوژی و منابع آب، دانشگاه شهید چمران اهواز

Email: feridon_radmanesh@yahoo.com

چکیده

بارندگی یکی از اجزای اصلی چرخه ی هیدرولوژی است. این فرآیند پیچیده به عوامل متعدد اقلیمی وابسته است. شبکه های عصبی مصنوعی در چند دهه اخیر و در مطالعات صورت گرفته برای مدل سازی سیستم های پیچیده و غیر خطی قابلیت بسیار بالایی از خود نشان داده است. تحقیق حاضر در سه ایستگاه منتخب از استان خوزستان صورت گرفته است. برای این منظور از داده های بارندگی ماهانه سه ایستگاه هواشناسی استان به مدت ۴۸ سال، (۱۳۴۰-۱۳۸۷)، استفاده شده است. سپس با استفاده از این مقادیر به عنوان خروجی های هدف، شبکه های مختلفی با ساختارهای متفاوت تعریف و آموزش داده شد. در نهایت قابلیت شبکه برای تخمین بارش با استفاده از قسمتی از داده ها که در آموزش شبکه وارد نشدند، مورد بررسی قرار گرفت. در این تحقیق شبکه های MLP و RBF با تغییراتی در تعداد لایه های میانی، تعداد نرون ها و الگوریتم های آموزش MOM و LM و CG به منظور پیش بینی بارش فصلی به کار گرفته شد. نتایج نشان داد که برای ایستگاه اهواز شبکه RBF با توپولوژی ۱-۴-۶ و یادگیری LM دارای بیشترین مقدار ضریب همبستگی برابر ۰/۹۶ و کمترین MSE برابر ۰/۰۴۴ است. برای ایستگاه آبادان شبکه RBF با توپولوژی ۱-۷-

^۱ نویسنده مسئول: اهواز- دانشگاه شهید چمران- گروه مهندسی آب

۶-۶ و یادگیری LM دارای بیشترین مقدار ضریب همبستگی برابر ۰/۹۲ و کمترین MSE برابر ۰/۰۶۲ است. برای ایستگاه دزفول شبکه MLP با توپولوژی ۱-۴-۳-۶ و یادگیری LM دارای بیشترین مقدار ضریب همبستگی برابر ۰/۹۴ و کمترین MSE برابر ۰/۰۳۴ است.

کلید واژگان: شبکه‌های عصبی مصنوعی، بارش فصلی، منابع آب، استان خوزستان.

مقدمه

بارندگی در مدیریت منابع آب به ویژه در مناطق خشک و نیمه خشک نقش اساسی دارد و مدل سازی این متغیر هیدرولوژیکی گامی بسیار مهم در راستای برنامه ریزی بهتر منابع آب و کشاورزی خواهد بود. یکی از کارهای معمول در برنامه ریزی منابع آب، شبیه سازی یا ساختن مدلی از برخی متغیرهای هیدرولوژیکی مانند بارندگی، جریان‌های رودخانه‌ای و جریان‌های سیلاب است که پدیده‌هایی احتمالی یا تصادفی هستند. برای هر یک از متغیرهای هیدرولوژیک عامل‌های گوناگونی اندازه گیری و ثبت می شود. با تجزیه و تحلیل این عامل‌ها، که در گذشته رخ داده و اندازه‌گیری شده‌اند، می توان به نتایجی رسید که اگر آن را برای آینده تعمیم دهند، تصمیم‌گیری یا شبیه سازی رفتار حوضه را ساده خواهد ساخت. با توجه به پیشرفت‌های تکنولوژیکی اگرچه این مدل سازی و پیش بینی در دامنه زمان و مکان امری محال نیست، ولی از پیچیدگی‌های بسیاری برخوردار است چرا که این رفتار خود تابع عوامل بسیاری از جمله فشار، دما، سرعت و جهت باد و غیره می‌باشد (ناصری، ۱۳۸۲). با توجه به محدودیت‌هایی از قبیل نبود اطلاعات بارش در مقیاس‌های مکانی و زمانی مناسب و پیچیدگی‌های یاد شده عملاً استفاده از مدل‌هایی با مبنای فیزیکی مقدور نیست. امروزه به موازات مدل‌های متداول موجود، روش‌های جدیدتری نیز برای پیش بینی ابداع شده‌اند. شبکه‌های عصبی از ابزارهای جدیدی است که در سیستم‌های غیرخطی و نامعین که روابط بین اجزا و پارامترهای سیستم به خوبی شناخته شده و توصیف پذیر نمی‌باشند، قادر به تحلیل و شبیه سازی می‌باشند (Kohzadi et al., 1995:463). پدیده بارندگی و پیش بینی آن یکی از این نوع سیستم‌ها می‌باشد. شبکه عصبی مصنوعی مدل ساده شده‌ای از سیستم عصبی طبیعی بوده و همانند مغز با پردازش روی داده‌های تجربی، قابلیت یادگیری دارد. در واقع شبکه‌ها با انجام محاسبات روی داده‌های عددی یا مثال‌ها، قوانین کلی را فرا می‌گیرند و به همین دلیل به آن‌ها سیستم‌های هوشمند^۱ گفته

^۱-Intelligent systems

می‌شود (محمدی و همکاران، ۱۳۸۷: ۸۵). مزیت شبکه عصبی یادگیری مستقیم از روی داده‌ها بدون نیاز به برآورد مشخصات آماری آنها است. شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه ورودی‌ها و خروجی‌ها برای پیش بینی هر خروجی متناظر با ورودی دلخواه می‌باشد. ماریا^۱ و همکاران (۲۰۰۵) به کمک مدل‌های شبکه عصبی مصنوعی و رگرسیون بارش منطقه سائوپولو برزیل را پیش بینی کردند. ایشان نشان دادند که نتایج و برآورد دو مدل مذکور برای منطقه مورد مطالعه بسیار دقیق است. بوستامی^۲ و همکاران (۲۰۰۷) بارش و سطح آب را در بوداپ مالتی با استفاده از تکنیک شبکه‌های عصبی مصنوعی پیش بینی 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 و همکاران^۳ (۲۰۰۸) به کمک یک سری پارامترهای هواشناسی با بهره گیری از مدل‌های شبکه‌های عصبی مصنوعی به پیش بینی بارش در بانکوک پرداختند. داهامشه و آکسوی^۴ (۲۰۰۹) 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^۵ 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 پیش بینی کردند. نتایج این پژوهش حکایت از این داشت که رگرسیون عمومی شبکه‌های عصبی مقادیر خطای پیش بینی کمتری را نسبت به شبکه‌های مصنوعی انتشار به عقب دارند. کارین (۲۰۱۰) روش‌های رگرسیون چندمتغیره اسپیلاین و شبکه‌های عصبی مصنوعی انتشار به عقب را برای پیش بینی بارش و دمای حوضه رودخانه مانتارو مقایسه کرد. شافعی و همکاران (۲۰۱۱) از شبکه‌های عصبی مصنوعی برای پیش بینی بارش اسکندریه مصر استفاده کردند. آنها مدل شبکه‌های عصبی مصنوعی و مدل رگرسیون چندمتغیره را با هم مقایسه کردند. نتایج مطالعه آنها نشان داد که مدل شبکه‌های عصبی مصنوعی مناسب‌تر و دقیق‌تر است. کارآموز و همکاران (۱۳۸۵) بارش بلند مدت را با استفاده از سیگنال‌های هواشناسی و شبکه عصبی در جنوب شرقی ایران پیش بینی نمودند. این پیش بینی نشان می‌دهد در ۷۰ درصد از سال‌ها پیش

2 Maria

3- Bustami

4 Hung

5- Dahamsheh & Aksoy

6- Multivariate regression

بینی در دامنه تعریف شده قرار دارد. اصغری مقدم و همکاران (۱۳۸۷) از شبکه‌های عصبی مصنوعی و فرمول تجربی ارائه شده برای تعیین تعداد گره‌های میانی جهت تهیه مدل پیش بینی بارش دشت تبریز استفاده کردند بر اساس نتایج بدست آمده، بهترین مدل از یک شبکه پیشرو^۱ با شش گره ورودی، یک گره خروجی، یک لایه میانی و الگوریتم لونیگ-مارکواریت^۲ تشکیل شده است. خوشحال و قویدل رحیمی (۱۳۸۷) نوسانات بارش سالانه‌ی تبریز را در ارتباط با ناهنجاری‌های دمایی کره‌ی زمین به کمک شبکه‌های عصبی مصنوعی شبیه سازی عددی کردند. نتایج این پژوهش نشان داد که روش پرسپترون چند لایه با ۳ لایه مخفی و الگوریتم آموزش پس انتشار قابلیت بسیار عالی در پیش بینی همبستگی بین سری‌ها دارد. قویدل رحیمی (۱۳۸۹) به کمک شبکه‌های عصبی مصنوعی اثر گرمایش جهانی بر ناهنجاری‌های بارش سالانه-ی جلغا را مطالعه کرد و نشان داد که روش پرسپترون چند لایه با چهار لایه مخفی و الگوریتم آموزش پس انتشار دارای قابلیت بسیار عالی در پیش بینی همبستگی بین سری‌هاست.

با توجه به این که اکثر مطالعات انجام شده در زمینه بارندگی در مواردی که از شبکه عصبی مصنوعی استفاده شده است، تنها از نوع شبکه عصبی پرسپترون چند لایه^۳ (MLP) می‌باشد، و همچنین مقایسه‌ای در مطالعات گذشته برای مقایسه الگوریتم‌های مختلف شبکه عصبی مصنوعی انجام نشده است، بنابراین هدف از انجام این تحقیق در گام اول مقایسه دو شبکه عصبی MLP و RBF با الگوریتم‌های آموزش مختلف در مدل سازی بارندگی فصلی ایستگاه‌های منتخب استان خوزستان است و در گام بعدی ارائه مدل شبکه عصبی به منظور مدل سازی بارندگی فصلی در ایستگاه‌های مذکور است که تاکنون کمتر مورد توجه قرار گرفته است.

مواد و روش‌ها

در این مطالعه از داده‌های بارش ماهانه سه ایستگاه هواشناسی از استان خوزستان که شامل اهواز، آبادان و دزفول (جدول ۱) می‌باشد، استفاده شده است. مقطع زمانی مورد مطالعه در این تحقیق یک دوره ۴۷ ساله است که بین سال‌های ۱۳۴۰-۱۳۸۷ واقع می‌گردد. مشخصات آماری سری زمانی بارندگی ایستگاه‌های مورد مطالعه در جدول (۲) آورده شده است.

جدول (۱) مشخصات ایستگاه‌های سینوپتیک

| نام | طول | عرض | ارتفاع (متر) |
|-----|-----|-----|--------------|
|-----|-----|-----|--------------|

^۱-Feedforward

^۲-Levenberg-Marquardt

^۳-Multilayer perceptron

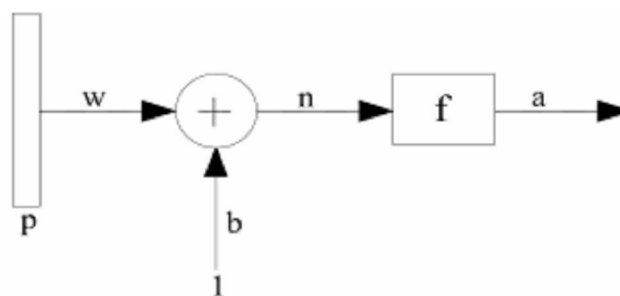
| ایستگاه | درجه | دقیقه | درجه | دقیقه |
|---------|------|-------|------|-------|
| اهواز | ۴۹ | ۱۱ | ۳۱ | ۵۰ |
| آبادان | ۴۸ | ۱۷ | ۳۰ | ۲۰ |
| دزفول | ۴۸ | ۲۵ | ۳۲ | ۱۶ |

جدول (۲) مشخصات آماری سری زمانی بارندگی فصلی ایستگاه های مورد مطالعه

| نام ایستگاه | میانگین | ماکزیمم | مینیمم | انحراف معیار | ضریب چولگی |
|-------------|---------|---------|--------|--------------|------------|
| اهواز | ۵۷/۲۴ | ۲۹۲/۸۰ | ۰/۰ | ۶۲/۰ | ۱/۰۵ |
| آبادان | ۳۹/۰۳ | ۲۰۹/۰ | ۰/۰ | ۴۴/۰۵ | ۱/۲۵ |
| دزفول | ۱۰۱/۲۲ | ۴۴۹/۲ | ۰/۰ | ۱۰۷/۸۲ | ۱/۱۷ |

شبکه های عصبی مصنوعی

یک شبکه عصبی از نرون های مصنوعی تشکیل شده است. نرون یا گره کوچکترین واحد پردازش اطلاعات می باشد که اساس عملکرد شبکه های عصبی را تشکیل می دهد (منهاج، ۱۳۸۴). هر یک از نرون ها، ورودی ها را دریافت نموده و پس از پردازش روی آن ها، یک سیگنال خروجی تولید می نمایند. لذا هر نرون در شبکه به عنوان مرکز پردازش و توزیع اطلاعات عمل کرده، ورودی و خروجی مخصوص به خود را دارد (Sadorsky, 2006:467). شکل (۲) نمایش ساختار یک نرون تک ورودی می باشد که در آن متغیرهای p و a به ترتیب ورودی و خروجی نرون هستند.



شکل (۲) مدل نرون تک ورودی

خروجی نرون از رابطه (۱) بدست می آید:

$$a = f(wp + b) \quad (1)$$

که در آن f تابع محرک^۱ (فعالیت)، w و b بترتیب وزن و بایاس نرون می‌باشند. پارامترهای w و b قابل تنظیم بوده و تابع محرک f نیز توسط طراح انتخاب می‌شود. بر اساس انتخاب f و نوع الگوریتم یادگیری^۲، پارامترهای w و b تنظیم می‌شوند. در حقیقت یادگیری به این معنی است که w و b طوری تغییر نمایند که رابطه ورودی و خروجی نرون با هدف خاصی مطابقت نماید. عموماً یک نرون، بیش از یک ورودی دارد. معمولاً یک نرون حتی با تعداد ورودی‌های زیاد نیز به تنهایی برای حل مسایل کفایت نمی‌کند (منهاج، ۱۳۸۴). بنابراین در بیشتر موارد از اجتماع نرون‌ها به عنوان یک لایه استفاده می‌شود. شبکه‌های عصبی مصنوعی مشابه با شبکه‌های عصبی بیولوژیکی می‌توانند به طرق مختلف سازمان‌دهی شوند. بدین مفهوم که نرون‌ها می‌توانند از راه‌های متفاوت به هم متصل گردند و شبکه‌های عصبی با ساختارهای مختلفی تولید نمایند (محمدی و همکاران، ۱۳۸۷).

شبکه‌های عصبی چند لایه پرسپترون^۳ (MLP)

شبکه‌های چند لایه ی پیشخور یکی از مهمترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشد. به طور معمول این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نرونهای پایه) می‌باشند که تشکیل دهنده‌ی لایه‌ی ورودی^۴، یک یا چند لایه‌ی پنهان^۵ و یک لایه‌ی خروجی^۶ می‌باشند. سیگنال ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شود. این نوع شبکه معمولاً با عنوان پرسپترون چند لایه (MLP) نامیده می‌شود.

شبکه‌های با تابع پایه‌ی شعاعی (RBF)^۷

شبکه‌های RBF نیازمند نرون‌های بیشتری نسبت به شبکه‌های استاندارد پیشخور با الگوریتم پس انتشار خطا می‌باشند ولی اغلب این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های پیشخور، آموزش داد. این شبکه‌ها زمانی که بردارهای ورودی فراوانی

¹-Activity function

²-Learning function

³-Multi layer perceptron

⁴-Input layer

⁵-Hidden layer

⁶-Output layer

⁷ Radial basis function

در دسترس باشد از عملکرد مطلوب تری برخوردارند. شبکه های RBF نوعی شبکه ی عصبی پیشخور می باشند و ساختار آنها شبیه شبکه های MLP می باشد.

داده های ورودی و خروجی شبکه

در مرحله اول داده های مربوطه از وب سایت سازمان هواشناسی تهیه و سپس اقدام به داده پردازی، محاسبه و ماتریس بندی داده ها گردید. برای تعیین بهترین الگوی ورودی به شبکه، عوامل مختلفی که ممکن است در پدیده موثر باشند باید در نظر گرفته شوند. در این مطالعه با توجه به عوامل تاثیرگذار در بارندگی هر ایستگاه برای ایستگاه های مورد مطالعه لایه ورودی شبکه را ۶ نرون شامل داده های: اختلاف دمای حداقل و حداکثر، حداقل رطوبت، دمای نقطه شبنم، متوسط فشار، دمای میانگین و دمای حداکثر و نرون خروجی را بارندگی فصلی تشکیل می دهد.

نرمالیزه نمودن داده ها

وارد کردن داده ها به صورت خام باعث کاهش سرعت و دقت شبکه می شود. از این رو داده های ورودی به شبکه بایستی نرمال شوند. در این بررسی برای نرمالیزه کردن داده ها از رابطه (۲) استفاده شده است که ورودی ها را بین ۰/۱ و ۰/۹ استاندارد می نماید. در نهایت می توان خروجی های شبکه را با معکوس نمودن الگوریتم استاندارد سازی، به حالت اولیه برگرداند.

$$X_i = \lambda_1 + (\lambda_2 - \lambda_1) \left(\frac{z_i - z_i^{\min}}{z_i^{\max} - z_i^{\min}} \right) \quad (2)$$

که در این رابطه X_i مقدار نرمالیزه شده Z_i ، Z_i متغیر مورد نظر، Z_i^{\max} و Z_i^{\min} مقادیر حداکثر و حداقل Z_i می باشند.

تعداد لایه های پنهان

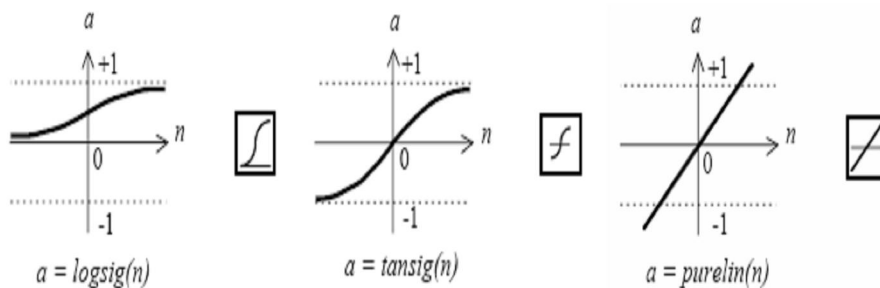
تعداد لایه های پنهان تا حد امکان باید کم باشد. ثابت شده است که هر تابع می تواند حداکثر با سه لایه پنهان تقریب زده شود. ابتدا شبکه با یک لایه پنهان آموزش داده می شود که در صورت عملکرد نامناسب، تعداد لایه های پنهان افزایش خواهد یافت (اسفندیاری و همکاران، ۱۳۸۹: ۴۵).

تعداد نرون‌های لایه پنهان

اندازه یک لایه‌ی مخفی عموماً به طور تجربی بدست می‌آید برای یک شبکه عصبی با اندازه معقول تعداد نرون‌های مخفی با یک نسبت کوچکی از تعداد ورودی‌ها انتخاب می‌گردد. اگر شبکه به جواب مطلوب همگرا نگردد تعداد نرون‌های لایه مخفی را افزایش می‌دهند و اگر شبکه همگرا گردید و از قدرت تعمیم خوبی هم برخوردار بود در صورت امکان تعداد نرون‌های مخفی کمتری را مورد آزمایش قرار می‌دهند (منهاج، ۱۳۸۴).

توابع محرک^۱

نرون‌ها می‌توانند از توابع محرک متفاوتی جهت تولید خروجی استفاده کنند. که از رایج‌ترین آنها می‌توان به توابع لگاریتم سیگموئیدی، تانژانت سیگموئیدی و تابع محرک خطی اشاره کرد (شکل ۳).



شکل (۳) توابع محرک رایج در شبکه‌های عصبی

بهبود قدرت تعمیم‌دهی شبکه

برای تعمیم‌دهی مناسب شبکه، باید به نحوی از آموزش بیش از اندازه جلوگیری نمود. در مطالعه‌ی حاضر برای جلوگیری از آموزش بیش از اندازه در شبکه‌های MLP از روش متوقف سازی زود هنگام آموزش استفاده شد. برای تصمیم‌گیری در مورد زمان متوقف ساختن آموزش، داده‌ها به صورت تصادفی به سه مجموعه تقسیم شد، ۶۰ درصد داده‌ها برای آموزش، ۲۵ درصد برای صحت سنجی و ۱۵ درصد برای آزمون بکار رفت. همچنین در مطالعه‌ی حاضر برای آموزش شبکه‌ی RBF به نحوی که از قابلیت تعمیم‌دهی مناسبی برخوردار باشد، ابتدا مقداری به عنوان خطای هدف به صورت مجموع مربعات خطا (SSE) در نظر گرفته شد، سپس مقادیر

^۱-Activity function

گستره و تعداد توابع انتقال با آزمون و خطا به گونه‌ای انتخاب شد که میانگین مربعات خطا (MSE) در دو مجموعه‌ی آموزش و صحت سنجی کمینه گردد.

روش های آموزش در شبکه‌های عصبی مصنوعی

جهت آموزش شبکه‌های عصبی الگوریتم‌های آموزشی متفاوتی وجود دارد این روش‌ها عبارتند از:

الگوریتم مومنتوم^۱

در این الگوریتم می‌توان قانون تغییر وزن‌ها را طوری در نظر گرفت که تغییر وزن در تکرار n ام تا حدی به اندازه تغییر وزن در تکرار قبلی بستگی داشته باشد.

$$\Delta W_{ji}(n) = \eta \delta_j X_{ji} + \alpha \Delta W_{ji}(n-1) \quad (3)$$

که در آن مقدار ممنتوم α بصورت $0 \leq \alpha \leq 1$ می‌باشد.

الگوریتم لونبرگ - مارکوارت (LM)

از میان روش‌های مختلف آموزش به روش پس انتشار خطا، الگوریتم لونبرگ - مارکوارت، به دلیل همگرایی سریع‌تر در آموزش شبکه‌های با اندازه‌ی متوسط، برای استفاده در تحقیق حاضر انتخاب شده است. الگوریتم پس انتشار خطا، وزن‌های شبکه و مقادیر بایاس^۲ را در جهتی تغییر می‌دهد که تابع عملکرد با سرعت بیشتری کاهش یابد.

الگوریتم گرادیان نزولی^۳ (CG)

الگوریتم استاندارد گرادیان نزولی فقط از تقریب محلی شیب سطح کارآمدی در تعیین بهترین جهت حرکت وزن‌ها برای رسیدن به کمترین خطا، استفاده می‌کند. این روش معمولاً از مشتقات دوم و یا تقریبی از آنها برای تصحیح وزن‌ها استفاده می‌نماید.

تعداد تکرار یا سیکل^۴

زمانی که پارامترهای شبکه پس از یک دوره کامل ارائه الگوها به دست آمدند در اصطلاح به این نوع تکرار یک سیکل می‌گویند. تعداد تکرارهای شبکه برابر تعداد داده‌های یادگیری می‌باشد (منهاج، ۱۳۸۴). که در این بررسی برای هر شبکه ۱۰۰ دور در نظر گرفته شد.

^۱-Momentum

^۲-Bias

^۳-Conjugate Gradient

^۴-Epoch

ارزیابی عملکرد شبکه

در پایان جهت بررسی و آزمون اعتبار شبکه‌ها، به ارزیابی عملکرد آنها پرداخته شد. برای ارزیابی عملکرد شبکه، از دو روش زیر استفاده گردید:

۱- ضریب تعیین همبستگی خطی (R^2)

توان دوم ضریب همبستگی خطی را، یعنی R^2 که میزان همبستگی بین دو متغیر (داده‌های محاسباتی و داده‌های مشاهداتی) را تعیین می‌کند، ضریب تعیین همبستگی خطی می‌نامند.

$$R^2 = \frac{\sum_1^n (calc - avg .obs)^2}{\sum_1^n (obs - avg .obs)^2} \quad (۴)$$

avg.obs: میانگین داده‌های مشاهداتی، n: تعداد کل زوج داده‌های مشاهداتی و محاسباتی،

obs: داده‌های مشاهداتی، Calc: داده‌های محاسباتی متناظر با داده‌های مشاهداتی

مقدار ایده آل برای R^2 یک می‌باشد (Ho, 2002: 371).

۲- میانگین مربعات خطا^۱ (MSE)

$$MSE = \frac{\sum_1^n (obs - calc)^2}{N} \quad (۵)$$

N = تعداد داده‌ها.

مقدار ایده‌آل برای معیار MSE صفر می‌باشد (Ho, 2002: 371).

یافته‌های پژوهش

در این تحقیق با بهره‌گیری از اطلاعات مشاهداتی در ایستگاه‌های سینوپتیک اهواز، آبادان و دزفول و با استفاده از شیوه‌های آماری، در هر کدام از ایستگاه‌ها ساختاری از شبکه عصبی مصنوعی به منظور مدل سازی بارندگی فصلی ارائه گردید.

نتایج حاصل از مرحله آموزش و تست مدل شبکه عصبی

در این قسمت داده‌های بارش فصلی سه ایستگاه توسط شبکه‌های عصبی مصنوعی، MLP و RBF و الگوریتم‌های آموزش مختلف با یک و دو لایه مخفی و با نرون‌های متفاوت آموزش و آزمایش شدند و پس از اعمال الگوهای مختلف و آموزش شبکه بهترین الگو از الگوهای برگزیده

^۱-Mean square of Error

انتخاب شدند. معیار انتخاب، شبکه‌ای است که بهترین آموزش را دیده باشد و نتایج قابل قبولی ارائه داده باشد. البته در انتخاب شبکه باید به وقوع پدیده بیش پردازش نیز دقت داشته باشیم زیرا در آزمون‌هایی که خطا به مقدار زیادی به صفر نزدیک شود شبکه تعمیم دهی قابل قبولی نخواهد داشت. نتایج این قسمت برای ایستگاه اهواز در جدول (۳) و برای ایستگاه آبادان در جدول (۴) و برای ایستگاه دزفول در جدول (۵) آورده شده است. پس از اعمال مجموعه تست به شبکه‌های آموزش داده شده برگزیده، تعمیم دهی شبکه‌ها مورد بررسی قرار گرفت و در نهایت شبکه‌ای که بهترین تعمیم دهی را در مورد مجموعه آزمون نشان داد را به عنوان شبکه مطلوب برای سری داده‌های تاریخ‌ای موجود بارندگی انتخاب کردیم.

جدول (۳) الگوهای برگزیده آزمون از بین الگوهای پیشنهادی برای ایستگاه اهواز

| نوع شبکه | نوع آموزش | تعداد نرون لایه مخفی اول | تعداد نرون لایه مخفی دوم | R ² مجموعه آزمایش | MSE صحت سنجی | R ² مجموعه صحت سنجی |
|-----------------------|---------------------|--------------------------|--------------------------|------------------------------|--------------|--------------------------------|
| Multilayer Perceptron | Momentum | ۴ | - | ۰/۸۷۴ | ۰/۰۹۷۶ | ۰/۸۳ |
| | | ۸ | ۱۰ | ۰/۸۷۳ | ۰/۰۸۲۵ | ۰/۸۲ |
| | Conjugate Gradient | ۸ | - | ۰/۹۱۵ | ۰/۰۵۶ | ۰/۸۸ |
| | | ۵ | ۸ | ۰/۸۶۹ | ۰/۰۶ | ۰/۸۶ |
| | | ۹ | ۱۰ | ۰/۹ | ۰/۰۵۹ | ۰/۸۷ |
| | | ۲ | - | ۰/۹۶۵ | ۰/۰۵۷ | ۰/۸۷ |
| Radial basis function | Levenberg Marquardt | ۲ | ۴ | ۰/۹۸ | ۰/۰۶۳ | ۰/۸۶ |
| | | ۵ | - | ۰/۹ | ۰/۰۵۱۸ | ۰/۸۹ |
| | Momentum | ۶ | - | ۰/۸۹۸ | ۰/۰۴۶۴ | ۰/۹۰ |
| | | ۸ | - | ۰/۸۹۶ | ۰/۰۳۸۹ | ۰/۹۲ |
| | | ۴ | ۴ | ۰/۸۹۵ | ۰/۰۷۱ | ۰/۸۳ |
| | | ۵ | - | ۰/۹۱۵ | ۰/۰۴۱۵ | ۰/۹۱ |
| | Conjugate Gradient | ۱۰ | - | ۰/۹ | ۰/۰۳۴ | ۰/۹۲ |
| | | ۵ | ۸ | ۰/۹۲۶ | ۰/۰۴۷۸ | ۰/۸۸ |
| | | ۶ | ۵ | ۰/۹۱ | ۰/۰۵۶۵ | ۰/۸۶ |
| | | ۴ | - | ۰/۹۹۹ | ۰/۰۴۳۷ | ۰/۹۲ |
| Levenberg Marquardt | ۵ | - | ۰/۹۹۹ | ۰/۰۳۳۷ | ۰/۹۵ | |
| | ۵ | ۵ | ۰/۹۹۸ | ۰/۰۵۵ | ۰/۸۸ | |
| | ۷ | ۹ | ۱/۰ | ۰/۰۷۴۸ | ۰/۸۱ | |

جدول (۴) الگوهای برگزیده آزمون از بین الگوهای پیشنهادی برای ایستگاه آبادان

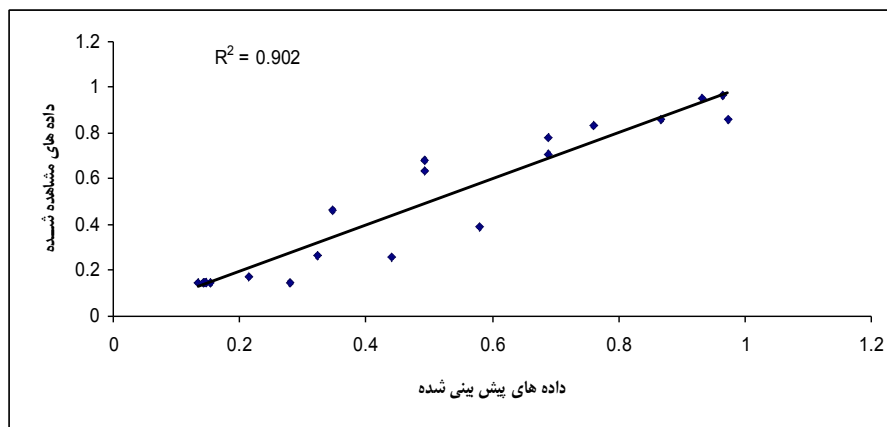
| نوع شبکه | نوع آموزش | تعداد نرون لایه مخفی اول | تعداد نرون لایه مخفی دوم | R ² مجموعه آزمایش | MSE صحت یابی | R ² مجموعه صحت یابی |
|-----------------------|---------------------|--------------------------|--------------------------|------------------------------|--------------|--------------------------------|
| Multilayer Perceptron | Momentum | ۵ | - | ۰/۸۸۱ | ۰/۰۹۸۸ | ۰/۷۷ |
| | Conjugate Gradient | ۵ | - | ۰/۸۹ | ۰/۰۹۵۶ | ۰/۷۹ |
| | | ۵ | ۳ | ۰/۸۷۵ | ۰/۰۷۸۲ | ۰/۷۹ |
| | Levenberg Marquardt | ۵ | ۵ | ۰/۹۸۸ | ۰/۰۶۲۱ | ۰/۸۳ |
| | | ۲ | ۴ | ۰/۹۷۴ | ۰/۰۸۲۶ | ۰/۷۷ |
| | | ۳ | ۴ | ۰/۹۷۵ | ۰/۰۸۵۷ | ۰/۷۸ |
| Radial basis function | Momentum | ۵ | ۶ | ۰/۸۷۶ | ۰/۰۸۳۹ | ۰/۸۰ |
| | | ۸ | ۱۰ | ۰/۸۴۶ | ۰/۰۶۹۲ | ۰/۸۱ |
| | Conjugate Gradient | ۶ | - | ۰/۸۸۷ | ۰/۰۸۹ | ۰/۸۰ |
| | | ۹ | - | ۰/۸۸۲ | ۰/۰۹ | ۰/۸۰ |
| | | ۹ | ۱۰ | ۰/۸۶ | ۰/۰۶۹۵ | ۰/۸۱ |
| | Levenberg Marquardt | ۷ | - | ۰/۹۹۹ | ۰/۰۹۴۷ | ۰/۷۷ |
| ۶ | | ۷ | ۰/۹۹۹ | ۰/۰۶۱۹ | ۰/۸۵ | |

نتایج حاصل از ترسیم منحنی پراکندگی مقادیر پیش بینی شده در برابر مقادیر مشاهده شده

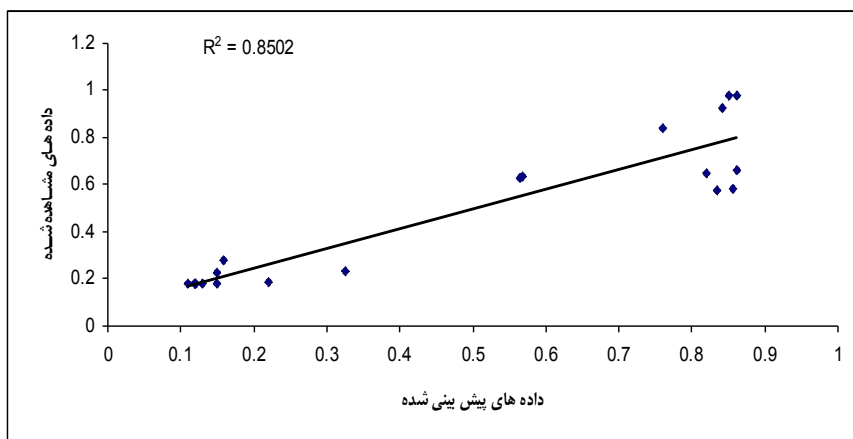
از رسم منحنی پراکندگی مقادیر پیش بینی شده مدل‌ها در مقابل مقادیر مشاهداتی و با توجه به این که هر چه پراکندگی داده‌های پیش بینی شده در اطراف خط رگرسیون کمتر باشد نشانگر دقت بالای مدل در برآورد داده‌ها می‌باشد، پراکندگی داده‌های پیش بینی شده در اطراف خط رگرسیون با توجه به شکل (۴) برای ایستگاه اهواز و شکل (۵) برای ایستگاه آبادان و شکل (۶) برای ایستگاه دزفول کم است. و تا حدود زیادی می‌توان کارایی مدل شبکه عصبی انتخاب شده را تضمین کرد.

جدول (۵) الگوهای برگزیده آزمون از بین الگوهای پیشنهادی برای ایستگاه دزفول

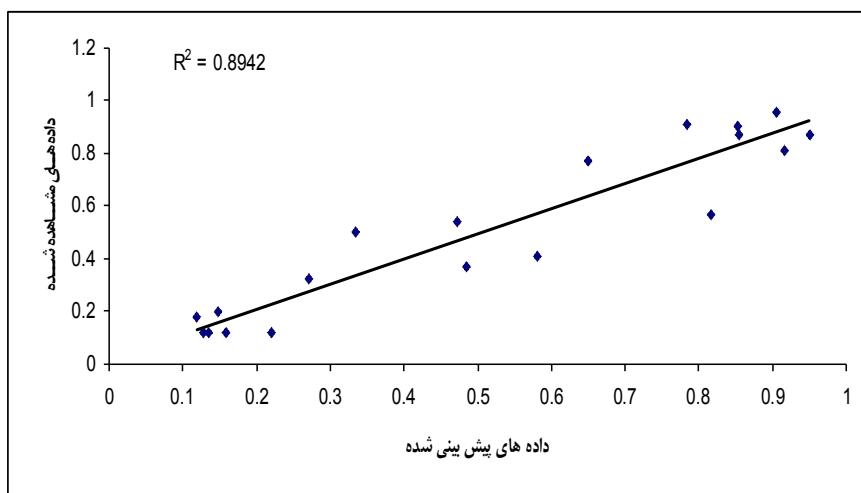
| نوع شبکه | نوع آموزش | تعداد نرون لایه مخفی اول | تعداد نرون لایه مخفی دوم | R ² مجموعه آزمایش | MSE صحت یابی | R ² مجموعه صحت یابی |
|-----------------------|---------------------|--------------------------|--------------------------|------------------------------|--------------|--------------------------------|
| Multilayer Perceptron | Momentum | ۵ | - | ۰/۹۲۶ | ۰/۰۳۷۹ | ۰/۹۰ |
| | | ۴ | - | ۰/۹۲۶ | ۰/۰۴ | ۰/۸۹ |
| | Conjugate Gradient | ۸ | - | ۰/۹۵۸ | ۰/۰۳۸ | ۰/۹۰ |
| | | ۹ | - | ۰/۹۴۷ | ۰/۰۳۴ | ۰/۹۱ |
| | | ۲ | ۳ | ۰/۹۵ | ۰/۰۵ | ۰/۸۸ |
| | | ۶ | ۷ | ۰/۹۶ | ۰/۰۵ | ۰/۸۶ |
| | | ۹ | - | ۰/۹۷۲ | ۰/۰۴۴ | ۰/۸۰ |
| | Levenberg Marquardt | ۲ | - | ۰/۹۷۵ | ۰/۰۵۴ | ۰/۸۶ |
| | | ۳ | ۴ | ۰/۹۹۷ | ۰/۰۳۴ | ۰/۸۹ |
| Radial basis function | Momentum | ۴ | ۴ | ۰/۹۴۳ | ۰/۰۴۴ | ۰/۸۶ |
| | | ۵ | ۶ | ۰/۹۵۴ | ۰/۰۴۳۵ | ۰/۸۷ |
| | | ۷ | ۹ | ۰/۹۴۳ | ۰/۰۳۷ | ۰/۸۹ |
| | Conjugate Gradient | ۹ | - | ۰/۹۵۶ | ۰/۰۶۶ | ۰/۸۴ |
| | | ۵ | ۸ | ۰/۹۵۸ | ۰/۰۴ | ۰/۸۸ |
| | Levenberg Marquardt | ۲ | - | ۰/۹۹۹ | ۰/۰۸۱۴ | ۰/۸۱ |
| | | ۷ | - | ۰/۹۹۹ | ۰/۰۷۱۲ | ۰/۸۴ |
| | | ۵ | ۵ | ۱/۰ | ۰/۳۴۵ | ۰/۹۰ |
| | | ۷ | ۹ | ۱/۰ | ۰/۰۴۳ | ۰/۸۸ |



شکل (۴) منحنی پراکندگی مقادیر پیش بینی شده بارش فصلی ایستگاه اهواز در مقابل مقادیر مشاهده شده



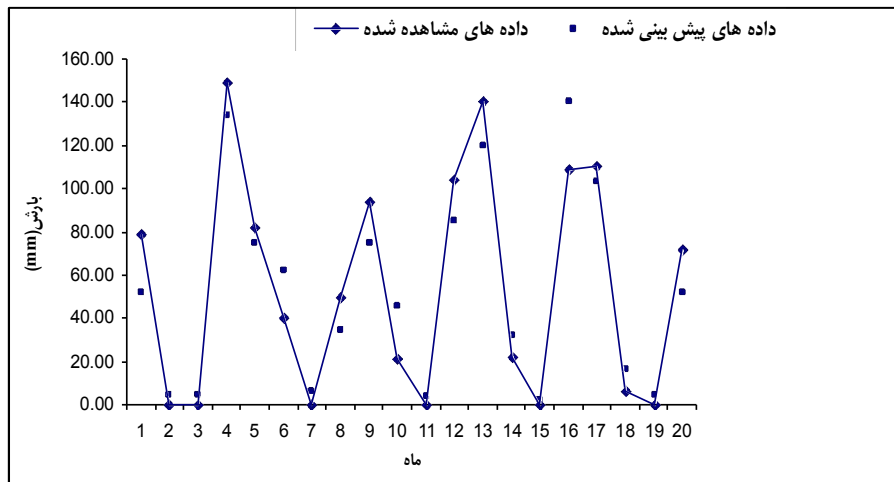
شکل (۵) منحنی پراکندگی مقادیر پیش بینی شده بارش فصلی ایستگاه آبادان در مقابل مقادیر مشاهده شده



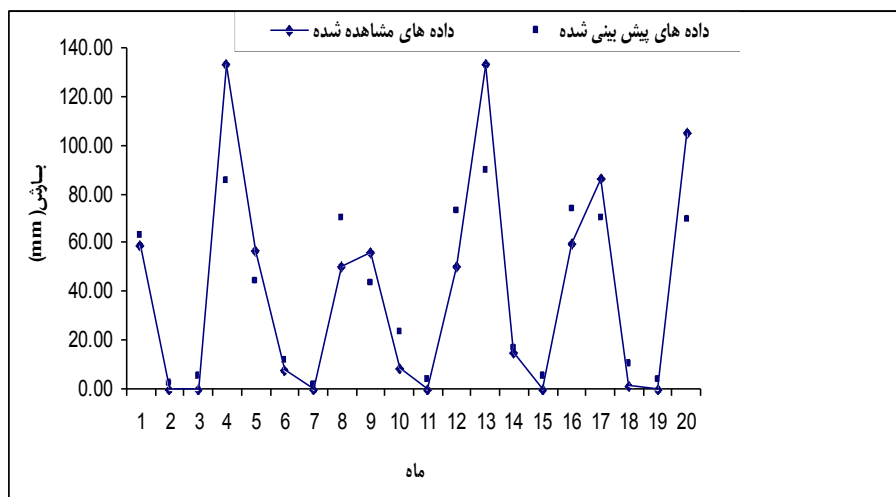
شکل (۶) منحنی پراکندگی مقادیر پیش بینی شده بارش فصلی ایستگاه دزفول در مقابل مقادیر مشاهده شده

به منظور ارزیابی و بررسی عملکرد مدل‌های طراحی شده از ترسیم زوج‌های مرتب مقادیر مشاهده شده در مقابل مقادیر پیش بینی شده توسط شبکه‌ها نیز استفاده گردید. (شکل ۷) برای ایستگاه اهواز و شکل (۸) برای ایستگاه آبادان و شکل (۹) برای ایستگاه دزفول) نتایج کارائی نسبی شبکه عصبی را در پیش بینی بارش فصلی نشان می‌دهند و تبعیت ساختارهای

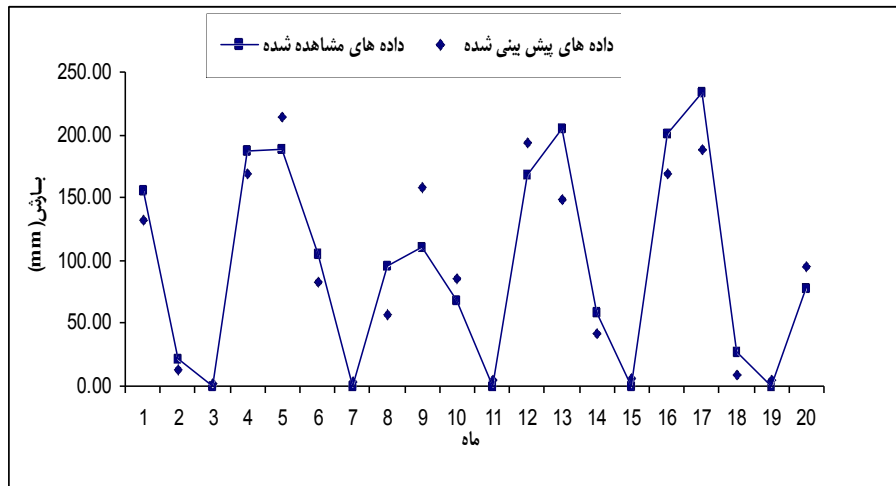
شبکه عصبی مصنوعی انتخاب شده برای ایستگاه ها از فراز و نشیب های داده های تاریخی قابل قبول می باشد.



شکل (۷) نمودار مقادیر بارش مشاهده شده و پیش بینی شده برای ایستگاه اهواز



شکل (۸) نمودار مقادیر بارش مشاهده شده و پیش بینی شده برای ایستگاه آبادان



شکل (۹) نمودار مقادیر بارش مشاهده شده و پیش بینی شده برای ایستگاه دزفول

نتیجه گیری

تکنیک شبکه‌های عصبی مصنوعی در مسائل هیدرولوژی کاربرد موفقیت‌آمیزی دارند. روش‌های شبکه‌های عصبی مصنوعی توانایی‌های زیادی در پیش‌بینی و بازسازی داده‌های تاریخی دارند. شبکه‌های عصبی مصنوعی دارای سطحی غنی از ساختارهای متفاوت و مختلف در مدل‌سازی بارندگی‌اند. همچنین پردازش اطلاعات اولیه آماری برای اخذ نتایج بهتر لازم به نظر می‌رسد. در شبکه‌های عصبی قضاوت شخصی و تجربه در انتخاب پارامترها و مدل بهینه مهم است، در واقع انتخاب بهترین ساختار شبکه‌های عصبی قالب مشخصی ندارد و با سعی و خطا انجام می‌گیرد. در تحقیق حاضر از دو نوع شبکه‌ی عصبی مصنوعی با عناوین MLP و RBF و الگوریتم‌های مومنتوم، گرادیان نزولی و لونیبرگ - مارکوارت برای تخمین بارش فصلی ایستگاه‌های منتخب استان خوزستان استفاده شد. در این تحقیق برای نخستین بار از شبکه‌های RBF برای تخمین بارش فصلی در منطقه مورد مطالعه استفاده شد. مقایسه انجام شده بین دو شبکه و الگوریتم‌های مورد استفاده نشان داد که شبکه مطلوب برای ایستگاه اهواز شبکه RBF است با یادگیری LM با یک لایه مخفی با ۵ نرون و برای ایستگاه آبادان نیز شبکه مطلوب شبکه RBF است با یادگیری LM با دو لایه مخفی که در لایه اول ۶ نرون و در لایه دوم ۷ نرون و برای ایستگاه دزفول شبکه مطلوب شبکه MLP است با یادگیری LM با ۲ لایه مخفی که لایه اول دارای ۳ نرون و لایه دوم دارای ۴ نرون می‌باشد. با توجه به استفاده از الگوریتم‌های آموزش مختلف مشاهده گردید که در هر سه ایستگاه الگوریتم لونیبرگ - مارکوارت بهترین الگوریتم

آزمایش می‌باشد و از دیگر نتایج این تحقیق آن است که با نرمال کردن داده‌ها می‌توان به نتایج بهتری جهت پیش بینی دست پیدا کرد.

منابع و ماخذ

۱. اسفندیاری، فریبا، حسینی، اسد، آزادی، محمد و حجازی، زهرا (۱۳۸۹) پیش بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنندج با استفاده از مدل شبکه‌ی عصبی مصنوعی پرسپترون چندلایه (MLP)، جغرافیا (فصلنامه علمی پژوهشی انجمن جغرافیای ایران)، ص ۴۵-۶۵.
۲. اصغری مقدم، اصغر، نورانی، وحید و ندیری، عطاله (۱۳۸۷) مدل‌سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی، مجله دانش کشاورزی دانشگاه تبریز، جلد ۱۸، شماره ۱، ص ۱-۱۵.
۳. خوشحال دستجردی، جواد و قویدل رحیمی، یوسف (۱۳۸۷) بررسی رابطه تغییرات بارش سالانه تبریز با ناهنجاری-های دمایی کره زمین و شبیه سازی عددی آن با استفاده از شبکه‌های عصبی مصنوعی، مجله علوم انسانی مدرس، ص ۲۹-۵۲.
۴. قویدل رحیمی، یوسف (۱۳۸۹) آشکارسازی آماری اثر گرمایش جهانی بر ناهنجاری های بارش سالانه جلفا با استفاده از شبکه‌های عصبی مصنوعی، جغرافیا و برنامه ریزی محیطی، ص ۶۵-۸۲.
۵. کارآموز، محمد، رضانی، فرید و رضوی، سامان (۱۳۸۵) پیش بینی بلندمدت بارش با استفاده از سیگنال‌های هواشناسی: کاربرد شبکه‌های عصبی مصنوعی، هفتمین کنگره بین المللی مهندسی عمران.
۶. محمدی، حمید، کفیل‌زاده، فرشید، نقشینه‌فرد، محمد و پیش‌بین، سیامک (۱۳۸۷) مقایسه قدرت پیش‌بینی شبکه عصبی مصنوعی با سایر روش‌های پیش‌بینی، مجله دانش نوین کشاورزی، جلد ۴، شماره ۱۳، ص ۸۵-۱۰۰.
۷. منهای، محمدباقر (۱۳۸۴) مبانی شبکه‌های عصبی، دانشگاه صنعتی امیرکبیر، تهران.
۸. ناصری، محسن (۱۳۸۲) پیش بینی بارندگی در دامنه زمان و مکان با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک، پایان‌نامه دوره کارشناسی ارشد، دانشگاه صنعتی اصفهان، گروه عمران.

Bustami, Rosmina, Nabil, Bessaih, Charles Bong and Suhaila, Suhaili (2007) *Artificial Neural Network For Precipitation and Water Level Predictions of Bedup River*, International Journal of Computer Science 34, 10-16.

Dahamsheh, Ahmad, Aksoy, Hafzullah (2009) *Artificial neural network models for forecasting intermittent monthly precipitation in arid regions*, Royal Meteorology Society 16, 325-337.

Ho, Siong Lin, Xie, Min and Goh, Thong Ngee (2002) *A comparative study of neural network and Box-Jenkins ARIMA modeling in time series production*, Computers and Industrial Engineering, 371-375.

Hung, Nguyen Quang, Babel, Mukand Singh, Weesakul, Sutat and Tripathi, Nitin Kumar (2008) *An artificial neural network model for rainfall forecasting in Bangkok, Thailand*, Hydrologe and Earth System Sciences discussions 5, 183-218.

Karen, Alexander Latinez Sotomayor (2010) *Comparison of adaptive methods using multivariate regression splines (MARS) and artificial neural networks backpropagation (ANNB) for the forecast of rain and temperatures in the Mantaro river basin*, Hydrology Days, 58-68.

Kohzadi, Nowrouz, Boyd, Milton, Kaastra, Iebeling, Kermanshahi, Bahman and Scuse, David (1995) *Neural Networks for Forecasting: An Introduction*, Canadian Journal of Agricultural Economics 43, 463-474.

Maria, Cleofe, Valverde, Ramirez, Haroldo Fraga de Campos, Velho and Nelso Jesus, Ferreira (2005) *Artificial Neural Network Technique for Rainfall Forecasting Applied to the Sao Paulo Region*, Journal of Hydrolgy 301, 146-162.

Sadorsky, Perry (2006) *Modeling and forecasting petroleum futures volatility*, Energy Economics 28, 467-488.

Shafie, Amr H El, Mazoghi, Hasan G El, Shehata, A and Taha, MohdR (2011) *Artificial neural network technique for rainfall forecasting applied to Alexandria, Egypt*, International Journal of the Physical Sciences 6, 1306-1316.

Trafalis, Theodore, White, Anderson, Santosa, Budi and Richman, Michael (2002) *Data mining techniques for improved WSR-88D rainfall estimation*, Computers in Industrial Engineering 43, 775-786.

Wang, Zhiliang and sheng, Huihua (2010) *Rainfall Prediction Using Generalized Regression Neural Network: Case study Zhengzhou*, International Conference on Computational and Information Sciences, 1265-1268.