نشریه تحقیقات کاربردی علوم جغرافیایی سال سیزدهم، شماره ۳۰، پاییز ۹۲

مقایسه عملکرد الگوریتم های مختلف شبکه عصبی مصنوعی در مدل سازی بارندگی فصلی مطالعه موردی؛ ایستگاه‌های 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 چرخه‌ی 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 داده‌های بارندگی ماهانه سه ایستگاه هواشناسی استان به مدت ۴۸سال، (۱۳۴۰-۱۳۸۷)، استفاده شده است. سپس با استفاده از این مقادیر به عنوان خروجی‌های هدف، شبکه‌های مختلفی با ساختارهای متفاوت تعریف و آموزش داده شد. در نهایت قابلیت شبکه برای تخمین بارش با استفاده از قسمتی از داده‌ها که در آموزش شبکه وارد نشدند، مورد بررسی قرار گرفت. در این تحقیق شبکه‌های MLP و RBF با تغییراتی در تعداد لایه‌های میانی، تعداد نرون‌ها و الگوریتم‌های آموزش MOM و LM و CG به منظور پیش‌بینی 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

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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 وجریان‌های 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 وغیره می‌باشد (ناصری، ۱۳۸۲). با توجه به محدودیت‌هایی از قبیل نبود اطلاعات بارش در مقیاس‌های مکانی و زمانی مناسب و پیچیدگی‌های یاد شده عملا استفاده از مدل‌هایی با مبنای فیزیکی مقدور نیست. امروزه به موازات مدل‌های متداول موجود، روش‌های جدیدتری نیز برای پیش بینی ابداع شده‌اند. شبکه های عصبی از ابزارهای جدیدی است که در سیستم های 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[1] گفته

[1]-Intelligent systems

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

می‌شود (محمدی و همکاران، ۸۵:۱۳۸۷). 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[1] و همکاران (۲۰۰۵) به کمک مدل‌های شبکه عصبی مصنوعی و رگرسیونی 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[2] و همکاران (۲۰۰۷) بارش و سطح آب را در بوداپ مالزی 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[3] (۲۰۰۸) به کمک یک‌سری پارامترهای هواشناسی با بهره گیری از مدل‌های شبکه‌های عصبی مصنوعی به پیش بینی بارش در بانکوک پرداختند. داهامشه و آکسوی[4] (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[5] مقایسه کردند. نتایج نشان داد که شبکه‌های عصبی مصنوعی نتایج بهتری را نسبت به رگرسیون چند متغیره ارایه می کند. 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 می دهد در ۷۰ درصد از سال‌ها پیش

2- Maria
3- Bustami
4- Hung
5- Dahamsheh& Aksoy
6-Multivarate regression

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

بینی در دامنه تعریف شده قرار دارد. اصغری‌مقدم 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[1] با شش گره ورودی، یک گره خروجی، یک لایه میانی و الگوریتم لونبرگ-مارکوارت[2] 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 جلفا 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[3] (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 (جدول۱) 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)

[1]-Feedforward
[2]-Levenberg-Marquardt
[3]-Multilayer perceptron

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

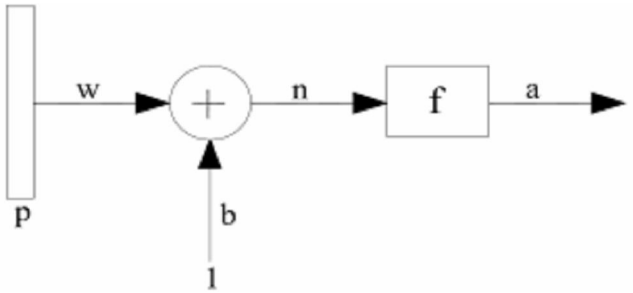
ایستگاه	درجه	دقیقه	درجه	دقیقه	
اهواز	۴۹	۱۱	۳۱	۵۰	۲۲/۵
آبادان	۴۸	۱۷	۳۰	۲۰	۶/۶
دزفول	۴۸	۲۵	۳۲	۱۶	۱۴۳

جدول (۲) مشخصات آماری سری زمانی بارندگی فصلی ایستگاه‌های 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

شبکه‌های عصبی مصنوعی

یک شبکه عصبی از نرون‌های مصنوعی تشکیل شده است. نرون یا گره کوچکترین واحد پردازش اطلاعات می‌باشد که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد (منهاج، ۱۳۸۴). هر یک از نرون‌ها، ورودی‌ها را دریافت نموده و پس از پردازش روی آن‌ها، یک سیگنال خروجی تولید می‌نمایند. 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 می‌باشد 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 می‌آید:

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

$$a = f(wp + b) \quad (۱)$$

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. عموما یک نرون، بیش از یک ورودی دارد. معمولا 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)

شبکه های چند لایه ی پیشخور یکی از مهمترین ساختارهای شبکه‌های عصبی مصنوعی می باشد. 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 می شود. این نوع شبکه معمولاً با عنوان پرسپترون چند لایه (MLP) نامیده می شود.

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
1-Radial basis function

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

در دسترس باشد از عملکرد مطلوب‌تری برخوردارند. شبکه‌هایRBF نوعی شبکه‌ی عصبی پیشخور می‌باشند و ساختار آنها شبیه شبکه‌های MLP می‌باشد.

داده‌های ورودی و خروجی شبکه

در مرحله اول داده‌های مربوطه از وب سایت سازمان هواشناسی تهیه و سپس اقدام به داده-پردازی، محاسبه و ماتریس‌بندی داده‌ها 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 ایستگاه‌های مورد مطالعه لایه ورودی شبکه را ۶ نرون شامل داده‌های: اختلاف دمای حداقل و حداکثر، حداقل رطوبت، دمای نقطه شبنم، متوسط فشار، دمای میانگین و دمای حداکثر و نرون خروجی را بارندگی فصلی تشکیل می‌دهد.

نرمالیزه نمودن داده‌ها

وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. از این رو داده‌های ورودی به شبکه بایستی نرمال شوند. در این بررسی برای نرمالیزه کردن داده‌ها از رابطه (۲) استفاده شده است که ورودی‌ها را بین ۰/۱ و ۰/۹ استاندارد می‌نماید. در نهایت می‌توان خروجی‌های شبکه را با معکوس نمودن الگوریتم استانداردسازی، به حالت اولیه برگرداند.

$$X_i = \lambda_1 + (\lambda_2 - \lambda_1)\left(\frac{z_i - z_i^{min}}{z_i^{max} - z_i^{min}}\right) \qquad (۲)$$

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 می‌باشند.

تعداد لایه‌های پنهان

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

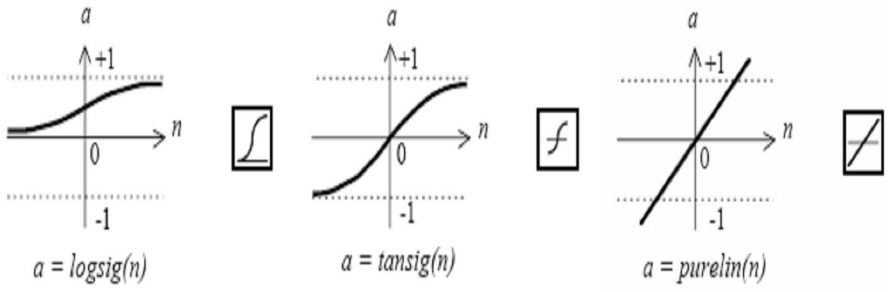
[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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 می دهند (منهاج، ۱۳۸۴).

توابع محرک[1]

نرون ها می توانند 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(شکل۳).



شکل (۳) توابع محرک رایج در شبکه‌های عصبی

بهبود قدرت تعمیم‌دهی شبکه

برای تعمیم‌دهی مناسب شبکه، باید به نحوی ازآموزش بیش از اندازه جلوگیری نمود. در مطالعه‌ی حاضر برای جلوگیری از آموزش بیش از اندازه در شبکه های MLP از روش متوقف سازی زود هنگام آموزش استفاده شد. برای تصمیم گیری 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 مطالعه ی حاضر برای آموزش شبکه‌ی RBF به نحوی که از قابلیت تعمیم دهی مناسبی برخوردار باشد، ابتدا مقداری به عنوان خطای هدف به صورت مجموع مربعات خطا (SSE) در نظر گرفته شد، سپس مقادیر

[1]-Activity function

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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.

روش‌های آموزش در شبکه‌های عصبی مصنوعی

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

الگوریتم مومنتوم[1]

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.

$$\Delta W_{ji}(n) = \eta \delta_j X_{ji} + \alpha \Delta W_{ji}(n-1) \qquad (۳)$$

که در آن مقدار ممنتم 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[2] را در جهتی تغییر می‌دهد که تابع عملکرد با سرعت بیشتری کاهش یابد.

الگوریتم گرادیان نزولی[3](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 معمولا از مشتقات دوم و یا تقریبی از آنها برای تصحیح وزن‌ها استفاده می‌نماید.

تعداد تکرار یا سیکل[4]

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 برابرتعداد داده‌های یادگیری می‌باشد (منهاج، ۱۳۸۴). که در این بررسی برای هر شبکه ۱۰۰ دور در نظر گرفته شد.

---

[1]-Momentum
[2] -Bias
[3]-Conjugate Gradient
[1]-Epoch

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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 (داده های محاسباتی وداده‌های 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[1] (MSE)

$$MSE = \frac{\sum_{1}^{n} (obs - calc)^2}{N} \quad (۵)$$

N = تعداد داده ها.

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 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

[2]-Mean square of Error

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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 شده‌ی 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 اموزش	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
	Levenberg Marquardt	۲	-	۰/۹۶۵	۰/۰۵۷	۰/۸۷
		۲	۴	۰/۹۸	۰/۰۶۳	۰/۸۶
Radial basis function	Momentum	۵	-	۰/۹	۰/۰۵۱۸	۰/۸۹
		۶	-	۰/۸۹۸	۰/۰۴۶۴	۰/۹۰
		۸	-	۰/۸۹۶	۰/۰۳۸۹	۰/۹۲
		۴	۴	۰/۸۹۵	۰/۰۷۱	۰/۸۳
	Conjugate Gradient	۵	-	۰/۹۱۵	۰/۰۴۱۵	۰/۹۱
		۱۰	-	۰/۹	۰/۰۳۴	۰/۹۲
		۵	۸	۰/۹۲۶	۰/۰۴۷۸	۰/۸۸
		۶	۵	۰/۹۱	۰/۰۵۶۵	۰/۸۶
	Levenberg Marquardt	۴	-	۰/۹۹۹	۰/۰۴۳۷	۰/۹۲
		۵	-	۰/۹۹۹	۰/۰۳۳۷	۰/۹۵
		۵	۵	۰/۹۹۸	۰/۰۵۵	۰/۸۸
		۷	۹	۱/۰	۰/۰۷۴۸	۰/۸۱

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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

نوع شبکه	نوع اموزش	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

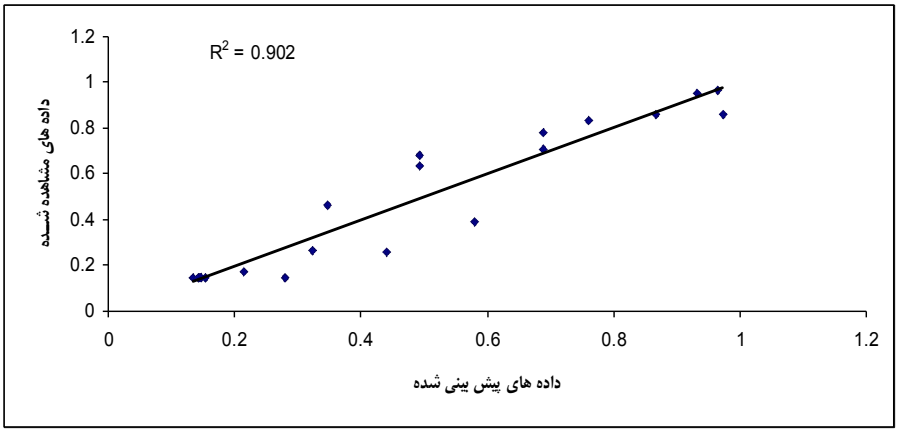
نتایج حاصل از ترسیم منحنی پراکندگی مقادیر پیش بینی شده در برابر مقادیر مشاهده شده

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 می باشد، پراکندگی داده‌ها ی 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 می توان کارائی مدل شبکه عصبی انتخاب شده را تضمین کرد.

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

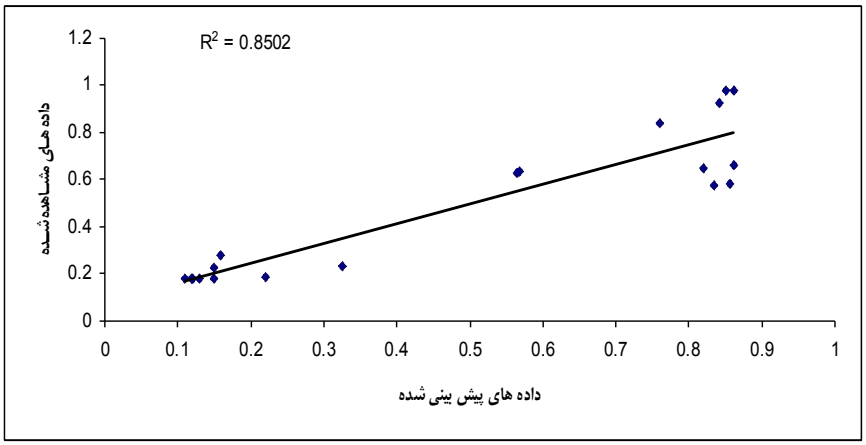
جدول(۵)الگوهای برگزیده آزمون از بین الگوهای پیشنهادی برای ایستگاه دزفول

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
	Levenberg Marquardt	۹	–	۰/۹۷۲	۰/۰۴۴	۰/۸۰
		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

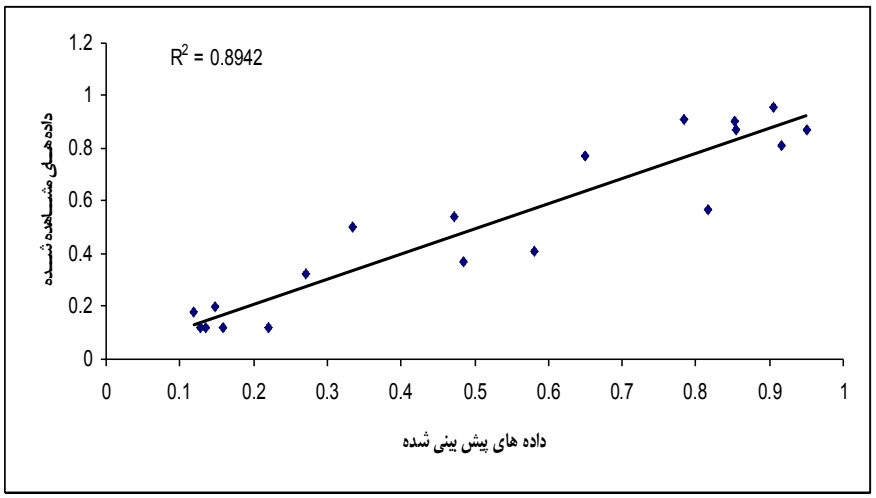


شکل(۴) منحنی پراکندگی مقادیر پیش بینی شده بارش فصلی ایستگاه اهواز در مقابل مقادیر مشاهده شده

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]



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

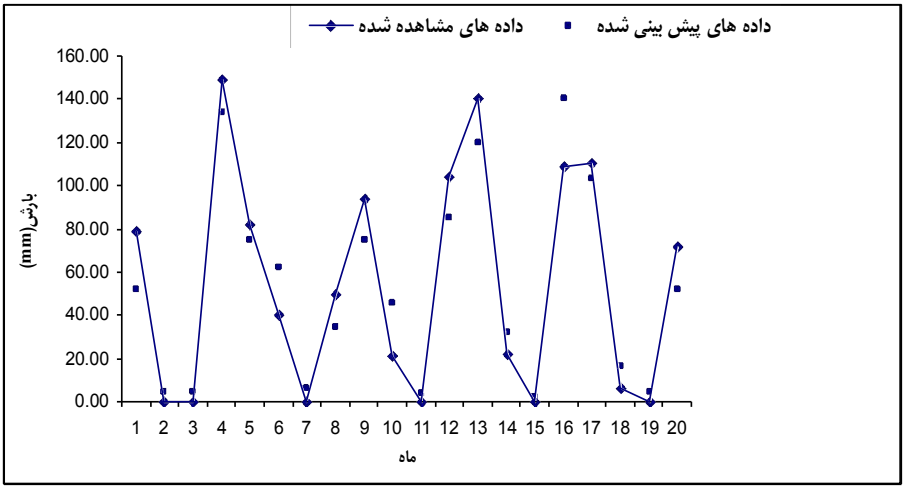


شکل(۶) منحنی پراکندگی مقادیر پیش بینی شده بارش فصلی ایستگاه دزفول در مقابل مقادیر مشاهده شده

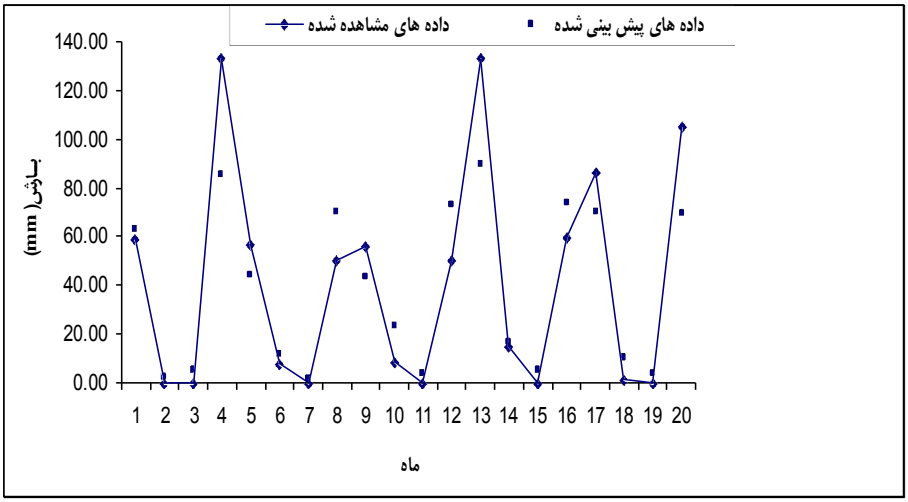
به منظور ارزیابی و بررسی عملکرد مدل‌های طراحی شده از ترسیم زوج‌های مرتب مقادیر مشاهده شده در مقابل مقادیر پیش بینی شده توسط شبکه‌ها نیز استفاده گردید. (شکل (۷) برای ایستگاه اهواز و شکل (۸) برای ایستگاه آبادان و شکل (۹) برای ایستگاه دزفول) نتایج کارائی نسبی شبکه عصبی را در پیش بینی بارش فصلی نشان می‌دهند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

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

شبکه عصبی مصنوعی انتخاب شده برای ایستگاه‌ها از فراز و نشیب های داده های تاریخی قابل قبول می‌باشد.

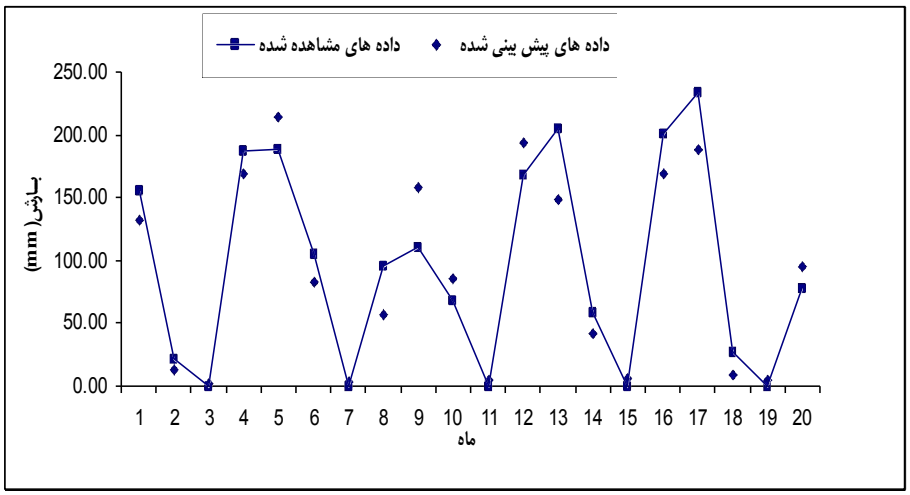


شکل(۷)نمودار مقادیر بارش مشاهده شده و پیش بینی شده برای ایستگاه اهواز



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

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]



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. روش-های شبکه‌های عصبی مصنوعی توانائی‌های زیادی در پیش بینی و بازسازی داده‌های تاریخی دارند. شبکه‌های عصبی مصنوعی دارای سطحی غنی از ساختارهای متفاوت و مختلف در مدل سازی بارندگی‌اند. همچنین پردازش اطلاعات اولیه آماری برای اخذ نتایج بهتر لازم به نظر می-رسد. 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 لونبرگ – مارکوارت برای تخمین بارش فصلی ایستگاه-های 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 لونبرگ – مارکوارت بهترین الگوریتم

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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 ۶۵-۴۵.

۲. اصغری مقدم، اصغر، نورانی، وحید و ندیری، عطاالله (۱۳۸۷) **مدلسازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی**، مجله دانش کشاورزی دانشگاه تبریز، جلد ۱۸، شماره ۱، ص ۱-۱۵.

۳. خوشحال‌دستجردی، جواد و قویدل‌رحیمی، 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 ۵۲-۲۹.

۴. قویدل‌رحیمی، 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 ۸۲-۶۵.

۵. کارآموز، محمد، رمضانی، 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 ۱۰۰-۸۵.

۷. منهاج، محمدباقر (۱۳۸۴) **مبانی شبکه های 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 کارشناسی‌ارشد، دانشگاه صنعتی اصفهان، گروه عمران.

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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 Scince 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 prodiction***, 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 Bankok, 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.

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]

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.

[Downloaded from ndea10.khu.ac.ir on 2026-11-08]