

# پیش‌بینی بارش اصفهان با استفاده از شبکه های عصبی

## مصنوعی

دریافت مقاله: ۹۰/۱۱/۸ پذیرش نهایی: ۹۱/۶/۱۳

صفحات: ۴۷-۶۳

امیرحسین حلبیان: استادیار اقلیم شناسی، گروه جغرافیا، دانشگاه پیام‌نور، تهران، ایران<sup>۱</sup>

Email: halabian\_a@yahoo.com

محمد دارند: استادیار اقلیم شناسی، دانشگاه کردستان

Email:mdarand@uok.ac.ir

## چکیده

بارش مهمترین سنج‌های هواشناسی و اقلیمی است. در این پژوهش به منظور پیش‌بینی بارش اصفهان از داده‌های بارش ماهانه‌ی ایستگاه همدید اصفهان در بازه‌ی آماری (۱۹۵۱-۲۰۰۹) به مدت ۵۹ سال و به دلیل رفتار غیرخطی بارش از شبکه‌های عصبی مصنوعی جهت پیش‌بینی آن بهره‌گرفته شد. در این ارتباط، ۷۰ درصد داده‌ها جهت آموزش شبکه و ۳۰ درصد داده‌ها برای تست و اعتبار سنجی اختصاص داده شد. نتایج پژوهش بعد از آزمون شبکه با لایه‌های پنهان و با ضرایب یادگیری مختلف آشکار ساخت که استفاده از شبکه‌های عصبی مصنوعی با یک پرسپترون با ۲ لایه پنهان و ضریب یادگیری ۰/۴ نسبت به سایر حالت‌ها و معماری شبکه، مدل نسبتاً بهتری را ارائه می‌کند. به بیانی دیگر، داده‌های پیش‌بینی شده بارش ماهانه توسط شبکه با چنین ساختار و معماری، بیشتر با واقعیت انطباق دارد. آموزش مجدد شبکه و آزمون شبکه با لایه‌های پنهان و ضرایب مختلف یادگیری در ترکیب با الگوریتم ژنتیک نیز 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، پیش‌بینی می‌کند. در عین حال، نتایج حاصل از تصادفی کردن داده‌ها تفاوتی چندانی با مرتب بودن داده‌ها برای آموزش شبکه ندارد.

کلید واژگان: بارش، پیش‌بینی، شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک، اصفهان.

<sup>۱</sup>. نویسنده مسئول: دانشگاه پیام‌نور، صندوق پستی ۳۶۹۷-۱۹۳۹۵، تهران، ایران

## مقدمه

پیش بینی تغییرات سنجه‌های اقلیمی و هواشناسی یکی از دغدغه‌های بسیار بزرگ دانشمندان علوم زمین است. اطلاعات دقیق در مورد بارش برای مدیریت منابع آب ضروری و حیاتی است. در عین حال، در مناطق شهری بارش تأثیر بسیار زیادی بر کنترل ترافیک، فاضلاب و فعالیت‌های دیگر انسان دارد. از آن جایی که حالت غیرخطی ویژگی اصلی فرایند و پارامترهای علوم جوی و هیدرولوژی است؛ در سالهای اخیر شبکه‌های عصبی مصنوعی در زمینه‌های مختلفی از جمله حفاظت از محیط زیست، طیف سنجی، باد، تخمین بارش و رواناب در مقیاسهای مختلف زمانی، پیش بینی دمای سطح دریا، آنالیز پارامترهای هواشناسی، پیش بینی ارتفاع موج، تکمیل سری‌های زمانی عناصر هواشناسی و پیش بینی دمای حداقل استفاده شده است (پلامین و همکاران، ۱۹۹۹؛ آر. لینکر و همکاران، ۲۰۰۵؛ گوساو و همکاران، ۲۰۰۸؛ تونی هال و همکاران، ۱۹۹۸؛ ووگت و ساچر، ۲۰۰۱، ناکاکیتا و همکاران، ۱۹۹۶). در این راستا، هال و همکاران (۱۹۹۹) بارش تگزاس را به کمک شبکه‌های عصبی مصنوعی پیش بینی کردند. نتایج آنان نشان داد که همبستگی خطی بین مقادیر پیش بینی شده بارش با مقادیر واقعی ۰/۹۵ است. در حال حاضر، نه تنها از شبکه‌های عصبی مصنوعی برای پیش بینی مقادیر بارش در مقیاسهای مختلف زمانی استفاده می‌شود؛ بلکه بسیاری از پژوهشگران از آن به عنوان ابزاری جهت پیش بینی رخدادهای فرین بارش نیز بهره برده‌اند. برای نمونه بدری و سیرماک (۲۰۰۰) از شبکه‌های عصبی مصنوعی برای پیش بینی مقادیر فرین بارش که در تابستان منجر به رخداد سیل در منطقه مراویا (شرق جمهوری چک) می‌شود، استفاده کردند. آنها شبکه را به کمک انتشار رو به عقب و با داده‌های ماهانه ۳۸ سال مربوط به دو ایستگاه در منطقه، آموزش دادند و مقایسه بارش ماه بعد و بارش تابستان سال بعد را پیش بینی کردند. نتایج آنان نشان داد که شبکه‌های عصبی مصنوعی به خوبی مقادیر بارش فرین را پیش بینی می‌کند؛ چرا که بین مقادیر واقعی و پیش بینی شده‌ی بارش اختلاف اندکی دیده می‌شود. میدا و همکاران<sup>۱</sup> (۲۰۰۱) نیز بارش ژاپن را به کمک شبکه‌های عصبی مصنوعی پیش بینی کردند و نتایج حاصله را با پیش بینی‌های ساعتی سازمان هواشناسی ژاپن مقایسه کردند. نتایج آنان نیز نشان داد که شبکه‌های عصبی مصنوعی ابزار مناسبی برای پیش بینی بارش و کاهش مخاطرات ناشی از آن می‌باشد. لکشمی و همکاران (۲۰۰۳) به کمک شاخص انسو و چرخه‌های لکه‌های خورشیدی بارش تابستانه‌ی هند را با ابزار شبکه‌های عصبی مصنوعی پیش بینی

---

<sup>۱</sup> - Maeda

کردند. بسطامی و همکاران (۲۰۰۷) از شبکه های عصبی مصنوعی برای پیش بینی بارش و تراز آب رودخانه بوداپ استفاده کردند. نتایج این پژوهش آشکار ساخت که دقت پیش بینی مقادیر بارش ۹۶/۴ درصد است. همچنین آنان به کمک خروجی پیش بینی شده بارش، تراز آب رودخانه را با دقت ۸۵/۳ درصد محاسبه کردند. این نتایج بیانگر کارایی خوب و مناسب شبکه های عصبی مصنوعی برای بارش و تراز آب است که یکی از ضروری ترین ورودی های هیدرولوژیکی است. هانگ و همکاران (۲۰۰۸) از شبکه های عصبی مصنوعی برای پیش بینی بارش بانکوک تایلند استفاده کردند. نتایج ایشان نشان داد که مدل توسعه یافته ی شبکه های عصبی مصنوعی برای پیش بینی زمان واقعی بارش و مدیریت سیلاب در بانکوک تایلند مناسب است. سلیمانی (۲۰۰۹) بارش-رواناب را به کمک شبکه های عصبی مصنوعی در حوضه آبریز جراحی پیش بینی کرد. نتایج وی نشان داد که تکنیک شبکه های عصبی مصنوعی برای پیش بینی رواناب رودخانه بسیار مناسب تر و کارآمدتر از مدل رگرسیون کلاسیک است. وانگ و شینگ (۲۰۱۰) بارش ژینگ ژوی چین را به کمک رگرسیون عمومی شبکه های عصبی پیش بینی کردند. نتایج این پژوهش حکایت از این داشت که رگرسیون عمومی شبکه های عصبی مقادیر خطای پیش بینی کمتری را نسبت به شبکه های مصنوعی انتشار به عقب دارند. کارین (۲۰۱۰) روش های رگرسیون چندمتغیره اسپه لاین و شبکه های عصبی مصنوعی انتشار به عقب را برای پیش بینی بارش و دمای حوضه رودخانه ماتتارو مقایسه کردند. شافعی و همکاران (۲۰۱۱) از شبکه های عصبی مصنوعی برای پیش بینی بارش اسکندریه مصر استفاده کردند. آنها مدل شبکه های عصبی مصنوعی و مدل رگرسیون چند متغیره را با هم مقایسه کردند. نتایج مطالعه آنها نشان داد که مدل شبکه های عصبی مصنوعی مناسب تر و دقیق تر است.

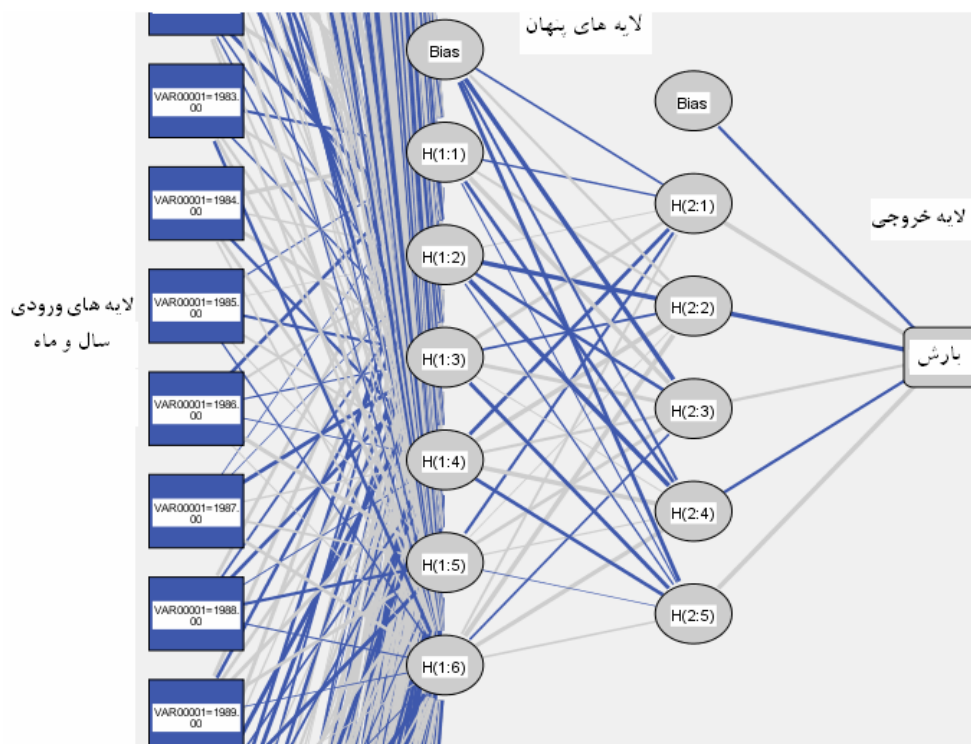
احمدی (۱۳۸۲) به طبقه بندی تغییرات بارش بوشهر با استفاده از شبکه های عصبی مصنوعی مبتنی بر مدل خود سازمانده کوهونن پرداخت و به این نتیجه رسید که روش شبکه های عصبی مصنوعی می تواند برای بیشتر پارامترهای اقلیمی و با بازه زمانی بلندتر به کار رود. علیجانی و قویدل رحیمی (۱۳۸۴) به مقایسه و پیش بینی تغییرات دمای سالانه ی تبریز با ناهنجاری های دمایی کره ی زمین با استفاده از روش های رگرسیون خطی و شبکه های عصبی مصنوعی پرداختند. نتایج آنان نشان داد که روش شبکه ی عصبی مصنوعی در مقایسه با روش های رگرسیون خطی ساده و رگرسیون نیمه خطی چند جمله ای درجه ۶، روش بهتر و دقیق تری است. خلیلی (۱۳۸۵) با استفاده از شبکه های عصبی مصنوعی بارش ماهانه ایستگاه سینوپتیک مشهد را بررسی کرد. نتایج وی نیز آشکار ساخت که شبکه های عصبی مصنوعی به خوبی روند بارش ماهانه را در ایستگاه مذکور پیش بینی می کند. خوشحال و قویدل رحیمی

(۱۳۸۷) نوسانات بارش سالانه‌ی تبریز را در ارتباط با ناهنجاریهای دمایی کره‌ی زمین به کمک شبکه‌های عصبی مصنوعی شبیه‌سازی 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. همچنین قویدل رحیمی (۱۳۸۹) به کمک شبکه‌های عصبی مصنوعی اثر گرمایش جهانی بر ناهنجاریهای بارش سالانه‌ی جلفا را مطالعه کرد و به نتایجی مشابه دست یافت 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 استفاده موفق پژوهشگران از شبکه‌های عصبی مصنوعی برای مدلسازی بارش و به جهت دقت آن در برآورد سنج‌های اقلیمی، در این پژوهش سعی بر آن است تا دقت شبکه‌های عصبی مصنوعی در برآورد بارش ماهانه‌ی ایستگاه همدید اصفهان را مورد آزمون و ارزیابی قرار دهیم.

### مواد و روش‌ها

برای انجام این پژوهش از داده‌های ماهانه بارش ایستگاه همدید اصفهان طی بازه زمانی ۱۹۵۱-۲۰۰۹ که از واحد خدمات ماشینی سازمان هواشناسی اخذ گردیده استفاده شده است. در عین حال، از شبکه‌های عصبی مصنوعی به عنوان ابزاری نیرومند جهت پیش بینی مقادیر بارش طی زمان بهره گرفته شده است. تکنیک شبکه‌های عصبی مصنوعی در این پژوهش شامل دو مرحله است: (۱) مرحله آموزش و (۲) مرحله تست. در این پژوهش ۶۹/۹ درصد داده‌ها (۴۹۵ داده) برای آموزش و ۳۰/۱ درصد داده‌ها (۲۱۳) برای تست و اعتبارسنجی در نظر گرفته شد. این که چه درصدی از داده‌ها برای آموزش شبکه کافی است و آیا حد آستانه‌ای وجود دارد که با داده‌های کمتر از آن شبکه کارآمد نباشد؛ به پیچیدگی مسأله و کیفیت داده‌ها بستگی دارد. میزان خطا در طول آموزش شبکه نیز به تعداد مثال‌های به کار رفته برای آموزش شبکه وابسته است. اگر تعداد الگوها و یا تعداد نرون‌های لایه‌ی میانی کم باشد، شبکه نمی‌تواند ارتباط موجود بین ورودی‌ها و خروجی‌ها را به درستی فراگیرد. علاوه بر آن اگر تعداد نرون‌های لایه‌ی میانی از حد لازم بیشتر باشد؛ شبکه شروع به حفظ کردن الگوها می‌کند؛ به طوری که در مرحله آموزش خوب ولی برای داده‌های آزمون ضعیف عمل نموده و قابلیت تعمیم‌پذیری ندارد (دزفولیان و اکبرپورشیرازی، ۱۳۹۰). به طور کلی، در اغلب پژوهش‌ها از ۷۰، ۷۵ و ۸۰ درصد داده‌ها برای آموزش شبکه استفاده شده است و مابقی داده‌ها جهت آزمون و اعتبارسنجی مدل شبکه بکار گرفته شده‌اند. در مرحله آموزش، شبکه‌های عصبی به کمک

داده‌های بارش و زمان، ارتباط بین نرخ بارش با گذشت زمان را فرا می‌گیرند. به بیانی دیگر شبکه می‌آموزد که مقادیر بارش در زمانهای مختلف چه رفتاری از خود نشان می‌دهد. در این پژوهش، زمان (سال، ماه) به عنوان پارامتر ورودی و مقادیر بارش به عنوان خروجی به شبکه داده شد. در مرحله تست و آزمون مقادیر خروجی با مقادیر واقعی مقایسه گردید و اختلاف یا خطا محاسبه شد. این مرحله آنقدر تکرار می‌شود تا این که میزان خطای برآورد مقادیر بارش به حداقل خود برسد و بهینه‌ترین حالت شبکه بدست آید. ساختار شبکه عصبی مصنوعی در این پژوهش شامل سه لایه‌ی رشته‌ای است: لایه ورودی، لایه پنهان و لایه خروجی. شبکه‌های عصبی مصنوعی یک شبیه‌سازی از دستگاه عصبی طبیعی است و شامل مجموعه‌ای از واحدهای عصبی بنام نرون می‌باشد که توسط ارتباطاتی موسوم به آکسون به هم متصل شده‌اند (شکل ۱).



شکل (۱) معماری سه لایه‌ای الگوریتم انتشار رو به عقب شبکه‌های عصبی مصنوعی

الگوریتم های زیادی برای آموزش شبکه وجود دارد که در میان آنها غالباً از انتشار رو به عقب<sup>۱</sup> استفاده می شود. هدف از آموزش شبکه یادگیری رفتار بارش توسط شبکه برای برآورد مقادیر پیش بینی شده است. این الگوریتم به طور مستقل توسط چندین پژوهشگر از جمله ویرئس (۱۹۷۴) و پارکر (۱۹۸۲) و رومرلهارت، هینتون و ویلیامز (۱۹۸۶) بسط و گسترش یافت. روش آموزش آن شهودی و مبتنی بر درک و انتقال مستقیم است و وزن ها را طوری تنظیم می کند که میزان خطا به حداقل خود برسد. لایه ها کاملاً با همدیگر ارتباط دارند و نرون ها داده های ورودی را از لایه ی ورودی می گیرند. در این پژوهش نیز با توجه به موارد فوق از الگوریتم انتشار رو به عقب برای آموزش داده ها بهره گرفته شد. تابع تان اکسون<sup>۲</sup> که تابع معروفی در روش انتشار پس انتشار است نیز به عنوان تابع تحریک استفاده گردید. همان گونه که یک سلول بیولوژیک باید به سطح آستانه تحریک خاصی برسد تا یک سیگنال تولید کند، توابع تحریک نیز تا زمانی که ورودی های ترکیب شده و وزن دار شده به یک حد آستانه- ای خاصی نرسند مقدار خروجی نظیر بسیار کوچکی تولید میکنند. تابع تحریک تابع انتقال نیز گفته می شود. در عین حال، به منظور کاهش خطای پیش بینی چندین بار سعی و خطا روی پارامترهای شبکه انجام شد و در نهایت پارامترها به صورت زیر تنظیم گردیدند. برای آموزش شبکه نیز از مدل پرسپترون چندلایه<sup>۳</sup> استفاده شد که در جدول ۱ آمده است.

جدول (۱) پارامترهای شبکه آموزش داده شده پس از سعی و خطا

مدل و یا نوع شبکه	پرسپترون چند لایه ای
تعداد لایه های مخفی	۲
روش آموزش	دلتا بار دلتا
نرخ یادگیری اولیه	۰/۴
مومنوم	۰/۹
تابع تحریک یا فشردگی	در لایه های پنهان سیگموئید در لایه ی خروجی هایپربولیک تانژانت
تعداد نرون های در دو لایه مخفی	۵،۶
تعداد اپاک	۱۰۰۰

<sup>۱</sup>-Back-propagation

<sup>۲</sup>-TanhAxon

<sup>۳</sup>- Multilayer perceptron

در شبیه‌سازی زمانی که طی فرایند یادگیری، وزن خاصی افزایش می‌یابد پس از آن معمولاً تا انتها افزایش می‌یابد و بالعکس اگر وزن باید کاهش یابد تا انتها کاهش می‌یابد و به ندرت پیش می‌آید که یک وزن بطور متوالی کم و زیاد شود. از این رو پارامتری به نام مومنتم بر روی تغییر وزن تأثیر داده می‌شود. معمولاً یکی از دو روند آموزش الگو به الگو (Epoch) و آموزش گروهی (Batch) در تدوین مدل‌های شبکه‌های عصبی به کار برده می‌شود. در این پژوهش از آموزش الگو به الگو (اپاک) استفاده شد.

در ادامه، هم در مراحل آموزش و تست شبکه و هم در مراحل نهایی مقادیر بارش واقعی با مقادیر پیش‌بینی شده بارش توسط شبکه از رابطه‌ی ساده‌ی ضریب همبستگی استفاده گردید. در مراحل آموزش و تست بارها شبکه با معماری که به آن داده می‌شود خود را سازگار می‌کند تا بهترین حالت در آن معماری به دست آید و بین مقادیر واقعی و پیش‌بینی شده بارش توسط شبکه بیشترین ضریب همبستگی وجود داشته باشد. همبستگی بین مقادیر بارش مشاهده شده و پیش‌بینی به کمک رابطه‌ی زیر محاسبه شد.

$$R = \frac{\sum_{i=1}^{i=n} [P_a - \bar{P}_a][P_s - \bar{P}_s]}{\sqrt{\sum_{i=1}^{i=n} [P_a - \bar{P}_a]^2 \sum_{i=1}^{i=n} [P_s - \bar{P}_s]^2}}$$

$P_a$  بارش مشاهده شده

$\bar{P}_a$  میانگین بارش مشاهده شده

$P_s$  بارش پیش‌بینی شده


$\bar{P}_s$  میانگین بارش پیش‌بینی شده

### یافته های پژوهش

#### داده های منظم و نتایج شبکه در ترکیب با الگوریتم ژنتیک

از آن جایی که الگوریتم پس انتشار غالباً برای مسائل واقعی بسیار کند عمل می‌کند؛ جهت غلبه بر این مشکل از الگوریتم ژنتیک برای انتخاب بهترین وزن های اولیه استفاده می‌شود. به عبارت دیگر با استفاده از شبکه عصبی و ترکیب آن با الگوریتم ژنتیک می‌توان سریعتر به نتیجه رسید و علاوه بر آن دقت را نیز افزایش داد و سرانجام به نتیجه بهتری دست یافت. در این پژوهش هم در مرحله آموزش و هم در مرحله تست از الگوریتم ژنتیک بهره گرفته شده و الگوریتم در پی بهینه سازی تابع دلتا بار دلتا که به عنوان تابع انتقال استفاده شده؛ بوده است.


لازم به ذکر است که مشخصات آموزش شبکه در ترکیب با الگوریتم ژنتیک دقیقاً همان خصوصیات آموزش شبکه بدون ترکیب با الگوریتم ژنتیک می باشد. شکل ۲ میزان بارش حداقل مجذور متوسط خطاها با آموزش منظم داده ها در ترکیب با الگوریتم ژنتیک را نشان می دهد. مجذور متوسط خطاها ( $MSE^1$ ) برای شبکه بدون ترکیب با الگوریتم ژنتیک برابر با ۰/۰۰۴ می باشد. مقایسه داده های ماهانه بارش با میزان پیش بینی شده توسط شبکه در حالت قرارگیری منظم داده ها در ترکیب با الگوریتم ژنتیک در شکل ۳ نشان داده شده است. همانطور که مشخص است شبکه عصبی مصنوعی به خوبی توانسته است که روند غیر خطی میزان بارش را با توجه به آموزشی که به شبکه داده شده است پیدا کند. شکل ۴ پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش بینی شده توسط شبکه بدون ترکیب با الگوریتم ژنتیک را نشان می دهد که ضریب بدست آمده برابر با ۰/۸۷ و ضریب تعیین برابر با ۰/۷۶ می باشد.




شکل (۲) برازش حداقل مجذور متوسط خطاها با آموزش منظم داده ها در ترکیب با الگوریتم ژنتیک

<sup>1</sup> - Mean Square Error





شکل (۳) مقایسه مقادیر واقعی ماهانه بارش با میزان بارش پیش بینی شده شبکه با آموزش منظم داده‌ها در ترکیب با الگوریتم ژنتیک




شکل (۴) پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش آگاهی شده توسط شبکه در حالت آموزش منظم داده‌ها در ترکیب با الگوریتم ژنتیک

### داده های تصادفی و نتایج شبکه در ترکیب با الگوریتم ژنتیک


در این پژوهش داده های تصادفی نیز برای آموزش شبکه نیز مورد آزمون قرار گرفت. شکل ۵ برازش مجذور میانگین خطا هنگام آموزش داده ها با داده های تصادفی را نشان می دهد. مجذور میانگین خطا در این حالت برابر با  $0/004$  است. همانطور که ملاحظه می شود نتایج حاصل از تصادفی کردن داده ها برای آموزش شبکه با نتایج حاصله از حالت قرارگیری منظم داده ها تفاوت چندانی ندارد. میزان حداقل مجذور خطا در هر دو حالت به یکدیگر نزدیک است. در شکل ۶ میزان بارش برآورد شده در حالت تصادفی کردن داده ها آمده است. همانطور که ملاحظه می شود در این حالت نیز شبکه توانسته است که رفتار غیرخطی بارش را در بازه زمان پیدا کند و میزان آن را برازش کند. پراکنش نگار میزان همبستگی بین مقادیر پیش بینی شده با مقادیر واقعی در شکل ۷ نشان داده شده است. همانطور که مشاهده می شود میزان همبستگی برابر با  $0/87$  و میزان ضریب تبیین برابر با  $0/76$  است.



شکل (۵) برازش حداقل مجذور متوسط خطاها با آموزش تصادفی داده ها در ترکیب با الگوریتم ژنتیک



شکل (۶) مقایسه مقادیر واقعی ماهانه بارش با میزان بارش پیش بینی شده شبکه در حالت تصادفی داده ها ترکیب با الگوریتم ژنتیک



شکل (۷) پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش بینی شده توسط شبکه در حالت تصادفی داده ها در ترکیب با الگوریتم ژنتیک

بنابراین می توان گفت که استفاده از داده‌های منظم و یا داده‌های تصادفی برای آموزش شبکه تفاوتی در نتایج برازش مدل ایجاد نمی‌کند؛ چرا که نتایج مدل در دو حالت مزبور اختلاف چندانی با هم ندارد. میزان بارش پیش بینی شده طی سالهای ۲۰۰۸ و ۲۰۰۹ در جدول ۲ آمده است. همانطور که ملاحظه می شود بین مقادیر واقعی و پیش بینی شده بارش هماهنگی نسبتاً خوبی برقرار است.


جدول (۲) مقادیر واقعی و پیش بینی شده توسط شبکه برای سالهای ۲۰۰۸ و ۲۰۰۹

پیش بینی ۲۰۰۹	واقعی ۲۰۰۹	پیش بینی ۲۰۰۸	واقعی ۲۰۰۸	داده های ورودی به شبکه بدون مقادیر واقعی بارش			
				۱	۲۰۰۹	۱	۲۰۰۸
۲۸,۱	۸,۷	۵,۶	۷,۴	۱	۲۰۰۹	۱	۲۰۰۸
۲۴,۴	۴۱,۲	۴,۶	۰,۷	۲	۲۰۰۹	۲	۲۰۰۸
۱۶,۹	۱۷,۶	۰	۰	۳	۲۰۰۹	۳	۲۰۰۸
۳۱,۴	۳۰,۸	۶,۴	۱۱,۳	۴	۲۰۰۹	۴	۲۰۰۸
۶,۶	۵,۹	۱,۵	۰	۵	۲۰۰۹	۵	۲۰۰۸
۱,۵	۰	۰,۷	۰	۶	۲۰۰۹	۶	۲۰۰۸
۱,۱	۰	۰,۶	۰	۷	۲۰۰۹	۷	۲۰۰۸
۱	۰	۰,۶	۰	۸	۲۰۰۹	۸	۲۰۰۸
۱,۲	۱,۸	۰,۶	۰	۹	۲۰۰۹	۹	۲۰۰۸
۱,۸	۰,۱	۵,۶	۶,۵	۱۰	۲۰۰۹	۱۰	۲۰۰۸
۲۱,۴	۳۰,۶	۴	۱۱,۳	۱۱	۲۰۰۹	۱۱	۲۰۰۸
۳۲	۴۲,۸	۶,۵	۳,۵	۱۲	۲۰۰۹	۱۲	۲۰۰۸

### تحلیل حساسیت

در تحلیل حساسیت نقش هر کدام از متغیرهای ورودی (زمان: سال و ماه) بر متغیر خروجی (بارش) سنجیده می‌شود.

همانطور که در شکل ۸ نشان داده شده است، نقش پارامتر ورودی سال در برآورد بارش برابر با ۰/۴۲۲ است ولی نقش پارامتر ورودی ماه برابر با ۰/۵۷۸ است. این موضوع نشان می دهد که تغییرات بارش نسبت به بردار زمان بیشتر تحت تأثیر تغییرات ماههای مختلف است. بارش در ماههای سرد سال (فصول پاییز و زمستان) افزایش ولی در ماههای گرم سال (فصول تابستان و بهار) کاهش می‌یابد. در عین حال، نوسانات بارش اصفهان طی سالهای مورد مطالعه بسیار اندک است. به بیان دیگر با گذشت زمان تغییرات بارش بسیار ناچیز می‌باشد.



شکل (۸) میزان اهمیت و نقش پارامترهای ورودی شبکه

### نتیجه گیری

اساساً پیش بینی بارش به سبب رفتار بسیار نامنظم و آشوبمندی که از خود نشان می‌دهد؛ دشوار، پیچیده و در عین حال حائز اهمیت است. اخیراً پژوهشگران متعددی از شبکه‌های عصبی مصنوعی به عنوان ابزاری جهت پیش بینی بارش در نقاط مختلف جهان استفاده کرده‌اند. یافته‌های این پژوهشگران نیز حکایت از کارآمدی شبکه‌های عصبی مصنوعی در مقایسه با سایر روش‌های آماری در مدل‌سازی بارش دارد. از این رو، در پژوهش حاضر نیز بر آن شدیم تا توانمندی این شبکه را در خصوص پیش‌بینی بارش اصفهان به بوتله آزمون گذاریم. نتایج حاصله نشان داد که آموزش شبکه با لایه های پنهان و با ضرایب یادگیری با یک پرسپترون چند لایه همراه با ۳ لایه پنهان و با ضریب یادگیری ۰/۱ نسبت به سایر حالت ها و معماری شبکه مدل نسبتاً بهتری را ارائه می کند. یافته‌های این پژوهش نیز به نوعی نتایج سایر پژوهشگران (خلیلی، ۱۳۸۵، خوشحال و قویدل رحیمی، ۱۳۸۷؛ قویدل رحیمی، ۱۳۸۹ و ...) را تأیید می کند. در عین حال، نتایج این پژوهش آشکار ساخت که استفاده از داده‌های منظم و یا داده‌های تصادفی تفاوتی در برآورد و پیش بینی مقادیر بارش ایجاد نمی‌کند. در مناطق دیگر ممکن است نتایج حاصل از آموزش شبکه با داده‌های تصادفی با آموزش آن با داده‌های منظم متفاوت باشد که دلیل آن نیاز به تحقیق بیشتر دارد. برای نمونه قلی‌زاده و دارند (۱۳۸۹) نشان دادند که آموزش شبکه با داده‌های منظم بهتر از داده‌های تصادفی مقادیر بارش را برای تهران برآورد

می‌کند. میزان همبستگی مقادیر واقعی با مقادیر پیش بینی شده در حالت استفاده از داده‌های تصادفی برابر با ۰/۸۶۹ و در حالت استفاده از داده‌های منظم برابر با ۰/۸۷۵ است. حداقل مجذور خطا نیز در حالت استفاده از داده‌های منظم و یا داده‌های تصادفی برابر با ۰/۰۰۴ است. از دیگر یافته‌های این پژوهش می‌توان به این نکته اشاره کرد که ترکیب شبکه با الگوریتم ژنتیک منجر به افزایش دقت و سرعت عمل در برآورد و پیش بینی مقادیر بارش می‌شود؛ زیرا در این حالت شبکه تمام داده‌ها را کدبندی می‌کند و رفتار بارش را سریعتر شناسایی و آشکار می‌سازد. این درحالی است که بدون ترکیب با الگوریتم ژنتیک مقادیر، کدبندی نشده و شبکه مدت زمان بیشتری را صرف آموزش خود می‌کند و میزان دقت آن نیز نسبت به ترکیب با الگوریتم ژنتیک کمتر است.

#### منابع و ماخذ

۱. احمدی، اسماعیل (۱۳۸۲) طبقه بندی تغییرات بارش بوشهر با استفاده از شبکه های عصبی مصنوعی (ANN) مبتنی بر مدل خود سازمانده کوهونن (SOM)، پایان نامه کارشناسی ارشد، دانشگاه تربیت معلم، گروه جغرافیا.
۲. خلیلی، نجمه (۱۳۸۵) پیش بینی بارش با استفاده از شبکه های عصبی، پایان نامه کارشناسی ارشد مهندسی آب، دانشگاه فردوسی مشهد، دانشکده کشاورزی.
۳. قویدل رحیمی، یوسف (۱۳۸۹) آشکارسازی آماری اثر گرمایش جهانی بر ناهنجاری های بارش سالانه جلفا با استفاده از شبکه های عصبی مصنوعی، جغرافیا و برنامه ریزی محیطی، ۶۵-۸۲.
۴. 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 شبکه های عصبی مصنوعی، مجله علوم انسانی مدرس، ۲۹-۵۲.
۵. علیجانی، بهلول و قویدل رحیمی، یوسف (۱۳۸۴) مقایسه و پیش بینی تغییرات دمای سالانه تبریز با ناهنجاری های دمایی کره زمین با استفاده از روش های رگرسیون خطی و شبکه عصبی مصنوعی، مجله جغرافیا و توسعه، ۲۱-۳۸.

۶. قلی‌زاده، محمدحسین، دارند، محمد (۱۳۸۹) پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مورد: تهران)، پژوهش‌های جغرافیای طبیعی، ۷۱، ۵۱-۶۳.

۷. دزفولیان، محمدامین، اکبرپور شیرازی، محسن (۱۳۹۰) مدل سازی سنگ شناسی در میدان گازی پارس جنوبی با استفاده از شبکه عصبی مصنوعی، پژوهش نفت، ۲۱(۶۶)، ۱۲-۲۲.

Nakakita, E., Sh. Ikebuchi, M. Nakmuri, M.Okuda, A. Yamaji and T. Takasao (1996) *Short-term rainfall prediction method using a volume scanning radar and GPV data from numerical weather prediction*. Journal of Geophysical Research, 101, No.D21; 26, 181-26,197.

Wang, Z.L and H.H sheng (2010) *Rainfall Prediction Using Generalized Regression Neural Network: Case study Zhengzhou*. International Conference on Computational and Information Sciences. 17-19 December, 1265-1268.

Bustami,R., N. Bessaih, Ch. Bong and S. Suhaili (2007) *Artificial Neural Network for Precipitation and Water Level Predictions of Bedup River*. IAENG International Journal of Computer Science, 34:2, IJCS\_34\_2\_10.

Lakshami, S.S., R.K. Tiwari and V.K. Somvanshi (2003) *Prediction of Indian Rainfall Index(IRF) using the ENSO variability and sunspot cycles-An artifivial neural network approach*. Journal of Indian Geophysics Union, Vol.7, 173-181.

Bodri, L and V. Cermak (2000) *Prediction of extreme precipitation using a neural network: application to summer flood occurrence in Moravia*. Advances in Engineering Software, Vol. 31, 311-321

Hall, T, H.E. Brooks and Ch.A. Doswell (1999) *Precipitation Forecasting Using a Neural Network*. Weather and forecasting, Vol.14, 338-345.

Shafie, A.H, A. El-Shafie, Hasan G. El Mazoghi, A. Shehata and Mohd. R. Taha (2011) *Artificial neural network technique for*

*rainfall forecasting applied to Alexandria, Egypt*, International Journal of the Physical Sciences Vol. 6(6), 1306-1316.

Hung, N.Q., M. S. Babel, S. Weesakul, and N. K. Tripathi (2008) *An artificial neural network model for rainfall forecasting in Bangkok, Thailand*, Hydrology and Earth Sciences Discussion, Vol. 5, 183-218.

Karen, A.L.S, (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.

Maeda, N, K. Shun'ichi, I. Kaoru IZUMI, K. Shigekazu and A. Michihiro (2001) *Prediction of Precipitation by A neural Network Method*, Journal of Natural Disaster Science, Volume 23, Number 1, pp23-33.

Plamen N. Penchev, George N. Andreev, Kurt Varmuza, 1999, *Automatic classification of infrared spectra using a set of improved expert-based features*, Anal. Chim. Acta, 388, 145-159.

Parker, D.B (1982) *Learning Logic: Stanford university*. Stanford, Claifornia, Office of Technology Licensing, Invention Report S81-64, File1, pp119.

Linker, R., I. Shmulevich, A. Kenny and A. Shaviv (2005) *Soil identification and chemometrics for direct determination of nitrate in soils using FTIR-ATR mid-infrared spectroscopy*. Chemosphere, 61, 5, 652-658.

Gosay, S., R. Dinica and M. Praisler (2008) *Choosing between GC-FTIR and GC-MS spectra for an efficient intelligent identification of illicit amphetamines*. J. Mol. Struct., 887, 1-3, 269-278 .

Hall, T., E.B. Harold and A.D Charles (1998) *Precipitation Forecasting Using a Neural Network*. Wea. Forecasting, 14, 338-345.



S. Vogt and D. Sacher (2001) *A neural network method for wind estimation using wind profiler data*. Meteorologische Zeitschrift, 10, 6, 479–487.

Solamani, K (2009) *Rainfall-runoff Prediction Based on Artificial Neural Network (A Case Study: Jarahi Watershed)*. American-Eurasian J. Agric. & Environ. Sci., 5 (6): 856-865.

Werbos, P. (1974) *beyond regression: New tools for prediction and analysis in the behavioural science*. PhD dissertation, Committee on Appl. Math., Harvard Univ., Cambridge, MA.

Rumelhart, D.E., Hinton, G.E and Williams, R. J. (1986) **Learning internal representations by error propagation**. *Parallel Distributed Processing*, Vol. 1, 318-362.