

# پیش آگاهی و برآورد بارش یزد با استفاده از شبکه های

## عصبی مصنوعی\*

دکتر امیر حسین حلبیان: استادیار اقلیم شناسی دانشگاه پیام نور اصفهان

### چکیده

بارش یکی از مهمترین داده های ورودی به سیستم های هیدرولوژیکی محسوب می شود که مطالعه و اندازه گیری آن در اکثر موارد برای مطالعات رواناب، خشکسالی، آبهای زیرزمینی، سیلاب، رسوب و ... لازم و ضروری است. هدف این مقاله پیش آگاهی مقادیر بارش ماهانه یزد با استفاده از شبکه های عصبی مصنوعی است. در این تحقیق از داده های بارش ماهانه طی دوره آماری ۵۳ سال (۱۹۵۰-۲۰۰۳) و شبکه های عصبی مصنوعی به عنوان یک روش غیر خطی جهت پیش بینی بارش استفاده شده است. نتایج این تحقیق بعد از آزمون شبکه با لایه های پنهان و با ضرایب یادگیری مختلف نشان داد که استفاده از شبکه های عصبی مصنوعی با یک پرسپترون ۲ لایه پنهان با ضریب یادگیری ۰/۱ و مومنتم ۰/۷ مدل نسبتاً بهتری را ارائه می کند و همچنین بعد از آموزش مجدد شبکه و آزمون شبکه با لایه های پنهان و ضرایب مختلف یادگیری در ترکیب با الگوریتم ژنتیک نشان داد که ترکیب شبکه با ویژگی های مذکور با الگوریتم ژنتیک باعث کاهش خطا و افزایش سرعت محاسبات شده و مدل بهتری را ارائه می کند. لازم به ذکر است که تصادفی کردن داده ها برای آموزش شبکه باعث افزایش دقت و بهتر بودن مدل می شود.

واژگان کلیدی: بارش، پیش آگاهی، شبکه های عصبی مصنوعی، الگوریتم ژنتیک، یزد.

\* این پژوهش با استفاده از اعتبارات دانشگاه پیام نور انجام شده است.

## مقدمه

بارش یکی از مهمترین داده های ورودی به سیستم های هیدرولوژیکی محسوب می شود که مطالعه و اندازه گیری آن در اکثر موارد برای مطالعات رواناب، آبهای زیرزمینی، سیلاب، رسوب و ... لازم می باشد. شبکه های عصبی مصنوعی به عنوان یک مدل تجربی برای اولین بار از فرموله کردن توانائی های مغز انسان توسط مک کالچ و پیتس<sup>۱</sup> (۱۹۴۳) ارائه گردید. شبکه های عصبی مصنوعی گسترش خود را مدیون تلاشهای هاپلفید در دو دهه اخیر می باشند(هایکین<sup>۲</sup>، ۱۹۹۴). شبکه های عصبی مصنوعی که اغلب شبکه های عصبی خوانده می شود به عنوان یک مدل تشخیص روند های ناپارامتری و غیر خطی می تواند روابط غیر خطی پیچیده یا لایه های پنهان بین متغیرهای وابسته و مستقل را پیدا کند و با دقت بهتری نسبت به روش های آماری از جمله روش رگرسیونی عمل نماید( کراس و همکاران<sup>۳</sup>، ۱۹۹۵، ۱۰۷۵). زمانی که بین پارامترهای مورد بررسی رابطه ی غیر خطی آشکاری وجود نداشته باشد، شبکه عصبی نمی تواند در مقایسه با رگرسیون نتیجه بهتری را ارائه دهد(ناماسیویام و همکاران<sup>۴</sup>، ۲۰۰۱، ۱۲۳). شبکه های عصبی کاربردهای زیادی در پیش بینی سربهای زمانی دارند(لاپلاس و فاربر<sup>۵</sup>، ۱۹۸۷). قبلاً برای پیش بینی بارش و سربهای زمانی از روش رگرسیون خطی استفاده می شد. اما در سالهای اخیر استفاده از شبکه های عصبی مصنوعی برای مدلسازی بارش توسط محققین فراوانی بکار گرفته شده است(ناونی و سیکاتو<sup>۶</sup>، ۱۹۹۴، ۳۰۵). به نظر می رسد که اولین سیستم تخمین مکانی-زمانی بارندگی با استفاده از شبکه های عصبی مصنوعی را، فرنچ و همکاران<sup>۷</sup> در سال ۱۹۹۲ ارائه کردند. پس از فرنچ در سال ۱۹۹۴، توما و ایگاتا<sup>۸</sup> با بکارگیری یک

<sup>1</sup>- McCulloch and Pitts

<sup>2</sup>- Haykin

<sup>3</sup>-Cross et al

<sup>4</sup>- Namasivayam et al

<sup>5</sup>-Lapedas and farber

<sup>6</sup>- Navonne and Ceccatto

<sup>7</sup>- French et al

<sup>8</sup>- Tohma, and Igata

شبکه سه لایه ای به پیش بینی بارندگی پرداختند. توکار و سانتون<sup>۱</sup> (۱۹۹۹) با استفاده از شبکه عصبی به پیش بینی بارش را انجام دادند. نتایج نشان داد که مدل رواناب- بارش حاصل از شبکه های عصبی مصنوعی در مقایسه با دیگر روش های آماری دقت بیشتری داشته و زمان کمتری برای برآزش مدل صرف می شود. در سال ۱۹۹۷ هال و همکاران<sup>۲</sup> با بکارگیری گروه های متصل شبکه ای به پیش بینی بارندگی پرداختند، که مسیر ورودی و خروجی با گروه های بهم پیوسته عصبی سازماندهی شده بود و نشان دادند که میزان همبستگی بین بارش واقعی و بارش پیش بینی شده توسط شبکه های عصبی برابر با ۹۵ درصد می باشد. ترافالیس و همکاران<sup>۳</sup> (۲۰۰۲) از شبکه های عصبی مصنوعی با معماری های مختلف مقادیر بارش را پیش بینی کردند. ایشان از داده های بارش رادار به عنوان داده های ورودی شبکه استفاده کردند و نتایج حاصل از برآزش شبکه های عصبی مصنوعی را با بعضی از روش های دیگر از جمله رگرسیون خطی و پولی نومیال مقایسه کردند و به این نتیجه رسیدند که شبکه های عصبی دقت بیشتری نسبت به دیگر روش ها دارد. حسامی و همکاران (۲۰۰۴) از شبکه های عصبی مصنوعی برای کالیبره کردن تخمین بارش با استفاده از داده های هواشناسی رادار استفاده کردند و به این نتیجه رسیدند که تابع لیونبرگ-مارکیوردت<sup>۴</sup> می تواند تابع قابل قبولی برای کالیبره کردن تخمین داده های بارش رادار باشد. هاستینراس و همکاران<sup>۵</sup> (۱۹۹۵) از شبکه های عصبی مصنوعی جهت پیش بینی ریزش های 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 شبکه های عصبی مصنوعی قابل پیش بینی است. در ایران، شمس (۱۳۸۲) در پایانامه 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 شبکه های عصبی مصنوعی بمنظور استخراج توزیع مکانی

<sup>۱</sup> - Tokar and Johnson

<sup>۲</sup> - Hall et al

<sup>۳</sup> - Trafalis


<sup>۴</sup> - Ievenberg\_Marquardt

<sup>۵</sup> - Hastenrath and Greischar

بارندگی استفاده کرد و به این نتیجه رسید که روش های زمین آماری و تخمینگر های کریجینک و کوکریجینگ نتایج برتری را نشان می دهد. 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. هدف اصلی این مقاله پیش آگاهی مقادیر بارش ماهانه با استفاده از شبکه های عصبی مصنوعی در ایستگاه یزد می باشد.

### مشخصات شبکه عصبی

اساس شبکه های عصبی مصنوعی در واقع شبیه سازی و مدل سازی تفکر مغز انسان از طریق سلولهای عصبی می باشد. هر سلول عصبی به عنوان یک واحد پردازشگر عددی عمل می کند. نرونهای شبکه با هم در ارتباط بوده و به صورت موازی کار می کنند. شکل ۱ ساختار شبکه عصبی مصنوعی را نشان می دهد.



شکل شماره (۱) مدل شبکه عصبی برای پیش آگاهی مواد و روشها

شکل دو نشان دهنده موقعیت ایستگاه مورد مطالعه می باشد. در این تحقیق از داده های مجموع ماهانه بارش ایستگاه سینوپتیک یزد طی دوره آماری ۲۰۰۳-۱۹۵۰ استفاده شده است. جهت پیش آگاهی بارش از شبکه عصبی مصنوعی و الگوریتم ژنتیک استفاده شد. تابع تان اکسون<sup>۱</sup> 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 می باشد، فشرده می نماید. ضریب همبستگی، بیان کننده مقداری است که میزان رابطه میان خروجی شبکه با مقدار واقعی را مشخص می نماید. این ضریب از ۱- تا ۱ تغییر می نماید. 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 می نمایند. شبکه ای با قابلیت مناسب جهت پیش-بینی مسائل غیرخطی فراهم می آورد و برای آموزش شبکه عصبی از نرم افزار NeuroSolutions استفاده شده است. سال و تعداد ماهها یک بار به عنوان پارامتر ورودی و داده های مجموع ماهانه بارش به عنوان خروجی در نظر گرفته شدند. به منظور کاهش خطای پیش بینی، سعی و خطا روی پارامترهای شبکه، انجام شد و در نهایت پارامترها به صورت زیر تنظیم شدند. برای آموزش شبکه از مدل پرسپترون چندلایه<sup>۲</sup> استفاده شد که در جدول یک آمده است.

---

<sup>۱</sup> -TanhAxon

<sup>۲</sup> - Multilayer perceptron


جدول شماره (۱) پارامتر های 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
ضریب یادگیری	۰/۱
تابع تحریک یا فشردگی	تان اکسون
تعداد نرون های لایه مخفی	۲
تعداد تکرار	۱۰۰۰
مومنتم	۰/۷

تعداد لایه های مخفی<sup>۱</sup> برای آموزش شبکه برابر با ۲ و از روش آموزش دلتا بار دلتا با ضریب یادگیری ۰/۱ که سرعت تطبیق وزن های میان نرون ها را کنترل می نماید یا به عبارتی در واقع طول گام ها را در هر بار اصلاح پارامتر های شبکه مشخص می کند استفاده شد. تابع تحریک تان اکسون، تعداد نرون های لایه مخفی<sup>۲</sup> برای آموزش شبکه برابر با ۲ و ضریب مومنتوم که یکی از پارامتر های اصلی آموزش است که نسبت تاثیر وزن های قبلی به وزن های جدید را مشخص می نماید برابر با ۰/۷ و تعداد اپاک یک هزار (۱۰۰۰) استفاده شد. یک مدل شبکه عصبی سه لایه ای، شامل 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.

<sup>۱</sup> -Hidden Layer

<sup>۲</sup> -Processing Element




شکل شماره (۲) نقشه موقعیت ایستگاه مورد مطالعه

### یافته های تحقیق

روند مجموع بارش ماهانه در ایستگاه یزد غیر خطی است. بنابراین نمی توان از مدل های آماری که کاربرد آنها برای پیش آگاهی روندهای خطی است استفاده کرد. برای گریز از این مشکل باید از مدل هایی استفاده کرد که توانایی پیش آگاهی روندهای غیرخطی را دارند. یکی از این مدل های پیش آگاهی روندهای غیرخطی شبکه های عصبی مصنوعی می باشد. نتایج آموزش شبکه با نمونه هایی که به صورت تصادفی


قرار گرفته اند نشان می دهد که در این حالت شبکه پس از آموزش نسبت به حالتی که در آن نمونه ها به صورت منظم (منظور از نمونه های منظم، افزایش و یا کاهش منظم پارامترهای نمونه است) انتخاب می شوند نتیجه ی بهتری را ارائه می دهد. شکل ۳ میزان حداقل مجذور متوسط خطاها با آموزش منظم داده ها بدون ترکیب با الگوریتم ژنتیک را نشان می دهد. حداقل مجذور متوسط خطاها ( $MMSE^1$ ) برای شبکه بدون ترکیب با الگوریتم ژنتیک برابر با ۰/۰۲ می باشد. مقایسه داده های ماهانه بارش با میزان پیش آگاهی شده توسط شبکه در حالت قرار گیری منظم داده ها بدون ترکیب با الگوریتم ژنتیک در شکل ۴ نشان داده شده است. همانطور که مشخص است شبکه عصبی مصنوعی تا حدی توانسته است که روند غیر خطی میزان بارش را با توجه به آموزشی که به شبکه داده شده پیدا کند. شکل ۵ پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش آگاهی شده توسط شبکه بدون ترکیب با الگوریتم ژنتیک را نشان می دهد که ضریب بدست آمده برابر با ۰/۵۴ و ضریب تعیین برابر با ۰/۳۰ می باشد.




شکل شماره (۳) میزان حداقل مجذور متوسط خطاها با آموزش منظم داده ها بدون ترکیب با الگوریتم ژنتیک

<sup>1</sup> - Minimum mean square error






شکل شماره (۴) مقایسه مقادیر واقعی ماهانه بارش با میزان بارش پیش آگاهی شده شبکه با آموزش منظم داده ها بدون ترکیب با الگوریتم ژنتیک




شکل شماره (۵) پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش آگاهی شده توسط شبکه در حالت آموزش منظم داده ها بدون ترکیب با الگوریتم ژنتیک


الگوریتم پس انتشار برای مسائل واقعی اغلب بسیار کند عمل می کند. جهت غلبه بر این مشکل از الگوریتم ژنتیک برای انتخاب بهترین وزن های اولیه استفاده می گردد. به عبارتی دیگر با استفاده از شبکه عصبی و ترکیب آن با الگوریتم ژنتیک می توان 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 می باشد. شکل ۶ میزان حداقل مجذور متوسط خطاها را نشان می دهد. حداقل مجذور متوسط خطاها برای شبکه در ترکیب با الگوریتم ژنتیک در حالتی که داده ها بطور منظم قرار گرفته اند، برابر با ۰/۰۱۹ می باشد. شکل ۷ مقایسه مقادیر ماهانه بارش با میزان پیش آگاهی شده توسط شبکه در ترکیب با الگوریتم ژنتیک را در حالتی که داده ها بطور منظم قرار گرفته اند نشان می دهد. 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 پیدا کند. شکل ۸ پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش آگاهی شده توسط شبکه در ترکیب با الگوریتم ژنتیک را نشان می دهد که برابر با ۰/۵۶ و ضریب تبیین برابر با ۰/۳۱ می باشد. می توان گفت که آموزش شبکه عصبی مصنوعی در داده های منظم شده، همراه با الگوریتم ژنتیک برای پیش آگاهی مقادیر ماهانه بارش نسبت به حالتی که در آن شبکه بدون بهره گیری از الگوریتم ژنتیک شبکه آموزش داده می شود، نتیجه بهتری را ارائه دهد.



شکل شماره (۶) میزان حداقل مجذور متوسط خطاها در حالت آموزش منظم داده ها در ترکیب با الگوریتم ژنتیک




شکل شماره (۷) مقایسه مقادیر واقعی ماهانه بارش با میزان بارش پیش آگاهی شده شبکه در ترکیب با الگوریتم ژنتیک




شکل شماره (۸) پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش آگاهی شده توسط شبکه بدون ترکیب با الگوریتم ژنتیک

شکل ۹ میزان حداقل مجذور متوسط خطای شبکه در حالت تصادفی بدون ترکیب با الگوریتم ژنتیک را نشان می دهد. همانطور که ملاحظه می شود حداقل مجذور میانگین خطاها برابر با ۰/۰۲ می باشد. شکل ۱۰ مقایسه مقادیر واقعی ماهانه بارش با مقادیر بارش پیش آگاهی شده شبکه در در حالت تصادفی بدون ترکیب با الگوریتم ژنتیک را نشان می دهد. همانطور که ملاحظه می شود شبکه عصبی در این حالت توانسته است نسبت به حالت آموزش منظم داده ها مدل بهتری را ارائه کند. بطوریکه ضریب همبستگی برابر با ۰/۸۶ و ضریب تعیین برابر با ۰/۷۴ می باشد و این بیانگر افزایش دقت و بهتر شدن برازش مدل در این حالت می باشد (شکل ۱۱). در حالتی که داده هایی که در اختیار شبکه برای آموزش قرار داده می شود رندومی و تصادفی باشد و شبکه را با الگوریتم ژنتیک ترکیب کنیم توانایی افزایش آموزش شبکه و دقت شبکه افزایش خواهد یافت (شکل ۱۲ و ۱۳). بطوریکه ضریب همبستگی در این حالت (تصادفی بودن داده ها برای آموزش و ترکیب با الگوریتم ژنتیک) برابر با ۰/۸۷ و


ضریب تعیین حدود ۰/۷۶ می باشد (شکل ۱۴). این بیانگر افزایش دقت شبکه و بهترین حالت شبکه برای پیش بینی بارش ماهانه یزد می باشد.




شکل شماره (۹) میزان حداقل مجذور متوسط خطای شبکه در حالت تصادفی بدون ترکیب با الگوریتم ژنتیک




شکل شماره (۱۰) مقایسه مقادیر واقعی ماهانه بارش با مقادیر بارش پیش آگاهی شده شبکه در حالت تصادفی بدون ترکیب با الگوریتم ژنتیک




شکل شماره (۱۱) پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش آگاهی شده توسط شبکه در حالت تصادفی بدون ترکیب با الگوریتم ژنتیک



شکل شماره (۱۲) میزان حداقل مجذور متوسط خطای شبکه در حالت تصادفی در ترکیب با الگوریتم ژنتیک



شکل شماره (۱۳) مقایسه مقادیر واقعی ماهانه بارش با مقادیر بارش پیش آگاهی شده شبکه در حالت تصادفی در ترکیب با الگوریتم ژنتیک




شکل شماره (۱۴) پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش آگاهی شده توسط شبکه در حالت تصادفی در ترکیب با الگوریتم ژنتیک

جدول ۲ مقادیر پیش آگاهی شده بارش در سال ۲۰۰۴ و ۲۰۰۵ بدون مقادیر واقعی داده های بارش توسط شبکه، بعد از آموزش شبکه با داده های منظم بدون ترکیب با الگوریتم ژنتیک را نشان می دهد. همانطور که ملاحظه می شود ضریب همبستگی بین مقادیر پیش بینی شده توسط شبکه در حالت قرار گیری منظم داده ها و بدون ترکیب با الگوریتم ژنتیک با داده های واقعی بارش برابر با ۰/۶۵ و ضریب تعیین برابر با ۰/۴۳ می باشد (شکل ۱۵). اگر داده های آموزش داده شده به شبکه در حالت رندومی و تصادفی قرار بگیرند و شبکه را با الگوریتم ژنتیک ترکیب کنیم می توان مدل بهتری را با دقت بالاتر و همچنین سرعت بالاتر برازش کرد. بطوریکه ضریب همبستگی و تعیین به ۰/۷۴ و ۰/۵۵ به ترتیب رسیده است (شکل ۱۶).

جدول شماره (۲) آموزش داده های مرتب شده و بدون ترکیب با الگوریتم ژنتیک

مقادیر پیش بینی شده بارش توسط شبکه در سال ۲۰۰۵	مقادیر پیش بینی شده بارش توسط شبکه در سال ۲۰۰۴	داده های ورودی به شبکه بدون مقادیر واقعی بارش			
۱۳/۲۰	۱۳/۲۴	۱	۲۰۰۵	۱	۲۰۰۴
۱۱/۳۶	۱۱/۴۲	۲	۲۰۰۵	۲	۲۰۰۴
۹/۰۱	۹/۰۸	۳	۲۰۰۵	۳	۲۰۰۴
۶/۳۲	۶/۳۸	۴	۲۰۰۵	۴	۲۰۰۴
۳/۶۴	۳/۶۸	۵	۲۰۰۵	۵	۲۰۰۴
۱/۴۵	۱/۴۸	۶	۲۰۰۵	۶	۲۰۰۴
۰/۱۱	۰/۱۲	۷	۲۰۰۵	۷	۲۰۰۴
-۰/۳۵	-۰/۳۴	۸	۲۰۰۵	۸	۲۰۰۴
۰/۰۰	۰/۰۰	۹	۲۰۰۵	۹	۲۰۰۴
۱/۳۲	۱/۳۳	۱۰	۲۰۰۵	۱۰	۲۰۰۴
۳/۹۸	۴/۰۱	۱۱	۲۰۰۵	۱۱	۲۰۰۴
۸/۱۸	۸/۲۱	۱۲	۲۰۰۵	۱۲	۲۰۰۴






شکل شماره (۱۵) پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش بینی شده توسط شبکه در حالت آموزش داده های منظم در ترکیب با الگوریتم ژنتیک

جدول شماره (۳) آزمون داده های رندومی شده در ترکیب با الگوریتم ژنتیک

مقادیر پیش بینی شده بارش توسط شبکه در سال ۲۰۰۵	مقادیر پیش بینی شده بارش توسط شبکه در سال ۲۰۰۴	داده های ورودی به شبکه بدون مقادیر واقعی بارش			
۱۲/۳۴	۱۲/۵۱	۱	۲۰۰۵	۱	۲۰۰۴
۱۰/۵۷	۱۰/۷۴	۲	۲۰۰۵	۲	۲۰۰۴
۸/۳۶	۸/۵۱	۳	۲۰۰۵	۳	۲۰۰۴
۵/۸۵	۵/۹۴	۴	۲۰۰۵	۴	۲۰۰۴
۳/۳۳	۳/۳۶	۵	۲۰۰۵	۵	۲۰۰۴
۱/۲۷	۱/۲۵	۶	۲۰۰۵	۶	۲۰۰۴
۰/۰۲	-۰/۰۰	۷	۲۰۰۵	۷	۲۰۰۴
-۰/۳۴	-۰/۳۸	۸	۲۰۰۵	۸	۲۰۰۴
۰/۱۴	۰/۰۹	۹	۲۰۰۵	۹	۲۰۰۴
۱/۷۶	۱/۶۹	۱۰	۲۰۰۵	۱۰	۲۰۰۴
۵/۱۴	۵/۰۵	۱۱	۲۰۰۵	۱۱	۲۰۰۴
۱۰/۶۳	۱۰/۵۱	۱۲	۲۰۰۵	۱۲	۲۰۰۴



شکل شماره (۱۵) پراکنش نگار و خط برازش یافته بین مقادیر واقعی ماهانه بارش و پیش بینی شده توسط شبکه در حالت تصادفی در ترکیب با الگوریتم ژنتیک

### نتیجه گیری

بارش یکی از مهمترین داده های ورودی به سیستم های هیدرولوژیکی محسوب می شود. با توجه به اهمیت بارش برای کشور خشکی مانند ایران تا کنون پژوهش های اندکی درباره پیش آگاهی بارش کشور انجام گرفته است. استفاده از شبکه های عصبی مصنوعی برای پیش آگاهی ماهانه بارش ایستگاه یزد نشان داد که روند بارش ایستگاه یزد ساده و خطی نیست، بلکه غیر خطی است که توسط شبکه عصبی مصنوعی قابل محاسبه و پیش آگاهی است. نتایج این مطالعه بعد از آزمون شبکه با لایه های پنهان و با ضرایب یادگیری مختلف نشان داد که استفاده از شبکه های عصبی مصنوعی با یک پرسپترون ۲ لایه پنهان با ضریب یادگیری ۰/۱ و مومنتم ۰/۷ در حالتی که نمونه ها بصورت رندومی قرار گرفته نسبت به حالت قرارگیری منظم آنها مدل نسبتاً بهتری را ارائه می کند بدین معنی که داده های پیش آگاهی شده بارش ماهانه توسط شبکه با چنین ساختار و معماری، بیشتر با واقعیت انطباق دارد. همچنین بعد از آموزش مجدد شبکه و آزمون شبکه با لایه های پنهان و ضرایب مختلف یادگیری در

ترکیب با الگوریتم ژنتیک نشان داد که ترکیب شبکه با ویژگی های مذکور با الگوریتم ژنتیک باعث کاهش خطا و افزایش سرعت محاسبات، شده و مدل بهتری را ارائه می کند. می توان گفت که شبکه عصبی به خوبی رابطه غیر خطی بین مقادیر ماهانه بارش را با توجه به آموزش شبکه با خصوصیات ذکر شده، پیش آگاهی می کند. در مجموع رندومی کردن داده ها برای آموزش شبکه در ترکیب الگوریتم ژنتیک سرعت تحلیل و دقت فرآیند افزایش می یابد به عبارتی دیگر میزان خطا کاهش می یابد.

#### 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. قلی زاده، محمد حسین و محمد دارند، ۱۳۸۹، پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی (مورد: تهران)، مجله پژوهش های جغرافیای طبیعی، ۷۱، ۶۳-۵۱.
۳. شمس، شعله، ۱۳۸۲، کاربرد شبکه های عصبی مصنوعی در تجزیه زمانی بارندگی، پایان نامه کارشناسی ارشد عمران، دانشگاه اصفهان، گروه مهندسی عمران.
۴. میثاقی، فرهاد، ۱۳۸۲، توسعه الگوریتم ترکیبی زمین آمار و شبکه های عصبی مصنوعی بمنظور استخراج توزیع مکانی بارندگی، پایان نامه کارشناسی ارشد کشاورزی، دانشگاه تربیت مدرس، گروه زراعت.
۵. خلیلی، نجمه، ۱۳۸۵، پیش بینی بارش با استفاده از شبکه های عصبی، پایان نامه کارشناسی ارشد مهندسی آب، دانشگاه فردوسی مشهد، دانشکده کشاورزی.

۶. محمد زاده فخر داود، علیرضا، ۱۳۸۰، کاربرد شبکه های عصبی-فازی برگشتی در پیش بینی پارامترهای کلیدی هواشناسی، پایان نامه کارشناسی ارشد، دانشگاه صنعتی خواجه نصیرالدین طوسی.
- Half, A.H., Half, H.M., Azmoodeh, M., 1993, *predicting runoff from rainfall using artificial neural network model*, Proc. Egrg. Hydrological, ASCE, New York, 760-765.
- Hastenrath S. and Greischar L, 1995, *Prediction of the summer rainfall over South Africa*, Journal of Climate, 8, 1511-1518.
- 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, 2, 107-124.
- Smith, J., Eli R.N., 1995, *neural network models of rainfall-runoff process*, Journal of water resource, ASCE, No.6, pp.499-508.
- Michaeldes, S.C., et al., 2001, *Classification of rainfall variability by using artificial neural network*, International journal of climatology, No.21, pp. 1401-1414.
- Namasivayam A and Waldemar A, 2001, *Comparison of the prediction of extremely low birth weight neonatal mortality by regression analysis and by neural networks*, Early Human Development, 65, 123-137.
- Tohma, S. and S. Igata, 1994, *Rainfall estimation from GMS imagery data using neural networks*, Hydraulic engineering software Vol.1, pp121-130.
- Tokar, A. S. and P. A. Santon, 1999, *Rainfall-Runoff modeling using artificial neural networks*, Journal of Hydrologic Engineering, 3, 232-239.
- Trafalis TB., A White, B Santosa, M.B Richman, 2002, *Data mining techniques for improved WSR-88D rainfall estimation*, Computers in Industrial Engineering, 43, 775-786.

Ramirez, M.C.V., Ferreira, N.J., 2006, *Linear and Nonlinear Statistical Downscaling for Rainfall Forecasting over Southeastern Brazil*, weather and forecasting, N0.21, pp. 969-990.

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.

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.

Aksoy, Hafzullah., Ahmad, Dahamsheh., 2009, *Artificial neural network models for forecasting precipitation in Jordan*, Stoch Environ Res Risk Assess, No.23, pp.917-931.

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.

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.

Coulibaly, P., Dibike, Y., 2005, *Downscaling Precipitation and Temperature with Temporal Neural Networks*, journal of hydrology, N0.6, pp. 483-496.

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.

Burian, S.J et al., 2001, *Training artificial neural networks to perform rainfall disaggregation*, journal of Hydrology Engineering, ASCE, No.1, pp.43-51.

Pal, S et al., 2002, *Sort term prediction of atmospheric temperature using neural networks*, MAUSAM, No.53, pp.471-480.

Chaudhari, S., Chattopadhyay, S., 2002, *Multi Layer perceptron model in pattern recognition of surface parameters during per monsoon thunder storm*, MAUSAM, No.53, pp. 417-424.

Applequist, S et al., 2002, *Comparison of Methodologies for Probabilistic Quantitative Precipitation Forecasting*, weather and forecasting, NO.17, pp. 783-799.

Ganguly, A.R., Bras, R.L., 2003, *Distributed Quantitative Precipitation Forecasting Using Information from Radar and Numerical Weather Prediction Models*, journal of hydrometeorology, No.4, pp.1168-1180.