

پیش‌بینی بارش‌های سالانه در ایستگاه‌های سینوپتیک کرمانشاه و نوژه همدان با استفاده از شبکه عصبی مصنوعی

فیروز مجرد^{*} - دانشیار اقلیم‌شناسی، دانشگاه رازی، کرمانشاه

غلامرضا زاهدی - استادیار مهندسی شیمی، دانشگاه رازی، کرمانشاه

حمیدرضا الفت‌میری - کارشناس ارشد اقلیم‌شناسی، دانشگاه رازی، کرمانشاه

وصول: ۱۳۹۲/۰۶/۲۴ پذیرش: ۱۳۹۲/۱۰/۱۸

چکیده

اهمیت پیش‌بینی بارش به عنوان مهم‌ترین عنصر اقلیمی و مبنای تمام برنامه‌ریزی‌ها، به‌ویژه در مناطقی که رژیم‌های بارش تغییرات معنی دار دارد، بر هیچ‌کس پوشیده نیست. استفاده از شبکه‌های عصبی مصنوعی یکی از روش‌های پیش‌بینی است که در سال‌های اخیر توسعه زیادی یافته است. در این پژوهش برای پیش‌بینی بارش‌های سال بعد در دو ایستگاه سینوپتیک کرمانشاه و نوژه همدان از داده‌های برخی از عناصر اقلیمی فصول سرد سال قبل استفاده شد. به این منظور، سری‌های زمانی هفت عنصر اقلیمی شامل میانگین دما، بارش، رطوبت نسبی، نسبت مخلوط، فشار بخار، دمای نقطه شبنم و فشار سطح دریا به عنوان ورودی به شبکه‌های عصبی وارد گردید. خروجی شبکه‌ها، بارش سال بعد در نظر گرفته شد. با توجه به ماهیت غیرخطی عناصر اقلیمی منتخب در این تحقیق، از شبکه‌های پرسپترون چندلایه استفاده شد که از انواع شبکه‌های پیشرو با الگوریتم‌های آموزشی نظراتی و مناسب داده‌های غیرخطی است. برای آموزش شبکه‌ها از دو رده الگوریتم آموزشی دیگر، شامل الگوریتم‌های آموزشی BP و الگوریتم نرم‌السازی اعداد استفاده شد. در نهایت، ترکیب این الگوریتم‌ها منجر به تولید ۷۲۰ شبکه آموزشی در دو ایستگاه شد. نتایج تحقیق نشان داد شبکه عصبی مصنوعی در هر دو ایستگاه به طرز مناسبی مقادیر بارش سالانه را پیش‌بینی می‌کند. بهترین پیش‌بینی در ایستگاه کرمانشاه مربوط به تابع آموزشی `traingd` با الگوریتم نرم‌السازی میانگین و انحراف معیار با خطای آزمایش معادل ۰/۰۱۹۵ در دوره سرد سال (پاییز و زمستان)، و در ایستگاه نوژه همدان مربوط به تابع آموزشی `traingdx` با الگوریتم نرم‌السازی `pca` با خطای آزمایش معادل ۰/۰۰۴۷ در فصل زمستان است.

وازگان کلیدی: بارش، شبکه عصبی مصنوعی، پیش‌بینی، کرمانشاه، نوژه همدان.

مقدمه

پیش‌بینی وقوع بارش، نقطه اطمینانی را در برنامه‌ریزی‌های مختلف، به‌ویژه برنامه‌ریزی‌های کشاورزی به وجود می‌آورد و بر آن اساس، بحران‌های ناشی از وقوع کم‌آبی با حداقل خسارت پشت سر گذاشته می‌شود. یکی از تکنیک‌هایی که در سال‌های اخیر برای پیش‌بینی بارش به کار گرفته می‌شود، استفاده از شبکه‌های عصبی مصنوعی^۱ است. در این تحقیق سعی شده است تا با استفاده از تکنیک شبکه عصبی مصنوعی، مقادیر بارش در دو ایستگاه سینوپتیک کرمانشاه و نوژه همدان که از جمله مناطق نیمه‌خشک غرب ایران هستند، با استفاده از متغیرهای اقلیمی فصول سرد سال قبل، شامل میانگین دما، بارش، رطوبت نسبی، دمای نقطه شبنم، فشار بخار اشیاع، نسبت مخلوط و فشار تبدیل شده به سطح دریا پیش‌بینی شود.

در علوم مربوط به هوا و آب، از شبکه‌های عصبی مصنوعی برای مدل‌سازی بارش - رواناب و پیش‌بینی رواناب و یا سیلان استفاده زیادی شده و اغلب آنها به نتایج مطلوبی منتهی گردیده است که از آن جمله می‌توان به تحقیقات باتاچاریا و سولومیتین^۲ (۲۰۰۰) بر روی رابطه دبی - اشل رودخانه‌ای در هند، ریاض^۳ و همکاران (۲۰۰۴) در مراکش، آیتک^۴ و همکاران (۲۰۰۸) در حوضه رودخانه جونیاتا در ایالت پنسیلوانیای آمریکا، مساح بوانی و مرید (۱۳۸۴) در حوضه زاینده‌رود اصفهان و وو و چاو^۵ (۲۰۱۱) در دو حوضه آبریز کشور چین اشاره کرد. کیسی و کبانر^۶ (۲۰۰۹) نیز با استفاده از شبکه عصبی مصنوعی، رابطه دبی - اشل را در سه ایستگاه رودخانه قیزیلیرماک^۷ در ترکیه مدل‌سازی کردند که نتایج تحقیق آنها حاکی از برتری شبکه عصبی مصنوعی بر روش‌های رگرسیونی^۸ بود. از شبکه عصبی مصنوعی برای بازسازی آمار مفقود آب‌وهوایی ایستگاه‌ها نیز استفاده می‌شود. از جمله می‌توان به کار نکونا و او迪و^۹ (۲۰۱۱) در حوضه رودخانه لوهو^{۱۰} آفریقای جنوبی برای بازسازی داده‌های مفقود بارش اشاره کرد. مطالعاتی نیز برای شبیه‌سازی مقادیر تبخیر و تعرق پتانسیل و دما انجام شده است که به خاطر محدودیت صفحات مقاله از ذکر آنها صرف نظر می‌شود.

مدل‌سازی‌ها و پیش‌بینی‌های بارندگی، سهم مهمی از مطالعات را به خود اختصاص داده و به این دلیل که تغییرپذیری بارندگی بسیار بیشتر از سایر عناصر اقلیمی است، از اهمیت بیشتری برخوردار است. توث^{۱۱} و همکاران (۲۰۰۰) در کوه‌های آپنین^{۱۲} ایتالیا از سه روش شبکه عصبی مصنوعی، مدل‌های آریما^{۱۳} خطی و روش ناپارامتری نزدیک ترین همسایگی^{۱۴} برای پیش‌بینی بارندگی استفاده کردند و به این نتیجه رسیدند که هر سه روش، به خصوص روش شبکه عصبی مصنوعی کارایی لازم را برای پیش‌بینی بارندگی‌های کوتاه‌مدت دارد. بودری و چرمک^{۱۵} (۲۰۰۰) در دو ایستگاه هواشناسی جمهوری چک با استفاده از آمار ماهانه بارش با به

1- Artificial Neural Network (ANN)

2- Bhattacharya & Solomatine

3- Riad

4- Aytac

5- Wu & Chau

6- Kisi & Cobaner

7- Kizilirmak

8- Nkuna & Odiyo

9- Luvuvhu

10- Toth

11- Apennines Mountains

12- Auto Regressive Integrated Moving Average (ARIMA)

13- Non-Parametric Nearest-Neighbours Method

14- Bodri & Cermak

کارگیری شبکه عصبی مصنوعی از نوع نشر عقب‌گرد^۱، بارش ماه بعد و بارش تابستان سال بعد را با دقت خوب خوب پیش‌بینی کردند. لوک^۲ و همکاران (۲۰۰۰) برای پیش‌بینی زمانی و مکانی بارش‌های کوتاه‌مدت در یک یک حوضه آبریز شهری در حومه سیدنی استرالیا از شبکه عصبی مصنوعی استفاده کردند و بیان نمودند هر زمان که تعداد مناسبی از ورودی‌های مکانی به شبکه معرفی می‌شود، دقیق‌ترین نتایج حاصل می‌گردد. کین^۳ کین^۴ و همکاران (۲۰۰۱) در حوضه آبریز رودخانه پاراماتا^۵ در حومه سیدنی استرالیا نشان دادند که شبکه عصبی مصنوعی بهترین روش برای پیش‌بینی بارش است. فیلیپ و جوزف^۶ (۲۰۰۳) طی یک مطالعه تطبیقی بر روی پیش‌بینی و روندیابی بارش نشان دادند که نتایج حاصل از شبکه عصبی مصنوعی از سایر روش‌های متداول دقیق‌تر است.

وو^۷ و همکاران (۲۰۰۵) در آمریکای شمالی ثابت کردند که در روندیابی بارش، شبکه‌های عصبی مصنوعی با روش پرسپترون با توابع انتقال غیرخطی یا شبکه‌های هاپغیلد، از توابع خطی مناسب‌ترند. رامیرز^۸ و همکاران (۲۰۰۵) در پژوهشی در سائوپائولوی برزیل، با استفاده از شبکه عصبی مصنوعی، مقدار بارندگی منطقه را به صورت مناسب پیش‌بینی کردند. سرینیواسلو و جین^۹ (۲۰۰۶) روش‌های مختلف آموزش از نوع پرسپترون چندلایه^{۱۰} شبکه‌های عصبی مصنوعی را مناسب‌ترین الگوریتم برای مدل‌سازی فرایند بارش معرفی نمودند. ناصری و همکاران (۲۰۰۸) طی پژوهشی در غرب سیدنی استرالیا، به صورت تلفیقی با استفاده از الگوریتم‌های ژنتیکی و شبکه عصبی مصنوعی، مقادیر بارش را پیش‌بینی نمودند. وو و همکاران (۲۰۱۰) در چین از شبکه عصبی مصنوعی مدوله^{۱۱} برای پیش‌بینی بارش‌های روزانه استفاده کرده و مزایای آن را نسبت به سایر روش‌ها توضیح داده‌اند. ال-شفیع^{۱۲} و همکاران (۲۰۱۱) در مصر از دو روش شبکه عصبی مصنوعی و مدل‌های رگرسیون چندمتغیره برای پیش‌بینی بارش ماهانه و سالانه استفاده کردند و به این نتیجه رسیدند که با توجه به ماهیت غیرخطی بارش، شبکه‌های عصبی مصنوعی، بهتر از مدل‌های رگرسیونی خطی، بارش را پیش‌بینی می‌کند. موستریس^{۱۳} و همکاران (۲۰۱۱) در یونان برای پیش‌بینی بارش‌های ماهانه حداکثر، حداقل، میانگین و تجمعی در چهار ماه متوالی بعد، از شبکه عصبی مصنوعی استفاده کردند و به این نتیجه رسیدند که شبکه عصبی مصنوعی مقادیر بارش را بهتر از روش‌های کلاسیک آماری پیش‌بینی می‌کند.

در ایران پژوهش‌هایی در زمینه شبیه‌سازی بارش با استفاده از شبکه عصبی مصنوعی صورت گرفته است. بارش‌های استان فارس با استفاده از شبکه عصبی مصنوعی مورد بررسی قرار گرفت و بر توانایی شبکه عصبی در تجزیه زمانی بارش تأکید و بیان گردید که مناسب‌ترین روش برای بازسازی و شبیه‌سازی داده‌های مفقود با استفاده از داده‌های ایستگاه‌های مجاور، استفاده از شبکه عصبی مصنوعی است (شمس، ۱۳۸۴). احمدی (۱۳۸۲) شبکه

1- Back Propagation

2 - Luk

3- Kin

4- Parramatta

5- Philip & Joseph

6- Wu

7- Ramirez

8- Srinivasulu & Jain

9- Multi Layers Perceptron (MLP)

10- Modular Artificial Neural Network

11- El-Shafie1

12- Moustris.

عصبی خودسازمانده کوهون را به عنوان یک ابزار مناسب برای مطالعه تغییرات اقلیمی میان و بلندمدت و طبقه‌بندی تغییرات درونی داده‌های اقلیمی و رژیم بارش مورد استفاده قرار داد. ناصری (۱۳۸۲) با استفاده از شبکه عصبی مصنوعی بارش‌های استان فارس را پیش‌بینی و با استفاده از الگوریتم ژنتیک، نتایج پیش‌بینی خود را بهینه‌سازی نمود. اصغری مقدم و همکاران (۱۳۸۷) با استفاده از این شبکه، بارش دشت تبریز را مدل‌سازی و با به کارگیری الگوریتم‌های این شبکه، با کمترین خطای مدل مورد نظر خویش را تولید نمودند.

کمبل^۱ (۲۰۰۵) عقیده دارد شبکه‌های عصبی مصنوعی عمدتاً برای پیش‌بینی کوتاه‌مدت عناصر جوی کاربرد دارند؛ اما استفاده از آنها در مدل‌سازی روند تغییرات بارش و یافتن همبستگی بین متغیرهای اقلیمی نتایج بسیار دقیقی داشته است و به همین علت در مدل‌سازی عناصر اقلیمی بهویژه در شبیه‌سازی تغییرات عناصر اقلیمی کاربرد وسیعی پیدا کرده است. با توجه به پیشینه تحقیق ارائه شده می‌توان به این نتیجه رسید که استفاده از شبکه‌های عصبی مصنوعی برای مدل‌سازی عناصر اقلیمی بهویژه بارش، کاربرد وسیعی در مطالعات یافته است.

مبانی نظری شبکه عصبی مصنوعی

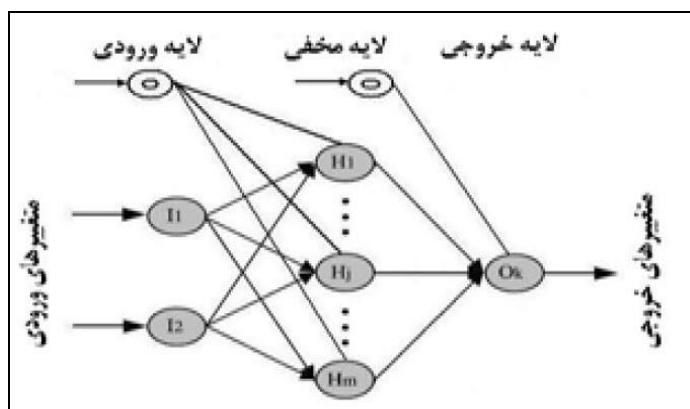
شبکه‌های عصبی سعی دارند تا با استفاده از اجزائی که شبیه سلول‌های عصبی زیستی رفتار می‌کنند، ماشین‌هایی ایجاد نمایند که مانند مغز انسان عمل کند. عمل شبکه عصبی این است که وقتی یک الگوی ورودی به آن ارائه شود، یک الگوی خروجی تولید نماید (پکتین، ۱۳۸۷: ۱۴-۱۳). شبکه عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری و با استفاده از پردازشگرهای ساده به نام نرون تلاش می‌کند با شناخت روابط ذاتی میان داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. در شبکه‌های عصبی مصنوعی سعی بر این است که ساختاری مشابه ساختار بیولوژیکی مغز انسان و شبکه بدن طراحی شود تا همانند آن، قدرت یادگیری، تعمیمدهی و تصمیم‌گیری داشته باشد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده را از لایه ورودی پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرآیندی است که در نهایت به یادگیری منجر می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف مقادیر پیش‌بینی شده و محاسبه شده در حد قبل قبولی باشد. با دست‌یابی به این شرایط، فرآیند یادگیری محقق شده است. این وزن‌ها، حافظه و دانش شبکه را بیان می‌کنند. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌هایی متناسب با مجموعه جدید داده به کار رود (سبزی پرور و بیات ورکشی، ۱۳۸۹).

شبکه‌های عصبی مصنوعی را می‌توان از دو جنبه طبقه‌بندی کرد: الف: از نظر برگشت‌پذیری ب: از نظر یادگیری. شبکه‌ها از نظر برگشت‌پذیری، خود به دو گروه عمدۀ تقسیم می‌شوند: ۱- شبکه‌های پیشرو: در یک شبکه پیشرو، گره‌های پردازشگر در لایه‌های مخفی قرار گرفته‌اند و هر شبکه می‌تواند چندین لایه مخفی و هر لایه مخفی چندین گره داشته باشد. در این شبکه‌ها اطلاعات از ورودی به طرف خروجی حرکت می‌کند. ۲- شبکه‌های برگشتی: در این شبکه‌ها داده‌ها بین گره‌ها در دو جهت جریان می‌یابند: از ورودی به خروجی و کاملاً بر عکس. این شبکه‌ها از خروجی‌ها به عنوان ورودی‌های جدید استفاده می‌کنند؛ بنابراین به داده‌ها اجازه برگشت به ورودی را می‌دهند (اصغری مقدم و همکاران، ۱۳۸۷).

شبکه‌های عصبی مصنوعی از نظر یادگیری خود به دو گروه زیر تقسیم می‌شوند: الف: یادگیری با ناظر ب: یادگیری بدون ناظر. در یادگیری با ناظر فرض بر این است که در هر مرحله تکرار از الگوریتم یادگیری، جواب

مطلوب سیستم یادگیرنده، از قبل آماده است و پاسخ بهینه پاسخی است که شبکه عصبی برای ورودی مفروض باید به آن برسد (منهاج، ۱۳۹۳: ۱۲۴). در یادگیری بدون ناظر تنها دسته‌ای از داده‌های ورودی برای شبکه، تهیه و وزن‌های ارتباطی به طور اتوماتیک و بدون وجود خروجی‌های تعلیم‌دهنده تعديل می‌شوند (اصغری مقدم و همکاران، ۱۳۸۷).

شبکه عصبی پرسپترون چندلایه یا MLP مجموعه‌ای از نرون‌ها است که در لایه مختلفی پشت سر هم قرار گرفته‌اند. مقادیر ورودی پس از ضرب در وزن‌های موجود در گذرگاه‌های بین لایه‌ها به نرون بعدی رسیده و در آنجا با هم جمع می‌شوند و پس از عبور از عبور از تابع شبکه مربوطه خروجی نرون‌ها را تشکیل می‌دهند. در پایان، خروجی به دست آمده با خروجی موردنظر مقایسه شده و خطای به دست آمده برای اصلاح وزن‌های شبکه به کار می‌رود. این امر اصطلاحاً آموزش شبکه عصبی نامیده می‌شود.^۱



شکل ۱. ساختمان شبکه عصبی MLP (منهاج، ۱۳۹۳)

به منظور انجام محاسبات مربوط به نرون‌ها معمولاً از تابع سیگموید به شرح رابطه‌های ۱ و ۲ استفاده می‌شود.

$$f(x) = \frac{1}{1+e^{-x}} \quad \text{رابطه ۱}$$

$$a_i = I_i - T_{1i} \quad \text{رابطه ۲}$$

که در آن I_i ورودی به نرون شماره ۱ از لایه ورودی و T_{1i} آستانه داخلی برای آن نرون است و a_i خروجی از نرون لایه ورودی است. با توجه به دریافت خروجی از لایه ورودی می‌توان خروجی از لایه مخفی را رابطه‌های ۳ و ۴ محاسبه کرد:

$$b_j = f\left(\sum_{i=1}^m v_{ij} a_i - T_{2j}\right) \quad \text{رابطه ۳}$$

$$c_k = f\left(\sum_{j=1}^n w_{jk} b_j - T_{3k}\right) \quad \text{رابطه ۴}$$

که در آن f تابع سیگموید، $v_{i,j}$ فاکتور وزن لایه مخفی و T_{2j} آستانه داخلی نرون‌های لایه مخفی است. با توجه به

خروجی‌های لایه مخفی می‌توان برونداد لایه خروجی را محاسبه کرد. مقادیر C_k خروجی شبکه است. در مرحله‌ای که شبکه آماده اجرا شده باشد (بعد از مرحله آموزش و فراخوانی) مقادیر C_k مقادیری هستند که شبکه تخمین می‌زند. خروجی‌های شبکه توسط اندازه‌گیری خطاب و تنظیم فاکتورهای وزنی، به گونه‌ای تنظیم می‌شوند که مقادیر C_k تخمین مطلوبی از خروجی‌های سیستم باشند.

امروزه الگوریتم‌های مختلفی برای آموزش شبکه‌ها وجود دارد. نشر عقب‌گرد از معروف‌ترین و مؤثرترین انواع الگوریتم‌ها است. در این روش، مقدار محدود خطاب در مرحله خروجی اندازه‌گیری می‌شود. الگوریتم نشر عقب‌گرد با انجام یک تکنیک کاهش گرادیان، مقدار خطاب را کمینه می‌کند تا شبکه به خروجی مطلوب دست یابد. در این الگوریتم سعی شده است تا سرعت آموزش شبکه افزایش یابد. کمینه کردن خطاب در این روش، با تنظیم مقادیر فاکتور وزنی و آستانه داخلی صورت می‌گیرد. به منظور انجام نشر عقب‌گرد، باید پس از در نظر گرفتن مقدار حدسی برای فاکتورهای وزنی، سه مرحله زیر اجرا شود:

- ۱- خروجی از شبکه ارزیابی گردد (عبور رو به جلو)^۱
- ۲- خطاب محاسبه شود (ارزیابی خطاب)^۲
- ۳- فاکتورهای وزنی تنظیم شود.

این مراحل تا وقتی که مقدار خطاب به اندازه کمینه خود برسد، ادامه خواهد یافت.

الگوریتم‌های BP

دو روش مختلف برای این الگوریتم پیاده‌سازی شده است:

الف: روش گام به گام

ب: روش دسته‌ای

در روش گام به گام، وزن‌ها و بایاس‌ها بعد از اعمال هر ورودی، به روز می‌شوند؛ در حالی که در روش دسته‌ای، پس از اعمال تمام ورودی‌ها، عملیات به روزرسانی انجام می‌شود. در این تحقیق از روش آموزش دسته‌ای استفاده شده است.

برای انجام تحقیق حاضر، از نرم‌افزار متلب استفاده شده است. الگوریتم‌های آموزشی در این نرم‌افزار شامل پنج دسته الگوریتم آموزشی با دوازده تابع آموزشی است که در زیر به طور مختصر به آنها اشاره می‌شود (کیا، ۱۳۸۷-۹۲):

- ۱- الگوریتم‌های آموزش دسته‌ای کاهش شبیب^۳ شامل تابع آموزشی: traingd, traingdm, traingda, traingdx
- ۲- الگوریتم پس‌انتشار ارجاعی^۴ با تابع آموزشی: trainrp
- ۳- الگوریتم‌های شبیب توأم^۵ شامل: traincfg, traincgb, traincgp, trainscg
- ۴- الگوریتم‌های شبکه‌نیوتون^۶ شامل تابع آموزشی: trainbfg, trainoss
- ۵- الگوریتم آموزشی LM^۷ با تابع آموزشی: trainlm

1- Forward Pass

2- Error or Objective Criterion

3- Batch Gradient Descent Algorithms

4- Resilient Back Propagation Algorithms

5- Conjugate Gradient Algorithms

6- Quasi-Newton Algorithms

7- Levenberg- Margwardt Algorithms

مواد و روش‌ها

تحقیق حاضر برای پیش‌بینی بارش‌های دو ایستگاه سینوپتیک کرمانشاه با طول جغرافیایی $47^{\circ} 0' 9''$ شرقی، عرض جغرافیایی $34^{\circ} 21'$ شمالی و ارتفاع $1318/6$ متر، و ایستگاه سینوپتیک نوژه همدان با طول جغرافیایی $48^{\circ} 43'$ شرقی، عرض جغرافیایی $35^{\circ} 12'$ شمالی و ارتفاع $1679/7$ متر صورت پذیرفته است. هر دو ایستگاه در داخل رشته‌کوه‌های زاگرس در غرب ایران قرار دارند. زاگرس مجموعه‌ای از پستی و بلندی‌های منظم و ویژه‌ای در ایران است که از جنوب گسله‌های کردستان جنوبی در غرب تا تنگه هرمز در جنوب، با امتداد شمال غرب به جنوب شرق به صورت دیواری کشیده شده است (محمدی و عظیمی، ۱۳۷۶: ۲۸). منطقه زاگرس با وجود ارتفاع زیاد، به علت دور بودن از توده‌هواهای شمالی، نسبتاً گرم است؛ ولی به هر حال دماهای زیر صفر در آن نسبتاً فراوان است. سرمای ناحیه تقریباً در تمام زمستان تداوم دارد. وضعیت حرارتی ناحیه در تابستان همگن‌تر از زمستان است. در ناحیه کوهستانی به سبب اینکه زمستان‌ها بسیار سرد و تابستان‌ها نسبتاً گرم است، دامنه دما زیاد است. این ناحیه به علت ماهیت کوهستانی خود، تقریباً مرتبط است و عوامل صعود، خواه به صورت بیرونی یا محلی، در سرتاسر آن وجود دارد. در دوره سرد سال، به علت حاکمیت بادهای غربی و نزدیکی به منبع رطوبتی دریای مدیترانه، بارندگی بیشتر است؛ اما در دوره گرم سال، نفوذ پرفشار آزور باعث کاهش بارندگی می‌شود؛ گرچه بارندگی تابستانه نیز به طور پراکنده یافت می‌شود. هوای ناحیه در زمستان‌ها مرتبط است. در زمستان در اکثر مناطق کوهستانی به علت پایین آمدن درجه حرارت، ظرفیت بخار آب در هوا کم شده، در نتیجه درصد نم نسبی بالا می‌رود. متوسط روزهای بارندگی ناحیه ۵۰ روز در سال و ضریب تغییرپذیری مکانی آن 32° درصد است. ویژگی عمده بارندگی ماهانه ناحیه کوهستانی بی ثباتی آن از سالی به سال دیگر است (علیجانی، ۱۳۸۱: ۱۸۳-۱۷۳).

برای رسیدن به هدف پژوهش، داده‌های هفت عنصر اقلیمی بارش، دما، رطوبت نسبی، نسبت مخلوط، دمای نقطه شبنم، فشار بخار و فشار سطح دریا مربوط به دو ایستگاه در دوره ۲۰۰۸-۱۹۵۵ از تاریخی سازمان هواشناسی کشور^۱ اخذ گردید. با توجه به اینکه برای آموزش شبکه‌ها در هر ایستگاه، از سه دوره زمانی فصل پاییز، زمستان و دوره سرد سال (مجموع پاییز و زمستان) استفاده شد و با در نظر گرفتن هفت عنصر اقلیمی مورد بررسی در این تحقیق، مجموعاً ۲۱ سری زمانی به عنوان ورودی به شبکه‌های عصبی معرفی گردید. از این سری‌های پایه برای تولید داده‌های آموزشی (دوسوم داده‌ها) و داده‌های آزمایشی (یکسوم داده‌ها) استفاده شد. بارش سالانه سال بعد نیز به عنوان خروجی به شبکه تعریف گردید. برای هر دوره زمانی در هر ایستگاه، جدولی از داده‌های ورودی و خروجی در صفحه گسترش‌دهنده^۲ تولید شد. سپس نمودارهای هر متغیر برای هر مرحله با استفاده از این نرم‌افزار تولید گردید تا نقاط آموزشی و آزمایشی بر اساس شکستگی این نمودارها تشخیص داده و از هم تفکیک شود. در مرحله بعد داده‌ها به نرم‌افزار متلب وارد شد.

در این پژوهش، برای برآورد بارش، از شبکه‌های MLP استفاده شد. به منظور دستیابی به مناسب‌ترین روش آموزش برای شبکه‌ها، با استفاده از الگوریتم‌های ۱۲ گانه، که قبلاً به آنها اشاره شد، چندین روش شناخته شده برای آموزش شبکه‌های عصبی به کار گرفته شد تا از روشی که کمترین خطای را دارد، استفاده شود. مبنای انتخاب بهترین شبکه، مقایسه مقدار خطا^۳ و خطای آزمایش^۳ در مرحله آزمون شبکه‌ها بوده است. فرمول‌های

1- www.irimo.ir

2- Maxerror

3- Testerror

مورد استفاده برای محاسبه مقادیر خطای رابطه‌های ۵ تا ۷ بودند:

$$\text{error} = \text{abs}(((y - t) / t) * 100) \quad \text{رابطه ۵}$$

$$\text{maxerror} = \text{max}(\text{error}) \quad \text{رابطه ۶}$$

$$\text{testerror} = \text{mse}(y - t) \quad \text{رابطه ۷}$$

که در آن y مقدار پیش‌بینی شده و t مقدار واقعی بارش است. طبیعتاً هرچه مقدار این خطای کمتر باشد، مطلوب‌تر است. در مورد خطای حداکثر همان‌طور که از فرمول ۴ مشخص است، بزرگترین عدد مربوط به خطای محاسبه شده، یکی از ملاک‌های تعیین بهترین شبکه است؛ اما شاخص اصلی بر اساس رابطه ۷ مقدار خطای آزمایش است که از مقدار میانگین مربع خطای σ^2 حاصل تغیریق مقادیر پیش‌بینی شده از مقادیر واقعی به دست می‌آید. در این مورد نیز مقدار کمتر متنظر است. در این تحقیق هرچه مقدار خطای آزمایش از 0.05 پایین‌تر بود، به عنوان شبکه بهتر انتخاب شد.

برای آموزش داده‌ها از سه روش مورد توصیه نرم‌افزار متلب، یعنی پیش‌پردازش، میانگین و انحراف‌معیار و تحلیل اجزاء اصلی (pca از ۹٪ تا ۲٪) استفاده شد. آموزش شبکه‌های عصبی در صورت اعمال یک‌سری پیش‌پردازش بر روی ورودی‌ها و هدف‌ها می‌تواند کارایی بهتری داشته باشد. بدین ترتیب که قبل از اجرای آموزش بهتر است تا ورودی‌ها و هدف را مقیاس‌بندی کنیم تا آنها در یک محدوده خاص قرار گیرند.تابع premnmx می‌تواند برای مقیاس‌گذاری داده‌ها استفاده شود. این تابع، داده‌ها را در محدوده -1 و 1 قرار می‌دهد. یک راه دیگر برای مقیاس‌بندی ورودی‌ها و هدف‌ها، استفاده از میانگین و انحراف‌معیار است. این رویه در تابع prestd پیاده‌سازی می‌شود. این تابع، ورودی‌ها و هدف‌ها را نرمال‌سازی می‌کند؛ به نحوی که میانگین آنها صفر و انحراف‌معیار آنها واحد شود. در برخی موقع ابعاد بردار ورودی بسیار بزرگ است؛ اما اجزاء این بردارها تا حد زیادی مرتبط هستند. در این موارد، کاهش ابعاد بردار ورودی مفید واقع می‌شود. رویه مؤثر برای انجام این کار تحلیل اجزاء اصلی است. این تکنیک سه تأثیر دارد:

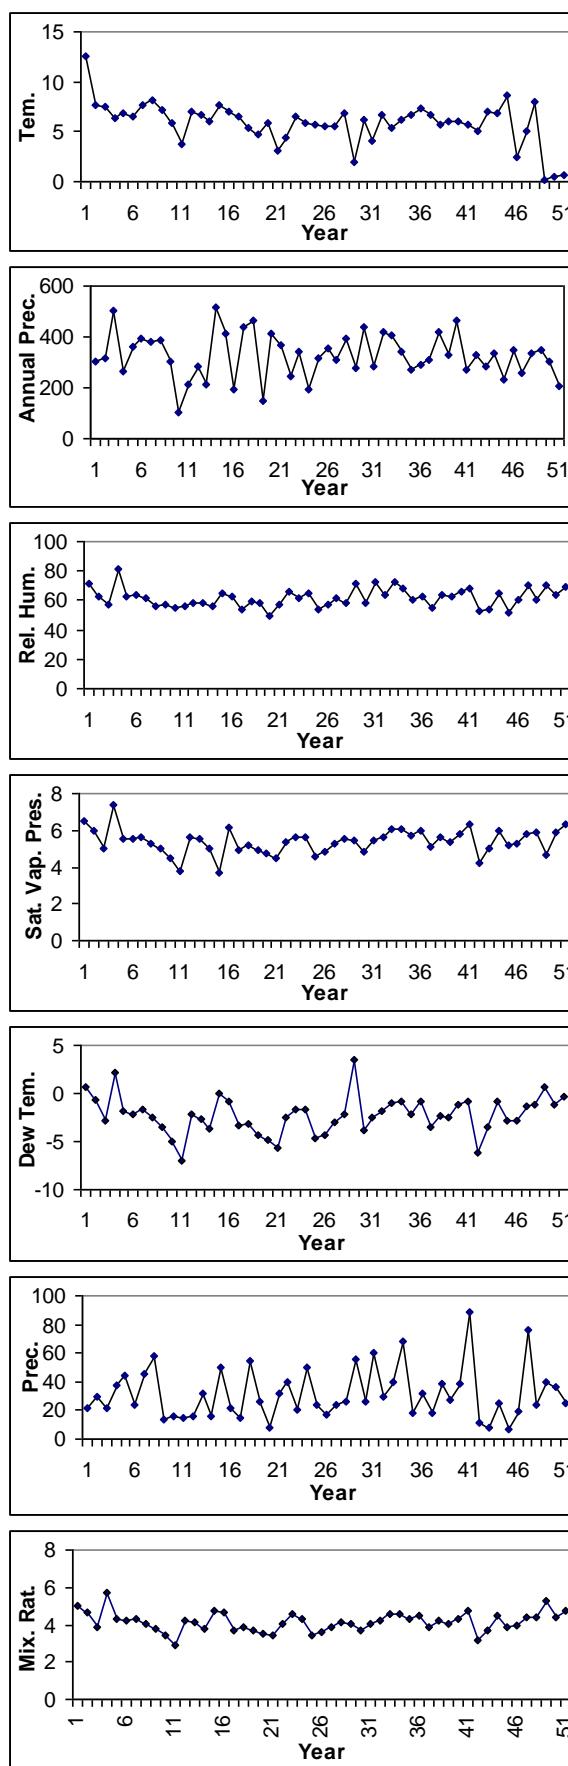
الف: این تابع، اجزاء بردار ورودی را متعامد می‌کند.

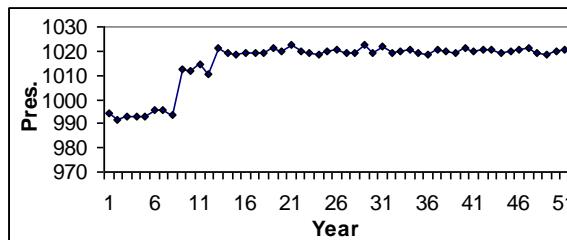
ب: اجزاء متعامد، نتیجه را مرتب می‌کند. بنابراین بیشترین تغییر، در اول می‌آید.

ج: اجزائی را که کمترین نقش در تغییر مجموعه داده‌ها دارند، حذف می‌کند. با توجه به اینکه بردار ورودی اولیه، از انحراف‌معیار استفاده می‌کند؛ بنابراین داده‌های نرمال‌شده، دارای میانگین صفر و انحراف‌معیار واحد خواهند بود. در این روش، از تابع prepca از ۹٪ تا ۲٪ استفاده شده است. استفاده از تابع prepca بدين معنی است که اين تابع، آن اجزائی از کل اجزاء اصلی را که در تغییر مجموعه داده‌ها، کمتر از ۲٪ نقش دارند، حذف می‌کند (کیا، ۱۱۲-۱۳۸۷).

نتایج و بحث

بر اساس روالی که در بخش مواد و روش‌ها گفته شد، مقادیر متغیرهای اقلیمی در دو فصل پاییز و زمستان و نیز دوره سرد سال (پاییز و زمستان) به عنوان ورودی، و بارش سالانه سال بعد به عنوان خروجی به نرم‌افزار متلب تعریف گردید. نمونه‌هایی از نمودارهای سری زمانی پایه برای فصل پاییز در ایستگاه نوژه همدان در شکل ۲ آورده شده است.

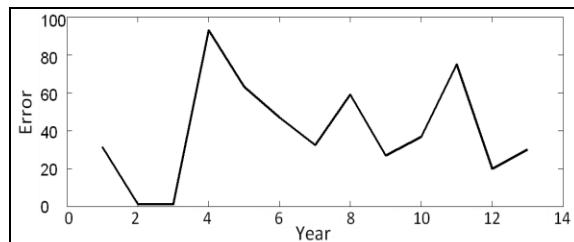




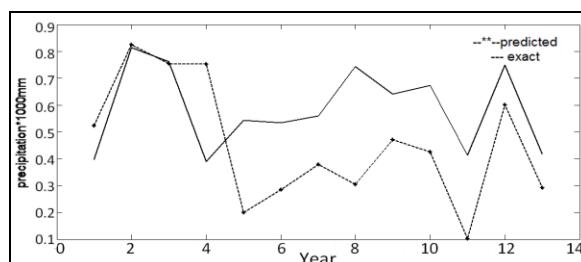
شکل ۲. نمونه هایی از سری های زمانی پایه برای فصل پاییز ایستگاه نوژه همدان (نمودار بارش سال بعد: خروجی، بقیه نمودارها: ورودی) برای آموزش شبکه های عصبی مصنوعی از ۱۲ تابع آموزشی و ۱۰ روش آموزشی نرم ال سازی استفاده گردید که با در نظر گرفتن دو ایستگاه و ۳ دوره زمانی (پاییز، زمستان و دوره سرد) مجموعاً ۷۲۰ شبکه به عنوان بهترین شبکه های عصبی برای هر دو ایستگاه تولید شد. نمونه هایی از مقادیر خطای به دست آمده از آموزش شبکه ها بر اساس فرمول های ۳ تا ۵ با سه روش یاد شده (پیش پردازش، میانگین و انحراف معیار و تحلیل اجزاء اصلی pca از ۲ تا ۹٪) برای فصل پاییز ایستگاه کرمانشاه در جداول ۱ تا ۳ آورده شده است. نمودارهای نمونه مقادیر خطای آزمایش برای آزمون ۱۳ سال مربوط به بهترین شبکه و نیز نمودارهای مقایسه مقادیر برآورده شده و مشاهداتی همان شبکه در شکل های ۳ تا ۸ نشان داده شده است.

جدول ۱. مقادیر خطای روش نرم ال سازی پیش پردازش برای فصل پاییز ایستگاه کرمانشاه

ردیف	تابع آموزشی	Mse	تابع آموزشی	خطای حد اکثر به درصد	خطای آزمایش
۱	Traingd	۰/۰۳۶۶۹۶۸	۰/۰۵۹۶	۹۲/۷۶۰۴	
۲	Traingdm	۰/۰۴۵۶۹۶۴	۰/۳۶۲۲	۲۲۲/۹۸۸۴	
۳	Traingda	۰/۰۲۰۷۹۴۹	۰/۰۹۳۰	۱۷۳/۱۰۴۹	
۴	Traingdx	۰/۰۱۴۹۶۲۲	۰/۰۸۶۱	۱۳۴/۶۹۸۹	
۵	Trainrp	۹/۸۸۲۵۸e-۱۰	۰/۰۶۰۱	۱۱۲/۳۲۹۷	
۶	Traincfg	۸/۷۵۷۵۵e-۸	۰/۱۹۴۹	۱۹/۷۹۴۸	
۷	Traincgp	۱/۴۳۴۱۷e-۷	۰/۱۵۱۹	۱۲۱/۶۲۹۴	
۸	Traincgb	۸/۳۸۶۹۲e-۹	۰/۴۵۲۲	۳۵۸/۷۲۴۹	
۹	Trainscg	۷/۸۵۱۶۴e-۱۰	۰/۰۹۸۳	۱۶۸/۱۴۱۲	
۱۰	Trainbfg	۸/۷۹۷۱۷e-۱۱	۰/۱۴۷۶	۲۳۰/۶۹۱۳	
۱۱	Trainoss	۲/۲۷۱۱۸e-۸	۰/۱۲۷۸	۱۵۲/۶۵۴۷	
۱۲	Trainlm	۴/۶۳۱۳e-۱۸	۰/۱۷۶۸	۱۳۹/۶۵۷۴	



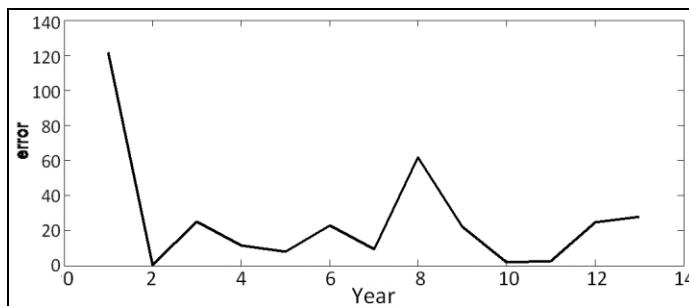
شکل ۳. نمودار مقادیر خطای داده های آزمایش برای تابع traingd در روش نرم ال سازی پیش پردازش برای فصل پاییز کرمانشاه



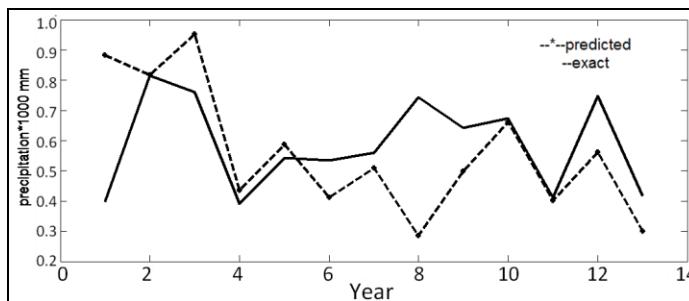
شکل ۴. نمودار مقایسه مقادیر مشاهداتی و برآورده شده با تابع traingd برای فصل پاییز ایستگاه کرمانشاه

جدول ۲. مقادیر خطای روش نرمال‌سازی میانگین و انحراف‌معیار برای فصل پاییز ایستگاه کرمانشاه

ردیف	تابع آموزشی	Mse آموزش	خطای آزمایش	خطای حداکثر به درصد
۱	Traingd	۰/۰۱۷۷۲۴	۰/۰۵۱۳	۹۶/۷۳۵۲
۲	Traingdm	۶/۳۹۵۶۷e-۵	۰/۰۷۴۰	۸۹/۰۳۷۹
۳	Traingda	۰/۰۰۶۸۵۶۱۳	۰/۰۶۴۴	۱۱۰/۷۷۶۵
۴	Traingdx	۹/۹۷۳۶e-۶	۰/۰۶۶۰	۱۰۲/۵۲۶۸
۵	Trainrp	۹/۹۱۶۳۸e-۱۰	۰/۰۴۸۹	۸۵/۵۲۰۴
۶	Traincfg	۱/۱۴۶۹۸e-۸	۰/۰۸۷۶	۱۱۸/۳۴۴۰
۷	Traincgp	۲/۵۱۰۹۱e-۸	۰/۱۰۳۳	۱۲۰/۸۱۲۲
۸	Traincgb	۶/۵۲۲۸۷e-۹	۰/۰۹۰۰	۱۱۶/۳۵۵۸
۹	Trainscg	۵/۰۵۱۱e-۱۰	۰/۰۴۴۰	۱۲۱/۸۰۷۶
۱۰	Trainbfg	۲/۰۴۳۵۴e-۱۰	۰/۰۷۸۸	۱۳۳/۴۳۸۷
۱۱	Trainoss	۸/۳۷۲۸۸e-۱۰	۰/۰۵۲۷	۷۴/۰۷۶۶
۱۲	Trainlm	۲/۲۶۹۹۲e-۱۸	۰/۰۷۶۰	۱۱۵/۰۹۸۸



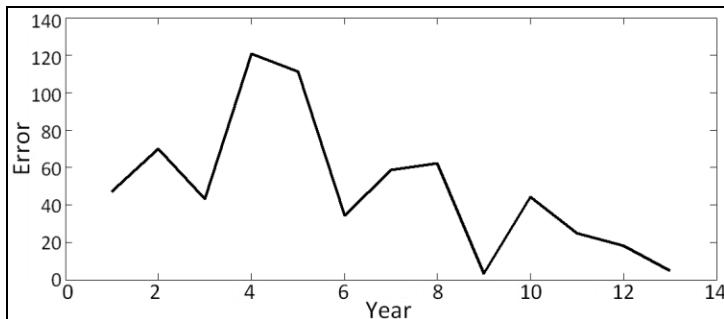
شکل ۵. نمودار مقادیر خطای داده‌های آزمایش برای تابع trainscg در روش نرمال‌سازی میانگین و انحراف‌معیار برای فصل پاییز ایستگاه کرمانشاه



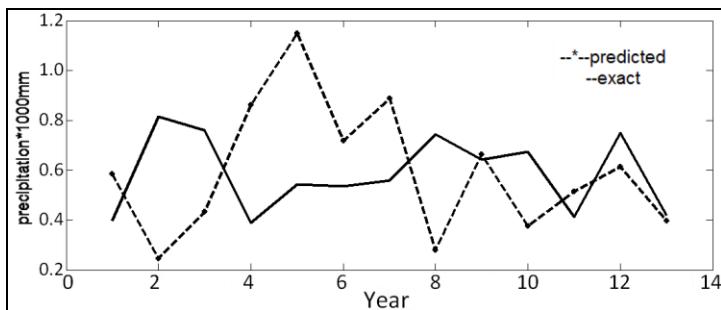
شکل ۶. نمودار مقایسه مقادیر مشاهداتی و برآورده شده با تابع trainscg برای فصل پاییز ایستگاه کرمانشاه

جدول ۳. مقادیر خطای روش نرمال‌سازی تحلیل اجزاء اصلی pca۰/۰۶ برای فصل پاییز ایستگاه کرمانشاه

ردیف	تابع آموزشی	Mse آموزش	خطای آزمایش	خطای حداکثر به درصد
۱	Traingd	۰/۰۰۰۱۹۶۲۳۴	۰/۰۵۶۰	۷۱/۵۱۲۰
۲	Traingdm	۰/۰۰۰۹۸۸۹۸۶	۰/۰۳۱۱	۵۹/۹۵۰۳
۳	Traingda	۰/۰۰۰۵۳۲۸۶۵	۰/۰۵۲۲	۱۱۴/۷۹۷۴
۴	Traingdx	۲/۰۱۴۶e-۷	۰/۰۶۶۲	۸۷/۹۴۵۸
۵	Trainrp	۹/۹۲۳۵۷e-۱۰	۰/۰۴۰۷	۹۴/۴۱۳۸
۶	Traincfg	۱/۵۲۰۷۵e-۸	۰/۱۷۳۸	۱۱۵/۹۴۷۴
۷	Traincgp	۳/۵۷۶۸۵e-۸	۰/۰۷۵۹	۱۲۵/۱۳۸۱
۸	Traincgb	۵/۲۵۴۹e-۸	۰/۱۶۱۱	۱۸۶/۶۵۵۲
۹	Trainscg	۶/۷۳۱۳۳e-۱۰	۰/۱۱۶۶	۱۴۴/۸۱۵۰
۱۰	Trainbfg	۱/۰۰۹۷e-۱۰	۰/۰۷۷۱	۱۱۰/۲۹۰۷
۱۱	Trainoss	۹/۹۲۱۸۱e-۱۰	۰/۰۵۳۷	۷۴/۸۶۰۷
۱۲	Trainlm	۲/۰۹۸۵۷e-۱۸	۰/۰۴۹۶	۹۶/۲۸۷۶



شکل ۷. نمودار مقادیر خطای داده‌های آزمایش برای تابع `traingda` در روش نرمال‌سازی 0.02 برای فصل پاییز کرمانشاه



شکل ۸. نمودار مقایسه مقادیر مشاهداتی و برآورده شده با تابع `traingda` برای فصل پاییز ایستگاه کرمانشاه

بر اساس کمترین مقادیر خطای شبکه‌ها در سه دوره زمانی (پاییز، زمستان و دوره سرد) برای هر کدام از دو ایستگاه انتخاب و در جدول ۶ ذکر گردید. با توجه به ارقام این جدول، در ایستگاه سینوپتیک کرمانشاه بهترین نتیجه مربوط به تابع آموزشی `trainlm` با مقدار خطای 0.0195 در دوره سرد سال، و در ایستگاه سینوپتیک نوژه بهترین نتیجه مربوط به روش تحلیل اجزا اصلی با 0.006 تابع آموزشی `pca` و تابع آموزشی `traingdx` با مقدار خطای 0.0047 در فصل زمستان بوده است. در مجموع با در نظر گرفتن مقدار خطاهای، برآوردها در ایستگاه نوژه بهتر از ایستگاه کرمانشاه بوده است.

جدول ۴. شبکه‌های انتخاب شده در ایستگاه‌ها در سه دوره زمانی بر اساس کمترین مقادیر خطای

ایستگاه	دوره زمانی	خطای آزمایش	خطای حداقل به درصد	تابع آموزشی	روش نرمال‌سازی
کرمانشاه	فصل پاییز	0.0311	$59/9503$	<code>traingdm</code>	0.006
	فصل زمستان	0.0334	$54/0.784$	<code>Traingd</code>	0.004
	دوره سرد سال (پاییز و زمستان)	0.0195	$74/8196$	<code>Trainlm</code>	<code>Std</code>
	فصل پاییز	0.0066	$20.1/6381$	<code>trainrp</code>	<code>pre</code>
نوژه همدان	فصل زمستان	0.0047	$39/5863$	<code>traingdx</code>	0.006
	دوره سرد سال (پاییز و زمستان)	0.0146	$49/2114$	<code>traingdx</code>	<code>Std</code>

بررسی نتایج دو ایستگاه در جدول ۴ نشان می‌دهد که در هر سه دوره زمانی، شبکه‌ها نتایج قابل قبولی را ارائه داده و خطای آزمایشی آنها از خطای آزمایشی معيار که 0.005 در نظر گرفته شده بود، کمتر است. ضمناً به دلیل آنکه نتایج پیش‌بینی دوره سرد سال در ایستگاه کرمانشاه و نیز فصل زمستان در ایستگاه نوژه دارای خطای آزمایشی کمتری است، قابلیت اطمینان بیشتری را دارد.

با توجه به ارقام جدول ۴ می‌توان برخی نتیجه‌گیری‌های دیگر را نیز انجام داد. از جمله اینکه چهار شبکه از شش شبکه برتر معرفی شده، مربوط به الگوریتم‌های آموزشی دسته‌ای کاهش شیب یعنی traingd، traingdx و traingdm هستند. همچنین در خصوص الگوریتم‌های نرمال‌سازی، سه شبکه از شش شبکه برتر معرفی شده، با الگوریتم نرمال‌سازی تحلیل اجزاء اصلی آموزش دیده‌اند و از بین هشت الگوریتم نرمال‌سازی به کار گرفته شده، الگوریتم pca دارای بیشترین حضور بوده و نسبت به سایر الگوریتم‌ها از پایین‌ترین خطای آزمایشی (۰/۰۰۴۷) برخوردار است که نشان‌دهنده مناسب‌تر بودن این الگوریتم نسبت به سایر الگوریتم‌های نرمال‌سازی است.

نتیجه‌گیری

با توجه به ارقام نمونه خطای برآورد در جداول ۱ تا ۳، مقایسه مقادیر بارش مشاهداتی و برآورده شده با شبکه در شکل‌های ۴، ۶ و ۸ و نیز ارقام نهایی خطا در جدول ۴ می‌توان نتیجه‌گیری کرد که با استفاده از هر سه شبکه عصبی مصنوعی منتخب در این پژوهش می‌توان مقادیر بارش‌های سالانه سال بعد را دو ایستگاه در سه دوره زمانی (پاییز، زمستان و دوره سرد) به طرز مناسب پیش‌بینی کرد. برای این کار با استفاده از اطلاعات هفت عنصر اقلیمی معرفی‌شده به شبکه‌های عصبی برتر برای هر ایستگاه را تا پایان دوره سرد سال جمع‌آوری و به عنوان ورودی به شبکه‌ها معرفی و از شبکه، خروجی مورد نظر را که بارش سالانه سال بعد است، دریافت نمود.

این پژوهش در مراحل انجام خود با مشکلات و محدودیت‌هایی همراه بود که ذیلاً به مهم‌ترین آنها اشاره می‌شود:

۱. تغییرپذیری بیش از حد بارش و در نتیجه مشکل بودن پیش‌بینی؛
 ۲. زمان بر بودن تحقیق به دلیل استفاده از روش آزمون و خطا در مرحله آموزش شبکه‌ها؛
- با توجه به محدودیت‌های ذکر شده و ضرورت‌های پژوهشی در زمینه مطالعاتی این تحقیق، برای تحقیقات آتی پیشنهادات زیر ارائه می‌گردد:
۱. روش به کار گرفته شده در این تحقیق در تعداد بیشتری از ایستگاه‌های دو استان کرمانشاه و همدان و یا سایر ایستگاه‌های منطقه‌ی غرب و کل کشور آزمایش شود. به نظر می‌رسد در ایستگاه‌های دارای نوسانات کمتر بارش میانگین سالانه، این روش کارایی بیشتری داشته باشد.
 ۲. نتایج روش شبکه عصبی مصنوعی با روش‌های دیگر مانند روش‌های ژنتیک یا روش‌های آماری از قبیل معادلات رگرسیون چندگانه مقایسه گردد تا بتوان درباره کارایی آن بهتر اظهار نظر نمود.
 ۳. پیش‌بینی بارش‌های سالانه سال بعد با استفاده از تعداد بیشتری از عناصر اقلیمی انجام شود.

منابع

- احمدی، اسماعیل (۱۳۸۲) طبقه‌بندی تغییرات بارش بوشهر با استفاده از شبکه عصبی مصنوعی مبتنی بر مدل خودسازمانده کوهون، پایان‌نامه کارشناسی ارشد اقلیم‌شناسی، دانشگاه تربیت‌معلم، دانشکده علوم انسانی.
- اصغری مقدم، اصغر؛ نورانی، وحید؛ ندیری، عطا... (۱۳۸۷) مدل سازی بارش دشت تبریز با استفاده از شبکه عصبی مصنوعی، دانش کشاورزی، ۱۸، صص. ۱-۱۵.
- پکتین، فیل (۱۳۸۷) شبکه‌های عصبی، ترجمه میرمجتبی میرصالحی و حسین تقی‌زاده کاخکی، انتشارات دانشگاه فردوسی مشهد، مشهد.
- سبزی‌پور، علی‌اکبر؛ بیات ورکشی، مریم (۱۳۸۹) ارزیابی دقیق روش‌های شبکه عصبی مصنوعی و عصبی - فازی در شبیه‌سازی تابش کل خورشیدی، پژوهش فیزیک ایران، ۱۰ (۴)، صص. ۳۴۷-۳۵۷.

شمس، شعله (۱۳۸۴) کاربرد شبکه عصبی مصنوعی در تجزیه زمانی بارندگی، پایان نامه کارشناسی ارشد، مهندسی عمران، دانشگاه صنعتی اصفهان.

علیجانی، بهلول (۱۳۸۱) آب و هوای ایران، چاپ پنجم، انتشارات دانشگاه پیام نور، تهران.

کیا، مصطفی (۱۳۸۷) شبکه های عصبی در MATLAB، انتشارات کیان رایانه سیز، تهران.

محمودی، فرج‌الله؛ عظیمی، ناصر (۱۳۷۶) جغرافیای ایران، شرکت چاپ و نشر کتاب‌های درسی ایران، تهران.

مساح بوانی، علیرضا؛ مرید، سعید (۱۳۸۴) اثرات تغییر اقلیم بر جریان رودخانه زاینده‌رود اصفهان، علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، ۹ (۴)، صص. ۱۷-۲۸.

منهاج، محمدباقر (۱۳۹۳) مبانی شبکه های عصبی هوش محاسباتی، جلد اول، چاپ نهم، انتشارات دانشگاه امیرکبیر، تهران.

ناصری، محمدحسن (۱۳۸۲) پیش‌بینی بارندگی در دامنه زمان و مکان با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک، پایان نامه کارشناسی ارشد گروه مهندسی عمران آب، دانشکده فنی، دانشگاه صنعتی اصفهان.

Aytek, A., Asce, M., Alp, M. (2008) An Application of Artificial Intelligence for Rainfall–Runoff Modeling, **Earth System Science**, 117, pp. 145-155.

Bhattacharya, B., Solomatine, D. P. (2000) Application of Artificial Neural Network in Stage-Discharge Relationship, **Proc. 4th International Conference on Hydroinformatics**, Iowa City, USA, July 2000.

Bodri, L., Cermak, V. (2000) Prediction of Extreme Precipitation Using a Neural Network: Application to Summer Flood Occurrence in Moravia, **Advances in Engineering Software**, 31, pp. 311-321.

Campbell, E. P. (2005) Statistical Modeling in Nonlinear Systems **Climate**, 18, pp. 3388-3399.

El-Shafie1, A. H., El-Shafie, A., El Mazoghi, H. G., Shehata, A. Taha, M. R., (2011) Artificial Neural Network Technique for Rainfall Forecasting Applied to Alexandria, Egypt, **International Journal of the Physical Sciences** 6 (6), pp. 1306-1316.

Kin, C., Luk, J., sharma, A. (2001) An Application of Artificial Neural Networks for Rainfall Forecasting, **Mathematical and Computer Modeling**, 33, pp. 699-883.

Kisi, O., Cobaner, M., (2009) Modeling River Stage-Discharge Relationship Using Different Neural Network Computing Techniques, **Clean**, 37 (2), pp. 160-169.

Luk, K. C., Ball, J. E., Sharma, A. (2000) A Study of Optimal Model Lag and Spatial Inputs to Artificial Neural Network for Rainfall Forecasting, **Hydrology**, 227, pp. 56–65.

Moustris, K. P., Larissi, I. K., Nastos, P. T., Paliatsos, A. G. (2011) Precipitation forecast Using Artificial Neural Networks in Specific Regions of Greece, **Water Resour Manage**, 25, pp. 1979-1993.

Nasseri, M., Asghari, K., Abedini, M. J. (2008) Optimized Scenario for Rainfall Forecasting Using Genetic Algorithm Coupled with Artificial Neural Network, **Expert Systems with Application**, 35, pp. 1415-1421.

Nkuna, T.R., Odiyo, J. O. (2011) Filling of Missing Rainfall Data in Luvuhu River Catchment Using Artificial Neural Networks, **Physics and Chemistry of the Earth**, 36, pp. 830-835.

Philip, N. S., Joseph, K. B. (2003) A Neural Network Tool For Analyzing Trends in Rainfall, **Computer & Geosciences**, 29, pp. 215-223.

Ramirez, M. C. V., Velho, H. F. C., Ferreira, N. J. (2005) Artificial Neural Network Technique for Rainfall Forecasting Applied to the Sao Paulo Region, **Hydrology**, 301, pp. 146-162.

Riad, S., Mania, J., Bouchaou, L., Najjar, Y. (2004) Rainfall –Runoff Model Using an Artificial Neural Network Approach, **Mathematical and Computer Modeling**, 40, pp. 839-846.

Srinivasulu, S., Jain, A. (2006) A Comparative Analysis of Training Methods for Artificial Neural Network Rainfall – Runoff Models, **Applied Soft Computing**, 6, pp. 295-306.

Toth, E., Brath, A., Montanari, A. (2000) Comparison of Short-Term Rainfall Predication Models for Real-Time Flood Forecasting, **Hydrology**, 239, pp. 132-147.

- Wu, A., Hsieh, W. W., Shabbar, A. (2005) The Nonlinear Patterns of North American Winter Temperature and Precipitation Associated with ENSO, **Climate**, 18, pp. 1736-1752.
- Wu, C. L., Chau, K. W. (2011) Rainfall–Runoff Modeling Using Artificial Neural Network Coupled with Singular Spectrum Analysis, **Hydrology**, 399, pp. 394-409.
- Wu, C. L., Chau, K.W., Fan, C. (2010) Prediction of Rainfall Time Series Using Modular Artificial Neural Networks Coupled with Data-Preprocessing Techniques, **Hydrology**, 389, pp. 146-167.

