

## مدل سازی بارش ماهانه با استفاده از شبکه سیستم عصبی مطالعه‌ی موردی: شهرستان خرم آباد

ایران صالحوند<sup>۱</sup>، امیر گندم کار<sup>۱</sup>، ابراهیم فتاحی<sup>۲\*</sup>

<sup>۱</sup> گروه جغرافیا، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران  
<sup>۲</sup> عضو هیات علمی پژوهشکده هواشناسی ایران، تهران، ایران

تاریخ دریافت: ۱۳۹۷/۰۵/۱۱ ، تاریخ پذیرش: ۱۳۹۷/۱۱/۱۵

### چکیده

مدل سازی بارش ماهانه برای یک ناحیه از اهمیت ویژه‌ای برخوردار است. در این پژوهش به منظور مدل سازی بارش خرم آباد از داده‌های بارش ماهانه‌ی ایستگاه همدید خرم آباد در بازه آماری (۲۰۱۴-۱۹۵۱) به مدت ۶۴ سال بعنوان متغیر وابسته و شاخص‌های اقلیمی و عناصر اقلیمی بعنوان متغیر مستقل استفاده شده است. برای استفاده از مهم ترین عناصر اقلیمی موثر بر منطقه مورد مطالعه از تحلیل عاملی استفاده شد و برای تشخیص مهم ترین شاخص اقلیمی موثر بر متغیر وابسته از روش‌های تحلیل رگرسیونی گام به گام استفاده گردید. نتایج پژوهش بعد از آزمون شبکه با لایه‌های پنهان و با ضرایب یادگیری مختلف و سعی و خطای زیاد آشکار ساخت که با شاخص‌های اقلیمی با مدل‌های ۶ گانه با ضریب همبستگی به ترتیب ۶۳٪، ۷۴٪، ۷۶٪، ۸۸٪، ۸۶٪، ۸۹٪ با عناصر اقلیمی عامل اول موثر بر اقلیم منطقه که بیش از ۵۰ درصد داده‌ها را تبیین می‌کند با ضریب همبستگی ۹۰ درصد و با عوامل بارشی ۹۹٪ و عوامل دمایی که بار منفی دارند با ضریب همبستگی ۹۸٫۸٪، عامل دوم موثر بر اقلیم منطقه عامل (بادی) ۷۶٪، عامل سوم (دمایی) ۹۱٪، می‌توان به مدل سازی بارش پرداخت و بارش را مدل سازی نمود.

کلمات کلیدی: تحلیل عاملی، خرم آباد، رگرسیون، شاخص‌های اقلیمی، شبکه عصبی پرسپترون، شیب خط.

بارش باران یکی از مهم ترین پدیده های جوی است که بر زندگی بشر اثر می گذارد (رحیمی نسب و عامریان، ۱۳۹۷). بارش نه تنها در زندگی بشر، بلکه در زندگی گیاهان و جانوران از ارزش حیاتی برخوردار بوده و جزء جدا نشدنی طبیعت محسوب می گردد (صلاحی و عالی جهان، ۱۳۹۲). پیش بینی بارش برای کشورهای در حال توسعه که اقتصادشان مبتنی بر کشاورزی است، بسیار اهمیت دارد. به طور مشخص، اقلیم و بارش از پدیده های غیرخطی بزرگ در طبیعت به شمار می آیند که به اثر پروانه ای مشهور شده اند (فلاح قاهره و خوشحال، ۱۳۸۸). مدل های مفهومی و آماری زیادی برای پیش آگاهی و پیش بینی متغیرهای اقلیمی مورد استفاده قرار گرفته است. بطور کلی پیش بینی ها را می توان در چهار دسته، پیش بینی های خیلی کوتاه مدت، کوتاه مدت، میان مدت و بلندمدت تقسیم کرد. پیش بینی های میان مدت و درازمدت برای اعمال مدیریت های صحیح منابع آب و کشاورزی دارای اهمیت بسیار زیادی است نخستین و بدیهی ترین فایده حاصل از پیش آگاهی های با افق های زمانی میان مدت و بلندمدت، کاهش در خسارات ناشی از بارش یا عدم بارش است (فتاحی و همکاران، ۱۳۸۷). در رابطه با بارش و پیش بینی آن با سیستم عصبی کارهای زیر انجام گرفته است: مقصود و همکاران (۲۰۰۴) در مطالعه ای به نام مجموعه ای از شبکه های عصبی برای پیش بینی وضع هوا از گروه شبکه های عصبی مصنوعی و پارادایم های یادگیری برای پیش بینی آب و هوا در جنوب ساسکاچوان، کانادا استفاده کردند. آنها از روش های شبکه های چند لایه پرسپترون، شبکه مکرر عصبی المن، شبکه شعاعی تابع پایه استفاده نمودند که داده های مورد استفاده در این تحقیق، دما، سرعت باد و رطوبت نسبی بود. نتایج تجربی نشان داد که شبکه مکرر عصبی المن و شبکه شعاعی تابع دقیق نبود لذا از شبکه ی چند لایه پرسپترون، برای پیش بینی آب و هوا با اطمینان بیشتری استفاده شد. میسلان<sup>۱</sup> و

همکاران (۲۰۱۵) در تحقیقی با عنوان پیش بینی بارش ماهانه با شبکه سیستم عصبی مطالعه موردی ایستگاه تنگارونگ کالیمانتان شرقی اندونزی با روش شبکه عصبی مصنوعی پرسپترون چند لایه، الگوریتم شبکه عصبی پس انتشار خطا<sup>۲</sup> انجام گردید. داده های ورودی همان داده های بارش بودند نتایج تجربی نشان داد که معماری ۱-۲۰-۵۰-۲ با تکرار ۱۰۰۰ بار با خطای ۰/۰۰۰۹۶ بهترین نتیجه را داشت. بنابراین الگوریتم شبکه عصبی پس انتشار خطا بهترین الگو جهت پیش بینی بارش کالیمانتان شرقی است. نایاک<sup>۳</sup> و همکاران (۲۰۱۷) در تحقیقی با عنوان بررسی پیش بینی بارش با استفاده از شبکه عصبی مصنوعی، به بررسی تحقیقات پیش بینی بارش در ۲۵ سال پرداختند و روش آنها بررسی مقایسه ای روشهای معماری مختلف بود. در این بررسی مشخص شد که بسیاری از محققان برای پیش بینی بارش شبکه انتشار را انتخاب نموده اند زیرا نتایج قابل توجهی داشته است. نتیجه این که شبکه عصبی مصنوعی برتری خاصی نسبت به سایر روش ها داشته است. کاشیوا<sup>۴</sup> و همکاران (۲۰۱۷) در مقاله ای با عنوان پیش بینی بارش با استفاده از داده های هواشناسی در اینترنت با سیستم عصبی مبتنی بر شبکه های محلی مطالعه موردی اطلاعات آرژانس هواشناسی ژاپن، به پیش بینی بارش ژاپن از طریق اینترنت با استفاده از سیستم عصبی مصنوعی با روش های پرسپترون چند لایه، الگوریتم ترکیبی پس انتشار، بهینه سازی تصادفی و شبکه شعاعی تابع پایه پرداختند. نتیجه ی تجربی این تحقیق پیش بینی بارش در ساعت ۱۲ تا ۲۴ در ماتسویاما، ساپورو و ناها نیم میلیمتر با واقعیت تفاوت داشت در صورتیکه مرکز پیش بینی ژاپن در ساعت ۱۷ تا ۲۴ در ۱۶ نقطه ۱ میلیمتر تفاوت را نشان داد. بارش های سنگین تابستانه در توکیو با استفاده از داده های بارش گذشته در سالهای بین ۲۰۱۱ و ۲۰۱۲ نیز به خوبی پیش بینی شد. بنابراین روش پیش بینی پرسپترون چند لایه برای خطر بارش های تندری بسیار

2 BPNN

3 Nayak

4 Kashiwao

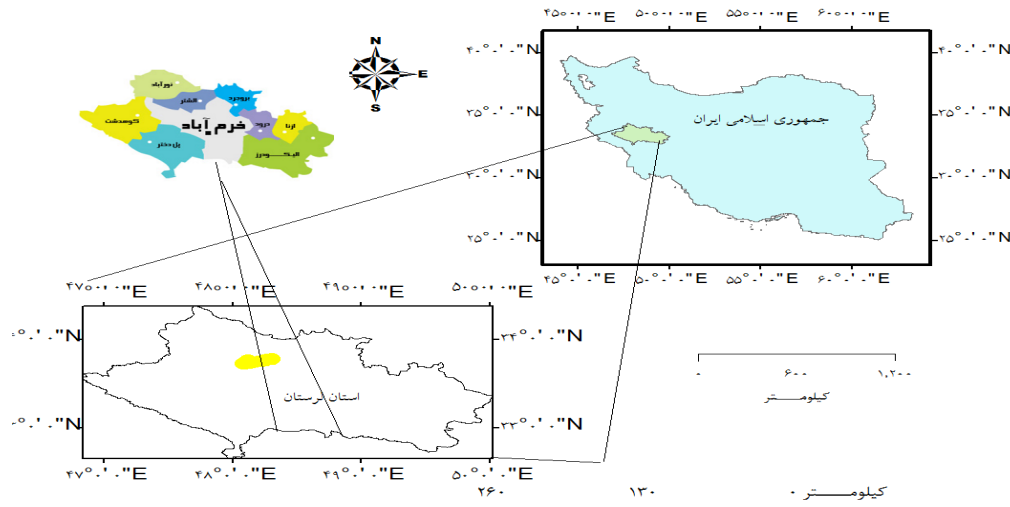
1 Mislan

در نظر گرفته شد. نتایج این تحقیق بعد از آزمون شبکه با لایه های پنهان و با ضرایب یادگیری مختلف 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. ضریب همبستگی بین مقادیر واقعی ماهانه بارش و پیش بینی شده توسط شبکه برابر ۰/۹۱ و ضریب تبیین برابر ۰/۸۳ بود. عرفانیان و همکاران (۱۳۹۲) در تحقیقی به نام پیش بینی بارش و دمای متوسط ماهانه با استفاده از الگوهای پیوند از دور به کمک شبکه های عصبی مصنوعی (مطالعه موردی: ایستگاه سینوپتیک مشهد) از الگوهای بزرگ مقیاس اقلیم (پیوند از دور) مؤثر بر پارامترهای دمای متوسط و بارش ماهانه ایستگاه سینوپتیک مشهد در دوره آماری ۵۵ ساله ۱۹۵۶-۲۰۱۰ م. به صورت هم زمان و با تأخیرات زمانی بهره گرفتند و اثر پیش پردازش داده های ورودی شبکه عصبی به چهار روش (رگرسیون، رگرسیون با داده های محدود، تست گاما و بدون پیش پردازش) مورد بررسی قرار دادند. روش شبکه عصبی پرسپترون چند لایه در این تحقیق معرفی شد. ایلدرومی و همکاران (۱۳۹۲) در تحقیقی به نام برآورد بارش به کمک شبکه عصبی مصنوعی با داده های هواشناسی غیر بارشی در سه منطقه شیراز، مشهد و کرمان با استفاده از روش شبکه مصنوعی در ایستگاه های شیراز، مشهد و کرمان به پیش بینی بارش پرداختند. ابتدا نمای هرست برای سه ایستگاه محاسبه شد، بالا بودن این نما ۸۰ تا ۹۲ درصد نشان داد که بارش هر سه ایستگاه قابلیت پیش بینی دارد. نوع پارامترهای ورودی بر اساس آزمون همبستگی پیرسون از بین داده های غیر بارشی، ترکیبی از داده های دمایی و رطوبتی شامل دمای حداقل، حداکثر و میانگین به درجه سلسیوس، میانگین، حداقل و حداکثر رطوبت نسبی به درصد، سرعت باد و دمای نقطه ی شبنم بودند. اعتبار سنجی مدل های بارش نشان داد دارای بهترین عملکرد بوده اند. در مجموع نتایج نشان دادند که استفاده از روش شبکه عصبی با در نظر گرفتن اطلاعات دمایی-رطوبتی، نتایج مناسبی برای توصیف فرآیند و ترکیب آن ها در

کارآمد است. خلیلی و همکاران (۱۳۸۷) در تحقیقی با عنوان پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی مطالعه ی موردی ایستگاه سینوپتیک مشهد از دو روش برای پیش بینی استفاده نمودند، مدل جی اس ۵۳۱ و جی اس ۷۴۱ به منظور پیش بینی ماهانه ی بارش از بارش ۵ ماه قبل استفاده شد، نتایج نشان داد که استفاده زیاد ورودی می تواند موجب خروج شبکه از حالت تعمیم شود. فقط با آزمون و خطای فراوان می توان بهترین مدل را برای پیش بینی انتخاب نمود که هر دو مدل قابل قبول و میزان همبستگی و خطا به ترتیب در مدل جی اس ۵۳۱، ۹۰ و ۱/۱۱ و در مدل جی اس ۷۴۱، ۹۲ و ۰/۰۰ بدست آمد. فلاح قالهیری و خوشحال (۱۳۸۸) در تحقیقی با عنوان پیش بینی بارش بهاره استان خراسان رضوی براساس سیگنال های بزرگ مقیاس اقلیمی، با استفاده از شبکه های عصبی مصنوعی از روش سیستم عصبی و تحلیل همبستگی جهت پیش بینی بارش استفاده نمودند در ضمن پیش بینی بارش فصلی خراسان بزرگ بر اساس الگوهای همدید با استفاده از تئوری مجموعه های فازی، تأثیر پذیری بارندگی منطقه شمال شرق ایران از الگوهای همدید واقع در خلیج فارس و دریای عمان، دریای سیاه، دریای خزر، دریای مدیترانه، دریای شمال، دریای آدریاتیک، دریای سرخ، اقیانوس هند، اقیانوس اطلس و سبیری را بررسی کرده و نتیجه گرفته اند که با مدل پیشنهادی در ۷۰ درصد از سال ها می توان بارش را با دقت قابل قبولی پیش بینی کرد. نتایج نهایی نشان داد که شبکه های عصبی مصنوعی در تمامی سال ها می تواند بارش را با دقت قابل قبولی پیش بینی نماید. قلی زاده و دارند (۱۳۸۸) در تحقیقی با عنوان پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی (مورد : تهران) در این تحقیق از داده های بارش ماهانه طی دوره آماری ۵۳ سال (۱۹۵۱-۲۰۰۳) و شبکه های عصبی مصنوعی به عنوان یک روش غیر خطی جهت پیش بینی بارش استفاده شد. بارش ماهانه دو سال ۲۰۰۴ و ۲۰۰۵ بعنوان ورودی و پیش بینی بارش بعنوان خروجی

5 GS531

6 GS741



شکل ۱. موقعیت جغرافیایی منطقه ی مورد مطالعه

پرجمعیات ایران و مرکز استان لرستان است. جمعیات خرم آباد طبق سرشماری سال ۱۳۹۰ مرکز آمار ایران، ۳۴۸'۲۱۶ نفر بوده است. شهر در ارتفاع ۱۱۴۷'۸ متری از سطح دریا و در میان دره های زاگرس قرار دارد. فاصله خرم آباد تا تهران ۴۹۰ کیلومتر است و به دلیل قرار گرفتن در مسیر تهران - جنوب دارای اهمیت ارتباطی و راهبردی است. این شهر دارای آب و هوایی مدیترانه ای معتدل و نیمه مرطوب است و دارای میزان بارندگی بسیار، خصوصاً در بهار می باشد. وجود منابع آب های زیر زمینی و چشمه های درون شهر از نکات قابل توجه در جغرافیای شهر خرم آباد است (شکل ۱).

برای انجام این پژوهش از داده های ماهانه بارش ایستگاه همدید خرم آباد جهت بررسی ارتباط شاخص های اقلیمی، طی بازه زمانی (۲۰۱۴-۱۹۶۱) که از واحد خدمات ماشینی سازمان هواشناسی اخذ گردیده استفاده شده است در ادامه از داده های نمایانگر شاخص های اقلیمی استفاده شد که شامل:

۱- نوسان اطلس شمالی: که با NAO نمایش داده میشود. تغییرات اقلیمی بزرگ مقیاس نیم کره شمالی است و بر اساس اختلاف فشار جوی در سطح آب اقیانوسی در محدوده ای بین ایستگاه ایسلند و ایستگاه

پیش بینی به دست می دهند. ضریب همبستگی از ۷۷ تا ۹۴ درصد بود. هدف از این تحقیق مدلسازی بارش شهرستان خرم آباد بود. جهت اینکار ابتدا به شناسایی کلیه ی عناصر و عوامل موثر بر بارش با تحلیل همبستگی پرداخته شد، سپس عوامل موثر بر بارش را با تحلیل عاملی بررسی نموده و مهمترین عامل ها بعنوان الگوی ورودی به سیستم شبکه ی عصبی و رگرسیون استفاده شد، زیرا با شناخت عوامل و عناصر موثر بر بارش می توان ورودی سیستم شبکه ی سیستم عصبی و رگرسیون را تعیین کرد و به پیش بینی بارش با روش رگرسیون و شبکه سیستم عصبی پرسپترون پرداخت. علت استفاده از شبکه ی عصبی مصنوعی پرسپترون نیز به این دلیل بود که به عنوان یک مدل تشخیص روندهای 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 همچنین کارایی آن در تحقیقات گذشته به اثبات رسیده است.

### مواد و روش ها

#### منطقه مورد مطالعه

خرم آباد بزرگترین شهر لر نشین، بیست و سومین شهر

۸- شاخص حالت نصف النهاری اقیانوس اطلس<sup>۱۰</sup>: برای اولین بار در سال ۱۹۷۰ بصورت علمی به عنوان تغییرات بارش باران در شمال شرقی آمریکای جنوبی ارائه شد (نامیاس<sup>۱۱</sup>، ۱۹۷۲؛ هاستنرات<sup>۱۲</sup>، ۱۹۷۶). مشخص شد که کشاورزان ساکن در شمال شرق برزیل در منطقه ای که نوردست<sup>۱۳</sup> نامیده می شود وابستگی زیادی به تغییرات فصل بارش برای محصولات کشاورزی خود دارند. فصل بارانی نوردست در بهار شمالی (مارس تا ماه مه) همزمان با موقعیت منطقه گرمسیری همگرایی<sup>۱۴</sup> رخ می دهد. این فرضیه بیشتر با استفاده از آزمون های مختلف آماری نشان دادن یک رابطه غیر قابل انکار بین دمای سطح دریا<sup>۱۵</sup>، ناهنجاری های فشار سطح دریا<sup>۱۶</sup> و موقعیت منطقه گرمسیری همگرایی همراه است، که با ناهنجاری بارش مورد حمایت قرار می گیرد. طی مثبت بودن فاز AMM، گرمتر از حد نرمال شدن سطح دریا و ضعیف تر از نرمال شدن بادهای عمودی را موجب می شود که سبب افزایش طوفان های گرمسیری در اقیانوس اطلس می شود.

تمامی شاخص های مذکور برای دوره ۱۹۶۱ تا ۲۰۱۴ از طریق آرشیو الکترونیکی سازمان هواشناسی استرالیا و مرکز ملی هواشناسی ایالات متحده آمریکا<sup>۱۷</sup> تهیه و مورد استفاده قرار گرفته است. چون هدف اولیه ی این تحقیق درک روابط بین بارش و شاخص های اقلیمی است، به دلیل این که بارش و داده های دیگر آب و هوا به طیف وسیعی از مدل های وابسته به زمان و مقیاس فضایی نیاز دارند (صالحوند، ۲۰۱۶) لذا از تحلیل عاملی استفاده شد. شناسایی عوامل و عناصر اصلی سازنده اقلیم هر منطقه ای می تواند در تعیین پتانسیل های اقلیمی آن منطقه بسیار موثر واقع شود. برای انجام تحلیل عاملی مراحل زیر طی شد: قبل از تحلیل عاملی باید از کفایت نمونه گیری اطمینان حاصل شود برای این کار از شاخص

10 Atlantic Meridional Mode

11 Namias

12 Hastenrath

13 Nordeste

14 Inter Tropical Convergence Zone (ITCZ)

15 Sea surface temperature (SST)

16 sea level Pressure (SLP)

17 National Current Weather

آزور محاسبه می گردد (جلیلی، ۱۳۹۰).

۲- شاخص نوسان جنوبی<sup>۸</sup>: نوسان جنوبی که به عنوان نمایه پدیده انسو در نظر گرفته می شود. در سال ۱۸۹۷ شناسایی شد و تحقیقات واکر وجود آن را ثابت کرد. زمان بالای شاخص نوسان جنوبی یعنی تشکیل پرفشار موجب تشدید جریان واکر و ظهور لانینا و زمان شاخص پایین نوسان جنوبی یعنی تشکیل کم فشار موجب وقوع پدیده ی النینو می شود (قویدل رحیمی، ۱۳۸۴).

۳- شاخص انتقالی انسو<sup>۹</sup>: که به اختصار TNI نشان داده می شود، این شاخص از اختلاف ناهنجاری های استاندارد شده دمای سطح دریا در منطقه نینو ۲+۱ و منطقه نینو ۴ بدست می آید. مقادیر مثبت آن نشانگر فاز گرم النینو و مقادیر منفی آن بیانگر فاز سرد لانینا است (یاراحمدی، ۱۳۸۶).

۴- نینو ۳/۴: از جمله شاخص هایی است که برای مشخص کردن فازهای انسو استفاده می شود. این شاخص از اندازه گیری دمای سطح اقیانوس در منطقه نینو ۳/۴ بدست می آید. منطقه نینو ۳/۴ از ۱۷۰ درجه غربی تا ۱۲۰ درجه شرقی و از ۵ درجه جنوبی تا ۵ درجه شمالی را شامل می شود (یاراحمدی، ۱۳۸۶).

۵- شاخص نینو ۱+۲: شاخص مذکور از سنجه های اصلی پدیده انسو می باشد و بیانگر نوسان های دمای سطح دریا در شرقی ترین بخش اقیانوس آرام مداری حد فاصل صفر تا ۱۰ درجه جنوبی و ۱۶۰ درجه شرقی تا ۱۵۰ درجه غربی است.

۶- شاخص نینو ۳: این شاخص نمایانگر اختلاف دمای سطح دریا در طرف شرقی، بخش مداری اقیانوس آرام بین دو منطقه ۵ درجه شمالی و ۵ درجه جنوبی تا حوالی ۱۵۰ و ۹۰ درجه غربی است.

۷- شاخص نینو ۴: این شاخص نمایانگر اختلاف دمای سطح دریا در دو ناحیه مرکزی بخش حاره ای اقیانوس آرام در ۵ درجه شمالی و ۵ درجه جنوبی تا حوالی ۱۶۰ درجه شرقی و ۱۵۰ درجه غربی است (قویدل رحیمی، ۱۳۸۴) برای پیش بینی استفاده شد.

8 Southern Oscillation Index

9 Trans-Nino Index

مدل سازی، پیش بینی عناصر اقلیمی است (اسفندیاری درآباد، ۱۳۸۹). شبکه طراحی شده برای پیش بینی از یک لایه ورودی، یک لایه میانی و یک لایه خروجی تشکیل شده است. توابع محرک مختلفی مانند توابع خطی مثبت، تانژانت هیپربولیک<sup>۲۵</sup>، زیگموئید<sup>۲۶</sup>، سوفتمکس<sup>۲۷</sup> و همانی<sup>۲۸</sup> را می توان استفاده کرد (فاتحی مرج: ۱۳۸۸). در این تحقیق لایه خروجی بارش ماهانه می باشد. عموماً هر شبکه عصبی از سه لایه تشکیل شده که عبارتند از: ۱- لایه ورودی<sup>۲۹</sup>، شامل چند نرون است که در این پژوهش، شاخص ها و عناصر اقلیمی را دریافت میکند؛ ۲- لایه پنهان<sup>۳۰</sup>، شامل تعدادی نرون متغیر است که تعداد بهینه آن ها برای حداقل شدن خطا از طریق آزمایش و تکرار تعیین میگردد؛ ۳- لایه خروجی<sup>۳۱</sup>، که برای افزایش سرعت شبکه در این لایه، از تابع فعال ساز که بنابر نیاز از تابع تانژانت هیپربولیک یا سافت مکس<sup>۳۲</sup> استفاده می شود تا با استفاده از آن هم سرعت یادگیری افزایش یابد و هم مقادیر خروجی بدون تغییر به شبکه ارائه شده، در نهایت خروجی مطلوب را بسازد (خوشحال دستجردی، ۱۳۸۹).

### نتایج و بحث

به منظور بررسی اولیه داده ها و تعیین همبستگی بین آنها برای مدل سازی بارش، ابتدا ماتریس، همبستگی بین بارش و سیگنال های هواشناسی مطابق با جدول ۲ استخراج شد.

برای تعیین مهمترین سیگنال های مؤثر در بارش از روش رگرسیون گیری چند گانه به روش گام به گام استفاده گردید. در این روش، متغیرها به ترتیب وارد معادله می شوند و با ورود متغیر جدید کلیه متغیرهای موجود در معادله بررسی می گردند و اگر هر کدام از آنها سطح معنی داری خود را از دست داده باشد، قبل از ورود

KMO<sup>۱۸</sup> و آزمون بارتلت<sup>۱۹</sup> (برای اطمینان از مناسب بودن داده ها برای تحلیل عاملی). استفاده می شود. اگر مقدار شاخص نزدیک به یک باشد (حداقل ۰.۶) داده ها برای تحلیل مناسب می باشند. در غیر اینصورت داده ها معتبر نیستند (شیخ الاسلامی، ۱۳۹۳). در این مطالعه ۴۴ عنصر اقلیمی شهرستان خرم آباد در تحلیل عاملی قرار گرفتند که در این تحلیل به پنج عامل تقسیم شدند (جدول شماره ۱). تمامی محاسبات مربوط به تحلیل رگرسیون و سیستم شبکه عصبی در نرم افزار اس پی اس اس<sup>۲۰</sup> انجام گرفت. چون هدف اولیه این تحقیق درک روابط بین بارش ایستگاه با شاخص ها و عناصر اقلیمی می باشد، بنابراین از ضریب همبستگی استفاده شد. ضریب همبستگی کمیتی است که درجه و میزان همبستگی دو جامعه که دارای افراد متناظرند را تعیین میکند (مهدوی و طاهرخانی، ۱۳۸۳). برای محاسبه ی ضریب همبستگی از روش همبستگی پیرسون استفاده شد. همچنین از روش شبکه عصبی برای مدل سازی استفاده گردید پس از انتخاب داده های ورودی و خروجی شبکه و تعیین ساختار شبکه از لحاظ تابع محرک، تعداد نرون های لایه پنهان، تعداد لایه های پنهان، تعداد تکرار<sup>۲۱</sup>، مقادیر پارامترهای آموزشی و تابع عملکرد، آموزش شبکه برای ارزیابی بهتر عملکرد و انتخاب شبکه بهینه اقدام به آنالیز رگرسیونی و تعیین ضریب همبستگی بین داده های ورودی و خروجی در مرحله آموزش و درصد خطا در مرحله آزمون گردید. ارزیابی عملکرد شبکه های عصبی نیز از شاخص های، مجذور میانگین مربعات خطا<sup>۲۲</sup> میانگین مربعات خطا<sup>۲۳</sup> و ضریب همبستگی<sup>۲۴</sup> استفاده شده است. شبکه ای که در این تحقیق استفاده شد، شبکه های عصبی مصنوعی پرسپترون چندلایه پیشرو بود. شبکه های عصبی مصنوعی پرسپترون از نوع شبکه های عصبی پیشخور هستند که یکی از پرکاربردترین مدل های شبکه عصبی مصنوعی در

25 Hyperbolic Tangen

26 Sigmoid

27 Output layer

28 Identify

29 Input layer

30 Hidden layer

31 softmax

18 Kaiser-Meyer-Olkin

19 Bartlett's test of sphericity

20 SPSS

21 1 Epoch

22 Root Mean Square Error

23 Mean Square Error

24 Correlation Coefficient

جدول ۱. بار عاملی عناصر موثر بر بارش شهرستان خرم آباد


	ردیف	۱	۲	۳	۴	۵	۶	۷	۹	۱۰	۱۱	۱۳	۱۴
عامل اول	نام عامل	تعداد روزهای با حداکثر دمای مساوی آسمان صاف	تعداد روزهای با حداکثر دمای مساوی ۳۰ یا بیش از آن	میانگین کمبود اشباع	حداقل دمای ثبت شده	درجه روز سرمای ۲۱ درجه	اختلاف بین میانگین حداکثر و میانگین حداقل دما	میانگین حداکثر دمای روزانه	میانگین دمای خشک ماهانه بر حسب درجه سانتی گراد	میانگین حداقل دمای روزانه	حداکثر دمای ثبت شده	سمت و جهت باد	درجه روز گرمایش پایه ۱۸ درجه
	بار عاملی	-۰٫۹۷۴	-۰٫۹۵۵	-۰٫۹۲۷	-۰٫۹۱۳	-۰٫۸۸۸	-۰٫۸۷۸	-۰٫۸۶۶	-۰٫۸۵۶	-۰٫۸۴۴	-۰٫۷۸۳	-۰٫۶۹۲	۰٫۶۷۵
	نام عامل	میانگین رطوبت نسبی، % در ساعت ۱۵ گرینویچ	میانگین رطوبت نسبی، % در ساعت ۹ گرینویچ	حداکثر بارندگی روزانه	میانگین رطوبت نسبی، %	تعداد ر وزهای ابری	مجموع بارندگی ماهیانه به میلیمتر	تعداد روزهای ببارنگی به میزان ۱۰ میلیمتر و یا بیشتر	تعداد روزهای ببارنگی به میزان ۱ میلیمتر و یا بیشتر	میانگین حداکثر رطوبت نسبی، %	میانگین رطوبت نسبی، % در ساعت ۳ گرینویچ	تعداد روزهای قسمت ی ابری	
بار عاملی	۰٫۸۵۴	۰٫۸۶۴	۰٫۸۹۹	۰٫۹۰۵	۰٫۹۲۶	۰٫۹۳۶	۰٫۹۴	۰٫۹۵	۰٫۹۵۱	۰٫۹۵۳	۰٫۹۷۷		
عامل دوم	نام عامل	تعداد روزهای با گرد و غبار	سمت باد	سرعت باد	درصد باد غالب	درصد باد آرام	میانگین برداری باد	ضریب پایداری باد	میانگین سرعت باد بر حسب نات	سرعت سریعترین باد			
	بار عاملی	۰٫۸۱۱	۰٫۶۷	۰٫۸۵۷	۰٫۷۰۶	-۰٫۹۳۳	۰٫۸۶۶	۰٫۷۴۶	۰٫۹۶۶	۰٫۶۸۸			
عامل سوم	نام عامل	تعداد روزهای با حداکثر دمای مساوی ۰ یا کمتر از آن	تعداد روزهای با حداقل دمای مساوی ۴- یا کمتر از آن	تعداد روزهای با حداقل دمای مساوی ۰ یا کمتر از آن	تعداد روزهای با برف یا برفابه								
	بار عاملی	-۰٫۸۳	-۰٫۸۰۲	-۰٫۷۰۲	-۰٫۸۳								
عامل چهارم	نام عامل	تعداد روزهای همراه با باد											
	بار عاملی	۰٫۸۸۹											
عامل پنجم	نام عامل	سمت سریعترین باد											
	بار عاملی	-۰٫۸۶۱											

(فتاحی و همکاران، ۱۳۸۸). بدین ترتیب، پراهمیت ترین سیگنال ها و به عبارت دیگر، مؤثرترین آنها در میزان بارش به ترتیب اهمیت آنها مرتب می شوند. با روش

متغیر جدید این متغیر از معادله خارج می شود. در پایان عملیات، متغیرهایی که دارای سطح معنی داری کمتری از سطح تعیین شده باشند، در معادله حضور نخواهند داشت

جدول ۲. رابطه بارش و سیگنال های بزرگ مقیاس اقلیمی با رگرسیون در ایستگاه مورد مطالعه

مدل	ضریب همبستگی	ضریب تعیین همبستگی	ضریب تعدیل یافته	میزان خطای استاندارد	سطح معنی داری
۱	.۴۰۱ <sup>a</sup>	.۱۶۱	.۱۴۷	۹/۶۲	۰/۰۰۰
۲	.۵۱۸ <sup>b</sup>	.۲۶۸	.۲۴۴	۹/۰۵	۰/۰۰۰
۳	.۵۹۰ <sup>c</sup>	.۳۴۸	.۳۱۶	۸/۶۲	۰/۰۰۰
۴	.۶۵۲ <sup>d</sup>	.۴۲۵	.۳۸۶	۸/۱۶	۰/۰۰۰
۵	.۶۸۴ <sup>e</sup>	.۴۶۷	.۴۲۱	۷/۹۲	۰/۰۰۰
۶	.۷۱۳ <sup>f</sup>	.۵۰۸	.۴۵۶	۷/۶۸	۰/۰۰۰
۱	a. AMM۱۱			۲	b. AMM۱۱, pna۸
۳	c. AMM۱۱, pna۸, NINO۴.۱۲			۴	d. AMM۱۱, pna۸, NINO۴.۱۲, pna۱۰
۵	e. AMM۱۱, pna۸, NINO۴.۱۲, pna۱۰, NINO۴.۱۰			۶	f. AMM۱۱, pna۸, NINO۴.۱۲, pna۱۰, NINO۴.۱۰, pna۵



شکل ۲. مهمترین سیگنالهای بزرگ مقیاس اقلیمی مؤثر بر بارش ایستگاه خرمآباد

می، اوت و اکتبر بر بارش این شهر نیز دارای ضریب بالایی است. این سیگنال یکی از بارزترین نوسان های کم بسامد منطقه برون حاره نیمکره شمالی است و جز در ژوئن و ژوئیه در همه ماههای سال بر منطقه برون حاره فعال است. سیگنال نینوی ۴ در ماههای اکتبر و دسامبر با بارش این شهر همبستگی دارد. این شاخص نمایانگر اختلاف دمای سطح دریا در دو ناحیه مرکزی بخش حاره ای اقیانوس آرام در ۵ درجه شمالی و ۵ درجه جنوبی تا حوالی ۱۶۰ درجه شرقی و ۱۵۰ درجه غربی است. برای تعیین مهمترین عناصر مؤثر بر شهرستان خرم آباد از روش تحلیل عاملی استفاده شد. مهمترین عناصر با پنج عامل شناسایی شد (جدول ۱).


هر یک از عوامل استخراجی با چرخش واریماکس ارزش ویژه بخشی از پراش یک متغیر که بوسیله عامل های شناسایی شده، تبیین نشده است، ارزش ویژه نامیده می شود (علیجان، ۱۳۸۱). عامل اول با چرخش واریماکس ۲۴/۹ درصد است. این مؤلفه حدود ۵۲/۹۹

گام به گام ۶ شبکه ایجاد شد، در این روش هرچه تعداد شاخص های اقلیمی بیشتر باشد ضریب همبستگی هم بالا می رود و میزان خطای استاندارد نیز کاهش می یابد. بطوریکه در شبکه ی یک ضریب همبستگی ۴۰ درصد، تعداد شاخص ها ۱ و میزان خطا ۹/۶۲ و در آخرین شبکه ضریب همبستگی ۷۱ درصد، تعداد شاخص ها ۶ مورد و میزان خطا ۷/۶۸ است. اعدادی که در جلوی شاخص ها آمده است مقدار تاخیر را به ماه نشان می دهد.


همانطور که بیان شد، اعدادی که در مقابل سیگنال ها قرار دارند تاخیر به ماه مورد نظر در هر شاخص است. در شکل ۲ ضریب همبستگی بارش با سیگنال های اقلیمی نشان داده شده است. ضریب همبستگی حالت نصف النهاری اقیانوس اطلس در ماه نوامبر است و این بدین معناست که بارش شهرستان خرم آباد با این سیگنال همبستگی زیادی دارد.

الگوی آرام امریکای شمالی در سه بازه زمانی با تاخیر پنج ماهه، هشت ماهه و ده ماهه شامل ماههای





شکل ۳. درصد پراش عاملهای موثر بر بارش




شکل ۴. ارزش ویژه دومین عامل موثر بر بارش خرمآباد

جدول ۳. مدل‌های ورودی ساخته شده بر اساس شاخصهای مهم با شبکه عصبی در ایستگاه مورد مطالعه

با شاخص اقلیمی، نوع خطا (خطای آنتروپی)			با عناصر اقلیمی، نوع خطا (خطای حاصل جمع مربعات)			
نام شبکه	ضریب همبستگی	مقدار خطا	نام شبکه	ضریب همبستگی	مقدار خطا	
					آموزش	ارزیابی
شبکه ۱	۶۳	۱۹/۲۸۹	شبکه ۱ کلیه ی عناصر موثر	۹۰/۸	۰/۰۷۴	۰/۲۱
			شبکه ۱ عناصر اقلیمی با بار مثبت	۹۹/۲	۰/۰۰۸	۰/۰۲۹
			شبکه ۱ عناصر اقلیمی با بار منفی	۸۹/۹	۰/۰۰۵	۰/۰۱۶
شبکه ۲	۷۴	۰/۱۹۲	شبکه ۲	۷۶	۰/۰۲۸	۰/۷۱۳
شبکه ۳	۷۶	۰/۰۱۸	شبکه ۳	۹۱	۰/۳۳۹	۰/۰۹۹
شبکه ۴	۸۸	۰/۱۹۶	شبکه ۴	۵۶	۲/۳۲۳	۰/۶۰۴
شبکه ۵	۸۶	۲/۹۲۱	شبکه ۵	۴۰	۲/۴۸	۰/۶۱۵
شبکه ۶	۸۹			۰/۷۱		

جدول ۴. مدل‌های ورودی ساخته شده بر اساس شاخصهای مهم با شبکه عصبی در ایستگاه مورد مطالعه

نام شبکه	رابطه‌ی بارش با شاخصهای اقلیمی		رابطه‌ی بارش با عناصر اقلیمی	
	ضریب همبستگی	شیب خط	ضریب همبستگی	شیب خط
شبکه ۱	۶۳	$y = .7701x + 8.7395$	۹۹	$y = 1.0244x - 1.074$
شبکه ۲	۷۴	$y = .8196x + 7.2182$	۸۹/۹	$y = .9681x + .5769$
شبکه ۳	۷۶	$y = .7314x + 11.236$	۹۰	$y = .9069x + 5.1877$
شبکه ۴	۸۸	$y = .9021x + 4.8675$	۷۶	$y = .7044x + 1.0987$
شبکه ۵	۸۶	$y = .996x + .5289$	۹۲	$y = 1.0277x - 1.2679$
شبکه ۶	۸۹	$y = .996x + .5289$	۵۶	$y = 1.1543x - 1.7583$
			۴۰	$y = .5109x + 27.325$




شکل ۵. مدل‌سازی بارش با NINO, PNA, NINO4, PNA, AMM, PNA

برای انتخاب مناسب‌ترین ورودی‌های مدل، برای مدل‌سازی با شاخص‌های اقلیمی، ضرایب همبستگی و رگرسیونی بین بارش واقعی و برآورد شده تمامی شبکه‌ها (ماه‌ها) به کار گرفته شده و مهم‌ترین نوسانات انتخاب گردید. تمامی آن‌ها در جدول (۱) ارائه شده است. نتایج با سعی و خطا و بررسی فراوان به دست آمده است؛ بدین صورت که همهٔ حالات ممکن از جمله برآورد بارش با استفاده از هفت متغیر ذکر شده یا با استفاده از ۱، ۲، ۳، ۴، ۵ و ۶ متغیر ذکر شده امتحان گردید که در نهایت، برآورد بارش ماهانه با استفاده از ۶ متغیر ذکر شده بیشترین ضریب همبستگی را نشان داد. این مساله نشان داد که افزایش دقت شبکه با افزایش متغیرهای ورودی در ارتباط است. برای مدل‌سازی با عناصر اقلیمی از تحلیل عاملی استفاده شد و ۵ عامل موثر در اقلیم منطقه به اثبات رسید. تمامی آن‌ها در جدول (۲) ارائه شده است. از الگوریتم گرادیان توام مدرج<sup>۳۳</sup> استفاده

درصد از پراش داده‌ها را بیان می‌کند شکل (۴). که نسبت به بقیه مولفه‌ها موثرتر است. بار این مولفه برای متغیر بارش و دما و رطوبت از سایر متغیرها بیشتر است (جدول ۴). بارش، رطوبت و دما بر شهرستان خرم‌آباد تاثیر متفاوتی دارند. این بدان معناست که هرگاه بارش همراه با رطوبت باشد دمای حداکثر وجود ندارد و برعکس زمانی که آسمان صاف است مسلماً دیگر بارشی وجود ندارد. بنابراین می‌توان گفت که بارش و دما با رابطه‌ی معکوس اولین عامل تاثیرگذار بر اقلیم منطقه می‌باشند. اولین مدل ورودی به شبکه‌ی عصبی عامل اول که ترکیبی از ۲۸ عنصر موثر در اقلیم که البته مجموع بارندگی ماهیانه به میلی‌متر حذف شده است، البته عواملی که بار مثبت یا منفی داشتند نیز بطور جداگانه وارد سیستم شدند و با آنها مدل‌سازی انجام شد که پیش‌بینی‌ها با ضریب همبستگی بالایی به نتیجه رسید. بقیه‌ی عوامل نیز بررسی شد. انتخاب مناسبترین متغیرهای ورودی و الگوریتم

33 Scaled Conjugate Gradient



شکل ۶. مدلسازی بارش با AMM

آن ها به ترتیب ۹۹٪، ۹۸/۹٪ و ۹۰٪ می باشد. عامل دوم (بادی) ۷۶٪، عامل سوم (دمایی) ۹۱٪، عامل چهارم (تعداد روزهای همراه با باد) ۵۶٪، عامل پنجم (سمت سریعترین باد) ۴۰٪ که بیشترین ضریب همبستگی مشارکت تمام عوامل موثر در مدلسازی بارش است.

یکی از مهمترین گام ها در پیشبرد رضایتبخش مدل پیش بینی، انتخاب متغیرهای ورودی مناسب می باشد. به این منظور نیاز به ارزیابی عملکرد شبکه های عصبی با ورودی های مختلف می باشد. سعی بر این است که شبکه ای با کمترین خطا و بالاترین همبستگی معرفی شود. به منظور پیش بینی بارش، مدل های ورودی برای پیش بینی بر اساس شاخصهای موثر بر بارش بررسی شد، نوع آموزش دسته ای انتخاب شد: زیرا این روش مستقیماً خطاهای کلی را حداقل می کند. در آموزش های دسته ای نیاز است که تا رسیدن به یکی از شرایط توقف وزن ها چندین بار به روزرسانی شود و بنابراین باید چندین بار بانک اطلاعات بررسی شود. این روش بیشتر برای مجموعه داده های کوچکتر مناسب است. زمانی که برای تابع فعال کننده لایه خروجی، از تابعی همچون، تابع همانی، سیگموئید یا تانژانت هیپربولیک استفاده نماییم، از خطای حاصل جمع مربعات<sup>۳۴</sup> استفاده می شود و چنانچه تابع سافت مکس باشد، خطای آنتروپی<sup>۳۵</sup> مورد استفاده قرار می گیرد. خطای تابع فعال کننده لایه خروجی نسبتی یا درصد پیش بینی نادرست بسته به سطوح اندازه گیری متغیر وابسته نمایش داده می شود. اگر یکی از متغیرهای وابسته سطح اندازه گیری مقیاس بندی

شد که فرضیات این روش را برای آموزش دسته ای ممکن می سازد. بنابراین برای آموزش های روی خط و دسته ای کوچک قابل استفاده نیست. مقدار اولیه ی پارامتر لاندای در الگوریتم گرادینت توام مدرج ۰۰۰۰۰۵/ بود. تعداد تکرار در بیشتر موارد از ۱۰۰ دور بالاتر بود. پس از هر بار آموزش شبکه، نموداری که نشان دهنده روند تغییرات خطای داده های آموزشی و تست شبکه است در نرم افزار اکسل به دلیل اینکه نمودارهای اکسل قابل تغییرند ترسیم شد که نمونه آن در شکل (۵) و شکل (۶) آورده شده است. در این نمودار، خط ممتد، مربوط به بهترین خط برازش یافته از بین نقاط داده ها و خط نقطه چین، نیمساز ربع اول دو محور عمودی و افقی است. هر قدر این خط به بهترین خط برازش یافته (خط ممتد) نزدیکتر باشد، بیانگر برازش عالی و برآورد دقیق خروجی های شبکه خواهد بود (داده های موجود در نمودار نرمال شده است). کمترین ضریب همبستگی با شبکه ی عصبی و مدل رگرسیون در مدل های ۶ گانه مربوط می شود به شبکه ANNI با ضریب همبستگی ۶۳٪ در شکل (۶) که این ضریب با سعی و تلاش فراوان به دست آمد. ضریب همبستگی در رگرسیون ۴۰٪ بود که این نشان دهنده ی موفقیت شبکه ی عصبی در پیش بینی بارش است، بقیه ی شبکه ها به ترتیب ۷۴٪، ۷۶٪، ۸۸٪، ۸۶٪ و ۸۹٪ در شکل (۵) در شبکه عصبی و در رگرسیون به ترتیب ۵۱٪، ۵۹٪، ۶۵٪، ۶۸٪، ۷۱٪ می باشند. در بررسی با عناصر اقلیمی، بالاترین ضریب همبستگی مربوط می شود به مهم ترین عامل موثر بر اقلیم یعنی عامل اول (بارشی-دمایی) رابطه ی عناصر بارشی و عناصر دمایی و مجموع این دو با بارش که ضریب

34 cross entropy

35 Sum of Squares Error

### جمع‌بندی

بارش یکی از مهمترین داده های ورودی به سیستم های هیدرولوژیکی محسوب می شود. با توجه به اهمیت بارش برای کشور خشکی مانند ایران تاکنون پژوهش های اندکی درباره مدل سازی بارش کشور انجام گرفته است برای مدل سازی بارش رابطه بین دو عامل شاخص های اقلیمی و عناصر اقلیمی با بارش ماهانه شهرستان خرم آباد از داده های ایستگاه هواشناسی در سطح استان لرستان بهره گرفته شد. روش های متعددی برای مدل سازی وجود دارد که در این مقاله از روش های رگرسیون و سیستم عصبی استفاده شد. هرکدام از این روش ها معایب و مزایای خاص خود را دارند. استفاده از شبکه های عصبی مصنوعی برای مدل سازی ماهانه بارش ایستگاه خرم آباد نشان داد که روند بارش ایستگاه خرم آباد ساده و خطی نیست، بلکه غیر خطی است که توسط شبکه عصبی مصنوعی قابل محاسبه و مدل سازی است. در این تحقیق از سیستم شبکه ی عصبی روش پرسپترون چند لایه استفاده شد که کارایی این روش در تحقیقات مقصود و همکاران (۲۰۰۴)، میسلان و همکاران (۲۰۱۵)، کاشیوا و همکاران (۲۰۱۷) امیدوار و نبوی زاده (۱۳۹۳) عرفانیان و همکاران (۱۳۹۱) به اثبات رسید. مدل شبکه ی عصبی پرسپترون با ۵ شبکه از عناصر اقلیمی و ۶ شبکه از شاخص های اقلیمی توانست بهترین الگو را برای مدل سازی بارش نشان دهد که تقریباً با کارهای گذشته متفاوت بود. از مدل رگرسیونی نیز جهت مدل سازی استفاده شد که مدل انتخابی برای ایجاد رابطه بین ۱۸ شاخص و بارش، مدل رگرسیونی چند متغیره با استفاده از روش ورود گام به گام متغیرها به مدل بود. برای ایجاد بهترین شبکه جهت مدل سازی بارش، از تحلیل عاملی بهره گرفته شد که ۵ عامل مهم در منطقه به شرح ذیل مشخص شد: عامل اول (بارشی-دمایی)، عامل دوم (بادی)، عامل سوم (دمایی)، عامل چهارم (تعداد روزهای همراه با باد)، عامل پنجم (سمت سریعترین باد).

شده داشته باشد، میانگین خطای نسبی کلی (مربوط به مدل میانگین) نمایش داده می شود. اگر تمامی متغیرهای وابسته مطلق باشند، میانگین درصد پیش بینی نادرست نمایش داده می شود. خطاهای نسبی یا درصدهای پیش بینی نادرست برای تک تک متغیرهای وابسته نیز مشخص می گردند. در مدل های ۱ تا ۶ از تابع سافتمکس استفاده شده است بنابراین نوع خطا، خطای آنتروپی می باشد. مقدار خطا در مدل ۱-۱۹/۲۸۹ درصد است که بیشترین مقدار خطا محسوب می شود، درصد پیش بینی نادرست ۰.۴٪ است که نسبت به بقیه ی مدلها بیشتر میباشد، ضریب همبستگی آن ۰.۶۳٪ است که مقدار آن از بقیه کمتر است. در بقیه هر قدر زمان آموزش بیشتر باشد درصد پیش بینی هم بالاتر می رود و درصد پیش بینی های نادرست هم کمتر می شود. در مدل های ۶ و ۴ یکبار هم از تانژانت هیپربولیک و همانی استفاده شده است که در اینجا اگر خطا در سطح ارزیابی کمتر شود ضریب همبستگی هم بالاتر می رود (جدول شماره ی ۳). با استفاده از عناصر اقلیمی و توابع همانی، سیگموئید یا تانژانت هیپربولیک خطای حاصل جمع مربعات مشخص شد و با کمترین خطا هم در سطح آموزش و هم ارزیابی بهترین نتیجه حاصل شد (جدول ۳).

### تعیین بهترین مدل با ضریب بالای همبستگی

برای عناصر اقلیمی ۵ شبکه و شاخصهای اقلیمی ۶ شبکه ایجاد شد. بالاترین ضریب همبستگی با عامل یا عنصر دوم با ضریب ۹۹/۲ ساخته شد که مقدار خطا هم در ارزیابی و هم در آموزش بسیار پایین بود. مقدار خطا در بررسی عناصر اقلیمی خطای حاصل جمع مربعات و در شاخصها خطای آنتروپی بود دلیل هم استفاده از تابعی بود که می توانست بالاترین ضریب همبستگی را نشان دهد. برای تمام شبکه ها مدل هایی تعیین شد. هرچه تعداد شاخص ها بیشتر باشد می توان به پیش بینی اعتماد بیشتری داشت، البته شبکه ی ۵ از این امر مستثنی می باشد (جدول ۴).

خوشحال دستجردی، جواد و حسینی، سیدمحمد، ۱۳۸۹، کاربرد شبکه عصبی مصنوعی در شبیه سازی عناصر اقلیمی و پیش بینی سیکل خشکسالی (مطالعه موردی: استان اصفهان)، مجله جغرافیا و برنامه ریزی محیطی، سال ۲۱، شماره پیاپی ۳۹، شماره ۳، پاییز ۱۳۸۹، صص ۱۲۰-۱۰۷

عرفانیان، مریم، انصاری، حسین و علیزاده، امین (۱۳۹۲). پیش بینی بارش و دمای متوسط ماهانه با استفاده از الگوهای پیوند از دور به کمک شبکه های عصبی مصنوعی (مطالعه موردی: ایستگاه سینوپتیک مشهد. مطالعات جغرافیایی مناطق خشک، ۳(۱۱)، ۵۳-۷۳

فاتحی مرج، ا. و م.ج. مهدیان. ۱۳۸۸. پیش بینی بارش پاییزه با استفاده از شاخص های انسو به روش شبکه عصبی در حوضه دریاچه ارومیه. پژوهش های آبخیزداری، شماره ۳۴، صص ۴۲-۵۲ فاتحی، ابراهیم و صداقت کردار، عبدالله (۱۳۸۷). پیش بینی بلند مدت بارش با استفاده از شبکه های عصبی مصنوعی (مطالعه ی موردی جنوب غرب ایران). پژوهش و سازندگی در منابع طبیعی، ۳۱(۳)، ۴۴-۵۰

فلاح قاهره، غلامعباس و خوشحال، جواد (۱۳۸۸). پیش بینی بارش بهاره استان خراسان رضوی بر اساس سیگنال های بزرگ مقیاس اقلیمی با استفاده از شبکه های عصبی مصنوعی. پژوهش های جغرافیای طبیعی، ۴۱(۶۹)، ۱۱۵-۱۳۳

فقیه، همایون، (۱۳۸۹). ارزیابی کاربرد شبکه عصبی مصنوعی و بهینه سازی آن با روش الگوریتم ژنتیک در تخمین داده های بارش ماهانه (مطالعه موردی: منطقه کردستان). علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، ۱۱۴(۵۱)، ۲۷-۴۲

قلی زاده، محمدحسین و دارند، محمد (۱۳۸۸). پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی (مورد: تهران). پژوهش های جغرافیای طبیعی، ۴۲(۷۱)، ۵۱-۶۳

قوبدل رحیمی، یوسف (۱۳۸۴). اثر الگوهای بزرگ مقیاس گردش جوی-اقیانوسی انسو بر تغییرپذیری فصلی اقلیم در ایران: آثار ال نینو و لاتینا بر تغییرپذیری بارشهای بهاری در آذربایجان شرقی. فصلنامه مدرس علوم انسانی، ۹(۴)، ۸۸-۷۱

مهدوی، مسعود و طاهرخانی، مهدی (۱۳۸۳). کاربرد آمار در جغرافیا. چاپ اول، نشر قومس، تهران

یاراحمدی، داریوش و عزیزی، قاسم، ۱۳۸۶. تحلیل چند متغیره ارتباط میزان بارش فصلی ایران و شاخص های اقلیمی، پژوهش های جغرافیایی، شماره ۶۲، صص ۱۷۴-۱۶۱

Elsanabary, H. , Mohamed, & Gan Thian, Y.(2014). Wavelet Analysis of Seasonal Rainfall Variability of the Upper Blue Nile Basin, Its Teleconnection to Global Sea Surface Temperature, and Its Forecasting by an Artificial Neural Network. Monthly Weather Review, 142(1). 1771-1791

Maqsood, I., Muhammad, R. Kh., & Ajith, A.(2004). An ensemble of neural networks for weather forecasting. Neural Comput & Applic, 13(1). 112-122

Iseri, Y. Dandy, G. Maier, H. Kawamura, A, 2005, Medium term forecasting of rainfall using artificial neural networks, MODSIM 2005 International Congress on Modelling and Simulation, Simulation Society of Australia and New Zealand, December 2005, pp.1834-1840 Publisher: mssanz Issue Date: 2005 ISBN: 0975840002.

John A. and Jennifer M, 2012, Application of Artificial Neural Networks to Rainfall Forecasting in Queensland, Australia . ADVANCES IN

شاخص های اقلیمی که توسط مراکز معتبر بین المللی ثبت می شوند، غالباً دارای طول دوره ی آماری بیش از ۵۰ سال می باشند، بنابراین می توان با استفاده از این شاخص ها به مدلسازی پرداخت. مهمترین سیگنال موثر بر بارش خرم آباد شاخص حالت نصف النهاری اقیانوس اطلس در ماه دسامبر است که در هیچکدام از تحقیقات گذشته به این شاخص توجه نشده است. دومین عامل موثر بر بارش خرم آباد، الگوی آرام امریکای شمالی است. سومین سیگنال موثر بر بارش خرم آباد شاخص نینوی ۴ در ماه های اوت و دسامبر است. از روش شبکه عصبی پرسپترون برای پیش بینی بارش از بین ۶۴ سال آمار بارش ۵۰ سال برای آموزش (۰.۷۸،۱٪) و ۱۴ سال برای آزمون (۰.۲۱،۹٪) مورد استفاده قرار گرفت. تعداد واحدها یا متغیرهای مستقل ۲۲۸ مورد بود. روش آموزش برای استفاده از متغیرها روش استاندارد کردن متغیرها بود. با انتخاب نوع و تعداد مناسب عوامل ورودی و نیز کالیبره کردن مناسب آن می توان گفت، این تکنیک ابزاری بسیار کارآمد و قدرتمند برای مدلسازی بارش برای شهرستان خرم آباد می باشد. مناسبترین ساختار برای مدلسازی بارش در شهرستان خرم آباد به کمک شبیه سازی شاخص های اقلیمی، با آرایش ۲۰-۱۵-۲ بود.

### مراجع

ایلدرومی، علیرضا، زارع ابیانه، حمید و بیات ورکشی، مریم، (۱۳۹۲)، برآورد بارش به کمک شبکه عصبی مصنوعی با داده های هواشناسی غیر بارشی در سه منطقه شیراز، مشهد و کرمان، نشریه علمی-پژوهشی جغرافیا و برنامه ریزی (دانشکده ی جغرافیا) سال ۱۷ شماره ۴۳، بهار ۱۳۹۲، صص ۲۱-۴۰

حجازی زاده، زهرا، فاتحی، ابراهیم و سلیقه، محمد، (۱۳۹۲)، بررسی تاثیر سیگنال های اقلیمی بر بارش ناحیه مرکزی ایران با استفاده از شبکه عصبی مصنوعی، نشریه تحقیقات کاربردی علوم جغرافیایی، سال سیزدهم، شماره 29، تابستان ۱۳۹۲، صص ۷۵-۸۹

خلیلی، نجمه، حق شناس، سعید رضا، داوری، کامران و موسوی پایگی، محمد (۱۳۸۷). پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی مطالعه ی موردی ایستگاه سینوپتیک مشهد، مجله علوم و صنایع کشاورزی، ویژه آب و خاک، ۲۲(۱)، ۹۹-۸۹. صلاحی، برومند، عالی جهان، مهدی (۱۳۹۲). تحلیل سینوپتیک مخاطرات اقلیمی شهرستان یاسوج (مطالعه موردی: بارش سنگین ۲۰ اسفند ۱۳۸۹. جغرافیا و مخاطرات محیطی، ۲(۵)، ۷۳-۸۹

- Meteorological Drought Index for Drought Assessment and Mapping in Basine Karoon in Iran, *International Journal of Review in Life Sciences*, 5(7), 2015, 772-781
- Salehvnd, Iran., Gandomkar, Amir., Fatahi, Abraham and Azizi, Ghasem, 2016, HMNDP annual periods of drought and wet in Lorestan Iran using Markov, chain 2016 Contents lists available at ScienceDirect. *Weather and Climate Extremes*.
- Salhvand, Iran, Montazeri Majid and Gandomkar, Amir, in 2013, More return periods for growing plants in the province of Markov chain in GIS environment and its impact on planning, Third International Conference on Environmental Planning and Management, Tehran, Tehran University, [http://www.civilica.com/Paper-ESPME03-ESPME03\\_463.html](http://www.civilica.com/Paper-ESPME03-ESPME03_463.html)
- Salhvand, Iran, Gandomkar, Amir and Fatahi, Ebrahim, 2015, The probability of dry periods and wet climate for growing plants in the province with Markov chain, third year (10) - Pages, -8-1
- ATMOSPHERIC SCIENCES, VOL. 29, NO. 4, 2012, 717-730.
- Mislan, H., Sigit H. & Sumaryono, M. A. ( 2015). Rainfall Monthly Prediction Based on Artificial Neural Network: A Case Study in Tenggara Station, East Kalimantan – Indonesia. *Procedia Computer Science*. 59(). 142-151
- M.T. Daštoria, H. Afkhami, 2011, Application of artificial neural networks on drought prediction in Yazd (Central Iran). *DESERT* 16 (2011) 39-48.
- Nayak, Deepak Ranjan .Amitav Mahapatra .Pranati Mishra 2017. A Survey on Rainfall Prediction using Artificial Neural Network. *International Journal of Computer Applications*, 72(16). 32–40
- P.T. Naštos, K.P. Mouštris, I.K. Larissi, A.G. Paliatsos, 2013, Rain intensity forecast using Artificial Neural Networks in Athens, Greece, *Atmospheric Research*, Volume 119, January 2013, Pages 153–160
- Salehvand, Iran., Hobi, Elham., Montazeri, Majid ., Momeni, Mehdi., Gandomkar, Amir and Hooshmand Ataei, 2015, Evaluation of

## Long- range precipitation prediction using artificial neural networks

*Iran Salehvand<sup>1</sup>, Amir Gandomkar<sup>\*1</sup>, Ebrahim Fatahi<sup>2</sup>*

<sup>1</sup> *Department of Geography, Najaf Abad Unit, Islamic Azad University, Najafabad, Iran*

<sup>2</sup> *Meteorological Institute faculty member, Tehran, Iran*

\*Corresponding Author Email: [hyper\\_hot2009@yahoo.com](mailto:hyper_hot2009@yahoo.com)

Received: 2 August 2018, accepted: 4 February 2019

### ABSTRACT

The climate indices which are recorded by the reliable international centers have frequently long statistical periods more than 50 years. Therefore the prediction is done using these indices. There are various methods to predict which in this study the methods of regression and neural system are used. Every method has its own advantages and disadvantages but the neural systems were more successful to predict Abadan precipitation. Neural network method was used to predict precipitation. 64 years of rainfall data, 49 years for training (78%) and 3 years for the test (21.9%) were used.

For modeling the relationship between the index and monthly rainfall and city of Khorramabad, Lorestan Province, meteorological station data was used. 18 indicators and is the model of choice for creating the relationship between multivariate regression model using stepwise variable model. The results of this model on monthly rainfalls of different combinations of each of these variables on the distribution of monthly precipitation was 18. So that the only variable with a combination of 6 and 86 percent of monthly precipitation changes can be justified. For modeling the relationship between the elements of the city of Khorramabad monthly rainfall and factor analysis were used and five important factors in the study area are as follows: the first factor (precipitation, temperature), the second factor (wind), the third factor (temperature), the fourth factor (number of days with wind), the fifth factor (the fastest wind), respectively. The first factor combined with positive or negative charges 99% of monthly precipitation changes can be justified. Climate indices that are recorded by prestigious international centers, often during a period of more than 50 years, so it can be used using these indices to predict. There are several ways to predict and nervous system regression methods were used in this article. Each of these methods has its own advantages and disadvantages. The neural network approach has been more successful in predicting precipitation Khorramabad.

**Keywords:** *Factor analysis, Khorramabad, regression, climate index, artificial neural network.*

### HOW TO CITE THIS ARTICLE

*Salehvand I., Gandomkar A., Fatahi E. (2019). Long- range precipitation prediction using artificial neural networks. J. Meteorol. Atmos. Sci., 2(1): 1-14.*

### COPYRIGHTS

Copyright for this article is retained by the author(s), with publication rights granted to the JMAS Journal. This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>).

