

کاربرد مدل شبکه عصبی مصنوعی در خرد مقیاس نمودن برون داد های مدل GCM برای پیش بینی بارش در پهنه جنوبی ایران

نوشین احمدی باصری^۱ - امین شیروانی^{۲*} - محمدجعفر ناظم السادات^۳

تاریخ دریافت: ۱۳۹۲/۲/۲۱

تاریخ پذیرش: ۱۳۹۳/۷/۷

چکیده

در این مطالعه، شبکه های عصبی مصنوعی و مدل های رگرسیونی برای خرد مقیاس نمودن خروجی های شبیه سازی شده مدل های گردش عمومی جو استفاده شدند. مجموعه داده های شبیه سازی شده بارش برای محدوده $25/18^{\circ}$ تا $34/51^{\circ}$ شمالی و 45° تا 60° شرقی، ارتفاع ژئو پتانسیل در سطح ۸۵۰ میلی بار و باد مداری در سطح ۲۰۰ میلی بار برای $12/56^{\circ}$ تا $43/25^{\circ}$ شمالی و $19/68^{\circ}$ تا $61/87^{\circ}$ شرقی به عنوان پیشگو کننده ها از مدل ECHAM5 GCM برای دوره ۲۰۰۵-۱۹۶۰ استخراج شدند. بارش ماهانه دیده بانی شده ایستگاه های آبادان، آباده، اهواز، بندرعباس، بوشهر، شیراز و فسا برای دوره ۲۰۰۵-۱۹۶۰ به عنوان پیشگو شونده ها استخراج شدند. مؤلفه های اصلی داده های شبیه سازی شده استخراج و شش مؤلفه اصلی به عنوان ورودی مدل های شبکه عصبی مصنوعی و رگرسیون چند گانه در نظر گرفته شدند. همچنین ترکیب مجموعه داده های شبیه سازی شده به عنوان ورودی این مدل ها استفاده شدند. دوره های ۲۰۰۰-۱۹۶۰ و ۲۰۰۵-۲۰۰۱ به ترتیب به عنوان دوره های آموزش و آزمون در شبکه عصبی مصنوعی در نظر گرفته شدند. نتایج ضریب همبستگی پیرسون و جذر میانگین مربعات خطای استاندارد شده نشان داد که در بیشتر مواقع شبکه عصبی مصنوعی دقیق تر از رگرسیون چند گانه، بارش را پیش بینی می کند. برای مقیاس زمانی ماهانه داده های شبیه سازی شده ارتفاع ژئوپتانسیل بهترین پیشگو کننده و برای مقیاس فصلی (زمستان) بهترین پیشگو کننده در مدل شبکه عصبی مصنوعی، مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده بارش می باشد.

واژه های کلیدی: بارش، پهنه جنوبی ایران، خرد مقیاس نمودن، شبکه عصبی مصنوعی، مدل گردش عمومی جو

مقدمه

مدل ها، به دو دسته تجربی- آماری و دینامیکی تقسیم می شوند (۶). این ها مدل های عددی هستند که فرآیند های ما بین اتمسفر، اقیانوس، یخ کره و سطح زمین را به طور سه بعدی شبیه سازی کرده و تغییرات اقلیمی آینده را برای مناطق مختلف جهان پیش بینی می کنند (۵).

مدل های GCM با قدرت تفکیک نمونه ای چند کیلومتری قادرند هر پهنه را با تعدادی شبکه سلولی نشان دهند (۶) و از جمله مدل های GCM می توان به مدل ECHAM در مرکز داده های اقلیمی جهانی مؤسسه ماکس پلانک^۵ در آلمان اشاره کرد. با توجه به این که مدل های گردش عمومی جو توانایی شبیه سازی برخی شرایط جوی محلی و منطقه ای را ندارند، به منظور هماهنگ کردن مقیاس های با پردازش کم و مقیاس های منطقه ای روش خرد مقیاس نمودن به کمک روش های آماری استفاده شد (۲۱).

موضوع تغییر اقلیم از اواخر قرن نوزدهم میلادی با روند گرم شدن هوا به صورت جدی به میان آمد. عوامل گوناگونی که بر اقلیم اثر گذارند می توانند باعث تغییرات به شکل سالیانه و دراز مدت شوند. این تغییرات دراز مدت اقلیمی تحت تأثیر گرمایش جهانی ناشی از تشدید گازهای گلخانه ای می باشد. از این رو به منظور شبیه سازی دما و بارش که در بررسی تغییر اقلیم نقش عمده ای دارند، مدل های گردش عمومی جو^۴ در دهه ۵۰ میلادی به منظور شبیه سازی تغییرات اقلیمی ناشی از افزایش گاز های گلخانه ای طراحی شد. این

۱، ۲ و ۳- به ترتیب دانشجوی کارشناسی ارشد، استادیار و استاد، بخش مهندسی آب و مرکز پژوهش های جوی اقیانوسی، دانشکده کشاورزی، دانشگاه شیراز
* - نویسنده مسئول: (Email: am_shirvani@hotmail.com)

کشاورزی و افزایش کاربرد روش ANN در دهه های اخیر، می توان گفت که روش شبکه عصبی مصنوعی با وجود توانمندی بیشتر دیگر روش ها در برخی پهنه ها، یکی از شیوه های کارا در خرد مقیاس نمایی بارندگی می باشد. همچنین با توجه به ضرورت پیش بینی های دقیق بارندگی برای دوره های آتی در جنوب کشور به نظر می رسد که کاربرد آن ممکن است ما را به نتایج بهتری در پیش بینی های اقلیمی رهنمون کند. در این پژوهش کوشش شده است که با کاربرد روش خرد مقیاس نمودن آماری خروجی های مدل GCM، با استفاده از شبکه عصبی مصنوعی، بارش مناطق جنوبی ایران پیش بینی شود. در این پژوهش مدل شبکه عصبی مصنوعی برای خرد مقیاس نمودن خروجی مدل های GCM در تعدادی ایستگاه های همدیدی پهنه جنوب و جنوب غربی کشور به کار برده شده و توانایی مدل GCM در پیش بینی بارندگی ارزیابی می شود.

مواد و روش ها

داده ها

در این پژوهش چهار گروه داده در برگیرنده:

- ۱- داده های بارش دیده بانی شده ایستگاه های همدیدی جنوب کشور بر حسب میلی متر
 - ۲- داده های شبیه سازی شده^۵ بارش مدل GCM بر حسب کیلوگرم بر متر مربع بر ثانیه
 - ۳- داده های شبیه سازی شده ارتفاع ژئوپتانسیل برای سطح ۸۵۰ هکتوپاسکال
 - ۴- داده های شبیه سازی شده باد مداری برای سطح ۲۰۰ میلی بار بر حسب متر بر ثانیه به کار گرفته شد.
- داده های بارش ماهانه هفت ایستگاه همدیدی آبادان، آباده، اهواز، بندر عباس، بوشهر، شیراز و فسا از پایگاه سازمان هواشناسی www.weather.ir برای دوره ۲۰۰۵-۱۹۶۰ (به جز ایستگاه آباده با دوره مطالعاتی ۲۰۰۵-۱۹۷۷ و ایستگاه فسا با دوره مطالعاتی ۲۰۰۵-۱۹۶۷) استخراج شدند. جایگاه جغرافیایی این ایستگاه ها و ویژگی آن ها در جدول ۱ آورده شده است. این ایستگاه ها به دلیل آنکه از الگوی بارشی مشابهی پیروی می کنند و در یک پهنه بارشی قرار می گیرند، انتخاب شدند (۳).

در این پژوهش تمامی داده های شبیه سازی شده، مربوط به مدل GCM ECHAM5 بوده و از پایگاه اطلاعاتی <http://cccsn.ca> استخراج شدند. داده های شبیه سازی شده بارش برای عرض های جغرافیایی $11^{\circ}18/25$ تا $50.7^{\circ}34/34$ شمالی و طول جغرافیایی 45° تا 60° شرقی با تفکیک مکانی $1/8^{\circ} \times 1/8^{\circ}$ و داده های شبیه سازی شده

هویتسون و کرین (۱۴)، جانگ و همکاران (۱۵) و تامبو و همکاران (۲۰) در پژوهش های خود نشان دادند که خرد مقیاس نمایی می تواند توانایی پیش بینی بارندگی را افزایش دهد. عباسی و همکاران (۴) و باباییان و همکاران (۲) نیز در ایران مدل LARS-WG برای خرد مقیاس نمایی آماری خروجی مدل ECHO-G را برای پیش بینی تغییرات اقلیمی در مناطق مختلف ایران بررسی نمودند.

متداول ترین روش خرد مقیاس کردن بهره جویی از تابع انتقال است که یک روش رگرسیونی می باشد و بر روابط کمی مستقیم بین متغیرهای در برگیرنده اطلاعات اقلیمی بزرگ مقیاس (پیش بینی کننده) و متغیرهای اقلیمی دیده بانی شده (پیش بینی شونده) از طریق روابط رگرسیونی تکیه دارد. تاکنون رگرسیون خطی و غیرخطی و شبکه های عصبی مصنوعی^۱ به منظور بررسی پیوند بین پیش بینی کننده و پیش بینی شونده و روابط حاکم بر آن ها بکار گرفته شده است. از این میان ANNs مبنی بر روش خرد مقیاس نمایی به دلیل توانایی بالا در فراهم نمودن روابط غیر خطی بین پیش بینی کننده و پیش بینی شونده کاربردی گسترده یافته است (۱۱).

کار آموز و همکاران (۱۶) با کاربرد مدل های SDSM و ANN بر روی پیش بینی بارش با زمان تأخیر پنج ماهه در ناحیه جنوب شرق ایران برتری روش آماری را نسبت به ANN نشان دادند. کالیلی و همکاران (۱۰) و رامیرز و همکاران (۱۷) به نتیجه ای متفاوت در مقایسه مدل شبکه عصبی مصنوعی و مدل های آماری دست یافتند. کالیلی و همکاران (۱۰) مدل های شبکه عصبی پیش خور با تأخیر زمانی^۲ را با مدل SDSM برای خرد مقیاس نمایی مقایسه نمودند. نتایج در این پهنه نشان از کارایی بهتر مدل خرد مقیاس TLFN نسبت به SDSM داشت. رامیرز و همکاران (۱۷) نیز روش ANN را برای پیش بینی بارش به کار بردند. در این مطالعه مشاهده شد که عملکرد پیش بینی ANN نسبت به مدل رگرسیون خطی در پهنه مورد مطالعه بهتر می باشد. دیبایک و کالیلی (۱۱) برای خرد مقیاس نمودن خروجی مدل های GCM، از شبکه های عصبی زمانی^۳ در پهنه کوئیک^۴ شمالی در کانادا بهره جستند. در این پژوهش عملکرد خرد مقیاس TNN با مدل رگرسیونی بر پایه خرد مقیاس نمودن آماری مقایسه شد. بررسی ها نشان داد که TNN نسبت به روش های آماری در خرد مقیاس نمودن روش کار آمد تری می باشد. تامستی و همکاران (۲۰) نیز نشان دادند که روش شبکه عصبی مصنوعی در خرد مقیاس نمودن بارندگی حوزه های آبریز در ایتالیا مناسب است.

با بررسی نتایج پژوهش های انجام شده و اهمیت پیش بینی بارندگی و ارزیابی تغییر اقلیم در بخش های مختلف از جمله

- 1- Artificial Neural Networks, ANNs
- 2- Time-lagged Feed-forward Neural Network, TLFN
- 3- Temporal Neutral Networks, TNNs
- 4- Quebec

می نماید. یادآور می شود که داده های گمشده نقش اساسی در یادگیری پیوند میان داده های ورودی - خروجی سیستم های تحت آزمون دارند. از این رو گزینش فرآیند ها و پیش پردازش روی داده ها جایگاه ارزنده ای در اجرای شبکه عصبی دارد. کاربرد روش تحلیل مؤلفه های اصلی می تواند شمار فراوان سری های ورودی را به شمار اندکی سری های ناهمبسته که مؤلفه اصلی نامیده می شوند، کاهش دهد (۸، ۹ و ۱۳).

در تحلیل PCA ابتدا ماتریس واریانس یا کواریانس از سری های نخستین ساخته می شود و پردازش های پس از این بر روی این ماتریس ها به انجام می رسد. بنا به تعریف ریاضی PCA تبدیل خطی متعامدی است که داده ها را به دستگاه مختصات نوین می برد. در مدل کردن شبکه عصبی، PCs باید به جای شمار فراوان سری های دیده بانی شده، شمار اندکی از PC های ناهمبسته که بخش بزرگی از واریانس داده های نخستین را توجیه می کنند وارد مدل نمود (۱۳).

استاندارد نمودن مؤلفه های اصلی

به منظور یکسان سازی و بدون بعد نمودن داده های ورودی به شبکه عصبی مصنوعی از روش استاندارد نمودن روی مؤلفه های اصلی استخراج شده، استفاده می شود.

$$Spc_{ij} = \frac{pc_{ij} - \min_{pc_j}}{\max_{pc_j} - \min_{pc_j}} \quad (1)$$

در رابطه مذکور \min_{pc_j} کمترین مقدار PC در هر یک از مؤلفه های اصلی در نظر گرفته شده و \max_{pc_j} بیشترین مقدار PC در هر یک از مؤلفه های اصلی می باشد.

برای ارزیابی دقت پیش بینی های انجام گرفته توسط شبکه عصبی مصنوعی از جذر میانگین مربعات خطا نرمال یا NRMSE به صورت رابطه زیر استفاده می شود.

$$NRMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n O_i^2}} \quad (2)$$

در رابطه ۲ O_i اندازه دیده بانی شده و P_i اندازه پیش بینی شده هستند و n شمار داده های مورد مطالعه می باشد.

نتایج و بحث

ارزیابی داده های شبیه سازی شده مدل ECHAM5 GCM برای پیش بینی بارش در ایستگاه های آبادان، آباده، اهواز، بندر عباس، بوشهر، شیراز و فسا به صورت ماهانه و فصلی انجام گرفت.

ارتفاع ژئو پتانسیل و باد مداری به ترتیب در سطوح ۸۵۰ و ۲۰۰ میلی بار برای عرض های جغرافیایی $12/558^{\circ}$ تا $43/25^{\circ}$ شمالی و طول جغرافیایی $19/68^{\circ}$ تا $61/87^{\circ}$ شرقی با تفکیک مکانی $2/813^{\circ} \times 2/813^{\circ}$ برای سال های ۲۰۰۵-۱۹۶۰ از مدل اقلیمی ECHAM5 استخراج گردیدند. همچنین بررسی های ماهانه برای ماه های ژانویه، فوریه، مارس، نوامبر و دسامبر انجام شد. ماه اکتبر به علت بارش کم و شمار صفر فراوان در آمار داده ها بررسی نشد. میانگین سه ماه ژانویه، فوریه و مارس به عنوان فصل زمستان (JFM) نگریده و واکاوی گردید.

روش ها

شبکه های عصبی مصنوعی (ANNs)

شبکه های عصبی مصنوعی با الهام از رفتار سلول های عصبی موجودات زنده برای انجام محاسبات پیچیده و بزرگ پیشرفت داده شدند (۲۰). محاسبات شبکه عصبی بر پایه مدل کردن ویژگی های عمده مغز و چگونگی کارکرد آن شکل گرفته است. مدلی که بتواند ویژگی های مهم سامانه های عصبی را دریافت و رفتار شبیه سازی را از خود بروز دهد (۷). گرچه شبکه های گوناگون عصبی ناسازگاری هایی با یکدیگر دارند اما ساختار بنیادین همه آن ها یکسان است (۱). ساختار هر شبکه عصبی با چهار ویژگی شناخته می شود: شمار نرون ها در هر لایه، نوع تابع انتقال، شمار لایه ها و الگوریتم یادگیری (۱۹). کوچک ترین واحد پردازش اطلاعات در شبکه عصبی نرون می باشد که پایه های کارکرد شبکه های عصبی را می سازد. نرون می تواند یک ورودی یا بیشتر داشته باشد.

فرایند انتقال می تواند خطی یا غیر خطی باشد و از مهمترین آن ها می توان به تابع آستانه ای دو مقداره، تابع انتقال لوجستیک و تابع انتقال هیپربولیک یاد کرد. تابع انتقال باید کراندار، فزاینده، پیوسته و مشتق پذیر باشد و بر پایه نیاز خاص برای حل مسئله گزینش شود. شبکه های عصبی می توانند تک لایه یا چند لایه ای باشند. اطلاعات در لایه ورودی شبکه دریافت شده و سپس شبکه عصبی اطلاعات دریافت شده را از طریق لایه خروجی، به عنوان خروجی می دهد.

تحلیل مؤلفه های اصلی^۱

در کار کردن با داده های زیستی و محیطی، مقادیر گمشده، اضافی و توزیع های غیر نرمال از کاستی های فراگیر و همیشگی هستند. در شبکه عصبی، داده های گمشده اثر پر رنگی بر فرآیند یادگیری دارند و فراوانی آنها این فرآیند را دچار کاستی های فراوانی

1- Principal Components Analysis, PCA

جدول ۱- طول و عرض جغرافیایی و طول دوره آماری در ایستگاه های همدیدی مورد مطالعه

| نام ایستگاه | عرض جغرافیایی | طول جغرافیایی | طول دوره آماری |
|-------------|---------------|---------------|----------------|
| اهواز | ۳۱° ۲۰' | ۴۸° ۴۰' | ۴۶ |
| آبادان | ۳۰° ۲۲' | ۴۸° ۱۵' | ۴۶ |
| بندرعباس | ۲۷° ۱۳' | ۵۶° ۲۲' | ۴۶ |
| بوشهر | ۲۸° ۵۹' | ۵۰° ۵۰' | ۴۶ |
| شیراز | ۲۹° ۳۲' | ۵۲° ۳۶' | ۴۶ |
| فسا | ۲۸° ۵۸' | ۵۳° ۴۱' | ۳۹ |
| آباده | ۳۱° ۱۱' | ۵۳° ۴۰' | ۲۹ |

شش مؤلفه های اصلی برای هر یک از دسته داده های شبیه سازی شده بیرون کشیده شد و در صد فراوانی مؤلفه های اصلی برای همه ماه ها و فصل زمستان به طور جداگانه به دست آمد. برای نمونه درصد فراوانی واریانس اولین مؤلفه اصلی در ماه های سرد سال برای ایستگاه بوشهر در جدول ۲ آورده شده است. جدول ۲ نشان می دهد که بیشترین درصد فراوانی اولین مؤلفه اصلی در ماه های نوامبر و دسامبر برای گروه داده های شبیه سازی شده بارش در ایستگاه بوشهر به دست آمده است.

استاندارد سازی بر پایه تحلیل مؤلفه های اصلی

فرآیند استاندارد سازی طبق رابطه ۱ بر روی شش مؤلفه اصلی استخراج شده از داده های شبیه سازی شده در ۴۰۰ گره مورد مطالعه (۱۹۲ گره باد مداری، ۱۹۲ گره ارتفاع ژئو پتانسیل و ۱۶ گره بارش اطراف هر ایستگاه) و همچنین بر روی داده های بارش در ماه های سرد سال و فصل زمستان در ایستگاه های مورد مطالعه انجام شد. داده های استاندارد شده به روش فوق ورودی شبکه عصبی مصنوعی قرار گرفتند.

شبکه عصبی مصنوعی بر پایه استاندارد سازی مؤلفه های اصلی

با انتخاب داده های ورودی به شبکه عصبی مصنوعی، پیش بینی بارش ماهانه و فصلی (JFM) در همه ایستگاه ها با استفاده از نوار ابزار شبکه عصبی نرم افزار Matlab انجام شد. شبکه در نظر گرفته شده در بر گیرنده دو لایه پنهان هر کدام با ۶ نرون با تابع انتقال تانژانت هیپربولیک (TANSIG) و یک لایه خروجی محتوی یک نرون با تابع انتقال خطی (PURLINE) می باشد. دوره ۲۰۰۰-۱۹۶۰ برای آموزش (Train) و دوره ۲۰۰۵-۲۰۰۱ برای دوره آزمون (Test) برگزیده شده است. شبکه از گونه Feed-Forward backprop برگزیده شد. همچنین در دوره آموزش ۲۰۰۰-۱۹۶۰ از معیار میانگین مربعات خطا (MSE) برای مقایسه توانایی شبکه با وزن های متفاوت استفاده شد.

بررسی پیش بینی بارش در مقیاس های ماهانه و فصلی استخراج مؤلفه های اصلی بر پایه داده های شبیه سازی شده

به منظور ارزیابی دقت مدل ECHAM5 در تخمین بارش، داده های شبیه سازی شده بارش به صورت شبکه ای شامل شانزده گره در اطراف هر یک از ایستگاه های همدیدی در نظر گرفته شدند. به عنوان نمونه شبکه داده های شبیه سازی شده بارش اطراف ایستگاه بوشهر در شکل ۱ نشان داده شده است.

همچنین از ترکیب این داده ها و داده های شبیه سازی شده شامل ارتفاع ژئوپتانسیل (gph) و باد مداری (zw) برای عرض های جغرافیایی $12/56^{\circ}$ تا $43/25^{\circ}$ شمالی و طول جغرافیایی $19/68^{\circ}$ تا $61/88^{\circ}$ شرقی، پنج ترکیب مختلف از داده ها در اطراف هر ایستگاه همدیدی در نظر گرفته شد. علت انتخاب این پنج دسته داده برای انجام مقایسه سه متغیر پیش بینی کننده می باشد.

پنج گروه داده های شبیه سازی شده در نظر گرفته شده به شرح زیر می باشند:

(۱) ترکیب داده های شبیه سازی شده ارتفاع ژئو پتانسیل، باد مداری و بارش (gph, zw, pre).

(۲) ترکیب داده های شبیه سازی شده ارتفاع ژئو پتانسیل، باد مداری (gph, zw).


(۳) داده های شبیه سازی شده ارتفاع ژئو پتانسیل (gph).

(۴) داده های شبیه سازی شده باد مداری (zw).

(۵) داده های شبیه سازی شده بارش (pre).

گروه داده های ساخته شده ورودی تحلیل مؤلفه های اصلی قرار گرفتند. تحلیل مؤلفه های اصلی بر پایه ماتریس همبستگی انجام شد. چند مؤلفه اصلی نخست که بیشترین سهم واریانس را داشتند به عنوان مؤلفه اصلی نگریسته شدند. با گزینش آستانه حذف سایر مؤلفه ها از محاسبات بعدی حذف شدند (۹).

از آنجا که در بیشتر مواقع در همه ایستگاه ها شش مؤلفه اصلی اول بخش بسیار بزرگی از کل واریانس داده ها را در بر می گیرد،



شکل ۱- گره داده های شبیه سازی شده بارش در اطراف ایستگاه بوشهر

جدول ۲- درصد فراوانی واریانس اولین مؤلفه اصلی ماه های سرد سال در ایستگاه بوشهر برای پنج دسته داده ورودی به PCA

| ایستگاه بوشهر | | | | | درصد فراوانی اولین مؤلفه اصلی در ماه های سرد سال |
|-------------------------|--------|-------|------|--------|--|
| گروه داده های ورودی PCA | ژانویه | فوریه | مارس | نوامبر | دسامبر |
| gph, zw, pre | ۲۶ | ۲۷/۴ | ۳۲/۳ | ۲۸/۲ | ۲۰/۷ |
| gph, zw | ۲۶/۸ | ۲۸/۵ | ۳۳/۶ | ۲۹/۳ | ۲۱/۶ |
| gph | ۴۷/۴ | ۵۱/۶ | ۵۹ | ۵۱/۱ | ۴۱/۲ |
| zw | ۴۳ | ۳۸/۹ | ۳۶/۹ | ۳۵/۶ | ۳۹/۷ |
| pre | ۶۹/۶ | ۶۴/۴ | ۶۰/۵ | ۷۴/۶ | ۷۶ |

ضریب همبستگی پیرسون بین داده های بارش دیده بانی

و پیش بینی شده خروجی شبکه عصبی مصنوعی

ضریب همبستگی پیرسون بین داده های بارش دیده بانی و پیش بینی شده خروجی شبکه عصبی مصنوعی در مقیاس های زمانی ماهانه و فصلی در همه ایستگاه ها برای پنج گروه داده های شبیه سازی شده آورده شده در قسمت های قبل، محاسبه شد. نتایج به دست آمده به عنوان نمونه برای ایستگاه بوشهر در ماه های سرد سال در دوره ۲۰۰۱-۲۰۰۵ در جداول ۳ و ۴ آورده شده است. با توجه به جداول ۳ و ۴، به طور نمونه در ماه ژانویه ایستگاه بوشهر مشاهده می شود که معنی داری در سطح ۵٪ بین داده های بارش و داده های پیش بینی شده توسط داده های شبیه سازی شده ارتفاع ژئوپتانسیل در گروه ۳، باد مداری در گروه ۴ و بارش در گروه ۵ در دوره ۲۰۰۵-۲۰۰۱ وجود دارد. با توجه به اینکه مقدار R^2 برای هر یک از گروه

پیش بینی به صورت ماهیانه و فصلی برای همه ایستگاه ها و برای پنج گروه داده های شبیه سازی شده به طور جداگانه انجام شد. تعداد تکرار ها ۲۰ مرتبه قرار داده شد. نتایج به دست آمده توسط شبکه عصبی برای پنج گروه داده های ورودی در دوره آزمون ۲۰۰۵-۲۰۰۱ با یکدیگر مقایسه شد. بهترین مقدار ضریب همبستگی بین داده های دیده بانی شده و پیش بینی شده بارش نشان دهنده این است که مجموعه داده های ورودی شبیه سازی شده به شبکه عصبی قابلیت پیش بینی بهتری نسبت به دیگر داده های شبیه سازی شده در ایستگاه و مقیاس زمانی مورد نظر دارند. برای گروه داده های شبیه سازی شده با ضریب همبستگی معنی دار، معیار R^2 در نظر گرفته شد. بزرگترین مقدار R^2 به دست آمده برای هر یک از گروه داده های شبیه سازی شده، نشان دهنده بهترین پیش بینی است که توسط شبکه عصبی به دست می آید.

توسط شبکه عصبی در ماه ژانویه ایستگاه بوشهر توسط مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ارتفاع ژئوپتانسیل با NRMSE برابر ۰/۲۲۵ به دست می آید.

داده های شبیه سازی شده نام برده به ترتیب ۸۹/۶۸، ۷۷/۹۶ و ۸۸/۱۷ درصد به دست آمد و مقدار R^2 برای داده های شبیه سازی شده ارتفاع ژئوپتانسیل بزرگتر می باشد، بنابراین بهترین پیش بینی

جدول ۳- ضریب همبستگی پیرسون بین داده های بارش دیده بانی و پیش بینی شده خروجی شبکه عصبی در ایستگاه بوشهر در ماه های سرد


سال برای دوره ۲۰۰۵-۲۰۰۱

| ضریب همبستگی پیرسون | گروه ۱ | گروه ۲ | گروه ۳ | گروه ۴ | گروه ۵ |
|---------------------|--------------|---------|--------|--------|--------|
| ایستگاه بوشهر | gph, zw, pre | gph, zw | gph | zw | pre |
| ژانویه | ۰/۷۴۲ | ۰/۷۷۳ | ۰/۹۴۷ | ۰/۸۸۳ | ۰/۹۳۹ |
| فوریه | ۰/۸۱۱ | ۰/۳۸۶ | ۰/۸۴۹ | ۰/۸۳۳ | ۰/۶۶۷ |
| مارس | ۰/۹۶۶ | ۰/۰۹ | ۰/۵۳ | ۰/۸۵۷ | ۰/۵۱۴ |
| نوامبر | ۰/۸۱ | ۰/۸۴۵ | ۰/۷۸۴ | ۰/۴۸۱ | ۰/۰۰۶ |
| دسامبر | ۰/۱۹۷ | ۰/۹۷۳ | ۰/۸۲۸ | ۰/۶۴۲ | ۰/۱۷۱ |

جدول ۴- p-مقدارها بین داده های بارش دیده بانی و پیش بینی شده خروجی شبکه عصبی در ایستگاه بوشهر در ماه های سرد سال برای دوره

۲۰۰۵-۲۰۰۱

| p-مقدارها | گروه ۱ | گروه ۲ | گروه ۳ | گروه ۴ | گروه ۵ |
|---------------|--------------|---------|--------|--------|--------|
| ایستگاه بوشهر | gph, zw, pre | gph, zw | gph | zw | pre |
| ژانویه | ۰/۱۵۱ | ۰/۱۲۶ | ۰/۰۱۵ | ۰/۰۴۷ | ۰/۰۱۸ |
| فوریه | ۰/۰۹۶ | ۰/۵۲۱ | ۰/۰۶۹ | ۰/۰۸ | ۰/۲۱۹ |
| مارس | ۰/۰۰۸ | ۰/۰۳۷ | ۰/۳۵۸ | ۰/۶۴ | ۰/۳۷۵ |
| نوامبر | ۰/۰۹۶ | ۰/۰۷۱ | ۰/۷۱۱ | ۰/۴۱۲ | ۰/۹۹۳ |
| دسامبر | ۰/۷۵۱ | ۰/۰۰۵ | ۰/۰۸۳ | ۰/۲۶ | ۰/۷۸۳ |



شکل ۲- داده های مشاهده و پیش بینی شده بارش در ماه ژانویه با استفاده از شبکه عصبی بر پایه داده های شبیه سازی شده ارتفاع ژئوپتانسیل برای ایستگاه بوشهر در دوره ۲۰۰۵-۲۰۰۱

در دوره ۲۰۰۵-۱۹۶۰ انجام شد و مؤلفه های اصلی معنی دار شناسایی شدند. به عنوان نمونه مؤلفه های معنی دار در رگرسیون چندگانه برای ایستگاه بوشهر در ماه های سرد سال در جدول ۵ آورده شده است.

سپس با توجه به اینکه هدف مقایسه مدل رگرسیون چند گانه و شبکه عصبی می باشد، پیش بینی های انجام شده توسط رگرسیون چندگانه برای دوره آزمون ۲۰۰۵-۲۰۰۱ برای گروه داده های شبیه سازی شده با مؤلفه های اصلی معنی دار مورد بررسی قرار گرفت و ضریب همبستگی بین سری های زمانی داده های دیده بانی و پیش بینی شده بارش به دست آمد. به عنوان نمونه نتیجه به دست آمده در ماه های سرد سال برای ایستگاه بوشهر در جدول ۶ آورده شده است. با توجه به جدول ۶ مشاهده می شود که در ماه ژانویه در ایستگاه بوشهر در دوره ۲۰۰۵-۲۰۰۱ داده های ورودی همه گروه ها بررسی شده اند و بهترین پیش بینی با توجه به بیشترین مقدار ضریب همبستگی توسط رگرسیون چند گانه با استفاده از داده های شبیه سازی شده ترکیبی ارتفاع ژئوپتانسیل و باد مداری به دست آمده است. همچنین مقادیر R^2 و NRMSE به ترتیب برابر با ۸۴/۰۱ و ۰/۳۴۳ درصد می باشد.

سری زمانی داده های مشاهده و پیش بینی شده بارش برای دوره آزمون ۲۰۰۵-۲۰۰۱ در ماه ژانویه ایستگاه بوشهر در شکل ۲ آورده شده است. به همین ترتیب در دیگر ایستگاه ها نیز در مقیاس های زمانی ماهانه و فصلی مناسب ترین دسته داده های شبیه سازی شده برای بهترین پیش بینی توسط شبکه عصبی در دوره ۲۰۰۵-۲۰۰۱ انتخاب گردید.

رگرسیون چند گانه بر پایه تحلیل مؤلفه های اصلی

پس از انتخاب شش مؤلفه های اصلی، رگرسیون چند گانه بر روی مؤلفه های اصلی استاندارد شده انجام شد و مؤلفه ها در سطح معنی داری ۵٪ مشخص شدند. متغیر پاسخ بارش دیده بانی شده و متغیر های پیش بینی کننده بارش، باد مداری و ارتفاع ژئوپتانسیل شبیه سازی شده می باشند. این آزمون برای بررسی مؤلفه های اصلی معنی دار در هر یک از پنج گروه داده های شبیه سازی شده ذکر شده می باشد. رگرسیون چند گانه نشان می دهد که کدامیک از گروه داده های شبیه سازی شده می تواند بهترین پیش بینی را در مقایسه با شبکه عصبی مصنوعی در دوره ۲۰۰۵-۲۰۰۱ در هر ایستگاه در مقیاس های زمانی مورد مطالعه داشته باشد. رگرسیون چند گانه بر روی پنج گروه داده های شبیه سازی شده

جدول ۵- PC های معنی دار در رگرسیون چند گانه برای ایستگاه بوشهر در ماه های سرد سال برای پنج گروه داده شبیه سازی شده در دوره


۱۹۶۰-۲۰۰۵

| داده های ورودی | گروه ۱ | گروه ۲ | گروه ۳ | گروه ۴ | گروه ۵ |
|----------------|--------------|----------|----------|----------|--------|
| ماه | gph, zw, pre | gph, zw | gph | zw | pre |
| ژانویه | Pc2, PC5 | Pc2, PC5 | Pc3, PC6 | PC3, PC4 | PC6 |
| فوریه | - | - | - | - | - |
| مارس | - | - | - | - | PC2 |
| نوامبر | Pc3, PC4 | Pc3, PC4 | PC2 | Pc3 | - |
| دسامبر | PC3 | PC3 | PC2 | - | - |

جدول ۶- ضریب همبستگی داده های دیده بانی و شبیه سازی شده بارش برای گروه داده های شبیه سازی شده با PC های معنی دار در

رگرسیون چند گانه برای ایستگاه بوشهر در ماه های سرد سال در دوره ۲۰۰۵-۲۰۰۱

| داده های ورودی | گروه ۱ | گروه ۲ | گروه ۳ | گروه ۴ | گروه ۵ |
|----------------|--------------|---------|--------|--------|--------|
| ماه | gph, zw, pre | gph, zw | gph | zw | pre |
| ژانویه | ۰/۹۰۷ | ۰/۹۱۶ | ۰/۷۲۴ | ۰/۸۰۸ | ۰/۸۸۷ |
| فوریه | - | - | - | - | - |
| مارس | - | - | - | - | -۰/۱۲۴ |
| نوامبر | ۰/۷۶۴ | ۰/۷۵۵ | ۰/۸۳۲ | ۰/۰۲ | - |
| دسامبر | ۰/۸۸۹۶ | ۰/۸۸۹۷ | ۰/۷۳۸ | - | - |



شکل ۳- داده های مشاهده و پیش بینی شده بارش در ماه ژانویه با استفاده از رگرسیون چند گانه بر پایه داده های شبیه سازی شده ترکیبی ارتفاع ژئوپتانسیل و باد مداری برای ایستگاه بوشهر در دوره ۲۰۰۱-۲۰۰۵

و فوریه مدل رگرسیون چند گانه و در ماه های مارس، نوامبر و دسامبر مدل شبکه عصبی مصنوعی توانایی بیشتری در پیش بینی بارش در دوره ۲۰۰۱-۲۰۰۵ نشان دادند. مدل شبکه عصبی مصنوعی در ایستگاه های اهواز، بندر عباس و بوشهر در تمام ماه ها توانایی پیش بینی بیشتری نسبت به مدل رگرسیون چند گانه در دوره ۲۰۰۵-۲۰۰۱ دارد. تنها در ماه مارس در ایستگاه اهواز هیچ یک از دو مدل قادر به پیش بینی بارش نبودند. در ایستگاه شیراز در ماه های ژانویه و فوریه مدل شبکه عصبی مصنوعی و در ماه های مارس، نوامبر و دسامبر مدل رگرسیون چند گانه توانایی بیشتری در پیش بینی بارش در دوره ۲۰۰۱-۲۰۰۵ نشان دادند. همچنین در ایستگاه فسا در ماه ژانویه و مارس مدل شبکه عصبی مصنوعی و در ماه های فوریه، نوامبر و دسامبر مدل رگرسیون چند گانه توانایی بیشتری در پیش بینی بارش در دوره ۲۰۰۱-۲۰۰۵ داشتند.

همچنین در فصل زمستان، در همه ایستگاه های آبادان، آباد، اهواز، بندرعباس، بوشهر، شیراز و فسا مدل شبکه عصبی مصنوعی نسبت به مدل رگرسیون چند گانه در دوره آزمون ۲۰۰۱-۲۰۰۵ توانایی بیشتری در پیش بینی بارش دارد. در مقیاس فصلی (فصل زمستان) در مدل شبکه عصبی در ایستگاه های آبادان، اهواز، بندرعباس و فسا پیش بینی های معنی دار بر پایه مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده بارش به دست آمد. همچنین در مدل شبکه عصبی در ایستگاه آباده پیش بینی بارش در فصل زمستان بر پایه مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ترکیب ارتفاع ژئوپتانسیل و باد مداری، در ایستگاه بوشهر

سری زمانی داده های دیده بانی و پیش بینی شده بارش در ماه ژانویه با استفاده از رگرسیون چند گانه بر پایه داده های شبیه سازی شده ترکیبی ارتفاع ژئوپتانسیل و باد مداری برای ایستگاه بوشهر در دوره ۲۰۰۱-۲۰۰۵ در شکل ۳ آورده شده است. به همین ترتیب در دیگر ایستگاه ها نیز در مقیاس های زمانی ماهانه و فصلی مناسب ترین دسته داده های شبیه سازی شده برای بهترین پیش بینی توسط رگرسیون چند گانه در دوره ۲۰۰۱-۲۰۰۵ انتخاب گردید.

مقایسه نتایج رگرسیون چند گانه و شبکه عصبی

مصنوعی در مقیاس های زمانی ماهانه و فصلی

با توجه به اینکه هر یک از مدل های شبکه عصبی و رگرسیون چندگانه نتایج متفاوتی در پیش بینی ها نشان دادند، مقایسه ای بین نتایج دو مدل انجام گرفت. در این مقایسه از ضریب همبستگی پیرسون و معیار R^2 استفاده شد. مدلی که دارای R^2 بزرگتری باشد، توانایی بیشتری در پیش بینی بارش در هر یک از ماه های سرد سال و فصل زمستان خواهد داشت. نتایج به دست آمده از هر دو مدل برای دوره ۲۰۰۱-۲۰۰۵ که در قسمت های ۳-۴-۱ و ۳-۵-۱ به دست آمده بود، مورد بررسی قرار گرفت. نتایج برای همه ایستگاه ها نشان دادند که در مقیاس ماهانه، در ایستگاه آبادان مدل شبکه عصبی مصنوعی در ماه های ژانویه، فوریه و نوامبر و مدل رگرسیون چند گانه در ماه های مارس و دسامبر در دوره آزمون ۲۰۰۱-۲۰۰۵ توانایی بیشتری در پیش بینی بارش دارند. در ایستگاه آباده در ماه های ژانویه

در مقیاس ماهانه (ماه های سرد سال) با استفاده از مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ارتفاع ژئوپتانسیل می باشد. فراوانی تعداد پیش بینی های انجام شده توسط گروه ۱ (داده های شبیه سازی شده ترکیب ارتفاع ژئوپتانسیل، باد مداری و بارش) ۳، توسط گروه ۳ (داده های شبیه سازی شده ارتفاع ژئوپتانسیل) ۵ مرتبه، توسط گروه ۴ (داده های شبیه سازی شده باد مداری) ۱ و توسط گروه ۵ (داده های شبیه سازی شده بارش) ۱ پیش بینی می باشد. همچنین توسط گروه ۲ (داده های شبیه سازی شده ترکیب ارتفاع ژئوپتانسیل و باد مداری) هیچ پیش بینی انجام نگرفت. بنابراین در مقیاس ماهانه (ماه های سرد سال) داده های شبیه سازی شده ارتفاع ژئوپتانسیل و باد مداری در پیش بینی بارش در ایستگاه های مورد بررسی در هر دو مدل رگرسیون چند گانه و شبکه عصبی کارآمدتر می باشند.

در مقیاس فصلی (فصل زمستان) در مدل شبکه عصبی در ایستگاه های آبادان، اهواز، بندرعباس و فسا پیش بینی های معنی دار بر پایه مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده بارش به دست آمد. همچنین در مدل شبکه عصبی در ایستگاه آبادان پیش بینی بر پایه مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ترکیب ارتفاع ژئوپتانسیل و باد مداری، در ایستگاه بوشهر بر پایه مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ارتفاع ژئوپتانسیل و در ایستگاه شیراز بر پایه مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ترکیب ارتفاع ژئوپتانسیل، باد مداری و بارش به دست آمد.

بر پایه مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ارتفاع ژئوپتانسیل و در ایستگاه شیراز بر پایه مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ترکیب ارتفاع ژئوپتانسیل، باد مداری و بارش به دست آمد.

نتیجه گیری

نتایج به دست آمده نشان داد که دقت مدل شبکه عصبی مصنوعی نسبت به مدل رگرسیون چند گانه در مقیاس های ماهانه (ماه های سرد سال) و فصلی (فصل زمستان) در ایستگاه های مورد مطالعه بیشتر است. در مقیاس ماهانه و فصلی برای تمامی ایستگاه ها ۴۱ پیش بینی مورد قبول واقع شد که ۳۱ پیش بینی توسط مدل شبکه عصبی و ۱۰ پیش بینی توسط مدل رگرسیون چند گانه انجام شد. همچنین در مقیاس ماهانه (ماه های سرد سال) بهترین پیش بینی ها توسط مدل شبکه عصبی با استفاده از مؤلفه های اصلی استاندارد شده داده های شبیه سازی شده ارتفاع ژئوپتانسیل می باشد. فراوانی تعداد پیش بینی های انجام شده توسط گروه ۱ (داده های شبیه سازی شده ترکیب ارتفاع ژئوپتانسیل، باد مداری و بارش) ۶ توسط گروه ۲ (داده های شبیه سازی شده ترکیب ارتفاع ژئوپتانسیل و باد مداری) ۶، توسط گروه ۳ (داده های شبیه سازی شده ارتفاع ژئوپتانسیل) ۷، توسط گروه ۴ (داده های شبیه سازی شده باد مداری) ۲ و توسط گروه ۵ (داده های شبیه سازی شده بارش) ۳ پیش بینی می باشد. بهترین پیش بینی های انجام شده توسط مدل رگرسیون چندگانه

منابع

- ۱- البرزی م. ۱۳۸۰. آشنایی با شبکه های عصبی. انتشارات دانشگاه صنعتی شریف. تهران.
- ۲- بابائیان ا، نجفی نیک ز، زابل عباسی ف، حبیبی نوخندان م، ادب ح. و ملبوسی ش. ۱۳۸۸. ارزیابی تغییر اقلیم کشور در دوره ۲۰۳۶-۲۰۱۰ میلادی با استفاده از ریز مقیاس نمایی داده های مدل گردش عمومی جو ECHO-G. مجله جغرافیا و توسعه. ۱۶: ۱۵۲-۱۳۵.
- ۳- شیروانی ا. و ناظم السادات م. ج. ۱۳۹۱. پهنه بندی بارش در ایران با استفاده از تحلیل مؤلفه های اصلی و تحلیل خوشه ای. مجله تحقیقات منابع آب ایران. (۱) ۸: ۸۵-۸۱.
- ۴- عباسی ف، ملبوسی ش، بابائیان ا، اثمیری م. و برهانی ر. ۱۳۸۹. پیش بینی تغییرات اقلیمی خراسان جنوبی در دوره ۲۰۳۹-۲۰۱۰ میلادی با استفاده از ریز مقیاس نمایی آماری خروجی مدل ECHO-G. نشریه آب و خاک (علوم و صنایع غذایی). (۲۴): ۲۳۳-۲۱۸.
- ۵- کوچکی ع، نصیری م. و کمالی غ. ۱۳۸۶. مطالعه شاخص های هواشناسی ایران در شرایط تغییر اقلیم. مجله پژوهش های زراعی ایران. (۵) ۱: ۱۴۲-۱۳۳.
- ۶- مساح بوانی ع. و مرید س. ۱۳۸۴. اثرات تغییر اقلیم بر جریان رودخانه زاینده رود اصفهان. مجله علوم و فنون کشاورزی و منابع طبیعی. (۹) ۴: ۲۷-۱۷.
- ۷- منهای م. ب. ۱۳۷۷. هوش محاسباتی «جلد اول» مبانی شبکه های عصبی. چاپ اول. انتشارات مرکز نشر پرفسور حسابی.
- ۸- ناظم السادات م. ج، بیگی ب. و امین س. ۱۳۸۲. پهنه بندی بارندگی زمستانه استان های بوشهر، فارس و کهگیلویه و بویر احمد با استفاده از روش تحلیل مؤلفه های اصلی. مجله علوم و فنون کشاورزی و منابع طبیعی. (۷) ۱: ۷۱-۶۱.

- ۹- ناظم السادات م. ج. و شیروانی ا. ۱۳۸۴. پیش بینی دمای سطح آب خلیج فارس با استفاده از رگرسیون چند گانه و تحلیل مؤلفه های اصلی. مجله علوم و فنون کشاورزی و منابع طبیعی. (۹): ۱-۱۱.
- 10- Coulibaly P., Dibike Y.B., and Anctil F. 2005. Downscaling precipitation and temperature with temporal neural networks, *Journal of Hydrology*, 6:483-496.
- 11- Dibike Y.B., and Coulibaly P. 2006. Temporal neural networks for downscaling climate variability and extremes, *Neural Networks*, 19:135-144.
- 12- Ghosh S., and Mujumdar P. P. 2008. Statistical downscaling of GCM simulations to stream flow using relevance vector machine, *Advances in Water Resources*, 31: 132-146.
- 13- Hanrahan G. 2011. *Artificial Neural Networks in Biological and Environmental Analysis*, CRC Press Pub.
- 14- Hewitson B.C., and Crane R.G. 2006. Consensus between GCM climate change projections with empirical downscaling: Precipitation downscaling over South Africa, *International Journal of Climatology*, 26: 1315-1337.
- 15- Junneng L., Tangang F.T., Kang H., Lee W.J., and Seng Y.K. 2010. Statistical downscaling forecasts for winter monsoon precipitation in Malaysia using multi model output variables, *Journal of Climate*, 23: 17-27.
- 16- Karamouz M., Fallahi M., Nazif S., and Rahimi Farahani M. 2009. Long lead rainfall prediction using statistical downscaling and artificial neural networks Modeling, *Civil Engineering*, 6(2): 163-172
- 17- Ramirez M.C.V., Velho H.F.D.C., and Ferreira N. J. 2005. Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region, *Journal of Hydrology*, 301:146-162.
- 18- Smith M. 1993. *Neural Networks for Statistical Modeling*, Van Nostrand Reinhold Pub.
- 19- Tomassetti B., Verdecchia M., and Giorgi F. 2009. NN5: A neural network based approach for the downscaling of precipitation fields – Model description and preliminary results, *Journal of Hydrology*, 367:14-26.
- 20- Tumbo S.D., Mpeta E., Tadross M., Kahimba F.C., Mbillinyi B.P., and Mahoo H.F. 2010. Application of self-organizing maps technique in downscaling GCMs climate change projections for Same, Tanzania, *Physics and Chemistry of the Earth*, 35:608-617.
- 21- Wetterhall F., Halldin S., and Xu C.y. 2005. Statistical precipitation downscaling in central Sweden with the analogue method, *Journal of Hydrology*, 306:174-19.



The Application of ANN for Downscaling GCMs Outputs for Prediction of Precipitation in Across Southern Iran

N. Ahmadi Baseri¹- A. Shirvani^{2*}- M.J. Nazemosadat³

Received: 11-04-2013

Accepted: 29-09-2014

Abstract

In this study, the artificial neural networks (ANNs) and regression models were used to downscale the simulated outputs of the general circulation models (GCMs). The simulated precipitation for 25.18 ° N to 34.51 ° N and 45 ° E to 60 ° E, geopotential height at 850 mb and zonal wind at 200 mb for 12.56° N to 43.25° N and 19.68° E to 61.87° E data sets as the predictors were extracted from ECHAM5 GCM for the period 1960-2005. The observed monthly precipitation data of Abadan, Abadeh, Ahwaz, Bandar Abbas, Bushehr, Shiraz and Fasa stations as the predictand were extracted for the period 1960-2005. The principal components (PCs) of the simulated data sets were extracted and then six PCs were considered as the input file of the ANN and multiple regression models. Also the combinations of the simulated data sets were used as the input file of these models. The periods 1960-2000 and 2001-2005 were considered as the train and test data in the ANN, respectively. The Pearson correlation coefficient and normalized root mean square error results indicated that ANN predicts precipitation more accurate than multiple regression. For the monthly time scale, the geopotential height is the best predictor and for the seasonal time scale (winter) the simulated precipitation is the best predictor in ANN based standardized precipitation principal components.

Keywords: Precipitation, Across Southern Iran, Downscaling, Artificial Neural Networks, General Circulation Model

1, 2, 3- MSc Student, Assistant Professor and Professor Department of Water Engineering and the Oceanic and Atmospheric Research Center, College of Agriculture, Shiraz University, Respectively
(* - Corresponding Author Email: am_shirvani@hotmail.com)