

پیش‌بینی بلندمدت بارش با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی جنوب غرب ایران)

• ابراهیم فتاحی، • عبدا... صداقت کردار

اعضای هیات علمی پژوهشکده هواشناسی

• مجید دلاور

دانشجوی دکترای آبیاری

تاریخ دریافت: آبان ماه ۱۳۸۵ تاریخ پذیرش: آبان ماه ۱۳۸۶

Email: fatahi@yahoo.com

چکیده

در این مقاله اثرات سیگنال‌های بزرگ مقیاس اقلیمی بر روی بارش‌های کوتاه مدت و بلند مدت ناحیه جنوب غرب ایران مورد بررسی قرار گرفت. سیگنال‌های بزرگ مقیاس اقلیمی یکی از عواملی هستند که می‌توانند در تحلیل تغییرات فصلی و سالانه بارش موثر باشند. در این تحقیق از داده‌های ماهانه سیگنال‌های بزرگ مقیاس اقلیمی نظیر شاخص نوسان جنوبی (SOI)، نوسان اطلس شمالی (NAO) و پدیده ENSO در مناطق NINO3.4, NINO3, NINO4 و NINO 1+2 استفاده شد. تمامی داده‌های مربوط به سیگنال‌های فوق از مرکز داده‌های آنالیز شده NCEP طی سال‌های ۱۹۶۰ تا ۲۰۰۳ دریافت گردید. به منظور تعیین موثرترین سیگنال‌ها بر بارش ناحیه جنوب غرب ایران از روش رگرسیون چند متغیره استفاده شد. نتایج تحلیل رگرسیونی نشان داد که پدیده ENSO در مناطق NINO1+2، NINO3، NINO3.4 و به عنوان موثرترین سیگنال در پیش‌بینی بارش ناحیه جنوب غرب ایران می‌باشند. پس از شناسایی سیگنال‌های موثر با استفاده از مدل شبکه عصبی مصنوعی، بارش برای بازه‌های همزمان، سه ماهه و شش ماه آینده پیش‌بینی شد. تحلیل نتایج مدل شبکه عصبی مصنوعی با داده‌های مشاهده‌ای نشان داد که فازهای گرم ENSO با دوره‌های پر بارش و فازهای سرد ENSO با دوره‌های کم بارشی در منطقه مورد مطالعه همراه است.

کلمات کلیدی: پیش‌بینی بارش، شبکه عصبی مصنوعی، شاخص نوسان جنوبی (SOI)، نوسان اطلس شمالی (NAO)، انسو (ENSO)، جنوب غرب ایران

Pajouhesh & Sazandegi No:80 pp: 44-50

Long- range precipitation prediction using artificial neural networks

By: Ebrahim Fattahi, Faculty Member, Atmospheric Science, A.Sedaghatkerdar, Faculty Member, Atmospheric Science, Majid Delavar, Meteorological Research Center, Tehran, Iran.

In this paper, the effects of large scales climate signals on the low and high precipitation Spells in the southwestern part of Iran are investigated. Large scales climate signals are parameters that can play the important role on analysis variations of seasonal and annual precipitation. In this study monthly southern oscillation index (SOI), North Atlantic Oscillation (NAO) and ENSO index were applied in NINO4, NINO3, NINO1+2, NINo3.4 were used respectively. All data of above signals received from center analyzed data (NCEP) during 1960 to 2003. In order to determine the rate of importance of these parameters on quantity of precipitation was used multivariate regression method. Results of regression analysis show that ENSO index in zone of NINO1+2, NINO3 and NINo3.4 strong correlations with the variations of precipitation. In this study long- Range precipitation prediction for the time period, 3 and 6 months was done. Analysis of artificial neural network model results in comparisons with observations show that the warm phases of ENSO are accompanied with more rainy periods and, cold phases of ENSO with less rainy periods.

Key words: Precipitation prediction, Artificial Neural Networks, Southern oscillation Index (SOI), North Atlantic Oscillation (NAO), ENSO, Southwestern Iran.

مقدمه

پیش آگاهی از میزان بارش یک مسئله تعیین کننده و دارای اهمیت در بهره برداری از سیستم‌های منابع آب، کشاورزی و غیره است. تصمیم‌گیرندگان منابع آب نیاز به پیش‌بینی‌های مطمئنی برای تصمیم‌گیری‌های مدیریتی دارند. در این بین روش‌های پیش‌بینی مختلفی سعی در تعیین ارتباط بین متغیرهای مستقل و وابسته داشته‌اند؛ و مدل‌های مفهومی و آماری زیادی برای پیش آگاهی و پیش بینی متغیرهای اقلیمی مورد استفاده قرار گرفته است. بطور کلی پیش‌بینی‌ها را می‌توانیم در چهار دسته خیلی کوتاه‌مدت، کوتاه‌مدت، میان‌مدت و بلندمدت تقسیم کرد. پیش‌بینی‌های خیلی کوتاه مدت شامل پیش‌بینی‌های کمتر از یک روز می‌باشد، پیش‌بینی کوتاه مدت اغلب دارای افق زمانی در حد روز می‌باشند و به منظور هشدار سیل و بهره‌برداری از زمان واقعی سیستم‌های منابع آب به کار می‌روند. در مقابل پیش‌بینی‌های بلند مدت دارای افق زمانی بیش از یک هفته تا یک سال می‌باشند و برای مدیریت منابع آب، کشاورزی و سایر فعالیت‌ها کاربرد دارند. اصولاً دقت و صحت پیش‌بینی‌ها با زمان رابطه عکس دارد و عملاً پیش‌بینی‌های کوتاه مدت از دقت بیشتری برخوردار بوده و آسانتر به دست می‌آیند، روابط ریاضی و فیزیکی این پیش‌بینی‌ها بیشتر مورد توجه قرار گرفته و قابلیت شبیه‌سازی بهتری دارند. در مقابل، پیش‌بینی‌های میان‌مدت و بلندمدت دارای خطای بیشتری بوده و از پیچیدگی‌های بیشتری در مدل‌سازی و شبیه‌سازی برخوردارند. به همین اندازه اهمیت پیش‌بینی‌های میان‌مدت و درازمدت برای اعمال مدیریت‌های صحیح منابع آب و کشاورزی بسیار زیاد می‌باشد. نخستین و بدیهی‌ترین فایده حاصل از پیش‌آگاهی‌های با افق‌های زمانی میان مدت و بلندمدت، کاهش در خسارات خشکسالی می‌باشد. مشاهده تاثیر سیگنال‌های بزرگ مقیاس اقلیمی مانند النینو، لاینیا، شاخص نوسان جنوبی، دمای آب سطح اقیانوس‌ها به عنوان مشاهده جدیدی از تاثیرات اقلیمی، در سال‌های اخیر مورد توجه محققین

مختلف در بهبود پیش آگاهی‌های میان‌مدت و بلندمدت قرار گرفته است. در این رابطه Priestley و Troup رابطه بین بارندگی استرالیا و دمای آب اقیانوس را در مناطق ساحلی و اقیانوس آرام مورد بررسی قرار دادند، آن‌ها متوجه شدند که مقادیر انحراف از میانگین دمای سطح آب در مناطق خاصی از گستره‌های آبی می‌تواند تغییرات آب و هوایی و نوسانات بارندگی در مناطق دور و نزدیک را توجیه نماید (۱۳). Torranin امکان پیش آگاهی طولانی مدت خشکسالی را با استفاده از ضرایب همبستگی چندگانه مورد مطالعه قرار داد (۱۸).

Ropelewski و Halpert (۱۵) نشان دادند که لاینیا تاثیر متفاوتی بر بخش‌های مختلف آفریقا دارد، به طوری که وقوع این پدیده در نواحی استوای شرقی آفریقا طی دوره‌ای؛ که لاینیا از ماه نوامبر شروع شده و تا ماه مارس سال بعد ادامه می‌یابد، با بارندگی‌های کمتر از حد نرمال مواجه می‌شوند. در حالی که مناطق جنوب شرقی آفریقا در زمان مشابه و تا ماه آوریل میزان بارندگی بیشتر از حد نرمال دریافت می‌کنند. Schonher و Nicholson ارتباط بین بارندگی سالانه کالیفرنیا و ENSO را تحلیل نمودند، تحقیقات آن‌ها حکایت از همزمانی عمده سال‌های مرطوب با رخداد ENSO در این ایالت داشت (۱۷). در تحلیلی دیگر Redmond و Roy ارتباط بارش، دما و رواناب غرب آمریکا را با سیگنال‌های بزرگ مقیاس بررسی کردند؛ نتایج آن‌ها نشان داد که بارش اکتبر تا مارس این مناطق بیشترین همبستگی را با متوسط SOI ماه‌های جولای تا نوامبر داشته است، همچنین آن‌ها نتیجه گرفتند که همبستگی رواناب با SOI همانند بارش می‌باشد (۱۴).

Allen و همکاران، Kripalani و Kulkarani بر این نکته تاکید می‌کنند که ENSO از مهم‌ترین پدیده‌های شناخته شده‌ای است که ناشی از واکنش‌های متقابل اقیانوس- جو و خشکی بوده و تغییرات اقلیمی در مقیاس سالانه در سطح کره زمین را موجب می‌گردد، وقوع دو پدیده متوالی

محاسبه همبستگی بین این دو متغیر استفاده کرد. این روش برای تعیین همبستگی بین دو متغیر که ارتباط آن‌ها در طول زمان ثابت نبوده و تغییر نماید مناسب می‌باشد (۵). کوره‌پزان در تحقیقی تأثیر سیگنال‌های بزرگ مقیاس اقلیمی نظیر ENSO, NAO و SST را برای پیش‌آگاهی تغییرات بارش مناطق جنوبی ایران مورد استفاده قرار داد. وی از قوانین فازی برای توسعه مدل پیش‌آگاهی بارش سیستم استنتاج^۲ فازی استفاده کرد، نتایج این مدل، SST خلیج فارس و دریای عمان را به عنوان بهترین پیش‌بینی کننده بارش سالانه و فصلی منطقه نشان داد، همچنین برای پیش‌آگاهی بارش پاییزه در هر دو حالت پربارش و کم بارش و NAO برای پیش‌بینی بارش زمستانه در حالت پر بارش مناسب تشخیص داده شد (۴). عراقی نژاد و کارآموز با استفاده از مفهوم تولید مجموعه‌ای از پیش‌بینی‌ها و تفکیک مدل سازی برای متغیرهای اقلیمی و هیدرولوژیکی، از مدل‌های مفهومی برای پیش‌بینی بلند مدت حجم جریان رودخانه زاینده رود استفاده کردند. نتایج تحقیق آن‌ها نشان داد که رویکرد ارائه شده علاوه بر دقت قابل قبول در پیش‌بینی نقطه ای و بلند مدت جریان، امکان پیش‌بینی به صورت مجموعه‌ای از جریان‌های ممکن را نیز فراهم می‌آورد که در برنامه‌ریزی و مدیریت منابع آب با در نظر گرفتن عدم قطعیت پیش‌بینی‌ها، حائز اهمیت است (۲).

هدف از این مطالعه، بررسی سیگنال‌های بزرگ مقیاس اقلیمی و ارتباط آن‌ها با بارش نواحی جنوب غرب ایران بر اساس این روش شبکه عصبی مصنوعی می‌باشد. تا بر اساس شناخت رفتار متغیر بارش نسبت به پدیده‌های فوق از نتایج آن در جهت بهبود پیش‌آگاهی و پیش‌بینی بارش در جنوب غرب ایران استفاده نماییم.

روش کار داده‌ها

در این تحقیق از داده‌های ماهانه سیگنال‌های بزرگ مقیاس اقلیمی نظیر شاخص نوسان جنوبی SOI، شاخص NAO و پدیده ENSO در مناطق NINO3, NINO3.4, NINO2+ و NINO4 استفاده شد. تمامی داده‌های فوق از مرکز داده‌های بازسازی شده NCEP طی سال‌های ۲۰۰۳-۱۹۶۰ دریافت شد. داده‌های مربوط به مجموع بارش ماهانه ایستگاه‌های مورد مطالعه نیز از سال ۱۹۶۰ تا ۲۰۰۳ از مرکز خدمات ماشینی سازمان هواشناسی تهیه گردید. برای تعیین مهمترین سیگنال‌های موثر در میزان بارش ایستگاه‌ها از رگرسیون چند گانه به روش گام به گام استفاده شد. در این روش متغیرها به ترتیب وارد معادله می‌شوند و با ورود متغیر جدید کلیه متغیرهای موجود در معادله مورد بررسی قرار می‌گیرند و اگر هر کدام از آن‌ها سطح معنی داری خود را از دست داده باشند، قبل از ورود متغیر جدید این متغیر از معادله خارج می‌گردد، در پایان عملیات متغیرهایی که دارای سطح معنی داری کمتری از سطح تعیین شده داشته باشند، در معادله حضور نخواهند داشت. بدین ترتیب سیگنال‌های موثر در میزان بارش به ترتیب اهمیت آن‌ها مرتب می‌شوند. در جدول شماره (۱) سیگنال‌های هواشناسی موثر در پیش‌بینی همزمان، سه ماهه و شش ماهه مندرج شده است. همان‌طوری که مشاهده می‌شود شاخص ENSO در مناطق NINO1+2 و NINO3 و NINO3.4 پر اهمیت‌ترین سیگنال در بارش منطقه جنوب غرب ایران می‌باشند.

ENSO تابع قانون زمانی مشخصی نبوده و دوره برگشت‌های آن در فواصل زمانی ۲ تا ۱۰ سال مشاهده شده است (۶، ۹). مطالعات Chiew و همکاران در مورد بررسی ENSO با بارندگی استرالیا در تایید کارهای قبل نشان می‌دهد که همبستگی همراه با تاخیر بین SOI و بارندگی فصلی استرالیا وجود دارد و بهترین همبستگی‌ها در دو حالت وجود دارد، حالت اول مربوط به ارتباط بین متوسط SOI ماه‌های جون و جولای با متوسط بارندگی بهار (سپتامبر، اکتبر و نوامبر) در قسمت شرق استرالیا و حالت دوم مربوط به ارتباط بین متوسط SOI ماه‌های آگوست، سپتامبر، اکتبر و نوامبر با متوسط بارندگی تابستانه در بخش شمال شرق استرالیا است (۷). Nicholson و Seluto تأثیر لائینا را بر بارش آفریقا با استفاده از روش‌های مونیکی بررسی نموده‌اند (۱۲). Trenbeth و Caron تحلیل دوباره بر روی الگوهای فشار سطح دریا، دمای سطح دریا و بارش با توجه به تغییرات SOI انجام دادند. استدلال آن‌ها این بود که در سال‌های اخیر با توجه به توسعه اندازه‌گیری پارامترهای جوی توسط ماهواره‌ها، شرایط اقیانوس‌ها را بهتر از سال‌های قبل می‌توان به تصویر کشاند (۱۹).

در سال‌های اخیر مدل‌های عددی و آماری زیادی جهت پیش‌بینی وضعیت ENSO توسعه داده شده است. به عنوان مثال Mason و Giliani سعی کرده‌اند با استفاده از روش‌های مختلف آماری تغییرات این پدیده را به صورت احتمالی پیش‌بینی و نتایج حاصله را با هم مقایسه کنند. بررسی‌های آن‌ها نشان داد که با استفاده از مدل‌های توسعه داده شده می‌توان النینو و لائینا را پیش‌بینی کرد (۱۱). در این میان پیش‌بینی لائینا بهتر و با اطمینان پذیری بیشتری صورت گرفته است. Marioti و همکاران رابطه تغییرات باران‌های اروپا و ENSO را بررسی کردند؛ نتایج به دست آمده توسط آن‌ها، بیانگر تأثیر معنی‌دار ENSO بر بارش‌های اروپا می‌باشند. آن‌ها نشان دادند، اگرچه قدر مطلق تغییرات بارندگی نسبت به مقدار نرمال آن در این مناطق در مقایسه با نواحی استوایی کمتر است، اما این تغییرات به خصوص در نواحی اطراف مدیترانه به طور مستقیم با پدیده ENSO در ارتباط می‌باشند. در نواحی غرب مدیترانه در فصول بهار و پاییز بلافاصله بعد و قبل از یک رخداد ENSO، تأثیر این رخداد بر بارندگی فصول مزبور متفاوت است. در اروپای شرقی و مرکزی در زمستان و بهار پس از رخداد یک فاز کامل ENSO مقدار بارش بیشتر از حد نرمال آن مشاهده شده است (۱۰).

در ایران نیز تحقیقاتی در این زمینه انجام شده است. بطوری که استوار ارتباط پدیده النینو با بارش‌های ماهانه ایران را مورد ارزیابی قرار داده است، نتایج تحقیق ایشان نشان می‌دهد که اثرگذاری پدیده النینو بر بارش‌های ایران؛ همزمان با تغییر الگوی فشار در اقیانوس آرام نبوده، بلکه با تاخیر زمانی همراه است. همچنین نتایج تحلیل وی نشان می‌دهد که ضرایب همبستگی بین شاخص نوسانات جنوبی (SOI) با بارش‌های ایران منفی می‌باشد، بطوری که در سال‌های وقوع النینو، بارش سالانه کشور نسبت به میانگین سی ساله افزایش می‌یابد (۱).

عزیزی در مقاله ای النینو و رابطه آنرا با دوره‌های خشکسالی و ترسالی ایران مورد بررسی قرار داده است؛ و اظهار داشتند که ارتباط نسبتاً قوی ای بین بارش سالانه ایران و شاخص نوسان جنوبی (SOI) وجود دارد (۳). ناظم السادات تأثیر ENSO بر بارش‌های پاییزه ایران را مورد بررسی قرار داد، وی SOI را به عنوان یک شاخص جهت پیش‌بینی فصلی در نظر گرفت و برای درک بهتر این ارتباط از روش رگرسیون متوالی^۱ جهت

جدول شماره ۱- تعیین موثرترین سیگنال‌های هواشناسی در میزان بارش جنوب غرب ایران در بازه زمانی ۰، ۳ و ۶ ماهه

NAO	SOI	NINO4	NINO 3/4	NINO3	NINO1+2	مقیاس زمانی پیش‌بینی به ماه	معرف منطقه	نام ایستگاه
	۴		۳	۲	۱*	پیش بینی همزمان	جنوب غرب	آبادان- بوشهر- اهواز
	۲			۳	۱	۳		
			۳	۲	۱	۶		

*- رنک سیگنال‌ها به ترتیب میزان اثرگذاری بر ناحیه بارش

می‌دهد؛ شکل ۱ شبکه عصبی سه لایه پیشرو با الگوریتم انتشار برگشتی را نشان می‌دهد و مدل ریاضی آن به صورت رابطه زیر است.

$$net_j = \sum_{i=1}^n w_{ij} x_j \quad (1)$$

در برخی موارد مقدار ثابتی در هر نرون به عبارت رابطه فوق بنام وزن اریب^۳ نیز افزوده می‌شود که رابطه به صورت زیر درمی‌آید.


$$net_j = \sum_{i=1}^n w_{ij} x_j + b_j \quad (2)$$

هدف اصلی در این تحقیق بررسی امکان پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی براساس کاربرد مستقیم مقدار سیگنال‌های هواشناسی موثر می‌باشد. بدین منظور از جعبه نرم افزاری شبکه عصبی مصنوعی در Matlab استفاده شد. این نرم افزار امکان طراحی، یادگیری و ارزیابی شبکه‌های عصبی مصنوعی را داشته و همچنین دربرگیرنده

پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی

طی سال‌های اخیر در پردازش داده‌ها برای مسائلی که برای آن‌ها راه حل مشخصی موجود نیست، سیستم‌های هوشمند بطور فزاینده‌ای مورد توجه واقع شده است، شبکه‌های عصبی مصنوعی از این مجموعه می‌باشند که با پردازش داده‌های تجربی قانون نهفته در ورای این داده‌ها را استخراج می‌کنند. شبکه‌های عصبی مدل‌های محاسباتی هستند که قادرند رابطه میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌ها که همگی با هم متصل هستند، تعیین نمایند که در آن میزان فعالیت هر یک از این اتصالات توسط داده‌های تاریخی تنظیم می‌شود (فرآیند یادگیری) و در نهایت مدل قادر خواهد بود قوانین مرتبط میان ورودی‌ها و خروجی‌ها را کشف نماید، هر چند این قوانین غیر خطی و پیچیده باشند.

نحوه محاسبات در شبکه‌های عصبی بدین شکل است که ورودی‌های به نرون (X1 تا X2) در اوزان (W1 تا W2) ضرب شده و مجموع نتایج حاصل از هر ورودی پس از اعمال در یک تابع، خروجی نرون را تشکیل



شکل ۱- شبکه عصبی سه لایه پیشرو با الگوریتم انتشار برگشتی (۸).

و MAE برابر صفر و مطابق معادلات زیر محاسبه می‌شوند.

$$RMSE = \sqrt{\frac{\sum_{k=1}^k (x_k - y_k)^2}{k}} \quad (5)$$

$$MAE = \frac{\sum_{k=1}^k |x_k - y_k|}{k} \quad (6)$$

در روابط فوق x_k مقادیر مشاهداتی، y_k مقادیر برآورد شده و K تعداد داده‌ها می‌باشد.

ورودی‌های مدل و دوره‌های آموزش و صحت‌یابی

انتخاب ورودی‌های مدل از مراحل مهم در طراحی شبکه‌های عصبی مصنوعی می‌باشد. مهمترین عامل در انتخاب این ورودی‌ها؛ فیزیک حاکم بر فرآیندی است که می‌خواهیم توسط شبکه‌های عصبی مصنوعی مدل کنیم. در این مطالعه موثرترین سیگنال‌ها (جدول ۱) به عنوان ورودی‌های شبکه عصبی انتخاب شدند و سعی شد که تاثیر فواصل زمانی مختلف در پیش‌آگاهی بارش با استفاده از سیگنال‌های هواشناسی مورد بررسی قرار گیرد. در نهایت داده‌های ورودی به دو دسته تقسیم شدند و ۸۰ درصد آن‌ها در مرحله آموزش و ۲۰ درصد باقی مانده در مرحله صحت‌سنجی مورد استفاده قرار گرفتند.

نتایج

برای تعیین سیگنال‌های موثر از روش رگرسیون چند گانه با روش گام به گام بین مقادیر عددی سیگنال‌ها و میزان بارش، استفاده شد. با توجه به سطح معنی‌داری و ضرایب نرمال هر یک از سیگنال‌ها در برآورد بارش؛ موثرترین آن‌ها در تاخیرهای زمانی همزمان، ۳ و ۶ ماهه مشخص گردید. برای نمونه با توجه به جداول (۲ و ۳) مشاهده می‌شود که شاخص ENSO در مناطق NINO1+2، NINO3، و NINO3.4 و شاخص SOI پر اهمیت‌ترین سیگنال‌ها در بارش ناحیه جنوب غرب ایران می‌باشند. با توجه به سیگنال‌های موثر در هر بازه زمانی سه مدل برای پیش‌بینی بارش با استفاده از شبکه عصبی در نظر گرفته شد.

جدول ۲- تعیین سیگنال‌های موثر بر بارش ماهانه ناحیه جنوب غرب ایران در حالت همزمان

متغیر	ضریب غیر استاندارد (B)	خطای استاندارد	ضریب استاندارد Beta	سطح معنی‌داری
ضریب ثابت	۷۴/۵	۵۳/۳	-	۰/۱۶
NINO1+2	۱۳/۷	۱/۶	۱۰/۱	۰/۰۰
NINO3	-۲۸/۴	۵/۳	-۱/۱	۰/۰۰
NINO3.4	۱۳/۳	۵/۱	۰/۴	۰/۰۱
SOI	-۲/۴	۰/۹۹	-۰/۱	۰/۰۱۶

شبکه‌های متفاوت با قوانین یادگیری مختلف می‌باشد.

بررسی‌های انجام شده نشان می‌دهند، حدود ۹۰ درصد ANNs^۴ که در فرآیندهای هیدرولوژیکی استفاده شده‌اند، شبکه عصبی انتشار برگشتی (BPN)^۵ می‌باشند (۸). در این تحقیق نیز از این شبکه برای پیش‌بینی بارش استفاده شد. از میان توابع محرک یاد شده در فصل قبل تابع Logsig عملکرد بهتری نسبت به سایر توابع نشان داد و به عنوان تابع فعالیت انتخاب گردید.

استاندارد کردن داده‌ها

به منظور جلوگیری از کوچک شدن بیش از حد وزن‌ها در معادله ۳، ورودی‌های ANNs استاندارد شد Sajicomar و همکاران برای استاندارد سازی داده‌ها از رابطه زیر استفاده گردید، که ورودی‌ها را بین ۰/۱ تا ۰/۹ استاندارد می‌نماید (۱۶).

$$N_i = 0.8 \left[\frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right] + 0.1 \quad (3)$$

که در این رابطه N_i = مقادیر استاندارد شده
 X_i = مقادیر واقعی
 X_{\max} = حداکثر مقادیر واقعی
 X_{\min} = حداقل مقادیر واقعی می‌باشند.
 در این مطالعه نیز با استفاده از رابطه ۳ تمامی پارامترهای به کار رفته در شبکه عصبی در دامنه ۰/۱ و ۰/۹ نرمال شدند.

معماری شبکه عصبی و معیارهای ارزیابی عملکرد آن


انتخاب معماری در محاسبات مربوط به شبکه عصبی با روش سعی و خطا می‌باشد که طی آن با استفاده از ارقام مختلف لایه‌های پنهان و نرون‌های مربوط، می‌توان شبکه بهینه را تعیین کرد. هر چه تعداد لایه‌ها و نرون‌ها افزایش یابد، باعث عملکرد بهتر شبکه برای دوره آموزشی می‌شود، اما عملکرد برای دوره آزمون شبکه معمولاً کاهش می‌یابد. این مساله را برازش بیش از حد اطلاق می‌کنند و بدین سبب شبکه با داشتن تعداد زیاد لایه پنهان و نرون‌های مربوطه، بیش از اندازه براساس داده‌های دوره آموزش واسنجی می‌گردد و قدرت انعطاف را برای الگوهای دیگر از دست می‌دهد.

برای ارزیابی عملکرد شبکه‌های عصبی سه معیار ضریب تبیین (R^2) ریشه میانگین مجذور خطا $(RMSE)$ و متوسط قدر مطلق خطا (MAE) بکار گرفته شد. R^2 معیاری بدون بعد و بهترین مقدار آن برابر یک می‌باشد. رابطه شماره ۴ نحوه محاسبه آن را نشان می‌دهد.

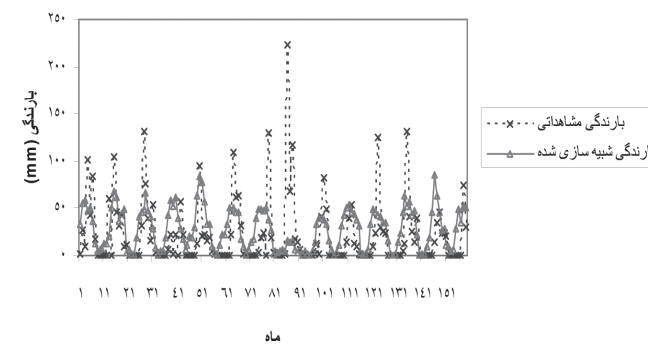
$$R^2 = \frac{\sum_{k=1}^k x_k y_k}{\sqrt{\sum_{k=1}^k x_k^2 \sum_{k=1}^k y_k^2}} \quad (4)$$

ریشه میانگین مجذور خطا $(RMSE)$ و متوسط قدر مطلق خطا (MAE) نیز نشان دهنده میزان خطای مدل می‌باشند. بهترین مقدار برای RMSE

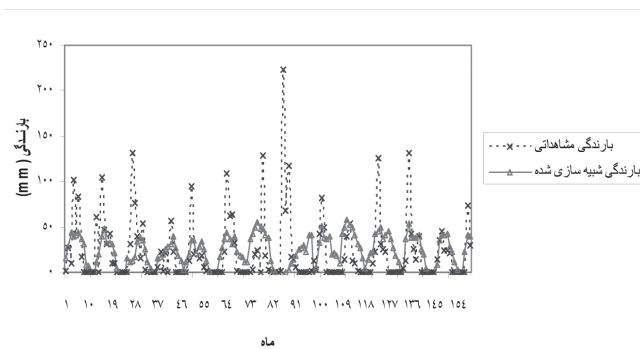
جنوبی به طور همزمان بر بارش‌های جنوب غرب ایران موثر نباشد، بلکه تاثیر آن با تاخیر زمانی و پس از چند ماه بعد مشخص می‌شود. به منظور مقایسه مدل‌های مختلف به کار رفته در تحقیق حاضر و بررسی قابلیت آن‌ها در امر پیش بینی بارش منطقه جنوب غرب ایران، رابطه همبستگی خروجی‌های هر یک از مدل‌ها با داده‌های واقعی محاسبه شد. بدین منظور



شکل ۲- پیش بینی بارش ایستگاه اهواز در حالت همزمان (براساس مدل ۱)



شکل ۳- پیش بینی بارش ایستگاه اهواز برای سه ماه آینده (براساس مدل ۲)



شکل ۴- پیش بینی بارش ایستگاه اهواز برای شش ماه آینده (براساس مدل ۳)

جدول ۵- مقایسه عملکرد مدل‌های پیش بینی بارش در ایستگاه اهواز

مدل	R ²	RMSE	MAE
مدل ۱	۰/۳۸	۲/۵۸	۲۱/۰۳
مدل ۲	۰/۳۹	۲/۶۶	۲۲/۴۵
مدل ۳	۰/۳۰	۲/۶۸	۲۱/۸۸

جدول ۳- تعیین سیگنال‌های موثر بر بارش ماهانه ناحیه جنوب غرب ایران با تاخیر سه ماهه

متغیر	ضریب غیر استاندارد (B)	خطای استاندارد	ضریب استاندارد Beta	سطح معنی داری
ضریب ثابت	-۲۴/۳	۳۶/۸	-	۰/۵۱
NINO1+2	-۱۳/۷	۱/۵	-۱/۰۱	۰/۰۰۰
NINO3	۲۷/۹	۴/۹	۱/۱	۰/۰۰۰
NINO3.4	-۱۳/۳	۴/۲	۰/۴	۰/۰۰۲

جدول ۴- تعیین سیگنال‌های موثر بر بارش ماهانه ناحیه جنوب غرب ایران با تاخیر شش ماهه

متغیر	ضریب غیر استاندارد (B)	خطای استاندارد	ضریب استاندارد Beta	سطح معنی داری
ضریب ثابت	۲۵۲/۶	۳۲/۶	-	۰/۰۰۰
NINO1+2	-۳/۷	۰/۹	-۰/۲۷	۰/۰۰۰
NINO3	-۳/۵	۰/۸	-۰/۲	۰/۰۰۰
NINO3.4	-۵/۷	۱/۸	-۰/۲۴	۰/۰۰۲

مدل ۱: $P_t = f(NINO1.2_t, NINO3_t, NINO3.4_t, SOI_t)$

مدل ۲: $P_{t+3} = f(NINO1.2_t, SOI_t, NINO3_t)$

مدل ۳: $P_{t+6} = f(NINO1.2_t, NINO3_t, NINO3.4_t)$

که در آن‌ها P_t میزان بارش در هر ماه و اندیس‌های $t+3$ و $t+6$ مربوط به پیش بینی میزان بارش سه و شش ماه آینده است. متغیرهای تعریف شده در تابع f نیز معرف مقادیر عددی سیگنال‌های هواشناسی در ماه t می‌باشد.

بحث و نتیجه‌گیری

نتایج بارش شبیه سازی شده توسط مدل در شکل‌های ۲ تا ۴ برای ایستگاه اهواز ارائه شده است. برای مقایسه نحوه عملکرد مدل‌های مطرح شده در پیش بینی بارش مقادیر آن‌ها در جدول ۵ آورده شده است. انتخاب متغیرهای ورودی و تاخیر در نظر گرفته شده دقت نتایج حاصله را نشان می‌دهد، بنابراین برای تعیین بهترین مدل، ورودی‌ها با تاخیرهای مختلف در نظر گرفته شده‌اند و در نهایت مناسب‌ترین مدل که بیشترین دقت پیش بینی را داشته است به عنوان مدل نهایی انتخاب گردید. در مطالعات Chiew و همکاران به منظور بررسی ENSO و اثر آن بر بارش‌های فصلی استرالیا از روش همبستگی همراه با تاخیر استفاده کردند. آن‌ها نتیجه گرفتند که همبستگی با تاخیر نتایج قابل قبول تری بین بارش و ENSO را ارائه می‌دهد، در تحقیق حاضر نیز توزیع ضریب همبستگی در سه حالت همزمان با وقوع بارش، اثر سیگنال‌ها بر بارش سه و شش ماهه آینده مورد بررسی قرار گرفته است. علت به کار بردن چنین شیوه‌ای توجه به فاصله مکانی زیاد بین ایران و مکان اصلی و خاستگاه سیگنال‌های بزرگ مقیاس اقلیمی بوده است، در ضمن فاصله مکانی قابل توجه بین ایران و مکان اصلی این پدیده‌ها، این فرض را تقویت می‌کند که شاخص نوسان

in Southeastern Australia". CSIRO Australia, Division of Water Resources, Report No.96/1.

7. Chiew F. H. S, Piechota T. C., Dracup J. A., and McMahon T. A., (1998) El Nino Southern oscillation and Australian drought: Link and potential for forecasting system Comp. Aided Civ and infrastructure. Enryr., 15(5), 355-364.

8. Coulibaly, P., Anctil, F. and Bobee, B. (2000) Daily reservoir inflow forecasting using artificial neural networks with stopped training approach Journal of Hydrology, 230, 244-257.

9. Kripalani, R. H., and Kulkarani, A. (1997). Rainfall variability over Southern-East Asia, connections with India monsoon and ENSO extremes: new perspective. International Journal of Climatology, 20(1): 47-61.

10. Mariotti, A., Zeng, N. and Lau, K. M. (2002). Euro-Mediterranean rainfall and ENSO-a seasonally varying relationship. South African Journal of Science, 82: 196-198.

11. Mason, S. J., and Gilian, M. M. (2001). Comparison of some statistical methods of probabilistic forecasting of ENSO. Journal of Climate, 15(1): 8-29.

12. Nicholson, S. E., and Selato, J. C. (2000). The influence of La Nina on African rainfall. International Journal of Climatology, 20: 1761-1776.

13. Priestley, C.H.B and Troup, A.J., (1966) Drought and wet periods and their Association with sea surface Temperature Australian Journal of science, 29, 57-76.

14. Redmond, K. T., and Koch, R. W. (1991). Surface climate and streamflow variability in the western United States and their relationship to Large-Scale circulation Indices. Water Resources Research, 27: 2381-2399.

15. Ropelewski, C.F. and M.S. Halpert, (1989) Precipitation Pattern associated with the high index phase of the southern oscillation. Journal of Climate, 2, 268-284.

16. Sajikumar, N., and Thandaveswara, B. S. (1999) Non-linear rainfall-runoff Model using artificial neural network Journal of Hydrology., 216, 32-35.

17. Schonher, T., and Nicholson, S. E. (1989). The relationship between California rainfall and ENSO events. Journal of Climate, 2: 1258-1269.

18. Torranin, P. (1976) "Proceeding of the second international symposium in hydrology Fort Collins, Colorado U. S. A, P: 595-604

19. Trenberth, K. E., and Caron, J. M. (2000). The Southern Oscillation revisited: sea level pressure, surface temperature and precipitation. Journal of Climate, 13: 4358-4365.

ضریب همبستگی به دو صورت استفاده از تمامی سری داده‌ها و در شرایط استفاده از مقادیر حدی بارش محاسبه گردید.

مقایسه نتایج تحقیق حاضر با نتایج مطالعات استوار، عزیزی، ناظم السادات و کوره‌پزان همسو بوده و بر این نکته تاکید می‌کند که:

۱- ارتباط نسبتاً قوی بین بارش سالانه ایران و شاخص نوسان جنوبی (SOI) وجود دارد.

۲- در سال‌های وقوع النینو، مجموع بارش سالانه مناطق جنوب غرب ایران نسبت به میانگین بیشتر می‌باشد.

۳- اثرگذاری پدیده النینو بر بارش‌های ایران؛ همزمان با تغییر الگوی فشار در اقیانوس آرام نبوده، بلکه با تاخیر زمانی همراه است.

۴- انتخاب سیگنال‌های هواشناسی ورودی و تاخیر در نظر گرفته شده دقت نتایج حاصله را نشان می‌دهد. بنابراین برای تعیین بهترین مدل آماری رویکرد مدل سازی ارائه شده در استفاده از روش‌های مفهومی، امکان انجام پیش‌بینی بارش را فراهم آورده است.

۵- مطابق با مدل‌های ارائه شده، سیگنال‌های هواشناسی انتخاب شده می‌تواند به عنوان پیش‌بینی کننده بارش مورد استفاده قرار گیرند و از آن‌ها برای پیش‌آگاهی بلندمدت بارش و در نهایت وضعیت خشکسالی و ترسالی استفاده کرد.

پاورقی‌ها

- 1- Sequential correlation Analysis
- 2- Fuzzy Inference System
- 3- Biase Weiget
- 4- Artigicial Neural Networkes
- 5- Back Propagation Networks
- 6- Rost Mean - Squave Error
- 7- Mean Absolute Error

منابع مورد استفاده

- ۱- استوار میبیدی، الف (۱۳۷۹). ال نینو و رابطه آن با بارش‌های ایران. پایان نامه کارشناسی ارشد جغرافیای طبیعی (هیدرو اقلیم)، دانشگاه تربیت مدرس.
- ۲- عراقی نژاد، شهاب و محمد، کارآموز (۱۳۸۴) پیش‌بینی بلند مدت رواناب با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی مجله تحقیقات منابع آب ایران، شماره ۲، تابستان ۱۳۸۴.
- ۳- عزیزی، قاسم (۱۳۷۹) ال نینو و دوره‌های خشکسالی- ترسالی در ایران، مجله پژوهش‌های جغرافیایی شماره ۳۸، مهرماه ۱۳۷۹.
- ۴- کوره پزان دزفولی، الف (۱۳۸۲). تاثیر سیگنال‌های هواشناسی در پیش‌بینی تغییرات بارش. پایان نامه کارشناسی ارشد، دانشگاه امیر کبیر.
- ۵- ناظم السادات، م، ج، (۱۳۸۰). آیا باران می‌بارد؟ خشکسالی و بارندگی مازاد در ایران و ارتباط آن‌ها با پدیده ال نینو- نوسانات جنوبی. انتشارات دانشگاه شیراز.
6. Allan, R. J., Bread, G. S., Close, A., Herczeg, A. L., Jones, P. D., and Simpson, H. J. (1996). "Mean sea level pressure indices of the El Nino/Southern Oscillation: Relevance to stream discharge