

پیش‌بینی بارش بهاره با استفاده از متغیرهای اقلیمی اقیانوسی - جوی به روش رگرسیون اجزای اصلی (مطالعه موردی: حوضه سد بوکان)

راضیه ترقی دلگرم^۱، مسعود تجریشی^۲

۱- دانش‌آموخته کارشناسی ارشد مهندسی عمران آب، دانشکده مهندسی عمران، دانشگاه صنعتی شریف

۲- استاد گروه مهندسی آب و محیط زیست، دانشکده مهندسی عمران، دانشگاه صنعتی شریف

Razieh.Taraghi@gmail.com

خلاصه

پیش‌بینی بارش برای اهداف مختلفی نظیر برآورد سیلاب، خشکسالی، مدیریت حوضه آبریز، برنامه‌ریزی آب، کشاورزی و ... دارای اهمیت است و ابزار مناسبی در اختیار مدیران قرار می‌دهد تا با در نظر گرفتن این پیش‌بینی‌ها، سیاست‌های آینده را به جهت بهره‌وری حداکثر، طرح‌ریزی کنند. هدف از مقاله حاضر، بررسی ارتباط بارندگی فصلی ایستگاه‌های بارانسنجی وزارت نیرو در یک دوره ۳۴ ساله و شاخص‌های اقلیمی دوربرد و نیز بررسی تأثیر تغییرات دمای آب دریای سرخ، خلیج فارس، مدیترانه و دریای سیاه به عنوان منابع حرارتی بارش‌های شمال غربی ایران بوده و بر این اساس معادلات پیش‌بینی فصلی برای هر ایستگاه به دست آمده است. معادلات ارائه شده ۴۷ درصد تغییرات بارش بهاره را پیش‌بینی نموده‌اند. همچنین دقت مدل‌سازی بارش بهاره در ایستگاه بارانسنجی آلاسق و صفاخانه از سایرین بالاتر می‌باشد که این امر به علت همبستگی بالای شاخص SOI ماه اکتبر با بارش بهاره ایستگاه آلاسق (۰۴۹-۰۳۳) و شاخص WP ماه فوریه با بارش بهاره ایستگاه صفاخانه (۰۲۱-۰۳۳) (-۰.۶) می‌باشد. در این تحقیق، شبکه‌های عصبی مصنوعی نیز به عنوان یک روش کارآمد جهت پیش‌بینی بارندگی مورد استفاده قرار گرفته است. تحلیل نتایج خروجی نشان داد که این مدل توانایی بهتر و دقت بالایی برای پیش‌بینی بارش نسبت به روش‌های آماری معمول داشته‌است.

کلمات کلیدی: پیش‌بینی بارش، متغیرهای اقیانوسی-جوی، رگرسیون اجزای اصلی، شبکه عصبی مصنوعی، سد بوکان

۱. مقدمه

دریاچه ارومیه از نظر منابع آب و محیط زیست یکی از مناطق مهم کشور به حساب می‌آید و پیش‌بینی بارندگی در آن می‌تواند در برنامه‌ریزی مؤثر منابع آب و جلوگیری از خسارات دوره‌های خشکسالی نقش مهمی داشته‌باشد. در این بین روش‌های پیش‌بینی مختلفی سعی در تعیین ارتباط بین متغیرهای مستقل و وابسته داشته‌اند و مدل‌های مفهومی و آماری زیادی برای پیش‌بینی و پیش‌آگاهی متغیرهای اقلیمی مورد استفاده قرار گرفته‌است [۱]. از این میان شبکه‌های عصبی، مدل‌های رگرسیونی خطی و غیرخطی در پژوهش‌های مربوط به بارش به طور موفقیت‌آمیزی مورد استفاده قرار گرفته‌اند.

تأثیر سیگنال‌های بزرگ مقیاس اقلیمی مانند پدیده انسو (ENSO)^۱ که به وسیله شاخص نوسانات جنوبی (SOI)^۲ کمی می‌شود، بر میزان بارش مناطق مختلف جهان به خوبی شناخته شده و به عنوان متغیر پیشگو در پیش‌بینی‌های اقلیمی و هیدرولوژیکی در مناطق مختلف به کار گرفته شده

¹ El-Nino Southern Oscillation Index

² Southern Oscillation Index

است. در رابطه با استفاده از SOI برای پیش بینی های بارندگی و جریان رودخانه می توان به پژوهش کورتیس و همکاران اشاره کرد که در این تحقیق اثر SOI بر دقت پیش بینی ها مشهود می باشد [۲].

اطلاعات مربوط به سیگنال های اقلیمی در پایگاه های اینترنتی مربوط به مراکز فعال در زمینه تغییرات اقلیم^۱، موجود است. برخی از این سیگنال ها که به عنوان شاخص های دمایی شناخته شده اند، نشان دهنده تغییرات دمای سطح آب اقیانوس در محدوده های جغرافیایی مشخص می باشند. برخی دیگر نیز، شاخص های اتمسفری می باشند که تغییرات فشار هوا در سطوح مختلف، مؤلفه های باد (شدت، سرعت و ...) و دیگر مؤلفه های جوی را در نظر می گیرند. داده های SST ماهانه مربوط به تمام پهنه های آبی کره زمین در سایت اینترنتی سازمان فضایی امریکا (NASA) و سازمان هواشناسی و اقیانوس شناسی امریکا (NOAA) موجود است و می توان به آن ها دسترسی داشت.

در دهه های اخیر، شناسایی سیگنال های بزرگ مقیاس اقلیمی، به عنوان پیش بینی کننده های پدیده های هیدرولوژیکی، تحول عظیمی در پیش بینی ها به وجود آورده است. در سالیان اخیر، مدل ها و ابزار پیش بینی هیدرولوژیکی بر پایه روش های آماری و تجربی در کنار مدل های عددی پیشنهاد شده و به عنوان ابزاری برای مدیریت بهتر منابع آب به کار رفته شده اند [۳]. Singh and Borah (۲۰۱۳) از شبکه عصبی برای پیش بینی بارش موسمی تابستانی هند استفاده کردند و به نتایج قابل قبولی دست یافتند [۴]. Mekanik و همکاران (۲۰۱۳) به پیش بینی بلند مدت بارش بهاره در ویکتوریای استرالیا با استفاده از سیگنال های اقلیمی اقیانوس هند دوقطبی (IOD) و النینوی نوسانات جنوبی پرداختند. آن ها با استفاده از تکنیک شبکه عصبی و تجزیه تحلیل رگرسیون چندگانه به این نتیجه رسیدند که در نواحی مرکز و غرب ویکتوریا رگرسیون چندگانه و در نواحی شرق ویکتوریا روش شبکه عصبی نتایج بهتری را ارائه می دهد [۵]. شافعی و همکاران (۲۰۱۱) از شبکه های عصبی مصنوعی برای پیش بینی بارش اسکندریه مصر استفاده کردند. آنها مدل شبکه های عصبی مصنوعی و مدل رگرسیون چند متغیره را باهم مقایسه کردند. نتایج مطالعات آن ها نشان داد که مدل شبکه های عصبی مصنوعی مناسب تر و دقیق تر است [۶]. در ایران نیز تحقیقاتی در این زمینه صورت گرفته است که از این میان می توان به تحقیقات ناظم السادات و کوردی^۲ (۲۰۰۰) اشاره کرد که اثر پدیده انسو را بر بارش پاییزه ایران مورد بررسی قرار دادند. نتایج تحقیقات آنها نشان داد که شاخص نوسانات جنوبی (SOI) دارای همبستگی منفی با بارش پاییزه می باشد و متوسط تابستانه این شاخص، پیش بینی کننده مناسبی برای بارش پاییزه می باشد. همچنین پدیده انسو اثر قابل توجهی بر بارش پاییزه دامنه جنوبی البرز و استان های شمال غرب ایران می گذارد [۷].

فلاح قاهری (۱۳۹۰) به ارزیابی نقش تغییرات سیگنال های اقلیمی بر نوسان های بارش بهاره در استان خراسان رضوی پرداخت. با بررسی همبستگی به دست آمده بین بارش متوسط منطقه ای و سیگنال های هواشناسی شاخص در بازه های زمانی گوناگون، سیگنال های اقلیمی مؤثر بر آب و هوای استان خراسان رضوی مشخص شد که از این سیگنال ها می توان در مدل های پیش بینی بارش و همچنین تشخیص دوره های خشک، تر و نرمال استفاده کرد [۸]. عظیمی و همکاران (۱۳۸۹) با برقراری رابطه رگرسیونی بین حجم جریان ورودی به سد دز و سیگنال های اقلیمی از جمله PDO, SOI و NAO میزان آورد ورودی به سد دز و همچنین میزان بارندگی فصلی را پیش بینی کرده و به نتایج قابل قبولی دست یافتند [۹]. فتاحی و همکاران (۱۳۸۷) با بررسی اثر سیگنال های بزرگ مقیاس اقلیمی بر بارش های کوتاه مدت و بلند مدت در ناحیه جنوب غرب ایران نشان دادند که پدیده انسو در نواحی NINO1+2, NINO3 و NINO3.4 مؤثرترین سیگنال ها برای پیش بینی بارش در ناحیه جنوب غربی ایران هستند [۱۰].

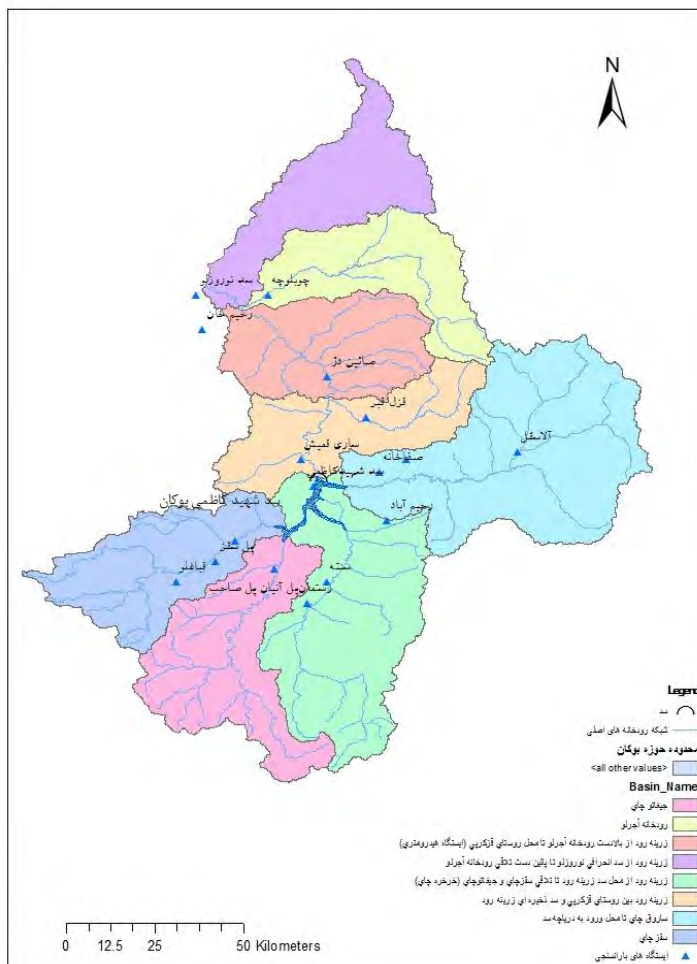
در سال های اخیر، روش های آماری چندمتغیره در موضوعات مرتبط با منابع آب، هیدرولوژی و محیط زیست به طور گسترده ای استفاده شده اند. یکی از این روش ها، روش تحلیل مؤلفه اصلی (PCA) است. روش مؤلفه های اصلی ابزاری ریاضی است که متغیرهای مؤثر را مشخص می کند و هدف اصلی آن تقلیل بعد مساله مورد مطالعه است. یکی از کاربردهای مهم تحلیل مؤلفه های اصلی در رگرسیون است. با استفاده از آن، می توان تعداد زیادی متغیر مستقل همبسته را با تعداد محدودی متغیر توضیحی جدید که مؤلفه های اصلی نامیده می شوند و ناهمبسته اند، جایگزین نمود. به این ترتیب علاوه بر کاهش بعد مساله، چندخطی هم به وجود نمی آید [۱۱]. در یک مقیاس جهانی، توسط محققان مختلف تلاش های زیادی برای پیش بینی بارش با دقت با استفاده از تکنیک های مختلف صورت گرفته است. الگوریتم شبکه های عصبی مصنوعی یک رویکرد استقرایی جالب در پیش بینی بارش با توجه به غیرخطی بودن آن می باشد.

¹ <http://www.esrl.noaa.gov/psd/>
<http://ioc-goos-oopc.org/>
<http://idn.ceos.org>
<http://jisao.washington.edu/>
<http://portal.iri.columbia.edu/>

² Cordery

۲. مواد و روش‌ها

به منظور شناخت نحوه تغییرات بارش در ایستگاه‌های بارانسنجی واقع در حوضه آبریز سد بوکان، از میان مجموع ایستگاه‌های بارانسنجی موجود در حوضه، ایستگاه‌هایی که دارای طول دوره آماری مناسب بوده، شناسایی و انتخاب شدند. این ایستگاه‌ها، در سطح حوضه پراکنده‌گی مناسب دارند. در جدول ۱ مشخصات این ایستگاه‌ها و همچنین در شکل ۱ موقعیت این ایستگاه‌ها نشان داده شده است. طول دوره آماری در نظر گرفته شده برای این ایستگاه‌ها از سال ۵۹-۱۳۵۸ تا سال ۹۲-۱۳۹۱ می‌باشد.



شکل ۱- موقعیت ایستگاه‌های بارانسنجی

جدول ۱- مشخصات ایستگاه‌های بارانسنجی در نظر گرفته شده

ردیف	کد ایستگاه	نام ایستگاه	نوع ایستگاه	طول جغرافیایی		عرض جغرافیایی		ارتفاع متر
				درجه	دقیقه	درجه	دقیقه	
۱	۳۳-۰۱۵	پل آفتاب	تبخیرسنجی	۴۶	۲۵	۳۶	۱۲	۱۴۵۱
۲	۳۳-۰۴۲	رستمان	تبخیرسنجی	۴۶	۳۰	۳۶	۷	۱۶۱۰
۳	۳۳-۰۰۷	چباغلو	تبخیرسنجی	۴۶	۱۰	۳۶	۱۰	۱۵۹۳
۴	۳۳-۰۲۳	ساری قمیش	تبخیرسنجی	۴۶	۲۹	۳۶	۲۸	۱۳۷۴
۵	۳۳-۰۴۹	آلاسقل	تبخیرسنجی	۴۷	۲	۳۶	۲۹	۱۷۱۲
۶	۳۳-۰۰۹	پل سقر	بارانسنجی	۴۶	۱۶	۳۶	۱۳	۱۴۸۸
۷	۳۳-۱۱	دره پنه دان	بارانسنجی	۴۶	۱۹	۳۶	۱۶	۱۴۷۹

ردیف	کد ایستگاه	نام ایستگاه	نوع ایستگاه	طول جغرافیایی		عرض جغرافیایی		ارتفاع متر
				درجه	دقیقه	درجه	دقیقه	
۸	۳۳-۳۰۸	قزل قبر	بارانسنجی	۴۶	۳۹	۳۶	۳۴	۱۹۵۷
۹	۳۳-۱۸	باغچه میشه	بارانسنجی	۴۶	۴۵	۳۶	۲۸	۱۹۰۹
۱۰	۳۳-۲۰	رحیم آباد	بارانسنجی	۴۶	۴۲	۳۶	۱۹	۱۸۳۳
۱۱	۳۳-۲۱	صفاخانه	بارانسنجی	۴۶	۴۱	۳۶	۲۶	۱۶۴۰
۱۲	۳۳-۰۵۸	صائین دژ	بارانسنجی	۴۶	۳۳	۳۶	۴۰	۱۳۴۸
۱۳	۳۳-۰۲۷	چوبلوچه	بارانسنجی	۴۶	۲۴	۳۶	۵۲	۱۳۶۲

پیش بینی بارندگی در یک دوره ۳۴ ساله و در محل ایستگاه‌های بارانسنجی انجام شده است. در جدول ۲ شماتیک متغیرهای وابسته و مستقل در پیش بینی بارش فصلی نشان داده شده است. همان طور که مشخص است متغیرهای مستقل به صورت ماهانه تا ۱۲ ماه پیش از آغاز زمان پیش بینی در نظر گرفته شده‌اند و در نهایت برای فصل بهار یک معادله رگرسیونی در محل ایستگاه‌های بارانسنجی ارائه شده است.

جدول ۲- شماتیک زمانی متغیرهای مستقل و وابسته در پیش بینی بارندگی

فصل	بازه پیش بینی			متغیر مستقل ۱۲ ماه						
	دسامبر	نوامبر	اکتبر	سپتامبر	اگوست	جولای	ژوئن	می	آوریل	مارس
پاییز	دسامبر	نوامبر	اکتبر	سپتامبر	اگوست	جولای	ژوئن	می	آوریل	مارس
زمستان	مارس	فوریه	ژانویه	دسامبر	نوامبر	اکتبر	سپتامبر	اگوست	جولای	ژوئن
بهار	ژوئن	می	آوریل	مارس	فوریه	ژانویه	دسامبر	نوامبر	اکتبر	سپتامبر


۱-۲ سیگنال‌های اقلیمی

در ابتدا، همبستگی بارش فصلی در ایستگاه‌های بارانسنجی منتخب در حوضه را با شاخص‌های اقلیمی مشخص شده در جدول ۳ بررسی می‌کنیم. سیگنال‌های اقلیمی شاخص‌هایی جهت نشان دادن نوسانات پدیده‌های اقلیمی و کمی کردن شدت آن‌ها می‌باشند. در سال‌های اخیر در بسیاری از مناطق دنیا استفاده از سیگنال‌های اقلیمی جهانی نظیر ENSO, PDO و NAO به منظور بررسی نوسانات و پیش‌بینی بارش از استقبال خوبی برخوردار شده است. اطلاعات ماهانه شاخص‌های ذکر شده از طریق وبسایت [Http://jisao.washington.edu](http://jisao.washington.edu) و پایگاه بین‌المللی علوم اقیانوسی-جوی [Http://esrl.noaa.gov](http://esrl.noaa.gov) تهیه شده است.

جدول ۳- سیگنال‌های استفاده شده در این پژوهش

نام خلاصه	نام کامل	معادل فارسی
PNA	Pacific North American Index	شاخص اقیانوس آرام امریکای شمالی
WP	Western Pacific Index	شاخص اقیانوس آرام غربی
NAO	North Ttantic Oscilation	نوسانات اقیانوس اطلس شمالی
SOI	Southern Oscilation Index	شاخص نوسانات جنوبی
ONI	Oceanic NINO Index	شاخص اقیانوسی نینو
TNA	Tropical Northern Atlantic Index	شاخص اقیانوس اطلس شمالی استوایی
TSA	Tropical Southern Atlantic Index	شاخص اقیانوس اطلس جنوبی استوایی
WHWP	Western Hemisphere Warm Pool Index	استخر گرم نیمکره غربی
NINO3.4	East Central Tropical Pacific SST	شاخص دمای سطحی بخش مرکزی اقیانوس آرام استوایی
NINO1+2	Extreme Eastern Tropical Pacific SST	شاخص دمای سطحی شدید بخش شرقی اقیانوس آرام استوایی
NINO4	Central Tropical Pacific SST	شاخص دمای سطحی بخش مرکزی اقیانوس آرام استوایی
PDO	Pacific Decadal Oscilation	نوسانات دهه‌ای اقیانوس آرام
NOI	Northern Oscilation Index	شاخص نوسانات شمالی
AO	Arctic Oscilation	نوسانات قطب شمال (شمالگان)
MEI	Multivariate ENSO Index	شاخص انسو چند متغیره
BEST	Bivariate ENSO Timeseries	سری زمانی انسو دومتغیره

همبستگی میان بارش فصلی ایستگاه‌ها در ۱۳ ایستگاه بارانسنجی با شاخص‌ها به صورت ماهانه و ۱۲ ماه قبل از آغاز فصل بررسی شده است (با تأخیر یک ماه). به عنوان مثال نتایج همبستگی بارش بهاره ایستگاه بارانسنجی صفاخانه (۰۲۱-۳۳) و سیگنال TSA در شکل ۲ آورده شده است. همانطور که در شکل مشخص است، شاخص TSA در ماه‌های سپتامبر، آگوست، جولای و مارس به عنوان پیش‌بینی کننده به مدل اضافه خواهد شد.



شکل ۲- همبستگی بارش بهاره ایستگاه بارانسنجی صفاخانه (۰۲۱-۳۳) و سیگنال TSA

به علاوه ارتباط دمای سطح آب دریای سرخ، دریای سیاه، خلیج فارس و دریای مدیترانه نیز به دلیل اهمیت سامانه‌های بارش زای سودانی و مدیترانه‌ای در بارش‌های حوضه و نیز تأثیر احتمالی دمای سطح آب این نواحی در انتقال رطوبت بررسی شده است. در ادامه با مشخص شدن پارامترهای مؤثر در بارش فصلی در محل ایستگاه‌های بارانسنجی، معادلات رگرسیونی جهت پیش‌بینی بارش فصلی در بهار ارائه شده است.


۲-۱ ارتباط بارش فصلی و دمای سطح آب

با توجه به موقعیت جغرافیایی ایران، می‌توان گفت که بارندگی در حوضه سد بوکان ناشی از فعالیت سیستم‌های بارانزای عرض‌های پایین (سیستم‌های سودانی)، متأثر از تغییرات دمای سطح آب دریای سرخ و خلیج فارس و سیستم‌های بارانزای عرض‌های بالا (سیستم‌های مدیترانه‌ای) و دمای سطح آب در دریای سیاه، مدیترانه و اقیانوس اطلس شمالی می‌باشد (شکل ۳) [۱۲].



شکل ۳- پهنه‌های آبی تأثیرگذار بر میزان بارش و رواناب حوضه‌های آبریز شمال غرب ایران

به طور مثال ارتباط بارش بهاره ایستگاه بارانسنجی صفاخانه (۰۲۱-۳۳) و دمای سطح آب پهنه‌های آبی مجاور در شکل ۴ آورده شده است.



شکل ۴- همبستگی میان بارش بهاره ایستگاه بارانسنجی صفاخانه (۰۲۱-۳۳) و دمای سطح آب پهنه‌های آبی مجاور

همانطور که مشخص است بارش بهاره ایستگاه صفاخانه (۰۲۱-۳۳) با دمای سطح آب مدیترانه شرقی و دریای سیاه ارتباط معکوس دارد به طوری که افزایش دمای سطح آن، موجب کاهش بارش بهاره می‌شود. به علاوه دمای سطح آب دریای سرخ در ماه‌های دسامبر و آوریل، دمای خلیج فارس در ماه نوامبر و همچنین دمای سطح آب مدیترانه شرقی در ماه‌های دسامبر و نوامبر و مدیترانه غربی در ماه اکتبر می‌تواند به عنوان متغیر پیشگو به مدل اضافه گردد.

در ادامه کار علاوه بر مدل رگرسیونی، مدل‌سازی با استفاده از شبکه‌های عصبی نیز انجام شد. مبنای شبکه‌های عصبی مصنوعی، استفاده از دانش نهفته در داده‌ها، تلاش برای استخراج روابط ذاتی بین آن‌ها و تعمیم آن در موقعیت‌های دیگر است. در استفاده از شبکه عصبی مصنوعی سعی می‌شود با آموزش شبکه‌ای پردازشگر، بدون یافتن قانون ریاضی حاکم بر پارامترها، ویژگی‌ها و روابط ذاتی میان متغیرها را به شبکه آموخت. یکی از ویژگی‌های شبکه‌های عصبی مصنوعی که عملکرد آن را به مغز انسان نزدیک‌تر می‌نماید، قدرت یادگیری آن‌هاست. هدف از آموزش این شبکه‌ها تغییر و تنظیم وزن‌های اولیه با توجه به الگوهای آموزشی است تا بتوانند با بدست آوردن رابطه بین ورودی و خروجی برای سایر الگوها نتایج دقیق‌تری ارائه نمایند. در زمان آموزش، ابتدا وزن‌ها به صورت تصادفی انتخاب می‌شوند سپس در یک فرآیند تکراری الگوهای آموزشی یک به یک اعمال شده و میزان خطا یا اختلاف هر خروجی با خروجی مطلوب محاسبه می‌گردد و وزن‌ها تغییر یافته و اصلاح می‌شوند. فرآیند اصلاح وزن‌ها تا زمانی ادامه خواهد یافت که میزان اختلاف به حداقل، کاهش یابد. در این حالت شبکه آموزش دیده و هم‌گرا شده است [۱۳].

در ابتدا به وسیله داده‌های آموزشی به شبکه آموزش داده می‌شود تا رابطه میان ورودی و خروجی را بیابد. سپس به وسیله مجموعه داده‌های آزمایشی صحت خروجی شبکه بررسی می‌گردد. میزان خطای خروجی بایستی از یک مقدار از پیش تعیین شده کمتر باشد. سپس با استفاده از مجموعه داده‌های اعتبار سنجی، تعداد بهینه نرون‌های لایه میانی را تعیین می‌گردد. بدین صورت که در ابتدا این داده‌ها به عنوان ورودی، به شبکه اعمال می‌گردند. سپس روندی مشابه آن‌چه در آموزش شبکه توضیح داده شد، طی می‌شود. نهایتاً آن دسته از نرون‌های لایه میانی که کم‌ترین میزان خطا را ارائه دهند به عنوان واحدهای این لایه در نظر گرفته می‌شوند [۱۴].

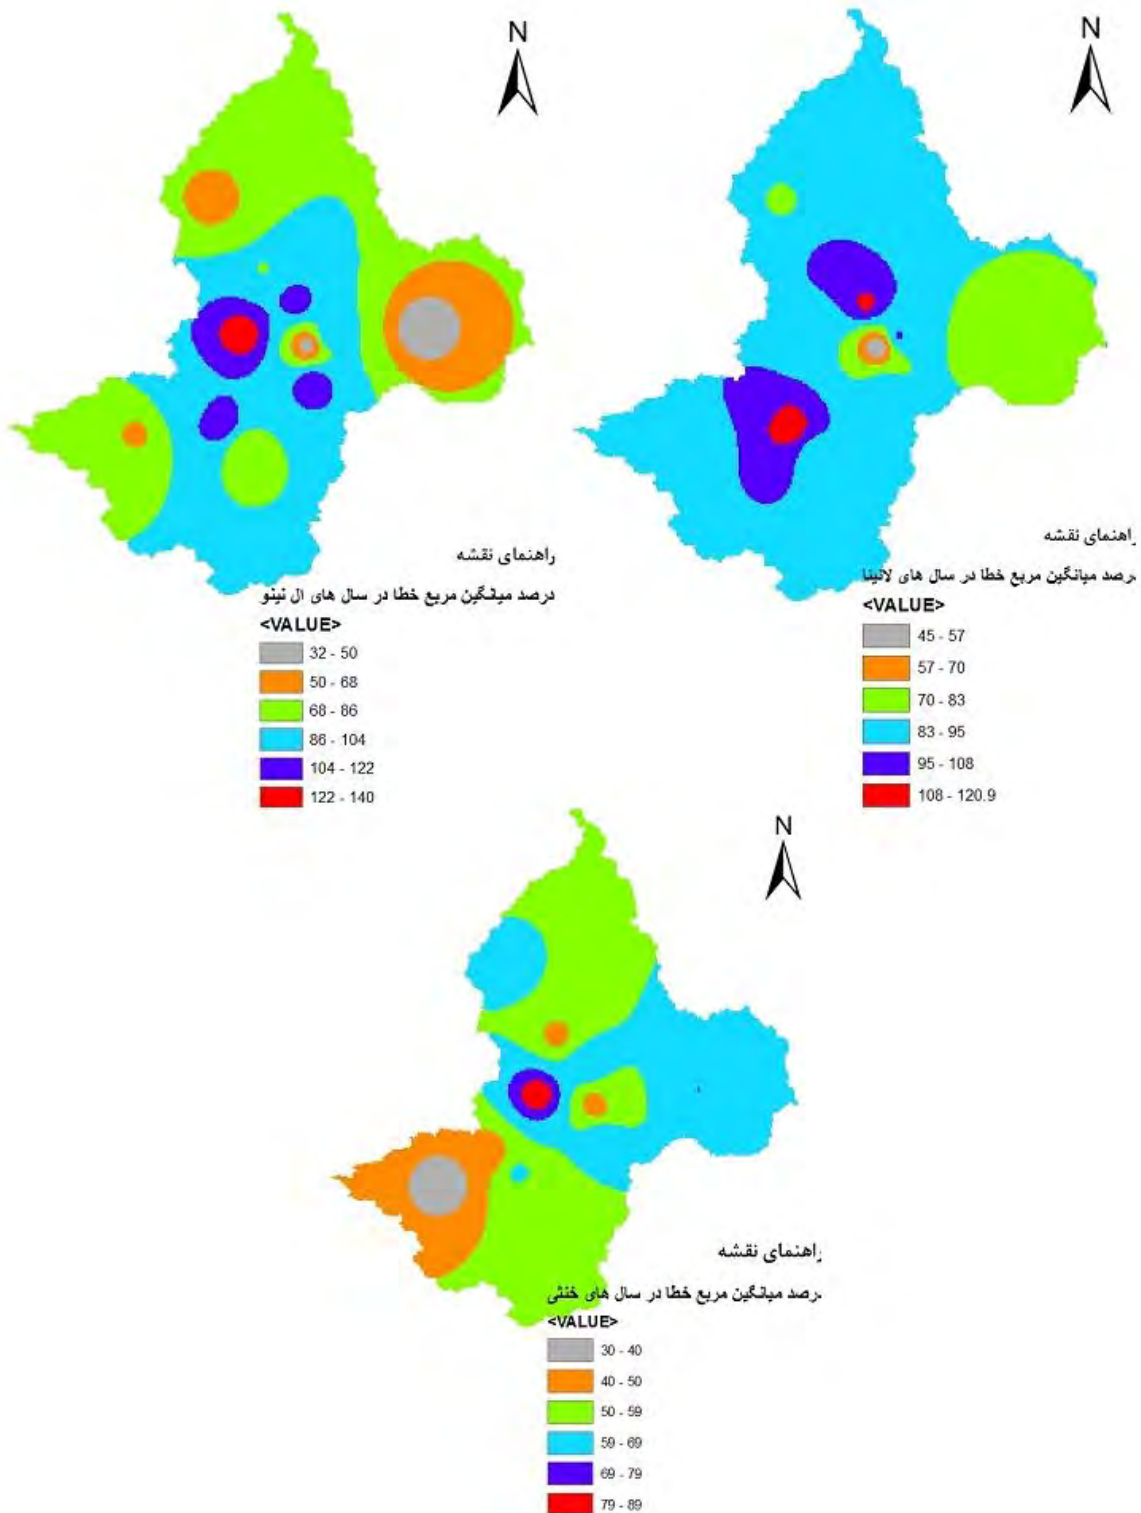
به طور کلی شبکه‌های عصبی به دلیل ویژگی‌ها و مزایای خاصی از جمله یادگیری تطبیقی، خودسازمان‌دهی، پردازش موازی، تحمل خطا، انعطاف‌پذیری و از همه مهم‌تر تعمیم‌پذیری بالا در شبیه‌سازی و مدل کردن مسائل پیچیده کاربری چشم‌گیری دارند. از این رو در دو دهه گذشته کاربرد این مدل در بخش‌های مختلف صنعتی، تجاری، پزشکی و ... افزایش قابل توجهی داشته است. صنعت آب نیز از این روند مستثنی نبوده و از این ابزار محاسباتی در موارد و شرایط مختلف، استفاده کرده است. این روش مدل‌سازی مانند سایر مدل‌ها دارای نقاط ضعفی می‌باشد، بدین منظور برای بالا بردن دقت مدل مذکور از روش‌های مختلف بهینه‌سازی استفاده می‌شود. الگوریتم ژنتیک با بهینه کردن پارامترهای مختلف شبکه عصبی مانند: تعداد لایه‌های پنهان، تعداد نرون‌های موجود در هر لایه، وزن بین نرون‌ها و ... می‌تواند میزان دقت و در برخی شرایط میزان سرعت عمل مدل شبکه‌های عصبی را به طور چشم‌گیری افزایش دهد. لازم به ذکر است که در این حالت، احتمال دستیابی به نقطه بهینه مطلق بسیار بالا است [۱۴].

۳. بحث و نتایج

معادلات پیش‌بینی بارش بهاره در محل ایستگاه‌های بارانسنجی در جدول ۴ آورده شده است. در شکل ۵ نیز الگوی توزیع مکانی درصد میانگین مربع خطا به تفکیک سال‌های ال نینو، لائینا و خنثی آورده شده است. مقادیر شاخص‌های صحت سنجی بارش بهاره به تفکیک روش رگرسیون و شبکه عصبی نیز در جدول ۵ آورده شده است.

جدول ۴- معادلات پیش‌بینی بارش بهاره

توضیحات	معادله پیش‌بینی بارش بهاره	ایستگاه بارانسنجی
	$Y = -18.294 (SOI-Oct) - 49.222 (TSA-Jun) - 20.576 (WP-Feb) + 146.141$	آلاسقل
$X_1 =$ دمای سطح آب دریای سرخ در محدوده (۳۵.۶-۴۱.۳) شرقی و (۲۰-۱۶.۲) شمالی در ماه جولای $X_2 =$ دمای سطح آب مدیترانه شرقی در محدوده (۱۳.۱-۳۳.۸) شرقی و (۳۵.۲-۳۱.۴) شمالی در ماه سپتامبر $X_5 =$ دمای سطح آب دریای سیاه در محدوده (۲۸.۱-۳۹.۴) شرقی و (۴۴.۸-۴۲.۹) شمالی در ماه آگوست $X_7 =$ دمای سطح آب خلیج فارس در محدوده (۲۹.۵-۲۳.۸) شرقی و (۵۴.۴-۴۸.۸) شمالی در ماه آوریل $X_8 =$ دمای سطح آب خلیج فارس در محدوده (۲۹.۵-۲۳.۸) شرقی و (۵۴.۴-۴۸.۸) شمالی در ماه آگوست	$Y = -11.778 X_1 - 10.32 X_2 - 5.266 (WP-Feb) - 11.956 (TSA-July) - 5.266 X_5 - 4.295 (TSA-Oct) - 3.286 X_7 - 10.146 X_8 + 1301.5$	پل آنیان
	$Y = -93.531 (TSA-April) - 99.79 (TSA-Aug) + 163.768$	باغچه‌میشه
$X_2 =$ دمای سطح آب خلیج فارس در محدوده (۲۹.۵-۲۳.۸) شرقی و (۵۴.۴-۴۸.۸) شمالی در ماه آگوست $X_3 =$ دمای سطح آب مدیترانه شرقی در محدوده (۱۳.۱-۳۳.۸) شرقی و (۳۵.۲-۳۱.۴) شمالی در ماه فوریه	$Y = 29.818 (NAO-April) - 35.35 X_2 - 60.104 X_3 + 2280.056$	چوبلوچه
$X_1 =$ دمای سطح آب دریای سرخ در محدوده (۳۵.۶-۴۱.۳) شرقی و (۲۰-۱۶.۲) شمالی در ماه دسامبر $X_3 =$ دمای سطح آب دریای سیاه در محدوده (۲۸.۱-۳۹.۴) شرقی و (۴۴.۸-۴۲.۹) شمالی در ماه مارس	$Y = -25.303 X_1 - 61.607 (TSA-July) - 22.841 X_3 + 843.735$	دره پنبه‌دان
$X_4 =$ دمای سطح آب مدیترانه غربی در محدوده (۰-۱۳.۱) شرقی و (۴۲.۹-۳۷.۱) شمالی در ماه سپتامبر	$Y = -20.857 (NAO-Dec) - 18.202 (WP-Sep) - 56.399 (TSA-Aug) + 20.831 X_4 - 332.68$	قبقلو
$X_7 =$ دمای سطح آب خلیج فارس در محدوده (۲۹.۵-۲۳.۸) شرقی و (۵۴.۴-۴۸.۸) شمالی در ماه جولای	$Y = -56.117 X_1 + 2081.531$	قزل قبر
	$Y = -4.119 (AO-Feb) + 7.461 (NINO1+2-Nov) - 6.258 (NAO-Feb) - 4.323 (SOI-Jan) - 7.224 (SOI-July) - 25.046 (TSA-Aug) - 18.876 (TSA-Sep) - 3.075 (WP-Feb) - 38.963$	رحیم‌آباد
$X_2 =$ دمای سطح آب دریای سرخ در محدوده (۳۵.۶-۴۱.۳) شرقی و (۲۰-۱۶.۲) شمالی در ماه آگوست $X_3 =$ دمای سطح آب دریای سرخ در محدوده (۳۵.۶-۴۱.۳) شرقی و (۲۰-۱۶.۲) شمالی در ماه نوامبر	$Y = -23.73 (WP-Feb) - 55.412 X_2 - 44.087 X_3 - 61.218 (TSA-April) + 2952.287$	رستمان
	$Y = -6.903 (NOI-Dec) - 73.002 (TSA-Oct) + 109.868$	صائین دژ
	$Y = -39.561 (WP-Feb) - 90.328 (TSA-July) - 26.329 (WP-Sep) + 172.101$	صفاخانه
	$Y = -131.887 (TSA-Aug) + 141.456$	ساری قمیش
$X_2 =$ دمای سطح آب خلیج فارس در محدوده (۲۹.۵-۲۳.۸) شرقی و (۵۴.۴-۴۸.۸) شمالی در ماه آگوست	$Y = -47.679 (NINO1+2-Jan) - 55.414 X_2 - 44.008 (AO-July) + 3208.835$	پل سقر



شکل ۴- الگوی توزیع مکانی درصد میانگین مربع خطا به تفکیک سال های النینو، لانینا و خنثی- بارش بهاره - رگرسبون

جدول ۵- مقادیر شاخص های صحت سنجی بارش بهاره

شبکه عصبی	رگرسیون											
	MSE		RMSE		MSE		MAD		SE		R square	بارش بهاره
	صحت سنجی	کالیبراسیون	صحت سنجی	کالیبراسیون	صحت سنجی	کالیبراسیون	صحت سنجی	کالیبراسیون	صحت سنجی	کالیبراسیون		
آلاسقل	۰.۱۰۹	۰.۱۰۶	۱.۲	۰.۶۳	۱.۴۴	۰.۳۹	۱.۰۲	۰.۴۸	۰.۳	۰.۱۸	۰.۶۶	
باغچه‌میشه	۰.۱۲	۰.۰۹۲	۱.۵۸	۰.۶۸	۲.۴۹	۰.۴۷	۱.۴۵	۰.۵۱	۰.۳۹	۰.۱۹	۰.۵۹	
چوبلوچه	۰.۰۱	۰.۰۵۱	۱.۳۲	۰.۶۶	۱.۷۴	۰.۴۴	۱.۱۷	۰.۵۴	۰.۴۳	۰.۱۷	۰.۵۹	
دره پنبه دان	۰.۰۹۲	۰.۰۶۲	۱.۴۴	۰.۶۷	۲.۰۷	۰.۴۵	۱.۳۳	۰.۵۳	۰.۲۵	۰.۱۹	۰.۶	
قیقلو	۰.۱۳	۰.۱۳	۰.۷۲	۰.۸۶	۰.۵۲	۰.۵۸	۰.۶۲	۰.۵۸	۰.۴۶	۰.۱۹	۰.۴۸	
قزل قبر	۰.۰۸۳	۰.۰۹۲	۰.۹۵	۰.۹۸	۰.۹۱	۰.۹۶	۰.۸۸	۰.۷۷	۰.۲۸	۰.۱۹	۰.۲۵	
رستمآن	۰.۱۲	۰.۰۹	۰.۸۵	۰.۸۱	۰.۷۳	۰.۶۵	۰.۷	۰.۶۷	۰.۲۳	۰.۱۹	۰.۴۵	
رحیم آباد	۰.۱۱	۰.۰۶	۱.۱۴	۰.۹۶	۱.۳	۰.۹۲	۰.۹۵	۰.۷۳	۰.۴	۰.۱۹	۰.۳	
صائین دژ	۰.۱	۰.۰۹	۰.۸۸	۰.۸۵	۰.۷۸	۰.۷۲	۰.۷۴	۰.۶۷	۰.۳۶	۰.۱۹	۰.۴۱	
صفاخانه	۰.۱	۰.۰۸	۰.۷۱	۰.۶۳	۰.۵	۰.۴	۰.۵۸	۰.۵۲	۰.۱۸	۰.۲	۰.۶۶	
پل آتیان	۰.۱	۰.۰۹	۱.۱	۰.۹۶	۱.۲	۰.۹۱	۱.۰۷	۰.۸۲	۰.۱۶	۰.۱۸	۰.۲۹	
ساری قمیش	۰.۱۲	۰.۱	۱.۳۹	۰.۹۳	۱.۹۲	۰.۸۶	۱.۳۲	۰.۷۵	۰.۲۸	۰.۲	۰.۳۴	
پل سقز	۰.۱۷	۰.۱۵	۰.۲۱	۰.۷۸	۰.۰۵	۰.۶۱	۰.۱۸	۰.۶۹	۰.۳۱	۰.۳۳	۰.۵۵	
میانگین	۰.۱	۰.۰۹	۱.۰۴	۰.۷۹	۱.۲	۰.۶۴	۰.۹۲	۰.۶۴	۰.۳۱	۰.۱۹	۰.۴۷	

۴. نتیجه‌گیری

همانطور که در جدول ۵ مشخص است، معادلات ارائه شده ۴۷ درصد تغییرات بارش بهار را پیش بینی نموده‌اند. همچنین دقت مدل سازی بارش بهاره در ایستگاه بارانسنجی آلاسقل و صفاخانه از سایرین بالاتر می‌باشد؛ که این امر به علت همبستگی بالای شاخص SOI ماه اکتبر با بارش بهاره ایستگاه آلاسقل (-0.6)، شاخص WP ماه فوریه با بارش بهاره ایستگاه صفاخانه (-0.6)، ذکر نمود.

در این پژوهش سعی شده علاوه بر در نظر گرفتن پدیده‌های ENSO، PDO، NAO و تأثیر دیگر شاخص‌های اقلیمی که در مطالعات قبلی در این منطقه در نظر گرفته نشده، همچنین تأثیر تغییرات دمای سطح آب منابع حرارتی مؤثر در بارش فصلی حوضه بوکان، مورد بررسی قرار گیرد. نتایج نشان داد که تغییرات دمای سطح آب مدیترانه شرقی در مدل سازی بارش بهاره حوضه مؤثر بوده است. در نهایت از روش شبکه عصبی آموزش داده شده توسط الگوریتم ژنتیک برای مقایسه دقت روش رگرسیونی و شبکه عصبی، استفاده شد. نتایج نشان داد که روش شبکه عصبی می‌تواند روشی کارآمد برای پیش بینی بارش فصلی حوضه بوکان باشد. با توجه به اینکه مدل رگرسیونی با استفاده از روند خطی مقادیر را پیش بینی می‌کند، می‌تواند دقت پیش بینی را کاهش دهد.

۵. مراجع

1. غیاث آبادی فراهانی، ف. فتاحی، ا. مقیمی، ش.، (۱۳۹۲)، پیش‌بینی بارش جنوب دریاچه ارومیه بر اساس سیگنال‌های اقلیمی با شبکه عصبی مصنوعی. دومین کنفرانس بین‌المللی مخاطرات محیطی، تهران، ۹.
2. Curtis, S., Piechota, T.C., and Dracup, J.A. (2001). *Evaluation of tropical and extratropical precipitation anomalies during the 1997-1999 ENSO cycle*. Int. J. Climatol. 21: 961-971
3. عظیمی، م (۱۳۸۹). پیش بینی بلندمدت بارش فصلی و جریان رودخانه به کمک منطقه‌ای کردن متغیرهای اقلیمی اقیانوسی و جوی. پایان نامه کارشناسی ارشد. دانشگاه صنعتی شریف. تهران.
4. P Singh and B Borah, (2013), *Indian summer monsoon rainfall prediction using artificial neural network*, Stochastic Environmental Research and Risk Assessment, 1436-3240.

5. F. Mekanik, M. A. Imteaz (2013). *Analysing lagged ENSO and IOD as potential predictors for long-term rainfall forecasting using multiple regression modelling*, International Congress on Modelling and Simulation, Australia, December 2013.
6. Amr H. El-Shafie, A. El-Shafie, Hasan G. El Mazoghi, A. Shehata and Mohd. R. Taha, 2011, *Artificial neural network technique for rainfall forecasting applied to Alexandria*, Egypt, International Journal of the Physical Sciences Vol. 6(6), pp. 1306–1316.
7. Nazemosadat, M. j., Cordery, I. (2000). *On the relationships between ENSO and autumn rainfall in Iran*. Int. J. Climatol., 20:47-61.
8. فلاح قاله‌ری. غ، ارزیابی نقش تغییرات سیگنال‌های اقلیمی بر نوسان‌های بارش بهاره استان خراسان رضوی، مجله فیزیک زمین و فضا، دوره ۳۷، (۱۳۹۰)، ۳: ۱۷۱-۱۵۵.
9. عظیمی، م. تجربی، م و ابریشم چی، ا. (۱۳۸۹). *پیش بینی آورد فصلی سد دز با استفاده از سیگنال‌های بزرگ مقیاس اقلیمی*، نهمین کنفرانس هیدرولیک ایران، دانشگاه تربیت مدرس، ۸ ص.
11. فتاحی، ا. صداقت کردار، ع.، دلاور، م.، (۱۳۸۷)، *پیش‌بینی بلندمدت بارش با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی جنوب غربی ایران)*. نشریه پژوهش و سازندگی در منابع طبیعی، ۸۰: ۴۴-۵۰.
11. Liu C.W., Lin K.H. and Kuo Y.M. (2003). *Application of factor analysis in the assessment of groundwater quality in a blackfoot disease area in Taiwan*, Science of the Total Environment, 313: 77-89.
12. ترقی دلگرم، ر (۱۳۹۴). *پیش بینی بلندمدت بارش فصلی و جریان رودخانه به کمک متغیرهای اقلیمی اقیانوسی و جوی (مطالعه موردی: سدبوکان)*. پایان نامه کارشناسی ارشد. دانشگاه صنعتی شریف. تهران.
13. منہاج، م. ب.، (۱۳۸۱)، "مبانی شبکه‌های عصبی"، چاپ دوم، انتشارات دانشگاه صنعتی امیرکبیر.
14. Brabazon, A., and O'Neill, M., (2006), *Biologically Inspired Algorithms for Financial Modelling*, Series: Natural Computing Series, Publisher: Springer, Pages: 275.