

پیش‌بینی خشک‌سالی با استفاده از شبکه‌ی عصبی مصنوعی،

مطالعه‌ی موردی: ایستگاه شیراز

محمود خسروی*، دانشیار گروه جغرافیای طبیعی و اقلیم‌شناسی، دانشگاه سیستان و بلوچستان
مریم نصیری، کارشناسی ارشد اقلیم‌شناسی در برنامه‌ریزی محیطی، دانشگاه سیستان و بلوچستان
دکتر سید علی اکبر صفوی، دانشیار مهندسی سیستم‌ها و کنترل، دانشگاه شیراز
نرجس پور جعفریان، کارشناسی ارشد برق کنترل، دانشگاه شیراز

چکیده

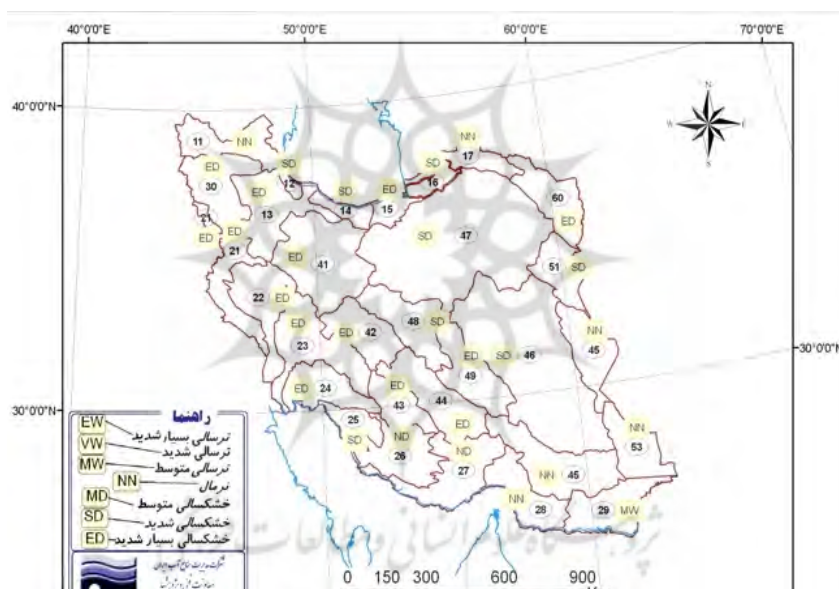
در این پژوهش برای پیش‌بینی خشک‌سالی در شهرستان شیراز از شبکه‌ی عصبی مصنوعی به عنوان یک روش کارآمد که شبیه‌سازی خشک‌سالی را براساس داده‌های واقعی به‌دست می‌آورد، استفاده گردیده است. در ابتدا برای تحلیل ارتباط میان خشک‌سالی با شاخص‌های پیوند از دور و عناصر اقلیمی در مقیاس‌های زمانی متفاوت از روش همبستگی استفاده گردید. با استفاده از روش همبستگی مناسب‌ترین متغیرها در مقیاس زمانی انتخاب شد. در مرحله‌ی بعدی با استفاده از مدل شبکه‌های عصبی مصنوعی پرسپترون چند لایه و متغیرهای چون شاخص‌های پیوند از دور و عناصر اقلیمی مؤثر به عنوان ورودی شبکه عصبی و مقادیر شاخص خشک‌سالی SPI که نمایش کمی خشک‌سالی می‌باشد، به عنوان خروجی شبکه عصبی مصنوعی، اقدام به پیش‌بینی خشک‌سالی‌های منطقه شیراز گردید. براساس نتایج به‌دست آمده در پیش‌بینی پیوسته ۱ و ۳ ماهه خشک‌سالی، شاخص‌های پیوند از دور، $Nino_1+2$, $Nino_3$, $Nino_4$ و عناصر اقلیمی بیشینه‌ی دما، کمینه‌ی دما، بیشینه‌ی رطوبت نسبی، کمینه‌ی رطوبت نسبی و بارش، موجب بهبود نتایج مدل‌ها گردید. در پیش‌بینی فصل زمستان از میان شاخص‌های پیوند از دور، شاخص NAO زمستانه و از میان عناصر اقلیمی بارش زمستانه، بیشینه رطوبت نسبی زمستانه و بیشینه دما زمستانه، بهترین نتایج را با کمترین خطا و بیشترین ضریب همبستگی ارائه داده‌اند. در بررسی روش‌های الگوریتم ژنتیک و پرندگان نسبت به الگوریتم پس انتشار نتایج تفاوت فاحشی را نشان نداد، لیکن در انتخاب بهینه‌ترین ساختار شبکه که نهایتاً منجر به کارایی بهتر شبکه جهت پیش‌بینی خشک‌سالی می‌شود؛ روش‌های الگوریتم ژنتیک و پرندگان هوش جمعی کارآمد می‌باشد.

واژگان کلیدی

خشک‌سالی، پیش‌بینی، شبکه عصبی مصنوعی، پرسپترون چند لایه، شاخص‌های پیوند از دور، عناصر اقلیمی.

۱- مقدمه

خشک‌سالی یکی از بلاهای طبیعی و اقلیمی و از جمله رخدادهای مصیبت‌باری است که هر ساله خسارت‌های قابل ملاحظه‌ای را به زندگی انسان و اکوسیستم‌های طبیعی در سراسر جهان به وجود می‌آورد. خشک‌سالی را در یک دوره‌ی زمانی، با میزان بارش کمتر از حد معمول همان منطقه می‌دانند که این پدیده منجر به وارد آمدن زیان‌های فراوانی به منطقه از طریق کاهش آب‌های زیرزمینی، کاهش رطوبت خاک، کاهش سریع جریان‌های سطحی و همچنین از بین رفتن محصولات زراعی می‌شود و در نتیجه تبعات اجتماعی را نیز به دنبال دارد. کشور ایران به دلیل موقعیت جغرافیای خاص و قرار گرفتن در کمربند بیابانی کره زمین، در بسیاری از مناطق خود دارای نزولات جوی ناچیز و کمتر از حد متوسط می‌باشد، بنابراین بروز خشک‌سالی گسترده و مداوم از ویژگی‌های اقلیمی این مناطق می‌باشد که بررسی این پدیده و به ویژه، پیش‌بینی آن دارای اهمیت فراوانی است. (پاپلی یزدی، ۱۳۷۸: ۱۸۶) خشک‌سالی نشانه‌ی روشنی از نوسانات اقلیمی است. بررسی علمی پدیده خشک‌سالی به منظور برنامه‌ریزی و مدیریت منابع آب و مقابله با مشکلات ناشی از کمبود آب ضروری می‌باشد. (مساعدی و همکاران، ۱۳۸۷: ۸).



شکل ۱- نقشه‌ی خشک‌سالی در سال آبی ۸۶-۸۷ (پایگاه اطلاع‌رسانی سامانه‌ی خشک‌سالی ۱۳۸۹).

با توجه به شکل ۱ نقشه‌ی پهنه‌بندی خشک‌سالی کشور ایران در سال آبی ۱۳۸۶-۱۳۸۷، منطقه‌ی شماره ۴۳ مربوط به ناحیه طشک، بختگان و مهارلو واقع در شهرستان شیراز است که خشک‌سالی‌های شدیدی را متحمل شده‌اند. شهرستان شیراز در استان فارس از جمله مناطقی در کشور است که گرفتار این بلیه طبیعی است و هر ساله خسارت‌های زیادی را به محصولات کشاورزی و اقتصاد منطقه وارد می‌نماید. یکی از مشکلات مهم در زمینه‌ی مواجهه با این پدیده آگاهی از رفتار و پیش‌بینی اقلیمی آن است. با توجه به علل متفاوت تأثیرگذار بر این پدیده، پیش‌بینی آن بسیار مشکل است. امروزه استفاده از روش‌های آماری معمول به دلیل عدم کفایت آمار و اطلاعات موجود، دقت پایین و خطای بالا که پیش‌بینی‌هایی با همبستگی پایینی ارائه نمودند، کاهش یافته است. بنابراین به‌کارگیری مدل شبکه‌ی عصبی که با در نظر گرفتن کلیه اطلاعات

موجود، توانایی خوبی در پیش‌بینی نیز دارند امری واضح است. شبکه‌های عصبی مصنوعی با تجزیه و تحلیل داده‌های ورودی و نتایج نظیر آن‌ها ارتباطی منطقی بین داده‌ها برقرار کرده، سپس با استفاده از این ارتباط منطقی، کار شبیه‌سازی را برای موارد احتمالی مشابه انجام می‌دهند (کوچک‌زاده و بهمنی، ۱۳۸۴: ۸۸). امروزه تحقیقات زیادی در زمینه قابلیت شبکه‌ی عصبی مصنوعی در پیش‌بینی بارش، حداقل و حداکثر دما، ضریب رواناب و خشک‌سالی‌ها انجام شده است. در جنوب شرقی کلرادو، سک-شین^۱ و همکارانش در سال (۲۰۰۰)، با استفاده از داده‌های بارش سالانه استاندارد شده، به وسیله‌ی شبکه عصبی پرسپترون چند لایه، به بررسی شدت خشک‌سالی در این منطقه پرداخته‌اند. تحلیل آماری از شدت خشک‌سالی منطقه‌ای مهم‌ترین موضوع در این پژوهش بوده است و با استفاده از نتایج شبکه‌ی عصبی به تهیه‌ی نقشه‌های شدت خشک‌سالی منطقه‌ای و بیان الگوی مکانی فضای خشک‌سالی پرداخته شده است.

برای بالا بردن دقت، مقصود^۲ و همکارانش (۲۰۰۴)، قابلیت شبکه‌ی عصبی مصنوعی برای پیش‌بینی آب و هوا در جنوب ساسکاچوان کانادا بررسی نموده‌اند. هدف در این پژوهش مقایسه‌ای بین شبکه‌ی عصبی پرسپترون چند لایه، شبکه عصبی بازگشت‌المان، شبکه عصبی رادیال بیس و مدل‌های فیلد می‌باشد. ورودی‌ها شامل داده‌های میانگین فصلی دما، سرعت باد، میانگین فصلی رطوبت نسبی می‌باشد که برای پیش‌بینی فصلی زمستان، بهار، تابستان، پاییز استفاده گردیده است. در میان مدل‌های به کار رفته نتایج عملی نشان می‌دهد که مدل‌های فیلد نسبتاً دارای دقت کمتری نسبت به دیگر مدل‌ها می‌باشد و مدل رادیال بیس قابلیت اطمینان بالاتری را برای پیش‌بینی آب و هوا دارا است. ضریب رواناب حوضه‌ی آبریز نیمه خشک نوتواین در بوتسوانای شرقی با استفاده از شبکه‌های عصبی مصنوعی و الگوریتم پس انتشار، توسط پاریدا^۳ و همکاران (۲۰۰۶) مورد بررسی قرار گرفت. هدف آن‌ها مدیریت منابع در حوضه آبریز بوده است. آن‌ها نیز معماری شبکه بهینه، انتخاب شایسته بردارهای ورودی، تعداد لایه‌های پنهان و نرون‌ها در لایه پنهان، الگوریتم آموزش و تابع انتقالی مناسب را، دارای اهمیت می‌دانند. آنان ورودی شبکه را عوامل اقلیمی با سهم ۴۸ درصد، کاربری اراضی پوشش زمین با سهم ۵۲ درصد و خروجی شبکه را ضریب رواناب حوضه مورد نظر، قرار داده‌اند. آن‌ها در این شبیه‌سازی به این نتیجه رسیده‌اند که هر ساله حدود ۱ درصد ضریب رواناب در حال افزایش است که البته احتمال کاهش نیز وجود دارد. مرید^۴ و باقرزاده (۲۰۰۷)، از دو شاخص خشک‌سالی SPI و EDI به عنوان متغیرهای پیش‌بینی شونده استفاده کرده‌اند و ترکیبات مختلفی از متغیرهای بارندگی، شاخص‌های بزرگ مقیاس اقلیمی SOI، NAO و هم‌چنین مقادیر قبلی خود شاخص‌های خشک‌سالی را به عنوان ورودی‌های مدل پیش‌بینی شبکه‌های عصبی مصنوعی مد نظر قرار دادند. در تمام مقیاس‌های زمانی، بهترین مدل‌ها آنهایی بودند که شامل مقادیر شاخص خشک‌سالی ماه متناظر و سال گذشته بودند. آن‌ها هم‌چنین دریافتند که SOI و NAO تأثیر چندانی بر بهبود قابلیت پیش‌بینی مدل در منطقه‌ی مورد مطالعه ندارند. از آن جمله سدکی^۵ و همکارانش (۲۰۰۸)، به بررسی کاربرد شبکه‌های عصبی برای پیش‌بینی رواناب روزانه در حوضه‌ی آبریز مرزی در آب و هوای نیمه خشک در مراکش پرداخته است. برای پیش‌بینی رواناب در زمان معین، متغیرهای ورودی باران و رواناب مشاهده شده، در دوره‌های زمانی پیشین می‌باشد. برای ارزیابی و

^۱ -Hyun-suk shin

^۲ -Maqsood

^۳ -Parida

^۴ - Morid

^۵ - Sedki

پیش‌بینی از پایه‌ی الگوریتم ژنتیکی شبکه‌ی عصبی پرسپترون چند لایه استفاده شده است که سنجش نتایج نشان می‌دهد الگوریتم ژنتیکی شبکه‌های عصبی مدل پیش‌بینی بهتری در رواناب-باران روزانه می‌باشد. آکسوی^۱ و داهمشی^۲ (۲۰۰۹)، در پژوهشی در منطقه خشک و نیمه خشک در نیمه‌ی شرقی اردن به وسیله شبکه عصبی مصنوعی به پیش‌بینی بارش ماهانه پرداخته‌اند. آنان مدل پرسپترون چند لایه و شبکه‌ی رادیال بیس برای سه ایستگاه (Baqura, Amman, Safawi) به کار برده‌اند و با به‌کارگیری نتایج میانگین مربعات خطا، میانگین خطای مطلق و ضریب تبیین ارزیابی شده، دریافتند که بهترین مدل سنجیده شده برای سه ایستگاه مدل پرسپترون چند لایه می‌باشد. در این میان همزیسبای^۳ (۲۰۰۸)، در مقاله‌ای ساختار شبکه عصبی پرسپترون چند لایه را برای پیش‌بینی سری‌های زمانی در تایوان پیشنهاد می‌نماید. نتایج به‌دست آمده به وسیله معماری شبکه عصبی پرسپترون نسبت به روش آریمان نشان می‌دهد که مدل شبکه عصبی پرسپترون با پایین‌ترین خطای پیش‌بینی نسبت به مدل‌های آماری قابل قبول‌تری باشد و مدل پیش‌بینی شده مخصوصاً برای سری زمانی فصلی دارای نتایج قوی‌تری می‌باشد.

خسروی و همکاران (۱۳۸۹)، استفاده از روش‌های پیش‌بینی با شبکه‌های عصبی مصنوعی را در زمینه علوم جوی و محاسبه پارامترهای اقلیم‌شناسی با اهمیت دانسته‌اند. آنان از متغیرهای میانگین رطوبت نسبی، میانگین سرعت باد، مجموع ساعات آفتابی، میانگین حداقل دما میانگین دمای حداکثر ماهانه به عنوان ورودی شبکه عصبی پرسپترون چند لایه استفاده کرده‌اند. بررسی شاخص‌های عملکرد شبکه نشان داده است که پیش‌بینی دمای حداکثر شیراز با دقت قابل قبولی انجام شده است. در این مقاله با استفاده از شبکه‌ی عصبی مصنوعی به بررسی و پیش‌بینی خشک‌سالی پرداخته شده است.

۱- موقعیت و ویژگی‌های منطقه مورد مطالعه

منطقه‌ی مورد مطالعه شهرستان شیراز می‌باشد که با مختصات جغرافیای ۵۲ درجه و ۳۶ دقیقه طول شرقی و ۳۲ درجه و ۲۹ دقیقه عرض شمالی و با ارتفاع از سطح دریا ۱۴۸۶ متر و وسعتی معادل ۱۰۶۸۸/۸ کیلومترمربع، ۶/۸ درصد کل مساحت استان فارس را به خود اختصاص داده است (طاهری بابرصاد، ۱۳۸۱:۱۷۴). جدول ۱ نیز حاوی اطلاعات آماری سری زمانی بارندگی سالیانه‌ی این ایستگاه می‌باشد. در شکل ۲ سری زمانی بارندگی سالیانه‌ی ایستگاه سینوپتیک شیراز در بازه‌ی زمانی ۲۰۰۷-۱۹۵۱ نمایش داده شده است.

جدول ۱- اطلاعات آماری سری زمانی بارندگی سالیانه ایستگاه سینوپتیک شیراز (۲۰۰۷-۱۹۵۱)

شاخص آماری	میانگین (mm)	بیشینه (mm)	کمینه (mm)	انحراف از معیار	چولگی ^۴	درجه اوج ^۵
مقدار	۳۴۶	۷۱۱/۱	۹۶/۳	۱۲۹/۹۷	۰/۹۴	۱/۳۳


۱ - Aksoy

۲ - Dahamsheh

۳ - Hamzacebi

۴ - Skewness

۵ - Kurtosis



شکل ۲- نمودار میزان بارندگی سالیانه بر حسب میلی‌متر در ایستگاه سینوپتیک شیراز (۱۹۵۱-۲۰۰۷)

۳- داده‌ها و روش شناسی

۳-۱- شاخص خشک‌سالی SPI

در ابتدا شاخص بارش استاندارد شده یا SPI که به عنوان خروجی شبکه‌ی عصبی مصنوعی در این پژوهش به کار برده شده است؛ برای شناسایی رخداد خشک‌سالی و ارزیابی شدت آن استفاده گردید. (موریا^۱ و همکاران، ۲۰۰۸: ۱۱۹).

$$SPI = \frac{x_i - \bar{x}}{\sigma} \quad (1)$$

در رابطه فوق، x_i مقادیر بارش رخ داده، \bar{x} میانگین بارش و σ انحراف از معیار بارش در هر مقیاس زمانی می‌باشد (ویلهایت^۲، ۲۰۰۰: ۶). در خصوص مزایای شاخص SPI می‌توان به موارد زیر اشاره نمود:

- ۱- نمایه SPI فقط براساس بارندگی محاسبه می‌شود.
- ۲- به شرایط رطوبت خاک بستگی ندارد، بنابراین می‌توان از آن برای ماه‌های زمستان نیز استفاده کرد.
- ۳- این شاخص نسبتاً ساده بوده و عملاً قابل استفاده برای تمام شرایط منابع آبی می‌باشد.
- ۴- شاخص SPI برای مقیاس زمانی متعدد از یک ماه تا چندین سال محاسبه می‌شود. هر پریرود زمانی را می‌توان برای آن در نظر گرفت. (صفدری و همکاران، ۱۳۸۲: ۴۶۶). مقادیر شاخص خشک‌سالی SPI در مقیاس‌های زمانی ماهانه و ۳ ماهه به صورت پیوسته و فصل زمستان به صورت گسسته در بازه زمانی بین سال‌های ۱۹۵۱ تا ۲۰۰۷ میلادی می‌باشند. از میان فصول، فصل زمستان را که دارای بیشترین بارش در شهرستان شیراز می‌باشد مورد بررسی قرار گرفته است و بدین فصل اکتفا شده است.

۳-۲- شاخص‌های پیوند از دور و عناصر اقلیمی

بررسی منابع متعدد نشان داد، ارتباط بین الگوهای پیوند از دور با بارش و دما در مناطق وسیعی از کره زمین به اثبات رسیده است، لذا در این تحقیق حاضر از سیگنال‌های فوق برای پیش‌آگاهی خشک‌سالی

۱- Moreira

۲- Willhite

منطقه شیراز استفاده گردیده است. الگوهای پیوند از دور منعکس کننده‌ی تغییرات در مقیاس وسیع در امواج اتمسفری و موقعیت رودبادهای بوده و بر درجه حرارت، بارش، مسیر توفان‌ها و موقعیت و شدت رودباد بر روی مناطق وسیع تأثیر می‌گذارند (خسروی، ۱۳۸۳:۱۶۹). اداره‌ی ملی اقیانوس و اتمسفر ایالات متحده آمریکا^۱، الگوهای ارتباط از دور اساسی را جهت بررسی سهم و درک نقش آن‌ها در سیستم اقلیم سیاره‌ای شناسایی نموده و در قالب شاخص‌هایی ارائه داده است (NOAA، ۲۰۰۹). این شاخص‌ها که از آن‌ها با عنوان شاخص‌های اقلیمی یاد می‌شود به عنوان ورودی مدل‌های پیش‌بینی استفاده گردیده است. شاخص‌های پیوند از دور در دوره‌ی زمانی ۲۰۰۷-۱۹۵۱ مورد استفاده در این مقاله عبارتند از: شاخص مد جنوبی اقیانوس اطلس^۲، شاخص نوسان چند دهه‌ای اقیانوس اطلس^۳، شاخص سری‌های زمانی انسو دو متغیره^۴، الگوی نوسان آرام شرقی^۵، شاخص چند متغیره انسو^۶، نوسانات اطلس شمالی^۷، شاخص‌های دمای سطح اقیانوس آرام^۸، الگوی آرام/آمریکای شمالی^۹، شاخص نوسان شبه دو سالانه^{۱۰}، شاخص نوسانات جنوبی^{۱۱}، شاخص بارش موسمی ناحیه جنوب غربی^{۱۲}، الگوی حاره‌ای اطلس شمالی^{۱۳}، شاخص ترنس-نینو^{۱۴}، الگوی حاره‌ای جنوب اقیانوس اطلس^{۱۵}، الگوی استخر گرم نیمکره غربی^{۱۶}، الگوی آرام غربی^{۱۷}. شاخص‌های پیوند از دور و عناصر اقلیمی «بارش، بیشینه دما، کمینه دما، بیشینه رطوبت نسبی و کمینه رطوبت نسبی» در پیش‌بینی خشک‌سالی متغیرهای مستقلی می‌باشند؛ بنابراین به عنوان پیش‌بین در مدل شبکه‌ی عصبی مصنوعی مورد استفاده قرار می‌گیرند. داده‌های عناصر اقلیمی در دوره‌ی زمانی ۲۰۰۷-۱۹۵۱ می‌باشد که از اداره‌ی هواشناسی شیراز اخذ گردید (نصیری، ۱۳۸۹).

۳-۳- ارزیابی همبستگی میان شاخص‌های پیوند از دور و عناصر اقلیمی بر میزان خشک‌سالی

در این تحقیق برای یافتن مهم‌ترین شاخص‌های اقلیمی و عناصر اقلیمی در میزان خشک‌سالی منطقه شیراز از ضریب همبستگی استفاده شد. مرسوم‌ترین و در عین حال منطقی‌ترین روش در ارزیابی ارتباط بین پارامترهای اقلیمی، بررسی همبستگی بین آن‌ها می‌باشد. تحلیل همبستگی ابزاری آماری برای تعیین نوع و درجه‌ی رابطه‌ی یک متغیر کمی با متغیر کمی دیگر است (مؤمنی و فعال قیومی، ۱۳۸۹:۱۱). با استفاده از روش همبستگی می‌توان پراهمیت‌ترین سیگنال و مؤثرترین عناصر در خشک‌سالی منطقه شیراز را برای

۱- NOAA

۲- AMM

۳- AMO

۴- BEST

۵- EPO

۶- MEI

۷- NAO

۸- Nino ۱+۲, Nino ۳, Nino ۳/۴, Nino ۴

۹- PNA

۱۰- QBO

۱۱- SOI

۱۲- SW monsoon

۱۳- TNA

۱۴- TNI

۱۵- TSA

۱۶- WHWP

۱۷- WP

ساخت مدل مناسب شناسایی نمود و در گام بعدی به ساخت مدل شبکه عصبی و بررسی الگوریتم پس انتشار، الگوریتم ژنتیک و پرندگان در شبکه عصبی پرسپترون چند لایه پرداخت.

جدول ۲- ضرایب همبستگی (پیرسون) ماهانه شاخص خشک‌سالی SPI و برخی از عناصر اقلیمی و شاخص اقلیمی در دوره‌ی آماری ۱۹۵۱-۲۰۰۷ در شیراز

	بارش	بیشینه رطوبت نسبی	بیشینه دما	کمینه دما	Nino ۱+۲	Nino ۳	Nino ۴	SW monsoon
SPI	۰.۷۹**	-۰.۱۷۹**	۰.۴۳۹**	۰.۵**	-۰.۳۶۲**	-۰.۱۴۲**	۰.۱۶۸**	۰.۲۷**

** . Correlation is significant at the ۰.۰۱ level.

* . Correlation is significant at the ۰.۰۵ level.

جدول ۳- ضرایب همبستگی (پیرسون) ۳ ماه شاخص خشک‌سالی SPI و برخی از عناصر اقلیمی و شاخص اقلیمی در دوره‌ی آماری ۱۹۵۱-۲۰۰۷ در شیراز

	بارش	بیشینه رطوبت نسبی	کمینه رطوبت نسبی	بیشینه دما	کمینه دما	Nino ۱+۲	Nino ۴	Nino ۳
SPI	۰.۸۵**	-۰.۵۲۲**	-۰.۴۳۶**	۰.۶۳۳**	۰.۶۹۴**	-۰.۴۰۷**	۰.۳۲۸**	۰.۳**

جدول ۴- ضرایب همبستگی (پیرسون) زمستانه شاخص خشک‌سالی SPI و برخی از عناصر اقلیمی و شاخص اقلیمی در دوره‌ی آماری ۱۹۵۱-۲۰۰۷ در شیراز

	بارش زمستانه	بیشینه رطوبت نسبی زمستانه	بیشینه دما زمستانه	Nao زمستانه
SPI	۰.۹۰۸**	۰.۵۰۸**	-۰.۶۰۲**	۰.۲۶۳*

۳-۴- نرمال سازی داده‌ها

پس از بررسی همبستگی داده‌ها و تعیین مؤثرترین ورودی شبکه‌ی عصبی، در ابتدا داده‌ها را برای ورودی شبکه‌ی عصبی استاندارد سازی می‌نماییم. نرمال سازی داده‌ها^۱ که به مفهوم پیش پردازش^۲ و پس پردازش^۳ داده‌ها می‌باشد، موجب بهبود عملکرد شبکه می‌گردد. (نجفی و طرازکار، ۱۳۸۵: ۲۰۲). در این تحقیق برای نرمال سازی داده‌ها از رابطه زیر استفاده شده است که ورودی‌ها را بین ۰/۱ و ۰/۹ استاندارد می‌نماید (صداقت کردار و فتاحی، ۱۳۸۷: ۶۴).

۱ - Data Normalization

۲ - Preprocessing

۳ - Post processing

$$N = 0.8 \left[\frac{X_i - X_{\min}}{X_{\min} - X_{\max}} \right] + 0.1 \quad (3)$$

N : مقادیر نرمال شده X_i : مقادیر واقعی X_{\max} : بیشینه مقادیر واقعی X_{\min} : کمینه مقادیر واقعی

۳-۵- روش شبکه‌ی عصبی مصنوعی جهت پیش‌بینی خشک‌سالی

مهم‌ترین مزیت شبکه‌ی عصبی نسبت به سیستم‌های هوشمند دیگر قدرت یادگیری شبکه از محیط پیرامون است. یادگیری به این معنی است که مقادیر وزن‌های شبکه طوری انتخاب گردد، که عملکرد شبکه همانی باشد که ما انتظار آن را داریم. مثلاً مقدار شاخص خشک‌سالی SPI پیش‌بینی شده به وسیله‌ی شبکه، با مقدار خطای قابل قبول، برابر با مقدار واقعی SPI گردد. یادگیری شبکه از طریق روش یا الگوریتمی صورت می‌گیرد که در طی آن مقادیر وزن‌ها به صورت مرحله به مرحله طوری تعدیل می‌شود، که مقدار خطای پیش‌بینی شبکه حداقل گردد. برای یادگیری شبکه ابتدا یکسری داده (متغیرهای مستقل) که دارای پراکندگی مناسب باشد به شبکه معرفی می‌گردد. در مرحله یادگیری ابتدا شبکه مقادیر اولیه‌ای برای وزن‌ها در نظر می‌گیرد و با استفاده از داده‌های ورودی به آن مقدار متغیر وابسته (شاخص خشک‌سالی SPI) را محاسبه می‌نماید. سپس مقادیر محاسبه شده را با مقادیر اندازه‌گیری شده مقایسه نموده، در صورت اختلاف آن دو، مقادیر وزن‌ها به طرق خاصی تعدیل می‌شود و مجدداً محاسبات تکرار می‌گردد. فرآیند تعدیل وزن‌ها به صورت مرحله به مرحله طوری تعدیل می‌شود که مقدار خطای پیش‌بینی شبکه، حداقل گردد. در این حالت اصطلاحاً گفته می‌شود که شبکه یاد گرفته است. برای یادگیری شبکه‌های عصبی می‌توان از الگوریتم‌های مختلفی استفاده نمود. یکی از مهم‌ترین الگوریتم‌ها یا روش‌ها برای یادگیری شبکه، الگوریتم آموزش پس انتشار خطا^۱ می‌باشد (فتحی و کوچک‌زاده، ۱۳۸۳:۲۱۳). یکی از کاربردی‌ترین مدل‌ها، مدل‌های شبکه عصبی پرسپترون چند لایه است که روی الگوریتم پس انتشار، پایه‌گذاری شده است. اساس آموزش الگوریتم پس انتشار به این صورت است که وزن‌های اولیه ارتباطی به صورت تصادفی انتخاب می‌گردند. با فرض وجود N نمونه آموزشی که هر نمونه N ورودی و 1 خروجی داشته باشد، بردار ورودی به صورت $X_j = (X_{1j}, \dots, X_{nj})$ و بردار خروجی به صورت $B_j = (B_1, \dots, B_{nj})$ که $1 \leq j \leq N$ ، تعریف می‌گردد. فرآیند آموزش با استفاده از دو گام زیر اتفاق می‌افتد:

الف - انتشار به جلو: بردار ورودی X_j به لایه ورودی فرستاده می‌شود و یک بردار خروجی

$Q_j = (Q_{1j}, \dots, Q_{nj})$ براساس وزن‌های جاری $W = (W_{1j}, \dots, W_{nj})$ ایجاد می‌گردد. مقدار Q_j با مقدار خروجی واقعی یعنی B_j مقایسه شده و تابع خطای E تولید می‌شود.

$$E = \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^N (B_{ij} - Q_{ij})^2 \quad (4)$$

ب- انتشار به عقب: در این گام، خطای به‌دست آمده از معادله ۴ به وسیله رابطه زیر روی وزن‌ها توزیع

می‌گردد.

۱ - Error back propagation training method

۲ - Forward propagation


۳ - Error back propagation training method

۴ - Forward propagation

۵ - Error Back propagation

$$\Delta W_{ni} = -\frac{\partial E}{\partial W_{ni}} \eta \quad (5)$$

ضریب $0 \leq \eta \leq 1$ پارامتری است که همگرایی نرخ الگوریتم را کنترل می‌کند. این دو مرحله آن قدر ادامه می‌یابد تا مقدار E خطا به مقدار کوچک از پیش تعیین شده‌ای همگرا گردد. در حقیقت شبکه، با توزیع خطای به دست آمده (در هر مرحله) روی وزن‌های قبلی و تکرار این عملیات آموزش می‌بیند. به تعداد این تکرارها اصطلاحاً اپاک^۱ و به روشی که خطاها را به طور معکوس (روبه عقب) روی وزن‌ها توزیع می‌نماید دلتا بار^۲ گفته می‌شود (قلی زاده و دارند، ۱۳۸۸: ۵۴).



شکل ۳- ساختار کلی شبکه‌ی عصبی مصنوعی

۳-۶- معیارهای ارزیابی عملکرد شبکه در مرحله آموزش و تست

به منظور مقایسه‌ی قدرت پیش‌بینی و انتخاب بهترین روش پیش‌بینی، از معیارهای مختلف از جمله: ضریب همبستگی^۳، میانگین مجذور خطا^۴، میانگین قدر مطلق خطا^۵، استفاده شده است (نجفی و طراز کار، ۱۳۸۵: ۲۰۳).

$$R^2 = 1 - \frac{\sum (y_0 - y_f)}{\sum y_0^2 - \frac{\sum y_f^2}{n}} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{j=0}^P \sum_{i=0}^n (y_0 - y_f)^2}{NP}} \quad (7)$$

$$MAE = \frac{1}{N} \sum_1^n [|y_0 - y_f|] \quad (8)$$

در روابط بالا y_0 : مقادیر مشاهده شده، y_f : مقادیر پیش‌بینی شده، n : تعداد داده‌ها، P : تعداد متغیرهای خروجی و n : تعداد نمونه‌ها در لایه خروجی می‌باشد (محتشم و همکاران، ۱۳۸۹: ۴).

۴- نتایج و بحث

۴-۱- بهینه‌سازی ساختار شبکه‌ی عصبی مصنوعی توسط الگوریتم ژنتیک (GA) و پرندگان (PSO)

الگوریتم‌های تکاملی به عنوان یکی از مهم‌ترین اعضای خانواده الگوریتم‌های بهینه‌سازی به شمار می‌آیند. اهمیت این گروه از الگوریتم‌ها در حل طیف وسیعی از مسایل مختلف از ریاضیات و مهندسی تا پزشکی و

۱- Epoch

۲- Delta Bar Delta

۳- R

۴- MSE

۵- MAE

تجارت می‌باشد که به طور روز افزون نیز در حال افزایش می‌باشد. دو خانواده مهم الگوریتم‌های تکاملی، الگوریتم ژنتیک و الگوریتم پرندگان می‌باشند، که در این تحقیق نیز مورد استفاده قرار گرفته‌اند. الگوریتم ژنتیک از اصول انتخاب طبیعی داروین برای یافتن بهینه‌ترین جواب استفاده می‌کند. این الگوریتم در سال ۱۹۷۵ میلادی توسط جان هلند ارایه گردید. می‌توان گفت این الگوریتم یک تکنیک برنامه نویسی است که از تکامل ژنتیکی به عنوان یک الگوی حل مسئله استفاده می‌کند. مسئله‌ای که باید حل شود ورودی می‌باشد و راه حل‌ها طبق یک الگو کد گذاری می‌گردند، تابع برازش نیز هر راه حل کاندید را ارزیابی می‌کند. سپس طی یک روند تصادفی نسلی جدید ایجاد می‌شود. در این فرآیند از مفاهیم علم زیست‌شناسی مثل وراثت، جهش، انتخاب ناگهانی، انتخاب طبیعی و ترکیب بهره گرفته می‌شود (هواپت^۱ و همکاران، ۲۰۰۴).

الگوریتم بهینه‌سازی پرندگان یکی از مهم‌ترین الگوریتم‌های حوزه‌ی هوش دسته جمعی (intelligence swarm) می‌باشد. این الگوریتم، توسط جیمز کندی و راسل سی ابره‌ارت در سال ۱۹۹۵ میلادی معرفی گردید. الگوریتم پرندگان با الهام از رفتار اجتماعی حیواناتی مانند ماهی‌ها و پرندگان که به صورت گروهی زندگی می‌کنند، طراحی شده است. در الگوریتم گروه ذرات، تمام اعضای جمعیت در ارتباط با یکدیگر می‌باشند و از طریق تبادل اطلاعات، به حل مسئله می‌پردازند. از این الگوریتم می‌توان در حل انواع مسائل پیوسته و گسسته استفاده کرد (Matlabsite).

در الگوریتم گروه ذرات، هر عضو جمعیت یک ذره نامیده می‌شود، این ذرات در فضای جستجوی تابعی که هدف بهینه کردن آن می‌باشد، پخش می‌شوند. موقعیت هر ذره از طریق محاسبه تابع هدف بررسی می‌گردد. سپس با استفاده از ترکیب اطلاعات محل فعلی اش و بهترین محلی که قبلاً در آن بوده است و هم‌چنین اطلاعات یک یا چند ذره از بهترین ذرات موجود در جمع، جهتی برای حرکت انتخاب می‌شود. پس از اینکه تمام ذرات موقعیت خود را بروز رسانی کردند، یک مرحله از الگوریتم به پایان می‌رسد. این مراحل تا زمانی که جواب مورد نظر به دست آید چندین بار تکرار می‌شوند. در واقع می‌توان مجموعه ذراتی که در جستجوی یافتن کمینه یک تابع هستند را همانند دسته‌ای از پرندگان دانست که به دنبال غذا می‌گردند.

کاربرد الگوریتم‌های تکاملی در آموزش شبکه‌ی عصبی مصنوعی و هم‌چنین بهینه‌سازی پارامترهای شبکه مانند تعداد لایه‌ها و هم‌چنین تعداد نرون‌های هر لایه می‌باشد که از این جمله می‌توان به کارهای منتانا^۲ و همکاران (۱۹۸۹) و مندس^۳ و همکاران (۲۰۰۲) اشاره کرد.

۴-۲- پیش‌بینی ۱ ماهه، ۳ ماهه و فصلی زمستانه خشک‌سالی به وسیله الگوریتم پس انتشار، الگوریتم ژنتیک و پرندگان در شبکه‌ی عصبی پرسپترون چند لایه

در ابتدا با استفاده از پارامترهای مؤثر بر میزان خشک‌سالی ماهانه که شامل بیشینه رطوبت نسبی، بیشینه دما، کمینه دما، بارش و شاخص‌های اقلیمی Nino^{۱+۲}، Nino^۳، Nino^۴، SW monsoon می‌باشند، فرایند مدل‌سازی در شبکه عصبی پرسپترون چند لایه با الگوریتم آموزش پس انتشار خطا انجام گردید که نتایج آن شامل مدل ۱ می‌باشد. سپس به منظور نشان دادن کاربرد الگوریتم‌های تکاملی در تعیین پاسخ شبکه عصبی،

^۱ Haupt

^۲ - Montana

^۳ - Mendes

به جای روش‌های یادگیری موجود برای شبکه‌های عصبی MLP از الگوریتم‌های ژنتیک و پرندگان به منظور تعیین ضرایب وزن‌ها و بایاس شبکه استفاده گردید. نتایج حاصل از این روش بر روی داده‌های ماهانه در جدول ۵ نشان داده شده است.

جدول ۵: نتایج پیش‌بینی پیوسته خشک‌سالی در مقیاس ۱ ماهه در شبکه‌ی عصبی (Feed Forward)،

الگوریتم ژنتیک و پرندگان

ساختار شبکه	تست			آموزش			
	MAE	R	RMSE	MAE	R	RMSE	
۸-۱	۰/۳۴	۰/۸۱	۰/۱۵	۰/۲۵	۰/۹۶	۰/۰۶	مدل ۱ (ANN)
۸-۱	۰/۳۲	۰/۷۶	۰/۱۷	۰/۳۱	۰/۸۰	۰/۱۵	مدل ۲ (GA-ANN)
۸-۱	۰/۳۸	۰/۷۶	۰/۱۶	۰/۲۸	۰/۸۳	۰/۱۴	مدل ۳ (PSO-ANN)

همان‌گونه که انتظار می‌رفت، نتایج حاصل از روش یادگیری مبتنی بر الگوریتم آموزش پس انتشار خطا تا حدودی بهتر از روش‌های تکاملی می‌باشد. در واقع کاربرد الگوریتم‌های بهینه‌سازی در آموزش شبکه‌هایی می‌باشد که تابع هدف نسبت به وزن‌ها مشتق پذیر نبوده و یا روش‌های عددی رایج برای آموزش آن‌ها کارایی لازم را ندارد.

همان‌گونه که ذکر شد روش دیگر به کارگیری الگوریتم‌های تکاملی در طراحی شبکه‌ی عصبی، تأکید بر انتخاب بهینه‌ترین ساختار شبکه (تعداد لایه‌ها و تعداد نرون‌ها در هر لایه) می‌باشد. بدین منظور بجای استفاده از روش سعی و خطا از الگوریتم‌های ژنتیک و پرندگان جهت پیدا کردن پارامترهای شبکه استفاده شده است. در این روش هر یک از اعضای جمعیت در واقع نماینده ساختار کامل یک شبکه می‌باشند که با تکامل و بهبود اعضا، شبکه بهتری نسبت به قبل ایجاد می‌گردد. در این روش حداکثر تعداد لایه‌ها ۵ و حداکثر مجاز تعداد نرون‌های هر لایه ۸ قرار داده شده است، هم‌چنین تابع $\log\text{sig}$ در لایه‌های پنهان و تابع purelin در لایه نهایی استفاده شده است. نتایج به دست آمده از اعمال این روش بر روی داده‌های ماهانه در جدول ۶ مشاهده می‌شود.

جدول ۶: نتایج پیش‌بینی پیوسته خشک‌سالی در مقیاس ۱ ماهه در شبکه‌ی عصبی (Feed Forward)،

الگوریتم ژنتیک و پرندگان

ساختار شبکه	تست			آموزش			
	MAE	R	RMSE	MAE	R	RMSE	
۸-۱	۰/۳۴	۰/۸۱	۰/۱۵	۰/۲۵	۰/۹۶	۰/۰۶	مدل ۱ (ANN)
۴-۷-۱	۰/۳۸	۰/۸۵	۰/۱۳	۰/۲۳	۰/۹۷	۰/۰۵	مدل ۲ (GA-ANN)
۴-۷-۱	۰/۳۸	۰/۸۵	۰/۱۳	۰/۲۳	۰/۹۷	۰/۰۵	مدل ۳ (PSO-ANN)

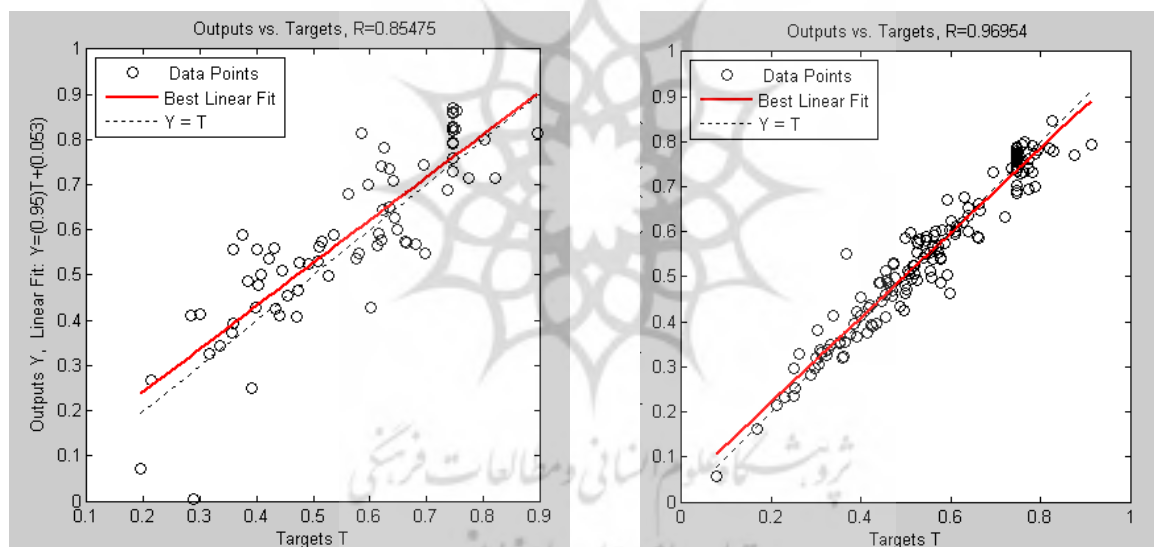
با توجه به نتایج به دست آمده، مدل ۲ و ۳ که شامل استفاده از الگوریتم ژنتیک و الگوریتم پرندگان برای تعیین پارامترهای شبکه می‌باشند، به ساختار یکسانی دست یافته‌اند و جواب‌های بهینه تری نسبت به مدل ۱ و استفاده از روش سعی و خطا نشان می‌دهند.

در پیش‌بینی سه ماهه خشک‌سالی ورودی شبکه بیشینه رطوبت نسبی، کمینه رطوبت نسبی، بیشینه دما، کمینه دما و شاخص‌های اقلیمی Nino ۱+۲، Nino ۳، Nino ۴ می‌باشند. مدل شماره ۱ مدل الگوریتم پس انتشار شبکه پرسپترون می‌باشد که نتایج حاصل از به‌کارگیری الگوریتم ژنتیک (مدل ۲) و پرندگان (مدل ۳) از نظر میزان خطا و میزان همبستگی تفاوت فاحشی با یکدیگر ندارند.


جدول ۷: نتایج پیش‌بینی پیوسته خشک‌سالی در مقیاس ۳ ماهه در شبکه‌ی عصبی (Feed Forward)،

الگوریتم ژنتیک و پرندگان


ساختار شبکه	تست			آموزش			
	MAE	R	RMSE	MAE	R	RMSE	
مدل ۱ (ANN) ۳-۵-۱	۰.۲۶	۰.۸۵	۰.۱۶	۰.۲۲	۰.۹۶	۰.۰۸	
مدل ۲ (GA-ANN) ۵-۵-۱	۰.۲۷	۰.۸۶	۰.۱۵	۰.۲۴	۰.۹۷	۰.۰۶	
مدل ۳ (PSO-ANN) ۲-۸-۱	۰.۲۳	۰.۸۶	۰.۱۵	۰.۲۲	۰.۹۷	۰.۰۶	



شکل ۴- ضرایب همبستگی مدل شماره ۱ (الگوریتم پس انتشار) در مرحله آموزش و تست. (الف، ب) ضرایب همبستگی به ترتیب در مرحله آموزش و آزمایش

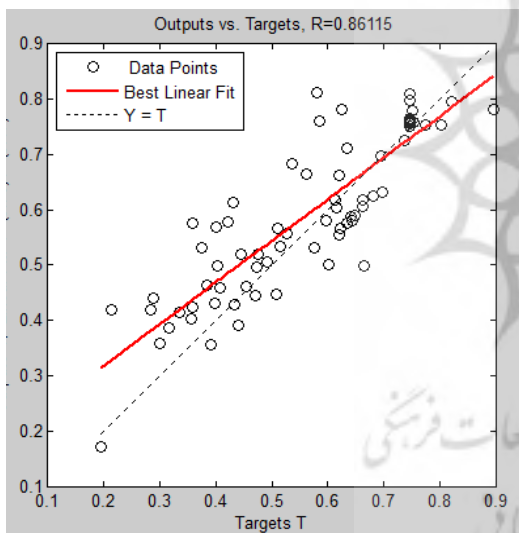


ب




الف

شکل ۵- ضرایب همبستگی مدل شماره ۲ (الگوریتم ژنتیک) در مرحله آموزش و تست. (الف، ب) ضریب همبستگی به ترتیب در مرحله آموزش و آزمایش



ب




الف

شکل ۶- ضرایب همبستگی مدل شماره ۳ (الگوریتم پرندگان) در مرحله آموزش و تست. (الف، ب) ضریب همبستگی به ترتیب در مرحله آموزش و آزمایش


در بررسی خشک‌سالی زمستانه پارامترهایی که دارای بیشترین همبستگی با Spi زمستانه می‌باشند شامل: بارش زمستانه، بیشینه رطوبت نسبی زمستانه، بیشینه دما زمستانه، شاخص اقلیمی $Na0$ زمستانه که به عنوان ورودی شبکه مورد استفاده قرار گرفت. عملکرد الگوریتم ژنتیک و پرندگان به جای روش سعی و خطا در الگوریتم پس انتشار، پیدا نمودن ساختار مناسب شبکه می‌باشد.

جدول ۸: نتایج پیش‌بینی خشک‌سالی زمستانه در شبکه‌ی عصبی (Feed Forward)، الگوریتم ژنتیک و پرندگان

ساختار شبکه	تست			آموزش			
	MAE	R	RMSE	MAE	R	RMSE	
۲-۲-۱	۰.۰۹	۰.۹۴۲	۰.۱۲	۰.۰۷	۰.۹۹	۰.۰۴	مدل ۱ (ANN)
۵-۱	۰.۱۴	۰.۹۳۷	۰.۱۱	۰.۰۳	۰.۹۹	۰.۰۲	مدل ۲ (GA-ANN)
۳-۳-۱	۰.۱۱	۰.۹۴۲	۰.۱۰	۰.۰۶	۰.۹۸	۰.۰۵	مدل ۳ (PSO-ANN)

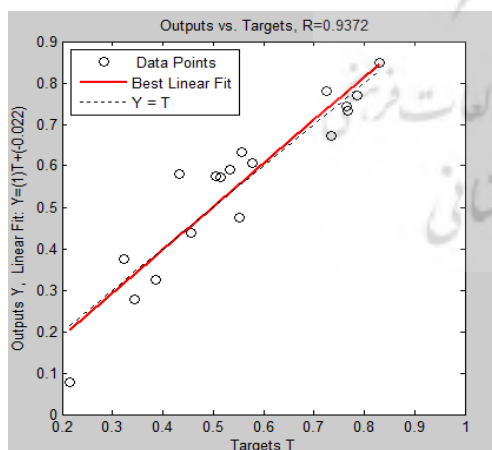


ب

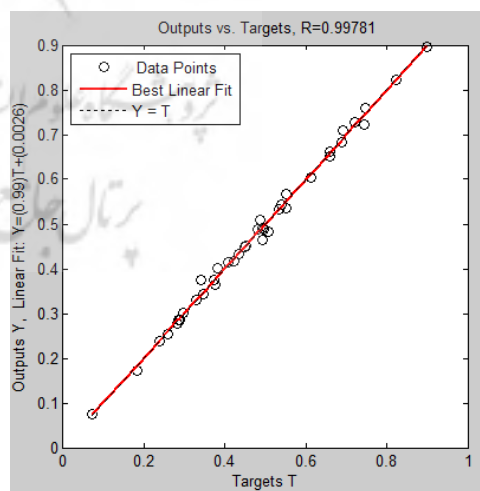


الف

شکل ۷- ضرایب همبستگی مدل شماره‌ی ۱ (الگوریتم پس انتشار) در مرحله آموزش و تست. (الف، ب) ضریب همبستگی به ترتیب در مرحله آموزش و آزمایش




ب




الف

شکل ۸- ضرایب همبستگی مدل شماره‌ی ۲ (الگوریتم ژنتیک) در مرحله آموزش و تست. (الف، ب) ضریب همبستگی به ترتیب در مرحله آموزش و آزمایش



ب



الف

شکل ۹- ضرایب همبستگی مدل شماره ۳ (الگوریتم پرندگان) در مرحله آموزش و تست. (الف، ب) ضریب همبستگی به ترتیب در مرحله آموزش و آزمایش

با توجه به نتایج به دست آمده از جدول ۶، مدل ۲ و ۳ که شامل استفاده از الگوریتم ژنتیک و الگوریتم پرندگان برای تعیین پارامترهای شبکه می‌باشند، به ساختار یکسانی دست یافته‌اند و جواب‌های بهینه تری نسبت به مدل ۱ و استفاده از روش سعی و خطا نشان می‌دهند. نتایج موجود در جدول‌های ۷ و ۸ نیز نشان دهنده برتری روش‌های مبتنی بر الگوریتم‌های بهینه سازی می‌باشد. البته لازم به ذکر است که هرچه پیچیدگی مسایل بیشتر باشد نقش الگوریتم‌های تکاملی در بهینه سازی ساختار شبکه پر رنگ تر خواهد بود.

۵- نتیجه گیری

در این مقاله جهت پیش بینی شاخص خشک سالی SPI در منطقه مورد مطالعه به کمک شبکه‌ی عصبی مصنوعی در ابتدا همبستگی میان عناصر اقلیمی و شاخص‌های اقلیمی با شاخص خشک سالی SPI بررسی شد. نتایج نشان داد که استفاده از ورودی‌های که دارای همبستگی بیشتری بودند، موجب بهبود عملکرد شبکه گردید. در پیش بینی خشک سالی به کمک شبکه‌ی عصبی استفاده از عناصر اقلیمی در کنار شاخص‌های پیوند از دور باعث بهبود نتایج شبکه گردید. در حالی که استفاده از عناصر اقلیمی به تنهایی به عنوان ورودی مدل‌ها و یا اینکه شاخص‌های پیوند از دور به تنهایی برای ورودی شبکه، نتایج مطلوبی را به دنبال نداشت.

پیش بینی شاخص خشک سالی SPI زمستانه نسبت به SPI ۳ ماهه و خشک سالی ۱ ماهه با نتایج بهتری انجام شد و میزان همبستگی بالاتری را نشان داد. نتایج حاصل از به کارگیری مدل نشان داد که این روش در صورت استفاده از ورودی‌های مناسب وسیله‌ای مطمئن برای پیش بینی اقلیمی خشک سالی در نواحی دیگر کشور می‌باشد. استفاده از روش‌های الگوریتم ژنتیک و پرندگان جهت پیدا کردن بهینه ترین ساختار شبکه به جای استفاده از روش سعی و خطا نتایج مطلوب تری را ارائه می‌نماید. در پیش بینی خشک سالی شیراز استفاده از تکنیک الگوریتم ژنتیک و پرندگان نسبت به روش الگوریتم پس انتشار خطا نتایج بهتری را شامل می‌گردد.

منابع :

- پاپلی یزدی و محمد حسین (۱۳۷۸)، آیین‌های باران خواهی در زمان خشک‌سالی‌ها، فصل‌نامه‌ی تحقیقات جغرافیایی ویژه‌ی هوا اقلیم، شماره‌ی ۵۴، صص ۱۷۶-۱۸۷.
- پایگاه اطلاع‌رسانی سامانه‌ی خشک‌سالی، ۱۳۸۹.
- خسروی، محمود، اژدری‌مقدم، مهدی، نظری‌پور، حمید و رزمجویی، شهرام (۱۳۸۹)، پیش‌بینی دمای بیشینه شیراز با استفاده از مدل شبکه عصبی مصنوعی، چهارمین کنگره‌ی بین‌المللی جغرافیدانان جهان اسلام، صص ۱-۱۴.
- خسروی، محمود (۱۳۸۳)، بررسی روابط بین الگوهای چرخش جوی کلان مقیاس نیمکره شمالی با خشک‌سالی‌های سالانه سیستان و بلوچستان، مجله‌ی جغرافیا و توسعه، شماره‌ی ۳، صص ۱۶۷-۱۸۸.
- صداقت‌کردار، عبدالله و فتاحی، ابراهیم (۱۳۸۷)، شاخص‌های پیش‌آگاهی خشک‌سالی در ایران، مجله‌ی جغرافیا و توسعه، شماره‌ی ۱۱، صص ۵۹-۷۶.
- صفدری، علی‌اکبر و محسنی ساروی، محسن و ثقفیان، بهرام و مهدوی، محمد (۱۳۸۲)، پهنه‌بندی فراوانی خشک‌سالی‌های حوزه کارون به کمک شاخص بارش استاندارد (SPI) در محیط GIS، سومین کنفرانس منطقه‌ای و اولین کنفرانس ملی تغییر اقلیم، صص ۴۶۰-۴۷۲.
- طاهری‌بابرصاد، خسرو (۱۳۸۱)، بررسی سیاست‌های توسعه مسکن برای اقشار کم درآمد شهری، مطالعه‌ی موردی و ارزیابی مسکن اجتماعی در شهر شیراز، پایان‌نامه کارشناسی ارشد در رشته شهرسازی، دانشگاه شیراز.
- فتحی، پرویز و کوچک‌زاده، مهدی (۱۳۸۳)، تخمین تعریق خیار گلخانه‌ای با استفاده از شبکه عصبی مصنوعی، مجله‌ی علوم خاک و آب، جلد ۱۸، شماره‌ی ۲، صص ۲۱۲-۲۲۱.
- قلی‌زاده، محمدحسین و دارند، محمد (۱۳۸۸)، پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی مورد تهران، پژوهش‌های جغرافیای طبیعی، شماره‌ی ۷۱، صص ۵۱-۶۳.
- کوچک‌زاده، مهدی و عارف، بهمنی (۱۳۸۴)، ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای مورد نیاز، جهت برآورد تبخیر و تعرق، مجله‌ی علمی پژوهشی علوم کشاورزی، سال ۱۱، شماره‌ی ۴، صص ۸۷-۹۷.
- مساعدی، ابوالفضل و خلیلی‌زاده، مجتبی و محمدی استادکلایه، امین (۱۳۸۷)، پایش خشک‌سالی هواشناسی در سطح استان گلستان، مجله‌ی علوم کشاورزی و منابع طبیعی، جلد ۱۵، شماره‌ی ۲، صص ۱-۸.
- محتشم، محسن، دهقانی، امیراحمد، اکبرپور، ابوالفضل، مفتاح‌هلقی، مهدی و اعتباری، بهروز (۱۳۸۹)، پیش‌بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه‌ی موردی: دشت بیرجند)، مجله‌ی آبیاری و زهکشی ایران، شماره‌ی ۱، جلد ۴، صص ۱-۱۰.
- مؤمنی، منصور و فعال قیومی، علی (۱۳۸۹)، تحلیل‌های آماری با استفاده از SPSS، تهران: کتاب نو.

- نجفی بهاء‌الدین و طرازکار، محمدحسین (۱۳۸۵)، پیش‌بینی میزان صادرات پسته ایران: کاربرد شبکه عصبی مصنوعی، پژوهشنامه‌ی بازرگانی، صص ۱۹۱-۲۱۴.

- نصیری، مریم (۱۳۸۹)، پیش‌بینی خشک‌سالی با استفاده از شبکه عصبی مصنوعی، مطالعه موردی: ایستگاه سینوپتیک شیراز، پایان‌نامه‌ی کارشناسی ارشد اقلیم‌شناسی، استاد راهنما: محمود خسروی، دانشگاه سیستان و بلوچستان.

-Aksoy, Hafzullah and Dahamsheh, Ahmad (۲۰۰۹), **Artificial neural network models for forecasting monthly precipitation in Jordan**. In *Stochastic Environmental Research and Risk Assessment*, ۱۰.۱۰۷, ۹۱۷-۹۳۱

-Hamzacebi Coskun, (۲۰۰۸), **Improving artificial neural networks Performance in Seasonal Time series forecasting**, *Information sciences* ۱۷۸, ۴۵۵۰-۴۵۵۹.

-Morid S, Smakhtin V, Bagherzadeh K (۲۰۰۸), **Drought forecasting using artificial neural networks and time series of drought indices**, *International Journal of Climatology*, ۲۷, ۲۱۰۳-۲۱۱۱.

-Maqsood Imran, Riazkhan Muhammad, Abraham Ajith,(۲۰۰۴),**An ensemble of neural networks for weather forecasting**, *Neuralcompute & Applic*, ۱۳, ۱۱۲-۱۲۲.

-Moreira Elsa E, Carlos A Coelho, Ana A. Paulo, Luis S. Pereira, Joao T. Mexia, (۲۰۰۸), **SPI-based drought category prediction using log linear models**, *Journal of Hydrology*, ۳۵۴, ۱۱۶-۱۳۰.

-Montana, D.J. and L. Davis(۱۹۸۹), **Training feed forward neural networks using genetic algorithms**, in *Proceedings of the ۱۱th international joint conference on Artificial intelligence - Volume ۱*, Morgan Kaufmann Publishers Inc.: Detroit, Michigan. p. ۷۶۲-۷۶۷.

-Mendes, R., et al.(۲۰۰۲), **Particle swarms for feed forward neural network training. in Neural Networks**, IJCNN '۰۲. *Proceedings of the International Joint Conference on*. ۲۰۰۲.

-NOAA Earth System Research Laboratory, (۲۰۰۹), <http://www.esrl.noaa.gov/psd/data/climateindices/list/>

-Parida B P, Moalafhi D B, Kenabatho P K, (۲۰۰۶), **Forecasting runoff coefficients using ANN for water resources management: The case of Notwane catchment in Eastern Botswana**, *Physics and Chemistry of the Earth*, ۳۱, ۱۱۱-۱۲۴.

-Suk shin Hyun, Jose Ana, salas D, Member ASCE, (۲۰۰۰), **Regional drought analysis based on neural networks**. *Jornal of Hydraulic Engineering*, ۵, ۱۴۵-۱۵۵.

-Sedki A D, Ouazar E, Mazoudi El, (۲۰۰۸), **Evolving neural network using real coded genetic algorithm for daily rainfall-runoff forecasting**, *Expert systems with Applications*, ۱۰.۱۰۱۶, ۵-۲۴.

-Willhite Donald A, (۲۰۰۰), **Characteristics of Drought in Kerala, India**, *A Newsletter of the International Drought Information Center and the National Drought Mitigation Center*, ۲۵, ۲-۱۴.