

## مقدمه

خشکسالی یکی از ویژگی‌های اجتناب‌ناپذیر و زیانبار اقلیمی در جهان به شمار می‌رود؛ یکی از قدم‌های مهم و اساسی در مطالعات خشکسالی و ترسالی برای بیان کمی خشکسالی و همچنین ارزیابی آن در مقیاس‌های مختلف زمانی و مکانی در هر منطقه، تعیین شاخص‌هایی است که می‌توان بر اساس آنها میزان، شدت و تداوم خشکسالی و ترسالی را ارزیابی نمود. در این میان شاخص بارش استاندارد<sup>۵</sup> یکی از جامع‌ترین شاخص‌های مطالعه خشکسالی و ترسالی به شمار می‌آید؛ تغییرپذیری SPI باعث می‌شود که در مقیاس‌های کوتاه مدت این شاخص برای بررسی خشکسالی‌های کشاورزی و در مقیاس‌های بلندمدت برای ارزیابی خشکسالی هیدرولوژی مورد استفاده قرارگیرد [۱۳]. کاربرد مدل شبکه عصبی مصنوعی<sup>۶</sup> در منابع طبیعی به طور قابل ملاحظه‌ای در دهه‌های اخیر افزایش یافته است [۱۱].

استفاده از تکنیک شبکه‌های عصبی مصنوعی از میان انواع مدل‌های غیر خطی در پیش‌بینی مسائل مربوط به مهندسی آب و هیدرولوژی نتایج درخشانی را نشان داده است [۱۵] و در اغلب موارد استفاده از (ANN) جهت پیش‌بینی و شبیه‌سازی در مسائل مربوط به منابع آب توانایی بالایی را از خود نشان داده است [۲۰] که در ذیل به برخی از آنها اشاره شده می‌گردد.

در حوضه رودخانه Mantaro روش‌های رگرسیون چند متغیره و شبکه‌های عصبی مصنوعی انتشار به عقب، برای پیش‌بینی بارش و دمای حوضه رودخانه به کار گرفته شد [۱۵]. در بررسی خشکسالی‌های شهر خاش، سه بازه زمانی یک ماهانه، سه ماهه و دوازده‌ماهه انتخاب گردید و خشکسالی با استفاده از شبکه عصبی مصنوعی، پیش-بینی گردید و مقایسه نتایج با مدل رگرسیونی نشان دهنده برتری شبکه عصبی در مقایسه با مدل رگرسیونی بود [۷].

در تحقیقی دیگر به پیش‌بینی خشکسالی با استفاده از مدل شبکه عصبی مصنوعی پرداخته شد و نتایج نشان داد، که کارایی مدل بالا است و می‌توان با دیدگاهی مثبت در پیش‌بینی مسائل هیدرولیکی به آن توجه کرد [۳].

به منظور پایش و پیش‌بینی خشکسالی در استان سیستان و بلوچستان نتایج بدست آمده نشان داد که در یک مقیاس زمانی مشخص، هر چه شدت خشکسالی بیشتر می‌شود فراوانی احتمال

 کاربرد مدل‌های شبکه عصبی مصنوعی در پیش‌بینی  
 خشکسالی استان اصفهان

مطهره اسفندیاری<sup>۱\*</sup>، حسین ملکی نژاد<sup>۲</sup>، محمدعلی حکیم زاده<sup>۳</sup> و

حمیده افخمی<sup>۴</sup>

تاریخ دریافت: ۹۴/۱۲/۰۷ تاریخ پذیرش: ۹۵/۱۲/۱۸

## چکیده

پیش‌بینی خشکسالی نقش بسزایی در برنامه‌ریزی، مدیریت و بهره‌برداری از منابع آب دارد؛ در این پژوهش برای پیش‌بینی سیکل خشکسالی در ۹ ایستگاه باران سنجی استان اصفهان از شبکه عصبی مصنوعی استفاده شده است. داده‌های مورد استفاده در این تحقیق شامل بارش ماهانه و شاخص بارش استاندارد (SPI) در ایستگاه‌های منتخب، از سال ۱۹۷۲ تا ۲۰۱۰ میلادی می‌باشد. به این منظور با استفاده از آمار موجود، مقادیر SPI برای یکسال بعد پیش‌بینی گردید. نتایج نشان داد در میان مدل‌های مختلف شبکه عصبی مصنوعی، شبکه‌های پرسپترون در اکثر ایستگاه‌ها با ضریب همبستگی بالایی قادر به پیش‌بینی مقادیر SPI در زمان آتی می‌باشد. در میان ایستگاه‌های مورد استفاده، ایستگاه کوهپایه با بالاترین ضریب همبستگی معادل ۰/۹۶ و با میانگین خطای عملکرد برابر با ۰/۰۴ بهترین عملکرد را از خود نشان داد. و ایستگاه زیار با ضریب همبستگی ۰/۸۶ و میانگین خطای ۰/۰۸۷ عملکرد پایین‌تری را نسبت به سایر ایستگاه‌ها از خود نشان داده است.

واژه‌های کلیدی: شاخص بارش استاندارد، شبکه عصبی مصنوعی، خشکسالی، اصفهان

۱- دانشجوی دکتری بیابان‌زدایی، دانشکده کشاورزی و منابع طبیعی دانشگاه یزد، نویسنده مسئول: Email: M.Esfandiari@stu.yazd.ac.ir

۲- دانشیار دانشکده کشاورزی و منابع طبیعی دانشگاه یزد

۳- استادیار دانشکده کشاورزی و منابع طبیعی دانشگاه یزد

۴- دانشجوی دکتری آبخیزداری، دانشکده کشاورزی و منابع طبیعی دانشگاه یزد.

5- Standardized Precipitation Index  
6- Artificial Neural Network

وقوع آن نیز در مقیاس‌های زمانی بلند مدت، به دلیل افزایش تعداد دفعات ضرب شدن ماتریس فراوانی در خودش کاهش می‌یابد؛ و نتیجه گرفته شد که احتمال وقوع خشکسالی در شهرستان‌های سروان و خاش در استان سیستان و بلوچستان دارای بیشترین شدت می‌باشد [۱]. در همین استان با استفاده از شاخص دهک بارش و شبکه عصبی مصنوعی، خشکسالی را مورد پایش قرار دادند و نتایج آنها نشان داد که شبکه عصبی مصنوعی با ضریب همبستگی ۰.۹۷ و میانگین خطای کمتر از ۵٪ قادر به پیش‌بینی خشکسالی می‌باشد [۶]. در تحقیقی دیگر با استفاده از مدل فازی - عصبی و سری‌های زمانی، شاخص‌های اقلیمی و دوره‌های خشکسالی در یک بازه‌ی زمانی یکساله در شهر زاهدان تعیین گردید [۲].

برای ارزیابی توانایی شبکه‌های مصنوعی در پیش‌بینی خشکسالی رودخانه پینوس کشور یونان از این تکنیک استفاده گردید، و نتیجه گرفته شد که شبکه‌های عصبی مصنوعی برای درون‌یابی مکانی خشکسالی قابل قبول بوده و می‌توان برای پیش‌بینی و پایش خشکسالی از آن استفاده کرد [۲۵].

برای توسعه مدل پیش‌بینی خشکسالی رودخانه Yarra (حوزه آبریزی در ویکتوریا، استرالیا) دو مدل شبکه عصبی مصنوعی برای پیش‌بینی مورد استفاده قرار گرفت و نتایج با مدل رگرسیونی ARIMA مقایسه شد، نتایج حاصله نشان داد که هر دو مدل شبکه عصبی مصنوعی، شامل مدل DMSNNI و RMSNN نسبت به مدل ARIMA از نتایج بهتری برخوردار هستند [۸].

به منظور پیش‌بینی خشکسالی با استفاده از شاخص خشکی SPI در دوره‌های زمانی ۳، ۶، ۱۲ و ۲۴ ماهه و با تأخیرهای زمانی ۱ تا ۶ ماهه، میشرا و همکاران بهترین ضریب کارایی را نتایج حاصله از SPI ۲۴ ماهه با تأخیر زمانی یک ماهه، با ضریب همبستگی ۰.۹۳ برآورد نمودند. [۱۹]. در پژوهشی دیگر از چندین مدل شبکه عصبی مصنوعی و دو شاخص خشکی SPI و EDI<sup>3</sup> به منظور پیش‌بینی خشکسالی برای دوره یک تا دوازده ماه آینده در شهر تهران استفاده گردید، بر اساس نتایج به دست آمده، بهترین ضریب همبستگی بین ۰.۶۶ تا ۰.۹۷ در بازه زمانی ۶ ماهه بوده است و این ضریب کارایی در بازه زمانی ۱۲ ماهه بین ۰.۵۴ تا ۰.۷۲ برآورد گردیده است [۱].

به منظور پیش‌بینی بارش در منطقه ژینگ ژوی چین از دو مدل شبکه‌های عصبی مصنوعی استفاده نمودند و نتیجه گرفتند که رگرسیون عمومی شبکه‌های عصبی مقادیر خطای پیش‌بینی کمتری را نسبت به شبکه‌های مصنوعی انتشار به عقب دارند. [۲۶]. در تحقیقی دیگر به منظور پیش‌بینی بارش در منطقه اسکندریه مصر از شبکه‌های عصبی مصنوعی استفاده گردید در این راستا مدل‌های شبکه‌های عصبی مصنوعی را با مدل رگرسیون چند متغیره مقایسه نمودند؛ نتایج مطالعات نشان داد که مدل شبکه‌های عصبی مصنوعی مناسب‌تر و دقیق‌تر می‌باشد [۲۴].

- 1- Coefficient of Correlation
- 2- Root Mean Square Error
- 3- Effective Drought Index

رضایان‌زاده و طبری، مقادیر شاخص خشکی SPI ۳، ۶، ۹، ۱۲ و ۲۴ ماهه را با استفاده از شبکه پرسپترون چند لایه محاسبه نمودند و نتایج نشان داد که پرسپترون چند لایه، شاخص خشکی SPI را در بازه زمانی ۱۲ ماهه نسبت به سایر دوره‌ها با دقت بیشتری ارائه می‌نماید [۲۲].

در تحقیقی مشابه فوق در ترکیه از مقادیر شاخص خشکی SPI ۳، ۶، ۹، و ۱۲ ماهه از شبکه عصبی مصنوعی استفاده گردید و نتایج نشان داد مقادیر شاخص خشکی SPI ۱۲ ماهه، با ضریب همبستگی ۰.۹۳ دارای بیشترین دقت در پیش‌بینی خشکسالی می‌باشد [۱۶].

با توجه به اهمیت بارش و وقوع خشکسالی‌ها در دهه‌های اخیر، در این پژوهش سعی شده با استفاده از تکنیک شبکه عصبی مصنوعی و مقادیر شاخص خشکسالی SPI، کارایی مدل در رابطه با پیش‌بینی خشکسالی در استان اصفهان ارزیابی گردد.

## مواد و روش‌ها

### ویژگی‌های منطقه مورد مطالعه

استان اصفهان در ۴۲° ۳۰' تا ۳۴° ۳۰' عرض شمالی و ۳۶° ۴۹' تا ۵۵° ۳۲' طول شرقی در زون ایران مرکزی واقع شده است. مطالعات آب و هوایی نشان می‌دهد که استان اصفهان بر روی کمربند بیابانی نیم‌کره شمالی قرار گرفته است به طوری که نیمی از مساحت استان را بیابان تشکیل می‌دهد. از ویژگی‌های اقلیمی استان بارش کم و زیاد بودن میزان تبخیر است که زندگی و فعالیت‌های اقتصادی را محدودتر کرده به طوری که زراعت را به آبیاری متکی می‌سازد و میزان آن به ویژه در فصل گرم سال بسیار قابل ملاحظه می‌باشد و تابستان، بحرانی‌ترین شرایط را از نظر تأمین آب به خصوص در شمال و شرق استان عرضه می‌دارد [۲۳]، خصوصیات ایستگاه‌های مورد استفاده در این تحقیق در جدول (۱) آمده است.

جدول ۱- موقعیت جغرافیایی ایستگاه‌های مورد مطالعه

ایستگاه کلیماتولوژی	طول جغرافیایی	عرض جغرافیایی	ارتفاع (متر)
زیار	۵۱۷۹۷۵	۳۶۹۷۲۲۰	۱۵۴۰
ورزنه	۵۴۳۳۷۱	۳۶۵۹۸۳۰	۱۲۵۰
تیران	۵۱۴۷۸۸	۳۶۱۸۲۲۵	۱۸۶۰
پل زمان خان	۵۲۱۶۸۸	۳۵۸۱۸۱۱	۱۷۶۰
مورچه خورت	۵۸۷۳۰۷	۳۷۰۷۷۹۲	۱۷۵۰
میمه	۵۷۵۹۶۹	۳۵۷۰۸۹۶	۱۴۷۰
مهیار	۵۹۴۹۶۱	۳۵۲۰۴۹۲	۱۹۶۷
مقصود بیک	۶۳۴۸۴۹	۳۶۲۴۶۱۲	۱۸۸۷
کوهپایه	۶۵۴۸۵۹	۳۵۸۱۱۲۳	۱۹۶۴

## شاخص بارش استاندارد (SPI)

مک کی و همکاران در سال ۱۹۹۳ شاخص SPI را به منظور پایش وضعیت خشکسالی توسعه دادند. شاخص SPI با مقایسه کل بارندگی تجمعی برای یک ایستگاه یا ناحیه خاص در یک فاصله زمانی مشخص با میانگین دراز مدت بارندگی برای همان فاصله زمانی در طول دوره آماری بدست می‌آید. مشخصه اصلی SPI، انعطاف پذیری در اندازه‌گیری خشکسالی در مقیاس‌های زمانی متفاوت است، زیرا خشکسالی‌ها از لحاظ مدت، بسیار گسترده هستند. بنابراین تشخیص و پیش‌بینی آنها با انواع مقیاس‌های زمانی مهم است. با توجه به این موضوع مک کی و همکاران مقیاس‌های زمانی ۳، ۶، ۱۲، ۲۴، و ۴۸ ماهه را برای تحلیل خشکسالی مد نظر قرار دادند [۷].

برای محاسبه SPI توزیع گاما بر سری‌های زمانی داده‌های بارندگی برازش داده می‌شود و به این ترتیب احتمال تجمعی بارندگی برای ماه مشخص بدست می‌آید. تابع چگالی احتمال<sup>۱</sup> توزیع گاما به صورت زیر تعریف می‌شود [۱۸].

$$f(x) = \frac{1}{\beta^{\alpha} \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \quad [1]$$

که در این رابطه  $x \geq 0$ ،  $\alpha > 0$  پارامتر شکل (Shape parameter)،  $\beta > 0$  پارامتر مقیاس (Scale parameter) و  $\Gamma(\alpha)$  تابع گاما هستند. این احتمال به متغیر تصادفی Z تبدیل گردید که یک مقدار نرمال شده با میانگین صفر و انحراف معیار یک است. در واقع SPI مقدار انحراف استاندارد است که یک رویداد مشخص از شرایط نرمال منحرف می‌شود [۱]. بر این اساس طبقه‌بندی خشکسالی بر اساس مقادیر SPI در جدول ۲ ارائه شده است.

جدول ۲- طبقه‌بندی خشکسالی بر اساس شاخص SPI [۱۹]

مقادیر شاخص	شدت خشکسالی
۲/۰۰ و بیشتر	ترسالی خیلی شدید
۱/۵۰ تا ۱/۹۹	ترسالی شدید
۱/۰۰ تا ۱/۴۹	ترسالی ملایم
۰/۹۹ تا -۰/۹۹	نزدیک به نرمال
-۱/۰۰ تا -۱/۴۹	خشکسالی ملایم
-۱/۵۰ تا -۱/۹۹	خشکسالی شدید
-۲/۰۰ و کمتر	خشکسالی خیلی شدید


## شبکه‌های عصبی مصنوعی

شبکه عصبی مصنوعی در واقع، مدل ساده شده‌ای از مغز انسان

1- Probability Density Function

است که توانایی شبیه‌سازی فرایندها و ترکیبات دلخواه غیرخطی برای ارتباط بین ورودی و خروجی‌های هر سیستمی را دارا می‌باشد ضمناً این شبکه، با داده‌های موجود طی فرایند یادگیری، آموزش داده می‌شود و به منظور پیش‌بینی در آینده استفاده می‌شود [۲۲]. در این تحقیق شبکه عصبی از سه لایه تشکیل شده که عبارت‌اند از: لایه ورودی، این لایه شامل ۱۲ نرون می‌باشد. تعداد نرون‌ها در این لایه پنهان متغیر است و لایه خروجی، شامل یک خروجی می‌باشد. شایان ذکر است برای افزایش سرعت شبکه در این لایه از تابع فعال استفاده می‌شود تا با استفاده از آن هم سرعت یادگیری افزایش یابد و هم مقادیر خروجی بدون تغییر به شبکه ارائه شود و در نهایت، خروجی مطلوب را بسازد. در سال‌های اخیر، چندین تقریب‌گر عمومی تابع پیشنهاد شده است که از آن جمله می‌توان به پرسپترون چندلایه<sup>۲</sup> (MLP) اشاره کرد. شبکه‌های پرسپترون یکی از انواع شبکه‌های عصبی می‌باشد که از چندین لایه و تعدادی نرون تشکیل شده است که هر نرون به وسیله اتصالاتی به نرون‌های لایه مجاور وصل می‌شوند [۱۷] (شکل ۲). تحقیقات نشان داده، جهت حل بسیاری از توابع غیرخطی پیچیده وجود یک لایه پنهان در شبکه‌های پرسپترون کافی می‌باشد [۴]. همچنین متداولترین الگوریتم یادگیری در این شبکه‌های پرسپترون لونیبرگ مارکووات<sup>۳</sup> می‌باشد که این الگوریتم پایدار و دارای بازدهی بالا می‌باشد [۲۵] و نسبت به الگوریتم کاهش شیب نزولی<sup>۴</sup> قوی‌تر عمل می‌نماید [۹].

در این پژوهش نیز از الگوریتم لونیبرگ مارکووات در شبکه‌های پرسپترون استفاده گردید.



شکل (۱): نمونه ساده‌ای از شبکه‌های عصبی پرسپترون چند لایه جهت برآورد خشکسالی

در تحقیق حاضر که به منظور پیش‌بینی شاخص بارش استاندارد انجام گرفته است از آمار ۹ ایستگاه باران سنجی با دوره آماری ۴۰ سال و بالاتر استفاده گردیده است که آمار مورد نیاز از سازمان هواشناسی و سازمان آب منطقه‌ای استان دریافت و تجزیه و تحلیل گردید. در نهایت ۳۰ سال دوره آماری مشترک از سال ۱۹۷۹ تا ۲۰۱۰ میلادی برای مطالعه انتخاب گردید؛ دلیل انتخاب دوره آماری ۳۰ ساله، این است که اولاً داده‌های موجود در سالهای اخیر با توجه

2- Multi Layer Perceptron

3 - Levenberg-Marquardt

4 - Gradient Descent

به افزایش اطلاعات دیده‌بانها و گسترش تکنولوژی ثبت داده‌ها، از دقت و اعتبار بیشتری برخوردارند و ثانیاً به دلیل خلأ کمتر اطلاعات و آمار هواشناسی در این بازه زمانی، میزان داده‌های بازسازی شده کمتر است.

پس از اخذ اطلاعات، ابتدا داده‌های بارش ایستگاه‌ها با آزمون‌های آماری از جمله تست همگنی با استفاده از روش ران تست و تست داده‌های پرت، آزمون کفایت و استقلال داده‌ها، آزمون نرمال بودن داده‌ها بررسی شد و صحت دادها تأیید گردید.

پس از بازسازی داده‌های ناقص توسط روش نسبت نرمال، مقادیر شاخص بارش استاندارد (SPI) به صورت ماهانه محاسبه گردید، به این ترتیب داده‌ها جهت ورود به مدل شبکه عصبی مصنوعی آماده گردیدند. به این منظور بعد از تصادفی کردن داده‌ها ۷۰ درصد داده‌ها جهت آموزش شبکه و ۳۰ درصد داده‌ها برای تست و اعتبارسنجی اختصاص داده شد و در نهایت جهت اعتبارسنجی مدل، نتایج پیش‌بینی با مقادیر واقعی مقایسه و میزان خطا محاسبه گردید.

## نتایج و بحث

### ارزیابی عملکرد شبکه عصبی مصنوعی

آماره‌های مورد استفاده در این تحقیق، جهت ارزیابی مدل‌ها شامل ضریب همبستگی (R)، و جذر میانگین مربعات خطا (RMSE) می‌باشد که مطابق با معادلات ۲ و ۳، استفاده، و نتایج بر اساس بالاترین ضریب کارایی و کمترین خطا ارزیابی و ارائه گردید است.

$$r = \sqrt{1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2}} \quad [2]$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad [3]$$

که در آن  $O_i$  داده‌های مشاهداتی  $P_i$  داده‌های شبیه‌سازی شده و  $n$  تعداد داده‌ها است [۱۲].

با استفاده از بسته نرم افزار متلب<sup>۱</sup> ساختار مناسب شبکه عصبی، تابع محرک، تعداد نرون‌ها، تعداد لایه‌های پنهان، و لایه‌های ورودی و خروجی با آزمون و خطا تست، و در نرم افزار متلب ترسیم شد که نمونه آن در شکل (۲) آورده شده است. الگوریتم مارکوات - لونیبرگ در میان سایر الگوریتم‌ها، در مرحله آموزش و آزمون بالاترین همبستگی را در تمام ایستگاه‌ها داشت که نشان از دقت بالای مدل ANN می‌باشد.

نتایج بررسی داده‌های ورودی به شبکه با پنج تابع آموزشی GDA , Train LM , Train GD , Train SCG , Train GDX در جدول ۳ آمده است؛ همان‌طور که از جدول مشخص است،

کمترین خطا برابر است با ۰/۰۵ مربوط به تابع LM بیشترین مقدار خطا برابر است ۰/۲ مربوط به تابع GD بدیهی است که میزان خطای شبکه بسیار کم است (کمتر از ۰/۳) و نتایج شبیه‌سازی شده تا حد بسیار قابل قبولی به مشاهدات واقعی نزدیک است و می‌توان گفت شبکه از عملکرد بسیار مناسبی برخوردار است.

جدول ۳- مقادیر آماره‌های برازش در ورودی و توابع آموزش

توابع آموزشی	Train R	Train RMSE
GDA	۰/۷۳	۰/۱۸
GDX	۰/۸۹	۰/۱
SCG	۰/۹۳	۰/۰۸
LM	۰/۹۷	۰/۰۵
GD	۰/۷۵	۰/۲

همچنین مناسبترین تعداد اپک<sup>۲</sup> در شبیه‌سازی‌ها جهت بهینه‌سازی با آزمون و خطا، بین ۱۰۰ - ۶۰۰ در نظر گرفته شده است. نتایج بدست آمده در مرحله ارزیابی مدل بر اساس زوابط ۲ و ۳ و در ایستگاه‌های مختلف که حاصل پیش‌بینی شاخص SPI برای ۱۲ ماه بعد می‌باشد در جدول ۴ ارائه شده است.

نتایج تحقیق حاضر نیز که به پیش‌بینی شاخص SPI و برای تاخیر زمانی ۱۲ ماهه انجام گرفته است نشان می‌دهد کارایی مدل شبکه عصبی مصنوعی در شبیه‌سازی شاخص SPI بالا می‌باشد به طوری که میزان ضریب همبستگی در این تحقیق بین ۰/۸۶ - ۰/۹۶ متغیر می‌باشد و این در حالی است که ایستگاه‌های مورد استفاده در منطقه نسبتاً خشک واقع شده و نوسانات بارش و بالتبع شاخص SPI در این مناطق نسبتاً بالا و پیچیده می‌باشد.

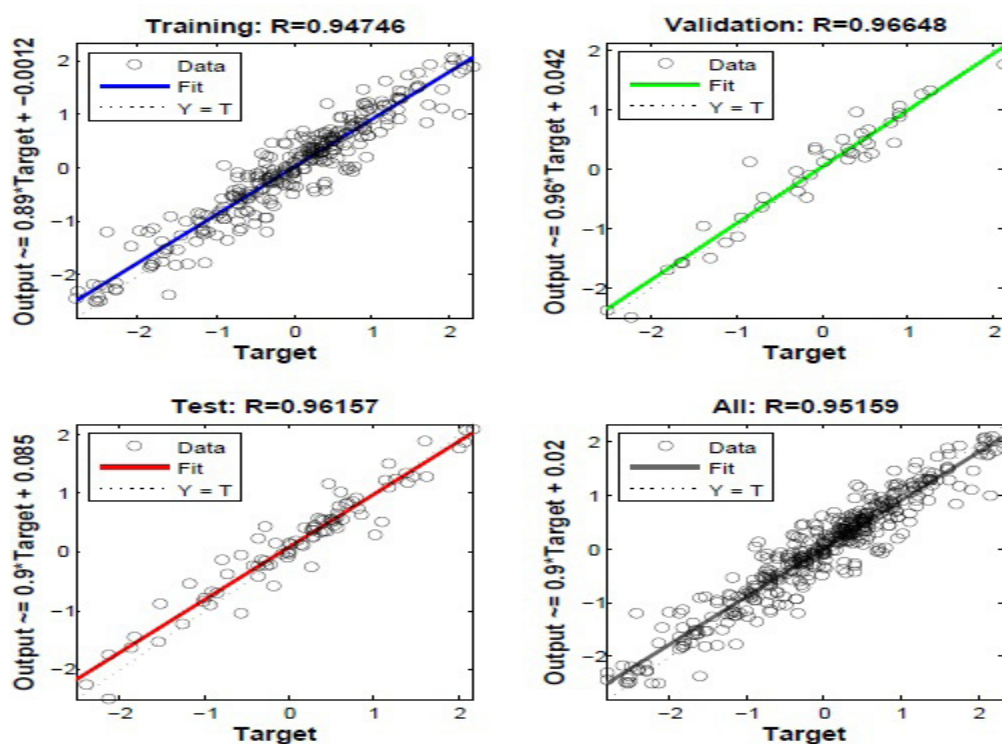
همان‌طور که نتایج جدول ۳ نشان می‌دهد در تمام ایستگاه‌ها الگوریتم یادگیری لونیبرگ مارکوات در مرحله آموزش به عنوان بهترین الگوریتم مورد استفاده قرار گرفت. تابع محرک سیگنویید در شبکه عصبی پرسپترون در لایه پنهان و خروجی بهترین عملکرد را از خود نشان داد. بر این اساس بهترین عملکرد مدل در ایستگاه کوهپایه مشاهده می‌گردد که ضریب همبستگی بین داده‌های مشاهداتی و شبیه‌سازی شده حدود ۰/۹۶ و همچنین در مقایسه با سایر ایستگاه‌ها کمترین خطا را با مقدار ۰/۰۴۶ دارا می‌باشد. شکل ۳ و ۴ به ترتیب نمودار خطی و نقطه‌ای بین داده‌های مشاهده‌ای و شبیه‌سازی شده را در ایستگاه کوهپایه نشان می‌دهند.

علاوه بر این در میان ۹ ایستگاه مدل‌سازی شده در این تحقیق، ایستگاه زیار با ضریب همبستگی ۰/۸۶ و بیشترین میزان خطا با مقدار ۰/۰۸۷ پایین‌ترین عملکرد را از خود نشان داد.

جدول (۴): نتایج حاصل از شبیه‌سازی خشکسالی با استفاده از شبکه عصبی مصنوعی پرسپترون

RMSE	r	تعداد نرون در لایه پنهان (۲n)	تابع فعال (لایه خروجی)	تابع فعال (لایه پنهان)	نام ایستگاه کليماتولوژی
۰/۰۷۷	۰/۹۱	۱۰	pureline	tansig	مهیاری
۰/۰۴۶	۰/۹۶	۱۹	pureline	tansig	کوهپایه
۰/۰۷۴	۰/۸۹	۱۱	pureline	tansig	مقصود بیک
۰/۰۷۶	۰/۹۱	۱۰	pureline	tansig	مورچه خورت
۰/۰۶۱	۰/۹۵	۱۰	pureline	tansig	میمه
۰/۰۷۳	۰/۹۲	۱۰	pureline	tansig	پل زمان خان
۰/۰۷۳	۰/۹۲	۱۵	pureline	tansig	تیران
۰/۰۶۴	۰/۹۳	۱۷	pureline	tansig	ورزنه
۰/۰۸۷	۰/۸۶	۱۲	pureline	tansig	زیار

n = تعداد نرون لایه ورودی

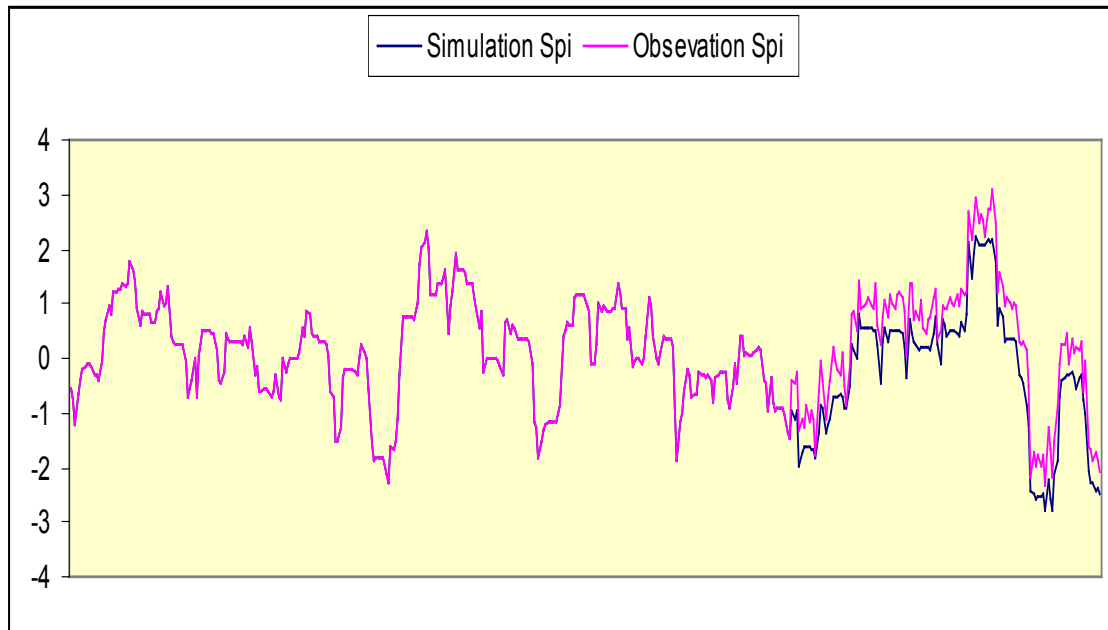


شکل ۲ - نمونه‌ای از همبستگی مقادیر شاخص SPI با الگوریتم LM (ایستگاه کوهپایه).


### نتیجه‌گیری نهایی

با توجه به پیچیدگی پدیده خشکسالی و اهمیت پایش و پیش‌بینی شاخص‌های آن بخصوص در مباحث مدیریت منابع آب در استان‌های خشک و نیمه‌خشک، نتایج این تحقیق، پیش‌بینی موفقیت آمیز مدل‌های هوشمند را در پیش‌بینی پارامترهای پیچیده به اثبات

شکل ۵ و ۶ به ترتیب نمودار خطی و نقطه‌ای بین داده‌های مشاهده‌ای و شبیه‌سازی شده را در ایستگاه زیار نشان می‌دهد. نتایج این تحقیق با نتایج حلبیان و دارند در پیش‌بینی بارش در استان اصفهان با استفاده از تلفیق شبکه عصبی مصنوعی و الگوریتم ژنتیک کاملاً مطابقت دارد [۱۴].



شکل ۳- نمودار خطی مقایسه داده‌های مشاهده‌ای و شبیه‌سازی شده شاخص SPI، ایستگاه کوهپایه

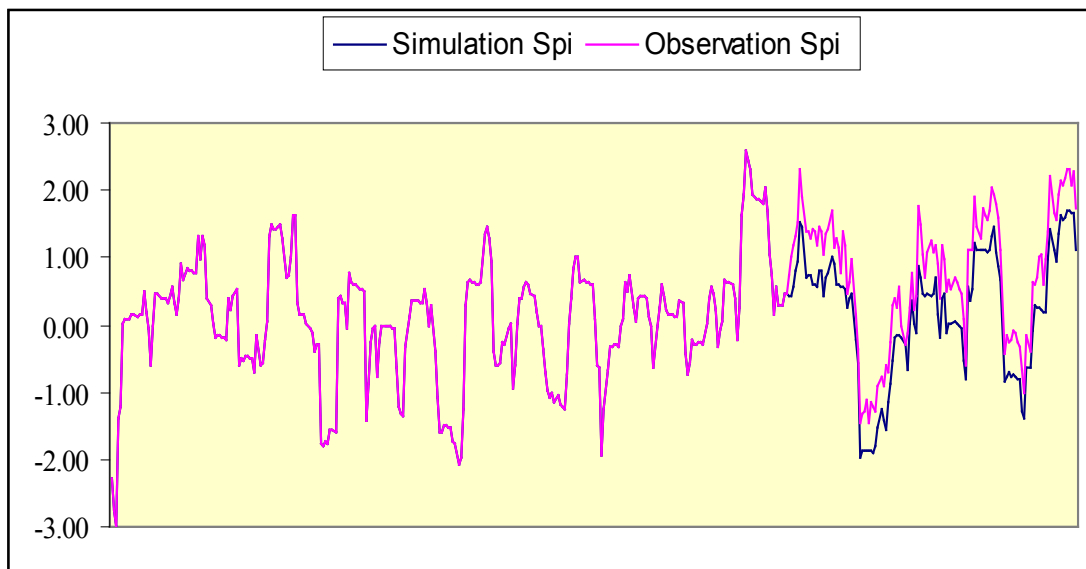


شکل ۴- نمودار نقطه‌ای مقایسه داده‌های مشاهده‌ای و شبیه‌سازی شده شاخص SPI، ایستگاه کوهپایه.


خشکسالی با توجه به ماهیت متغیر آن بخصوص در زمان قبل از وقوع به ویژه در منطقه‌ای نسبتاً خشک مانند اصفهان کاری دشوار بوده و اغلب روش‌های موجود قادر نیستند آن را با دقت قابل قبول پیش‌بینی نمایند. با توجه به نتایج حاصله می‌توان گفت شبکه‌های پرسپترون چندلایه، مدلی مناسب در پیش‌بینی شاخص SPI می‌باشد

می‌رساند. اگر چه نتایج بدست آمده در ۹ ایستگاه مورد بررسی در این تحقیق متفاوت هستند اما در مقایسه، این تفاوت اندک می‌باشد و مقادیر بالای ضریب همبستگی و خطای پایین در تمام ایستگاه‌های مدل‌سازی شده در این تحقیق موید قابل اعتماد بودن عملکرد شبکه عصبی مصنوعی می‌باشد. لازم به ذکر است که پیش‌بینی شاخص





شکل ۵- نمودار خطی مقایسه داده‌های مشاهده‌ای و شبیه‌سازی شده شاخص SPI، ایستگاه زیار



شکل ۶- نمودار نقطه‌ای مقایسه داده‌های مشاهده‌ای و شبیه‌سازی شده شاخص SPI، ایستگاه زیار

#### منابع

۱. حسن‌زاده، یوسف، عبدی کردانی، امین و احمد فاخری فرد، ۱۳۹۱. پیش‌بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی - موجکی، دو ماهنامه آب و فاضلاب، (۳): ۲۲، ۴۸ - ۵۹.
۲. حسین‌پور نیک‌نام، حسین، خسروی، محمود و مهدی اژدری مقدم. ۱۳۹۱. پیش‌بینی خشکسالی یکساله با استفاده از مدل فازی-عصبی، سریهای زمانی خشکسالی و شاخص‌های اقلیمی (مطالعه

و در نهایت با توجه به نتایج بدست آمده از شاخص خشکسالی SPI در ۱۲ ماه آینده و مقایسه آن با میانگین دراز مدت بارش می‌توان به احتمال وقوع وضعیت ترسالی و یا خشکسالی در آینده پی برد. نتایج تحقیق حاضر نشان می‌دهد کارایی مدل شبکه عصبی مصنوعی در شبیه‌سازی شاخص SPI بالا می‌باشد به‌طوری‌که میزان ضریب همبستگی در این تحقیق بین ۰/۸۶-۰/۹۶ متغیر می‌باشد، نتایج کلی بدست آمده از این تحقیق با نتایج خوشحال دستجردی و حسینی مطابقت دارد [۳].

drought index and the standardized precipitation index. *Journal of American Water Resources Associatio.* 2(35): 311-322

14. Halabian, A.H. and Darand, M. 2012. Prediction of rainFall using artificial neural networks. *Geographical Sciences College of Applied Research.* (12)26: 47-63

15. Karen, A.L.S . 2010. Comparison of adaptive methods using multivariate regression splines (MARS) and artificial neural networks backpropagation (ANNB) for the forecast of rain and temperatures in the Mantaro river basin. *Hydrology Days.* 58-68

16. Keskin, M.E., Terzi, O. and Taylan, E.D. and Kucukyaman, D. 2011. Meteorological drought analysis using artificial neural networks. *Academic journals.* 6( 21): 4469-4477

17. Lucio, P. S., Conde, F. C., Cavalcanti, I. F. A., Serrano, A.I., Ramos, A.M. and ardos, A.O. 2007. Spatiotemporal monthly rainFall reconstruction via artificial neural network ( case study:South Brazil). *Adv. Geosci,* 10,67-76.

18. Mishra, A.K. and Desai, V.R. 2005. Drought forecasting using stochastic models. *Jornal of Stochastic Environmental Research and Risk Assessment.* 19(5):326-339

19. Mishra, A.K., Singh, V.P. and Desai, V.R. 2009. Drought characterization: A probabilistic approach. *Stochastic Environmental Research and Risk Assessment.* 23(1): 41-55

20. Mishra, A. K. 2007. Drought forecasting using a hybrid stochastic and neursl network model. *Journal of Hydrology, Eng. ASCE.* 12: 626-638

21. . Morid, S., Bagherzadeh, R. and Smakhtin, V. 2007. Drought forecasting using artificial neural networks and time seried of drought indices. *Intl, Journal of Climatology.* 21: 2103-2111

22. Parker, D.B. 1982. *Learning Logic:* Stanford University. Stanford, Claifornia, Offoice of Technology Licensing, Invention Report S81-64, File1, pp119.

23. Rezaeian Zadeh, M. and Tabari, H. 2012.

موردی: زاهدان). دو ماهنامه آب و فاضلاب، ۲۳ (۲): ۴۲ - ۵۱.

۳. خوشحال دستجردی، جواد و سیدمحمد حسینی. ۱۳۸۹. کاربرد شبکه عصبی مصنوعی در شبیه‌سازی عناصر اقلیمی و پیش‌بینی سیکل خشکسالی ( مطالعه موردی :استان اصفهان). مجله جغرافیا و برنامه ریزی محیطی، ۲۱(۳): ۱۲۰ - ۱۰۷.

۴. سعادت، سیده سارا، سلطان، سعید و سیدسعید اسلامیان. ۱۳۸۸. بررسی آماری دوره بازگشت وضعیت‌های مختلف خشکسالی (میانگین، شدید، خیلی شدید) در استان اصفهان با بهره‌گیری از شاخص استاندارد بارش. نشریه مرتع و آبخیزداری، مجله منابع طبیعی ایران، ۶۲، (۲): ۲۶۹ - ۲۵۷.

۵. علیزاده، امین، انصاری، حسین، ارشادی سارا، و شادی آشگر طوسی. ۱۳۸۷. پایش و پیش‌بینی خشکسالی در استان سیستان و بلوچستان. مجله‌ی جغرافیا و توسعه‌ی ناحیه‌ای، ۱۱(۱): ۱۷ - ۱.

۶. ملکیان، آرش، ده‌بزرگی مهرو، احسانی، امیرهوشنگ و میررضا کشتکار. ۱۳۹۲. کاربرد شبکه‌ی عصبی مصنوعی در پیش‌بینی و شبیه‌سازی شاخص اقلیمی خشکسالی هواشناسی دهک بارش (مطالعه‌ی موردی: استان سیستان و بلوچستان). نشریه مرتع و آبخیزداری، مجله منابع طبیعی ایران، ۶۷، (۱): ۱۳۹ - ۱۲۷.

۷. نگارش، حسین و محسن آرمش. ۱۳۹۰. پیش‌بینی خشکسالی شهر خاش با استفاده از مدل شبکه عصبی. نشریه مطالعات جغرافیایی مناطق خشک، ۶ (۲): ۵۰ - ۲۳.

8. Barua, S., Ng, A. and Perera, B. 2012. Artificial neural network based drought forecasting using anonlinear aggregated drought index, *Journal of hydrologic engineering;* 17(12): 1408-1413

9. Cigizoglu, H. K. and Kisi, O. 2004. Flow prediction by three back propagation techniques using k-fold partitioning of neural network training data. *Nordic Hydrol,* 36: 49-64.

10. Cybenco, G. 1989. Approximation by superposition of a sigmoidal function. *Mathematics of control. Signals and Systems.* 2: 303-314.

11. Dogan, A., Demirpence, H. and Cobaner, M. 2008. Prediction of groundwater level from lake levels and climate data using ANN approach. *Journal of Water Resources Associatio.* 34(2): 199-208

12. Fatehimarj, A. and Meijerink, A.M.J. 2011. Agricultural drought forecasting using satellite images, climate indices and artificial neural network. *International journal of remote sensing.* 32(24): 9707-9719

13. Guttman, N.B. 1999. Comparing the



25. Toth, E., Brath, A. and Montanari, A. (2000). Comparison of short-term rainfall prediction model for real-time flood forecasting. *Journal of Hydrology*. 239:132-147.

26. Wang, Z.L. and Sheng, H.H. 2010. Prediction of Rainfall Using Generalized Regression Neural Network: Case study Zhengzhou. *International Conference on Computational and Information Sciences*. 17-19 December. 1265-1268

MLP-Based drought forecasting in different climatic regions. *Theoretical and Applied Climatology*. 1-8.

24. Shafie, A., El-Shafie, H., Hasan, A., El Mazoghi, G., Shehata, A. and Taha Mohd, R. 2011. Artificial neural network technique for rainfall forecasting applied to Alexandria, Egypt. *International Journal of the Physical Sciences*. 6(6): 1306-1316

*Abstract*

## Application of Artificial Neural Network Models to Estimate Droughtness of Isfahan Province

M. Esfandyari<sup>1\*</sup>, H. malekinezhad<sup>2</sup>, M.A. Hakimzadeh<sup>3</sup> and H. Afkhami<sup>4</sup>

Received: 2016/02/26 Accepted: 2017/03/08

Drought prediction has been playing important role in the planning management and using of water resources. In this research for drought predicting in 9 rain gauges station the Artificial Neural Network were used. The data used in this research is precipitation and the Standardized Precipitation Index (SPI), selected stations from 1972 to 2010 sets. The results obtained showed that among the Artificial Neural Networks models, in the most stations the Multi Layer Perceptron (MLP) has been able to predicting of SPI values with high correlation. Among the using stations, the Koochpayeh station showed the best action with correlation of  $r= 0.96$  and  $RMSE= 0.04$  and Ziyar station showed correlation of  $r= 0.86$  and  $RMSE= 0.087$ , the lower performance than the other stations are shown.

**Keywords:** *Standardized precipitation index, Artificial neural network, Droughtness, Isfahan*

---

1. Ph.D, Student of Combat Desertification, Yazd University.corresponding author: Email M.Esfandiari@stu.yazd.ac.ir  
2. Associate Prof, Faculty of Agriculture and Natural Resources. University of Yazd, Iran.  
3. Assistant Prof, Faculty of Agriculture and Natural Resources, University of Yazd, Iran.  
4. Ph.D, Student of Watershed Management Sciences and Engineering, Yazd University.