

## تحلیل خشکسالی هواشناسی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات – شبکه‌های عصبی مصنوعی بر مبنای شاخص MSPI

مریم شفیعی نجد<sup>۱\*</sup>، یوسف حسن زاده<sup>۲</sup>، محمد تقی اعلمی<sup>۲</sup>، امین عبدی کردانی<sup>۳</sup>

تاریخ دریافت: ۹۶/۰۹/۲۲

تاریخ پذیرش: ۹۷/۰۷/۱۰

۱- دانش‌آموخته کارشناسی ارشد، گروه مهندسی عمران، پردیس خودگردان تبریز، دانشگاه تبریز

۲- استاد، گروه مهندسی عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز

۳- دانش‌آموخته دکتری، گروه مهندسی عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز

\* مسئول مکاتبات، پست الکترونیکی: mshafieinajd@yahoo.com

### چکیده

پدیده خشکسالی یکی از بلاهای طبیعی می‌باشد که احتمال وقوع آن در تمام مناطق اقلیمی امکان‌پذیر است و در هر منطقه‌ای که روی می‌دهد، باعث ایجاد آسیب‌های جدی در محیط زیست و زندگی انسان‌ها می‌شود. بنابراین، پیش‌بینی این پدیده مضر، می‌تواند تأثیر قابل توجهی در مدیریت منابع آب داشته باشد و آثار مخرب آن را تا حد امکان کاهش دهد. در این مطالعه، ابتدا با استفاده از شاخص بارندگی استاندارد شده چند متغیره (MSPI)، مشخصه‌های خشکسالی در حوضه آبریز ليقوان‌چای به دست آمد و سپس از شبکه‌های عصبی مصنوعی (ANN) جهت پیش‌بینی شاخص فوق استفاده گردید. جهت آموزش شبکه‌های عصبی مصنوعی و تخمین بهینه وزن‌های آن، الگوریتم بهینه‌سازی ازدحام ذرات (PSO) به کار برده شد و عملکرد آن با الگوریتم پس انتشار خطا (BP) مورد مقایسه قرار گرفت. در این راستا سناریوها و ساختارهای مختلفی در نظر گرفته شد و سپس با استفاده از آزمون‌های نیکویی برازش، میزان دقت هر یک از آن‌ها محاسبه گردید. نتایج حاصل، برتری مدل ANN-PSO نسبت به مدل ANN-BP در پیش‌بینی خشکسالی را نشان داد.

واژه‌های کلیدی: الگوریتم بهینه‌سازی ازدحام ذرات، حوضه آبریز ليقوان‌چای، خشکسالی هواشناسی، شاخص بارندگی استاندارد شده چند متغیره، شبکه‌های عصبی مصنوعی

## Meteorological Drought Analysis Using Particle Swarm Optimization Algorithm- Artificial Neural Networks Based on MSPI Index

M Shafiei Najd<sup>1\*</sup>, Y Hassanzadeh<sup>2</sup>, MT Alami<sup>2</sup>, A Abdi Kordani<sup>3</sup>

Received: 2017-12-13

Accepted: 2018-10-02

<sup>1</sup> Graduate, Civil Engin. Dept., Tabriz Campus, Univ. of Tabriz, Iran

<sup>2</sup> Prof., Water Engin. Dept., Faculty of Civil Engin., Univ. of Tabriz, Iran

<sup>3</sup> Graduate, Water Engin. Dept., Faculty of Civil Engin., Univ. of Tabriz, Iran

\*Corresponding Author, Email: mshafieinajd@yahoo.com

### Abstract

The drought phenomenon is one of the natural disasters, which may occur in all climatic zones and cause serious damages to the environment and human life. So, forecasting this phenomenon may have significant impact on the water resources management and reduce its destructive effects as much as possible. In this study, the multivariate standardized precipitation index (MSPI) was utilized to compute the drought characteristics in the Lighvanchai basin and then the artificial neural network (ANN) was used to forecast the MSPI values. In order to train the ANN and estimate its optimized weights, the particle swarm optimization (PSO) algorithm was applied and its performance was compared with the backpropagation (BP) algorithm. In this context, different scenarios and structures were considered and then the goodness-of-fit tests were utilized for evaluating the accuracy of them. The results demonstrated that the ANN-PSO model had a better performance than the ANN-BP model for drought forecasting.

**Keywords:** Artificial neural network, Lighvan Chai Basin, Meteorological drought, Multivariate standardized precipitation index, Particle swarm optimization algorithm

### مقدمه

محاسبه می‌گردد و دربرگیرنده مقیاس‌های زمانی مختلف شاخص SPI می‌باشد. این شاخص، یک رویکرد چندمتغیره بر مبنای تحلیل مولفه‌های اصلی<sup>۲</sup> (PCA) داشته که توانایی تجمیع انواع سری‌های زمانی SPI و تبدیل آن‌ها به یک سری زمانی جدید، بر اساس اولین مولفه اصلی را دارا می‌باشد. بذرافشان و همکاران (۲۰۱۴) شاخص MSPI را بر اساس شاخص SPI در مقیاس‌های زمانی مختلف (از قبیل ۳-۶، ۳-۱۲، ۳-۱۲، ۳-۲۴ و ۱۲-۴۸ ماهه) در چهار ایستگاه مختلف در

خشکسالی به‌عنوان یکی از بلایای طبیعی، قرن‌ها دامنگیر جوامع بشری بوده و خسارات مادی و معنوی بسیاری ایجاد نموده است. برای تحلیل و ارزیابی خشکسالی، شاخص‌های مختلفی وجود دارد که یکی از جدیدترین آن‌ها، شاخص بارندگی استاندارد شده چند متغیره<sup>۱</sup> (MSPI) می‌باشد که توسط بذرافشان و همکاران در سال ۲۰۱۴ ارائه گردیده است. شاخص MSPI بر اساس شاخص بارندگی استاندارد شده (SPI)

<sup>2</sup> Principal component analysis

<sup>1</sup> Multivariate standardized precipitation index

سرعت همگرایی پایین و همچنین گیر افتادن در بهینه‌های محلی برخوردار می‌باشد، قادر به تخمین بهینه‌های سراسری مخصوصاً برای مدل‌های با ساختار پیچیده نمی‌باشد (ژنگ و همکاران ۲۰۰۷). بنابراین لازم است از روشی دیگر همچون الگوریتم بهینه‌سازی ازدحام ذرات<sup>۲</sup> (PSO) که یکی از الگوریتم‌های فراکاوشی<sup>۳</sup> می‌باشد، جهت آموزش شبکه‌های عصبی مصنوعی استفاده گردد. در زمینه استفاده از الگوریتم PSO در شبکه‌های عصبی مصنوعی، تحقیقات بسیار کمی وجود دارد. به‌عنوان مثال، چاوو و همکاران (۲۰۰۶) از الگوریتم PSO به‌عنوان یک الگوریتم آموزش شبکه‌های عصبی مصنوعی، جهت پیش‌بینی سطح آب رودخانه شینگون در هنگ کنگ بهره گرفت. پیتروسکی و ناپیورکوسکی (۲۰۱۱) جهت پیش‌بینی رواناب در حوضه رودخانه آنابولیس کانادا، از روش‌های بهینه‌سازی مختلف برای آموزش شبکه‌های عصبی مصنوعی استفاده نمودند و سپس با الگوریتم‌های مبتنی بر گرادیان<sup>۴</sup> در شبکه عصبی پرسپترون چند لایه<sup>۵</sup> استفاده نمودند. اسدنیا و همکاران (۲۰۱۴) از الگوریتم‌های PSO و BP جهت آموزش شبکه‌های عصبی مصنوعی در پیش‌بینی تراز سطح آب حوضه هشوی چین استفاده نمودند. تاپوولو و همکاران (۲۰۱۴) جهت پیش‌بینی تراز آب زیرزمینی در دو منطقه آگیا و چانیا کشور یونان، از شبکه‌های عصبی مصنوعی استفاده نمودند. در این تحقیق، سه مدل از الگوریتم PSO برای آموزش وزن‌های شبکه‌های عصبی مصنوعی در نظر گرفته شد. نتایج تحقیقات فوق نشان‌دهنده این مطلب است که الگوریتم PSO می‌تواند به‌عنوان یک الگوریتم آموزشی جایگزین در شبکه‌های عصبی مصنوعی استفاده گردد.

با توجه به مطالب ذکر شده، اهداف تحقیق حاضر را می‌توان به‌صورت خلاصه ذکر نمود: (۱) استفاده از شاخص جدید MSPI جهت به‌دست آوردن مشخصات خشکسالی؛ (۲) آموزش شبکه‌های عصبی

مناطق آب و هوایی کویری تا مرطوب ایران مورد محاسبه و ارزیابی قرار دادند و نشان دادند که مولفه اصلی اول، قابلیت بیان بیش از ۷۴ درصد از ویژگی‌های مجموعه شاخص SPI انتخاب شده را دارا می‌باشد. بنابراین به‌جای استفاده از سری‌های زمانی مختلف شاخص SPI که ممکن است باعث سردرگمی محققان گردد، می‌توان از شاخص MSPI بهره گرفت که نه تنها سبب کاهش تعداد سری‌های زمانی شاخص SPI می‌گردد، بلکه دربرگیرنده اطلاعات تمامی آن‌ها نیز می‌باشد. همچنین بذرافشان و همکاران (۲۰۱۵) در تحقیق دیگر به مقایسه شاخص MSPI با شاخص کمبود توام<sup>۱</sup> (JDI) پرداختند. برای این منظور ابتدا شاخص SPI در بازه‌های زمانی ۱ تا ۱۲ ماهه در ۴۲ ایستگاه گوناگون در مناطق مختلف ایران طی سال‌های ۱۹۶۶ تا ۲۰۱۰ را محاسبه نمودند و سپس شاخص‌های JDI و MSPI را محاسبه نمودند. در انتها نتایج حاصل از تحقیق فوق نشان داد که شاخص MSPI نسبت به شاخص JDI جهت پایش خشکسالی برتری دارد.

پس از تجزیه و تحلیل خشکسالی‌های به‌وقوع پیوسته، پیش‌بینی این پدیده پیچیده می‌تواند کمک شایانی در کنترل و مدیریت منابع آب داشته باشد و آثار مخرب آن را تا حد ممکن کاهش دهد. یکی از راه‌های پیش‌بینی این پدیده، استفاده از شبکه‌های عصبی مصنوعی (ANN) می‌باشد که در پیش‌بینی پدیده‌های مختلف هیدرولوژیکی کاربرد فراوانی را دارا می‌باشد. در دهه اخیر، بسیاری از محققان جهت پیش‌بینی خشکسالی از مدل‌های ANN استفاده نمودند که از میان آن‌ها می‌توان به تحقیقات انجام گرفته توسط میشر و دسای (۲۰۰۶)، مرید و همکاران (۲۰۰۷)، باکانلی و همکاران (۲۰۰۹)، رضائیان‌زاده و طبری (۲۰۱۲) و بلاینه و همکاران (۲۰۱۴) اشاره نمود.

جهت بهینه‌سازی وزن‌های شبکه‌های عصبی مصنوعی، الگوریتم‌های آموزشی مختلفی وجود دارد که از پرکاربردترین آن‌ها می‌توان به الگوریتم پس انتشار خطا (BP) اشاره نمود. از آنجایی‌که الگوریتم BP از

<sup>2</sup> Particle swarm optimization

<sup>3</sup> Metaheuristic algorithms

<sup>4</sup> Gradient based algorithms

<sup>5</sup> Multilayer perceptron

<sup>1</sup> Joint deficit index

در صورتی که بین متغیرهای اصلی، همبستگی بالا باشد، تجزیه به مؤلفه‌های اصلی می‌تواند بسیار مفید باشد. این عامل باعث می‌شود که  $PC_1$  قادر به توجیه بخش بزرگی از کل واریانس در متغیرهای اصلی باشد (ویلکس ۲۰۱۱). یک پیش‌نیاز برای PCA تشکیل ماتریس همبستگی متغیرهای اصلی است. بعد از تشکیل این ماتریس، مقادیر ویژه<sup>۱</sup> و بردارهای ویژه<sup>۲</sup> مربوط به هر یک محاسبه می‌شود. عناصر بردار ویژه مربوط به بیشترین مقدار ویژه، به‌عنوان اولین مولفه اصلی محسوب می‌شود. شاخص MSPI بر اساس اولین مولفه اصلی بنا نهاده شده است و یک ترکیب خطی از  $k$  متغیر اصلی می‌باشد ( $k$  سری زمانی از شاخص SPI که به  $k$  مقیاس زمانی مربوط است) و نماینده درصد بالایی از ویژگی‌های متغیرهای اصلی است. سری‌های زمانی  $PC_1$  نیاز به استانداردسازی نسبت به انحراف معیار و میانگین ماه‌های سال دارد:

$$Z_{1ym} = \frac{PC_{1ym} - \overline{PC_{1m}}}{SD_{1m}} \approx \frac{PC_{1ym}}{SD_{1m}} \quad [2]$$

که در آن  $Z_{1ym}$  مقدار استاندارد شده  $PC_1$  در  $m$ امین سال و  $m$ امین ماه است،  $\overline{PC_{1m}}$  در واقع میانگین  $PC_1$  در ماه  $m$  است و  $SD_{1m}$  انحراف معیار  $PC_1$  در ماه  $m$  است. از آنجایی که مقدار  $\overline{PC_{1m}}$  در رابطه بالا بسیار کوچک و نزدیک به صفر است، بنابراین می‌توان از آن صرف‌نظر نمود. در نهایت مقادیر  $Z_{1ym}$  به‌دست آمده، نشان‌دهنده مقادیر شاخص MSPI می‌باشد (بذرافشان و همکاران ۲۰۱۴).

### الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی ازدحام ذرات یکی از روش‌های بهینه‌سازی الهام گرفته از طبیعت است که برای حل مسائل بهینه‌سازی عددی با فضای جستجوی بسیار بزرگ، بدون نیاز به اطلاع از گرادینان تابع هدف است. این الگوریتم اولین بار در سال ۱۹۹۵ توسط کندی و ابرهات معرفت گردید. جهت حل مسائل بهینه-

مصنوعی با استفاده از الگوریتم PSO و مقایسه آن با الگوریتم BP؛ و (۳) استفاده از سناریوهای مختلف شبکه‌های عصبی مصنوعی جهت پیش‌بینی شاخص MSPI و ارائه بهترین الگوریتم و سناریو.

### مواد و روش‌ها

#### شاخص بارندگی استاندارد شده چندمتغیره

بذرافشان و همکاران (۲۰۱۴) شاخص بارندگی استاندارد شده چندمتغیره را معرفی نمودند که بر اساس داده‌های سری‌های زمانی شاخص SPI با مقیاس‌های زمانی مختلف از قبیل ۳-۶ ماهه، ۶-۱۲ ماهه، ۱۲-۲۴ ماهه و یا ۲۴-۴۸ ماهه در هر ایستگاه محاسبه می‌گردد. واضح است که مطالعه همزمان چندین سری زمانی شاخص SPI می‌تواند اطلاعات بیشتری را در مورد ویژگی‌های انواع متعدد خشکسالی ارائه دهد، با این حال تنوع سری‌های زمانی ممکن است باعث پیچیدگی نتایج گردد. بنابراین جهت جلوگیری از سردرگمی محققان و برای داشتن نگرشی وسیع، لازم است که تعداد سری‌های زمانی SPI کاهش یابد. کاهش تعداد سری‌های زمانی SPI به معنای حذف کامل برخی از آن‌ها بدون انجام هیچ محاسبه خاص بر روی آن‌ها نیست. بلکه به معنای استفاده از یک روش جدید برای خلاصه نمودن آن‌ها می‌باشد. برای این منظور از تحلیل مولفه‌های اصلی استفاده می‌شود که نحوه محاسبه آن در زیر شرح داده می‌شود:

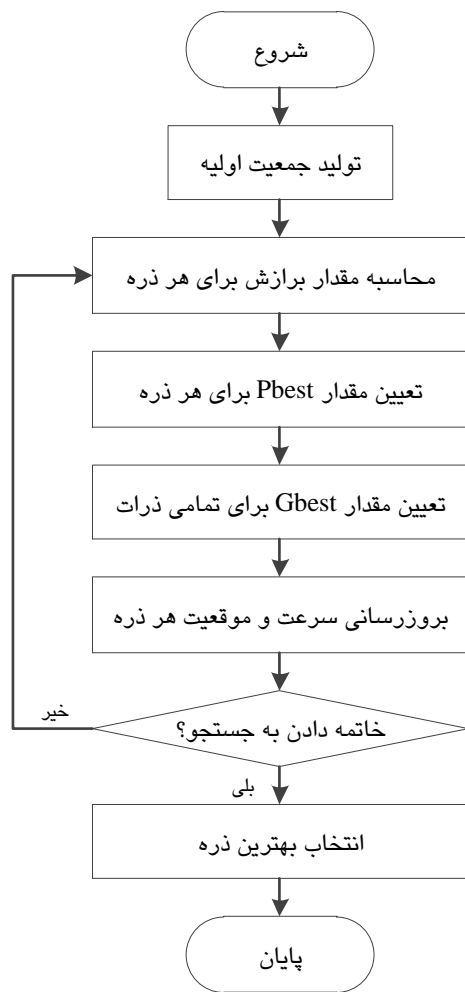
$$PC_i = E_i^T X = \sum_{k=1}^k e_{ki} x_k, \quad k=1,2,3,\dots \quad [1]$$

که در آن  $PC_i$ ،  $i$ امین مؤلفه اصلی،  $E_i^T$ ،  $i$ امین بردار ویژه،  $x_k$ ،  $k$ امین متغیر اصلی و  $e_{ki}$  برابر  $k$ امین مؤلفه  $i$ امین بردار ویژه است که ترکیب خطی آن‌ها دارای ویژگی‌های زیر است (شرما ۱۹۹۶):

- (۱) عدم وابستگی به یکدیگر،
- (۲) بیشینه تعداد آن‌ها می‌تواند به تعداد متغیرهای اصلی باشد، و
- (۳) اولین مؤلفه اصلی،  $PC_1$ ، نماینده درصد زیادی از  $k$  متغیر اصلی است.

<sup>1</sup> Eigenvalue

<sup>2</sup> Eigenvector



شکل ۱- فلوچارت مراحل الگوریتم بهینه‌سازی ازدحام ذرات.

آموزش عبارت است از پیدا کردن مناسب‌ترین بردار وزن و بردار اریب و کمینه کردن تابع خطا بین داده‌های محاسباتی (خروجی) و داده‌های مشاهداتی (هدف) که معمولاً از رابطه میانگین مربع خطاها<sup>۲</sup> استفاده می‌شود. یکی از الگوریتم‌های آموزشی، روش انتشار برگشتی<sup>۳</sup> (BP) می‌باشد که با به‌دست آوردن مقدار وزن‌های اصلاح شده در هر مرحله، سبب بهبود نتایج می‌شود (حسن‌زاده و همکاران ۱۳۹۴).

یکی دیگر از روش‌های آموزش شبکه‌های عصبی مصنوعی، استفاده از الگوریتم PSO می‌باشد که نحوه محاسبه آن در بخش بعدی ارائه می‌گردد.

سازی توسط الگوریتم PSO، جمعیتی از ذرات (جواب-های کاندید) با استفاده از یک فرمول ساده در دامنه مسئله به حرکت در می‌آیند و آن را با هدف یافتن جواب بهینه سراسری<sup>۱</sup> مورد کاوش قرار می‌دهند. سرعت  $(V_j(i+1))$  و موقعیت  $(X_j(i+1))$  جدید هر ذره، به ترتیب از روابط زیر حاصل می‌شوند:

$$V_i(t+1) = wV_i(t) + c_1r_1[P_{best,i} - X_i(t)] + c_2r_2[G_{best} - X_i(t)] \quad [۳]$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad [۴]$$

که در آن،  $V_i(t)$  سرعت قبلی هر ذره،  $X_i(t)$  موقعیت قبلی هر ذره،  $P_{best,i}$  بهترین موقعیتی که ذره  $i$  ام تاکنون داشته‌است،  $G_{best}$  بهترین موقعیتی که کل ذرات تاکنون داشته‌اند،  $w$  ضریب اینرسی،  $c_1$  ضریب آموزش شخصی،  $c_2$  ضریب آموزش جمعی و  $r$  تابع رندوم می‌باشد که اعداد تصادفی در بازه  $[0,1]$  تولید می‌کند. در رابطه [۳]، جمله اول جابجایی فعلی ذرات؛ جمله دوم اثر حافظه ذرات؛ جمله سوم اثر جمعی ذرات نامیده می‌شود (شی و ابره‌ارت ۱۹۹۸). در انتها، فلوچارت مراحل الگوریتم بهینه‌سازی ازدحام ذرات در شکل ۱ ارائه گردیده است.

### شبکه‌های عصبی مصنوعی

یک شبکه عصبی مصنوعی روشی بر پایه پردازش اطلاعات و داده‌ها است که بر اساس سیستم مغز و اعصاب انسان و عملکرد آن‌ها شبیه‌سازی شده است. در این مدل، اجزای کوچکی به نام نرون وجود دارد که وظیفه آن پردازش اطلاعات است. این نرون‌ها به یکدیگر متصل شده و بسته به چگونگی این اتصالات، شبکه‌ها و ساختارهای مختلفی به وجود می‌آیند (حسن‌زاده و همکاران ۱۳۹۱).

برای اینکه شبکه عصبی بتواند خروجی را تا حد امکان به هدف نزدیک کند، به فرآیند آموزش نیاز دارد.

<sup>2</sup> Mean square error (MSE)

<sup>3</sup> Back propagation

<sup>1</sup> Global optimum

$w_{kj}$  مقدار وزنی است که به نرون  $j$ ام لایه میانی اختصاص داده می‌شود تا براساس آن نرون  $k$ ام لایه خروجی به دست آید. در نهایت تابع هدف بر اساس رابطه بین داده‌های مشاهداتی و محاسباتی به صورت زیر بیان می‌گردد:

$$E(n) = \sum_{k=1}^K [y_k(n) - \hat{y}_k(n)]^2 \quad [6]$$

در رابطه بالا،  $K$  تعداد کل نرون‌های لایه خروجی،  $y_k(n)$  و  $\hat{y}_k(n)$  به ترتیب داده مشاهداتی و محاسباتی برای  $k$ امین نرون در  $n$  امین تکرار می‌باشد.

### استراتژی کدگذاری

بعد از تعریف تابع هدف برای مدل ANN-PSO، گام بعدی استفاده از استراتژی کدگذاری، جهت معرفی وزن‌ها و اریب‌های لایه‌های میانی و خروجی به الگوریتم PSO به عنوان مجموعه جواب (متغیرهای تصمیم) می‌باشد. سه روش برای نمایش وزن‌ها و اریب‌ها در استراتژی کدگذاری وجود دارد که شامل بردار، ماتریس و کدگذاری باینری است. در کدگذاری برداری<sup>۴</sup> هر یک از عوامل توسط یک بردار کدگذاری می‌شود. جهت آموزش شبکه‌های عصبی مصنوعی، هر عامل نشان دهنده همه وزن‌ها و اریب‌های ساختار شبکه است. در کدگذاری ماتریسی<sup>۵</sup> هر یک از عوامل توسط یک ماتریس کدگذاری می‌شوند. در کدگذاری باینری<sup>۶</sup> عوامل توسط یک رشته از بیت‌های باینری کدگذاری می‌شود (ژنگ و همکاران ۲۰۰۷). در این تحقیق، از استراتژی کدگذاری برداری، جهت تبدیل ماتریس‌های وزن‌ها و اریب‌های به کار رفته در شبکه‌های عصبی به یک بردار، به شرح زیر استفاده می‌گردد: در این استراتژی هر یک از پارامترها توسط یک بردار کدگذاری می‌شود که برای شبکه‌های عصبی پیش‌خور، هر پارامتر نشان‌دهنده همه وزن‌ها و اریب‌های ساختار شبکه می‌باشد. برای مثال برای شبکه با

### الگوریتم بهینه‌سازی ازدحام ذرات - شبکه‌های عصبی مصنوعی

الگوریتم PSO برخلاف الگوریتم‌های کلاسیک موجود جهت بهینه‌سازی وزن‌های ANN (همچون BP)، که از سرعت همگرایی پایین و همچنین گیر افتادن در بهینه‌های محلی<sup>۱</sup> برخوردار می‌باشند، قادر به تخمین بهینه‌های سراسری برای مدل‌های با ساختار پیچیده می‌باشد (ژنگ و همکاران ۲۰۰۷). در این تحقیق سعی بر آن است، از مدلی که ANN-PSO نامیده می‌شود، مقدار بهینه وزن‌ها و اریب‌ها را برای به کمینه رساندن خطا در شبکه‌های عصبی پیش‌خور به دست آوریم. برای این منظور اولاً باید تابع هدفی<sup>۲</sup> تعریف شود که از خطای شبکه‌های عصبی پیش‌خور برای ارزیابی شایستگی مدل ANN-PSO استفاده کند. ثانیاً از استراتژی کدگذاری<sup>۳</sup> برای کدگذاری وزن‌ها و اریب‌ها در شبکه‌های عصبی پیش‌خور استفاده گردد (میرجلالی و همکاران ۲۰۱۲).

### تابع هدف

ابتدا یک شبکه عصبی پیش‌خور متشکل از سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) فرض می‌گردد و سپس مدل ریاضی مورد استفاده برای بیان مقدار یک خروجی از آن، توسط رابطه زیر محاسبه می‌شود (کیم و والدس ۲۰۰۳):

$$\hat{y}_k = f_o \left[ \sum_{j=1}^M w_{kj} \cdot f_h \left( \sum_{i=1}^N w_{ji} x_i + w_{jo} \right) + w_{ko} \right] \quad [5]$$

که در آن  $N$  تعداد کل نرون‌های لایه ورودی،  $M$  تعداد کل نرون‌های لایه میانی،  $f_o$  تابع محرک مورد استفاده در لایه خروجی،  $f_h$  تابع محرک مورد استفاده در لایه میانی،  $w_{jo}$  مقدار وزن اریب نرون  $j$ ام لایه میانی، مقدار وزن اریب نرون  $k$ ام لایه خروجی،  $w_{ji}$  مقدار وزنی است که به نرون  $j$ ام لایه ورودی اختصاص داده می‌شود تا براساس آن نرون  $k$ ام لایه میانی به دست آید،

<sup>4</sup> Decision variables

<sup>5</sup> Vector encoding strategy

<sup>6</sup> Matrix encoding strategy

<sup>7</sup> Binary encoding strategy

<sup>1</sup> Local optimum

<sup>2</sup> Objective function

<sup>3</sup> Encoding strategy

۱۹۸۳ تا دسامبر ۲۰۱۳ استفاده می‌گردد. بیشینه بارندگی ماهانه به‌میزان ۵۶/۲ میلی‌متر مربوط به ماه آوریل بوده است و کمینه آن مربوط به ماه اوت می‌باشد که دارای ۱۲/۳ میلی‌متر بارندگی می‌باشد.

### نتایج و بحث

برای استخراج مشخصات خشکسالی، در این تحقیق از شاخص MSPI مربوط به مقیاس زمانی ۶ الی ۱۲ ماهه استفاده می‌شود. بنابراین ابتدا بر اساس داده‌های بارندگی ماهانه ایستگاه لیقوان در حوضه لیقوان-چای و طی دوره آماری ۳۱ ساله (ژانویه ۱۹۸۳ الی دسامبر ۲۰۱۳)، شاخص SPI در مقیاس‌های زمانی ۶ تا ۱۲ ماهه استخراج می‌گردد. اکنون بر اساس مقادیر شاخص SPI در مقیاس‌های زمانی ۶ الی ۱۲ ماهه، به محاسبه شاخص MSPI پرداخته می‌گردد. برای این منظور، ابتدا برای تشخیص وابستگی مقادیر شاخص SPI با بازه‌های زمانی مختلف (متغیرها)، ماتریس همبستگی متغیرها را به دست آورده می‌شود.

$$R = \begin{bmatrix} 1.00 & 0.96 & 0.90 & 0.84 & 0.80 & 0.76 & 0.73 \\ 0.96 & 1.00 & 0.97 & 0.91 & 0.86 & 0.82 & 0.79 \\ 0.90 & 0.97 & 1.00 & 0.97 & 0.92 & 0.88 & 0.85 \\ 0.84 & 0.91 & 0.97 & 1.00 & 0.97 & 0.93 & 0.89 \\ 0.80 & 0.86 & 0.92 & 0.97 & 1.00 & 0.98 & 0.94 \\ 0.76 & 0.82 & 0.88 & 0.93 & 0.98 & 1.00 & 0.98 \\ 0.73 & 0.79 & 0.85 & 0.89 & 0.94 & 0.98 & 1.00 \end{bmatrix}$$

ساختار ۱-۳-۲ روش فوق برای هر پارامتر به صورت زیر نمایش داده می‌شود:

$$W = \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \\ w_{31} & w_{32} \end{bmatrix} \quad \text{اگر وزن لایه میانی،}$$

$$b = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}, \quad W' = [w'_1 \quad w'_2 \quad w'_3]$$

اریب لایه میانی و  $b' = [b'_1]$  اریب لایه خروجی باشند، مطابق استراتژی کدگذاری برداری، بردار مربوط به هر ذره (Particle) تشکیل می‌گردد.

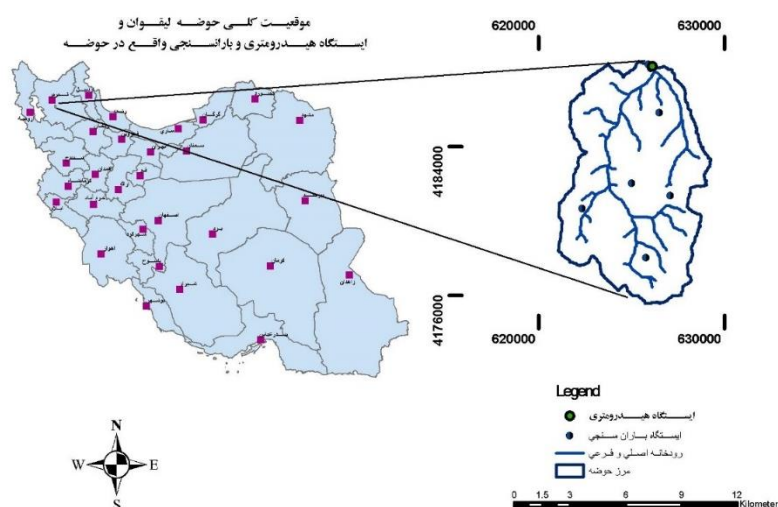
$$\text{Particle}(i) = [w_{11}, w_{21}, w_{31}, w_{12}, w_{22}, w_{32}, w_{32}, w'_{1}, w'_{2}, w'_{3}, b_1, b_2, b_3, b'] \quad [V]$$

در نهایت اگر  $M$  تعداد کل ذرات باشد، ماتریس ذرات (Matrix) با استفاده از رابطه زیر معین می‌گردد:

$$\text{Matrix} = [\text{Particle}(1); \dots; \text{Particle}(M)] \quad [A]$$

### حوضه مورد مطالعه

حوضه مورد مطالعه، حوضه لیقوان چای می‌باشد که در جنوب شرقی استان آذربایجان شرقی واقع شده است. این حوضه با وسعتی معادل ۷۶ کیلومترمربع در دامنه شمالی سهند، بین ۴۶ درجه و ۲۵ دقیقه تا ۴۶ درجه و ۲۶ دقیقه طول شرقی و ۳۷ درجه و ۴۵ دقیقه تا ۳۷ درجه و ۵۰ دقیقه عرض شمالی گسترده شده است. نقشه کلی حوضه آبریز لیقوان چای در شکل ۲ نشان داده شده است. در این تحقیق از آمار بارندگی ایستگاه لیقوان طی دوره آماری ۳۱ ساله از ژانویه



شکل ۲- موقعیت جغرافیایی و نقشه حوضه آبریز لیقوان‌چای.

مطابق این نمودار، واریانس اولین مؤلفه اصلی ( $PC_1$ ) دربرگیرنده ۹۰ درصد واریانس متغیرهای اولیه می‌باشد، در صورتی‌که که مجموع واریانس شش مؤلفه اصلی دیگر ( $PC_2$  الی  $PC_7$ )، فقط برابر ۱۰ درصد می‌باشد. بنابراین این نتایج اهمیت اولین مؤلفه اصلی را نسبت به سایر مؤلفه‌ها به اثبات می‌رساند. اولین مؤلفه اصلی با استفاده رابطه زیر به دست می‌آید:


$$PC_1 = 0.3571X_1 + 0.3765X_2 + 0.3867X_3 + 0.3896X_4 + 0.3865X_5 + 0.3793X_6 + 0.3690X_7 \quad [9]$$

در رابطه فوق،  $X_1$  تا  $X_7$  متغیرهای استاندارد شده به‌شمار می‌آیند. ضرایب متغیرهای  $X$  که تقریباً یکسان هستند، نشان‌دهنده تأثیر نسبتاً برابر هر یک از متغیرهای اولیه ( $SPI_6$  الی  $SPI_{12}$ ) در تشکیل اولین مؤلفه اصلی می‌باشد. در نهایت بر اساس اولین مؤلفه اصلی، مقادیر شاخص MSPI محاسبه و در شکل ۴ نشان داده می‌گردد. بر اساس شاخص MSPI به دست آمده، فراوانی رویدادهای خشکسالی در جدول ۱ ارائه می‌گردد.

جهت مقایسه بهتر نتایج شاخص MSPI، با شاخص SPI در بازه‌های زمانی مختلف، سری زمانی شاخص‌های فوق در شکل ۵ ترسیم می‌گردد. از این شکل چنین برداشت می‌گردد که شاخص MSPI، به

با توجه به ماتریس همبستگی، دو به دو متغیرها ( $SPI_6$  الی  $SPI_{12}$ ) از همبستگی بسیار خوبی برخوردار می‌باشند و به عبارت دیگر به یکدیگر وابسته‌اند.

بنابراین تشکیل مؤلفه‌های اصلی سبب تفکیک بهتر متغیرها و به تبع آن کاهش تعداد متغیرها می‌گردد. برای بررسی اهمیت نسبی مؤلفه‌های اصلی، بر اساس مقادیر ویژه مؤلفه‌های اصلی، نمودار غربالی ترسیم و در شکل ۳ ارائه می‌گردد.



شکل ۳- نمودار غربالی برای تمامی مؤلفه‌های اصلی.



پس از به دست آوردن شاخص MSPI، در این تحقیق از شبکه‌های عصبی مصنوعی جهت پیش‌بینی خشکسالی استفاده می‌شود. برای این منظور پس از محاسبه شاخص MSPI طی دوره آماری ۳۰ ساله (ژانویه ۱۹۸۴ الی دسامبر ۲۰۱۳)، کل داده‌ها به دو بخش جهت آموزش (۷۵ درصد از ابتدا) و آزمون (۲۵ درصد مابقی) تقسیم‌بندی می‌گردند. در مرحله بعد و قبل از مدل‌سازی توسط شبکه‌های عصبی مصنوعی، کلیه داده‌ها باید نرمال گردند. جهت نرمال نمودن داده‌ها از تابع Min-Max استفاده می‌گردد، که به‌عنوان یک تبدیل خطی بر روی داده‌های اصلی عمل می‌کند.

$$Y = (Y_{\max} - Y_{\min}) \left( \frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) + Y_{\min} \quad [10]$$

که در آن  $X$  داده‌های اصلی،  $X_{\max}$  و  $X_{\min}$  مقادیر بیشینه و کمینه داده‌های اصلی،  $Y$  داده‌های نرمال شده،  $Y_{\max}$  و  $Y_{\min}$  مقادیر بیشینه و کمینه داده‌های نرمال شده می‌باشد که به ترتیب برابر  $+1$  و  $-1$  در نظر گرفته می‌شود. شبکه‌های عصبی مورد استفاده در این تحقیق، شبکه‌های پیش‌خور (FFN) با معماری پرسپترون چند لایه (MLP) می‌باشد که شامل یک لایه ورودی، یک لایه میانی (مخفی) و یک لایه خروجی است. برای تشکیل لایه ورودی سناریوهای مختلفی را می‌توان در نظر گرفت.

$$MSPI_{t+1} = f(MSPI_t)$$

$$MSPI_{t+1} = f(MSPI_t, MSPI_{t-1})$$

$$MSPI_{t+1} = f(MSPI_t, MSPI_{t-1}, MSPI_{t-2})$$

$$MSPI_{t+1} = f(MSPI_t, MSPI_{t-1}, MSPI_{t-2}, MSPI_{t-3})$$


بنابراین نرون لایه خروجی که دربرگیرنده شاخص MSPI در زمان  $t+1$  است، می‌تواند بر اساس نرون‌های لایه ورودی مختلف که شامل شاخص MSPI در زمان‌های  $t$ ،  $t-1$ ،  $t-2$  و  $t-3$  است، وابسته گردد.

ساختار شبکه عصبی به صورت  $(n, h, m)$  می‌باشد که در آن  $n$  تعداد نرون لایه ورودی می‌باشد که بسته به سناریوی انتخابی می‌تواند از یک تا چهار تغییر کند،  $h$  تعداد نرون لایه میانی است که جهت به دست آوردن آن از روش سعی و خطا استفاده می‌شود که در این


خوبی شاخص SPI با مقیاس‌های زمانی ۶ تا ۱۲ ماهه را پوشش می‌دهد و حاوی اطلاعات آن‌ها می‌باشد.

جدول ۱- درصد فراوانی رویدادهای خشکسالی براساس شاخص MSPI.

رویداد	فراوانی	درصد فراوانی
ترسالی	۱۷۱	۴۷/۵۰
خشکسالی ملایم	۱۲۱	۳۶/۳۹
خشکسالی متوسط	۲۷	۷/۵۰
خشکسالی شدید	۲۱	۵/۸۳
خشکسالی بسیار شدید	۱۰	۲/۷۸



شکل ۴- سری زمانی شاخص MSPI با مقیاس زمانی ۶-۱۲ ماهه.



شکل ۵- سری زمانی شاخص MSPI بر اساس شاخص SPI با مقیاس‌های زمانی ۶-۱۲ ماهه.

بنابراین به جای استفاده از بازه‌های زمانی مختلف شاخص SPI که می‌تواند موجب سردرگمی در تعیین مقادیر خشکسالی‌های یک منطقه گردد، از شاخص MSPI بهره گرفت.

در رابطه فوق  $n$  تعداد کل داده‌ها،  $X_{oi}$  داده‌های مشاهداتی،  $X_{ci}$  داده‌های محاسباتی،  $\bar{X}_0$  میانگین داده‌های مشاهداتی و  $\bar{X}_c$  میانگین داده‌های محاسباتی می‌باشد.

برای مقایسه بهتر نتایج مدل ANN-BP با مدل ANN-PSO، به‌ازای سناریوها و ساختارهای مختلف، تعداد ۲۰ اجرای مستقل در نظر گرفته می‌شود که طی این اجراها، نتایج آزمون‌های نیکویی برازش از قبیل بهترین، بدترین، میانگین و انحراف معیار نتایج محاسبه می‌گردد. لازم به ذکر است که بهترین و بدترین نتایج، از میان نتایج مربوط به مرحله آزمون، طی اجراهای مختلف محاسبه می‌گردد که از اهمیت به‌سزایی برخوردار می‌باشد. جهت نمایش نتایج آماری حاصل از دو مدل ANN-BP با ANN-PSO، جهت جلوگیری از افزایش تعداد جداول، از میان تعداد نرون لایه میانی مختلف (۲ الی ۱۵ نرون)، تعداد ۲، ۸ و ۱۵ نرون در سناریوهای مختلف به‌عنوان نمونه انتخاب گردیده و سپس نتایج معیار EC مرحله آزمون در جدول ۲ ارائه می‌شود. مطابق این جدول، مقادیر مربوط به بدترین، میانگین و انحراف معیار نتایج طی اجراهای مستقل هر سناریو و به‌ازای تعداد لایه میانی مختلف، نشان می‌دهد که مدل ANN-PSO از پایداری بیشتری نسبت به مدل ANN-BP برخوردار می‌باشد. پایداری نتایج به این معنی است که به‌ازای یک ساختار دلخواه، با اجراهای مختلف تغییرات محسوسی در نتایج ایجاد نگردد.

تحقیق  $h$  از دو تا چهارده نرون در نظر گرفته شده است، و در نهایت  $m$  تعداد نرون لایه خروجی بوده که برابر یک می‌باشد. همچنین تابع محرک در نظر گرفته شده برای لایه‌های میانی و خروجی به‌ترتیب برابر است با تابع تانژانت سیگموئید (tansig) و تابع خطی (purelin).

جهت آموزش پارامترهای مدل شبکه عصبی (یعنی وزن‌ها و اربها)، از الگوریتم‌های آموزشی مختلفی می‌توان استفاده نمود. همان‌طوری‌که قبلاً نیز ذکر گردید در این تحقیق از دو الگوریتم آموزشی به نام‌های الگوریتم پس انتشار خطا (BP) و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) در شبکه‌های عصبی مصنوعی استفاده می‌گردد. بنابراین مطابق الگوریتم آموزشی انتخابی، دو مدل ANN-BP و ANN-PSO تشکیل می‌گردد.

الگوریتم PSO حاوی پارامترهای مختلفی می‌باشد که قبل از اجرا باید مشخص گردند. از میان پارامترهای مختلف الگوریتم PSO، ضریب اینرسی ( $w$ )، ضریب آموزش شخصی ( $c_1$ ) و ضریب آموزش جمعی ( $c_2$ ) به‌ترتیب برابر  $0.729$ ،  $1/49445$  و  $1/49445$  در نظر گرفته می‌شوند (ابرهارت و شی ۲۰۰۰). همچنین تعداد ذرات برابر ۵۰ و تعداد تکرار برابر ۳۰۰ انتخاب می‌گردند. در نهایت جهت به‌دست آوردن بهترین مدل ANN از میان الگوریتم‌ها، سناریوها و ساختارهای مختلف، از آزمون‌های نیکویی برازش همچون ضریب راندمان<sup>۱</sup> (EC) و جذر میانگین مربع خطاها<sup>۲</sup> (RMSE) استفاده می‌شود (حسنزاده و همکاران ۲۰۱۱). مطابق آزمون‌های نیکویی برازش، مدلی بهتر است که مقدار EC آن نزدیک به عدد یک باشد و مقدار RMSE نزدیک به صفر باشد.

$$EC = 1 - \frac{\sum_{i=1}^n (X_{oi} - X_{ci})^2}{\sum_{i=1}^n (X_{oi} - \bar{X}_0)^2} \quad [11]$$

$$RMSE = \left[ \frac{1}{n} \sum_{i=1}^n (X_{oi} - X_{ci})^2 \right]^{1/2} \quad [12]$$

<sup>1</sup> Efficiency coefficient

<sup>2</sup> Root mean square errors

جدول ۲- نتایج معیار EC مرحله آزمون بر اساس مدل‌های ANN-BP و ANN-PSO.

سناریو	ساختار	مدل ANN-BP			مدل ANN-PSO			
		بهترین	بدترین	میانگین	انحراف معیار	بهترین	بدترین	میانگین
۱	۱-۲-۱	۰/۸۴۶۰	۰/۸۳۹۳	۰/۸۴۵۳	۰/۰۰۱۵	۰/۸۴۶۰	۰/۸۴۵۳	۰/۰۰۰۱
	۱-۸-۱	۰/۸۴۴۱	۰/۸۴۲۸	۰/۸۴۳۸	۰/۰۰۰۳	۰/۸۴۶۶	۰/۸۴۵۷	۰/۰۰۰۳
	۱-۱۵-۱	۰/۸۲۳۴	۰/۷۹۲۰	۰/۸۰۴۰	۰/۰۰۸۴	۰/۸۴۶۴	۰/۸۴۵۷	۰/۰۰۰۳
۲	۲-۲-۱	۰/۹۱۵۴	۰/۹۰۵۸	۰/۹۱۲۴	۰/۰۰۳۰	۰/۹۱۴۶	۰/۹۱۴۰	۰/۰۰۰۴
	۲-۸-۱	۰/۹۱۴۴	۰/۷۹۲۵	۰/۸۸۷۹	۰/۰۲۵۵	۰/۹۱۴۲	۰/۹۱۱۴	۰/۰۰۲۲
	۲-۱۵-۱	۰/۹۰۳۷	۰/۷۹۴۸	۰/۸۷۴۲	۰/۰۲۵۸	۰/۹۱۵۹	۰/۹۰۹۴	۰/۰۰۳۶
۳	۳-۲-۱	۰/۹۱۷۹	۰/۹۰۵۶	۰/۹۱۲۴	۰/۰۰۳۸	۰/۹۱۶۲	۰/۹۱۲۸	۰/۰۰۳۲
	۳-۸-۱	۰/۹۱۶۵	۰/۸۴۲۸	۰/۸۹۲۰	۰/۰۱۸۵	۰/۹۲۰۴	۰/۹۱۳۰	۰/۰۰۴۲
	۳-۱۵-۱	۰/۹۱۴۱	۰/۷۴۲۴	۰/۸۵۰۶	۰/۰۵۲۹	۰/۹۱۷۱	۰/۹۰۵۷	۰/۰۱۰۳
۴	۴-۲-۱	۰/۹۱۹۹	۰/۸۹۳۲	۰/۹۱۲۳	۰/۰۰۶۹	۰/۹۲۰۱	۰/۹۱۴۲	۰/۰۰۶۰
	۴-۸-۱	۰/۹۱۴۹	۰/۸۶۲۶	۰/۸۹۴۲	۰/۰۱۳۱	۰/۹۲۰۲	۰/۹۱۱۶	۰/۰۰۶۶
	۴-۱۵-۱	۰/۹۱۵۲	۰/۷۰۹۰	۰/۸۷۳۴	۰/۰۴۹۴	۰/۹۲۰۳	۰/۹۰۸۳	۰/۰۰۷۵

باشد که سبب می‌گردد با اجراهای مختلف، تغییر چندان در جواب‌ها ایجاد نگردد. همچنین مدل ANN-BP با ساختارهای مختلف، به تعداد نرون لایه میانی بسیار حساس می‌باشد، به طوری که انتخاب ناصحیح تعداد نرون موجب بیش‌برازش می‌گردد. به این معنی که در مرحله آموزش، شبیه‌سازی به خوبی انجام می‌گیرد ولی در عوض در مرحله آزمون که به لحاظ کاربردی، از اهمیت بیشتری نسبت به مرحله آموزش برخوردار می‌باشد، نتایج بسیار ضعیفی به دست می‌آید. برای رفع این مشکل، روش سعی و خطا پیشنهاد شده است که روشی بسیار وقت‌گیر می‌باشد و بسته به نوع مسئله متغیر است. ولی در مدل ANN-PSO با تغییر تعداد نرون لایه میانی، تغییر آنچنان محسوسی در نتایج دو مرحله آموزش و آزمون ایجاد نمی‌کند. همچنین تعداد تکرار در مدل ANN-BP از اهمیت بسزایی برخوردار می‌باشد. در صورتی که تعداد تکرار به درستی انتخاب نگردد، نتایج مرحله آزمون را تحت تأثیر قرار می‌دهد، به طوری که در بعضی از اجراها برای یک ساختار معین،

بنابراین باید توجه نمود که هرچند مدل ANN-BP برای یک ساختار معین، می‌تواند وزن‌های شبکه را تخمین بزند و به یک جواب دست یابد، اما لزوماً این جواب‌ها ممکن است بهینه‌ترین جواب‌ها نباشد. علت را می‌توان به تابع هدف غیرخطی ارتباط داد که یک تابع بسیار پیچیده بوده و حاوی تعداد زیادی کمینه محلی می‌باشد. با توجه به اینکه مدل‌های شبکه‌های عصبی مبتنی بر الگوریتم BP وابستگی بسیاری به شرایط آغازین دارند، بنابراین ممکن است که در برخی موارد در بهینه‌های محلی گیر بیافتند. جهت رفع این مشکل لازم است که دوباره شبکه را به طور مستقل ایجاد کرده<sup>۱</sup> و دوباره آنرا چندین بار آموزش داده تا بهترین جواب (بهینه سراسری) به دست آید. در صورتی که در مدل‌های شبکه‌های عصبی مبتنی بر الگوریتم PSO، فرآیند یافتن جواب‌ها به گونه‌ای است که به راحتی می‌توانند از بهینه‌های محلی خارج شده و به بهینه سراسری و یا نزدیک آن برسند. از مزایای دیگر الگوریتم PSO، حساسیت پایین آن به نقطه شروع می-


<sup>2</sup> Over fitting<sup>1</sup> Reinitialize

می‌باشد. همچنین از میان سناریوهای مختلف، سناریوی چهارم به‌عنوان بهترین سناریو انتخاب می‌گردد که در آن شاخص MSPI در هر ماه، بر اساس همین شاخص طی چهار ماه گذشته پیش‌بینی می‌گردد. بنابراین بر اساس ساختار ۱-۶-۴ مدل ANN-PSO به پیش‌بینی شاخص MSPI اقدام نموده و در نهایت نتایج حاصل از دو مرحله آموزش و آزمون در شکل ۶ نشان داده می‌شود.

حتی جواب‌های منفی برای ضریب راندمان به‌دست می‌آید. در اینجا از میان ۱۰ الی ۵۰ تکرار، در نهایت تعداد ۲۰ تکرار مناسب تشخیص داده شد. در نهایت، بهترین ساختار در سناریوهای مختلف دو مدل بر اساس مرحله آزمون انتخاب و نتایج آن در جدول ۳ ارائه می‌گردد. از این جدول چنین برداشت می‌گردد که نتایج دو مدل در سناریوهای مختلف نزدیک به هم بوده، ولی نتایج مدل ANN-PSO اندکی بهتر از نتایج مدل ANN-BP

جدول ۳- بهترین ساختار در سناریوهای مختلف دو مدل ANN-PSO و ANN-BP

EC		RMSE		ساختار	مدل
آزمون	آموزش	آزمون	آموزش		
۰/۸۴۶۲	۰/۹۲۵۹	۰/۱۷۵۶	۰/۱۱۰۲	۱-۷-۱	ANN-BP
۰/۸۴۶۶	۰/۹۲۲۹	۰/۱۷۵۴	۰/۱۱۲۴	۱-۸-۱	ANN-PSO
۰/۹۱۶۰	۰/۹۵۲۷	۰/۱۲۹۵	۰/۰۸۸۱	۱-۹-۲	ANN-BP
۰/۹۱۸۱	۰/۹۴۵۸	۰/۱۲۷۹	۰/۰۹۴۲	۱-۱۱-۲	ANN-PSO
۰/۹۲۰۴	۰/۹۴۹۹	۰/۱۲۶۱	۰/۰۹۰۸	۱-۶-۳	ANN-BP
۰/۹۲۱۰	۰/۹۴۷۳	۰/۱۲۵۶	۰/۰۹۳۱	۱-۹-۳	ANN-PSO
۰/۹۲۱۶	۰/۹۵۴۴	۰/۱۲۵۱	۰/۰۸۶۷	۱-۹-۴	ANN-BP
۰/۹۲۳۴	۰/۹۵۰۴	۰/۱۲۳۶	۰/۰۹۰۵	۱-۶-۴	ANN-PSO



شکل ۶- سری زمانی مشاهداتی و محاسباتی شاخص MSPI بر اساس مدل ANN-PSO

#### نتیجه‌گیری کلی

۱- با توجه به همبستگی بسیار بالای متغیرهای شاخص SPI با مقیاس‌های زمانی ۶ الی ۱۲ ماهه،

نتایج حاصل از این تحقیق را می‌توان به‌صورت

زیر ارائه نمود:

- تشکیل مؤلفه‌های اصلی سبب تفکیک بهتر متغیرها می‌گردد.
- ۲- به جای استفاده از شاخص SPI با بازه‌های زمانی ۶ الی ۱۲ ماهه، می‌توان از شاخص MSPI بهره گرفت که حاوی اطلاعات شاخص SPI با بازه‌های زمانی فوق می‌باشد.
- ۳- نتایج بهترین ساختار در سناریوهای مختلف دو مدل ANN-BP و ANN-PSO نشان می‌دهد که نتایج مدل ANN-PSO بهتر از نتایج مدل ANN-BP می‌باشد.
- ۴- نتایج مدل ANN-PSO نسبت به مدل ANN-BP پایدارتر می‌باشد، به طوری که به ازای یک ساختار مشخص، با اجزای مختلف تغییرات محسوسی در نتایج ایجاد نمی‌گردد.
- ۵- مدل ANN-PSO بر خلاف مدل ANN-BP که گاهاً در بهینه‌های محلی گیر می‌کند، به راحتی می‌تواند به بهینه سراسری و یا نزدیک آن برسد.
- ۶- حساسیت مدل ANN-BP به تعداد نرون لایه میانی، بسیار بیشتر از مدل ANN-PSO می‌باشد، به طوری که با تغییر تعداد نرون لایه میانی، نتایج به شدت تحت تأثیر قرار می‌گیرد.

#### منابع مورد استفاده

- Asadnia M, Lioyd HC, Chau XS, Qin AM and Talei A, 2014. Improved particle swarm optimization-based artificial neural network for rainfall-runoff modeling. *Journal of Hydrologic Engineering* 19: 1320-1329.
- Bacanli UG, Firat M and Dikbas F, 2009. Adaptive neuro-fuzzy inference system for drought forecasting. *Stochastic Environmental Research and Risk Assessment* 23: 1143-1154.
- Bazrafshan J, Hejabi S and Rahimi J, 2014. Drought monitoring using the multivariate standardized precipitation index (MSPI). *Water Resources Management* 28: 1045-1060.
- Bazrafshan J, Nadi M and Ghorbani K, 2015. Comparison of empirical copula-based joint deficit index (JDI) and multivariate standardized precipitation index (MSPI) for drought monitoring in Iran. *Water Resources Management* 29(6): 2027-2044.
- Belayneh A, Adamowski J, Khalil B and Ozga-Zielinski B, 2014. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models. *Journal of Hydrology* 508: 418-429.
- Chau KW, 2006. Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River. *Journal of Hydrology* 329: 363-367.
- Eberhart RC and Shi Y, 2000. Comparing inertia weights and constriction factors in particle swarm optimization. Pp. 84-88. *Proceedings of the Congress on Evolutionary Computation, IEEE, La Jolla, California, USA.*
- Hassanzadeh Y, Abdi A and Fakheri-Fard A, 2012. Drought forecasting using genetic algorithm and conjoined model of neural network-wavelet. *Water and Wastewater* 23(83): 48-59.
- Hassanzadeh Y, Abdi A, Shafiei M and Khoshtinat S, 2015. Daily streamflow forecasting of Nooranchay River using the hybrid model of artificial neural networks-principal component analysis. *Water and Soil Science- University of Tabriz* 25(3): 53-63.
- Hassanzadeh Y, Abdi A, Talatahari S and Singh VP, 2011. Meta-heuristic algorithms for hydrologic frequency analysis. *Water Resources Management* 25(7): 1855-1879.
- Kennedy J and Eberhart RC, 1995. Particle swarm optimization. Pp. 1942-1948. *Proceedings of the 1995 IEEE International Conference on Neural Networks, IEEE Service Center, Perth, Australia.*
- Kim TW and Valdes JB, 2003. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering* 8(6): 319-328.
- Mirjalili S, Mohd Hashim SZ and Sardroudi HM, 2012. Training feedforward neural networks using hybrid particle swarm optimization and gravitational search algorithm. *Applied Mathematics and Computation* 218: 11125-11137.
- Mishra AK and Desai VR, 2006. Drought forecasting using feed-forward recursive neural network. *Ecological Modelling* 198: 127-138.
- Morid S, Smakhtin V and Bagherzadeh K, 2007. Drought forecasting using artificial neural networks and time series of drought indices. *International Journal of Climatology* 27: 2103-2111.

- Piotrowski AP and Napiorkowski JJ, 2011. Optimizing neural networks for river flow Forecasting-Evolutionary Computation methods versus the Levenberg-Marquardt approach. *Journal of Hydrology* 407: 12-27.
- Rezaeian-Zadeh M and Tabari H, 2012. MLP-based drought forecasting in different climatic region. *Theoretical Applied Climatology* 109: 407-414.
- Sharma S, 1996. *Applied multivariate techniques*. John Wiley & Sons, New York.
- Shi Y and Eberhart R 1998. A modified particle swarm optimizer. Pp. 69-73. *Proceedings of the IEEE International Conference on Evolutionary Computation*, IEEE Computer Society, Washington, USA.
- Topoglou E, Trichakis IC, Doku Z, Nikolos IK and Karatsaz GP, 2014. Groundwater-level forecasting under climate change scenarios using an artificial neural network trained with particle swarm optimization. *Hydrological Sciences Journal* 59(6): 1225-1239.
- Wilks DS, 2011. *Statistical methods in the atmospheric sciences*, third edition, Academic Press, Amsterdam.
- Zhang JR, Zhang J, Lok TM and Lyu MR, 2007. A hybrid particle swarm optimization-back-propagation algorithm for feedforward neural network training. *Applied Mathematics and Computation* 185: 1026-1037.