

## پیش‌بینی روزانه تقاضای آب شهری با استفاده از شبکه‌های عصبی مبتنی بر الگوریتم‌های تکاملی (مطالعه موردی: شهرستان صوفیان)

نازیلا کاردان<sup>1\*</sup>، یوسف حسن‌زاده<sup>2</sup>، حامد رضوی‌نژاد<sup>3</sup>

تاریخ دریافت: 1395/6/23 تاریخ پذیرش: 1395/8/23

### چکیده

پیش‌بینی تقاضای آب در سیستم‌های آبرسانی به منظور مدیریت صحیح منابع آب و توزیع آن امری ضروری است. با توجه به روند پرنوسان و غیرخطی مصرف آب و متغیرهای موثر بر آن، استفاده از مدل‌های غیرخطی مانند شبکه‌های عصبی در این زمینه توفیق بیشتری داشته‌اند. از طرفی این مدل‌ها دارای نقاط ضعفی مانند نیاز به داده‌های آموزشی فراوان و ضعف در یافتن نقاط بهینه سراسری می‌باشند. در این مطالعه با ادغام شبکه عصبی چند لایه با الگوریتم‌های تکاملی PSO و ICA، علاوه بر رفع نقایص مذکور، اقدام به آموزش شبکه و پیش‌بینی روزانه مصرف آب در شهرستان صوفیان بر اساس پارامترهای هواشناسی شده است. مقایسه نتایج شبکه ترکیب شده با الگوریتم‌های PSO و ICA با شبکه‌ای که توسط الگوریتم کلاسیک LM آموزش دیده، نشان می‌دهد که شبکه‌های ترکیبی عملکرد بهتری داشته و در این بین، شبکه عصبی ترکیبی با PSO، با ضریب همبستگی 0/98 در هر یک از فصول گرم و سرد سال، دقت بالاتری نسبت به سایر شبکه‌ها دارد. همچنین پیش‌بینی تقاضای آب با استفاده از مدل ترکیبی طراحی شده، با چشم‌انداز 10 ساله، نشان می‌دهد که تقاضای آب در این شهرستان در سال 1404 حدود 40% افزایش خواهد یافت.

**واژه‌های کلیدی:** الگوریتم اجتماع ذرات، الگوریتم رقابت استعماری، پیش‌بینی، تقاضای آب، شبکه عصبی

### مقدمه

توجه به روند غیرخطی و پرنوسان تقاضای آب و متغیرهای اثرگذار بر آن، توابع ریاضی غیرخطی می‌توانند منجر به حصول نتایج دقیق‌تر برای تقاضای آب شهری گردند، بنابراین این امر منجر به جستجوی راه‌حلی‌هایی با رویکرد هوشمند مانند الگوریتم اجتماع ذرات (PSO<sup>4</sup>)، الگوریتم رقابت استعماری (ICA<sup>5</sup>) و شبکه‌های عصبی مصنوعی<sup>6</sup> (ANN) شده است (سهرابی وفا و همکاران، 1392).

توقف الگوریتم در کمینه محلی، نبود یک روش استقرایی جامع در انتخاب الگوریتم یادگیری شبکه و همچنین نیاز به منبع غنی داده‌ها برای یادگیری شبکه از نقایص این الگوریتم به‌شمار می‌رود (سهرابی وفا و همکاران، 1392).

در سال‌های اخیر مطالعات فراوانی در زمینه پیش‌بینی تقاضا و مصرف آب شهری با استفاده از روش‌های نوین محاسباتی در جهت غلبه بر مسایل مرتبط با روند غیرخطی و پرنوسان تقاضای انرژی و متغیرهای توضیحی آن انجام شده است.

استفاده از شبکه‌های عصبی پرسپترون چندلایه و شبکه‌های

نیاز روزافزون به آب بر اثر رشد جمعیت، صنعت و کشاورزی، محدودیت منابع قابل استحصال در کشور، هزینه‌های سنگین طرح‌های جدید برای توسعه منابع آب و از سویی دیگر اثرات زیست محیطی و اجتماعی آن‌ها، از جمله دلایلی می‌باشند که مدیریت تقاضا و تولید آب را به عنوان راهکار موثر بر مدیریت جامع منابع آب، مطرح و ضروری می‌نمایند. از این‌رو مدل‌سازی و پیش‌بینی تقاضای آب به‌عنوان مهم‌ترین جز انرژی، جهت برنامه‌ریزی صحیح تولید و بهره‌برداری بسیار حایز اهمیت می‌باشد. برنامه‌ریزی تقاضای آب شهری بدون دانش کافی از روند گذشته، کنونی و همچنین روند آتی مصرف آن غیر ممکن است (Sozen and Arcklioglu., 2007). با

1- استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه شهید مدنی آذربایجان

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

3- دانشجوی دکتری سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه

تبریز

(Email: n.kardan@azaruniv.ac.ir

\*) نویسنده مسئول:

4- Particle Swarm Optimization (PSO)

5- Imperialist Competitive Algorithm (ICA)

6- Artificial Neural Network (ANN)

مدل جهت پیش‌بینی بلندمدت مصرف آب شهر ریاض در عربستان سعودی به کار برده شد. این مدل قابلیت پیش‌بینی مصرف آب سرانه بر اساس متغیرهای مختلفی مانند درآمد خانوار، تعداد افراد خانوار و پیشینه دمای ماهانه را دارد (Almutaz et al., 2012b). عملکرد سه مدل ابتکاری تطبیقی<sup>6</sup>، نویز/انتقال<sup>7</sup> و رگرسیون خطی چند متغیره<sup>8</sup>، با متغیره<sup>8</sup>، با و بدون در نظر گرفتن پارامترهای هواشناسی در پیش‌بینی مصرف آب مقایسه گردیده و این نتیجه حاصل شد که در صورت استفاده از پارامترهای هواشناسی، خطای پیشینه و متوسط به ترتیب 11 و 7 درصد کاهش می‌یابد (Bakker et al., 2014). جهت پیش‌بینی تقاضای آب روز بعد شهر الخبر در حوزه عربستان سعودی از مدل‌های شبکه عصبی، رگرسیون عمومی، سری‌های زمانی و نیز مدل ترکیبی شبکه عصبی - رگرسیون عمومی - سری‌های زمانی استفاده گردید. نتایج نشان داد که عملکرد مدل ترکیبی در مقایسه با دو مدل دیگر بهتر می‌باشد (Al-Zahrani and Abo-Monasa, 2015).

از نتایج پژوهش‌ها می‌توان دریافت الگوهایی که بر پایه مدل‌های غیرخطی و به خصوص شبکه‌های عصبی (ANN) طرح‌ریزی شده‌اند، نسبت به الگوهای خطی نتایج مطلوب‌تری داشته‌اند. همچنین بررسی مطالعات انجام یافته توانایی الگوریتم‌های هوشمند و شبکه‌های عصبی را در پیش‌بینی تقاضای میان مدت آب شهری به اثبات می‌رساند که در مطالعات داخلی و خارجی می‌توان به موارد زیر اشاره نمود. جهت پیش‌بینی تراز سطح آب در رودخانه Shing Mun در هنگ کنگ، و پیش‌بینی رواناب در منطقه Siu Lek Yuen، از شبکه عصبی MLP با الگوریتم‌های آموزشی اجتماع ذرات و پس انتشار خطا<sup>9</sup> (BP) استفاده گردید. نتایج حاکی از دقت بالای الگوریتم PSO در قیاس با الگوریتم BP در تمام دوره‌های زمانی مورد استفاده بود (Chau., 2006). در تحقیقی به منظور مدل‌سازی و پیش‌بینی رواناب از شبکه‌های عصبی مصنوعی استفاده نمودند. در این تحقیق برای بالا بردن دقت آموزش و نتایج پیش‌بینی رواناب، اقدام به استفاده از الگوریتم PSO برای بهینه نمودن بردارهای وزن شبکه عصبی گردید. نتایج، نشان دهنده مطلوبیت بالای ساختار پیشنهاد شده در آموزش شبکه‌های عصبی BP به منظور پیش‌بینی رابطه بین بارش - رواناب بود (Kuok et al., 2010).

شبکه‌های عصبی در بسیاری از زمینه‌های مهندسی مورد استفاده قرار گرفته است. با این وجود، دستیابی به نتایج مطلوب تنها زمانی ممکن است که منبع غنی داده‌ها با مشاهدات فراوان در اختیار باشد و زمانی که آموزش شبکه با داده‌های اندک انجام شود، کارایی بالایی نداشته و توقف الگوریتم در نقطه بهینه محلی از جمله نقایصی است

عصبی پایه شعاعی برای پیش‌بینی کوتاه مدت و بلند مدت تقاضای آب شهری در آفریقای جنوبی مطرح گردید. مقایسه دو مدل نشان داد که مدل‌های پایه شعاعی سریع‌تر به پاسخ مطلوب همگرا شده و دقت نتایج آن‌ها بیش از مدل پرسپترون چندلایه است (Msiza et al., 2007). سه مدل شبکه عصبی مصنوعی، سری‌های زمانی و رگرسیون خطی چندمتغیره<sup>1</sup> برای پیش‌بینی پیک تقاضای روزانه آب در ماه‌های تابستان شهر اتاوا کانادا به کار برده شد. نتایج نشان داد مدل شبکه عصبی مصنوعی عملکرد بهتری نسبت به دو مدل دیگر دارد (Adamowski., 2008). یک مدل شبکه عصبی مصنوعی دینامیکی برای پیش‌بینی تقاضای آب شهری استفاده گردیده و از نتایج به دست آمده از شبکه واقعی که اطلاعات را به صورت ساعتی، روزانه، هفتگی و ماهانه در اختیار قرار می‌داد برای تصدیق مدل استفاده شد. مدل‌های ساعتی دارای دقت بالای 97 درصد و مدل‌های روزانه، هفتگی و ماهانه دارای دقت بالای 99 درصد بودند (Ghiassi et al., 2008). دو مدل فازی و نروفازی جهت پیش‌بینی کوتاه مدت مصرف آب شهر تهران به کار برده شده که نتایج حاکی از عملکرد بهتر مدل نروفازی بود (Tabesh and Dini., 2008).

پژوهشگران از ماشین بردار پشتیبان<sup>2</sup> با الگوریتم آموزشی ژنتیک<sup>3</sup> (GA) به منظور پیش‌بینی مصرف آب شهری استفاده نموده و به این نتیجه دست یافتند که دستیابی به نتایج با دقت بالا با داده‌های آموزشی کم نیز امکان‌پذیر است (Chen., 2009). طی پژوهشی پارامترهای موثر بر پیش‌بینی تقاضای آب با استفاده از شبکه عصبی مصنوعی تعیین گردیدند. نتایج این پژوهش معلوم کرد مصرف آب در کوتاه مدت تابعی از مصرف آب روزهای قبل، دمای میانگین و بارندگی می‌باشد (Babel and Shinde., 2011).

عملکرد مدل شبکه عصبی-موجک<sup>4</sup>، رگرسیون خطی چند متغیره متغیره و رگرسیون غیرخطی چند متغیره و مدل آماری<sup>5</sup> ARIMA در پیش‌بینی تقاضای روزانه آب مقایسه گردید. نتایج مدل‌ها نشان داد مدل ترکیبی شبکه عصبی-موجک، با ضریب همبستگی 0/919 و مجذور میانگین مربعات خطا 0/027 بهتر از دو مدل دیگر می‌باشد (Adamowski et al., 2012).

یک مدل احتمالاتی بر اساس رشد جمعیت، ورود توریست، تعداد افراد خانوار و درآمد خانوار جهت پیش‌بینی تقاضای آب شهر مکه در عربستان سعودی توسعه داده شد (Almutaz et al., 2012a). یک

1- Multiple linear regression (MLR)

2- Support vector machine (SVM)

3- Genetic algorithm (GA)

4- Wavelet-ANN (WA-ANN)

5- Autoregressive integrated moving average (ARIMA)

6- Adaptive heuristic model

7- Transfer/Noise model

8- Multiple linear regression model

9- Back propagation algorithm (BP)

<sup>3</sup>1385، صوفیان دارای جمعیتی بالغ بر ۸۰۷۳۳ نفر و 4200 فقره انشعاب آب می‌باشد. شهر صوفیان در بین محور ارتباطی تبریز به مرند و تبریز به شبستر واقع شده است. این شهر در 20 کیلومتری شرق شبستر، 45 کیلومتری شمال تبریز و 679 کیلومتری شمال غرب تهران واقع شده است.

داده‌های هواشناسی که از طریق سازمان هواشناسی استان تهیه شده‌اند، شامل دمای میانگین، دمای کمینه، دمای بیشینه، دمای تر، دمای نقطه شبنم، مقدار بارش، رطوبت نسبی هوا، میزان تبخیر، تعداد ساعات آفتابی، فشار هوا در ایستگاه، فشار هوا در سطح دریا و سرعت باد می‌باشد. این اطلاعات از فروردین سال 1380 تا اسفند سال 1393 در دسترس بوده است (اداره آب و فاضلاب استان آذربایجان شرقی، 1394). داده‌های مربوط به مصارف آب نیز از فروردین سال 1384 تا اسفند سال 1393 در اختیار می‌باشند. براساس اطلاعات موجود، داده‌های هواشناسی و مصرف آب از فروردین سال 1384 تا اسفند سال 1393 یکدیگر را پوشش می‌دهند، بنابراین عملیات مربوط به تجزیه و تحلیل و مراحل مدل‌سازی بر روی داده‌های سال‌های 1384 تا 1393 انجام گرفته است.

برای شناسایی عوامل موثر بر مصرف آب در محدوده مورد مطالعه، تحلیل همبستگی بر روی داده‌های موجود انجام گرفت و سپس با توجه به مقدار ضریب همبستگی، عواملی که دارای بیشترین مقدار همبستگی با تقاضای آب بودند جهت مدل‌سازی انتخاب گردیدند. برای محاسبه مقدار همبستگی مثبت و منفی بین پارامترها ( $R$ )، از فرمول پیرسون و نرم‌افزار SPSS استفاده شد (رابطه 1) (تابش و همکاران، 1387).

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

که در آن،  $R$  ضریب همبستگی،  $x$  متغیر مستقل (پارامترهای هواشناسی)،  $y$  متغیر وابسته (تقاضای آب) و  $\bar{x}$  و  $\bar{y}$  مقادیر میانگین حسابی آن‌ها می‌باشد.

بررسی نتایج حاصل از نرم‌افزار SPSS نشان داد در فصول مختلف، تاثیر پارامترهای مختلف بر مصرف آب متغیر می‌باشد. بنابراین هر سال به دو دوره زمانی به‌عنوان ماه‌های گرم و ماه‌های سرد تقسیم شد. ماه‌های گرم از اول فروردین هر سال تا آخر شهریور و ماه‌های سرد از اول مهر تا آخر اسفند انتخاب شدند. به بیانی دیگر پارامترهای هواشناسی و تقاضای آب به دو دوره زمانی تقسیم شد و در هر یک از دوره‌ها با انجام تحلیل حساسیت، پارامترهای موثر در بهینه‌یابی مشخص گردیدند. نتایج حاصل از تحلیل مقادیر همبستگی برای پارامترهای مختلف در جدول 1 آورده شده است.

که کاربردهای شبکه‌ی عصبی را به شدت محدود می‌کند. همچنین با توجه به این نکته که مصرف آب همواره در حال رشد بوده و عوامل اثرگذار بر تقاضای آن دارای روندی غیرخطی و به‌شدت در نوسان می‌باشند، استفاده از تکنیک‌های هوشمند غیرخطی در مدل‌سازی تقاضای آب جهت فایده‌ی آمدن بر مساله محدودیت داده‌های آموزشی، اجتناب ناپذیر است.

در مطالعه پیش‌رو، با توجه به روند غیرخطی و محدودیت داده‌ها، برای نخستین بار روش ترکیبی الگوریتم اجتماع ذرات و شبکه عصبی چندلایه پرسپترون ( $MLP^1$ ) و نیز روش ترکیبی الگوریتم رقابت استعماری و شبکه عصبی ( $MLP$ ) جهت پیش‌بینی تقاضای آب شهری ارایه شده است. مفهوم شبکه‌های عصبی در سال 1943 توسط مک‌کلاک و پیت مطرح و بعدها به‌طور گسترده‌ای در مدل‌سازی تجربی فرآیندهای غیرخطی گسترده‌ای مورد توجه پژوهشگران قرار گرفت (McCulloch and Pitts., 1943). در سال 1986 مک‌کلند و همکاران با ارایه الگوریتم BP منجر به توسعه هرچه بیش‌تر شبکه‌های عصبی چندلایه MLP شدند (McClelland et al., 1986). جنبه‌های نوآوری این مطالعه علاوه بر معرفی الگوریتم‌های ترکیبی به‌منظور پیش‌بینی هرچه دقیق‌تر تقاضای آب شهری در شرایط محدودیت داده، ارایه روند آتی تقاضای آب شهری برای بازه زمانی 10 ساله است. از این‌رو، نخست از دو الگوریتم PSO و ICA به‌عنوان الگوریتم‌های تکاملی جهت آموزش شبکه عصبی پرسپترون MLP استفاده شده و در گام بعدی پس از تعیین برترین ساختار شبکه توسط بهترین الگوریتم، اقدام به پیش‌بینی تقاضای روزانه آب شهری شهرستان صوفیان شده است. در نهایت کارایی این دو الگوریتم با الگوریتم کلاسیک لونبرگ - مارکوارت ( $LM^2$ ) (Levenberg., 1944) مقایسه شده است.

## مواد و روش‌ها

### انتخاب پارامترها

داده‌های لازم برای بررسی و تحلیل آماری عوامل موثر بر تقاضای آب و ارایه مدل پیش‌بینی آن، شامل اطلاعات اندازه‌گیری شده پارامترهای هواشناسی و اطلاعات مربوط به مصرف دو ماهه آب (از روی قبوض آب) در شهرستان صوفیان است. صوفیان یکی از شهرهای استان آذربایجان شرقی بوده که در بخش صوفیان شهرستان شبستر واقع است. این شهر مرکز بخش صوفیان است. این شهرستان از نظر مختصات جغرافیایی در عرض شمالی 38 درجه و 28 دقیقه و در طول شرقی 45 درجه و 5 دقیقه و 30 ثانیه قرار گرفته است. طبق آخرین سرشماری مرکز آمار ایران در سال

1- Multi-Layer Perceptron (MLP)

2- Levenberge-Marquardt algorithm (LM)

حسب پارامترهای موثر در نظر گرفت. با توجه به میزان اهمیت هر کدام از پارامترها، تنها دو مدل A و B با ورودی‌های نشان داده شده در جدول 2 تعریف شده است.

با توجه به نتایج به دست آمده پارامترهای زیر برای مدل‌سازی انتخاب شده‌اند؛ دمای میانگین روزانه، رطوبت نسبی هوا، تعداد ساعات آفتابی، مصرف یک هفته قبل و مصرف یک سال قبل. بر حسب ورودی‌های مختلف به الگوریتم، مدل‌های مختلفی را می‌توان بر

جدول 1- ضریب همبستگی پارامترهای مختلف با مصرف سرانه روزانه آب در طول دوره‌ی آماری 1384 تا 1393

| پارامتر              | همبستگی با مصرف سرانه روزانه آب |          | پارامتر           | همبستگی با مصرف سرانه روزانه آب |          |
|----------------------|---------------------------------|----------|-------------------|---------------------------------|----------|
|                      | فصول سرد                        | فصول گرم |                   | فصول سرد                        | فصول گرم |
| دمای میانگین روزانه  | 0/89                            | 0/86     | سرعت باد          | 0/1                             | 0/23     |
| دمای کمینه           | 0/65                            | 0/74     | مصرف یک روز قبل   | 0/923                           | 0/918    |
| دمای بیشینه          | 0/77                            | 0/76     | مصرف دو روز قبل   | 0/918                           | 0/906    |
| دمای تر              | 0/64                            | 0/72     | مصرف سه روز قبل   | 0/909                           | 0/903    |
| دمای نقطه شبنم       | 0/67                            | 0/74     | مصرف چهار روز قبل | 0/900                           | 0/900    |
| مقدار بارش           | -0/72                           | -0/75    | مصرف پنج روز قبل  | 0/898                           | 0/898    |
| رطوبت نسبی هوا       | -0/86                           | -0/88    | مصرف شش روز قبل   | 0/891                           | 0/890    |
| میزان تبخیر          | 0/75                            | 0/81     | مصرف یک هفته قبل  | 0/905                           | 0/906    |
| تعداد ساعات آفتابی   | 0/74                            | 0/87     | مصرف دو هفته قبل  | 0/837                           | 0/897    |
| فشار هوا در ایستگاه  | -0/42                           | -0/37    | مصرف سه هفته قبل  | 0/882                           | 0/880    |
| فشار هوا در سطح دریا | -0/51                           | -0/44    | مصرف یک سال قبل   | 0/896                           | 0/890    |

جدول 2- پارامترهای ورودی مدل‌های تعریف شده

| فصل سال  | نام مدل | پارامترهای ورودی مؤثر   |
|----------|---------|---|
| فصول گرم | مدل A   | دمای میانگین روزانه - رطوبت نسبی هوا - تعداد ساعات آفتابی - مصرف یک روز تا یک هفته قبل                                |
|          | مدل B   | دمای میانگین روزانه - رطوبت نسبی هوا - تعداد ساعات آفتابی - مصرف یک روز تا یک هفته قبل - مصرف یک سال قبل              |
| فصول سرد | مدل A   | دمای میانگین روزانه - رطوبت نسبی هوا - مقدار بارش - تعداد ساعات آفتابی - مصرف یک روز تا یک هفته قبل                   |
|          | مدل B   | دمای میانگین روزانه - رطوبت نسبی هوا - مقدار بارش - تعداد ساعات آفتابی - مصرف یک روز تا یک هفته قبل - مصرف یک سال قبل |

مناسب نرون‌های لایه‌های پنهان، 2 تعداد مناسب لایه‌های پنهان و 3 نوع توابع فعال‌ساز لایه پنهان و لایه خروجی نقش مهمی دارند. با توجه به این‌که خروجی مدل تقاضای مصرف آب است، لایه خروجی فقط یک نرون داشته و نیز تعداد نرون‌های لایه ورودی برابر تعداد پارامترهای ورودی به شبکه است، در نتیجه با توجه به نتایج تحلیل حساسیت، تعداد نرون‌های لایه ورودی برای مدل A و B در فصول گرم سال به ترتیب برابر با چهار و پنج و در فصول سرد سال به ترتیب برابر با پنج و شش می‌باشد.

تعداد نرون‌های لایه پنهان عموماً به صورت تجربی به دست می‌آید که در تحقیق حاضر، تعداد نرون‌های لایه پنهان به تدریج تا همگرا شدن الگوریتم به جواب مطلوب (بر اساس مقدار خطا) افزایش داده شد. توابع فعال‌ساز نرون‌های تشکیل دهنده لایه‌های مخفی شبکه عصبی از دو نوع خطی و غیرخطی هستند که عمل پردازش بر روی اطلاعات ورودی را انجام می‌دهند. معادله توابع فعال‌ساز غیر-خطی تانژانت هذلولی شبکه‌های عصبی پرسپترون به صورت رابطه 3

### ارزیابی شبکه عصبی چندلایه پرسپترون

شبکه پرسپترون MLP شامل یک لایه ورودی و یک لایه خروجی است که می‌توان آن‌ها را با یک یا چند لایه پنهان به کار برد. خروجی شبکه عصبی چند لایه به صورت معادله 2 قابل آرایه است (Hornik., 1991):

$$y(k) = \sum_{j=1}^m w_j f_j \left( \sum_{i=1}^n w_{ij} x_i(k) + w_0 \right) \quad (2)$$

در تابع فوق،  $y(k)$  متغیر هدف،  $w_j$  ضریب وزن‌دهی به نرون پنهان  $j$ ام به لایه‌ی آخر،  $f_j$  تابع فعال‌ساز غیرخطی نرون  $j$ ام لایه پنهان،  $w_{ij}$  ضرایب وزن‌دهی میان نرون  $j$ ام لایه‌ی پنهان و ورودی  $i$ ام،  $m$  تعداد نرون‌های لایه پنهان،  $n$  تعداد نرون‌های لایه ورودی،  $x_i(k) = [x_1(k), x_2(k), \dots, x_n(k)]^T$  در زمان  $k$  بایاس لایه‌ی خروجی،  $w_i$  بایاس لایه‌ی ورودی و  $T$  ترانهاده ماتریس  $x_i(k)$  می‌باشد.

در تعیین ساختار الگوریتم شبکه عصبی سه پارامتر اساسی 1 تعداد

### الگوریتم رقابت استعماری ICA

الگوریتم ICA یک الگوریتم تکاملی<sup>1</sup> جدید در زمینه محاسبات تکاملی و بر اساس تکامل اجتماعی - سیاسی بشر است. در این الگوریتم تشکیل کشورهای اولیه جهت یافتن پاسخ بهینه به صورت ماتریسی از متغیرهای بهینه‌سازی با رابطه 6 قابل تعریف است (Atashpaz and Lucas., 2007):

$$Country = [P_1, P_2, P_3, \dots, P_N] \quad (6)$$

$P_i$  کشور  $i$  ام و  $N$  تعداد کل کشورهای اولیه می‌باشد که در فضای پاسخ وارد می‌شوند. زمانی که این الگوریتم با شبکه عصبی ترکیب شود، متغیرهای بهینه‌سازی همان وزن‌ها و بایاس‌های شبکه خواهند بود. شروع الگوریتم با تعداد کشورهای اولیه، تعداد استعمارگران و تعداد کشورهای باقی‌مانده به عنوان مستعمره خواهد بود. تعداد اولیه مستعمرات هر استعمارگر متناسب با قدرت آن استعمارگر می‌باشد. به منظور محاسبه قدرت هر استعمارگر هزینه نرمال شده هر استعمارگر از رابطه 7 محاسبه شده و از رابطه 8 نیز قدرت آن استعمارگر به دست می‌آید. سپس با استفاده از رابطه 9 مستعمرات بین استعمارگران تقسیم می‌شود (Ahmadi., 2011):

$$C_n = \max_i \{c_i\} - c_n \quad (7)$$

که در آن،  $c_n$  هزینه استعمارگر  $n$  ام،  $\max_i \{c_i\}$  بیش‌ترین هزینه میان استعمارگران و  $C_n$  هزینه نرمال شده آن استعمارگر می‌باشد.

$$P_n = \left| \frac{C_n}{\sum_{i=1}^{N_{imp}} C_i} \right| \quad (8)$$

$$N.C_n = Round \{P_n \cdot (N_{col})\} \quad (9)$$

که در آن،  $N_{col}$  تعداد کل کشورهای مستعمره موجود در جمعیت کشورهای اولیه،  $N.C_n$  تعداد مستعمرات یک استعمارگر و  $P_n$  قدرت نسبی نرمال شده آن استعمارگر می‌باشد. در طی اعمال سیاست جذب<sup>2</sup> کشورهای استعمارگر مستعمرات خود را به سمت خود کشیده و سعی در بهتر کردن وضعیت آن‌ها می‌کنند. در طی اعمال این سیاست مستعمرات به اندازه  $x$  واحد به سمت استعمارگر خود حرکت می‌کنند که  $x$  مقداری تصادفی با توزیع یکنواخت می‌باشد.

$$x : U(0, \beta \times d), \theta : U(-\gamma, \gamma) \quad (10)$$

که  $d$  بردار واصل بین مستعمره و استعمارگر،  $\gamma$  عددی دلخواه است که موجب تغییر در سیاست جستجوی تصافی میان کشورهای مستعمره می‌گردد و  $\beta$  ضریب جذب بوده که جهت کنترل تعادل جستجوی الگوریتم میان اکتشاف و استخراج استفاده شده و بزرگ‌تر

است که در این مطالعه هم برای لایه پنهان و هم برای لایه خروجی استفاده شد:

$$y = f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

این انتخاب بر پایه دو عامل می‌باشد 1 این تابع غیرخطی بوده و در نتیجه عملکرد غیرخطی تقاضای آب را بهتر مدل می‌نماید، 2 این تابع در بازه  $[-1, +1]$  قرار دارد که برای اطلاعات نرمال شده ایده‌آل است. رابطه 4 یک مدل اولیه برای شبکه عصبی پرسپترون سه لایه با خروجی غیرخطی می‌باشد.

$$\hat{y} = \tanh(w_2 \cdot \tanh(w_1 \cdot X + B_1) + B_2) \quad (4)$$

با توجه به ساختار شبکه عصبی پرسپترون، پارامترهای معادله فوق باید به گونه‌ای حساب شوند که خروجی شبکه عصبی پرسپترون سه لایه ( $\hat{y}$ ) با بیش‌ترین دقت ممکن به  $y$  نزدیک شود و یا به عبارتی دیگر تابع هزینه کمینه گردد.

### الگوریتم کلاسیک لونیبرگ-مارکوارت

پس از معرفی الگوریتم BP، الگوریتم لونیبرگ - مارکوارت (LM) با سرعت همگرایی بیش‌تر در بهینه‌یابی وزن‌های شبکه عصبی ارایه شد. الگوریتم لونیبرگ-مارکوارت روشی برای یافتن کمینه یک تابع غیرخطی چند متغیره است که به عنوان یک روش استاندارد برای حل مساله کمینه مربعات برای توابع غیرخطی درآمده است (Lourakis., 2005). الگوریتم لونیبرگ - مارکوارت بین الگوریتم گاوس - نیوتن (GNA) و روش نزول گرادینتی درون‌یابی می‌کند.

الگوریتم LM از الگوریتم GNA مقاوم‌تر است، به عبارتی دیگری، این الگوریتم در حالتی که حتی جستجوی فضای پاسخ از نقاط بسیار دور از نقطه کمینه نهایی آغاز می‌شود با سرعت، جواب کمینه نهایی را می‌یابد. از دیگر سو، برای تابع‌های خوش‌رفتار و پارامترهای آغازین معقول، عملکرد LM کمی کند است. همچنین نظیر سایر الگوریتم‌های کمینه‌سازی عددی، الگوریتم لونیبرگ-مارکوارت دارای یک فرآیند تکراری است، بدین ترتیب که برای شروع کمینه‌سازی، ابتدا باید یک حدس آغازین برای بردار متغیرها ارایه کند. در بسیاری مواقع یک حدس ناآگاهانه استاندارد به خوبی کار می‌کند. در جاهای دیگر، الگوریتم تنها زمانی عمل می‌کند که حدس آغازین تا حدی به جواب نهایی نزدیک باشد (Lourakis., 2005). قاعده یادگیری این الگوریتم به صورت رابطه 5 می‌باشد (Levenberg., 1944; Marquardt., 1963):

$$w_{k+1} = w_k - [J_k' J_k + \mu I]^{-1} J_k' e_k \quad (5)$$

که در آن،  $w$ ،  $\mu$ ،  $J$ ،  $I$  و  $e$  به ترتیب نشان دهنده‌ی بردار وزن، ماتریس ژاکوبین (بردار مشتق‌های خطای متناظر هر وزن)، پارامتر ثابت، ماتریس واحد و بردار خطا می‌باشد.

1- Evolutionary algorithm

2- Assimilation

کل جمعیت مقایسه می‌شود. پس از یافتن این دو مقدار بهینه، ذره با بروز رسانی سرعت و موقعیت خود بر اساس معادلات 11 و 12 حرکت می‌کند:

$$V_i^{t+1} = \omega \times V_i^t + c_1 \times rand_1 \times (P_{i\ best} - X_i^t) + c_2 \times rand_2 \times (g_{best} - X_i^t) \quad (11)$$

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (12)$$

در روابط فوق،  $i = (1, 2, \dots, N_{pop})$  که در آن  $N_{pop}$  نشان دهنده اندازه جمعیت،  $P_{i\ best}$  بهترین پاسخ یافت شده توسط ذره  $i$  ام و  $g_{best}$  بهترین پاسخ در کل گروه می‌باشد.  $c_1$  و  $c_2$  پارامترهای شناختی و اجتماعی می‌باشند که مقدار آن‌ها در بازه  $[0, 2]$  قابل انتخاب است. توابع  $rand_1$  و  $rand_2$  تولید کننده دو عدد تصادفی با احتمال یکنواخت در بازه  $[0, 1]$  می‌باشند. ضریب اینرسی  $\omega$  جهت کنترل تعادل جستجوی الگوریتم میان اکتشاف و استخراج استفاده می‌شود. در این الگوریتم، مراحل بازگشتی تا زمانی که شرایط توقف حاصل شود ادامه خواهد داشت. در جدول 4 پارامترهای الگوریتم اجتماع ذرات ارائه شده است.

جدول 4- تنظیم پارامترهای الگوریتم اجتماع ذرات

| پارامتر         | علامت اختصاری | مقدار  |
|-----------------|---------------|--------|
| تعداد جمعیت     | $N_{pop}$     | 40     |
| پارامتر شناختی  | $c_1$         | 1/4965 |
| پارامتر اجتماعی | $c_2$         | 1/4965 |
| ضریب اینرسی     | $\omega$      | 0/7298 |

## نتایج و بحث

### ساخت مدل

برای ساخت و تعیین ساختار بهینه مدل شبکه عصبی، بخشی از داده‌های ورودی برای آموزش و بخشی دیگر برای آزمون شبکه در نظر گرفته شد. نمونه‌های آموزش و آزمون معمولاً با یکی از قاعده‌های 90-10 درصد، 80-20 درصد و یا 70-30 درصد انتخاب می‌شوند (تابش و همکاران، 1387). انتخاب هر قاعده بستگی به نوع مساله و محدودیت داده‌ها دارد، اما تحقیقات نشان داده است هر چه تعداد نمونه‌های آموزشی افزایش یابد، عملکرد شبکه در پیش‌بینی داده‌ها بهبود می‌یابد (Zhang et al., 1998). در این مطالعه با توجه به محدودیت داده‌ها از 70 درصد مشاهدات برای آموزش و 30 درصد آن برای آزمون استفاده شد.

به‌منظور بررسی میزان کارایی ترکیب شبکه عصبی با الگوریتم‌های فوق، در پیش‌بینی تقاضای آب شهری، از معیارهای ضریب همبستگی خطی ( $R^2$ ) و میانگین مربعات خطا ( $MSE$ )<sup>2</sup> استفاده

از 1 و نزدیک به 2 می‌باشد (Ahmadi., 2011). در الگوریتم ICA، جهت جستجوی نقاط مختلف اطراف کشور استعمارگر، یک مقدار زاویه انحراف تصادفی ( $\theta$ ) به مسیر حرکت مستعمره به استعمارگر اضافه می‌شود (Atashpaz Gargari and Lucas., 2007).

عملگر انقلاب<sup>1</sup> بر روی تعدادی از کشورها جهت خارج شدن از نقاط بهینه محلی و افزایش تعداد پاسخ‌های بهینه به کار برده می‌شود و در طی آن تغییرات ناگهانی در یک یا تعدادی از پارامترهای مساله به‌وجود می‌آید. در جریان رقابت امپریالیستی، امپراطوری‌های ضعیف به تدریج سقوط کرده و مستعمرات‌شان به دست امپراطوری‌های قوی‌تر می‌افتد. در نهایت تنها یک امپراطوری وجود خواهد داشت و بقیه کشورها تحت کنترل این امپراطوری واحد قرار می‌گیرند. در چنین موقعیتی رقابت امپریالیستی به پایان رسیده و به عنوان یکی از شروط توقف، الگوریتم متوقف می‌شود. جدول 3 پارامترهای بهینه الگوریتم ICA را نشان می‌دهد.

جدول 3- تنظیم پارامترهای مورد استفاده در الگوریتم رقابت استعماری

| پارامتر              | علامت اختصاری | مقدار |
|----------------------|---------------|-------|
| تعداد تکرار الگوریتم | Iteration     | 100   |
| تعداد کل کشورها      | $N$           | 300   |
| تعداد مستعمرات       | $N_{col}$     | 70    |
| تعداد استعمارگران    | $N - N_{col}$ | 30    |
| ضریب $\gamma$        | $\gamma$      | 0/02  |
| نرخ انقلاب           | ---           | 0/3   |
| زاویه انحراف تصادفی  | $\theta$      | 45°   |
| ضریب جذب             | $\beta$       | 2     |

### الگوریتم اجتماع ذرات PSO

الگوریتم اجتماع ذرات در سال 1995 از سوی ابرهات و کندی ارائه شد که یک الگوریتم تکاملی جهت بهینه‌سازی توابع غیرخطی بوده و بر مبنای الگوبرداری از فعل و انفعال اجتماعی پرندگان ارائه شده است (Kennedy and Eberhart., 1995). زمانی که الگوریتم اجتماع ذرات به منظور حل یک مساله بهینه‌یابی به کار می‌رود جمعیتی از ذرات به‌منظور دست‌یابی به یک پاسخ بهینه به کار گرفته می‌شوند. هر ذره یک پاسخ احتمالی فضای مسئله را ارائه می‌دهد که با مختصات معینی در فضای  $D$  بعدی شناخته می‌شود. موقعیت ذره  $i$  ام با  $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$  و سرعت ذره توسط  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  نشان داده می‌شود (Kennedy and Mendes., 2002). تابع برازندگی برای هر ذره در جمعیت اندازه‌گیری شده و با اندازه بهترین نتیجه قبلی همان ذره و بهترین ذره در میان

2- Mean Square Error (MSE)

1- Revolution

گردید.

الگوریتم‌های مختلف بر اساس داده‌های آموزش و آزمون در فصل گرم را برای مدل‌های A و B نمایش می‌دهد.

همان‌گونه که نتایج شکل 1 (الف) نشان می‌دهد، روند یادگیری شبکه براساس الگوریتم PSO بسیار بهتر از LM و ICA بوده و در انتهای فرآیند یادگیری خطای کمتری داشته است. از سوی دیگر شکل 1 (ب) که روند یادگیری داده‌های آزمون را نمایش می‌دهد ضمن تایید نتایج نمودار 1 (الف) نشان می‌دهد که در یافتن نقاط کمینه، الگوریتم PSO خطای مربوط به داده‌های آزمون (نقطه توقف و اوزان ایده‌آل شبکه)، را بسیار کمتر از LM و ICA ارائه می‌کند.


در جدول 5 مقادیر خطای MSE و R<sup>2</sup> برای داده‌های آموزشی و آزمون ارائه شده است. در فصل گرم کمترین خطا برای سه مدل ترکیبی LM-ANN، PSO-ANN و ICA-ANN به ترتیب برابر 0/00542، 0/00013 و 0/00213 و در فصل سرما این مقادیر به ترتیب برابر 0/00412، 0/00012 و 0/00160 می‌باشند.

$$R^2 = \left[ \frac{\sum_{i=1}^n (y_i - \bar{y}_i)(\hat{y}_i - \bar{\hat{y}}_i)}{\sum_{i=1}^n (y_i - \bar{y}_i)^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)^2} \right]^2 \quad (13)$$


$$MSE = \left[ \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N} \right] \quad (14)$$

که  $y_i$  مقدار واقعی تقاضای روزانه آب،  $\bar{y}_i$  میانگین حسابی مقدار واقعی تقاضای روزانه آب،  $\hat{y}_i$  مقدار پیش‌بینی شده تقاضای روزانه آب و  $\bar{\hat{y}}_i$  میانگین حسابی مقدار پیش‌بینی شده تقاضای روزانه آب است.

برای تعیین تعداد لایه‌های پنهان و نیز تعداد نرون‌های لایه پنهان، ساختارهای مختلفی به لحاظ تعداد لایه‌های پنهان و تعداد نرون ایجاد شده است، طوری که برای شبکه یک لایه، تعداد نرون‌ها از چهار تا بیست و برای شبکه دو لایه تعداد نرون‌ها برای لایه پنهان اول از سه تا هشت و برای لایه پنهان دوم از یک تا ده تغییر داده شد. شکل‌های 1 (الف) و 1 (ب)، فرآیند یادگیری شبکه با



(الف)



(ب)

شکل 1- فرآیند یادگیری شبکه با الگوریتم‌های LM، ICA و PSO بر اساس (الف) داده‌های آموزشی (ب) داده‌های آزمون (فصل گرم)

جدول 5- خلاصه‌ای از نتایج به‌کارگیری الگوریتم‌های مختلف در یادگیری شبکه عصبی در فصول گرم و سرد سال

| فصل | نوع آموزش | تعداد نرون لایه پنهان اول | تعداد نرون لایه پنهان دوم | MSE داده‌های آموزش | R <sup>2</sup> داده‌های آموزش | MSE داده‌های آزمون | R <sup>2</sup> داده‌های آزمون |
|-----|-----------|---------------------------|---------------------------|--------------------|-------------------------------|--------------------|-------------------------------|
| گرم | LM        | 6                         | -                         | 0/00757            | 0/78                          | 0/02230            | 0/70                          |
|     |           | 10                        | -                         | 0/00902            | 0/75                          | 0/05891            | 0/54                          |
|     |           | 3                         | 6                         | 0/00671            | 0/80                          | 0/02455            | 0/71                          |
|     |           | 5                         | 8                         | 0/00666            | 0/80                          | 0/01992            | 0/74                          |
|     |           | 6                         | 10                        | 0/00542            | 0/82                          | 0/03260            | 0/67                          |
|     | PSO       | 16                        | -                         | 0/00061            | 0/92                          | 0/00246            | 0/79                          |
|     |           | 12                        | -                         | 0/00098            | 0/95                          | 0/00435            | 0/69                          |
|     |           | 5                         | 5                         | 0/00143            | 0/91                          | 0/00401            | 0/70                          |
|     |           | 4                         | 7                         | 0/000131           | 0/98                          | 0/00157            | 0/91                          |
|     |           | 7                         | 9                         | 0/00230            | 0/92                          | 0/00391            | 0/73                          |
| ICA | 10        | -                         | 0/00213                   | 0/90               | 0/00589                       | 0/87               |                               |
|     | 15        | -                         | 0/00285                   | 0/95               | 0/00713                       | 0/85               |                               |
|     | 6         | 7                         | 0/00306                   | 0/81               | 0/01216                       | 0/75               |                               |
| سرد | LM        | 8                         | 4                         | 0/00303            | 0/81                          | 0/01609            | 0/73                          |
|     |           | 5                         | -                         | 0/00697            | 0/80                          | 0/03123            | 0/60                          |
|     |           | 8                         | -                         | 0/00712            | 0/79                          | 0/03001            | 0/62                          |
|     |           | 5                         | 5                         | 0/00412            | 0/83                          | 0/02671            | 0/70                          |
|     |           | 6                         | 8                         | 0/00499            | 0/83                          | 0/02899            | 0/66                          |
|     | PSO       | 7                         | 3                         | 0/00555            | 0/82                          | 0/02157            | 0/76                          |
|     |           | 9                         | -                         | 0/00083            | 0/94                          | 0/00441            | 0/83                          |
|     |           | 15                        | -                         | 0/00066            | 0/86                          | 0/00421            | 0/84                          |
|     |           | 3                         | 1                         | 0/00312            | 0/71                          | 0/01029            | 0/66                          |
|     |           | 8                         | 3                         | 0/000122           | 0/98                          | 0/00366            | 0/90                          |
| ICA | 4         | 9                         | 0/00130                   | 0/84               | 0/01124                       | 0/62               |                               |
|     | 8         | -                         | 0/00254                   | 0/92               | 0/01740                       | 0/61               |                               |
|     | 11        | -                         | 0/00330                   | 0/88               | 0/00912                       | 0/75               |                               |
|     | 6         | 9                         | 0/00394                   | 0/86               | 0/00606                       | 0/81               |                               |
|     |           | 7                         | 2                         | 0/00160            | 0/92                          | 0/00759            | 0/79                          |


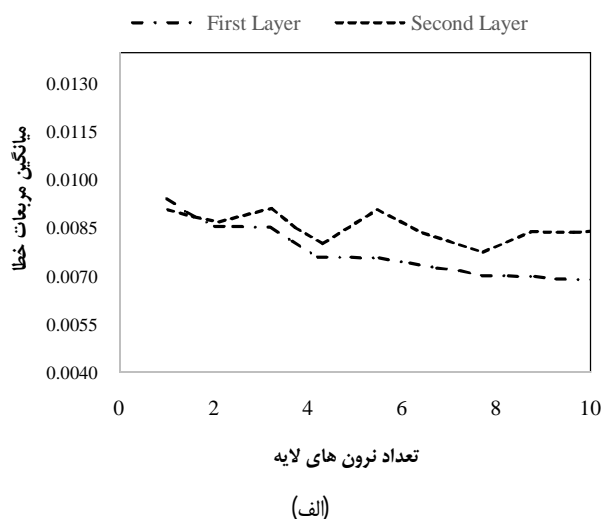
است. بنابراین بر اساس معیارهای ارزیابی شبکه، مشاهده شد که شبکه مطلوب در هر یک از فصول گرم و سرد سال، شبکه عصبی MLP با دو لایه پنهان با الگوریتم یادگیری PSO می‌باشد که از نظر تعداد نرون در فصول گرم، در لایه پنهان اول چهار و در لایه پنهان دوم هفت نرون و در فصول سرد، در لایه پنهان اول هشت و در لایه پنهان دوم سه نرون دارد. در نهایت مدل PSO-ANN برای سایر مدل‌های پیش‌بینی مورد استفاده قرار گرفت.

تغییرات خطای داده‌های آموزش با تعداد نرون‌های لایه پنهان اول و دوم در شکل 2 (الف) ارایه شده است. پس از تعیین تعداد مناسب نرون‌ها، تعداد گام‌های آموزشی از مقدار 10 با فواصل 10 تایی تغییر داده شد و مقدار خطا در هر گام آموزشی محاسبه گردید که تغییرات آن در شکل 2 (ب) ترسیم شده است. بر اساس این نمودار، میزان خطا تا گام 150 کاهش و پس از آن تغییر محسوسی نمی‌یابد؛

با مقایسه عملکرد سه الگوریتم مشاهده شد که الگوریتم کلاسیک LM در هیچ فصل عملکرد قابل قبولی نداشته لیکن عملکرد الگوریتم PSO به نسبت ICA بهتر است. علت برتری دو الگوریتم هوشمند PSO و ICA به الگوریتم کلاسیک LM، جستجوی نقاط بهینه سراسری و عدم قرارگیری در نقاط بهینه محلی توسط این دو الگوریتم است. از طرفی چون منبع غنی از داده‌ها وجود ندارد، در آموزش شبکه، عملکرد بهینه الگوریتم کلاسیک کم‌تر می‌شود که این نتیجه از قبل هم انتظار می‌رفت. در مقابل، سرعت دو الگوریتم هوشمند کم‌تر از الگوریتم کلاسیک بوده و همچنین مراحل این دو الگوریتم (به‌خصوص الگوریتم PSO) به مراتب زیادتر و پیچیده‌تر از الگوریتم کلاسیک است. همچنین هر سه الگوریتم رفتار مشخصی در قبال افزایش تعداد نرون‌ها و تعداد لایه‌ها از خود نشان ندادند به عبارتی یافتن ساختار بهینه از شبکه با آزمون و خطا انجام گرفته



بر این اساس بهترین حالت 160 گام آموزشی است.



شکل 2- (الف) تغییرات خطای داده‌های آموزش با افزایش تعداد نرون‌های لایه پنهان (ب) تغییرات خطای داده‌های آموزش با افزایش تعداد گام‌های آموزشی

جدول 6-مقایسه نتایج مدل PSO-ANN با ورودی‌های مدل A و B

| نوع فصل  | نوع داده | MSE     | R <sup>2</sup> |
|----------|----------|---------|----------------|
| فصل گرما | A        | 0/00082 | 0/9276         |
|          | B        | 0/00013 | 0/9104         |
| فصل سرما | A        | 0/00122 | 0/9465         |
|          | B        | 0/00012 | 0/9312         |

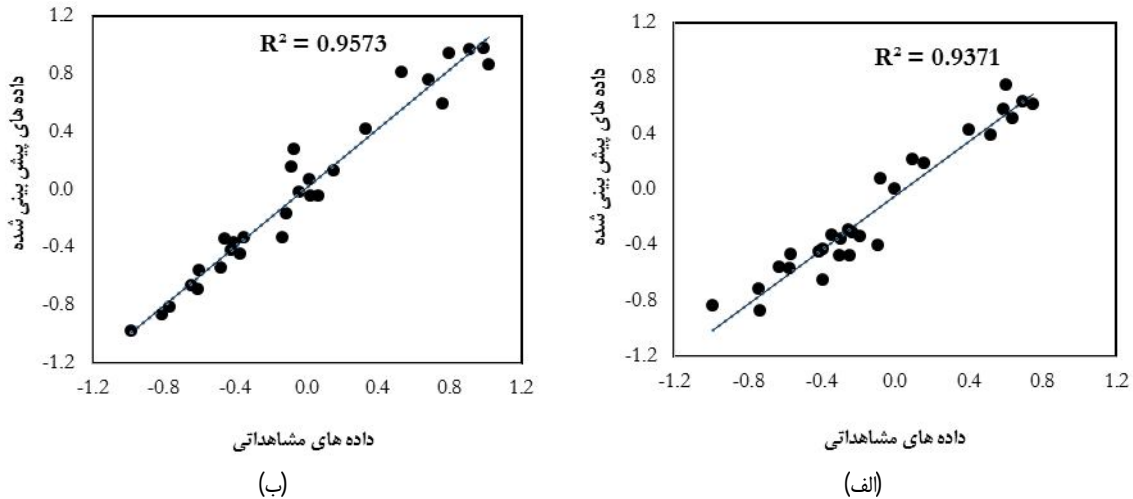
در فصل گرما، خطای مدل B برابر 0/00013 می‌باشد که کم‌تر از خطای 0/00082 در مدل A است. در فصل سرما نیز برای مدل B به مراتب خطای کم‌تری نسبت به مدل A حاصل شده است. این اختلاف در مقادیر خطا از تغییرات فصلی ناشی می‌شود که در فصل گرما به دلیل افزایش بی‌رویه مصرف، نوسان تقاضا زیاد بوده و خطای

### پیش‌بینی تقاضای آب (مرحله آزمون)

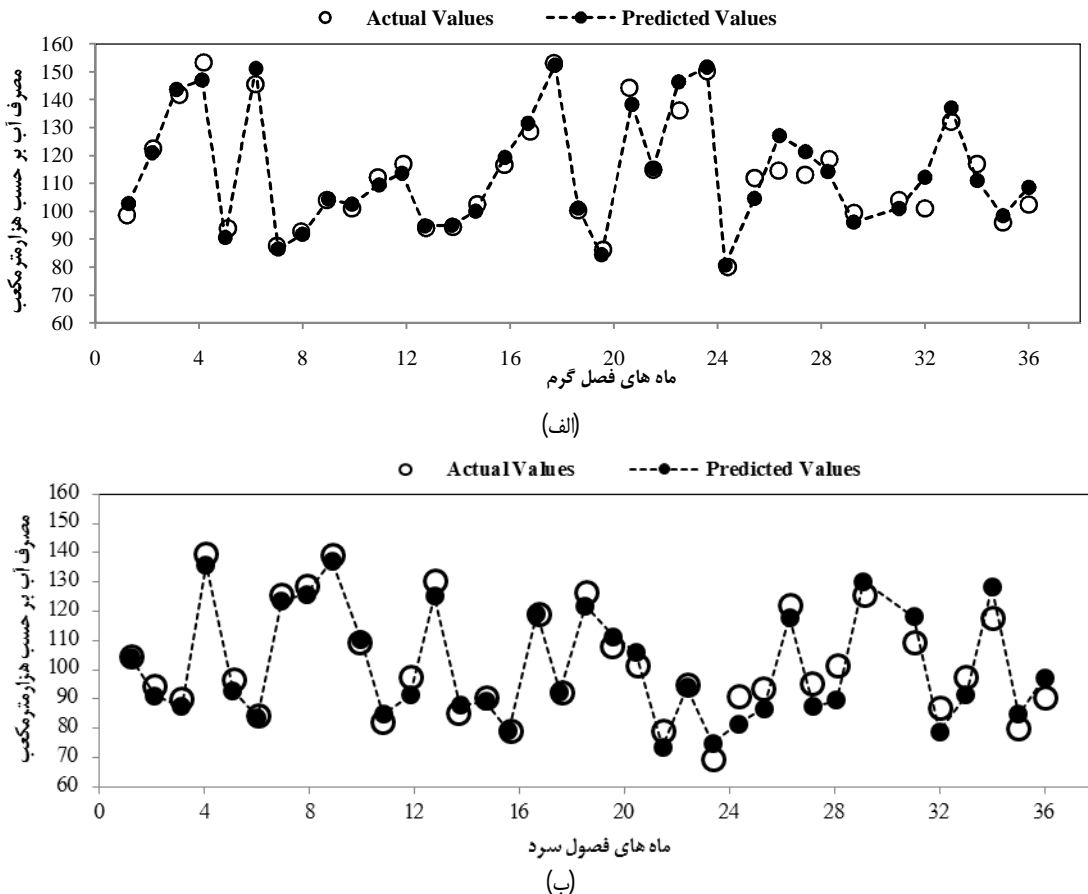
پس از ساخت مدل‌ها و مقایسه عملکرد سه الگوریتم یادگیری، بهترین ساختار برای مدل ترکیبی PSO-ANN به لحاظ تعداد نرون‌ها و تعداد لایه‌های پنهان تعیین گردید. از میان پارامترهای تاثیرگذار در پیش‌بینی تقاضای آب، موثرترین پارامترها در قالب ورودی‌های دو مدل A و B برای فصول گرم و سرد تعیین شده و نتایج خروجی آن‌ها مورد بررسی قرار گرفتند. جدول 4 مقایسه نتایج مدل PSO-ANN را برای مدل‌های A و B ارائه می‌دهد. نتایج جدول 6 برای مدل PSO-ANN با تابع فعال‌ساز تانژانت هذلولی برای شبکه عصبی، نشان می‌دهد که هم برای فصل گرما و هم فصل سرما، نتایج داده‌های مدل B نسبت به مدل A در تمامی شاخص‌ها بهتر است.

گروه B مورد استفاده قرار گرفته است. باید توجه نمود که مدل A به دلیل در نظر گرفتن مصرف سالیانه (سال قبل) می‌تواند روند تغییرات مصرف ناشی از جمعیت را نیز در برگیرد.


بیش‌تری در محاسبات وارد می‌گردد، بنابراین عملکرد مدل B در پیش‌بینی تقاضا، بهتر از مدل A است، لیکن تفاوت قابل توجهی بین مقادیر خطا وجود ندارد. از این‌رو در سایر مدل‌ها، داده‌های ورودی



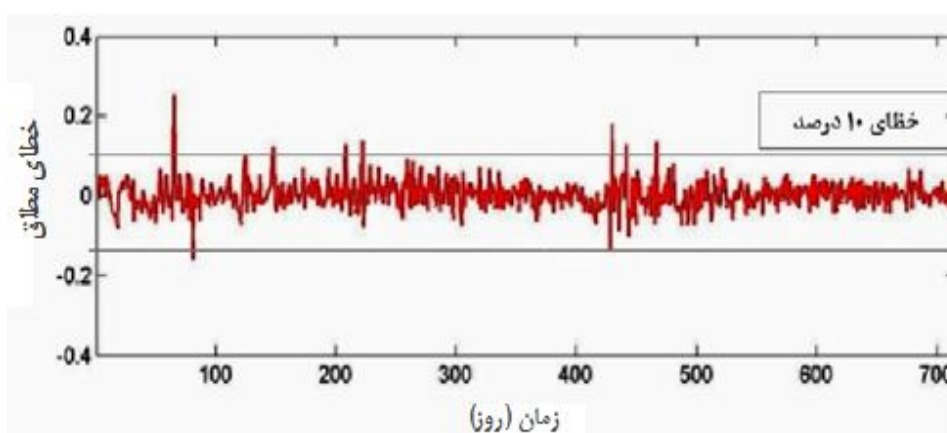
شکل 3- پراکندگی داده‌های مشاهده‌ای و پیش‌بینی شده در اطراف خط رگرسیون برای (الف) فصول گرم (ب) فصول سرد



شکل 4- مقادیر مشاهده شده و پیش‌بینی شده تقاضای ماهانه آب شهر صوفیان در سال‌های 1391-1393 توسط بهترین مدل PSO-ANN برای (الف) فصول گرم (ب) فصول سرد



شکل 5- مقایسه مقادیر واقعی و مقادیر پیش‌بینی شده تقاضای روزانه آب شهر صوفیان برای سال 1393



شکل 6- تغییرات خطای مطلق داده‌ها با نتایج مدل PSO-ANN برای دوره دو ساله 1392-1393

به بیانی دیگر نقاط بیشینه و کمینه در مدل عددی با نقاط پیک تقاضای واقعی مطابقت دارند.

شکل 6 نشان دهنده نوسانات خطای مطلق (MAPE<sup>1</sup>) داده‌ها برای دو سال متوالی 1392 و 1393 می‌باشد. با توجه به این شکل می‌توان نتیجه گرفت تنها برای چند روز در طول دوره‌ی دو ساله میزان خطا بیش از ده درصد است، در سایر روزها مقدار خطا اندک بوده و عمدتاً در بازه‌ی 0-5 درصد قرار می‌گیرد. اوج تقاضای آب در اوایل تابستان می‌باشد.

#### پیش‌بینی آتی

با توجه به گوناگونی عوامل و پارامترهای موثر بر تقاضای آب و نیز وجود پیچیدگی میان این پارامترها، هرگز نمی‌توان پیش‌بینی کاملاً دقیقی از تقاضای آتی آب داشت. از سویی دیگر با توجه به

در شکل 3 نمودار پراکندگی داده‌های تقاضای روزانه واقعی و پیش‌بینی شده با مدل B در مقابل یکدیگر و میزان همبستگی آن‌ها برای مدل PSO-ANN نمایش داده شده است. هرچه میزان پراکندگی داده‌های پیش‌بینی شده در اطراف خط رگرسیون کم‌تر باشد نشانگر دقت بالای مدل در برآورد داده‌ها می‌باشد. پراکندگی داده‌های پیش‌بینی شده در اطراف خط رگرسیون برای فصول گرم (شکل 3 الف)) و برای فصول سرد (شکل 3 ب)) کم است، در نتیجه تا حدود بسیار زیادی کارایی مطلوب مدل PSO-ANN را تضمین می‌نماید. در شکل 4 نتایج مدل PSO-ANN برای ماه‌های سه سال متوالی 1391 الی 1393 در کنار مقادیر واقعی نشان داده شده است.

شکل 5 این تغییرات را به صورت روزانه نمایش می‌دهد. این نمودار نشان دهنده دقت بسیار خوب مدل عددی در پیش‌بینی تقاضای آب شهری شهرستان صوفیان می‌باشد. بنابراین می‌توان گفت تقاضای آب پیش‌بینی شده با مدل PSO-ANN علاوه بر منطبق بودن بر روند کلی سری زمانی تقاضای واقعی روزانه، از نظر زمانی نیز از سری زمانی تقاضای واقعی تبعیت نموده و نسبت به آن تاخیر ندارد،


1- Mean absolut percentage error (MAPE)

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i}$$

سالیانه تقاضای آب در سال 1404 را در حدود 175000 مترمکعب تخمین می‌زند. این مقدار برای سال 1393 حدود 125000 مترمکعب است. مدل A پیش‌بینی کم‌تری نسبت به مدل A داشته و متوسط سالیانه تقاضا در سال 1404 را حدود 150000 مترمکعب تخمین می‌زند که به نظر می‌رسد با توجه به روند جهانی گرم شدن هوا در سال‌های اخیر، رشد جمعیت، افزایش شهرنشینی و نیز افزایش سطح رفاه جامعه، این پیش‌بینی مناسب نباشد. از سویی دیگر در مدل B، نمودار پیش‌بینی روند آتی به حالت نمایی بوده و غیرخطی می‌باشد، در حالی که نمودار A علی‌رغم غیرخطی بودن روند افزایشی نداشته و تقریباً به سمت مجانب افقی میل می‌کند. بنابراین با توجه به مدل B، پیش‌بینی می‌شود تقاضای آب در 10 سال آینده حدود 40 درصد افزایش یابد.

بحران جهانی آب در سال‌های اخیر، سیاست‌گذاری کلان در این حوزه نیازمند داشتن چشم‌اندازی 20 ساله از تقاضای آب در آینده می‌باشد. لیکن با توجه به نوسانات غیرخطی تقاضا، به نظر می‌رسد اعمال پیش‌بینی 20 ساله، تا حدودی موجب وارد شدن خطای بالایی در پیش‌بینی کوتاه مدت نیز خواهد شد. بنابراین بازه‌ی زمانی 10 ساله برای این پیش‌بینی در نظر گرفته شده است.

در این پژوهش، دو مدل پیش‌بینی A و B برای رشد تقاضای آب در نظر گرفته شد و سپس مقادیر آتی تقاضا برای 10 سال آینده (1394 الی 1404) پیش‌بینی شده است. شکل 7 پیش‌بینی روند آتی تقاضای آب را تا سال 1404 برای شهرستان صوفیان نشان می‌دهد. همان‌طور که در شکل معلوم است مدل B به‌صورت مناسب‌تری مقادیر آتی تقاضای آب را با تخمین بالایی پیش‌بینی نموده و متوسط



شکل 7- پیش‌بینی روند آتی تقاضای آب تا سال 1404

که مدل ترکیبی PSO-ANN با حداقل خطای پیش‌بینی برای داده‌های آموزش، برابر 0/00013 و 0/00012 به ترتیب برای فصول گرم و سرد سال، مناسب‌ترین روش برای تخمین تقاضای آب شهری می‌باشد. مقایسه مقادیر واقعی و پیش‌بینی شده برای تقاضای آب در سال‌های 1391 الی 1393 نیز نشان دهنده دقت بسیار خوب مدل عددی در پیش‌بینی تقاضای آب شهری شهرستان صوفیان بود. مقایسه درصد خطا برای دو سال 1392 و 1393 تایید کننده آن بود که تنها برای چند روز در طول دوره‌ی دو ساله میزان خطا بیش از ده درصد است و در سایر روزها مقدار خطا اندک بوده و عمدتاً در بازه‌ی 0-5 درصد قرار می‌گیرد.

با توجه به اهمیت پیش‌بینی صحیح تقاضای آب با لحاظ نمودن بحران جهانی آب و به‌منظور برنامه‌ریزی بلندمدت در این حوزه، پس از اطمینان از قدرت عملکرد مدل ترکیبی PSO-ANN، تقاضای آتی آب برای 10 سال آینده (تا سال 1404) برای دو مدل با داده‌های

## نتیجه‌گیری

در پژوهش حاضر، پیش‌بینی تقاضای آب شهری شهرستان صوفیان برای چشم‌انداز 10 ساله مورد توجه قرار گرفت، و به‌منظور تخمین دقیق این تقاضا ترکیب شبکه عصبی با سه الگوریتم لونیگ-مارکوارت (LM)، الگوریتم اجتماع ذرات (PSO) و الگوریتم رقابت استعماری (ICA) معرفی و مورد بررسی قرار گرفت. برای شبکه عصبی تابع فعال‌ساز تانژانت هذلولی و دو لایه پنهان انتخاب شدند. تعداد نرون‌های لایه‌های پنهان از جمله پارامترهای موثر در تخمین دقیق نتایج به‌شمار می‌رود، از این‌رو، تعداد مختلف نرون در هر لایه مورد بررسی قرار گرفت و در نهایت تعداد چهار نرون در لایه اول و هفت نرون در لایه دوم برای فصول گرم، و تعداد هشت نرون در لایه اول و سه نرون در لایه دوم برای فصول سرد تعیین شد.

نتایج به‌دست آمده قدرت پیش‌بینی بیش‌تر شبکه عصبی مبتنی بر PSO را در مقایسه با دو الگوریتم LM و ICA تایید کرد و نشان داد

- Rietveld, L. 2014. Improving the performance of water demand forecasting models by using weather input. *Journal of Procedia Engineering*, 70: 93-102.
- Chau, K.W. 2006. Particle swarm optimization training algorithm for ANNs in stage prediction of Shingmun river. *Journal of Hydrology*, 329.3-4: 363-367.
- Chen, X. 2009. Prediction of urban water demand based on GA-SVM. *International Conference on Future Computer and Communication*, 6-7 June, (pp. 285-288). Huaiyin Institute of Technology Huaian, China: IEEE.
- Ghiassi, G.A., Zimbra, D.K.B and Saidane, H.C. 2008. Urban water demand forecasting with a dynamic artificial neural network model. *Journal of Water Resources Planning and Management*, 134.2: 138-146.
- Hornik, K. 1991. Approximation capabilities of multilayer feedforward networks. *Journal of Neural Networks*, 4: 251-257.
- Kennedy, J and Eberhart, R. 1995. Particle swarm optimization. In: *IEEE International Conference on Neural Networks*, 25-28 September, (pp. 1942-1948). Perth, WA, Australia: IEEE.
- Kennedy, J and Mendes, R. 2002. Population structure and particle swarm performance. In: *IEEE Congr. Evol. Comput.*, 12-17 May. 1671-1676.
- Kim, J.H., Hwang, S.H and Shin, H.S. 2001. A neuro-genetic approach for daily water demand. *Journal of Civil Engineering*, 5.3: 281-288.
- Kuok, K.K., Harun, S and Shamsuddin, S.M. 2010. Particle swarm optimization feed forward neural network for modeling run-off. *International Journal of Environmental Science Technology*, 7.1: 67-78.
- Levenberg, k. 1944. A method for solution of certain non-linear problems in least squares. *Journal of Quarterly of Applied Mathematics*, 2: 164-168.
- Lourakis, M. 2005. A brief description of the Levenberg-Marquardt algorithm implemented by levmar, *Foundation for Research and Technology - Hellas*: 1-7.
- Marquardt, D. 1963. An algorithm for least-squares estimation of nonlinear parameters. *SIAM Journal on Applied Mathematics*, 11.2: 431-441.
- McCulloch, W.S and Pitts, W. 1943. A logic calculus of the ideas immanent in nervous activity. *Journal of Bulletin of Mathematical Biophysics*, 5.4: 115-133.
- McClelland, J.L., Rumelhart, D.E and Hinton, G.E. 1986. The appeal of distributed processing. In: *Parallel Distributed Processing: Explorations in Microstructure of Cognition-Foundations*, 1: 3-44.
- Msiza, I.S., Nelwamondo, F.V and Marwala, T. 2007. Water demand forecasting using multi-layer perceptron and radial basis functions. In: *Proceedings of the IEEE International Conference on Neural Networks*, 12-17 August, (pp. 13-18). Orlando, Florida: IEEE.
- Sozen, A and Arcaklioglu, E. 2007. Prospects for Future Projections of the Basic Energy Sources in Turkey. *Energy Sources, Part B: Economics, Planning, and Policy*, 2: 183-201.
- Tabesh, M., Goosheh, S and Yazdanpanah, M.J. 2006. Short term water demand forecasting of Tehran city by artificial
- ورودی مختلف A و B، تخمین زده شد. بر اساس مدل B که روند تقاضای آب را به صورت غیرخطی شبیه سازی می نماید، متوسط سالیانه تقاضای روزانه آب شهری برای شهرستان صوفیان در سال 1404 به اندازه 175000 مترمکعب خواهد رسید، به عبارتی دیگر تقاضای آب در 10 سال آینده 1/4 برابر سال 1394 خواهد شد.

## منابع

تابش، م، دینی، م، خوش خلق، ع.ج، زهرایی، ب. 1387. برآورد مصرف روزانه آب تهران با استفاده از سری های زمانی، نشریه تحقیقات منابع آب ایران، 4: 65-57.

سهرابی وفاج، نوری، ف و عبادی، م. 1392. پیش بینی تقاضای انرژی با استفاده از شبکه عصبی مبتنی بر الگوریتم انبوه ذرات، نشریه انرژی ایران، 16: 90-69.

Adamowski, J. 2008. Peak daily water demand forecast modeling using artificial neural networks. *Journal of Water Resources Planning and Management*, 134.2: 119-128.

Adamowski, J., Chan, H., Prasher, S., Ozga-Zielinski, B and Sliusarieva, A. 2012. Comparison of multiple linear and nonlinear regressions, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada. *Journal of Water Resources Research*, 48.1: 1-14.

Ahmadi, M.A. 2011. Prediction of Asphatene precipitation using artificial neural network optimized by imperialist competitive algorithm, *Journal of Petroleum Exploration and Production Technology*, 1: 99-106.

Almutaz, I., Ajbar, A., Khalid, Y and Ali, E. 2012a. A probabilistic forecast of water demand for a tourist and desalination dependent city: case of Mecca, Saudi Arabia. *Journal of Desalination*, 294: 53-59.

Almutaz, I., Ajbar, A., Khalid, Y and Ali, E. 2012b. Determinants of residential water demand in an arid and oil rich country: a case study of Riyadh city in Saudi Arabia. *International Journal of Physical Sciences*, 7.43: 5787-5796.

Al-Zahrani, M and Abo-Monasar, A. 2015. Urban residential water demand prediction based on artificial neural networks and time Series Models. *Journal of Water Resources Management*, 29.10: 3651-3662.

Atashpaz-Gargari, E and Lucas, C. 2007. Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. In: *IEEE Congress on Evolutionary Computation*, 25-28 September, (pp. 4661-4667). Suntec Singapore Intl. Convention & Exhibition Ctr, Singapore: IEEE.

Babel, M.S and Shinde, R.V. 2011. Identifying prominent explanatory variables for Water demand prediction using artificial neural networks: a case study of bangkok. *Water Resources Management*, 25: 1653-1676.

Bakker, M., Van Duist, H., Van Schagen, K., Vreeburg, J and

61-77.

Zhang,G., Patuwo,B.E and Hu,M. 1998. Forecasting with artificial neural network: the state of art. International Journal of Forecasting. 14.1: 35-62.

neural network. Journal of Tehran University Engineering Faculty. 41.2: 11-24.

Tabesh,M and Dini,M. 2008. Fuzzy and neuro- fuzzy models for short-term water demand forecasting in Tehran. Iranian Journal of Science and Technology, Transaction B, 33.1:

## Forecasting Daily Urban Water Demand Using Artificial Neural Networks Based on Evolutionary Algorithms, A Case Study of Soufiyan Urban Water

N. Kardan<sup>1\*</sup>, Y. Hassanzadeh<sup>2</sup>, H. Razavi Nejad<sup>3</sup>

Received: Sep.13, 2016

Accepted: Nov.13, 2016

### Abstract

Forecasting of water demand in water supply systems is essential to water resources management and its distribution as properly. According to non-linear and oscillation process of water consumption and its affecting variables, the use of non-linear models such as neural networks have get more success in this field. On the other hand, these models have some defects such as the need to more training data and weakness in finding global optimal solutions. In this study by combining the multi-layer neural networks with PSO and ICA evolutionary algorithms, the mentioned defects eliminated firstly, and then the neural networks trained and the daily water demand of Soufiyan city is predicted based on weather parameters. The results show that the hybrid neural network with PSO and ICA algorithms had better performance compared to a network that trained by LM classical algorithm. The hybrid model of neural network with PSO algorithm has correlation coefficient equal to 0.98 which have the more accurate solutions than other models in any of the warm and cold seasons. Also water demand forecasting with proposed hybrid model in the next 10 years revealed that water demand will be increased about 40% in this city.

**Keywords:** Forecasting, Imperialist competitive algorithm, Particle swarm optimization, Neural network, Water demand

1- Assistant Professor, Department of Civil Engineering, Azarbaijan Shahid Madani University

2- Professor, Faculty of Civil Engineering, University of Tabriz

3- PhD Student of Hydraulic Structure, Faculty of Civil Engineering, University of Tabriz

(\*- Corresponding Author Email: n.kardan@azaruniv.ac.ir)