

Article Type: Applied Article

نوع مقاله: پژوهش کاربردی

## Prediction of Daily Water Demand of the Shiraz City Using Neural Network and Honey Bee Colony Optimization Algorithm

E. Asrari<sup>1\*</sup>, M. Hosseini<sup>2</sup>

1,2- Associate Professor and M.Sc, Department of Civil Engineering, Payame Noor University, Tehran, Iran.

\*(Corresponding Author Email: e\_asrari@pnu.ac.ir)

Received: 15-01-2022

Revised: 01-04-2022

Accepted: 03-04-2022

Available Online: 21-09-2022

## پیش‌بینی تقاضای روزانه آب شهر شیراز با استفاده از شبکه‌عصبی و الگوریتم بهینه‌سازی کلونی زنبور عسل

الهام اسراری<sup>۱\*</sup>، محمد حسینی<sup>۲</sup>

۱ و ۲- به‌ترتیب دانشیار و دانش‌آموخته کارشناسی‌ارشد، گروه فنی و مهندسی، دانشگاه پیام نور، تهران، ایران.

\*(نویسنده‌ی مسئول، E-Mail: e\_asrari@pnu.ac.ir)

تاریخ بازنگری: ۱۴۰۱/۰۱/۱۵

تاریخ دریافت: ۱۴۰۰/۱۰/۲۵

تاریخ انتشار: ۱۴۰۱/۰۶/۳۰

تاریخ پذیرش: ۱۴۰۱/۰۱/۱۴

### Abstract

Access to safe drinking water is one of the most important human needs and citizenship rights. For this reason, the supply, transmission, treatment, and distribution of sanitary drinking water to meet the water needs of urban and rural subscribers is one of the primary tasks and priorities of any government. Predicting water demand in water supply and distribution systems will be of great help to managers related to water supply, to manage and prevent crises and water supply planning, service and maintenance of equipment and facilities, culture, information and so on. In this study, a combined method based on neural network methods and bee colony optimization to predict drinking water demand and health of Shiraz is presented. The purpose of this study was to improve the accuracy of water demand forecasting using the neural network method. Parameters considered for modeling water demand forecasts include past information on water demand, air temperature, population, wind, and date. The data used to train the neural network included 10 years from 1988 to 1997. In order to verify and evaluate the performance of the proposed method, water demand in 1998 and April 1999 has been predicted and compared with real statistics. Based on the obtained results, it was concluded that the proposed method was able to adequately predict water demand. The proposed method has good accuracy and the deviation of the water demand forecast in the worst conditions has reached one percent, which is an acceptable amount. Statistically, the results obtained using the MAPE parameter were compared with previous studies, and from this perspective, the proposed method is reliable and has good efficiency in predicting the water demand of the Shiraz city system.

**Keywords:** Water Supply System Upgrade, Water Demand Forecast, Shiraz, Neural Network.

### چکیده

دسترسی به آب شرب بهداشتی یکی از مهمترین نیازهای بشری و حقوق شهروندی است. به همین دلیل، تأمین، انتقال، تصفیه و توزیع آب شرب بهداشتی به منظور رفع نیازهای آب مشترکین شهری و روستایی یکی از وظایف اولیه و اولویت‌های هر دولتی است. پیش‌بینی تقاضای آب در سیستم‌های آبرسانی و توزیع آب، کمک شایانی به مدیران مرتبط با تأمین آب، جهت مدیریت و جلوگیری از بروز بحران و برنامه‌ریزی تأمین آب، سرویس و نگهداری تجهیزات و تأسیسات، فرهنگ‌سازی، اطلاع‌رسانی و غیره خواهد داشت. در این مقاله روشی ترکیبی مبتنی بر روش‌های شبکه‌عصبی و بهینه‌سازی کلونی زنبور عسل برای پیش‌بینی تقاضای آب شرب و بهداشت شهر شیراز ارائه شده است. هدف از این مقاله ارتقای دقت پیش‌بینی تقاضای آب با به‌کارگیری روش شبکه‌عصبی بود. پارامترهای در نظر گرفته شده جهت مدل‌سازی پیش‌بینی تقاضای آب شامل اطلاعات گذشته تقاضای آب، دمای هوا، جمعیت، وزش باد و تاریخ است. اطلاعات استفاده شده برای آموزش شبکه‌عصبی شامل ۱۰ سال از سال ۸۸ تا ۹۷ بود. جهت صحت‌سنجی و بررسی عملکرد روش پیشنهادی، تقاضای آب سال ۹۸ و فروردین ۹۹ پیش‌بینی و با آمار واقعی مقایسه شد. بر اساس نتایج به‌دست آمده روش پیشنهادی به‌طور مناسبی توانسته پیش‌بینی تقاضای آب را انجام دهد. روش پیشنهادی دقت مطلوبی داشته و انحراف پیش‌بینی تقاضای آب در بدترین شرایط به عدد یک درصد رسیده که مقدار قابل قبولی است. از لحاظ آماری نتایج به‌دست‌آمده با استفاده از پارامتر MAPE با تحقیقات پیشین مقایسه شد، از این منظر روش پیشنهادی قابل اطمینان بوده و کارایی مناسبی در پیش‌بینی تقاضای آب سیستم شهر شیراز داشته است.

**واژه‌های کلیدی:** ارتقای سیستم آبرسانی، پیش‌بینی تقاضای آب، شیراز، شبکه‌عصبی.

حجم آب‌های موجود بر روی کره زمین زیاد است، اما بیش از ۹۷٪ این آب‌ها در دریاها و اقیانوس‌ها متمرکز هستند و حدود ۲٪ به صورت یخ و یخچال‌ها در مناطق قطبی یافت می‌شود. از یک درصد آب باقی‌مانده بخش زیادی در اعماق زمین بوده که استخراج آن مشکل و از دسترس انسان به دور است (Nazemi و Wheater، ۲۰۱۵). بنابراین تأمین آب برای مصارف مختلف برای بشر موضوعی بسیار حیاتی می‌باشد.

منابع آب شرب در مقیاس وسیع و در محل‌های سکونت قابل ذخیره نبوده و مدیریت آبرسانی (تولید و توزیع آب) باید براساس تطبیق عرضه بر تقاضای آب، اقدام به برنامه‌ریزی، بهره‌برداری و سرمایه‌گذاری بهینه نماید. از این‌رو در برنامه‌ریزی آینده یک سیستم آبرسانی، پیش‌بینی تقاضای آب اهمیت ویژه‌ای دارد و باید میزان خطای آن تا حد امکان کاهش یابد. ابزارهایی مانند پیش‌بینی تقاضای آب، نقش مهمی در بهره‌برداری از تأسیسات آبرسانی دارند. جهت تأمین آب پایدار در سیستم آبرسانی به پیش‌بینی‌های دقیق نیاز است (Ghalekhondabi و همکاران، ۲۰۱۷). دقت نتایج این پیش‌بینی بر هزینه تولید در سیستم آبرسانی تأثیرگذار می‌باشد. در مقالات متعددی روش‌های مختلفی برای پیش‌بینی تقاضای آب ارائه شده است. از جمله آن‌ها می‌توان به شبکه‌های عصبی، منطق‌فازی، روش هموارسازمایی، روش یافتن روزهای مشابه، مدل اتورگرسور، مدل سری زمانی و سیستم‌های فازی-عصبی نظیر سیستم TSK<sup>۱</sup> با یادگیری لونیگ-مارکوارت و غیره اشاره کرد (Antonio و Candelieri، ۲۰۱۷) و Meireles و همکاران، (۲۰۲۲) مدلی برای توصیف تقاضا برای آب خانگی براساس عادت‌های مصرفی کاربران نهایی تهیه نموده و استفاده از وسایل مسکونی منفرد با استفاده از یک رویکرد احتمالی تعبیری می‌شود. در مرجع (Smolak و همکاران، ۲۰۲۰). ارزیابی قیاسی و مرور کامل بر روی مدل‌های پیش‌بینی کوتاه‌مدت تقاضای آب ارائه شده است. در این مرجع روش‌های سری زمانی مبتنی بر اتورگرسو، حرکت متوسط، و روش‌های متغیرخارجی ارزیابی شده است. Zubaidi و همکاران (۲۰۲۰) از روش سلسله مراتبی لاجیکال ویولت برای پیش‌بینی آب برای کاربردهای حقیقی استفاده کردند. در این مرجع از سری‌های زمانی مختلف برای روش ویولت و ضرایب مقیاس‌دهی استفاده شده است. Graf و همکاران (۲۰۱۹) پیش‌بینی آب مبتنی بر سری زمانی دمایی با استفاده از روش مدل‌سازی ترکیبی شبکه عصبی-ویولت ارائه شده است. Waqas و همکاران (۲۰۲۰) در مرجع روشی برای پیش‌بینی سطح آب با استفاده از مدل‌های یادگیری ماشین ارائه شده است. در این مرجع دو مدل یادگیری ماشین شامل شبکه عصبی پیش‌خور و یادگیری عمیق برای پیش‌بینی ماهیانه آب استفاده شده است. ارتقای دقت پیش‌بینی تقاضای

آب و بررسی فاکتورهای تأثیرگذار در مقیاس‌های مختلف براساس روش ماشین‌افزایشی گرادیان پیشنهاد شده است (Gue و همکاران، ۲۰۲۱). اکثر روش‌های ذکر شده دارای پیچیدگی‌هایی بوده و نیاز به تنظیمات پارامترهای زیادی نظیر تعداد نرون‌ها، تعداد قوانین مورد استفاده و غیره دارند. همچنین طبق اصل پارسیمونی از میان مدل‌های مشابه، مدل‌های کوچکتر و در واقع با پارامترهای کمتر ارجحیت دارند و می‌توانند قابلیت تعمیم بالایی را برای سیستم تضمین کنند. از این‌رو باز هم دامنه تحقیقات به سمت روش‌هایی که با وجود سادگی و داشتن پارامترهای کمتر بتوانند دقت بالایی داشته باشند، در جریان است. در مقدار تقاضای آب مصرفی عوامل مختلفی مانند شرایط آب‌وهوایی، فعالیت‌های اجتماعی و فاکتورهای فصلی اثرگذار بوده و سبب می‌شود تقاضای آب رفتاری به شدت غیرخطی داشته باشد. در طول سالیان گذشته، روش‌های مختلفی برای افزایش دقت پیش‌بینی بررسی شده‌اند (Kozłowski و همکاران، ۲۰۱۸).

تا سال ۱۳۵۷، آب موردنیاز نزدیک به ۷۰۰۰۰ مشترک شهر شیراز از طریق چاه‌های منطقه تأمین می‌شد و با افزایش سریع جمعیت، مصارف آب آشامیدنی افزایش یافت که طرح انتقال آب از سد درودزن در دستور کار قرار گرفت و در حال حاضر بخشی از آب شرب شهر شیراز از طریق منابع سطحی تأمین می‌شود (Tavanpour و همکاران، ۲۰۱۶). باتوجه به نیاز پیش‌بینی و تأمین آب شرب و بهداشت مورد نیاز که مبتنی بر الگوی مصرف، فرهنگ، جمعیت و تغییرات دمایی می‌باشد، نظر به اینکه شهر شیراز قطب پزشکی، گردشگری و زیارتی جنوب کشور است و مهاجرت از شهرهای جنوبی کشور به‌ویژه در فصول گرم سال به شهر شیراز زیاد می‌باشد از این‌رو تأمین آب مورد لزوم مهم بوده و پیش‌بینی تقاضای آب شرب و بهداشت در سیستم آبرسانی شهری با لحاظ نمودن میزان مصرف روزها در گذشته و عوامل آب‌وهوایی و جمعیت ارائه خواهد شد.

به طور خلاصه برای بهینه‌سازی عملکرد شبکه عصبی در پیش‌بینی تقاضای آب از روش الگوریتم کلونی زنبور عسل به منظور بهینه‌سازی رویه یادگیری شبکه عصبی استفاده می‌شود. همچنین وزن‌های بهینه شده به روشی بازگشتی با به‌کارگیری روش بهینه‌سازی کلونی زنبور عسل به‌دست می‌آید. هدف از این تحقیق، ارتقای دقت پیش‌بینی تقاضای آب با به‌کارگیری بهینه‌سازی داخلی و قابلیت بالای همگرایی کلونی زنبور عسل می‌باشد. شبکه عصبی با استفاده از الگوریتم بهینه‌سازی کلونی زنبور عسل آموزش داده شده است تا وزن‌های اتصالات نرون‌ها به‌دست‌آید. پیش‌بینی تقاضای آب در شبکه آبرسانی شیراز با لحاظ کردن میزان مصرف آب روزها در گذشته، جمعیت و عوامل آب‌وهوایی مانند وزش باد، دما ارائه می‌شود. روش پیشنهادی در محیط نرم‌افزار MATLAB پیاده‌سازی می‌شود.

در این بخش روش پیشنهادی جهت ارتقای کارایی پیش‌بینی تقاضای آب مبتنی بر روش‌های شبکه عصبی و الگوریتم بهینه‌سازی زنبور عسل ارائه می‌شود. ابتدا پارامترهای ورودی مساله معرفی می‌شود.

### ۱ معرفی داده‌ها و پارامترها

تقاضای آب یک واحد دینامیک است که برای آن فاکتورهای زیادی در ایام سال موثر می‌باشند. ۱- جمعیت که در ایام و فصول مختلف سال متفاوت بوده و نیاز می‌باشد تا الگوی خاصی برای جمعیت هر شهر در فصول مختلف سال طراحی شود. ۲- شرایط آب‌وهوایی که شامل عواملی مانند دما و رطوبت می‌باشد و از عوامل موثر بر تغییر میزان مصرف آب در شهرها می‌باشند، ۳- روزهای کاری هفته، آخر هفته، روزهای تعطیل بر روی مصرف آب تأثیرگذار می‌باشند. این الگوی تقاضای آب روزانه، الگوی نرمال زندگی روزمره را نشان می‌دهد. شایان ذکر است در میان فاکتورهای آب‌وهوایی تأثیرگذار بر روی تقاضای آب، دما مهمترین آن‌ها می‌باشد (Zubaidi و همکاران، ۲۰۲۱). داده‌های ورودی شامل تقاضای آب گذشته، دما، وزش باد و جمعیت است. جهت پیش‌بینی تقاضای آب از روش شبکه عصبی استفاده می‌شود. در این راستا، جهت آموزش شبکه عصبی اطلاعات ورودی شامل تقاضای آب گذشته، دما، وزش باد و جمعیت برای سال‌های ۱۳۸۸ تا ۱۳۹۷ (۱۰ سال) به‌عنوان اطلاعات مورد نیاز جهت آموزش شبکه عصبی استفاده شده است. همچنین اطلاعات مربوط به سال ۹۸ و فروردین ۹۹ جهت مقایسه دقیق با خروجی شبکه عصبی از شرکت آب و فاضلاب شیراز دریافت شده است. نمونه اطلاعات ورودی استفاده شده در جدول (۱) نمایش داده شده است. شایان ذکر است در این جدول اطلاعات مربوط به خروجی مخزن شبکه می‌باشد. همچنین جمعیت برای هر سال از اطلاعات موجود در دیتابیس سازمان آب شهر شیراز دریافت شده است.

جدول ۱- نمونه اطلاعات ورودی

تاریخ	تقاضای آب (m <sup>3</sup> )	دما (°C)	جمعیت	وزش باد (m/s)
۱۳۹۸/۱۰/۱	۳۶۶۵۴۹/۵۷	۶/۵	۲۰۱۳۱۶۰	۱/۸

### ۲- معرفی شبکه عصبی

روش شبکه عصبی، روشی پیشرفته است که از یک مدل تشخیص الگوی ابتدایی برای پیش‌بینی تقاضای آب استفاده می‌کند. این روش مبتنی بر مفهوم شبکه عصبی از "یادگیری

از گذشته" به‌منظور پیش‌بینی آینده می‌باشد. مدل شبکه عصبی باید به‌صورت متناوب برای به دست آوردن نتایج دقیق‌تر، آموزش داده شود (Abiodun و همکاران، ۲۰۱۸). در این الگوریتم، یک شبکه از نورون‌ها با استفاده از اطلاعات گذشته آموزش داده می‌شوند. وزن‌های اتصالات داخلی نورون‌ها طوری تنظیم می‌شوند که آن‌ها با اطلاعات گذشته تطبیق داده شوند. پس از مرحله آموزش، این شبکه عصبی برای پیش‌بینی تقاضای آب آینده استفاده می‌شود. در رویه یادگیری بهینه‌سازی وزن‌ها با استفاده از الگوریتم کلونی زنبور عسل صورت می‌گیرد. شبکه عصبی می‌تواند به‌طور کارآمدی رابطه‌ای خطی بین پارامترهای ورودی و خروجی مدل کند. برای پیش‌بینی تقاضای آب، مدل شبکه عصبی از پارامترهای ورودی شامل اطلاعات دمایی، جمعیت و وزش باد با استفاده از رابطه (۱) استفاده می‌کند.

$$W(t) = f(t, T(t) - TS), (T(t) - TC)^2, (T(t) - TC)^3, \quad (1)$$

$$(T(t) - T(t-1)), (T(t-1) - T(t-2)), WP_1(t), \text{population}$$


در رابطه فوق  $W(t)$ : تقاضای آب ساعتی،  $T(t)$ : دما در زمان  $t$ . این دمای متوسط برای ناحیه تقاضای آب پیش‌بینی است.  $T(t-i)$ : دمای ساعتی تقاضای آب در زمان  $t-i$ . قرار داد آن است که دوره  $i$  پیش از  $t$  می‌باشد.  $WP_1(t)$ : پارامتر آب‌وهوایی در کنار دما می‌باشد که در این مقاله وزش باد در نظر گرفته شده است. همچنین Population به جمعیت اشاره دارد.

هدف، آموزش یک مدل شبکه عصبی برای تطبیق مدل غیرخطی رابطه (۱) می‌باشد. هر شبکه عصبی می‌تواند یک لایه اولیه، یک زوج لایه‌های پنهان و یک لایه خروجی داشته باشد. به‌منظور آموزش شبکه عصبی از روش بهینه‌سازی کلونی زنبور عسل استفاده می‌شود که در ادامه معرفی شده است.

### ۳- تشریح روش پیشنهادی مبتنی بر الگوریتم کلونی زنبور عسل

برای بهینه‌سازی عملکرد شبکه عصبی در پیش‌بینی تقاضای آب و بهینه‌سازی رویه یادگیری شبکه عصبی از روش الگوریتم کلونی زنبور عسل استفاده می‌شود. وزن‌های بهینه شده به روشی بازگشتی با به‌کارگیری روش بهینه‌سازی کلونی زنبور عسل به‌دست خواهد آمد که از الگوریتم کلونی زنبور عسل برای جستجوی بهترین پارامترهای آموزش استفاده خواهد شد. الگوریتم کلونی زنبور عسل الهام گرفته از رفتار هوشمند جمعیت زنبور عسل در جستجوی غذا می‌باشد. در الگوریتم کلونی زنبور عسل، موقعیت هر منبع غذا متناظر با یک راه‌حل ممکن برای مسأله بهینه‌سازی می‌باشد و مقدار نکتار (شهد) یک منبع غذایی نشانگر مقدار شایستگی (کیفیت) راه‌حل

متناظر می‌باشد. مجموع زنبورها در یک کلونی را می‌توان به سه دسته تقسیم کرد: کارگر، تماشاگر، و پیشرو می‌باشد (Wang و همکاران، ۲۰۲۰). زنبورهای کارگر و تماشاگر در کندو برابر بوده و متناظر با یک تعداد راه‌حل در جمعیت می‌باشند. فرمول‌بندی مدل مدنظر برای پیش‌بینی تقاضای آب در اینجا بحث می‌شود و شامل پارامترهای شبکه عصبی و کلونی زنبور عسل می‌باشد. رویه آموزش شبکه عصبی در شکل (۱) نشان داده شده است و تکنیک مدنظر برای رویه یادگیری در آن ذکر شده است. ورودی‌ها از شبکه عصبی که وزن‌های اتصال آن با استفاده از رویه یادگیری به دست می‌آیند عبور می‌کنند و نتایج در هر تکرار ارزیابی می‌شود. تنظیمات شبکه عصبی و رویه یادگیری در ادامه آورده شده است.



شکل ۱- نحوه ارتباط میان الگوریتم‌های کلونی زنبور عسل و شبکه عصبی

رابطه غیرخطی و پیچیده‌ای میان تقاضای آب و فاکتورهای تأثیرگذار بر آن وجود دارد. تقاضا در افق تحت تأثیر ورودی‌های تقویم، شرایط آب‌وهوایی می‌باشند. ورودی‌های تقویم شامل زمان روز، روز از هفته و تعطیلات می‌باشد. پارامترهای آب‌وهوایی بیشتر شامل دما، رطوبت و یا وزش باد و شدت تابش خورشید می‌باشد. به دلیل اینکه فاکتورهای ورودی تأثیر به‌سزایی در مدل‌سازی پیش‌بینی تقاضای آب دارند، ورودی‌های شبکه عصبی باید به دقت در مدل‌سازی وارد شوند. ورودی‌های انتخاب شده مبتنی بر همبستگی آن‌ها با تقاضای آب خروجی می‌باشند. یک شبکه عصبی سه لایه پیش‌خور برای پیش‌بینی تقاضای آب استفاده می‌شود. ورودی‌ها متغیرهای تأثیرگذار در تغییرات تقاضای آب و خروجی تقاضای آب ساعات بعدی می‌باشد. تعداد نورون‌ها در لایه پنهان بر روی قابلیت یادگیری و عمومیت‌دهی تأثیرگذار هستند. نورون‌های لایه پنهان براساس تعداد ورودی‌ها و خروجی‌ها انتخاب می‌شوند و با افزایش آهسته نورون‌ها از شایستگی خارج نژم جلوگیری می‌شود تا نتایج بهینه حاصل شود. شبکه عصبی استفاده شده در این مقاله شامل هشت ورودی (I)، پنج نورون پنهان (H) و یک نورون خروجی می‌باشد. علاوه بر این دو نورون بایاس اضافی (b1, b2) در نظر گرفته شده است، یکی در لایه پنهان و دیگری در لایه خروجی می‌باشد و در مجموع به ۵۳ اتصال

نورونی منجر می‌شود. اتصالات نورون‌ها با ضرب نورون‌ها در هر لایه حساب می‌شود. ۸ ورودی + بایاس به پنج نورون پنهان وصل هستند که ۵۳ اتصال نورونی را نتیجه می‌دهند. این موضوع را می‌توان به صورت رابطه (۲) فرموله کرد.

$$N = ((I+b1)*H) + ((H+b2)*O) + b1 + b2 \quad (2)$$

براساس تجربیات مقالاتی نظیر (Wang و همکاران، ۲۰۲۰) در زمینه ارتقای رویه یادگیری شبکه عصبی این تعداد در نظر گرفته شده است. تابع تبدیل سیگموئید برای دستیابی به خروجی نورون استفاده می‌شود. خطای میانگین مربعات به‌منظور ارزیابی عملکرد شبکه عصبی استفاده می‌شود. وزن‌ها از یک توزیع یکنواخت مقداردهی اولیه می‌شود.

نحوه تنظیمات الگوریتم کلونی زنبور عسل به‌منظور بهینه‌سازی اتصالات نورون‌های شبکه عصبی بسیار اهمیت دارد. تعداد منابع غذایی در اینجا ۲۸ در نظر گرفته شده است که جمعیت زنبورهای عسل نیز می‌باشد. تعداد زنبورهای کارگر و تماشاگر نیز ۱۴ می‌باشد. دیمانسیون فضای جستجو برابر با ۵۳ یعنی تعداد اتصالات وزن‌ها می‌باشد. مرزهای بالا و پایین برابر با ۱ و -۱ می‌باشد (Wang و همکاران، ۲۰۲۰).

رویه یادگیری الگوریتم کلونی زنبور عسل بر پایه مراحل مختلف می‌باشد و در شکل (۲) نشان داده شده است.

در شکل (۲) مرحله اول مقداردهی اولیه می‌باشد که یک جمعیت اولیه از منابع غذایی N به‌صورت تصادفی در رنج مرزهای بالا و پایین تولید می‌شوند. رابطه (۳) برای مقداردهی اولیه جمعیت استفاده می‌شود. در اینجا اندازه جمعیت ۲۸ است (Xue و همکاران، ۲۰۱۸).

$$x_{ij} = x_j^{\min} + \text{rand}(0,1)(x_j^{\max} - x_j^{\min}) \quad (3)$$

که در این رابطه i بیانگر iامین منبع غذایی و z متغیر بهینه‌سازی مربوط به iامین منبع غذایی می‌باشد. در این مرحله مقدار نکتار هر منبع غذایی محاسبه خواهد شد و شایستگی منبع غذایی مطابق با رابطه (۴) ارزیابی می‌شود:

$$\text{fitness}_i = \frac{1}{1 + f_i}; f_i \geq 0 \quad (4)$$

$$1 + \text{abs}(f_i); f_i < 0$$

در رابطه فوق fi هزینه مربوط به راه‌حل xi می‌باشد و این تابع مستقیماً با تابع هزینه مسأله حداکثرسازی رابطه دارد. در اینجا پس از تعیین شایستگی، هر زنبور کارگر یک منبع غذای کاندید جدید vi را در همسایگی منابع غذایی موجود جستجو می‌کند. منبع غذایی جدید براساس اطلاعات زنبورها مقایسه می‌شوند و براساس رابطه (۵) ارزیابی می‌شوند. در این روش انتخاب مشتاقانه برای انتخاب منبع غذایی بهتر به‌عنوان منبع غذایی جدید انتخاب می‌شود (Chen و همکاران، ۲۰۱۸).

$$V_{ij} = X_{ij} + \phi_{ij} (X_{ij} - X_{kj}) \quad (5)$$

در این رابطه یک متغیر بهینه‌سازی تصادفی در رنج [۱, D] می‌باشد

در این رابطه  $x_i$  بردار ورودی و  $w_{ij}$  وزن‌های متناظر با بردار ورودی می‌باشد.  $Y_i$  پاسخ نورون مبتنی بر تابع هدف است. مطابق با رابطه (۸) برای خروجی، نورون از یک تابع تبدیل سیگموئید استفاده می‌کند:

$$y_i = \frac{1}{1 + e^{-x_i}} \quad (8)$$

شبکه تابع هدف و خطا با استفاده از رابطه (۹) محاسبه می‌شود:

$$E = \frac{1}{n} \sum_{i=1}^n (y_i - a_i)^2 \quad (9)$$

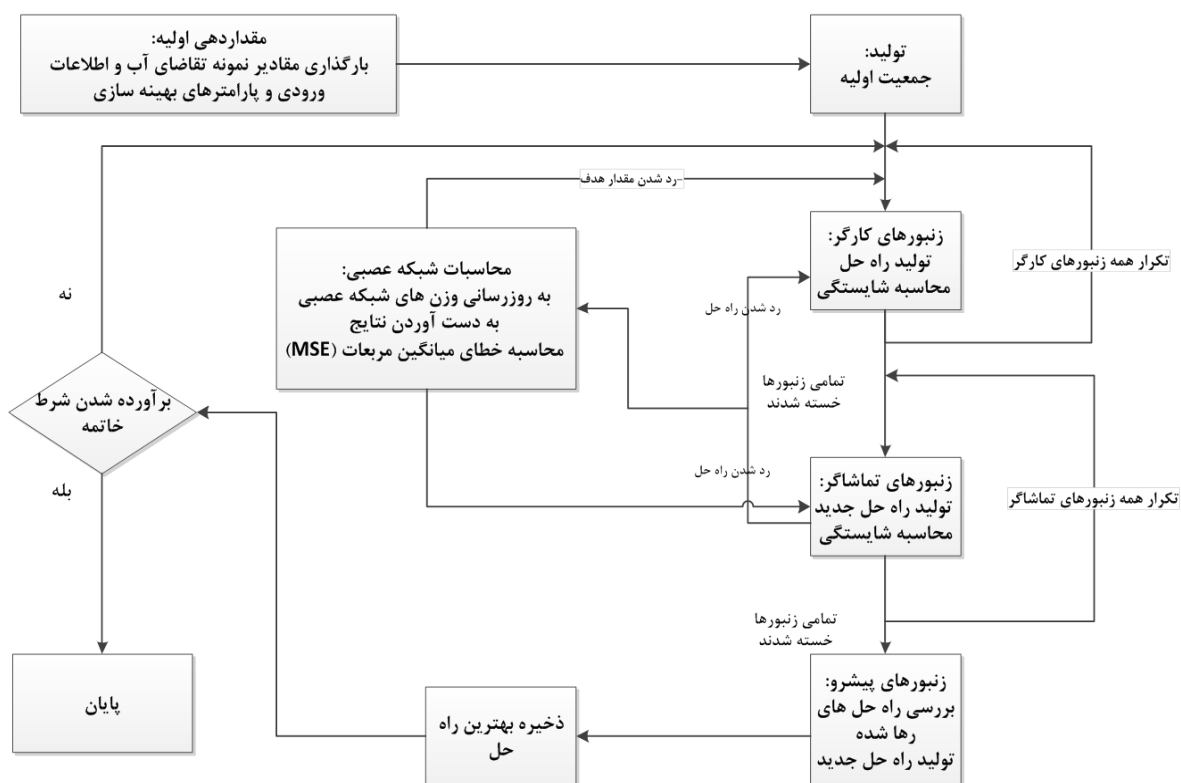
$y_i$  خروجی به‌دست آمده از در نورون  $i$  و  $a_i$  خروجی مطلوب است. در این گام، شبکه تابع هدف را به مرحله آموزش بر می‌گرداند تا راه‌حل‌ها بیشتر ارزیابی شوند. پس از آنکه هر راه‌حل کاندید با استفاده از زنبورهای مصنوعی تولید شده و در شبکه عصبی پیش‌خور ارزیابی شد، شایستگی راه‌حل با بهترین راه‌حل قبلی محاسبه می‌شود. اگر راه‌حل جدید بهتر یا برابر مقدار شایستگی پیشین بود، بهترین راه‌حل قبلی با راه‌حل جدید در حافظه جایگزین می‌شود. الگوریتم کلونی زنبور عسل مراحل ذکر شده را تا برآورده شدن معیار خاتمه یا تعدادی معین تکرار انجام می‌دهد. پس از خاتمه الگوریتم مقدار شایستگی و موقعیت بهینه منبع غذایی به‌عنوان پارامترهای تصمیم‌گیری ذخیره می‌شوند. در این مقاله الگوریتم در صورتی دیگر تکرار نمی‌شود که به تکرار ۵۰۰ برسد و یا خطای میانگین مربعات به کمتر از ۰/۰۰۰۱ برسد.

و  $k$  یک منبع غذایی انتخاب شده به‌صورت تصادفی و متفاوت از  $i$  می‌باشد که یک عدد تصادفی حقیقی با توزیع یکنواخت در بازه  $-1$  و  $1$  است.  $D$  یک عدد غیرمنفی است. به نحوه وزندهی راه‌حل پرداخته می‌شود. احتمال انتخاب یک راه‌حل در جمعیت متناسب با مقدار نکتار در منبع غذایی و یا مقدار شایستگی منبع غذایی در جمعیت می‌باشد. با استفاده از روش انتخاب چرخ رولت (Goldberg و همکاران، ۱۹۸۹)، هر زنبور تماشاگر یک منبع غذایی با احتمال بالاتر را با استفاده از رابطه (۶) انتخاب می‌کند. سپس یک راه‌حل کاندید مبتنی بر رابطه (۴) تولید می‌شود.

$$p_i = \frac{\text{fitness}_i}{\sum_{i=1}^N \text{fitness}_i} \quad (6)$$

$p_i$  احتمال منبع غذایی  $i$ ام می‌باشد. در این مرحله راه‌حل‌ها ارزیابی شده و منابع غذایی بهتر جایگزین دیگر منابع غذایی می‌شوند که این امر با رویه انتخاب مشتاقانه صورت می‌پذیرد. راه‌حل بهتر که ترکیب وزن‌های نورونی است به شبکه عصبی داده می‌شود تا در رویه پردازش قرار بگیرد. در شبکه عصبی نورون‌های مختلف در سه لایه ترکیب شده و وزن‌های اتصال و سیگنال‌های ورودی در هر نورون پردازش شده و به دیگر نورون‌ها در لایه دیگر می‌روند. یک نورون تکی ورودی‌های وزن دهی شده را با استفاده از فرمول ذیل محاسبه می‌کند:

$$y_i = \sum_{j=1}^n x_j w_{ij} \quad (7)$$

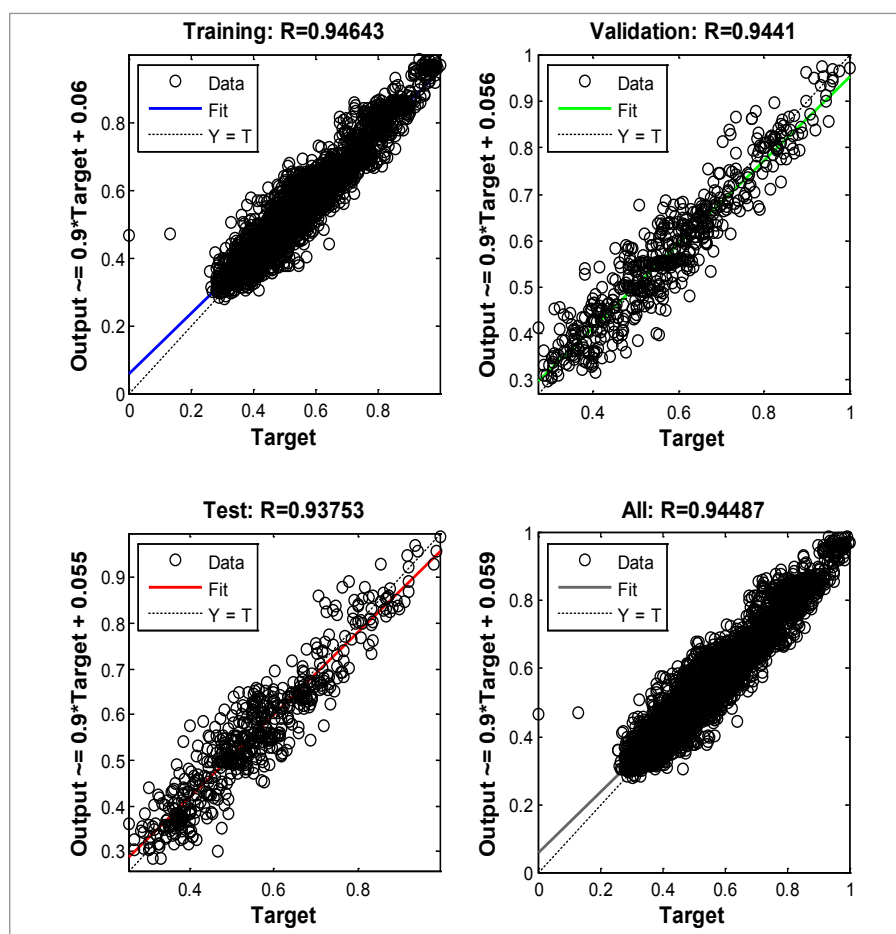


شکل ۲- رویه یادگیری شبکه عصبی با استفاده از الگوریتم بهینه‌سازی کلونی زنبور عسل

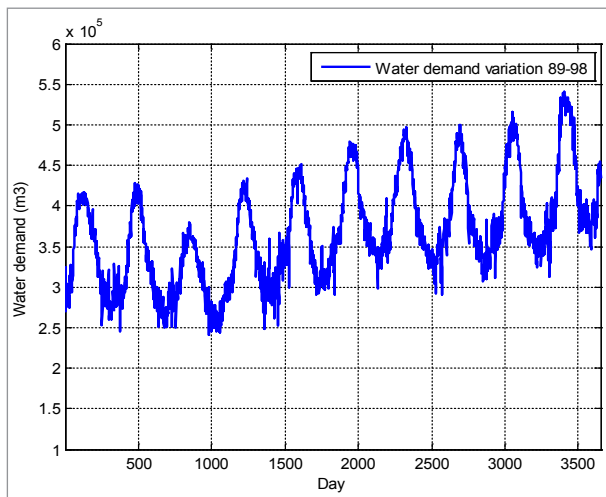
## نتایج و بحث

برای شبیه‌سازی از اطلاعات ۱۰ ساله تقاضای آب، جمعیت و اطلاعات آب‌وهوایی شامل متوسط دمای روزانه و وزش باد مربوط به سیستم آبرسانی شیراز به‌عنوان اطلاعات گذشته استفاده شده است. این اطلاعات ۱۰ ساله از سال ۱۳۸۹ تا سال ۱۳۹۸ جمع‌آوری شده است. اطلاعات شامل تقاضای آب، جمعیت، دما و وزش باد در شیراز می‌باشد. همچنین برای مقایسه اطلاعات پیش‌بینی شده با واقعیت پیش‌بینی تقاضای آب سال ۱۳۹۸ انجام گرفته است اما می‌توان برنامه نوشته شده را به‌صورت ساعتی برای زمان‌های آینده استفاده کرد. داده تست مربوط به دو سال بوده است. در حقیقت فقط برای مقایسه با اطلاعات در دسترس از پیش‌بینی سال ۱۳۹۸ استفاده شده است. جهت پیش‌بینی تقاضای آب سال ۱۳۹۸، این شبیه‌سازی‌ها برای کل مصرف شیراز انجام شده است. به‌منظور شبیه‌سازی پیش‌بینی تقاضای آب از نرم‌افزار MATLAB استفاده شده است.

رویه مرحله مقدار دهی اولیه تا مرحله خاتمه برای زنبورهای کارگر تکرار می‌شود تا راه حلی بهتر پیدا کنند و پس از آن زنبورهای تماشاگر فراخوانده می‌شوند تا راه‌حل‌ها را براساس احتمالاتشان دوباره تولید کنند. اگر زنبورهای تماشاگر قادر به یافتن مینیمم مطلق نشوند، پس از آن زنبورهای پیشرو شروع به تولید یک راه‌حل تصادفی می‌نمایند. این رویه از یافتن مینیمم محلی جلوگیری می‌کند. هر نوع زنبور راه‌حل‌های کاندید را به شبکه عصبی می‌دهد تا مقدار هدف محاسبه شود و دوباره برای انتخاب یا رد راه‌حل بازگردانده شود. هر یک از زنبورهای کارگر و زنبورهای تماشاگر در گام نخست قرار دارند و سه خط خروجی دارند. یک خط به بلوک شبکه عصبی وصل می‌شود تا روندهای محاسباتی شایستگی و خطا را انجام دهد و دوباره راه‌حل‌ها را به بلوک‌های زنبورها می‌دهد. این رویه تا زمانی‌که همه زنبورهای بلوک‌ها خسته شوند ادامه می‌یابد. اگر تمامی زنبورهای یک بلوک خسته شوند و شرط خاتمه برآورده نشود، نوبت به زنبورهای پیشرو برای تولید تصادفی خواهد رسید تا فضای جستجو را تغییر دهند. در ادامه به تحلیل نتایج پرداخته می‌شود.

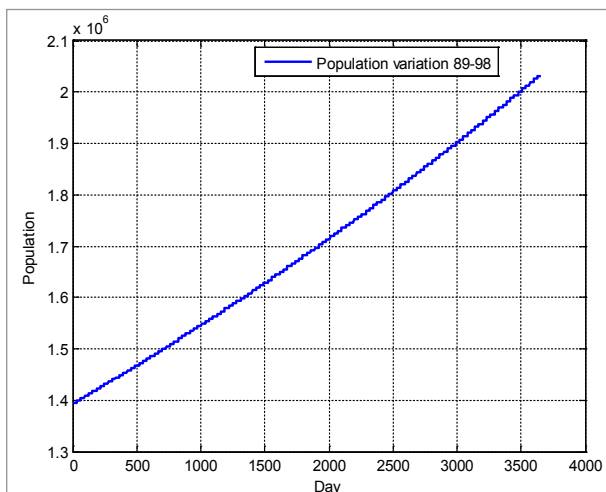


شکل ۳- رگرسیون داده‌ها در آموزش، تست و اعتبارسنجی روش شبکه عصبی



شکل ۶- تغییرات تقاضای آب طی ده سال از ۱۳۸۹ تا ۱۳۹۸

در شکل (۷) تغییرات جمعیت شیراز از سال ۸۹ تا ۹۸ برای ماه‌های مختلف نمایش داده شده است، این پارامتر یکی از پارامترهای ورودی پیش‌بینی بوده است.

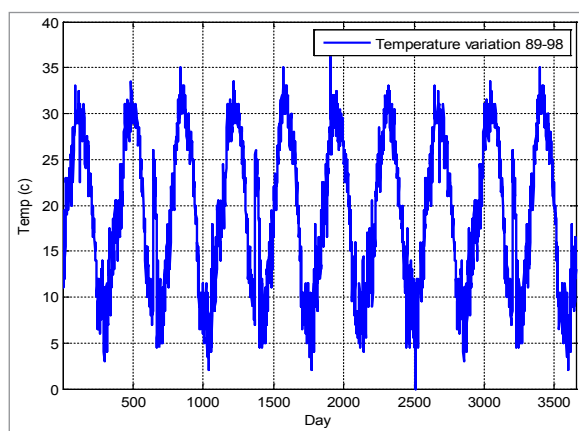


شکل ۷- تغییرات جمعیتی از سال ۱۳۸۹ تا ۱۳۹۸


پس از اجرای شبکه عصبی و آموزش شبکه و تست و اعتبارسنجی برای مشاهده نتایج، تقاضای آب سال ۹۸ پیش‌بینی شده است. برای آنالیز داده‌ها، نتایج پیش‌بینی تقاضای آب برای چهار فصل و به صورت مقایسه‌ای با داده‌های واقعی نمایش داده شده است. به این منظور از چهار ماه فروردین، مرداد، آذر و بهمن در ۴ فصل متفاوت استفاده شده است. در شکل (۸) اطلاعات پیش‌بینی تقاضای آب و اطلاعات واقعی برای ماه فروردین نشان داده شده است. همچنان که مشاهده می‌شود پیش‌بینی تقاضای آب در این ماه بسیار نزدیک به مقادیر واقعی بوده است. در شکل (۹) اطلاعات پیش‌بینی تقاضای آب و اطلاعات واقعی

در شکل (۳) وضعیت رگرسیون داده‌ها در آموزش، تست و اعتبارسنجی نمایش داده شده است. در این شکل‌ها مشاهده می‌شود داده‌ها پیرامون خط رگرسیون در سه مورد آموزش، تست و اعتبارسنجی پراکنده شده‌اند. در شکل‌های ذیل مشخص است  $R$  برای کل داده‌ها برابر با  $0/994$  و  $R^2$  برابر با  $0/9$  است. در حقیقت  $R$  همان ضریب تعیین در پیش‌بینی‌ها می‌باشد که این شاخص قدرت پیش‌بینی متغیر مورد نظر براساس متغیرهای ورودی را نمایش می‌دهد.  $R^2$  نیز ضریب تشخیص در شبکه عصبی می‌باشد که به‌عنوان معیاری برای تعیین مناسب بودن پیش‌بینی داده‌ها به‌کار می‌رود. باتوجه‌به این شکل‌ها به دلیل آن که داده‌ها به خط مدنظر نزدیک بوده‌اند و این پارامتر به عدد یک نزدیک‌تر است متغیرهای ورودی به خوبی به مدل شبکه عصبی معرفی شده‌اند.

به‌منظور پیش‌بینی تقاضای آب در این مقاله از داده‌های گذشته تقاضای آب، جمعیت، دما و وزش باد استفاده شده است که در شکل‌های (۴ تا ۷) نمودار روند تغییرات آن‌ها برای ۱۰ سال آموزش یعنی ۸۹ تا ۹۸ آورده شده است. شایان ذکر است کلیه داده‌ها برای ۱۰ سال به‌عنوان ورودی لحاظ شده است.

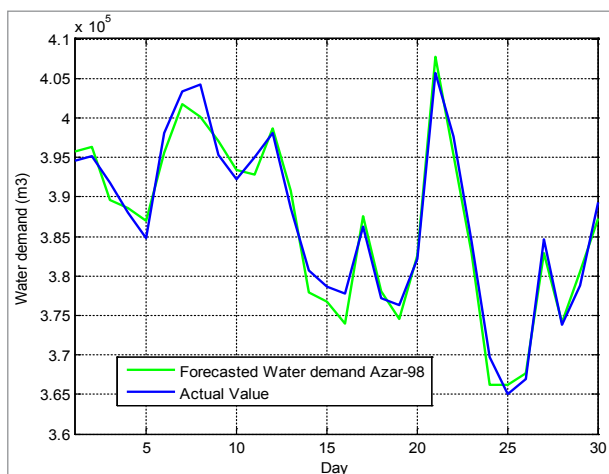


شکل ۸- تغییرات دمایی طی ده سال ۱۳۸۹ تا ۱۳۹۸




شکل ۹- تغییرات وزش باد طی ده سال از ۱۳۸۹ تا ۱۳۹۸

پیشنهادی انجام شده است. تقاضای آب در این ماه نسبت به تابستان کاهش داشته است که الگوریتم پیشنهادی به خوبی توانسته مقادیر این فصل را نیز مبتنی بر اطلاعات آموزش داده شده شبکه عصبی پیش‌بینی نماید. اطلاعات پیش‌بینی تقاضای آب و اطلاعات واقعی برای ماه بهمن در فصل زمستان در شکل (۱۱) نمایش داده شده است. همچنان که مشاهده می‌شود برای این ماه به خوبی پیش‌بینی تقاضای آب انجام شده است و مقادیر پیش‌بینی در نزدیکی مقادیر واقعی قرار دارد.



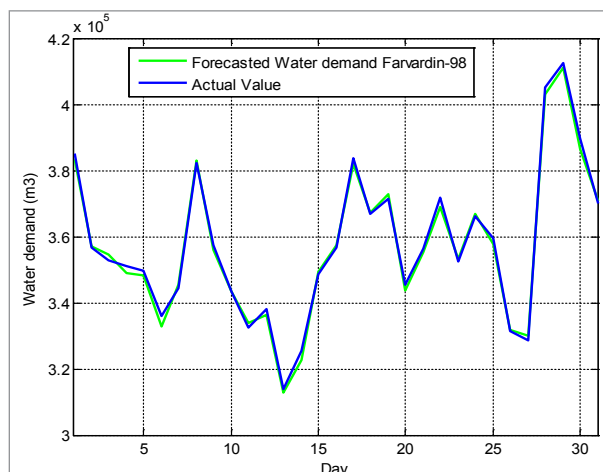
شکل ۱۰- نتایج پیش‌بینی تقاضای آب برای آذر ماه ۱۳۹۸  
آبی: مقدار واقعی، سبز: مقدار پیش‌بینی



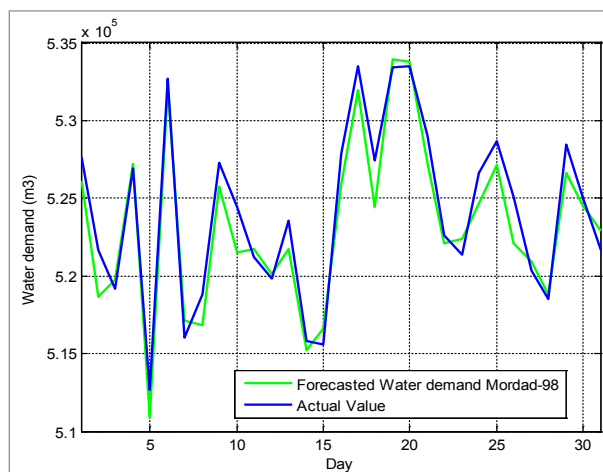
شکل ۱۱- نتایج پیش‌بینی تقاضای آب برای بهمن ماه ۱۳۹۸  
آبی: مقدار واقعی، سبز: مقدار پیش‌بینی

مقدار پیش‌بینی به مقدار تقاضا برابر با ۰/۰۰۲ بوده است. در این بخش با توجه به رابطه  $MAPE^2$  که یک پارامتری آماری مناسب برای تحلیل مناسب بودن پیش‌بینی می‌باشد، به مقایسه نتایج این مقاله با دیگر مقالات پرداخته می‌شود. رابطه  $MAPE$  به صورت رابطه (۱۰) است:

تقاضای آب برای ماه مرداد در تابستان نمایش داده شده است. مشاهده می‌شود برای این ماه پیش‌بینی در حد قابل قبولی بوده است. تقاضای آب در این ماه در مقادیر بالایی قرار دارد که به دلیل دمای بالای هوا و مصرف بالا می‌باشد. روش پیشنهادی به خوبی توانسته مقادیر این فصل را با توجه به اطلاعات آموزش داده شده شبکه عصبی پیش‌بینی کند. اطلاعات پیش‌بینی تقاضای آب و اطلاعات واقعی برای ماه آذر در پاییز در شکل (۱۰) نمایش داده شده است. همچنان که مشاهده می‌شود برای این ماه به خوبی پیش‌بینی تقاضای آب توسط روش



شکل ۸- نتایج پیش‌بینی تقاضای آب برای فروردین ماه ۱۳۹۸  
آبی: مقدار واقعی، سبز: مقدار پیش‌بینی



شکل ۹- نتایج پیش‌بینی تقاضای آب برای مرداد ماه ۱۳۹۸  
آبی: مقدار واقعی، سبز: مقدار پیش‌بینی

در پایان به منظور اعتبارسنجی روش پیشنهادی با پژوهش‌های پیشین مقایسه می‌شود. در این قسمت هدف مقایسه داده‌های آماری این مقاله با دو مقاله دیگر در زمینه پیش‌بینی تقاضای آب می‌باشد. لازم به ذکر است برای پیش‌بینی تقاضای آب سال ۱۳۹۹ انحراف معیار خطا برابر با ۰/۰۹۲ و انحراف معیار نسبت



$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|At - Ft|}{At} \quad (10)$$

در این رابطه  $At$  مقدار واقعی و  $Ft$  مقدار پیش‌بینی و  $n$  تعداد داده می‌باشد. برای داده‌های فروردین ۹۹ مقدار  $MAPE$  این مقاله برابر با نه درصد می‌شود. Hutton و همکاران (۲۰۲۰) این مقدار برابر با هفت درصد بوده است که روش پیشنهادی این مقاله به دنبال ارتقای دقت پیش‌بینی تقاضای آب و بررسی فاکتورهای تأثیرگذار در مقیاس‌های مختلف براساس روش ماشین‌افزایشی گرادیان بوده است. در این مرجع اطلاعات مربوط به مصرف آب در سطح خانگی، موقعیت‌های مختلف، مشخصات خانه‌ها و اطلاعات آب‌وهوایی به‌عنوان ورودی در نظر گرفته شده است، درحالی‌که در این مقاله جمعیت، دمای هوا، مشخصات زمانی و ورزش باد به‌عنوان ورودی در نظر گرفته شده‌اند. از لحاظ مقدار پارامتر آماری  $MAPE$  روش ارائه شده در این مقاله مقادیر مطلوب و نزدیکی به روش ارائه شده در مقاله (Hutton و همکاران، ۲۰۲۰) به‌دست آمد. در همین راستا مقاله Bakker و همکاران، (۲۰۱۴) از پارامتر آماری  $MAPE$  استفاده نموده است که در این مرجع این مقدار برابر با ۶ درصد به‌دست آمد. به‌طورکلی از داده‌های آب‌وهوایی استفاده شده و از یک روش تطبیقی جهت پیش‌بینی تقاضای آب استفاده شده است.

باتوجه به مطالب ذکر شده نتایج این مقاله معتبر بوده است و توانسته تا حد مطلوبی خطا را در پیش‌بینی تقاضای آب کاهش دهد و دقت روش پیش‌بینی را ارتقا دهد که از این منظر روش ترکیبی شبکه عصبی-بهینه‌سازی کلونی زنبور عسل به شیوه مناسبی عمل نموده است.

#### نتیجه‌گیری

یک سیستم آبرسانی، شرکت‌های آب و فاضلاب باید به‌صورت دقیق تقاضاهای پیش‌بینی شده را تطبیق دهنده تا منابع آبرسانی را به‌صورتی متناسب در دسترس قرار دهند. در این مقاله برای بهینه‌سازی عملکرد شبکه عصبی در پیش‌بینی تقاضای آب از روش الگوریتم کلونی زنبور عسل استفاده شد. بر این اساس روشی ترکیبی برای پیش‌بینی تقاضای آب استفاده شد. از الگوریتم کلونی زنبور عسل به‌منظور بهینه‌سازی رویه یادگیری شبکه عصبی در پیش‌بینی تقاضای آب استفاده شده است. وزن‌های بهینه شده به روشی بازگشتی با به‌کارگیری روش بهینه‌سازی کلونی زنبور عسل به‌دست آمده که از الگوریتم کلونی زنبور عسل برای به‌دست آوردن بهترین پارامترهای آموزش استفاده می‌شود. روش پیشنهادی مبتنی بر استفاده از شبکه عصبی و کلونی زنبور عسل برای پیش‌بینی

تقاضای آب در شبکه آبرسانی شیراز با لحاظ کردن میزان مصرف آب روزها در گذشته، جمعیت و عوامل آب‌وهوایی مانند ورزش باد، دما شد.

نتایج پیاده‌سازی روش پیشنهادی اثبات نمود، استفاده از روش الگوریتم کلونی زنبور عسل و شبکه عصبی دقت مطلوبی داشته است، به‌طوری‌که انحراف پیش‌بینی تقاضای آب در بدترین شرایط به عدد یک رسید و در بیشتر موارد در زیر یک بود که حد قابل قبولی می‌باشد. همچنین با مقایسه رفتار تقاضای آب در دو بازه زمانی مشاهده شده که بازه گرم سال با افزایش و مصرف بالای تقاضای آب همراه می‌باشد. به‌طورکلی نتایج شبیه‌سازی پیش‌بینی تقاضای آب نشان می‌دهد روش پیشنهادی کارایی خوبی داشته است.

محدودیت‌های این مقاله عدم دسترسی به پارامترهایی مانند رطوبت، پوشش ابر و تابش خورشید در پیش‌بینی تقاضای آب بوده است که می‌توان در تحقیقات آتی اثرات آن‌ها را بر روی پیش‌بینی تقاضای آب ارزیابی کرد. علاوه بر این باتوجه به پیچیدگی شبیه‌سازی در این مقاله از روش ترکیبی رگرسیون-شبکه عصبی استفاده نشده است که با مطالعات بیشتر می‌توان در تحقیقات آینده جهت ارتقای کارایی روش پیش‌بینی تقاضای آب می‌توان از این روش استفاده نمود.

#### پی‌نوشت

- 1- Takagi-Sugeno-Kang
- 2- Mean Absolute percentage error

#### منابع

- Abiodun O. I., Jantan A., Omolara A. E., Dada K. V., Mohamed N. A and Arshad H. 2018. State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11): e00938.
- Bakker H., van Duistc K., van Schagen K., Vreeburg J. and Rietved L. 2014. Improving the performance of water demand forecasting models by using weather input, *Procedia Engineering*, 70: 93-103.
- Candelieri A. 2017. Clustering and Support Vector Regression for Water Demand Forecasting and Anomaly Detection. *Water*, (3): 224-243.
- Chen S., Guohua F., Xianfeng H. and Yuhong Zh. 2018. Water Quality Prediction Model of a Water Diversion Project Based on the Improved Artifi-

- els-Part 1: Problem definition and representation of water demand. *Hydrology and Earth System Sciences*, 19(1): 33-61.
- Smolak K., Kasieczka B., Fialkiewicz W., Rohm W., Siła-Nowicka K. and Kopańczyk K. 2020. Applying human mobility and water consumption data for short-term water demand forecasting using classical and machine learning models. *Urban Water Journal*, 17(1): 32-42.
- Tavanpour N., Noshadi M. and Tavanpour N. 2016. Scale formation and corrosion of drinking water pipes: a case study of drinking water distribution system of Shiraz city. *Modern Applied Science*, 10(3): 166-177.
- Wang Y., Jian L., Rong L., Xinyu S. and Enhui L. (2020). Precipitation forecast of the Wujiang River B based on artificial bee colony algorithm and backpropagation neural network, *Alexandria Engineering Journal*, 59: 1473-1483.
- Waqas Khan P., Byun Y. C., Lee S. J. and Park N. 2020. Machine learning based hybrid system for imputation and efficient energy demand forecasting. *Energies*, 13(11): 2681.
- Zubaidi S. L., Al-Bugharbee H., Ortega-Martorell S., Gharghan S. K., Olier I., Hashim K. S and Kot P. 2020. A novel methodology for prediction urban water demand by wavelet denoising and adaptive neuro-fuzzy inference system approach. *Water*, 12(6): 1628.
- Zubaidi S. L., Ortega-Martorell S., Kot P., Alkhaddar R. M., Abdellatif M., Gharghan S. K and Hashim K. 2021. A method for predicting long-term municipal water demands under climate change. *Water Resources Management*, 34(3): 1265-1279.
- cial Bee Colony-Back propagation Neural Network, *Water*, 10(6): 806.
- Ghalekhondabi I., Ardjmand E. and Young W.A. 2017. Water demand forecasting: review of soft computing methods. *Environmental Monitoring and Assessment Journal*, 189(7): 313-330.
- Graf R., Zhu S. and Sivakumar B. 2019. Forecasting river water temperature time series using a wavelet-neural network hybrid modelling approach. *Journal of Hydrology*, 578: 124115.
- Goldberg David E. 1989. Genetic algorithms in search, optimization and machine learning, 1st ed. Addison-Wesley Longman Publishing Co., Inc, Boston.
- Guo L., Fu P., Shi T., Chen Y., Zeng C., Zhang H. and Wang S. 2021. Exploring influence factors in mapping soil organic carbon on low-relief agricultural lands using time series of remote sensing data. *Soil and Tillage Research*, 210: 104982.
- Hutton C., Hofman J. and Kapelan Z. 2020. Water demand forecasting accuracy and influencing factors at different spatial scales using a Gradient Boosting Machine. *Water Resources Research*. 56(8): 1-13.
- Kozłowski E., Kowalska B. and Kowalski D. 2018. Water demand forecasting by trend and harmonic analysis. *Archivs Civil and Mechanical Engineering*, 18: 140-148.
- Meireles I., Sousa V., Bleys B. and Poncelet B. 2022. Domestic hot water consumption pattern: Relation with total water consumption and air temperature. *Renewable and Sustainable Energy Reviews*, 157: 112035.
- Nazemi A. and Wheeler H. S. 2015. On inclusion of water resource management in Earth system mod-