



عملکرد شش روش ترکیبی هوشمند در مدل‌سازی کیفی آب زیرزمینی مطالعه موردی: دشت بافق

امیرمحمد رخ شاد^۱، علی شهیدی^{۲*}

۱- دانشجوی دکترای منابع آب، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، خراسان جنوبی، ایران

۲- دانشیار، گروه علوم و مهندسی آب، دانشگاه بیرجند، خراسان جنوبی، ایران

* نویسنده مسئول: ashahidi@birjand.ac.ir

تاریخ پذیرش مقاله: ۱۳۹۹/۱۰/۱۶

تاریخ دریافت مقاله: ۱۳۹۸/۰۶/۲۶

چکیده

بررسی و کنترل کیفیت آب‌های زیرزمینی در برنامه‌ریزی و توسعه منابع آب نقش مهمی دارد و استفاده از یک روش کارا می‌تواند تا حد زیادی موجب افزایش دقت و کاهش هزینه‌ها در این زمینه گردد. در این پژوهش، برای آموزش و بهینه‌یابی پارامترهای مدل سیستم استنتاج عصبی-فازی (ANFIS) جهت مدل‌سازی کیفی آب زیرزمینی دشت بافق در استان یزد، از ۶ الگوریتم فراابتکاری بهینه‌سازی ازدحام ذرات (PSO)، ژنتیک (GA)، رقابت استعماری (ICA)، کرم شب‌تاب (FA)، فرهنگ (CA) و استراتژی تکامل انطباق ماتریس کوواریانس (CMA-ES) استفاده گردید. برای انتخاب بهترین ترکیب ورودی جهت تخمین سه پارامتر هدایت الکتریکی (EC)، جذب سدیم (SAR) و سختی کل (TH) از روش‌های پیرسون و اسپیرمن برای تحلیل حساسیت و میزان همبستگی سایر پارامترها استفاده گردید و مدل‌سازی کیفی با روش‌های ترکیبی انجام و عملکرد مدل‌ها با نمایه‌های ضریب همبستگی (R^2)، خطای جذر میانگین مربعات (RMSE) و ضریب نش-ساتکلیف (NSE) سنجیده شد. نتایج نشان داد که هر شش روش ترکیبی عملکرد بسیار مناسبی را در مدل‌سازی پارامترهای آب زیرزمینی از خود نشان دادند. همچنین مدل ANFIS-FA در هر سه دسته مدل‌سازی جزو بهترین مدل‌ها بود، به طوری که مقدار R^2 ، RMSE و NSE آن به ترتیب برای بخش آزمایش در TH، ۰/۹۹، ۰/۴۱ و ۰/۹۹، برای SAR، ۰/۹۸، ۱/۱۱ و ۰/۹۵، برای EC، ۰/۹۹، ۰/۷ و ۰/۹۹ به دست آمد. سایر روش‌ها نیز با دقتی مناسب موفق به مدل‌سازی و پیش‌بینی پارامترهای مورد نظر شدند. با توجه به دقت محاسبات، این روش‌ها گزینه‌های مناسبی برای پیش‌بینی متغیرهای کیفی آب زیرزمینی به شمار می‌روند.

واژه‌های کلیدی: آب زیرزمینی، نروفازی، الگوریتم، مدل‌سازی، نسبت جذب سدیم، هدایت الکتریکی.

مقدمه

و فرآیندهای آلوده کننده همراه شده است (ابوخلف و همکاران،

۲۰۱۳).

آب‌های زیرزمینی یکی از منابع اصلی تأمین آب شرب و کشاورزی است. مدل‌سازی کیفیت آب‌های زیرزمینی برای ایجاد استراتژی‌های بهتر برای برنامه ریزی و مدیریت منابع آب ضروری است (لیو و همکاران، ۲۰۰۹). از میان پارامترهای مختلفی که می‌توانند در آب‌های زیرزمینی دارای اهمیت باشند، اندازه‌گیری و مشخص کردن سه پارامتر رسانایی الکتریکی (EC)، نسبت

از آب می‌توان به‌عنوان مهمترین منبع طبیعی نام برد که نقش حیاتی نگهداری کمی و کیفی از آن به‌خصوص در کشورهایی با اقلیم خشک، غیرقابل انکار است. بسیاری از عوامل مانند رشد جمعیت، توسعه کشاورزی و اقتصادی و همچنین آب و هوای خشک باعث کمبود آب کافی شده است که بحران جدی برای این‌گونه منطقه به‌شمار می‌رود. افزون بر این، این محدودیت با افزایش سریع کاهش کیفیت منابع آب شیرین، به دلیل شوری

آنیون‌ها و کاتیون‌های اصلی، SAR و pH با روش شبکه عصبی پرداختند. نتایج نشان داد این روش کارایی بالایی در پیش‌بینی مقادیر پارامترهای کیفی آب زیرزمینی دارد. میرسنجری و همکاران (۱۳۹۶)، به مدل‌سازی پارامترهای کیفی TDS و EC آب زیرزمینی دشت مهران پرداختند. تنها روش استفاده شده در این مطالعه، شبکه عصبی مصنوعی بود که توانایی بالایی در ایجاد رابطه بین سایر پارامترها و پارامترهای موردنظر نشان داد.

استفاده از الگوریتم‌های فراابتکاری نیز در پژوهش‌های متعدد مرتبط با منابع آب به کار گرفته شده است. ژو و همکاران (۲۰۰۶)، از دو مدل PSO^۲ و ANN^۴ برای پیش‌بینی کیفیت آب در رودخانه یانگ تسه استفاده نمودند. براساس نتایج به دست آمده، الگوریتم PSO توانایی بهتری از خود نشان داده است. سودر و ماتور (۲۰۱۲)، به بررسی توانایی الگوریتم PSO به‌عنوان یک روش آموزش در مدل‌سازی ضریب ذخیره و ضریب انتقال یک آبخوان پرداختند. براساس نتایج به‌دست آمده، الگوریتم PSO توانایی مناسبی به‌خصوص در مقایسه با سایر الگوریتم‌های استفاده شده نشان داد. کاظم‌زاده پارسا و همکاران (۲۰۱۵)، از روش ترکیبی الگوریتم FA^۵ و اجزای محدود (FEM) برای تعیین طراحی بهینه سیستم پمپ-تصفیه جهت پاکسازی آب زیرزمینی در سه سناریو استفاده نمودند و عملکرد این روش را با الگوریتم GA مقایسه کردند. نتایج نشان دهنده عملکرد بهتر الگوریتم FA می‌باشد.

دلیر و همکاران (۲۰۱۹)، با استفاده از الگوریتم FA به بهینه‌سازی شبکه توزیع آب شهری پرداختند و کارایی این الگوریتم را تأیید نمودند. حسینی مقاری و همکاران (۲۰۱۵)، از الگوریتم‌های ICA^۶ و COA^۷ برای بهینه‌سازی مخزن سد کارون ۴ با توجه به معیارهای مختلف استفاده و عملکرد آن‌ها را با نتایج حاصل از الگوریتم GA و روش MLP مقایسه نمودند. با توجه به نتایج، هر دو الگوریتم مورد بررسی عملکرد مناسب‌تری را ارائه

جذب سدیم (SAR) و سختی کل (TH) اهمیت زیادی دارد (جلال کمالی، ۲۰۱۵).

از میان روش‌های تجزیه و تحلیل کیفیت آب‌های زیرزمینی، شیوه‌های سنتی مانند سری‌های زمانی و آمار و احتمالات، اساساً مبتنی بر مدل‌سازی ریاضی هستند که معمولاً یک رابطه خطی بین متغیر وابسته و مستقل را در نظر می‌گیرند. بنابراین دقت کلی مدل کافی به نظر نمی‌رسد (لیو و همکاران، ۲۰۰۳). به همین دلیل استفاده از شیوه‌های جدید و هوش مصنوعی به عنوان یک روش جایگزین مطرح شده و پژوهش‌های متعددی براین اساس صورت گرفته است.

یکی از شیوه‌های رایج برای مدل‌سازی کیفی آب، مدل ANFIS^۱ است که در کنار روش شبکه عصبی، از جمله پرکاربردترین مدل‌ها در حوضه شبیه‌سازی در منابع آب به‌شمار می‌رود. موسوی و امیری (۲۰۱۲)، از چهار مدل ANFIS برای برآورد میزان غلظت نیترات براساس پارامترهای کیفی در استان اصفهان استفاده نمودند. براساس نتایج حاصل شده، مدل ANFIS1 با مقدار $R^2=0.93$ بهترین عملکرد را نشان داد و به‌طورکلی برای برآورد میزان نیترات در منطقه موردنظر توصیه شد. امامقلی‌زاده و همکاران (۲۰۱۴)، از روش‌های MLP^۲ و ANFIS برای مدل‌سازی سه پارامتر DO، BOD و COD در رودخانه کارون استفاده نمودند. ورودی مدل آن‌ها شامل ۹ پارامتر بود که با توجه به نمایه‌های مورد استفاده، روش MLP مناسب‌تر تشخیص داده شد و پارامتر فسفات نیز موثرترین پارامتر ورودی معرفی گردید. خدر و الشمی (۲۰۱۶)، مدل ANFIS را برای پیش‌بینی پارامترهای کیفی آب زهکش‌های مرتبط با دریاچه مانزال در مصر به کار بردند که هدف اصلی آنها به دست آوردن میزان فسفر و نیتروژن بود. نتایج نشان می‌دهد که مدل ANFIS قادر به شبیه‌سازی پارامترهای کیفی موردنظر بود و مقادیر پیش‌بینی‌های قابل‌قبولی از فسفر و نیتروژن ارائه داد. اقدر و محمدیاری (۱۳۹۴)، به مدل‌سازی پارامتر TH بر اساس سایر مؤلفه‌های شیمیایی یعنی

⁵ Firefly Algorithm

⁶ Imperialist Competitive Algorithm

⁷ Cuckoo Optimization Algorithm

¹ Adaptive Neuro Fuzzy Inference System

² Multilayer Perceptron

³ Particle Swarm Optimization

⁴ Artificial Neural Network

روزانه در پایین دست رودخانه طالقان با استفاده از داده‌های شش‌ساله ایستگاه باران‌سنجی و هیدرومتری سنجیدند. نتایج بررسی نشان داد که FIS-DSOA بهتر از مدل‌های غیرهیبریدی در پیش‌بینی جریان روزانه عمل می‌کند و دقت نتایج به دست آمده را به‌طور قابل‌توجهی افزایش یافته است. کیسی و همکاران (۲۰۱۷)، دومدل ANN-PSO و ANN-DE را برای مدل‌سازی پارامترهای کیفی آب زیرزمینی مانند EC و SAR مورد استفاده قرار دادند. نتایج نشان داد که ANN-DE نتایج دقیق‌تری نسبت به ANN-PSO در مدل‌سازی SAR و هدایت الکتریکی (EC) ارائه می‌دهد. آزاد و همکاران (۲۰۱۸)، از سه الگوریتم ژنتیک (GA)، کلونی مورچه (ACOR) و تکامل افتراقی (DE) برای بهبود عملکرد سیستم استنتاج فازی جهت ارزیابی پارامترهای کیفی آب رودخانه گرگان‌رود استفاده کردند. پارامترهای مورد بررسی آنها، EC، SAR و TH بود. نتایج نشان داد که مدل ANFIS-DE برای EC و TH و مدل‌های ANFIS-DE و ANFIS-GA برای SAR بهترین عملکرد را از خود نشان داده‌اند. تین بوی و همکاران (۲۰۱۸)، از سه روش ترکیبی ANFIS-CA، ANFIS-BA و ANFIS-IWO برای بررسی حساسیت سیل در حوضه هراز در ایران استفاده نمودند. نتایج بهینه‌سازی نشان داد که روش ANFIS-IWO نسبت به دو روش دیگر عملکردی بهتری دارد ولی هر سه روش دارای کارایی لازم می‌باشند. نوری و همکاران (۱۳۹۷)، به برآورد پیک رودخانه یالفان با استفاده از سه روش MLP، ANFIS و روش ترکیبی الگوریتم ژنتیک و شبکه عصبی پرداختند. ۵ پارامتر به‌عنوان ورودی و دبی پیک به‌عنوان خروجی در نظر گرفته شد. نتایج نشان می‌دهد که روش ترکیبی الگوریتم ژنتیک و شبکه عصبی نتایج بهتری ارائه نموده است. هدف از این پژوهش، ارزیابی عملکرد ۶ الگوریتم فراابتکاری GA، PSO، FA، CA، ICA و CMA-ES در بهبود توانایی مدل ANFIS برای مدل‌سازی پارامترهای کیفی آب زیرزمینی در یک منطقه خشک می‌باشد.

کرده‌اند. علی ضمیر و سبحان اردکانی (۲۰۱۷)، با هدف پیش-بینی آلودگی آرسنیک و فلزات سنگین (Zn و Pb، Cu) در منابع آب‌های زیرزمینی دشت قهاوند در استان همدان، از روش شبکه عصبی مصنوعی (ANN) بهینه شده توسط الگوریتم رقابت امپریالیستی (ICA) استفاده نمودند. نتایج نشان داد که این روش می‌تواند به‌طور مؤثری برای پیش‌بینی غلظت فلزات سنگین در منابع آب زیرزمینی دشت موردنظر استفاده شود. سموئی و همکاران (۲۰۱۸)، در پژوهشی جهت حل معکوس مسئله داری در آب زیرزمینی، پیشنهاد ترکیب یک الگوریتم و مدل اجزای محدود را دادند و از الگوریتم CMA-ES^۸ استفاده نمودند. نتایج نشان‌دهنده کارآمدی روش پیشنهادی جهت حل مسئله موردنظر بود. کارتراکیس و همکاران (۲۰۰۷)، به استفاده از الگوریتم DE در حل مسئله نفوذ آب شور در آبخوان ساحلی در یونان پرداختند و به نتایج قابل قبولی دست یافتند. همچنین از دیگر روش‌های مدل‌سازی عددی آب‌های زیرزمینی می‌توان به استفاده از مدل ARIMA در پژوهش‌های جانی (۱۳۹۸) و به کارگیری مدل‌سازی عددی توسط کرد و همکاران (۱۳۹۸) اشاره کرد.

به‌دلیل وجود برخی ضعف‌ها در روش‌های هوش مصنوعی و افزایش دقت آن‌ها، روش‌های ترکیبی پیشنهاد شد که علاوه بر افزایش دقت، در بسیاری از موارد با افزایش سرعت دست‌یابی به جواب نیز همراه است. عروجی و همکاران (۲۰۱۳)، برای مدل‌سازی کیفی آب رودخانه سپیدرود در ایستگاه آستانه، دو مدل ANFIS و الگوریتم ژنتیک را به‌کار گرفتند و شش ترکیب داده را به‌عنوان ورودی انتخاب نمودند. نتایج نشان داد الگوریتم ژنتیک انعطاف‌پذیری بیشتری نسبت به روش دیگر از خود نشان می‌دهد. جلال کمالی (۲۰۱۵)، با ترکیب مدل ANFIS با الگوریتم‌های GA و PSO، به شبیه‌سازی سه پارامتر EC، CI و pH در دشت کرمان پرداخت. با توجه به نتایج به‌دست آمده، هر دو روش دارای کارایی مناسبی در این زمینه بودند. طبری (۲۰۱۶)، توانایی مدل ترکیبی الگوریتم بهینه‌سازی جستجوی مستقیم و منطق فازی (FIS-DSOA) را برای پیش‌بینی رواناب

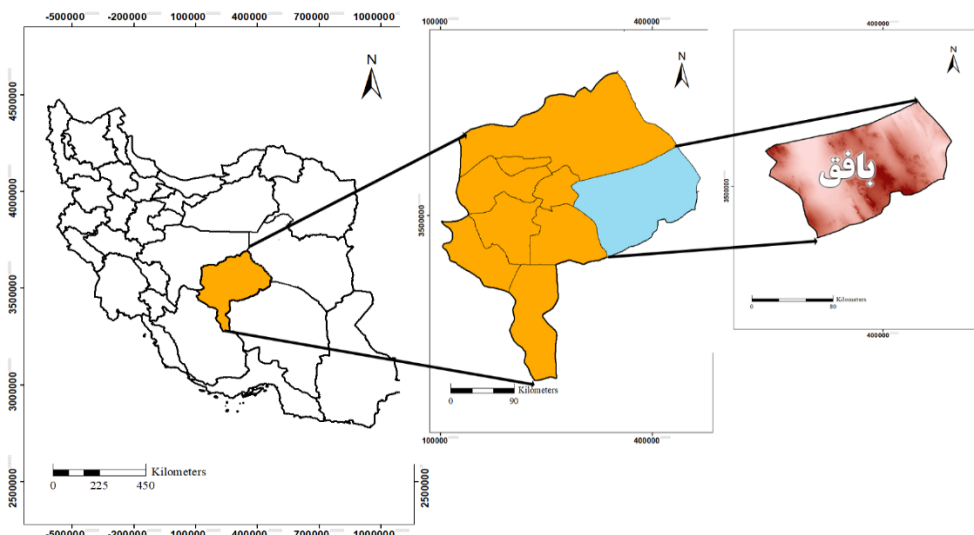
⁸ Covariance Matrix Adaptation Evolution Strategy

مواد و روش‌ها

منطقه مورد مطالعه

عرض شمالی است. ارتفاع این شهرستان از سطح دریا ۹۲۷ متر و دارای آب و هوای گرم و خشک می‌باشد. شیب عمومی دشت با توجه به روند تغییر ارتفاع کمتر از یک درصد بوده و با توجه به دامنه تغییرات کم آن، دشتی و مسطح را ایجاد کرده است. محدوده این منطقه در شکل ۱ نشان داده شده است.

بافق یکی از شهرستان‌های استان یزد است که در مرکز ایران و به فاصله ۱۲۰ کیلومتری از یزد قرار دارد. مختصات جغرافیایی بافق ۲۱° ۵۵' تا ۲۵° ۵۵' طول شرقی و ۳۱° ۳۴' تا ۳۱° ۳۸'



شکل ۱- منطقه مورد مطالعه.

قانون به مجموع درجه مشارکت همه قوانین را محاسبه می‌کند. در لایه چهارم با استفاده از پارامترهای نتیجه، خروجی هر گره محاسبه می‌شود و لایه پنجم نیز گره خروجی است که مقدار نهایی خروجی را به صورت مجموع خروجی گره‌های لایه قبل بیان می‌کند.

الگوریتم ژنتیک (GA)

الگوریتم ژنتیک که به عنوان یکی از روش‌های تصادفی بهینه‌یابی شناخته شده، توسط جان هالند در سال ۱۹۶۷ ابداع شد. بعدها این روش با تلاش‌های گلدبرگ در سال ۱۹۸۹، جایگاه خود را پیدا نمود و امروزه نیز به واسطه توانایی‌هایش، جای مناسبی در میان دیگر روش‌ها دارا می‌باشد. این الگوریتم معمولاً به عنوان یک شبیه‌ساز کامپیوتری که در آن جمعیت یک نمونه انتزاعی (کروموزوم‌ها) جهت رسیدن به مجموع جواب بهینه، پیاده‌سازی می‌شوند. فرضیه با جمعیتی کاملاً تصادفی و منحصر به فرد آغاز می‌شود و در نسل‌ها ادامه می‌یابد. در هر نسل، ظرفیت تمام

سیستم استنتاجی عصبی-فازی (ANFIS)

سیستم استنتاج فازی که توسط لطفی‌زاده (۱۹۶۵) ارائه شد، نگاشتی از فضای ورودی به خروجی است که با استفاده از توابع عضویت و قوانین فازی پیاده‌سازی می‌شوند. در ادامه، ژانگ با ارائه یک مدل تعلیمی، از الگوریتم شبکه عصبی مصنوعی و قوانین اگر-آنگاه فازی در قالب توابع عضویت به صورت ترکیبی، در تحلیل پدیده‌ها استفاده کرده است. مدل ANFIS از ساختار شبکه عصبی مصنوعی استفاده کرده و تحت عنوان سیستم استنتاجی عصبی-فازی شناخته می‌شود، به طوری که ضمن داشتن قابلیت یادگیری شبکه‌های عصبی و قدرت استنتاج فازی، توانایی نگاشت هرگونه مدل غیرخطی را نیز دارا می‌باشند. ANFIS شبکه‌ای پنج‌لایه است که لایه نخست، محل ورودی‌های مدل هستند. لایه دوم شامل گره‌های مربوط به قوانین است و از عملگرها برای محاسبه درجه مشارکت استفاده می‌شود. لایه سوم نیز شامل گره‌های نرمال شده است که نسبت درجه مشارکت هر

معمولاً بین ۰/۷ تا ۰/۹ در نظر گرفته می‌شود. تست همگرایی در این الگوریتم، مانند سایر الگوریتم‌های بهینه‌سازی است و می‌تواند تعداد تکرار معین یا رسیدن به یک دقت مشخص باشد. پارامترهای c1 و c2 که میزان اهمیت و وزن هوش جمعی و شخصی را مشخص می‌کنند، در اینجا ۱/۲ و ۱/۹ در نظر گرفته شدند. وزن w نیز ۰/۹۱ قرار داده شد.

الگوریتم فرهنگی (CA)

الگوریتم فراابتکاری فرهنگی (CA) یکی از جدیدترین الگوریتم‌های فراابتکاری است که بر اساس افکار و باورهای یک جامعه کار می‌کند. این الگوریتم که الهام گرفته شده از فرهنگ جوامع مختلف و نحوه بهبود و ارتقای آن است، امروزه در جهت بهینه‌سازی مسائل ریاضی به کار گرفته شده است. بخش‌های مختلف این الگوریتم عبارتند از: طبقه‌بندی^{۱۱}، الهام‌بخشی^{۱۲}، استعارگری^{۱۳} و استراتژی^{۱۴}. فضای باور یک الگوریتم فرهنگی، به بخش‌های مختلفی تقسیم می‌شود. این بخش‌ها نماینده حوزه‌های مختلف دانشی هستند که جمعیت از فضای جستجو دارد. فضای باور پس از هر تکرار توسط بهترین عضو جمعیت به روز می‌شود. این افراد را می‌توان با استفاده از یک تابع صلاحیت برگزید. این تابع، شبیه آنچه در الگوریتم‌های ژنتیک رخ می‌دهد، کارایی هر فرد در جمعیت را ارزیابی می‌کند.

مراحل کار الگوریتم که تا ایجاد نسل مورد نظر و محقق شدن شرایط ادامه می‌ابند، عبارتند از: ۱- مقداردهی اولیه فضای جمعیت (جمعیت اولیه)، ۲- مقداردهی اولیه فضای باور (تعیین محدوده ارزش‌ها)، ۳- ارزیابی فعالیت‌های افراد در فضای جمعیت، ۴- ارزیابی هر فرد با تابع صلاحیت، ۵- انتخاب والدین مناسب جهت زاد و ولد، ۶- اجازه دادن به فضای باور برای تغییر ژنوم نسل جدید با استفاده از تابع اثرگذاری، ۷- به روز رسانی فضای باور برای مدل‌سازی، نسبت پذیرش ۰/۳ و مقادیر آلفا و بتا به ترتیب ۰/۳ و ۰/۵ قرار داده شدند.

جمعیت ارزیابی و چندین فرد منحصر در فرآیندی تصادفی از نسل جاری انتخاب می‌شوند (بر اساس شایستگی‌ها) که برای شکل دادن نسل جدید، اصلاح می‌شوند (کسر یا دوباره ترکیب می‌شوند) و در تکرار بعدی الگوریتم به نسل جاری تبدیل می‌شود. این فرآیند تا زمانی که بهترین عضو جامعه به اندازه کافی مناسب باشد ادامه می‌یابد. پس از اعمال سعی و خطا به منظور دستیابی به دقت بالاتر، اعداد درصد همگذری^۹ و جهش^{۱۰} به ترتیب ۰/۷ و ۰/۴ برای این مطالعه انتخاب شدند.

الگوریتم ازدحام ذرات (PSO)

الگوریتم PSO در سال ۱۹۹۵ به عنوان یک روش جستجوی غیرقطعی برای بهینه‌سازی تابع، مطرح گشت. این الگوریتم از حرکت دسته جمعی پرندگان که به دنبال غذا می‌باشند، الهام گرفته شده است. گروهی از پرندگان در یک فضای جستجو به دنبال غذا می‌گردند. این گروه از ذرات که در آغاز کار به صورت تصادفی به وجود می‌آیند، با به روز کردن نسل‌ها، سعی در یافتن راه‌حل بهینه می‌نمایند. در هر گام، هر ذره با استفاده از دو بهترین مقدار به روز می‌شود. اولین مورد، بهترین موقعیتی است که تاکنون ذره موفق به رسیدن به آن شده است. موقعیت مذکور شناخته و نگهداری می‌شود که این بهترین مقدار شخصی آن ذره نیز گفته می‌شود که آن را با pbest نمایش می‌دهند. بهترین مقدار دیگری که توسط الگوریتم مورد استفاده قرار می‌گیرد، بهترین موقعیتی است که تا کنون توسط جمعیت ذرات به دست آمده است که آن را gbest گویند (هوش جمعی). پس از یافتن بهترین مقادیر، سرعت و مکان هر ذره با استفاده از رابطه ۱ و ۲ به روز می‌شود دارد (جلال کمالی، ۲۰۱۵).

$$V(t+1) = w \times v(t) + c1 \times \text{rand}(t) - \text{position}(t) + c2 \times \text{and}(t) \times (\text{Gbest}(t) - \text{position}(t)) \quad (1)$$

$$\text{Position}(t+1) = \text{position}(t) + v(t+1) \quad (2)$$

که $v(t)$ سرعت فعلی ذره و $c1 \times \text{rand}(t) - \text{position}(t)$ و $c2 \times \text{and}(t) \times (\text{Gbest}(t) - \text{position}(t))$ میزان تغییر سرعت ذره و جهت آن می‌باشند. W نیز ضریبی است که با توجه به مسئله

¹² Inspiration

¹³ Metaphor

¹⁴ Strategy

⁹ Crossover Percentage

¹⁰ Mutation Percentage

¹¹ Taxonomy

الگوریتم رقابت استعماری (ICA)

کوچک در نظر گرفتن باعث می‌شود که هزینه کل یک امپراتوری، تقریباً برابر با هزینه حکومت مرکزی آن (کشور استعمارگر) شود.

ممکن است در روند حرکت کشورها در طول اجرای الگوریتم، یک کشور مستعمره قدرت بیشتری از استعمارگر نظیر خود پیدا کند. در این حالت، جای کشور مستعمره و استعمارگر عوض خواهد شد. در هر مرحله از تکرار الگوریتم، میان استعمارگران رقابتی برقرار است. در این رقابت، استعمارگری که نسبت به دیگر استعمارگران قدرت کمتری دارد، یکی از مستعمرات خود را از دست می‌دهد. در این فرآیند، ضعیف‌ترین مستعمره از ضعیف‌ترین استعمارگر به‌طور تصادفی به یکی از استعمارگران دیگر ملحق می‌شود. اگر استعمارگری تمام مستعمرات خود را از دست بدهد، خود به‌صورت مستعمره یک استعمارگر دیگر در خواهد آمد. مراحل الگوریتم به همین ترتیب ادامه می‌یابد تا بالاخره تعداد استعمارگران به یک برسد. در این حالت تمام کشورها، مستعمره یک استعمارگر هستند و الگوریتم به پایان می‌رسد. البته شرایط توقف دیگری مانند تعداد تکراری معین نیز، می‌تواند به کار رود. پارامترهای نرخ انقلاب، ضریب جذب، گاما و زتا به ترتیب ۰/۴، ۰/۵، ۰/۵ و ۰/۰۸ قرار داده شد.

الگوریتم کرم شب تاب (FA)

الگوریتم بهینه‌سازی کرم شب تاب (FA)، از رفتار کرم‌های شب تاب که در مجموعه‌ها بزرگ در کنار هم زندگی می‌کنند الهام گرفته شده است و یکی از الگوریتم‌های بسیار کارآمد در حل مسائل بهینه‌سازی ترکیبی است. این الگوریتم در اواخر سال ۲۰۰۷ و توسط ژین‌شی یانگ معرفی شد که ایده اصلی آن از ارتباط نوری میان کرم‌های شب تاب الهام گرفته شده است. همه کرم شب تاب‌ها تمایل جنسی دارند، به طوری که یک کرم شب تاب تمام کرم شب تاب‌های دیگر را جذب می‌کند و این قدرت جذب، به میزان نوری که می‌تواند تولید کند بستگی دارد، یعنی اگر کرم شب تاب‌ی روشن‌تر از کرم شب تاب دیگر وجود داشته باشد، آن را به‌طور تصادفی حرکت خواهد داد.

دو مرحله اصلی الگوریتم در هر تکرار، فاز به روز کردن رنگدانه و فاز حرکت است. کرم‌های شب تاب به سمت کرم‌های شب تاب

الگوریتم رقابت استعماری (ICA) اولین بار توسط آتشپزگرگری (۱۳۸۷) معرفی شد که در آن برخلاف اکثر الگوریتم‌ها، به جای طبیعت، از یک پدیده اجتماعی سیاسی الهام گرفته شده است. در این الگوریتم، مشابه با افراد در الگوریتم ژنتیک، تعدادی کشور در نظر گرفته می‌شود که نقاطی تصادفی درون فضای جستجو هستند. به این ترتیب، کشورهای قدرتمند به‌منزله استعمارگر و کشورهای ضعیف به‌منزله مستعمره قرار می‌گیرند. الگوریتم با ایجاد تعداد N کشور اولیه و قرار دادن N_{Imp} تا از بهترین‌های آن‌ها (که دارای کمترین مقدار تابع هزینه هستند) به‌عنوان استعمارگر و همچنین باقیمانده کشورها (N_{Col}) به‌عنوان مستعمره، آغاز می‌شود و مستعمرات را بین استعمارگران تقسیم می‌نماید. برای تقسیم مستعمرات اولیه بین استعمارگرها، به هر استعمارگر، تعدادی مستعمره متناسب با قدرت آن، اختصاص داده می‌شود که با استفاده از رابطه ۳ این قدرت که همان کمتر بودن هزینه بهنجارش است به دست می‌آید (آتشپزگرگری، ۱۳۸۷):

$$C_n = \max_i \{C_i\} - C_n \quad (3)$$

که C_n ، هزینه استعمارگر $\ln \max_i \{C_i\}$ بیشترین هزینه میان استعمارگرها و C_n ، هزینه بهنجارشده این استعمارگر می‌باشد. هر استعمارگری که دارای هزینه بیشتری باشد (استعمارگر ضعیف‌تری باشد)، دارای هزینه بهنجارش کمتری خواهد بود. کشورهای استعمارگر با اعمال سیاست جذب (همگون‌سازی) در راستای محورهای خاصی، کشورهای مستعمره را به سمت خود می‌کشند. حرکت کشور مستعمره به سمت کشور استعمارگر به اندازه x و با انحراف زاویه‌ای θ صورت می‌گیرد که به‌صورت تصادفی تعیین می‌شوند. قدرت یک امپراتوری برابر است با قدرت کشور استعمارگر، به‌اضافه درصدی از قدرت کل مستعمرات آن. بدین ترتیب برای محاسبه هزینه کل یک امپراتوری از رابطه ۴ استفاده می‌شود (آتشپزگرگری، ۱۳۸۷):

$$TC_n = Cost(imperialist_n) + \frac{1}{n} \text{mean}\{Cost(colonies\ of\ empire_n)\} \quad (4)$$

که TC_n هزینه کل امپراتوری \ln م و n عددی مثبت است که معمولاً بین صفر و یک و نزدیک به صفر در نظر گرفته می‌شود.

به هر کرم شب‌تاب i یک همسایگی تخصیص می‌یابد که برد شعاعی rid آن به‌طور طبیعی دینامیک است. $(0 < rid \leq rs)$. از آنجا که اطلاعات از پیش‌دانسته درباره تابع هدف (به‌عنوان مثال تعداد قله‌ها و یا فاصله بین قله‌ها) برای مسئله فرض نمی‌شود به سادگی نمی‌توان برد همسایگی ثابتی مناسب برای تمامی تابع‌های هدف در نظر گرفت. در اینجا ضریب جذب نور برابر ۱ و ضریب جهش برابر $0/2$ در نظر گرفته شدند.

الگوریتم استراتژی تکامل انطباق ماتریس کواریانس^{۱۵} (CMA-ES)

این الگوریتم از جمله الگوریتم‌های تکاملی شناخته شده بهینه‌سازی است که از یک توزیع نرمال، نمونه‌گیری کرده و جمعیت جدید را به‌وجود می‌آورد. سپس یک ماتریس کواریانس و یک بردار میانگین را از جمعیت، تخمین زده و طبق قوانین مختلف به روزرسانی، ماتریس کواریانس تطبیق یافته‌ای را در هر نسل ایجاد می‌کند که در کیفیت جمعیت جدید و در نتیجه هدایت تکامل، نقش مهمی دارد. بنابراین چگونگی به‌روزرسانی این ماتریس حائز اهمیت است. از سوی دیگر، ماتریس پراکندگی غیرپارامتری که از روش طبقه‌بندی فیشر به‌دست می‌آید، در جمعیت، الگویی از افراد با عملکرد بالا و پایین ایجاد می‌کند. سپس از هر گروه به k نزدیکترین همسایه آن برداری می‌کشد. این بردارها جهت را نشان می‌دهند که افراد از عملکرد نامناسب به سمت عملکرد مناسب سوق داده شده‌اند و بنابراین این جهت می‌تواند در هدایت بهتر جمعیت به سوی هدف بهینه مفید باشد. در طول فرآیند این مطالعه، هر یک از الگوریتم‌های ذکر شده با مدل ANFIS ترکیب شده، به‌نحوی که وظیفه این الگوریتم‌ها تنظیم بهینه وزن‌های گره‌ها براساس نمایه‌های معرفی شده است تا دقت مدل‌سازی افزایش یابد. مراحل این کار در شکل ۲ قابل مشاهده است.

دیگر با رنگدانه بیشتر که در همسایگی آنها باشند حرکت می‌کنند. به این ترتیب طی تکرارهای متوالی مجموعه به سمت جواب بهتر متمایل می‌گردد. از آنجایی که جذابیت یک کرم شب‌تاب با شدت نور دیده شده توسط کرم‌های مجاور آن متناسب است، می‌توان جذابیت β را به صورت رابطه ۵ تعریف نمود (یانگ و همکاران، ۲۰۱۲):

$$\beta = \beta_0 e^{-\gamma r^2} \quad (5)$$

که در آن β_0 جذابیت اولیه و ثابت γ ضریب جذب نور، r فاصله منبع نور است.

در ابتدا همه کرم‌ها مقدار یکسانی از لوسی‌فرین (ماده تولید کننده نور) به اندازه L در اختیار دارند. هر تکرار الگوریتم شامل یک فاز به روز کردن لوسی‌فرین و یک فاز به روز کردن مکان کرم‌ها می‌باشد. برای به روز کردن لوسی‌فرین از رابطه ۶ استفاده می‌شود (یانگ و همکاران، ۲۰۱۲).

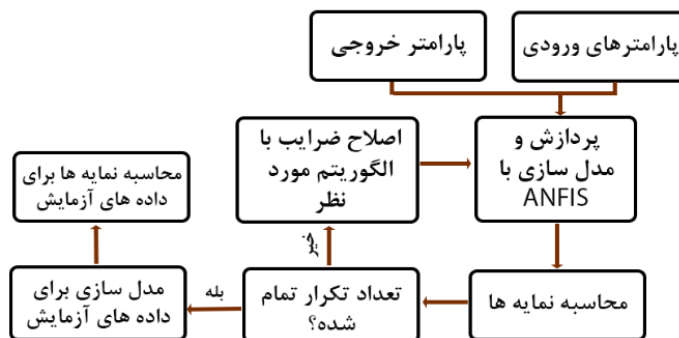
$$l_i = (1-p)l_i(t-1) + \gamma J(x_i(t)) \quad (6)$$

که در آن l_i ، $l_i(t-1)$ و $J(x_i(t))$ به ترتیب مقدار جدید لوسی‌فرین، مقدار قبلی لوسی‌فرین و برازندگی مکان کرم i در تکرار t از الگوریتم بوده و p و γ اعداد ثابتی برای مدل کردن افت تدریجی و تأثیر برازندگی بر لوسی‌فرین می‌باشند. در خلال فاز حرکت، هر کرم به صورت احتمالی به سمت یکی از همسایگانش که لوسی‌فرین بالاتری دارد حرکت می‌کند. به این ترتیب کرم‌ها به سمت همسایگان با درخشندگی بیشتر حرکت می‌کنند. با فرض انتخاب شدن کرم شب‌تاب z توسط کرم شب‌تاب i با احتمال p ، معادله حرکت زمان-گسسته کرم شب‌تاب را می‌توان به‌صورت رابطه ۷ نوشت (یانگ و همکاران، ۲۰۱۲).

$$x_i(t+1) = x_i(t) + s \times \left(\frac{x_j(t) - x_i(t)}{\|x_j(t) - x_i(t)\|} \right) \quad (7)$$

که در آن $x_i(t)$ بردار m بعدی مکان کرم شب‌تاب i در زمان t است، $\| \cdot \|$ عملگر نرم اقلیدسی را نشان می‌دهد و s اندازه گام حرکت است.

¹⁵ Covariance Matrix Adaptation Evolution Strategy



شکل ۲- فلوچارت مراحل مدل سازی روش های ترکیبی.

نتایج و بحث

در این مطالعه، کیفیت آب زیرزمینی شهرستان بافق مورد توجه قرار گرفته است. مدل سازی متغیرهای کیفیت آب بر روی سه پارامتر مهم از جمله هدایت الکتریکی (EC)، نسبت جذب سدیم (SAR) و سختی کل (TH) انجام پذیرفت. برای انتخاب داده های ورودی جهت تخمین هریک از سه متغیر مورد نظر، همبستگی بین پارامترهای Ca، Mg، pH، Cation، Anion، TDS، K، Na، SO₄، Cl و HCO₃ با آن پارامتر در نرم افزار SPSS و با روش های پیرسون و اسپیرمن سنجیده شد و داده های با همبستگی بالای ۹۵ در یکی از دو روش، با خروجی مذکور انتخاب گردید که در جدول ۱ آورده شده است. این پارامترها عبارتند از: سولفات (SO₄، mg L⁻¹)، کلرید (Cl، mg L⁻¹)، بی کربنات (HCO₃، mg L⁻¹)، پتاسیم (K، mg L⁻¹)، سدیم (Na، mg L⁻¹)، منیزیم (Mg، mg L⁻¹)، کلسیم (Ca، mg L⁻¹)، آنیون (Anion، meq L⁻¹) و کاتیون (Cation، meq L⁻¹). که از این میان، تنها بی-کربنات و پتاسیم به دلیل عدم همبستگی مناسب با هیچکدام از پارامترهای خروجی مورنظر، کنار گذاشته شدند. بنابراین برای TH از ورودی های Ca، Mg، Cation و Anion، برای SAR از ورودی های Cl و Na و برای EC از ورودی های Cl، SO₄، Na، Cation و Anion استفاده گردید. آمار پایه این متغیرهای ورودی و سه متغیر وابسته (EC، SAR و TH) در جدول ۲ نشان داده شده است.

برای یکسان سازی شرایط جهت مدل سازی، تعداد جمعیت اولیه در همه الگوریتم ها ۱۰۰ و تعداد تکرار ۵۰۰ در نظر گرفته شد. همچنین در هر مرحله، ۷۵٪ از داده ها به عنوان داده های آموزش و ۲۵٪ به عنوان داده های صحت سنجی استفاده گردید. نمایه های مورد استفاده در این پژوهش جهت بررسی عملکرد مدل ها، ضریب همبستگی (R²)، خطای جذر میانگین مربعات (RMSE) و ضریب نش-ساتکلیف (NSE) هستند که نحوه محاسبه آنها در روابط ۸ تا ۱۰ آورده شده است.

$$R^2 = \frac{[\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})]^2}{[\sum_{i=1}^n (X_i - \bar{X})^2 (Y_i - \bar{Y})^2]} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{N}} \quad (9)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n (X_i - \bar{X}_i)^2} \quad (10)$$

در این روابط، X_i و Y_i مقادیر مشاهداتی و محاسباتی می باشند و N تعداد داده ها است.

داده های استفاده شده در این پژوهش، شامل ۱۶ سری داده برداشت شده از ۳۱ چاه عمیق و قنات بین سال های ۱۳۸۱ تا ۱۳۹۶ در دشت بافق می باشد که از سازمان آب منطقه ای اخذ شده اند. در ادامه ضمن حذف داده های پرت، داده های گمشده نیز به وسیله درون یابی اصلاح و در نهایت ۶۷۵ داده برای هر پارامتر در مدل سازی ها به کار گرفته شد.

جدول ۱- همبستگی بین پارامترهای ورودی و خروجی.

	Anion	Cation	pH	TDS	K	Na	Mg	Ca	SO ₄	Cl	HCO ₃
TH (Pierson)	۰/۹۵	۰/۹۵	-۰/۳۷	۰/۹۰	۰/۶۸	۰/۹۰	۰/۹۷	۰/۹۸	۰/۹۰	۰/۹۴	-۰/۳۸
TH (Spearman)	۰/۹۴	۰/۹۴	-۰/۳۷	۰/۸۸	۰/۶۵	۰/۸۷	۰/۹۷	۰/۹۸	۰/۹۴	۰/۸۹	-۰/۴۶
SAR (Pierson)	۰/۹۳	۰/۹۳	-۰/۲۷	۰/۸۸	۰/۷۸	۰/۹۶	۰/۷۹	۰/۷۸	۰/۸۷	۰/۹۲	-۰/۵۱
SAR (Spearman)	۰/۹۳	۰/۹۳	-۰/۲۶	۰/۸۶	۰/۷۵	۰/۹۸	۰/۷۸	۰/۷۶	۰/۸۶	۰/۹۵	-۰/۶۲
EC (Pierson)	۰/۹۹	۰/۹۹	-۰/۳۳	۰/۹۴	۰/۷۶	۰/۹۹	۰/۹۲	۰/۹۳	۰/۹۲	۰/۹۹	-۰/۴۵
EC (Spearman)	۰/۹۹	۰/۹۹	-۰/۳۱	۰/۹۳	۰/۷۳	۰/۹۸	۰/۹۳	۰/۹۲	۰/۹۶	۰/۹۸	-۰/۵۸

جدول ۲- آمار پایه پارامترهای اندازه گیری شده آب زیرزمینی.

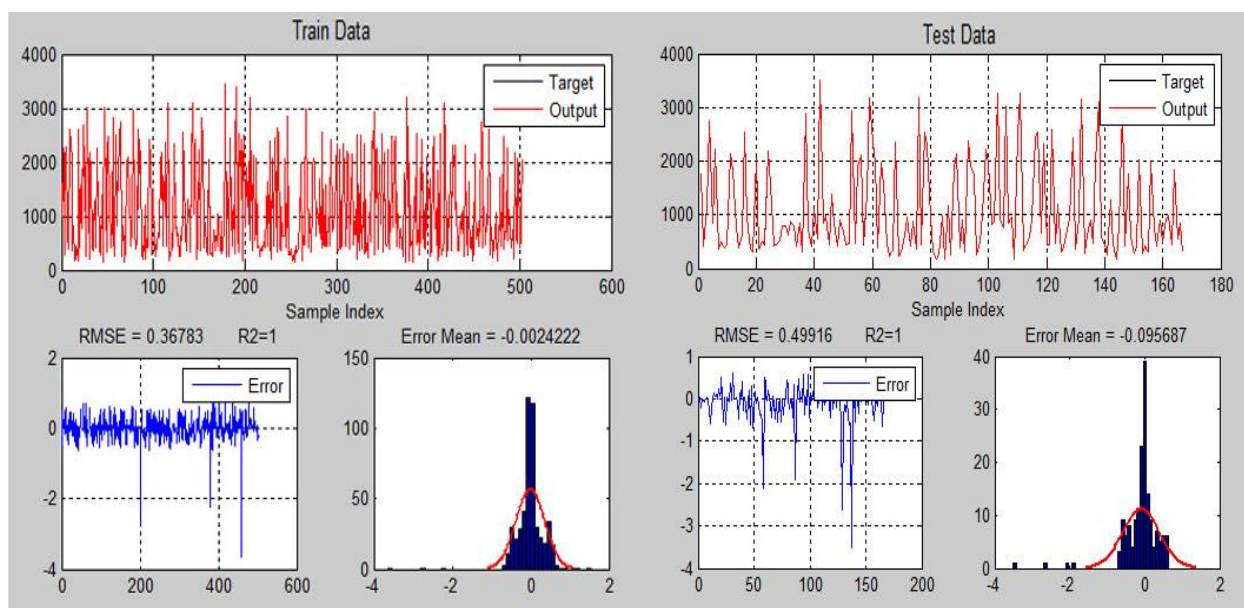
	واحد	کمینه	بیشینه	میانگین	انحراف معیار	ضریب تغییرات
TH	mg L ⁻¹	۱۴۳	۳۷۶۷	۱۱۰۷/۹	۸۵۳/۸۴	۰/۷۷
SAR	-	۰/۶۱	۳۱/۹۳	۱۰/۴۲	۷/۸۳	۰/۷۵
EC	μmho cm-1	۴۱۵	۱۸۰۴۵	۵۹۶۸/۹۱	۵۳۸۴/۶۲	۰/۹
Anion	meq L ⁻¹	۴/۳۱	۲۰۵/۷۸	۶۲/۴۲	۵۶/۷۱	۰/۹
Cation	meq L ⁻¹	۴/۰۷	۱۹۰/۸۷	۶۲/۲۲	۵۶/۵۴	۰/۹
Na	mg L ⁻¹	۰/۸۷	۱۴۶/۱۵	۴۰	۴۰/۵۴	۱/۰۱
Mg	mg L ⁻¹	۱/۳۴	۴۲/۶۱	۱۰/۸۷	۸/۴۵	۰/۷۷
Ca	mg L ⁻¹	۱/۰۴	۴۶/۳	۱۱/۲۴	۸/۹۳	۰/۷۹
SO ₄	mg L ⁻¹	۰/۱۵	۵۷/۲۶	۱۹/۵۷	۱۴/۳۵	۰/۷۳
Cl	mg L ⁻¹	۱/۰۷	۱۴۵/۲۳	۳۹/۲۱	۴۳/۷۷	۱/۱۱

جدول ۳- مقدار نمایه‌های عملکرد روش‌های ترکیبی مورد استفاده در برآورد TH، SAR و EC.

مدل	پارامتر	R ²		RMSE		NSE	
		آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش
ANFIS-GA	TH	۱	۰/۹۸	۰/۳۸	۰/۴۴	۰/۹۹	۰/۹۹
ANFIS-PSO	TH	۱	۱	۰/۴۹	۰/۳۶	۰/۹۹	۰/۹۹
ANFIS-FA	TH	۰/۹۸	۰/۹۹	۰/۳۴	۰/۴۱	۰/۹۹	۰/۹۹
ANFIS-CA	TH	۱	۱	۰/۴۵	۱/۳۷	۰/۹۹	۰/۹۹
ANFIS-ICA	TH	۰/۹۹	۱	۲/۳	۱/۸۲	۰/۹۹	۰/۹۹
ANFIS-CMA-ES	TH	۱	۰/۹۹	۱/۸۷	۲/۱۷	۰/۹۹	۰/۹۹
ANFIS-GA	SAR	۰/۹۷	۰/۹۷	۱/۲۴	۱/۳۷	۰/۹۶	۰/۹۷
ANFIS-PSO	SAR	۰/۹۵	۰/۹۷	۱/۷	۱/۱۱	۰/۹۷	۰/۹۵
ANFIS-FA	SAR	۰/۹۵	۰/۹۸	۱/۶۹	۱/۱۱	۰/۹۷	۰/۹۵
ANFIS-CA	SAR	۰/۹۲	۰/۹۷	۱/۹۴	۱/۳۴	۰/۹۷	۰/۹۳
ANFIS-ICA	SAR	۰/۹۷	۰/۹۷	۱/۱۱	۱/۳۶	۰/۹۷	۰/۹۷
ANFIS-CMA-ES	SAR	۰/۹۶	۰/۹۷	۱/۳۶	۱/۳۸	۰/۹۶	۰/۹۶
ANFIS-GA	EC	۰/۹۹	۰/۹۹	۲۸۰/۸	۳۱۸/۹	۰/۹۹	۰/۹۹
ANFIS-PSO	EC	۰/۹۹	۰/۹۹	۲۷۳/۵	۲۹۵/۴	۰/۹۹	۰/۹۹
ANFIS-FA	EC	۰/۹۹	۰/۹۹	۲۵۸/۲	۳۰۵/۷	۰/۹۹	۰/۹۹
ANFIS-CA	EC	۰/۹۹	۰/۹۹	۳۰۴/۴	۲۶۷/۲	۰/۹۹	۰/۹۹
ANFIS-ICA	EC	۰/۹۹	۰/۹۹	۲۹۲/۳	۲۷۶/۳	۰/۹۹	۰/۹۹
ANFIS-CMA-ES	EC	۰/۹۹	۰/۹۹	۲۷۴/۹	۳۳۸/۶	۰/۹۹	۰/۹۹

$R^2=1$ هستند که نشان‌دهنده همبستگی بسیار خوب بین داده‌های محاسباتی و مشاهداتی دارد. البته این نمایه در بخش آزمایش نیز، تنها برای مدل‌های ANFIS-GA و ANFIS-FA مقدار ۱ را به دست نیاورد. با توجه به مقادیر مشابه NSE برای همه مدل‌ها، نمایه RMSE می‌تواند ملاک بهتری برای انتخاب مدل بهتر باشد، به نحوی که در بخش آموزش، مدل‌های ANFIS-GA و ANFIS-FA دارای کمترین میزان RMSE هستند و در بخش آزمایش مدل ANFIS-PSO مناسب‌ترین مقدار را داراست. در کل هرچند تمامی مدل‌ها در مدل‌سازی TH توانایی بالایی را نشان دادند ولی می‌توان مدل ANFIS-PSO را مورد مناسب‌تر این بخش برشمرد. خروجی این مدل در دو بخش آموزش و آزمایش در شکل ۳ نمایش داده شده است.

بر طبق اعداد جدول (۲) که براساس حدود ۶۷۵ داده مورد بررسی به دست آمده است، میانگین EC آب بیش از مقدار مناسب ($3000 \mu\text{mho/cm}$) بوده و در دسته آب شور جای می‌گیرد. اما از لحاظ SAR در حد مجاز و استاندارد می‌باشد. سایر پارامترها نیز در محدوده مجاز براساس شاخص WHO می‌باشند. پس از انجام مدل‌سازی و محاسبه نمایه‌های مورد نظر در دو بخش آموزش و آزمایش، نتایج در جدول ۳ آورده شد. بر این اساس، در مدل‌سازی سختی کل (TH) که بیشتر به خاطر وجود کلسیم و منیزیم است، براساس میزان همبستگی محاسبه شده از جدول (۱)، داده‌های آنیون، کاتیون، منیزیم و کلسیم جهت ورودی مدل‌ها به منظور مدل‌سازی TH استفاده شدند. براساس نتایج به دست آمده در جدول (۳)، در بخش آموزش، تمامی مدل‌ها به جز ANFIS-FA و ANFIS-ICA دارای مقدار



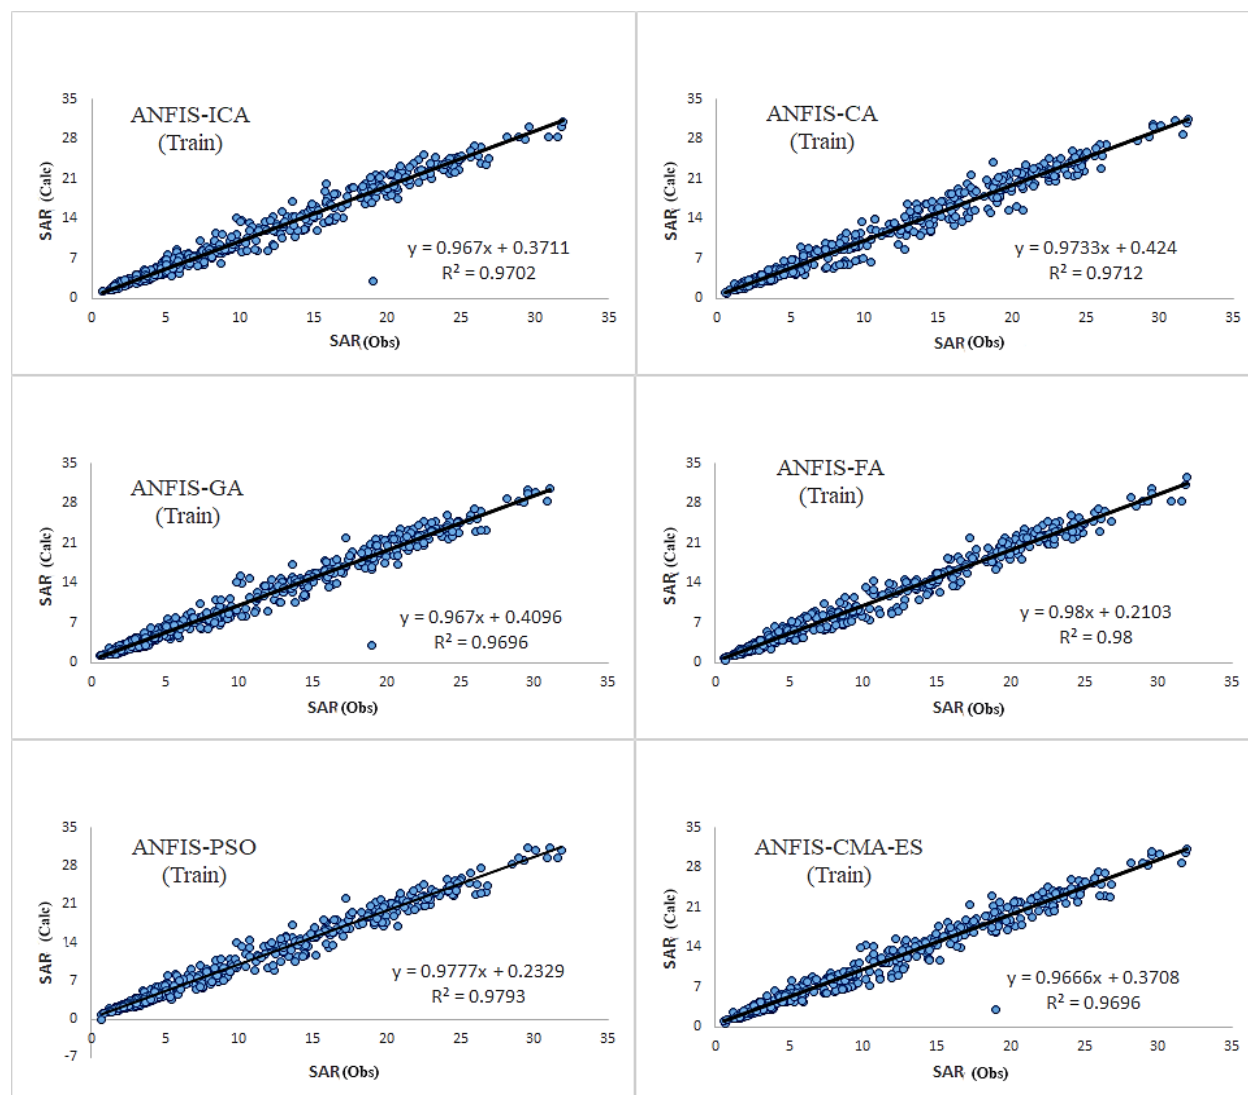
شکل ۳ - خروجی مدل ANFIS-PSO برای پارامتر TH.

$R^2=0.97$ و $RMSE=1/11$ و $NSE=0.97$ قوی‌ترین مدل در بخش آموزش شناخته شد. پس از آن، مدل‌های ANFIS-GA و ANFIS-CMA-ES قرار گرفتند. نمودارهای این مدل‌ها در شکل ۴ آورده شده است. در بخش آزمایش نیز مدل ANFIS-FA بهترین عملکرد را از خود نشان داد. در مجموع مدل ANFIS-

برای محاسبه SAR، پارامترهای Na و Cl با توجه به همبستگی بالای ۹۵٪ به عنوان ورودی انتخاب شدند. هرچند برخی پارامترهای دیگر همچون منیزیم و کلسیم نیز بر SAR مؤثرند ولی با توجه به مقدار نه‌چندان بالای همبستگی آن‌ها در داده‌های مورد استفاده این مطالعه، از به‌کارگیری آنها صرف‌نظر شد. بنابراین با توجه به شرایط ذکر شده، مدل ANFIS-GA با داشتن

ICA بهترین مدل این مطالعه برای مدل سازی SAR معرفی می شود که مقادیر خروجی آن در شکل ۵ قابل مشاهده است. در بخش مدل سازی برای پارامتر EC، از پنج پارامتر آنیون، کاتیون، سدیم، کلرید و سولفات استفاده شد. واحد داده های استفاده شده برای EC، $\mu\text{mho Cm}^{-1}$ است، بنابراین واحد RMSE های محاسبه شده نیز بر پایه همین واحد بیان می گردد. با توجه به مقدار مساوی R^2 و NSE به دست آمده برای همه مدل ها، بر این اساس، مدل ANFIS-FA با مقادیر

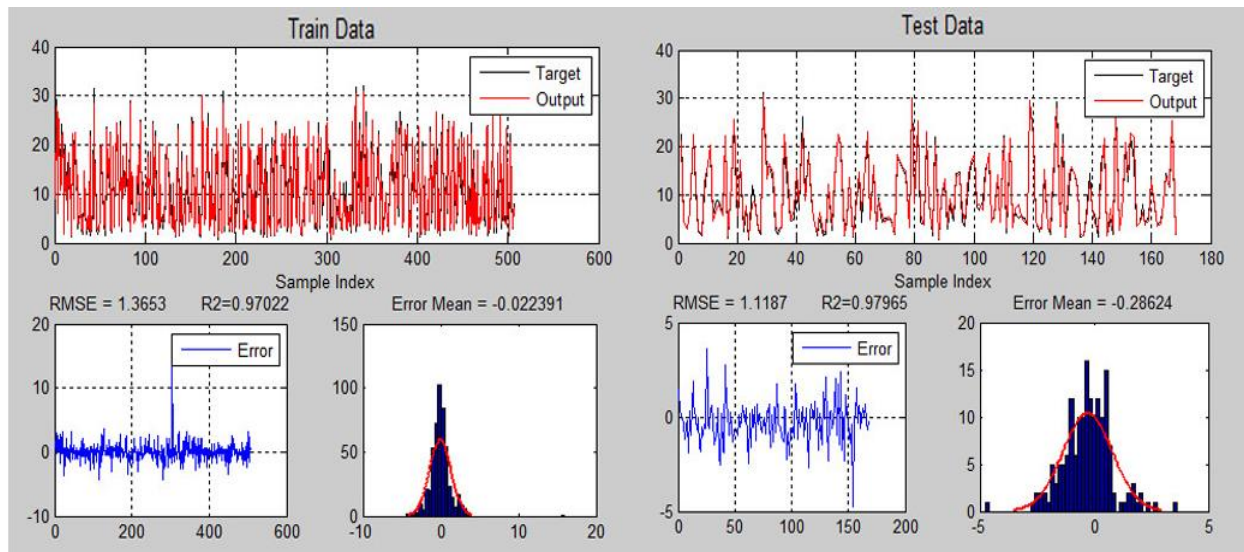
بهترین مدل این مطالعه برای مدل سازی SAR معرفی می شود که مقادیر خروجی آن در شکل ۵ قابل مشاهده است. در بخش مدل سازی برای پارامتر EC، از پنج پارامتر آنیون، کاتیون، سدیم، کلرید و سولفات استفاده شد. واحد داده های استفاده شده برای EC، $\mu\text{mho Cm}^{-1}$ است، بنابراین واحد RMSE های محاسبه شده نیز بر پایه همین واحد بیان می گردد. با توجه به مقدار مساوی R^2 و NSE به دست آمده برای همه مدل ها، بر این اساس، مدل ANFIS-FA با مقادیر



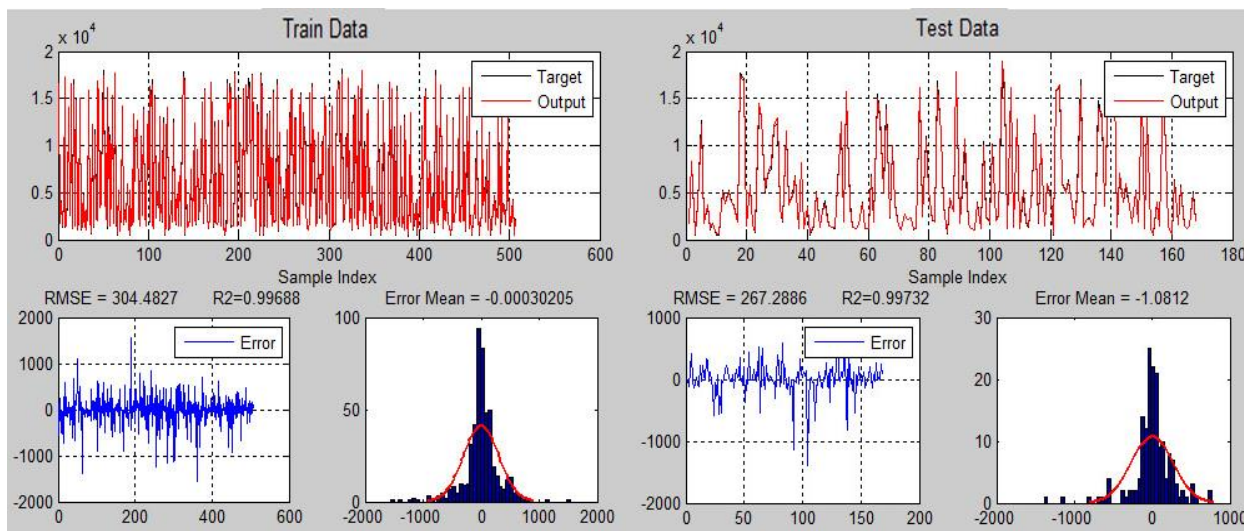
شکل ۴- نمودارهای همبستگی شش روش ترکیبی مورد نظر در مدل سازی SAR.

می‌توان مدل ANFIS-PSO را سریعترین مدل این استفاده شده در این پژوهش برشمرد و پس از آن به ترتیب مدل‌های ANFIS-CA، ANFIS-GA، ANFIS-CMA-ES و ANFIS-ICA دارای سرعت بالاتر هستند. اما مدل ANFIS-FA نسبت به سایر مدل‌ها چند برابر کندتر عمل کرده و این موضوع را می‌توان نقطه ضعف آن دانست.

البته لازم به ذکر است که نتایج بهتر تمامی مدل‌های ترکیبی ذکر شده ممکن است با تغییر شرایط جستجو و پارامترهای الگوریتم و همچنین گیر نکردن در بهینه‌های محلی امکان پذیر باشد. از آنجایی که زمان اجرای یک مدل، می‌تواند در انتخاب یا عدم انتخاب آن روش دارای اهمیت باشد، مدل‌های بررسی شده در این مطالعه بر اساس زمان نیز رتبه بندی می‌شوند. بر این اساس،



شکل ۵ - خروجی مدل ANFIS-ICA برای پارامتر SAR.



شکل ۶ - خروجی مدل ANFIS-CA برای پارامتر EC.

نتیجه گیری

در این پژوهش، از شش الگوریتم هوشمند ICA, GA, PSO, CMA-ES و FA, CA برای افزایش قابلیت مدل ANFIS جهت مدل سازی و ارزیابی سه پارامتر آب زیرزمینی EC, SAR و TH در شهرستان بافق استفاده شد. با توجه به نتایج نمایه های مورد استفاده، دقت پیش بینی متغیرهای ذکر شده با هر شش روش ترکیبی مناسب می باشد. نتایج نشان داد که مدل ANFIS-FA در هر سه دسته مدل سازی جزو بهترین مدل ها به شمار می رود و می تواند به عنوان مدل برگزیده در این پژوهش معرفی گردد، به طوری که مقدار R^2 ، RMSE و NSE آن به ترتیب برای بخش آزمایش TH، ۰/۹۹، ۰/۴۱ و ۰/۹۹، برای SAR، ۰/۹۸ و ۱/۱۱ و ۰/۹۵ و برای EC، ۰/۹۹، ۰/۵۷/۳ و ۰/۹۹ به دست آمد. هر چند سرعت اجرای مدل نسبت به سایر مدل ها بسیار پایین تر بود. به طور کلی می توان نتیجه گرفت که مدل های ترکیبی الگوریتم های مختلف با مدل ANFIS می تواند به عنوان ابزاری موثر برای محاسبه و پیش بینی متغیرهای کیفی آب زیرزمینی مورد استفاده قرار گیرد.

منابع

- آتشپز گرگری، ا.، ۱۳۸۷. توسعه الگوریتم بهینه سازی اجتماعی و بررسی کارایی آن. پایان نامه کارشناسی ارشد، دانشکده مهندسی برق، دانشگاه تهران.
- آقدر، ح. محمدیاری، ف.، ۱۳۹۴. مدل سازی پارامتر کیفی TH در آب زیرزمینی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت مهران و دهلران). سومین همایش سراسری محیط زیست، انرژی و پدافند زیستی، تهران، موسسه آموزش عالی مهر اروند، گروه ترویجی دوستداران محیط زیست.
- جانی، ر.، ۱۳۹۸. مدل سازی خوشه ای تراز آب زیرزمینی دشت تبریز با استفاده از مدل آریمما. هیدروژئولوژی، جلد ۴، شماره ۲، ۷۴-۹۱.
- کرد، م.، اصغری مقدم، ا.، نخعی، م.، ۱۳۹۸. مدل سازی عددی آبخوان دشت اردبیل و مدیریت آن با استفاده از بهینه سازی برداشت آب زیرزمینی. هیدروژئولوژی، جلد ۴، شماره ۱، ۱۵۳-۱۶۷.
- میرسنجری، م. م.، محمدیاری، ف.، بصیری، ر. حمیدی پور، ف.، ۱۳۹۶. مدل سازی پارامترهای کیفی EC، SAR و TDS در آب زیرزمینی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت مهران و دهلران). انسان و محیط زیست، جلد ۱۵، شماره ۳، ۱-۱۲.
- نوری، ح.، ایلدرومی، ع.، سپهری، م.، آرتیمانی، م. م.، ۱۳۹۷. مقایسه سه روش اصلی هوش مصنوعی در برآورد دبی سیلاب رودخانه یلفان. جغرافیا و برنامه ریزی محیطی. جلد ۲۹، شماره ۴، ۳۵-۵۰.
- Abu-Khalaf, N., Khayat, S., Natsheh, B., 2013. Multivariate data analysis to identify the groundwater pollution sources in Tulkarm area/Palestine. Sci Technol, 3(4): 99-104.
- Alizamir, M., Sobhanardakani, S., 2017. Predicting arsenic and heavy metals contamination in groundwater resources of Ghahavand plain based on an artificial neural network optimized by imperialist competitive algorithm. Environ Health Eng Manag J, 4: 225-231.
- Azad, A., Karami, H., Farzin, S., Saedian, A., Kashi, H., Sayyahi F., 2018. Prediction of water quality parameters using ANFIS optimized by intelligence algorithms (case study: Gorganrood River). KSCE J Civ Eng, 22(7): 2206-2213.
- Delir, S., Froughi-Asl, A., Talatahari, S., 2019. A hybrid charged system search-firefly algorithm for optimization of water distribution networks. International Journal of Optimization in Civil Engineering, 9(2): 273-290.
- Emamgholizadeh, S., Kashi, H., Marofpoor, I., Zalaghi, E., 2013. Prediction of water quality parameters of Karoon river (Iran) by artificial intelligence-based models. Int J Environ Sci Technol, 11: 645-656.
- Hosseini-Moghari, S.M., Morovati, R., Moghadas, M., Araghinejad S., 2015. Optimum operation of reservoir using two evolutionary algorithms: imperialist competitive algorithm (ICA) and cuckoo optimization algorithm (COA). Water Resour Management, 29(10): 3749-3769.
- Jalalkamali, A., 2015. Using of hybrid fuzzy models to predict spatiotemporal groundwater quality parameters. Earth Science Informatics, 8(4): 885-894.
- Karterakis, S.M., Karatzas, G.P., Nikolos, I.K., Papadopoulou, M.P., 2007. Application of linear programming and differential evolutionary optimization methodologies for the solution of

- Chen, W., Bin Ahmad, B., 2018. New Hybrids of ANFIS with several optimization algorithms for flood susceptibility modeling. *Water*, 10(9): 1210.
- Yang, X.S., Sadat Hosseini, S.S., and Gandomi, A.H., 2012. Firefly Algorithm for Solving Non Convex Economic Dispatch Problems with Valve Loading Effect. *Applied Soft Computing*, 12: 1180–1186.
- Zadeh. L.A., 1965. Fuzzy sets. *Inf Control*, 8(3):338–353.
- Zhou, C.H., Gao, L., Gao, H., and Chuanyong, P., 2006. Pattern classification and prediction of water quality by neural network with particle swarm optimization. *Proceeding of the 6th world Congress on Control and utomation, Jun, Dalian, China*, pp. 21-23.
- coastal subsurface water management problems subject to environmental criteria. *J Hydrol*, 342: 270–282.
- Kazemzadeh-Parsi, M.J., Daneshmand, F., Ahmadfard, M.A., Adamowski, J., Martel, R., 2015. Optimal groundwater remediation design of pump and treat systems via a simulation–optimization approach and firefly algorithm. *Engineering Optimization*, 47(1): pp. 1–17.
- Khadr, M. and Elshemy, M., 2016. Data-driven modeling for water quality prediction case study: The drains system associated with Manzala Lake, Egypt. *Ain Shams Engineering Journal*, DOI: 10.1016/j.asej.2016.08.004
- Kisi, O., Keshavarzi, A., Shiri, J., Zounemat-Kermani, M., Omran E-SE., 2017. Groundwater quality modeling using neuro-particle swarm optimization and neuro-differential evolution techniques. *Hydrol Res*, 48(6): 1508–1519.
- Liu, W.C., Chen, W.B., Kimura, N., 2009. Impact of phosphorus load reduction on water quality in a stratified reservoir eutrophication modeling study. *Environmental Monitoring and Assessment*, 159(1–4): 393–406.
- Luo, D., Guo, Q., Wang, X., 2003. Simulation and prediction of underground water dynamics based on RBF neural network. *Acta Geoscientia Sinica*, 24(5): 475–478.
- Mousavi, S.F. and Amiri, M.J., 2012. Modelling nitrate concentration of groundwater using adaptive neural-based fuzzy inference system. *Soil Water Resour*, 7(2): 73–83.
- Orouji, H., Bozorg Haddad, O., Fallah-Mehdipour, E., and Mariño M.A., 2013. Modeling of water quality parameters using data-driven models. *J Environ Eng*, 139(7): 947–957.
- Smaoui, H., Zouhri, L., Kaidi, S., Carlier E., 2018. Combination of FEM and CMA-ES algorithm for transmissivity identification in aquifer systems. *Hydrol Process*, 32(2): 264–277.
- Sudheer, C., Mathur, S., 2012. Particle swarm optimization trained neural network for aquifer parameter estimation KSCE. *J Civil Eng*, 16: 298–307.
- Tabari, M.M.R., 2016. Prediction of river runoff using fuzzy theory and direct search optimization algorithm coupled model. *Arabian Journal for Science and Engineering*, 41(10): 4039–4051.
- Tien Bui, D., Khosravi, K., Li, S., Shahabi, H., Panahi, M., Singh, V., Chapi, K., Shirzadi, A., Panahi, S.,