Archive of SID

هیدروژئولوژی، سال ششم، شماره ۱، تابستان ۱۴۰۰
Hydrogeology, Volume 6, No. 1, Summer 2021

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 دریافت مقاله: ۱۳۹۸/۰۶/۲۶ تاریخ پذیرش مقاله: ۱۳۹۹/۱۰/۱۶

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)، فرهنگی (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، به‌طوری‌که مقدار R^2 ، RMSE و NSE آن به‌ترتیب برای بخش آزمایش در TH، ۰/۹۹، ۰/۴۱ و ۰/۹۹، برای SAR، ۰/۹۸، ۱/۱۱ و ۰/۹۵ و برای EC، ۰/۹۹، ۳۰۵/۷ و ۰/۹۹ به‌دست آمد. سایر روش‌ها نیز با دقتی مناسب موفق به مدل‌سازی و پیش‌بینی پارامترهای موردنظر شدند. با توجه به دقت محاسبات، این روش‌ها گزینه‌های مناسبی برای پیش‌بینی متغیرهای کیفی آب زیرزمینی به‌شمار می‌روند.

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

مقدمه

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 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

www.SID.ir

Archive of SID

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 درنظر 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[1] 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=۰/۹۳ بهترین عملکرد را نشان داد و به‌طورکلی برای برآورد میزان نیترات در منطقه موردنظر توصیه شد. امامقلی‌زاده و همکاران (۲۰۱۴)، از روش‌های MLP[2] و ANFIS برای مدل-سازی 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 نیزموثرترین پارامتر ورودی معرفی گردید. خدر و الشمی (۲۰۱۶)، مدل ANFIS را برای پیش‌بینی پارامترهای کیفی آب زهکش‌های مرتبط با دریاچه مانزال در مصر به‌کار 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 مدل-سازی پارامتر TH بر اساس سایر مؤلفه‌های شیمیایی یعنی 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 به‌کار گرفته شده است. ژو و همکاران (۲۰۰۶)، از دو مدل PSO [3] و ANN[4] 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 پارسی و همکاران (۲۰۱۵)، از روش ترکیبی الگوریتم FA [5] 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 بهینه-سازی شبکه توزیع آب شهری پرداختند و کارایی این الگوریتم را تأیید نمودند. حسینی مقاری و همکاران (۲۰۱۵)، از الگوریتم‌های ICA[6] و COA[7] 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

[1] Adaptive Neuro Fuzzy Inference System
[2] Multilayer Perceptron
[3] Particle Swarm Optimization
[4] Artificial Neural Network
[5] Firefly Algorithm
[6] Imperialist Competitive Algorithm
[7] Cuckoo Optimization Algorithm

www.SID.ir

Archive of SID

کرده‌اند. علی ضمیر و سبحان اردکانی (۲۰۱۷)، با هدف پیش-بینی آلودگی آرسنیک و فلزات سنگین (Cu، Pb و Zn) 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 می تواند به طور مؤثری برای پیش‌بینی غلظت فلزات سنگین در منابع آب زیرزمینی دشت موردنظر استفاده شود. سموئی و همکاران (۲۰۱۸)، در پژوهشی جهت حل معکوس مسئله دارسی در آب زیرزمینی، پیشنهاد ترکیب یک الگوریتم و مدل اجزای محدود را دادند و از الگوریتم CMA-ES[8] 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 روش های مدل‌سازی عددی آب های زیرزمینی می‌توان به استفاده از مدل ARIMA در پژوهش های 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 مدل سازی 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 Cl، EC 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 روزانه در پایین‌دست 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 به‌دست 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 روشMLP، ANFIS و روش ترکیبی الگوریتم ژنتیک و شبکه عصبی پرداختند. ۵ پارامتر به‌عنوان ورودی و دبی پیک به‌عنوان خروجی درنظر 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.

[8] Covariance Matrix Adaptation Evolution Strategy

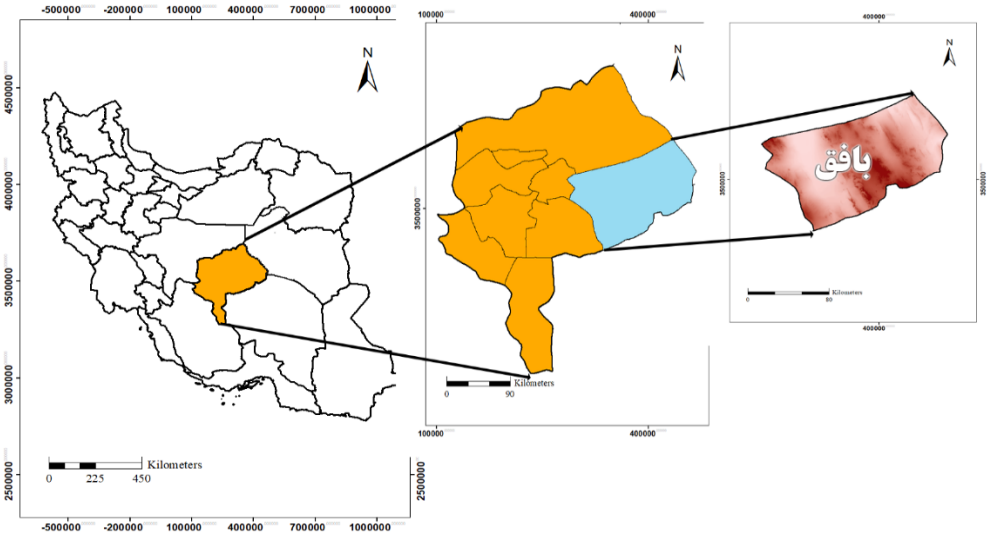
www.SID.ir

Archive of SID

مواد و روش‌ها

منطقه مورد مطالعه

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 '۳۴ ۳۱ ° تا '۳۸ ۳۱ ° 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.



شکل ۱ – منطقه مورد مطالعه.

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 به‌صورت 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، به‌طوری‌که ضمن داشتن قابلیت یادگیری شبکه‌های عصبی و قدرت استنتاج فازی، توانایی نگاشت هرگونه مدل غیرخطی را نیز دارا می‌باشند. ANFIS شبکه ای 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 نرمال‌شده است که نسبت درجه مشارکت هر 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 به‌صورت مجموع خروجی گره‌های لایه قبل بیان می‌کند.

الگوریتم ژنتیک (GA)

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

www.SID.ir

Archive of SID

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 میابد. پس از اعمال سعی و خطا به‌منظور دستیابی به دقت بالاتر، اعداد درصد همگذری[9] و جهش[10] به ترتیب ۰/۷ و ۰/۴ برای این مطالعه انتخاب شدند.

الگوریتم ازدحام ذرات (PSO)

الگوریتم PSO در سال ۱۹۹۵ به‌عنوان یک روش جستجوی غیرقطعی برای بهینه‌سازی تابع، مطرح گشت. این الگوریتم از حرکت دسته جمعی پرندگانی 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 به‌صورت تصادفی به‌وجود 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 به‌دست آمده‌است 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).

$$V(t+1)=w\times v(t)+cl\times rand(t)-position(t)+c2\times and(t)\times(Gbest(t)-position(t)) \quad (۱)$$

$$Position(t+1)=position(t)+v(t+1) \quad (۲)$$

که v(t)سرعت فعلی ذره و cl×rand(t)-position(t) و c2×and(t) ×(Gbest(t)-position(t)) میزان تغییر سرعت ذره و جهت آن می‌باشند. W نیز ضریبی است که با توجه به مسئله معمولاً بین ۰/۷ تا ۰/۹ درنظر 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 درنظر 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 به‌کار گرفته شده است. بخش‌های مختلف این الگوریتم عبارتند از: طبقه‌بندی[11]، الهام‌بخشی[12]، استعارگری[13] و استراتژی[14]. 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 موردنظر و محقق‌شدن شرایط ادامه می‌ابند، عبارتند از: ۱- مقداردهی اولیه فضای جمعیت (جمعیت اولیه)، ۲- مقدار دهی 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 به‌ترتیب ۰/۳ و ۰/۵ قرار داده شدند.

[9] Crossover Percentage
[10] Mutation Percentage
[11] Taxonomy
[12] Inspiration
[13] Metaphor
[14] Strategy

www.SID.ir

Archive of SID

الگوریتم رقابت استعماری (ICA)

الگوریتم رقابت استعماری (ICA) اولین بار توسط آتشپزگرگری (۱۳۸۷) معرفی شد که در آن برخلاف اکثر الگوریتم‌ها، به‌جای طبیعت، از یک پدیده اجتماعی سیاسی الهام گرفته شده است. در این الگوریتم، مشابه با افراد در الگوریتم ژنتیک، تعدادی کشور درنظر گرفته می‌شود که نقاطی تصادفی درون فضای جستجو هستند. به‌این‌ترتیب، 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 به‌دست می‌آید (آتشپزگرگری، ۱۳۸۷):

$$C_n=max_i\{C_i\}-C_n \quad (۳)$$

که C_n، هزینه استعمارگر nام، $max_i\{C_i\}$ 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 به‌اندازه 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):

$$TC_n=Cost(imperialist_n+\zeta\ \text{mean}\{Cost(colonies\ of\ empire_n)\}) \quad (۴)$$

که TC_n هزینه کل امپراتوری nام و ζ عددی مثبت است که معمولاً بین صفر و یک و نزدیک به صفر درنظر گرفته می‌شود. کوچک درنظر گرفتن ζ باعث می‌شود که هزینه کل یک امپراتوری، تقریباً برابر با هزینه حکومت مرکزی آن (کشور استعمارگر) شود.

ممکن است درروند 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 درخواهد 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 به‌کار رود. پارامترهای نرخ انقلاب، ضربی 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 شب‌تاب (FA)، از رفتار کرم‌های شب‌تاب 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 شب‌تاب الهام گرفته شده است. همه کرم شب‌تاب‌ها تمایل جنسی دارند، به‌طوری‌که یک کرم شب‌تاب تمام کرم شب‌تاب‌های دیگر را جذب می‌کند و این قدرت جذب، به میزان نوری که می‌تواند تولید کند بستگی دارد، یعنی اگر کرم شب‌تابی روشن‌تر از کرم شب‌تاب 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 شب‌تاب به سمت کرم‌های شب‌تاب

www.SID.ir

Archive of SID

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 مجاورآن متناسب است، می‌توان جذابیت β را به صورت رابطه ۵ تعریف نمود (یانگ و همکاران، ۲۰۱۲):

$$\beta = \beta_0 e^{-\gamma r^2} \quad (۵)$$

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 کردی لوسی‌فرین از رابطه ۶ استفاده می‌شود (یانگ و همکاران، ۲۰۱۲).

$$l_i = (1-p) l_i(t-1) + \gamma J(x_i(t)) \quad (۶)$$

که در آن ، l_i ، $l_i(t-1)$ و $J(x_i(t))$ به ترتیب مقدار جدید لوسی-فرین، مقدار قبلی لوسی‌فرین و برازندگی مکان کرم i در تکرار t از الگوریتم بوده و ρ 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 لوسی-فرین بالاتری دارد حرکت می‌کند. به این ترتیب کرم‌ها به سمت همسایگان با درخشندگی بیشتر حرکت می‌کنند. با فرض انتخاب شدن کرم شب‌تاب j توسط کرم شب‌تاب i با احتمال p، معادله حرکت زمان-گسسته کرم شب‌تاب را می‌توان به‌صورت رابطه ۷ نوشت (یانگ و همکاران، ۲۰۱۲).

$$x_i(t+1) = x_i(t) + s \times \left(\frac{x_j(t) - x_i(t)}{\| x_j(t) - x_i(t) \|}\right) \quad (۷)$$

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

به هر کرم شب‌تاب i یک همسایگی تخصیص می‌یابد که برد شعاعی rid آن به‌طور طبیعی دینامیک است .$(0 < \text{rid} \leq \text{rs})$. از آنجا که اطلاعات ازپیش‌دانسته 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 درنظر گرفت. در اینجا ضریب جذب نور برابر ۱ و ضریب جهش برابر ۰/۲ در نظر گرفته شدند.

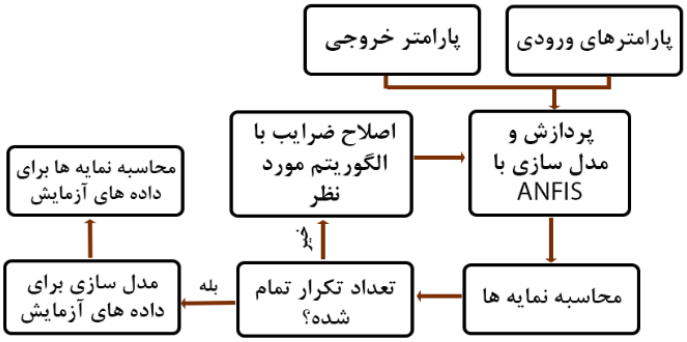
الگوریتم استراتژی تکامل انطباق ماتریس کوواریانس[15](CMA-ES)

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 جهتی 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. درطول 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.

[15] Covariance Matrix Adaptation Evolution Strategy

www.SID.ir

Archive of SID



شکل ۲- فلوچارت مراحل مدل سازی روش‌های ترکیبی.

برای یکسان‌سازی شرایط جهت مدل‌سازی، تعداد جمعیت اولیه در همه الگوریتم‌ها ۱۰۰ و تعداد تکرار ۵۰۰ درنظر گرفته شد. همچنین در هر مرحله، ۷۵٪ از داده‌ها به‌عنوان داده‌های آموزش و ۲۵٪ به‌عنوان داده‌های صحت‌سنجی استفاده گردید. نمایه‌های مورداستفاده در این پژوهش جهت بررسی عملکرد مدل‌ها، ضریب همبستگی(R^2)، خطای جذر میانگین مربعات (RMSE) و ضریب نش-ساتکلیف (NSE) هستند که نحوه محاسبه آنها در روابط ۸ تا ۱۰ آورده شده است.

$$R^2 = \frac{[\sum_{i=1}^{n}(X_i-\bar{X})(Y_i-\bar{Y})]^2}{[\sum_{i=1}^{n}(X_i-\bar{X})^2(Y_i-\bar{Y})^2]} \quad (۸)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(X_i-Y_i)^2}{N}} \quad (۹)$$

$$NSE = 1-\frac{\sum_{i=1}^{n}(X_i-Y_i)^2}{\sum_{i=1}^{n}(X_i-\bar{X}_i)^2} \quad (۱۰)$$

در این روابط، Xi و Yi مقادیر مشاهداتی و محاسباتی می‌باشند و N تعداد داده‌ها است.

داده‌های استفاده شده در این پژوهش، شامل ۱۶ سری داده برداشت شده از ۳۱ چاه عمیق و قنات بین سال‌های ۱۳۸۱ تا ۱۳۹۶ در دشت بافق می‌باشد که از سازمان آب منطقه‌ای اخذ شده‌اند. در ادامه ضمن حذف داده‌های پرت، داده‌های گمشده نیز به‌وسیله درون‌یابی اصلاح و در نهایت ۶۷۵ داده برای هر پارامتر در مدل‌سازی‌ها به‌کار گرفته شد.

نتایج و بحث

در این مطالعه، کیفیت آب زیرزمینی شهرستان بافق موردتوجه قرار گرفته است. مدل‌سازی 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 داده‌های ورودی جهت تخمین هریک از سه متغیر مورد نظر، همبستگی بین پارامترهای Ca، Mg، pH، Cation، Anion، TDS، K، Na، SO_4، Cl و HCO_3 با آن پارامتر در نرم‌افزار SPSS و با روش‌های پیرسون و اسپیرمن سنجیده شد و داده‌های 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 (SO_4، $mg\ L^{-1}$)، کلرید (Cl، $mg\ L^{-1}$)، بی کربنات (HCO3، mgL^{-1})، پتاسیم (K، $mg\ L^{-1}$)، سدیم (Na، $mg\ L^{-1}$)، منیزیم (Mg، $mg\ L^{-1}$) ، کلسیم (Ca، $mg\ L^{-1}$)، آنیون (Anion، $meqL^{-1}$) و کاتیون (Cation، $meqL^{-1}$). که از این میان، تنها بی-کربنات و پتاسیم به‌دلیل عدم همبستگی مناسب با هیچکدام از پارامترهای خروجی مورنظر، کنار گذاشته شدند. بنابراین برای TH از ورودی‌های Ca، Mg، Cation و Anion، برای SAR از ورودی‌های Cl و Na و برای EC از ورودی‌های Cl، SO_4، 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.

www.SID.ir

Archive of SID

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 وEC .

		R^2		RMSE		NSE	
مدل	پارامتر	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

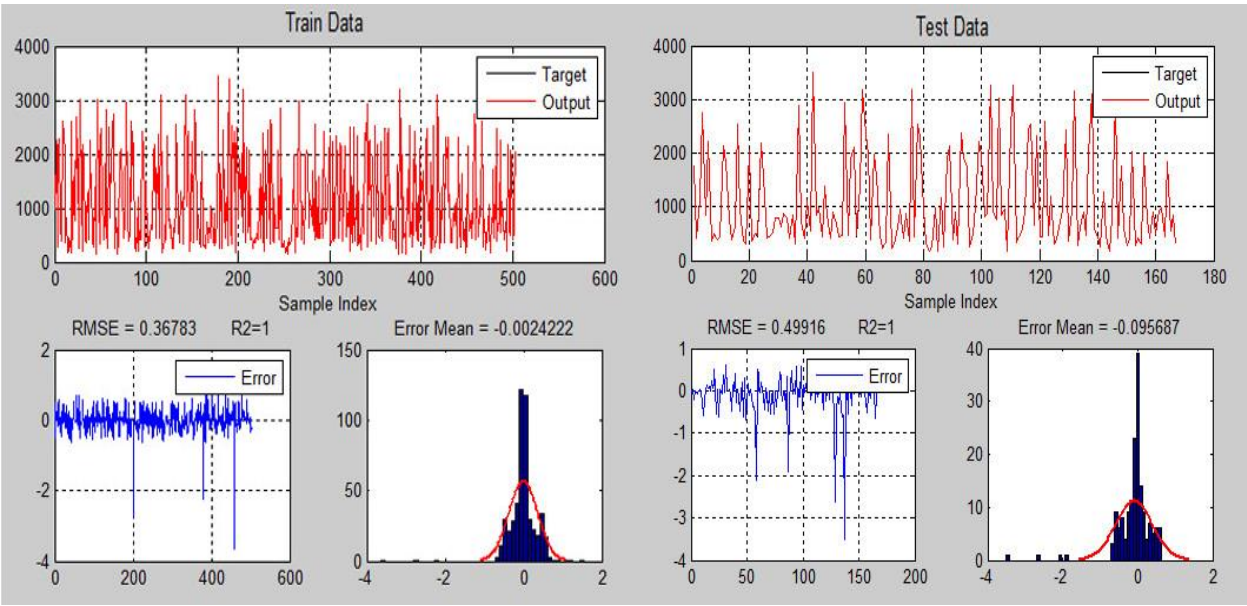
www.SID.ir

Archive of SID

بر طبق اعداد جدول (۲) که براساس حدود ۶۷۵ داده موردبررسی به‌دست آمده است، میانگین EC آب بیش از مقدار مناسب (۳۰۰۰µmho/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 مدل سازی و محاسبه نمایه‌های مورد نظر در دو بخش آموزش و آزمایش، نتایج در جدول ۳ آورده شد.

بر این اساس، در مدل سازی 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 به‌منظور مدل‌سازی TH استفاده شدند. براساس نتایج به‌دست آمده در جدول (۳)، در بخش آموزش، تمامی مدل‌ها به‌جز ANFIS-FA و ANFIS-ICA دارای مقدار R^2=1 هستند که نشان‌دهنده همبستگی بسیارخوب بین داده‌های محاسباتی و مشاهداتی دارد. البته این نمایه در بخش آزمایش نیز، تنها برای مدل‌های ANFIS-GA و ANFIS-FA مقدار ۱ را به‌دست نیاورد. با توجه به مقادیر مشابه NSE برای همه مدل‌ها، نمایه RMSE می‌تواند ملاک بهتری برای انتخاب مدل بهتر باشد، به‌نحوی 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.



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

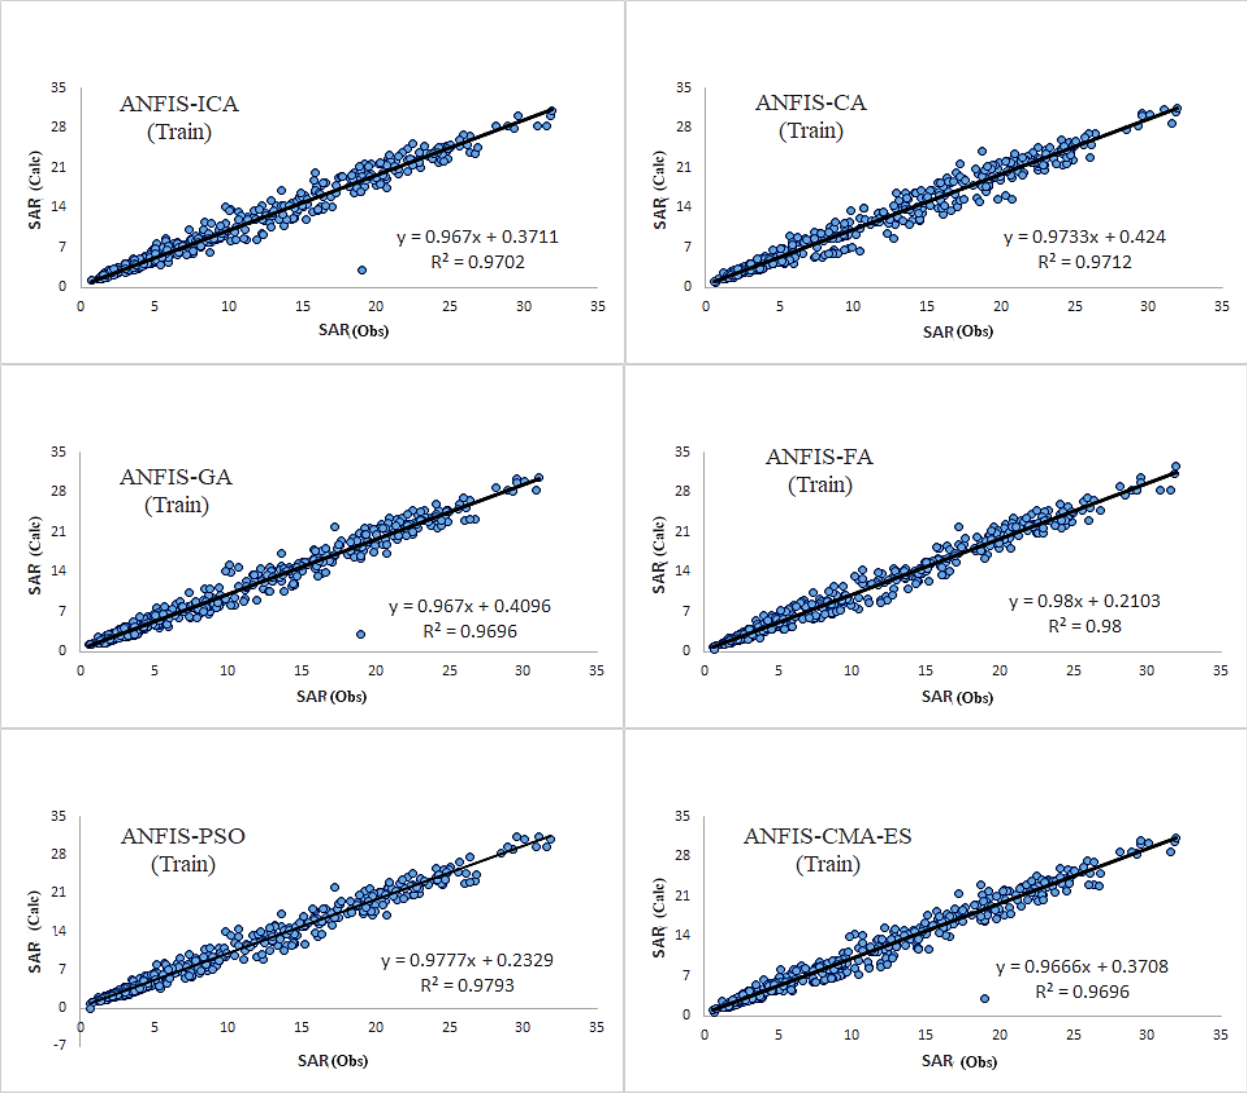
برای محاسبه SAR، پارامترهای Na و Cl با توجه به همبستگی بالای ۹۵٪ به‌عنوان ورودی انتخاب شدند. هرچند برخی پارامترهای دیگر همچون منیزیم و کلسیم نیز بر SAR موثرند ولی با توجه به مقدار نه‌چندان بالای همبستگی آن‌ها در داده‌های مورداستفاده این مطالعه، از به‌کارگیری آنها صرف‌نظر شد. بنابراین با توجه به شرایط ذکر شده، مدل ANFIS-GA با داشتن R^2=۰/۹۷ و RMSE=۱/۱۱ و NSE=۰/۹۷ 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-

www.SID.ir

Archive of SID

ICA بهترین مدل این مطالعه برای مدل‌سازی SAR معرفی می‌شود که مقادیر خروجی آن در شکل ۵ قابل مشاهده است.

در بخش مدل‌سازی برای پارامتر EC، از پنج پارامتر آنیون، کاتیون، سدیم، کلرید و سولفات استفاده شد. واحد داده‌های استفاده شده برای EC ، µmho Cm-1 است، بنابراین واحد RMSEهای محاسبه شده نیز برپایه همین واحد بیان می‌گردد. با توجه به مقدار مساوی R^2 و NSE به‌دست آمده برای همه مدل‌ها، بر این اساس، مدل ANFIS-FA با مقادیر RMSE=۲۵۸/۲ به‌عنوان مدل برتر در بخش آموزش انتخاب و مدل‌های ANFIS-PSO و ANFIS-CMA-ES دررتبه‌های بعدی قرار گرفتند. در بخش آزمایش نیز مدل ANFIS-CA با RMSE=۲۶۷/۲ بهترین مدل شناخته شد که خروجی آن در شکل (۶) مشاهده می‌شود. در مجموع جهت مدل‌سازی پارامتر EC به‌دلیل عدم برتری قاطعانه هیچ‌یک از مدل‌ها بر سایرین، نمی‌توان مدلی را ارجح‌تر معرفی کرد.

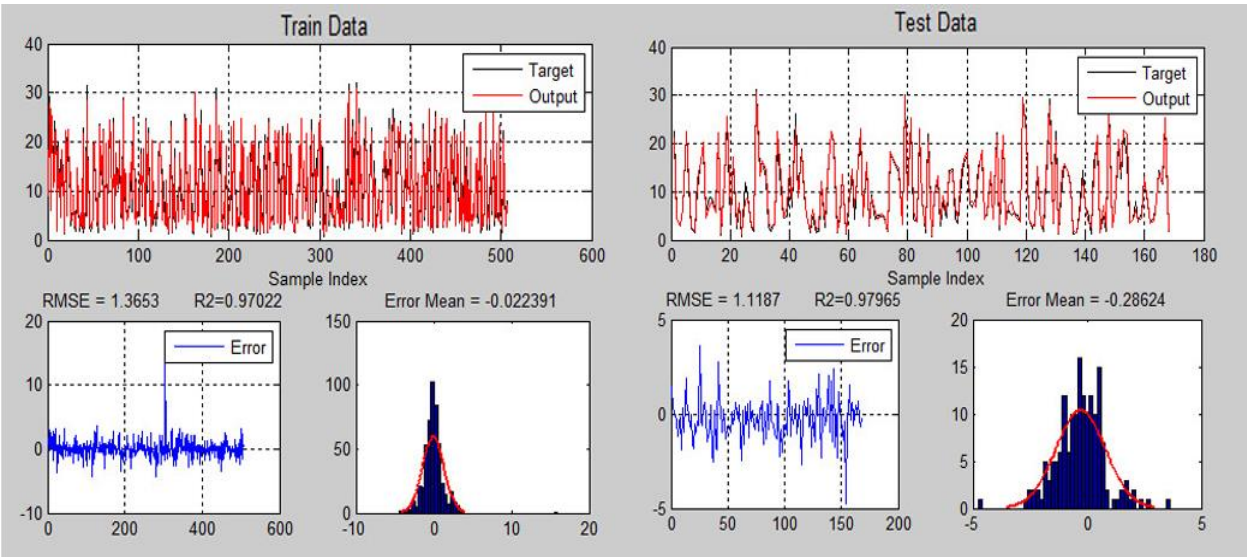


شکل ۴ – نمودارهای همبستگی شش روش ترکیبی مورد نظر در مدل سازی SAR.

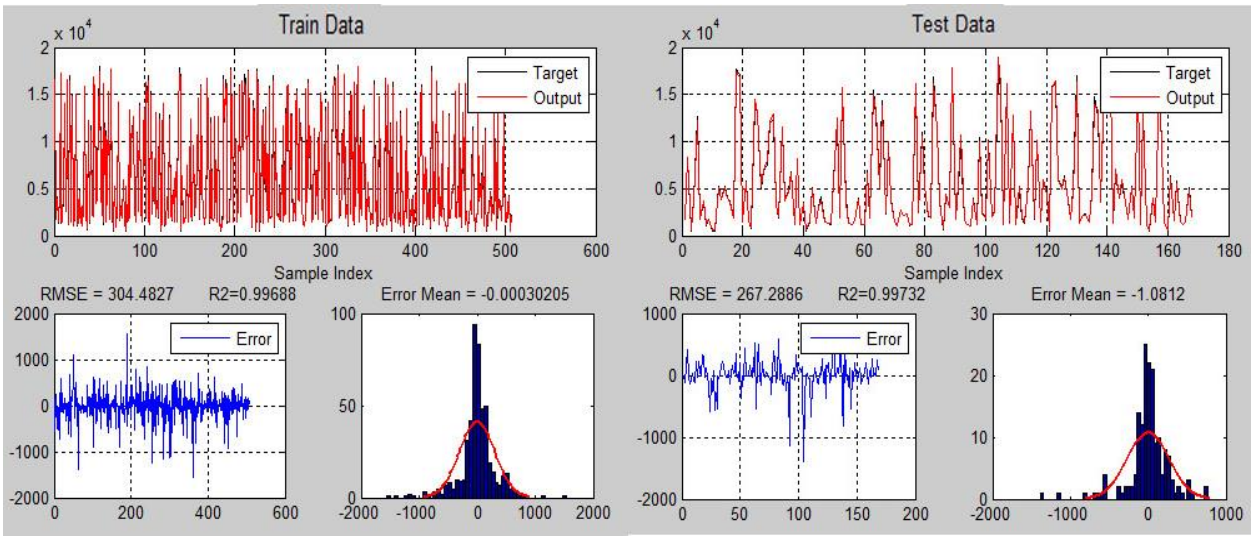
www.SID.ir

Archive of SID

البته لازم به ذکر است که نتایج بهتر تمامی‌مدل‌های ترکیبی ذکر شده ممکن است با تغییر شرایط جستجو و پارامترهای الگوریتم و همچنین گیرنکردن 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، 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 وANFIS-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.



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



شکل۶ – خروجی مدل ANFIS-CA برای پارامتر EC.

www.SID.ir

Archive of SID

نتیجه گیری

در این پژوهش، از شش الگوریتم هوشمند PSO، GA، ICA، CA، FA و CMA-ES برای افزایش قابلیت مدل ANFIS جهت مدل‌سازی و ارزیابی سه پارامتر آب زیرزمینی EC، SAR و TH در شهرستان بافق استفاده شد. با توجه به نتایج نمایه‌های مورد استفاده، دقت پیش‌بینی متغیرهای ذکر شده با هر شش روش ترکیبی مناسب می‌باشد. نتایج نشان داد که مدل ANFIS-FA در هر سه دسته مدل‌سازی جزو بهترین مدل‌ها به‌شمار می‌رود و می‌تواند به‌عنوان مدل برگزیده در این پژوهش معرفی گردد، به‌طوری که مقدار R^2 ، RMSE و NSE آن به‌ترتیب برای بخش آزمایش TH، ۰/۹۹، ۰/۴۱ و ۰/۹۹، برای SAR، ۰/۹۸، ۱/۱۱ و ۰/۹۵ و برای EC، ۰/۹۹، ۳۰۵/۷ و ۰/۹۹ به‌دست آمد. هرچند سرعت اجرای مدل نسبت به سایر مدل‌ها بسیار پایین‌تر بود. به‌طورکلی می‌توان نتیجه گرفت که مدل‌های ترکیبی الگوریتم‌های مختلف با مدل ANFIS می‌تواند به‌عنوان ابزاری موثر برای محاسبه و پیش‌بینی متغیرهای کیفی آب زیرزمینی مورد استفاده قرار گیرد.

منابع

آتشپز گرگری، ا.، ۱۳۸۷. توسعه الگوریتم بهینه‌سازی اجتماعی و بررسی کارایی آن. پایان‌نامه کارشناسی ارشد، دانشکده مهندسی برق، دانشگاه تهران.

اقدر، ح. محمدیاری، ف.، ۱۳۹۴. مدل‌سازی 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. مدل‌سازی خوشه‌ای تراز آب زیرزمینی دشت تبریز با استفاده از مدل آریما .هیدروژئولوژی، جلد ۴، شماره ۲، ۷۴-۹۱.

کرد، م.، اصغری مقدم، ا.، نخعی، م.، ۱۳۹۸. مدل‌سازی عددی آبخوان دشت اردبیل و مدیریت آن با استفاده از بهینه‌سازی برداشت آب زیرزمینی. هیدروژئولوژی، جلد ۴، شماره ۱، ۱۵۳-۱۶۷.

میرسنجری، م. م.، محمدیاری، ف.، بصیری، ر. حمیدی پور، ف.، ۱۳۹۶. مدل‌سازی 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 برنامه‌ریزی 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., Saeedian, 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., Foroughi-Asl, A., Talatahari, S., 2019. A hybrid charged system search-firefly algoritm 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

www.SID.ir

Archive of SID

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.,

www.SID.ir