



شبیه‌سازی تراز، کلر و بی‌کربنات آب زیرزمینی توسط ماشین آموزش ترکیبی

علی عزیزپور^۱، محمد علی ایزدبخش^{۲*}، سعید شعبانلو^۳، فریبرز یوسفوند^۲، احمد رجبی^۲

۱- دانشجوی دکتری منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

۲- استادیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

۳- دانشیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

* نویسنده مسئول: izadbakhsh.mohammad.ali@gmail.com

تاریخ پذیرش مقاله: ۱۳۹۹/۱۰/۱۶

تاریخ دریافت مقاله: ۱۳۹۹/۰۱/۲۷

چکیده

در این مطالعه، دو مدل فرا ابتکاری هوش مصنوعی برای شبیه‌سازی داده‌های سری زمانی پارامترهای کمی (نوسانات تراز آب زیرزمینی) و کیفی (کلر و بی‌کربنات) آب زیرزمینی درون یک چاه مشاهداتی واقع در شهر کرمانشاه، ایران، از سال ۲۰۰۵ تا ۲۰۱۸ به‌صورت ماهانه ارائه شد. برای تعریف مدل هیبریدی هوش مصنوعی، ماشین آموزش نیرومند (ELM)، الگوریتم تکامل تفاضلی (DE) و تبدیل موجک با هم ترکیب شدند و مدل‌های ماشین آموزش نیرومند خود تطبیقی (SAELM) و موجک-ماشین آموزش نیرومند خود تطبیقی (WSAELM) ارائه شدند. لازم به ذکر است که برای شناسایی تأخیرهای موثر داده‌های سری زمانی از تابع خود همبستگی استفاده گردید. علاوه بر این، ۷۰ درصد داده‌های مشاهداتی برای آموزش مدل‌های هوش مصنوعی و ۳۰ درصد باقیمانده برای تست آنها استفاده شدند. سپس، با استفاده از این تأخیرهای موثر، مدل‌های مختلفی برای الگوریتم‌های هیبریدی SAELM و WSAELM تعریف شدند. سپس با اجرای یک تحلیل حساسیت، مدل‌های برتر برای مدل‌سازی تراز آب زیرزمینی، کلر و بی‌کربنات معرفی شدند. به‌عنوان مثال، برای مدل برتر WSAELM جهت شبیه‌سازی نوسانات آب زیرزمینی، مقادیر ضریب همبستگی (R)، شاخص عملکرد (VAF) و ضریب نش (NSC) به ترتیب مساوی با ۰/۹۸۸، ۹۷/۴۵۰ و ۰/۹۷۳ به دست آمدند. لازم به ذکر است که برای پیش‌بینی HCO_3 نیز تأخیرهای (t-1)، (t-2)، (t-3) و (t-4) به‌عنوان موثرترین تأخیرهای داده‌های سری زمانی شناسایی شدند. با اجرای یک تحلیل عدم قطعیت نشان داده شد که مدل برتر مقادیر Cl و HCO_3 کمتر از واقعی شبیه‌سازی کرد اما مدل برتر مقادیر تراز آب زیرزمینی را با عملکردی بیشتر از مقدار واقعی پیش‌بینی نمود.

واژه‌های کلیدی: الگوریتم تکامل تفاضلی، بی‌کربنات، تبدیل موجک، کلر، ماشین آموزش، نوسانات آب زیرزمینی.

مقدمه

برداشت بیش‌ازحد از این منابع، دشت‌های بسیاری دچار بحران‌هایی مانند کاهش تراز آب زیر زمینی، تشکیل فروچاله‌ها، شور شدن آب زیرزمینی، خشک‌شدن منابع آب‌های سطحی (رودخانه‌ها و دریاچه‌ها) شده‌اند. بنابراین، تخمین و مدل‌سازی پارامترهای کیفی و کمی آب‌های زیرزمینی در کشور ایران اهمیت بالایی دارد. شایان ذکر است که استفاده از مدل‌های هوش مصنوعی به‌دلیل دقت بالا در مدل‌سازی و صرفه‌جویی در زمان و هزینه‌ها روز به روز در حال گسترش است. در سال‌های اخیر،

به‌دلیل گرمایش کره زمین و تغییر اقلیم، نواحی خشک و نیمه‌خشک برای تأمین آب شیرین کافی با چالش روبه‌رو شده‌اند. به‌عنوان مثال، کشور ایران که در جنوب غربی آسیا واقع است دارای اقلیمی خشک و نیمه‌خشک می‌باشد که اخیراً مشکلات فراوانی در زمینه تأمین آب آشامیدنی دارد. به عبارت دیگر، بخش قابل توجهی از مصارف شهری و کشاورزی در ایران از منابع آب-های زیرزمینی تأمین می‌شود که در چند دهه اخیر به دلیل

نمودند که مدل‌های مبتنی بر طول موج، عملکردهای مدل‌های GMDH و ELM را در پیش‌بینی تراز آب زیرزمینی آبی بهبود می‌بخشند. علاوه بر این، کیسی و همکاران (۲۰۱۷) مدل شبکه عصبی مصنوعی را توسط الگوریتم‌های بهینه‌سازی ازدحام ذرات و تکامل تفاضلی (DE) برای شبیه‌سازی پارامترهای کیفی آب‌های زیرزمینی بهینه‌سازی کردند. محمد رضاپور و همکاران (۲۰۱۸) با استفاده از الگوریتم‌ها ژنتیک و نرو فازی مشخصات کیفی آب زیرزمینی از قبیل ذرات جامد و کلر شبیه‌سازی کردند. آنها با تجزیه و تحلیل نتایج شبیه‌سازی‌ها نشان دادند که مدل فازی عملکرد بهتری داشت. رادفارد و همکاران (۲۰۱۹) تعدادی از پارامترهای کیفی آب زیرزمینی منجمله کلر، بی‌کربنات و نترات درون یک سفره آب زیرزمینی واقع در کشور ایران را توسط مدل ANFIS پیش‌بینی نمودند. با مرور مطالعات گذشته، شبیه‌سازی پارامترهای کمی و کیفی آب زیرزمینی جزو مهمترین حوزه‌های علم هیدرولوژی است که توجه بسیاری از محققین را به خود جلب کرده است. لازم به ذکر است که تکنیک‌های مختلف هوش مصنوعی به دلیل انعطاف پذیری بالا، دقت مناسب و ارزانی آنها، محبوبیت قابل توجهی دارند. در این مطالعه، برای اولین بار مشخصات کمی و کیفی آب زیرزمینی درون یک چاه مشاهداتی در شهر کرمانشاه، واقع در کشور ایران، توسط یک مدل هوش مصنوعی نوین هیبریدی شبیه‌سازی می‌شود که همین موضوع نشان دهنده نوآوری مقاله حاضر است. برای توسعه مدل هوش مصنوعی اشین آموزش نیرومند (ELM)، تکامل تفاضلی (DE) و تبدیل موجک ترکیب می‌گردند. برای شناسایی تأخیرهای داده‌های سری زمانی از تابع خود همبستگی استفاده خواهد شد. در ادامه با اجرای یک تحلیل حساسیت، بهترین مدل‌های هوش مصنوعی و تأخیرهای تأثیرگذار معرفی خواهند شد.

مواد و روش‌ها

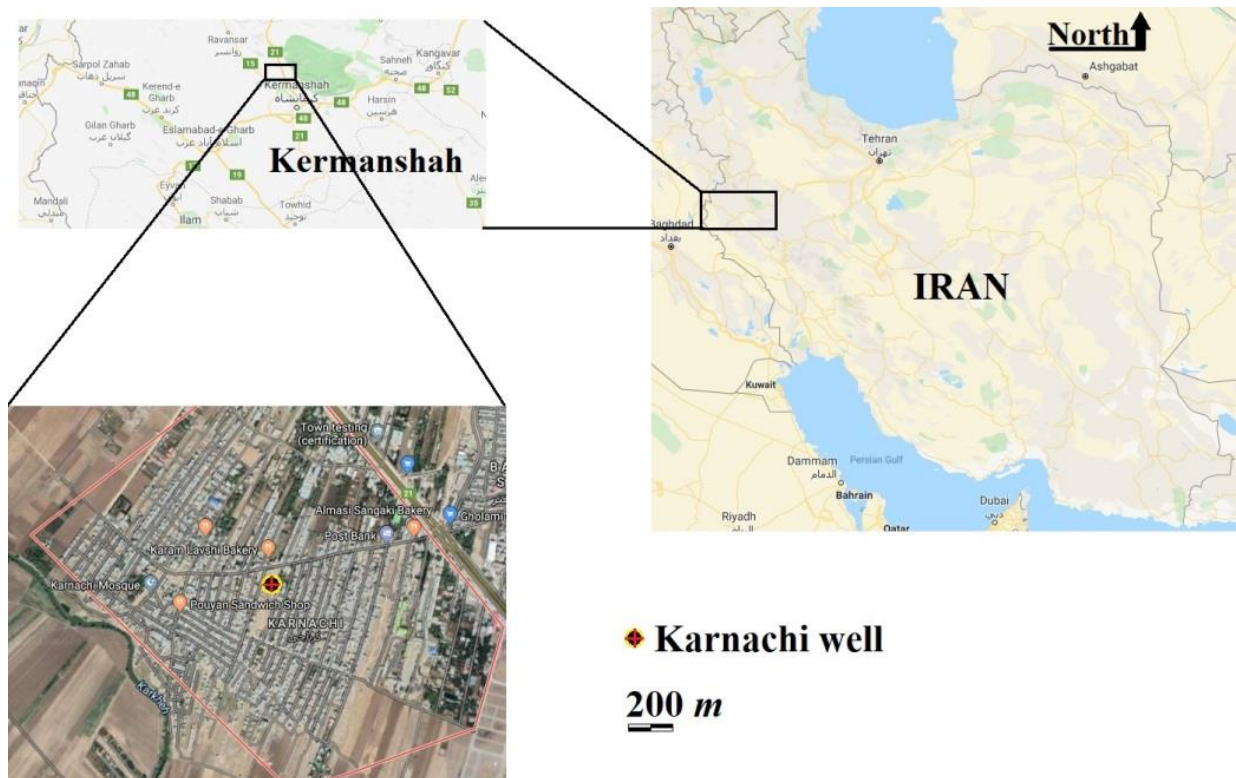
ناحیه مورد مطالعه

در این مطالعه، برای اعتبارسنجی مدل‌های هوش مصنوعی از مقادیر مشاهداتی چاه کرناچی واقع در شهر کرمانشاه، غرب ایران، استفاده شده است. مقادیر مشاهداتی شامل پارامترهای کمی (تراز آب زیرزمینی) و کیفی (کلر و بی‌کربنات) آب

الگوریتم‌های مختلف هوش مصنوعی برای پیش‌بینی پارامترهای مختلف آب‌های زیرزمینی به‌کار رفته‌اند (ترابی ۱۳۹۸؛ دانشور و ثوقی ۱۳۹۷، ۱۳۹۹؛ نیکبخت ۱۳۹۵). به‌عنوان مثال سیواپراگاسام و همکاران (۲۰۱۵) قابلیت مدل تکاملی برنامه-نویسی ژنتیک را برای پیش‌بینی نوسانات تراز آب زیرزمینی در Arjuna Nadhi کشور هند بررسی کردند. این نویسندگان نشان دادند که این مدل توانایی مناسبی در شبیه‌سازی تغییرات آب زیرزمینی داشت. همچنین، نورانی و همکاران (۲۰۱۶) با ترکیب تبدیل موجک و شبکه انفیس یک مدل هیبریدی برای پیش‌بینی تغییرات تراز آب زیر زمینی واقع در خلیج مکزیک توسعه دادند. آنها قابلیت مدل‌های انفیس و موجک-انفیس را با هم مقایسه کرده و نشان دادند که مدل ترکیبی توانایی بهتری در مقایسه با مدل انفیس داشت. در ادامه، ژانگ و همکاران (۲۰۱۷) با استفاده از مدل شبکه عصبی مصنوعی و شبکه انفیس تغییرات تراز آب زیر زمینی در شهر Jilin در کشور چین را از سال ۲۰۰۰ تا ۲۰۰۹ را مدل‌سازی کردند. در ادامه، ملکزاده و همکاران (۲۰۱۹) با ترکیب تبدیل موجک و ماشین آموزش نیرومند، یک مدل هیبریدی هوش مصنوعی برای مدل‌سازی تغییرات آب زیرزمینی تعریف نمودند. آنها با اجرای یک تحلیل حساسیت موثرترین تأخیرهای داده‌های سری زمانی را معرفی نمودند. همچنین، کلر و بی‌کربنات جزو مهمترین پارامترهای کیفی منابع آب‌های زیر زمینی محسوب می‌شوند که مطالعاتی پیرامون مدل‌سازی ترکیبات کلردار و کربنات‌دار در آب‌های زیرزمینی انجام شده‌اند. به‌عنوان مثال، هووانگ و همکاران (۲۰۱۴) با استفاده از شبکه ANFIS و رگرسیون خطی برخی از پارامترهای کیفی درون سفره آب زیرزمینی از قبیل آمونیوم بی‌کربنات و فسفر در یک دشت در کشور چین را شبیه‌سازی نمودند. برزگر و همکاران (۲۰۱۷) به منظور ارزیابی عملکرد روش WA-GMDH و مدل‌های WA-ELM و ترکیب کردن مدل‌های مبتنی بر طول موج برای پیش‌بینی تراز آب زیرزمینی، دست به شبیه‌سازی آبخوان دشت مراغه-بناب زدند. آنها در مطالعه خود از ۳۶۷ مجموعه داده ماهانه تراز آب زیرزمینی برای آموزش مدل و همچنین آزمایش آن استفاده کردند. آنها در پایان نتیجه‌گیری

موجود صرف نظر از ریزش‌های جوی در سطح دشت، آبراهه‌های متعددی هستند که از دامنه ارتفاعات مجاور سرچشمه گرفته و وارد محدوده دشت می‌شوند، همچنین وجود چشمه‌های فراوان که عمدتاً کارستیک بوده خود باعث تغذیه آبخوان می‌گردد. همچنین ضریب قابلیت انتقال سفره آب زیرزمینی در مناطق مختلف محدوده طرح متفاوت است، در حاشیه سفره به علت شیب تند و ضخامت کم آبرفت‌ها حدود ۵۰۰ متر مربع در روز و حتی کمتر و در مناطق مرکزی تا حداکثر ۱۰۰۰۰ مترمربع در روز متغیر است. مقادیر مشاهداتی در یک بازه زمانی ۱۳ ساله از سال ۲۰۰۵ تا ۲۰۱۸ به صورت متوسط ماهیانه استفاده شدند. علاوه بر این، ۱۰ سال از این مقادیر مشاهداتی برای آموزش و ۳ سال برای تست مدل‌های هوش مصنوعی استفاده شده‌اند. موقعیت جغرافیایی چاه کرناچی در شکل ۱ به تصویر کشیده شده است.

زیرزمینی درون چاه کرناچی واقع از سال ۲۰۰۵ تا ۲۰۱۸ به صورت ماهانه به کار گرفته شد. چاه مشاهداتی کرناچی در شمال شهر کرمانشاه قرار دارد و دارای طول و عرض جغرافیایی ۳۴/۳۸۳۳، ۴۷/۰۷۵۳ است. سرتاسر حاشیه شمالی و شرقی و قسمتی از حاشیه شمال غربی این دشت به وسیله آهک‌های کرتاسه که اکثراً نیز خاصیت کارستیک دارند پوشیده شده است. در این دشت آب زیرزمینی در آبرفت‌هایی به ضخامت ۵۰-۲۰۰ متر وجود دارد. در دشت کرمانشاه سفره‌های آزاد و محبوس آرتزین وجود دارند و مخازن آب زیرزمینی این محدوده در رسوبات آبرفتی دوران چهارم که نتیجه فرسایش ارتفاعات حاشیه‌ای دشت هستند، تشکیل گردیده است. اجزای متشکله رسوبات در محدوده سفره آب شامل قلوه‌سنگ، شن، ماسه، سیلت و رس است و از نظر ترکیب بیشتر از قطعات آهکی تشکیل یافته است. عمده‌ترین منبع تغذیه کننده سفره آب زیرزمینی



شکل ۱- موقعیت جغرافیایی چاه مورد مطالعه

مدل عددی

ماشین آموزش نیرومند^۱

ماشین آموزش نیرومند (ELM) که یک شبکه عصبی پیشخور تک‌لایه است اولین بار توسط هووانگ و همکاران (۲۰۰۶) ارائه شده است. مدل ELM وزن‌های ورودی را به صورت تصادفی و وزن‌های خروجی را به صورت تحلیلی تعیین می‌کند. تنها تفاوت ELM با شبکه عصبی پیشخور تک‌لایه (SLFFNN)، عدم استفاده از بایاس برای نرون خروجی است. در این مدل هوش مصنوعی نرون‌های لایه ورودی با همه نرون‌های لایه مخفی در ارتباط است. نرون‌های لایه مخفی با استفاده از یک بایاس به وجود می‌آیند. تابع فعال‌سازی نرون‌های مخفی می‌تواند به صورت تابع پیوسته تکه‌ای باشد درحالی‌که برای نرون لایه خروجی به صورت خطی است. مدل ELM از الگوریتم‌های مختلفی جهت محاسبه وزن‌ها و بایاس‌ها استفاده می‌کند که در نتیجه کاهش قابل‌توجه زمان آموزش شبکه را به همراه دارد. توصیف ریاضی شبکه عصبی پیش‌خور تک‌لایه با تعداد n نود مخفی، به صورت زیر بیان می‌شود (هووانگ و همکاران ۲۰۰۶).

$$f_n(x) = \sum_{i=1}^n \beta_i G(a_i, b_i, x) \quad (1)$$

که β_i وزن بین گره مخفی i ام و گره خروجی، a_i ($a_i \in R^n$) و b_i فاکتورهای آموزش گره‌های مخفی و $G(a_i, b_i, x)$ خروجی گره i ام برای ورودی x است. تابع فعال‌سازی $g(x)$ (که دارای انواع مختلفی می‌باشند) برای گره مخفی افزاینده $G(a_i, b_i, x)$ را می‌توان به شکل زیر بازنویسی کرد (هووانگ و همکاران ۲۰۰۶).

$$G(a_i, b_i, x) = g(a_i \cdot x + b_i) \quad (2)$$

از توابع فعالیت به منظور محاسبه خروجی پاسخ نرون‌ها استفاده می‌شود. رفتار نرون‌ها از دو بخش تشکیل شده است که شامل مجموع وزنی ورودی‌ها و تابع فعالیت است. زمانی که مجموعه‌ای از سیگنال ورودی وزن‌دار اعمال می‌شود، برای به دست آوردن پاسخ از توابع فعال‌سازی استفاده می‌شود. همچنین برای نرون‌های لایه‌های یکسان از توابع فعال‌سازی یکسان استفاده می‌شود که ممکن است خطی و یا غیرخطی باشند. در توابع خطی یک گراف خطی مستقیم کشیده می‌شود و در توابع غیرخطی یک خط

منحنی دار ترسیم می‌شود و با توجه به اینکه در توابع غیرخطی میزان متغیرهای ورودی و خروجی ثابت نیستند مشکلات طبقه‌بندی در آنها معمول است. توابع فعال‌سازی غیرخطی ELM که در این مطالعه مورد بررسی قرار گرفته است شامل تابع پله‌ای (hardlim)، سیگموید (sig)، سینوسی (sin)، بایاس مثلثی (tribas) و بایاس شعاعی (radbas) است. در ELM وزن‌ها و بایاس‌ها بین نرون‌های لایه ورودی و مخفی به صورت تصادفی اختصاص داده می‌شوند. فعال‌سازی نرون‌های لایه مخفی برای هر نمونه آموزشی در یک شبکه ELM با تعداد "j" نرون در لایه مخفی، "i" نرون ورودی و تعداد "k" نمونه آموزشی، از رابطه زیر محاسبه می‌شود (هووانگ و همکاران ۲۰۰۶).

$$H_{jk} = g\left(\sum_j (W_{ji} X_{ik}) + B_j\right) \quad (3)$$

که $g(\cdot)$ می‌تواند هر تابع فعال‌سازی غیرخطی پیوسته باشد، W_{ji} وزن نرون ورودی i ام و نرون لایه مخفی j ام، B_j بایاس نرون لایه مخفی j ام، X_{ik} ورودی نرون ورودی برای k امین نمونه آموزشی و H_{ik} ماتریس فعال‌سازی نرون لایه مخفی برای k امین نمونه آموزشی است به طوری‌که فعال‌سازی همه نرون‌های لایه مخفی برای نمونه‌های مورد استفاده در آموزش توسط این ماتریس ارائه می‌شود. در این ماتریس j ستون و k ردیف است. ماتریس H به عنوان ماتریس لایه مخفی خروجی شبکه عصبی بیان می‌شود. وزن‌های بین نرون‌های لایه مخفی و خروجی با استفاده از برازش حداقل مربعات برای مقادیر هدف در حالت آموزش در برابر خروجی‌های نرون‌های لایه مخفی برای هر نمونه آموزشی، به کار برده می‌شود که معادل ریاضی آن را می‌توان به شکل زیر بیان کرد (هووانگ و همکاران ۲۰۰۶).

$$H\beta = T \quad (4)$$

$$\beta = (\beta_1, \dots, \beta_j)_{j \times 1} \quad (5)$$

که β نشان دهنده وزن بین نرون لایه خروجی و نرون‌های لایه مخفی است و T بردار نشان‌دهنده مقادیر هدف برای نمونه‌های آموزش است که به صورت زیر بیان می‌شود (هووانگ و همکاران ۲۰۰۶).

$$T = (T_1, \dots, T_k)_{k \times 1} \quad (6)$$

¹ Extreme Learning Machine (ELM)

الگوریتم تکامل تفاضلی به‌عنوان روشی قدرتمند و سریع برای مسائل بهینه‌سازی در فضاهای پیوسته معرفی شده است و توانایی خوبی در بهینه‌سازی توابع غیرخطی مشتق‌ناپذیر دارد. همانند دیگر الگوریتم‌های تکاملی، این الگوریتم با ایجاد یک جمعیت اولیه شروع به کار می‌کند. سپس با اعمال عملگرهایی شامل ترکیب، جهش و تقاطع، نسل فرزند تشکیل شده و در مرحله بعد که مرحله انتخاب نام دارد، نسل فرزند با نسل والد از برای میزان شایستگی که توسط تابع هدف سنجیده می‌شود، مقایسه می‌گردد. سپس بهترین اعضا به‌عنوان نسل بعدی وارد مرحله بعد می‌گردند. این عمل تا رسیدن به نتایج مطلوب ادامه می‌یابد. الگوریتم تکامل تفاضلی یکی از بهترین الگوریتم‌های بهینه‌سازی است که برای افزایش عملکرد الگوریتم‌های هوش مصنوعی استفاده می‌شود. در مطالعه حاضر، الگوریتم بهینه‌سازی تکامل تفاضلی باعث بهبود عملکرد مدل ماشین آموزش نیرومند خواهد شد و انعطاف پذیری مدل‌های هوش مصنوعی را به شکل قابل‌ملاحظه‌ای افزایش می‌دهد. این ابزار بهینه‌سازی مانع از بهینه‌سازی محلی خواهد شد و مقادیر بهینه را در کل دامنه مورد مطالعه پیدا خواهد کرد.

ماشین آموزش نیرومند خود تطبیقی^۲ (SAELM)

استفاده از الگوریتم تکامل تفاضلی به‌صورت خود تطبیقی توانایی غلبه بر محدودیت‌های موجود مانند پارامترهای کنترل در الگوریتم، انتخاب استراتژی بردار trial را داراست. از این‌رو، الگوریتم ماشین آموزش نیرومند خود تطبیقی (SAELM) جهت بهینه‌سازی وزن‌های ورودی شبکه و بایاس‌های نود مخفی، توسط کائو و همکاران (۲۰۱۲) ارائه شده است. با داشتن مجموعه داده‌های آموزشی، تعداد L گره مخفی و تابع فعال‌سازی $g(x)$ ، می‌توان ماشین آموزش نیرومند خود تطبیقی را فرمول‌نویسی کرد. بدین منظور، ابتدا جمعیت اولیه با استفاده از بردارهای جمعیت (NP) که نودهای مخفی را در بر می‌گیرند.

نهایتاً وزن‌ها را می‌توان از رابطه زیر محاسبه کرد (هووانگ و همکاران ۲۰۰۶).

$$\beta = HT \quad (7)$$

که در آن:

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_1, b_1, x_1) \dots G(a_L, b_L, x_L) \\ \dots \\ G(a_1, b_1, x_N) \dots G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (8)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad \text{and} \quad T = \begin{bmatrix} T_1^T \\ \vdots \\ T_L^T \end{bmatrix}_{L \times m} \quad (9)$$

که $\tilde{a} = a_1, \dots, a_L$; $\tilde{b} = b_1, \dots, b_L$; $\tilde{x} = x_1, \dots, x_L$ بردار وزن بین نرون‌های لایه‌های مخفی و لایه پنهان و H' شبه معکوس Moore-Penrose ماتریس H است. T بردار بین وزن‌های نمونه-های آموزشی است. با توجه به توضیحات ارائه شده می‌توان گفت که آموزش ELM شامل دو مرحله است: مرحله اول، اختصاص تصادفی وزن‌ها و بایاس‌ها به نرون‌های لایه پنهان و محاسبه خروجی لایه پنهان ماتریس H و مرحله دوم، محاسبه وزن‌های خروجی با استفاده از شبه معکوس Moore-Penrose ماتریس H و مقادیرهدف برای نمونه‌های آموزشی مختلف. روند آموزش جهت پیدا کردن شبه معکوس Moore-Pensore ماتریس لایه پنهان (H)، سریع است به‌طوری‌که از سرعت بالاتری نسبت به الگوریتم‌های مبتنی بر تکرار رایج مانند لونیبرگ-مارکوآردت که در آن هیچ نوع روالی از بهینه‌سازی غیرخطی را در بر نمی‌گیرد، برخوردار است. بنابراین زمان آموزش شبکه به‌طور قابل‌توجهی کاهش می‌یابد (Huang, 2006). مدل ELM با استفاده از تعداد زیادی از پیش‌بینی فضای ورودی تصافی غیرخطی کار می‌کند به‌طوری‌که هر نرون با یک نمونه تصادفی منفرد در ارتباط است.

تکامل تفاضلی

روش بهینه‌سازی تکامل تفاضلی (DE) یکی از تکنیک‌های نسبتاً جدید در زمینه بهینه‌سازی فراکاوشی است که توسط استورن و پرایس (۱۹۹۷) ارائه شده است. در سال‌های اخیر

² Self-Adaptive Extreme Learning Machine

تبدیل موجک

مشخصات اصلی تبدیل موجک این است که این تبدیلی توانایی به دست آوردن اطلاعات در زمان، تناوب و موقعیت را به طور همزمان، دارا است (میسیتیت و همکاران، ۱۹۹۶). تبدیل موجک پیوسته توانایی عملکرد در هر مقیاس را دارا است هر چند که محاسبه ضرایب موجک در هر مقیاس بسیار مشکل است و نیازمند زمان محاسباتی بالا و تولید حجم زیادی داده، می باشد. در انفضال تبدیل موجک تنها یک زیرمجموعه از مقیاس ها و موقعیت ها به منظور انجام محاسبات، انتخاب می شود. ورودی های مدل باید تعیین شوند که به صورت تأخیرهای موثر داده های سری زمانی ارائه می شود. در این مطالعه از تابع خود همبستگی جهت تعیین تأخیرهای موثر استفاده می شود (شکل ۲). با توجه به نمودارهای ACF با همان توابع خودهمبستگی ارائه شده، ورودی های مختلفی برای هر یک از پارامترهای مورد مطالعه در این پژوهش به شرح زیر ارائه می شود.

داده های مورد استفاده در این تحقیق جزو داده های سری زمانی هستند که بر خلاف داده های معمولی دارای نوسان و دوره بازگشت هستند. تبدیل موجک در این مطالعه برای نوسان گیری فرکانس های داده های سری زمانی استفاده شده است. علاوه بر این، همان طور که مشاهده خواهید کرد تبدیل موجک دقت مدل های هوش مصنوعی را نیز به شکل محسوسی بهبود خواهد داد. به طور کلی، موجک دسته ای از توابع ریاضی است که برای تجزیه سیگنال پیوسته به مولفه های فرکانسی آن به کار می رود و توانایی بهینه سازی و افزایش دقت مدل های هوش مصنوعی را نیز دارد. این روش یک آنالیز طیفی مستقل از زمان است که به منظور توصیف مقیاس زمانی فرایندها و روابط آنها، سری های زمانی را در فضای زمان-فرکانس از هم جدا می کند. تبدیل موجک همانند تبدیل فوریه، سری زمانی را به صورت ترکیب خطی از چند تابع اصلی (base)، در نظر می گیرد. یکی از

GWL:

$$M1: GWL(t) = f(GWL(t-1))$$

$$M2: GWL(t) = f(GWL(t-1), GWL(t-2))$$

$$M3: GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3))$$

$$M4: GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3), GWL(t-4))$$

(۱۰)

CL:

$$M1: CL(t) = f(CL(t-1))$$

$$M2: CL(t) = f(CL(t-1), CL(t-2))$$

$$M3: CL(t) = f(CL(t-1), CL(t-2), CL(t-3))$$

$$M4: CL(t) = f(CL(t-1), CL(t-2), CL(t-3), CL(t-4))$$

$$M5: CL(t) = f(CL(t-1), CL(t-12))$$

$$M6: CL(t) = f(CL(t-1), CL(t-2), CL(t-12))$$

$$M7: CL(t) = f(CL(t-1), CL(t-2), CL(t-3), CL(t-12))$$

$$M8: CL(t) = f(CL(t-1), CL(t-2), CL(t-3), CL(t-4), CL(t-12))$$

(۱۱)

HCO₃:

$$M1: HCO_3(t) = f(HCO_3(t-1))$$

$$M2: HCO_3(t) = f(HCO_3(t-1), HCO_3(t-2))$$

$$M3: HCO_3(t) = f(HCO_3(t-1), HCO_3(t-2), HCO_3(t-3))$$

$$M4: HCO_3(t) = f(HCO_3(t-1), HCO_3(t-2), HCO_3(t-3), HCO_3(t-4))$$

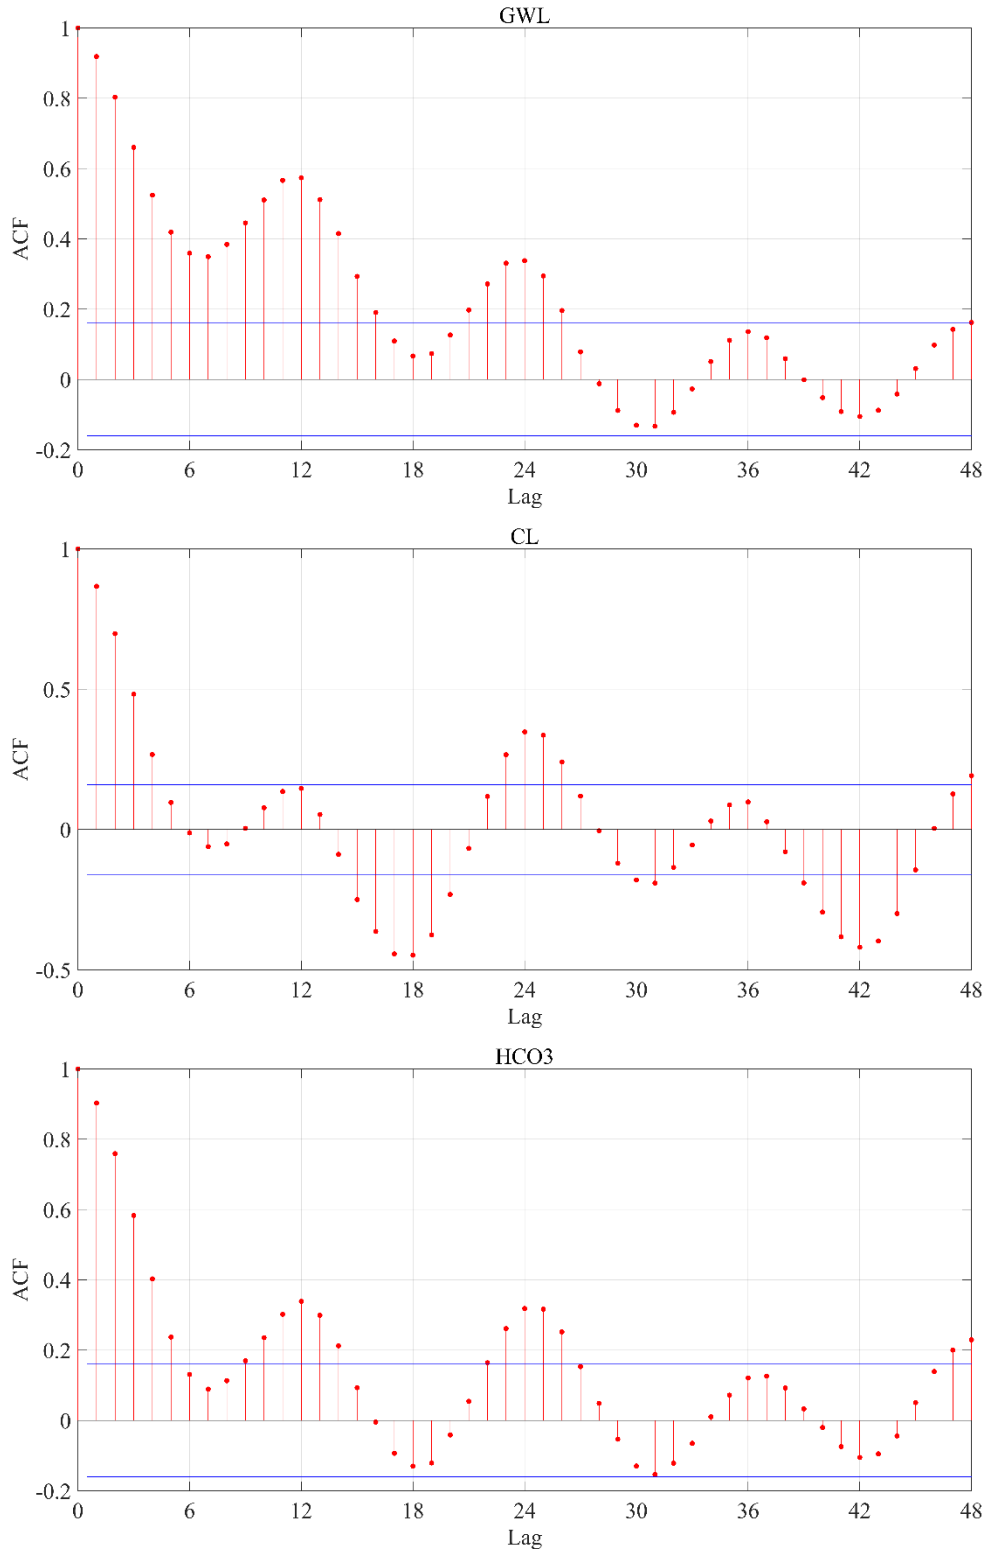
$$M5: HCO_3(t) = f(HCO_3(t-1), HCO_3(t-12))$$

$$M6: HCO_3(t) = f(HCO_3(t-1), HCO_3(t-2), HCO_3(t-12))$$

$$M7: HCO_3(t) = f(HCO_3(t-1), HCO_3(t-2), HCO_3(t-3), HCO_3(t-12))$$

$$M8: HCO_3(t) = f(HCO_3(t-1), HCO_3(t-2), HCO_3(t-3), HCO_3(t-4), HCO_3(t-12))$$

(۱۲)



شکل ۲- نمودارهای تابع خود همبستگی برای داده‌های سری زمانی پارامترهای کمی و کیفی مورد مطالعه در این پژوهش

و NSC به عدد یک به معنای همبستگی بالای مدل عددی با مقادیر مشاهداتی است اما نزدیک بود مقادیر RMSE، SI و MAE به صفر به معنای کم بودن خطای مدل عددی و دقت بالای آن می‌باشد. لازم به ذکر است که در این مطالعه مقادیر تراز آب زیرزمینی، CI و HCO₃ در یک بازه زمانی ۱۳ ساله از سال ۲۰۰۵ تا ۲۰۱۸ به صورت ماهانه مورد بررسی قرار گرفته‌اند. همچنین، ده سال از این مقادیر مشاهداتی برای آموزش و ۳ سال برای آزمون مدل‌های هوش مصنوعی استفاده گردید. در ادامه تنها نتایج حالت آزمون ارائه می‌گردد.

نتایج و بحث

تراز آب زیرزمینی

در این بخش به ارزیابی مدل‌های مختلف SAELM و WSAELM برای پیش‌بینی GWL پرداخته می‌شود. با توجه به معادله (۱۰)، چهار مدل SAELM و WSAELM توسعه داده شده‌اند. برای ۱ SAELM، مقادیر RMSE، MAE و VAF به ترتیب مساوی با ۰/۶۵۸، ۰/۵۰۱ و ۸۰/۲۷۷ هستند. این در حالی است که مقادیر NSC برای مدل‌های ۲ SAELM و ۳ SAELM به ترتیب مساوی با ۰/۸۰۷ و ۰/۸۴۲ می‌باشند. مقدار شاخص‌های آماری RMSE، R و SI برای مدل ۴ SAELM به ترتیب مساوی با ۰/۵۵۴، ۰/۹۲۸ و ۰/۰۰۴ به دست آمده‌اند. این در حالی است که مقدار شاخص آماری VAF برای مدل‌های ۱ WSAELM و ۲ WSAELM به ترتیب برابر ۸۵/۷۳۱ و ۹۶/۴۴۵ هستند. برای مدل ۳ WSAELM نیز مقادیر RMSE، MAE و NSC به ترتیب مساوی با ۰/۳۱۱، ۰/۲۵۱ و ۰/۹۵۶ تخمین زده شده‌اند. مقادیر شاخص‌های R، VAF و SI برای مدل ۴ WSAELM نیز به ترتیب برابر با ۰/۹۸۸، ۹۷/۴۵۰ و ۰/۰۰۲ می‌باشند. نتایج شاخص‌های آماری محاسبه شده برای مدل‌های SAELM و WSAELM جهت شبیه‌سازی GWL در شکل ۳ به تصویر کشیده شده است.

به بیان دیگر، در این مطالعه برای توسعه مدل‌های هوش مصنوعی مختلف از تأخیرهای موثر داده‌های سری زمانی که توسط تابع خودهمبستگی شناسایی شدند استفاده گردید. به بیان دیگر، مدل‌های هوش مصنوعی از ترکیب تأخیرهای موثر داده‌های سری زمانی تولید شدند.

معیارهای بررسی مدل‌های هوش مصنوعی

در این مقاله، برای ارزیابی دقت مدل‌های عددی معرفی شده از شاخص‌های آماری ضریب همبستگی (R)، شاخص عملکرد (VAF)، خطای مربعات میانگین ریشه ($RMSE$)، شاخص پراکندگی (SI)، خطای مطلق میانگین (MAE) و ضریب بهره‌وری نش ساتکلیف (NSC) به صورت زیر استفاده می‌گردد (عظیمی و همکاران ۲۰۱۸).

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (13)$$

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)}\right) \times 100 \quad (14)$$

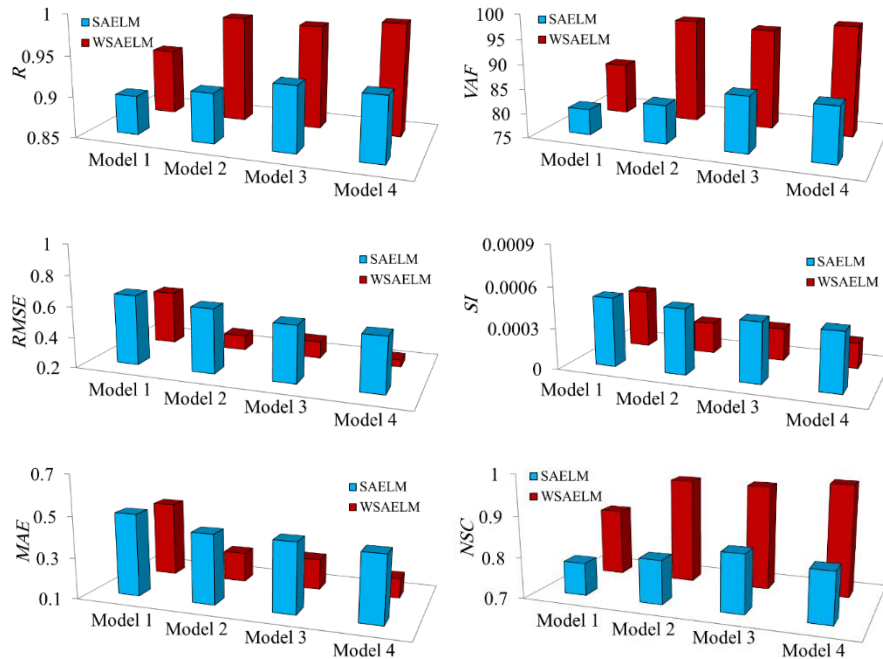
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad (15)$$

$$SI = \frac{RMSE}{\bar{O}} \quad (16)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad (17)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (18)$$

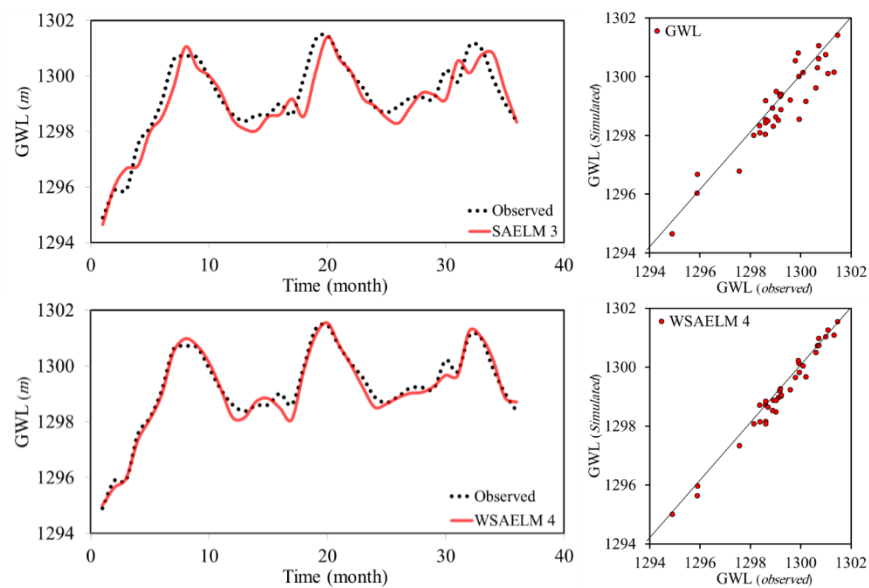
در اینجا O_i مقادیر مشاهداتی، F_i مقادیر تراز پیش‌بینی شده به وسیله مدل‌های عددی، \bar{O} میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی است. نزدیک بودن شاخص‌های آماری R



شکل ۳- شاخص‌های آماری محاسبه شده برای شبیه‌سازی تراز آب زیرزمینی توسط مدل‌های مختلف SAELEM و WSAELM

است که مدل 4 WSAELM نیز دقت بهتری در مقایسه با مدل 3 SAELEM دارد. بنابراین برای شبیه‌سازی GWL، مدل 4 WSAELM به‌عنوان مدل برتر انتخاب می‌شود. نتایج شبیه‌سازی GWL توسط مدل‌های 3 SAELEM و 4 WSAELM به‌همراه نمودارهای پراکندگی آنها در شکل 4 نشان داده شده است.

بر اساس نتایج شبیه‌سازی GWL توسط مدل‌های SAELEM و WSAELM، مدل 3 SAELEM و 4 WSAELM به‌عنوان مدل‌های برتر شناسایی می‌شوند. مدل 3 SAELEM مقادیر GWL را بر حسب تأخیرهای (t-1)، (t-2) و (t-3) شبیه‌سازی می‌کند. این در حالی است که مدل 4 WSAELM مقادیر تابع هدف را بر حسب (t-1)، (t-2)، (t-3) و (t-4) پیش‌بینی می‌نماید. لازم به ذکر

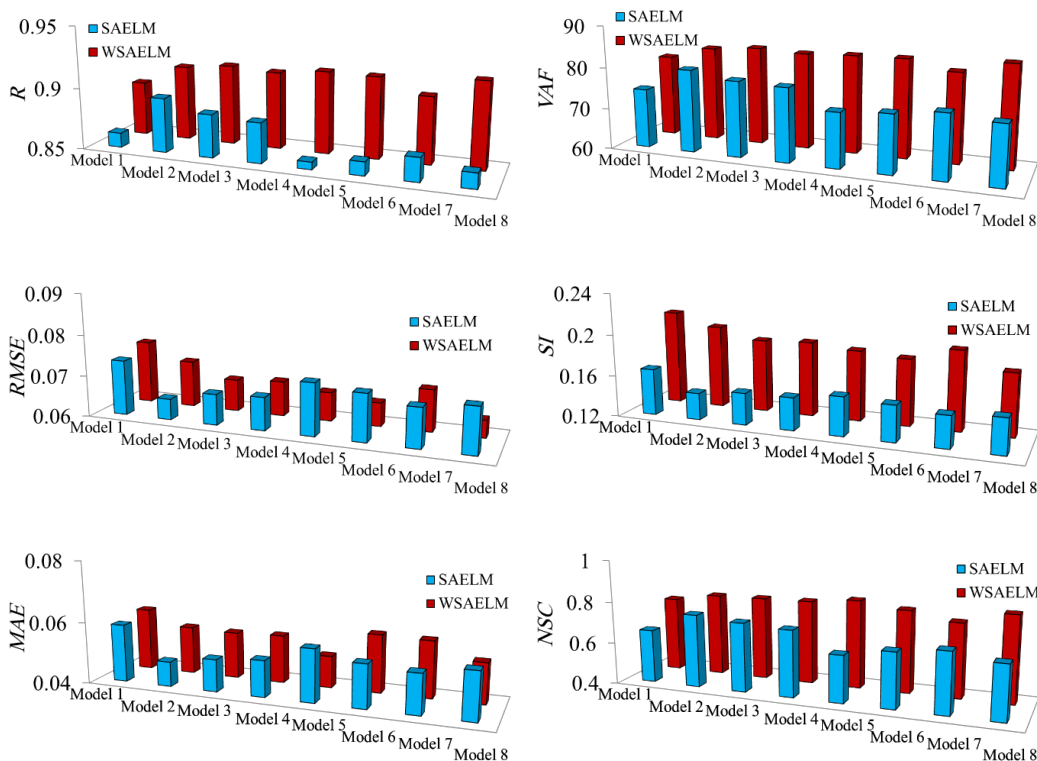


شکل ۴- مقایسه تراز آب زیرزمینی مشاهداتی با مقادیر شبیه‌سازی شده توسط مدل‌های برتر

کلر

همچنین، مقدار شاخص آماری NSC برای مدل‌های SAELM 7 و 8 به ترتیب برابر با ۰/۶۹۲ و ۰/۶۶۱ می‌باشند. این در حالی است که برای مدل‌های 1 و 2، WSAELM 3 و 4 مقدار ضریب همبستگی به ترتیب مساوی با ۰/۸۹۴، ۰/۹۱۱ و ۰/۹۱۵ محاسبه شده‌اند. برای مدل 7 WSAELM مقادیر RMSE، SI و MAE به ترتیب برابر با ۰/۰۷۰، ۰/۱۹۷ و ۰/۰۵۸ تخمین زده شده‌اند. علاوه بر این، مقادیر شاخص‌های NSC، VAF و R برای مدل 8 WSAELM به ترتیب مساوی با ۰/۸۱۶، ۰/۴۹۸ و ۰/۹۱۹ می‌باشند.

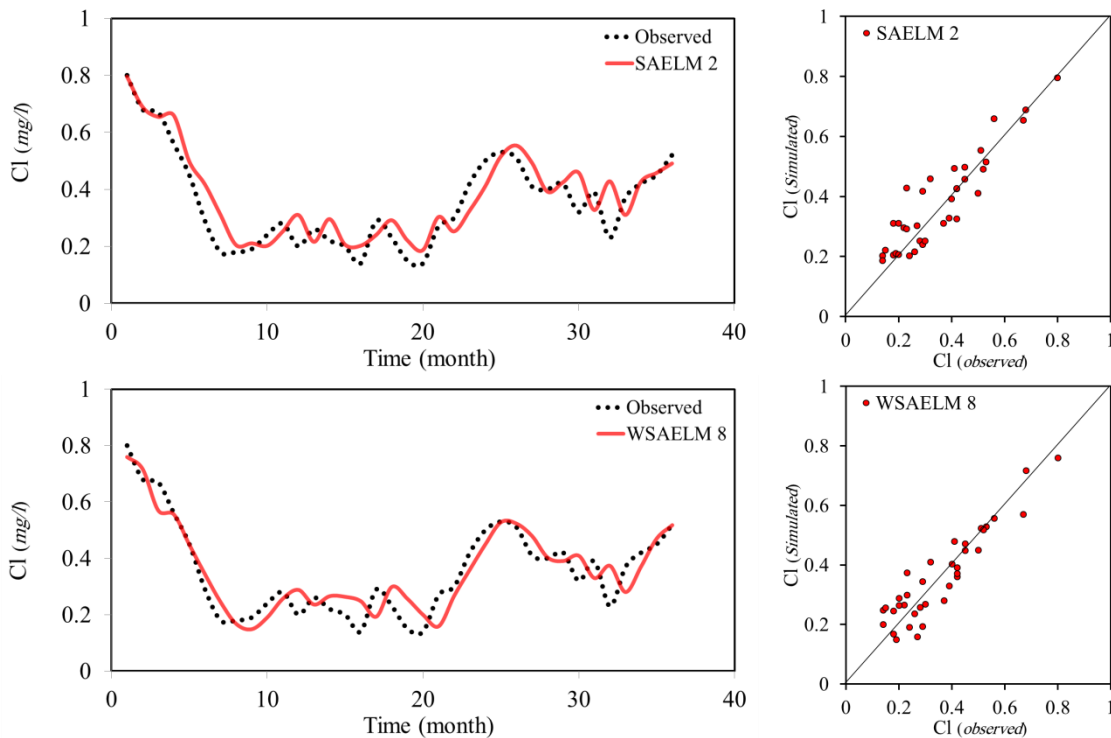
در این قسمت به ارزیابی مدل‌های SAELM و WSAELM مختلف برای پیش‌بینی CI پرداخته می‌شود. با توجه به معادله (۱۱)، هشت مدل متمایز SAELM و WSAELM تعریف شده‌اند که نتایج شاخص‌های آماری محاسبه شده برای آنها در شکل ۵ قابل مشاهده است. بر اساس نتایج شبیه‌سازی‌ها، مقدار R برای مدل‌های 1 و 2، SAELM 3 و 4، SAELM 5 و 6 مساوی با ۰/۸۶۲، ۰/۸۹۴ و ۰/۸۸۵ به دست آمده‌اند. لازم به ذکر است که برای مدل‌های 4، 5، 6 و 7، SAELM 6 و 7 مقدار MAE به ترتیب برابر با ۰/۰۵۲، ۰/۰۵۷ و ۰/۰۵۴ هستند.



شکل ۵- شاخص‌های آماری محاسبه شده برای شبیه‌سازی کلر توسط مدل‌های مختلف SAELM و WSAELM

تأخیرهای (t-1)، (t-2)، (t-3)، (t-4) و (t-12) پیش‌بینی کرده‌اند. علاوه بر این دقت مدل 8 WSAELM به شکل قابل ملاحظه‌ای از مدل 2 SAELM بیشتر بود. مقایسه مقادیر CI شبیه‌سازی شده توسط مدل‌های 2 SAELM و 8 WSAELM با مقادیر مشاهده‌ای به همراه نمودارهای پراکندگی آنها در شکل ۶ نشان داده شده‌اند.

با توجه به شبیه‌سازی پارامتر CI توسط مدل‌های هوش مصنوعی، در میان مدل‌های SAELM 2 و 3 و در میان مدل‌های WSAELM 8 نیز مدل 8 WSAELM دارای بیشترین دقت و کمترین مقدار خطا هستند. مدل 2 SAELM مقادیر CI را بر حسب تأخیرهای (t-1) و (t-2) شبیه‌سازی می‌نماید. این در حالی است که مدل 8 WSAELM مقادیر تابع هدف را توسط



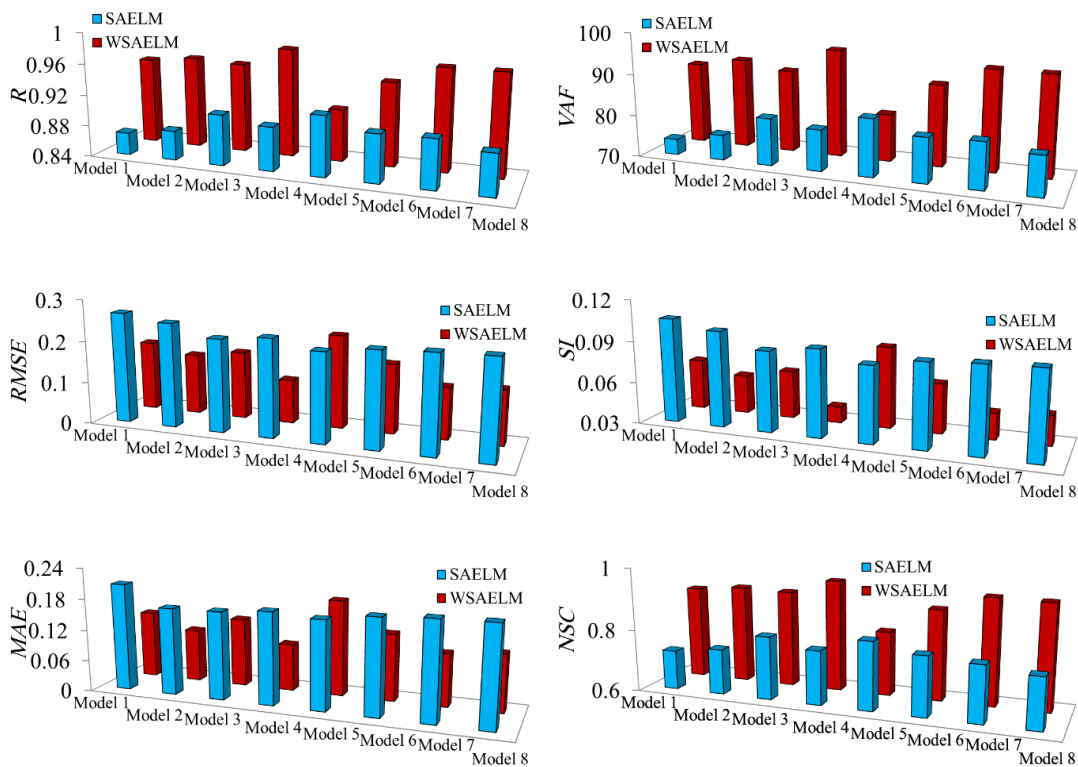
شکل ۶- مقایسه مقادیر کلر مشاهداتی با مقادیر شبیه‌سازی شده توسط مدل‌های برتر

است که مقدار NSC برای مدل‌های WSAELM، WSAELM 5، WSAELM 6 و WSAELM 7 به ترتیب برابر با ۰/۸۹۰، ۰/۸۳۹ و ۰/۹۳۹ تخمین زده شده‌اند. برای مدل WSAELM 8 نیز مقادیر MAE، RMSE و R به ترتیب مساوی با ۰/۱۱۰، ۰/۱۳۰ و ۰/۹۷۰ محاسبه شده‌اند.

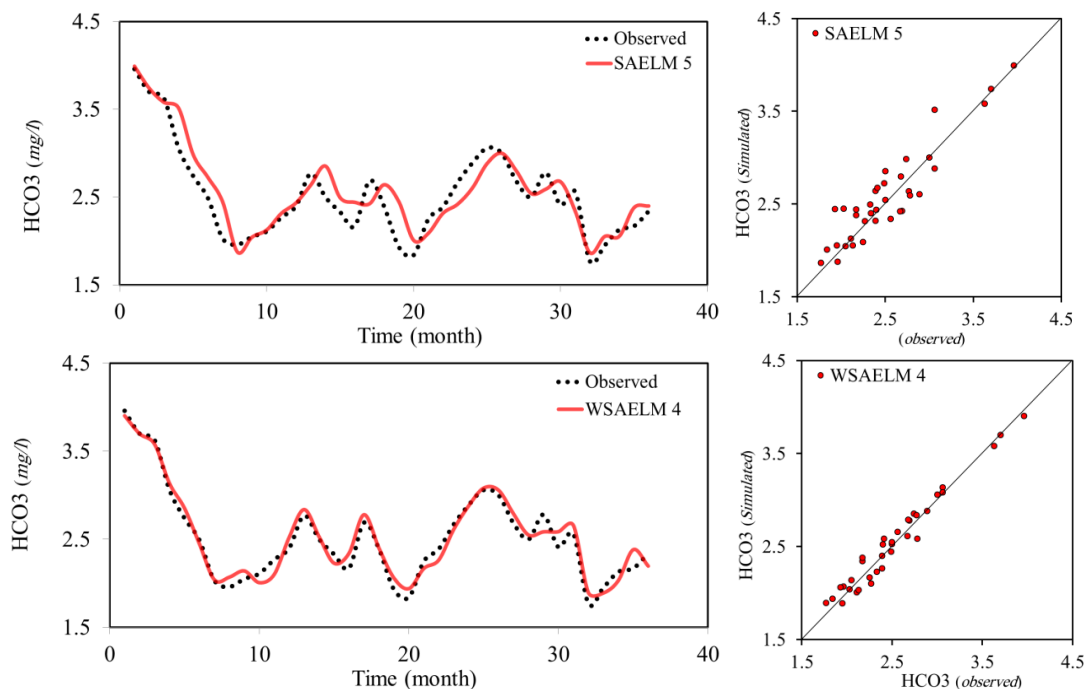
با توجه به شبیه‌سازی HCO_3 توسط مدل‌های مختلف هوش مصنوعی، مدل‌های SAELM 5 و WSAELM 4 به عنوان مدل‌های برتر معرفی می‌شوند. این مدل‌ها مقادیر تابع هدف را با کمترین مقدار خطا و بیشترین همبستگی با مقادیر مشاهداتی شبیه‌سازی می‌کنند. مدل SAELM 5 مقادیر HCO_3 را بر حسب تأخیرهای (t-1) و (t-12) شبیه‌سازی می‌نماید. این در حالی است که مدل WSAELM 4 مقادیر تابع هدف را بر حسب تأخیرهای (t-1)، (t-2)، (t-3) و (t-4) پیش‌بینی می‌نماید. مقادیر HCO_3 شبیه‌سازی شده توسط این دو مدل برتر با مقادیر مشاهداتی به همراه نمودارهای پراکندگی آنها در شکل ۸ قابل مشاهده می‌باشد.

بی‌کرنات

در این قسمت به ارزیابی دقت مدل‌های SAELM و WSAELM برای شبیه‌سازی HCO_3 پرداخته می‌شود. با توجه به معادله (۱۲)، هشت مدل SAELM و WSAELM توسعه داده شده‌اند. در شکل ۷ نتایج شاخص‌های آماری محاسبه شده توسط این مدل‌ها به تصویر کشیده شده است. به عنوان مثال، مقدار ضریب همبستگی و شاخص پراکندگی برای مدل SAELM 1 به ترتیب مساوی با ۰/۸۶۹ و ۰/۱۰۶ به دست آمده‌اند. این در حالی است که مقدار VAF برای مدل‌های SAELM 2، SAELM 3 و SAELM 4 به ترتیب برابر با ۰/۷۶/۰۳۰، ۰/۸۱/۲۹۷ و ۰/۷۹/۸۲۲ به دست آمده‌اند. لازم به ذکر است که برای مدل SAELM 5 نیز مقادیر NSC، RMSE و R به ترتیب مساوی با ۰/۸۱۸، ۰/۲۱۳ و ۰/۹۱۷ هستند. در مقابل، برای مدل‌های WSAELM 1، WSAELM 2 و WSAELM 3 مقدار شاخص آماری NSC به ترتیب مساوی با ۰/۸۹۹، ۰/۹۱۳ و ۰/۹۰۹ هستند. این در حالی



شکل ۷- شاخص‌های آماری محاسبه شده برای شبیه‌سازی بی‌کربنات توسط مدل‌های مختلف SAELM و WSAELM



شکل ۸- مقایسه مقادیر بی‌کربنات مشاهده‌ای با مقادیر شبیه‌سازی شده توسط مدل‌های برتر

سنجش خطای پیش‌بینی شده توسط مدل‌های عددی و بررسی نحوه عملکرد این مدل‌ها اجرا می‌شود. به‌طور کلی خطای پیش‌بینی شده توسط مدل عددی برابر است با مقادیر شبیه‌سازی شده توسط مدل عددی (P_i) منهای مقادیر مشاهداتی (O_i) است ($e_i = P_i - O_i$). همچنین، میانگین خطای پیش‌بینی شده به صورت $\bar{e} = \sum_{i=1}^n e_i$ محاسبه می‌شود. همچنین، انحراف استاندارد مقادیر خطای پیش‌بینی شده به صورت $S_e = \sqrt{\sum_{i=1}^n (e_i - \bar{e})^2 / n - 1}$ می‌باشد. لازم به ذکر است که منفی بودن مقدار \bar{e} نشان می‌دهد که مدل عددی دارای عملکردی کمتر از واقعی است و مثبت بودن \bar{e} به معنای بیشتر از واقعی بودن مدل عددی است. همچنین، با استفاده از پارامترهای \bar{e} و S_e یک باند اطمینان در اطراف مقادیر خطای پیش‌بینی ایجاد می‌شود. سپس با استفاده از $\pm 1/6 S_e$ به صورت تقریبی منجر به 95% باند اطمینان می‌گردد (عظیمی و همکاران ۲۰۱۸). پارامترهای تحلیل عدم قطعیت مدل‌های برتر در جدول ۱ قابل مشاهده است. در این جدول‌ها عرض باند عدم قطعیت با WUB و 95% خطای پیش‌بینی شده با 95% PEI نشان داده می‌شود. با توجه به نتایج تحلیل عدم قطعیت، مدل WSAELM 4 برای شبیه‌سازی GWL دارای عملکردی بیشتر از واقعی هستند در حالی که این مدل هوش مصنوعی برای تخمین CI و HCO₃ عملکردی کمتر از دارد. برای شبیه‌سازی GWL، CI و HCO₃ توسط این مدل، مقدار WUB به ترتیب مساوی با ۰/۰۸۱، ۰/۰۲۳ و ۰/۰۳۵ به دست آمدند.

برای شبیه‌سازی تراز آب زیرزمینی (GWL)، مدل WSAELM 4 به‌عنوان مدل برتر انتخاب می‌شود. لازم به ذکر است که تأخیرهای (t-1)، (t-2)، (t-3) و (t-4) نیز به‌عنوان موثرترین تأخیرها برای پیش‌بینی GWL توسط مدل برتر معرفی می‌گردند. علاوه بر این، مدل WSAELM 8 نیز به‌عنوان بهترین مدل هوش مصنوعی جهت تخمین CI معرفی می‌گردد. همچنین، تأخیرهای (t-1)، (t-2)، (t-3)، (t-4) و (t-12) به‌عنوان تأثیرگذارترین تأخیرهای ورودی داده‌های سری زمانی جهت شبیه‌سازی CI انتخاب می‌شوند. برای پیش‌بینی HCO₃ نیز مدل WSAELM 4 به‌عنوان بهترین مدل هوش مصنوعی معرفی می‌گردد. لازم به یادآوری است که مدل مذکور مقادیر بی‌کربنات‌ها را با استفاده از تأخیرهای (t-1)، (t-2)، (t-3) و (t-4) مدل‌سازی کرد بنابراین این تأخیرها تأثیرگذارترین تأخیرهای داده‌های سری زمانی جهت پیش‌بینی بی‌کربنات هستند.

تحلیل عدم قطعیت

در ادامه برای بررسی عملکرد مدل‌های هوش مصنوعی یک تحلیل عدم قطعیت اجرا می‌شود. در این قسمت با انجام یک تحلیل عدم قطعیت نحوه عملکرد مدل‌های هوش مصنوعی WSAELM که مقادیر GWL، CI، HCO₃ توسط آنها تخمین زده شده، مورد ارزیابی قرار خواهد گرفت. به‌طور کلی تحلیل عدم قطعیت یک تحلیل کارآمد جهت ارزیابی عملکرد مدل‌های عددی استفاده می‌شوند. به‌عبارت دیگر، تحلیل عدم قطعیت برای

جدول ۱- نتایج تحلیل عدم قطعیت مدل WSAELM 4

| Parameter | Model | \bar{e} | S_e | WUB | 95% PEI |
|------------------|----------|-----------|-------|--------|-----------------|
| GWL | WSAELM 4 | ۰/۰۸۲ | ۰/۰۴۰ | -۰/۰۸۱ | ۰/۰۰۱ تا ۰/۱۶۲ |
| CI | WSAELM 4 | -۰/۰۰۴ | ۰/۰۱۱ | -۰/۰۲۳ | -۰/۰۲۷ تا ۰/۰۱۸ |
| HCO ₃ | WSAELM 4 | -۰/۰۲۳ | ۰/۰۱۷ | -۰/۰۳۵ | -۰/۰۵۸ تا ۰/۰۱۱ |

هشت مدل نیز برای پیش‌بینی پارامترهای Cl و HCO_3 تعریف گردید.

علاوه بر این، نتایج تحلیل حساسیت نشان داد که مدل‌های هیبریدی هوش مصنوعی مقادیر کمی و کیفی آب زیرزمینی را با دقت مناسبی شبیه‌سازی کردند. به‌عنوان مثال، شاخص‌های آماری RMSE ، MAE و R برای مدل شبیه‌سازی HCO_3 توسط مدل برتر به ترتیب مساوی با ۰/۰۹۱، ۰/۱۰۵ و ۰/۹۷۹ محاسبه شدند.

علاوه بر این، تأخیرهای $(t-1)$ ، $(t-2)$ ، $(t-3)$ ، $(t-4)$ و $(t-12)$ به‌عنوان تأثیرگذارترین تأخیرهای ورودی داده‌های سری زمانی جهت شبیه‌سازی Cl معرفی شدند.

لازم به ذکر است که مدل هوش مصنوعی برتر مقادیر GWL را با یک عملکرد بیشتر از واقعی و مقادیر Cl و HCO_3 را با عملکردی کمتر از واقعی پیش‌بینی کرد.

این مطالعه نشان داد که مدل‌های هوش مصنوعی ابزاری مناسب و قابل‌اعتماد برای شبیه‌سازی پارامترهای کمی و کیفی آب‌های زیر زمینی محسوب می‌شوند که می‌توان به کمک آنها هزینه‌های مربوط به مطالعات میدانی و شبیه‌سازی‌های سه‌بعدی را کاهش داد. پیشنهاد می‌شود که در مطالعات آتی عملکرد مدل‌های عددی که توانایی شبیه‌سازی سه‌بعدی پارامترهای کمی و کیفی آب زیر زمینی را دارند با مدل‌های هوش مصنوعی مقایسه شوند.

منابع

ترابی، ح، نصرالهی، ع.ح، دهقانی، ر، ۱۳۹۸. ارزیابی مدل شبکه عصبی موجک در پیش‌بینی منابع آب زیرزمینی استان لرستان. هیدروژئولوژی، انتشار آنلاین از تاریخ ۲۴ مهر ۱۳۹۸. دانشور وثوقی، ف، ۱۳۹۹. استفاده از رفع نویز موجکی در بررسی روند تراز آب زیرزمینی (مطالعه موردی: دشت اردبیل). هیدروژئولوژی، دوره ۵، شماره ۱، ۶۱-۷۲.

دانشور وثوقی، ف، کریمی، ع، ۱۳۹۷. استفاده از روش‌های پیش پردازش SOM و تبدیل موجک در پیش‌بینی تراز آب زیرزمینی (مطالعه موردی: دشت آذرشهر). هیدروژئولوژی، دوره ۳، شماره ۱، ۱۵-۳۲.

تغییرات سطح آب زیرزمینی و همچنین میزان بارندگی ماهیانه در ناحیه مورد مطالعه برای ۱۳ سال آبی بررسی گردید که براساس نتایج به‌دست آمده مشخص شد که روند تغییرات آب زیرزمینی در دشت در این بازه زمانی سیر نزولی داشته به‌گونه‌ای که طی این مدت حدود ۵/۷۷ متر افت سطح آب زیرزمینی در مخزن مشاهده شد که با بررسی کلی می‌توان به این نتیجه رسید که این امر ناشی از خشکسالی‌های چند ساله اخیر و همچنین افزایش میزان برداشت بوده است. در سه سال اخیر این بازه زمانی، روند افت سطح آب تقریباً دارای شدت کمتری بوده و سفره در سطح بسیار پائین‌تری نسبت به سال‌های قبل به تعادل نسبی رسید. لازم به ذکر است که تعداد مقادیر برداشت شده برای ۱۵۶ ماه متوالی در قالب سری زمانی مورد استفاده قرار گرفتند که تأخیرهای شماره $(t-1)$ ، $(t-2)$ ، $(t-3)$ و $(t-4)$ موثرترین تأخیرهای داده‌های سری زمانی در این مدت شناسایی شدند.

نتیجه‌گیری

در این مطالعه، دو مدل هیبریدی هوش مصنوعی برای شبیه‌سازی داده‌های سری زمانی پارامترهای کمی (تراز آب زیرزمینی) و کیفی (کلر و بی‌کربنات) آب زیرزمینی درون یک چاه مشاهداتی واقع در شهر کرمانشاه، ایران، از سال ۲۰۰۵ تا ۲۰۱۸ به‌صورت ماهانه استفاده شدند. مهمترین مطالب این مطالعه به‌صورت زیر ارائه می‌شود:

- از ترکیب ماشین آموزش نیرومند (ELM)، تکامل تفاضلی (DE) و تبدیل موجک با هم ترکیب شدند و مدل‌های ماشین آموزش نیرومند خود تطبیقی (SAELM) و موجک-ماشین آموزش نیرومند خود تطبیقی (WSAELM) توسعه داده شدند.
- لازم به ذکر است که برای آموزش مدل‌های هوش مصنوعی از ۷۰ درصد مقادیر مشاهداتی استفاده گردید و برای آزمون این مدل‌ها از ۳۰ درصد باقیمانده بهره گرفته شد.
- در ابتدا، توسط تابع خود همبستگی تأخیرهای موثر داده‌های سری زمانی شناسایی شدند و با ترکیب این تأخیرها، چهار مدل SAELM و WSAELM برای شبیه‌سازی GWL و

- network (ANFIS) and Arc-Gis. *MethodsX*, 6: 1021-1029.
- Huang, G.B., Zhu, Q.Y., Siew, C.K., 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70(1): 489-501.
- Cao, J., Lin, Z., Huang, G.B., 2012. Self-adaptive evolutionary extreme learning machine. *Neural Process. Lett.* 36, 285-305.
- Storn, R., Price, K., 1997. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11(4): 341-359.
- Huang, G.B., Zhou, H., Ding, X., Zhang, R., 2012. Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2): 513-529.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Gharabaghi, B., Khoshbin, F., 2018. Evolutionary design of generalized group method of data handling-type neural network for estimating the hydraulic jump roller length. *Acta Mechanica*, 229(3): 1197-1214.
- نیکبخت، ج.، نوری، س. ۱۳۹۵. پیش‌بینی تراز آب زیرزمینی با کمک شبکه‌های موجک-عصبی (مطالعه موردی: دشت مراغه-آذربایجان شرقی). *هیدروژئولوژی*، دوره ۱، شماره ۱، ۲۹-۴۳.
- Sivapragasam, C., Kannabiran, K., Karthik G., Raja, S., 2015. Assessing suitability of GP modeling for groundwater level. *Aquatic Procedia*, 4: 693-699.
- Nourani, V., Alami, M.T., Vousoughi, F.D., 2016. Hybrid of SOM-clustering method and wavelet-ANFIS approach to model and infill missing groundwater level data. *Journal of Hydrologic Engineering*, 21(9): 05016018.
- Zhang, N., Xiao, C., Liu, B., Liang, X., 2017. Groundwater depth predictions by GSM, RBF, and ANFIS models: a comparative assessment. *Arabian Journal of Geosciences*, 10. <https://doi.org/10.1007/s12517-017-2954-8>.
- Malekzadeh, M., Kardar, S., Shabanlou, S., 2019. Simulation of groundwater level using MODFLOW, extreme learning machine and Wavelet-Extreme Learning Machine models. *Groundwater for Sustainable Development*, 9: 100279. <https://doi.org/10.1016/j.gsd.2019.100279>.
- Huang, S., Liu, C., Wang, Y., Zhan, H., 2014. Multivariate analysis of the heterogeneous geochemical processes controlling arsenic enrichment in a shallow groundwater system. *Journal of Environmental Science and Health, Part A*, 49(4): 478-489.
- Barzegar, R., Fijani, E., Moghaddam, A.A., Tziritis, E., 2017. Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models. *Science of The Total Environment*, 599: 20-31.
- Kisi, O., Keshavarzi, A., Shiri, J., Zounemat-Kermani, M., Omran, E.S.E., 2017. Groundwater quality modeling using neuro-particle swarm optimization and neuro-differential evolution techniques. *Hydrology Research*, 48(6): 1508-1519.
- Mohammadrezapour, O., Kisi, O., Pourahmad, F., 2018. Fuzzy c-means and K-means clustering with genetic algorithm for identification of homogeneous regions of groundwater quality. *Neural Computing and Applications*, 32: 363-375.
- RadFard, M., Seif, M., Hashemi, A.H.G., Zarei, A., Saghi, M.H., Shalyari, N., Samaei, M.R., 2019. Protocol for the estimation of drinking water quality index (DWQI) in water resources: Artificial neural