پیش‌بینی تغییرات تراز آب زیرزمینی با استفاده از مدل ترکیبی موجک- ماشین آموزش نیرومند خودتطبیقی- چاه مشاهداتی سراب قنبر کرمانشاه

فریبرز یوسفوند* و سعید شعبانلو[۱]

(تاریخ دریافت: ۱۳۹۷/۹/۴ ؛ تاریخ پذیرش: ۱۳۹۸/۲/۳۱)

چکیده

در این مطالعه، سطح آب زیرزمینی در منطقه سراب قنبر- واقع در جنوب شهر کرمانشاه، کشور ایران- با استفاده از مدل موجک ماشین آموزش نیرومند خودتطبیقی (WA-SAELM) تخمین زده شد. برای توسعه مدل عددی از روش هوش مصنوعی و جدید ماشین آموزش نیرومند خودتطبیقی و تبدیل موجک استفاده شد. در ابتدا، با استفاده از تابع خودهمبستگی، خودهمبستگی نسبی و تأخیرهای مؤثر، هشت مدل مختلف SAELM و WA-SAELM متمایز توسعه داده شدند، سپس مقادیر تراز آب زیرزمینی چاه مشاهداتی نرمال‌سازی شدند. در ادامه، با تجزیه‌وتحلیل نتایج مدل‌سازی، بهینه‌ترین خانواده موجک برای مدل‌سازی انتخاب شد. با ارزیابی نتایج مدل‌های SAELM و WA-SAELM مشخص شد که مدل‌های WA-SAELM در مقایسه با مدل‌های SAELM مقادیر تابع هدف را با دقت بیشتری تخمین زدند. سپس مدل برتر بر اساس دقت آن در پیش‌بینی تراز آب زیرزمینی انتخاب شد. به‌عنوان مثال در حالت تست، مقادیر R، MAE و NSC برای مدل برتر به‌ترتیب برابر ۰/۹۹۵، ۰/۹۸۸ و ۰/۹۹۰ محاسبه شدند. همچنین برای مدل‌های عددی، تحلیل عدم قطعیت انجام و نشان داده شد که مدل برتر مقادیر مشاهداتی را کمتر از مقدار واقعی تخمین زده است.

واژه‌های کلیدی: تراز آب زیرزمینی، ماشین آموزش نیرومند خودتطبیقی، تحلیل عدم قطعیت، تبدیل موجک

۱. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

*: مسئول مکاتبات: fariborzyosefvand@gmail.com

www.SID.ir

Archive of SID

مقدمه

آب‌های زیرزمینی یکی از منابع آب شرب محسوب می‌شوند. به‌طور کلی، یافتن منابع آب جایگزین یک موضوع بحث‌برانگیز است که در بازه زمانی درازمدت مشکلات مختلفی همچون مهاجرت و تغییرات جمعیتی را در پی خواهد داشت. به‌دلیل اهمیت پیش‌بینی و تخمین تراز آب‌های زیرزمینی مطالعات مختلفی در این زمینه انجام شده است. همچنین به‌تازگی استفاده از تکنیک‌های مختلف هوش مصنوعی در پیش‌بینی تراز آب زیرزمینی به‌صورت گسترده مورد استفاده قرار گرفته‌اند. به‌عنوان مثال، سوریانارایانا و همکاران (۱۳) توسط یک مدل هیبریدی نوسان آب زیرزمینی درون آبخوان‌های واقع در شرق هندوستان را تخمین زدند. آنها از بردار پشتیبان و تبدیل موجک برای توسعه مدل هیبریدی مذکور استفاده کردند و مقادیر این روش را با شبکه عصبی مصنوعی مقایسه کردند. خاکی و همکاران (۵) نوسان تراز آب درون آبخوان‌های زیرزمینی واقع در مالزی در یک بازه زمانی هفت ساله را به‌وسیله مدل شبکه عصبی مصنوعی و انفیس شبیه‌سازی کردند. نتایج مطالعه آنها نشان داد که مدل انفیس دارای دقتی بیشتری برای تخمین تراز آب زیرزمینی بود. همچنین یوون و همکاران (۱۴) تغییرات تراز آب زیرزمینی دورن چاه‌های مشاهداتی واقع در کره جنوبی را توسط شبکه عصبی مصنوعی و ماشین بردار پشتیبان در یک بازه زمانی درازمدت شبیه‌سازی کردند. آنها با تجزیه‌وتحلیل نتایج مدل‌های خود نشان دادند که ماشین بردار پشتیبان دارای دقت بیشتری در مدل‌سازی نوسانات آب زیرزمینی بود. برزگر و همکاران (۱) دو مدل هیبریدی برای تخمین تغییرات سری زمانی آب زیرزمینی توسعه دادند. آنها مدل‌های روش دسته‌بندی گروهی داده‌ها و ماشین یادگیری نیرومند را با تبدیل موجک ترکیب کردند. همچنین آنها بیان کردند که مدل موجک دسته‌بندی گروهی داده‌ها دارای دقت بیشتری بود. ماکونگو و اودیو (۷) تراز آب زیرزمینی درون آبخوان‌هایی واقع در آفریقای جنوبی را توسط مدل‌های شناسایی سیستم شبیه‌سازی کردند. آنها نشان دادند که این مدل برای نواحی که فاقد دیتاهای کافی هستند مناسب بود. علاوه بر این، ملک‌زاده و همکاران (۸) تغییرات آب زیرزمینی در یک چاه مشاهداتی واقع در منطقه کبودر آهنگ همدان را توسط مدل‌های فرا ابتکاری هوش مصنوعی پیش‌بینی کردند. آنها نشان دادند که تبدیل موجک توانایی مدل‌سازی را به شکل قابل توجهی افزایش داد.

با بررسی مطالعات گذشته مشاهده می‌شود که تاکنون شبیه‌سازی تراز آب زیرزمینی توسط مدل موجک- ماشین آموزش نیرومند خود تطبیقی (WA-SAELM) انجام نشده است. در این مطالعه، تغییرات تراز آب زیرزمینی در منطقه جنوب شهر کرمانشاه واقع در ایران (سراب قنبر) توسط مدل نوین WA-SAELM تخمین زده می‌شود. به‌عبارت دیگر، نوسان تراز آب زیرزمینی چاه مشاهداتی واقع در منطقه سراب قنبر کرمانشاه- ایران در یک بازه زمانی ۱۳ ساله از سال ۲۰۰۲ تا ۲۰۱۵ به‌صورت متوسط ماهیانه در قالب سری زمانی توسط مدل بسیار قدرتمند WA-SAELM مدل‌سازی می‌شود.

مواد و روش‌ها

در بخش مواد و روش‌ها، ابتدا ناحیه مورد مطالعه مورد بررسی قرار می‌گیرد. سپس مدل ماشین آموزش نیرومند تشریح شده و در ادامه توضیحات مربوط به الگوریتم تکامل تفاضلی و ترکیب آن با ماشین آموزش نیرومند که خروجی آن ماشین آموزش نیرومند خود تطبیقی است، ارائه می‌شود. در قسمت پایانی بخش مواد و روش‌ها، تبدیل موجک که برای بهینه‌سازی ماشین آموزش نیرومند خود تطبیقی استفاده می‌شود به شکل مختصر معرفی می‌شود.

ناحیه مورد مطالعه

منطقه مطالعاتی در این مطالعه در منطقه سراب قنبر در جنوب شهر کرمانشاه واقع شده است. سراب قنبر دارای آب‌وهوای گرم و معتدل است. این ناحیه دارای زمستان‌های بارانی و تابستان‌های خنک است. در این منطقه میانگین سالانه دما در حدود ۱۲/۹ سانتی‌گراد و میانگین بارندگی تقریباً ۴۴۰ میلی‌متر

www.SID.ir

Archive of SID

است. مختصات جغرافیایی منطقه مذکور ۳۴/۲۸۷۰ درجه شمالی و ۴۷/۰۵۴۷ درجه شرقی است. در این مطالعه برای صحت‌سنجی مدل‌های هوش مصنوعی از چاه مشاهداتی واقع در این منطقه استفاده شد.

سرتاسر حاشیه شمالی و شرقی و قسمتی از حاشیه شمال غربی این دشت به‌وسیله آهک‌های کرتاسه که بیشتر نیز خاصیت کارستیک دارند، پوشیده شده است. قسمت‌های جنوب و جنوب شرقی و در بخشی از شمال غربی به ارتفاعاتی محدود می‌شود که دارای رخساره‌های گوناگون بوده و شامل رسوبات آذرین در جنوب شرقی وآهک سیلیسی و رادیولاریت درقسمت جنوب هستند. منطقه مورد مطالعه از نظر زمین‌شناسی جزء دو ساختار زون زاگرس و زون خرد شده است. این دو بخش به‌همراه دشت خوزستان تمامی ساختار زاگرس را تشکیل می‌دهد. قدیمی‌ترین واحد سنگی پیرامون دشت میاندربند متعلق به ژوراسیک است. با توجه به این مسئله ضخامت، نوع و دانه‌بندی آبرفت در این دشت در نقاط مختلف متفاوت است. دراین دشت آب زیرزمینی درآبرفت‌هایی به ضخامت ۲۰۰-۵۰ متر وجود دارد که بیشتر تناوبی از رس سیلیت‌دار، ماسه‌های ریز و درشت و ریگ هستند. به‌طور کلی کوهپایه و حاشیه دشت‌ها را اجزای دانه‌درشت تشکیل می‌دهند که همین امر باعث نفوذپذیری خوبی در این مناطق می‌شود. سنگ کف قسمت اعظم دشت کرمانشاه را سنگ‌های رادیولاریتی تشکیل می‌دهد. 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 شده است. اجزاء 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 تغذیه‌کننده سفره آب زیرزمینی 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 میشود. همچنین ضریب قابلیت انتقال سفره آب زیرزمینی در مناطق مختلف محدوده طرح متفاوت است، در حاشیه سفره به‌علت 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 ۲۰۰۲ تا ۲۰۱۵ به‌صورت متوسط ماهیانه استفاده شدند.

تغییرات سطح آب زیرزمینی و همچنین میزان بارندگی ماهیانه در این ناحیه برای ۱۳ سال آبی بررسی شده که بر اساس نتایج مشخص شد که روند سطح آب در دشت در این بازه زمانی سیر نزولی داشته به‌گونه‌ای که طی این ۱۳ سال 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 چندساله اخیر و همچنین افزایش میزان برداشت است. در سه سال اخیر این بازه زمانی، روند افت سطح آب تقریباً دارای شدت کمتری بوده و سفره در سطح بسیار پایین‌تری نسبت به سال‌های قبل به تعادل نسبی رسید.

به‌عبارت دیگر تعداد مقادیر برداشت شده برای ۱۵۶ ماه متوالی در قالب سری زمانی استفاده شدند. علاوه بر این، ۹ سال از این مقادیر مشاهداتی برای آموزش و ۴ سال برای تست مدل‌های هوش مصنوعی استفاده شده‌اند. موقعیت جغرافیایی چاه سراب قنبر در شکل (۱) به تصویر کشیده شده است.

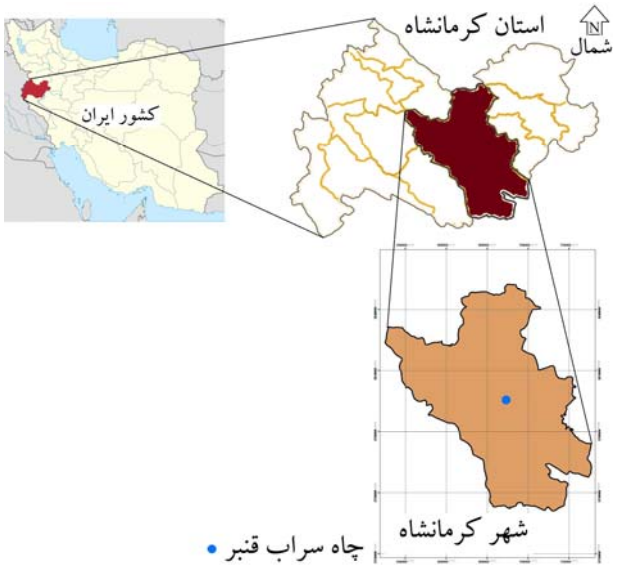
مدل عددی

ماشین آموزش نیرومند (Extreme Learning Machine)

ماشین آموزش نیرومند (ELM) یک نوع شبکه عصبی پیش‌خور (Feed-forward) تک‌لایه است که توسط هوانگ و همکاران (۳ و ۴) ارائه شد. مدل ELM وزن‌های ورودی را به‌صورت تصادفی تعیین و وزن‌های خروجی را به‌صورت تحلیلی (Analytical) تعیین می‌کند. تنها تفاوت ELM با شبکه عصبی پیش‌خور تک‌لایه (single layer feed forward neural network)

www.SID.ir

Archive of SID



شکل ۱. موقعیت جغرافیایی چاه مورد مطالعه

(SLFFNN)، عدم استفاده از بایاس (bias) برای نرون خروجی است. نرون‌های لایه ورودی با همه نرون‌های لایه مخفی در ارتباط هستند. نرون‌های لایه مخفی با استفاده از یک بایاس به‌وجود می‌آیند. تابع فعال‌سازی نرون‌های مخفی می‌تواند به‌صورت تابع پیوسته تکه‌ای (piecewise continuous function) باشد درحالی که برای نرون لایه خروجی به‌صورت خطی است. مدل ELM از الگوریتم‌های مختلفی برای محاسبه وزن‌ها و بایاس‌ها استفاده می‌کند که درنتیجه کاهش قابل توجه زمان آموزش شبکه را به‌همراه دارد. توصیف ریاضی شبکه عصبی پیش‌خور تک‌لایه با تعداد n گره مخفی، به‌صورت زیر بیان می‌شود:

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

که β_i وزن بین گره مخفی iام 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 iام برای ورودی x است. تابع فعال‌سازی g(x) (که دارای انواع مختلفی هستند) برای گره مخفی افزاینده (additive) $G(a_i, b_i, x)$ را می‌توان به شکل زیر بازنویسی کرد:

$$G(a_i, b_i, x) = g(a_i.x + b_i) \qquad (2)$$

از توابع فعال‌سازی به‌منظور محاسبه خروجی پاسخ نرون‌ها استفاده می‌شود. رفتار نرون‌ها از دو بخش تشکیل شده است که شامل مجموع وزنی ورودی‌ها و تابع فعال‌سازی است. زمانی که مجموعه‌ای از سیگنال ورودی وزن‌دار اعمال می‌شوند، برای به‌دست آوردن پاسخ از توابع فعال‌سازی استفاده می‌شود. همچنین برای نرون‌های لایه‌های یکسان از توابع فعال‌سازی یکسان استفاده می‌شوند که ممکن است خطی و یا غیرخطی باشند. در توابع خطی یک گراف خطی مستقیم کشیده می‌شود و در توابع غیرخطی یک خط منحنی‌دار 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 (sigmoid) (sig)، سینوسی (sin)، بایاس مثلثی (tribas) و بایاس شعاعی (radbas) است. در ELM، وزن‌ها و بایاس‌ها بین نرون‌های لایه ورودی و مخفی به‌صورت 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:

$$H_{jk} = g(\sum W_{ji} X_{ik}) + B_j \qquad (3)$$

که در اینجا g(.) می‌تواند هر تابع فعال‌سازی غیرخطی پیوسته باشد، W_{ji} وزن نرون ورودی iام و نرون لایه مخفی jام، B_j، بایاس نرون لایه مخفی jام، X_{ik} ورودی نرون ورودی برای k امین نمونه آموزشی و H_{ik} ماتریس فعال‌سازی j امین نرون لایه مخفی برای k امین نمونه آموزشی است به‌گونه‌ای که 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 به‌عنوان 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،

www.SID.ir

Archive of SID

به‌کار برده می‌شود که معادل ریاضی آن را می‌توان به شکل زیر بیان نوشت:

$$H\beta = T \qquad (۴)$$

$$\beta = (\beta_1,...,\beta_j)_{j\times 1} \qquad (۵)$$

که β نشان‌دهنده وزن بین نرون لایه خورجی و نرون‌های لایه مخفی است و T بردار نشان‌دهنده مقادیر هدف برای نمونه‌های آموزش بوده که به‌صورت زیر بیان می‌شود:

$$T = (T_1,...,T_k)_{k\times 1} \qquad (۶)$$

درنهایت وزن‌ها را می‌توان از رابطه زیر محاسبه کرد:

$$\beta = H'T \qquad (۷)$$

که در آن:

$$H(\tilde{a},\tilde{b},\tilde{x}) = \begin{bmatrix} G(a_1,b_1,x_1) & ... & G(a_L,b_L,x_L) \\ G(a_1,b_1,x_N) & ... & G(a_L,b_L,x_N) \end{bmatrix}_{N\times L} \qquad (۸)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L\times m} \quad \text{and} \quad T = \begin{bmatrix} T_1^T \\ \vdots \\ T_L^T \end{bmatrix}_{L\times m} \qquad (۹)$$

که $\tilde{x} = x_1,...x_L$ ، $\tilde{b} = b_1,...b_L$ ، $\tilde{a} = a_1,...a_L$ ، β بردار وزن بین نرون‌های لایه‌های مخفی و لایه پنهان و H' شبه معکوس Moore-Penrose ماتریس H است. ماتریس T بردار بین وزن‌های نمونه‌های 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 شبه‌معکوس Moore-Penrose ماتریس H و مقادیر هدف برای نمونه‌های آموزشی مختلف هستند. روند آموزش برای پیدا کردن شبه‌معکوس Moore-Pensore ماتریس لایه پنهان (H)، سریع است به‌صورتی که از سرعت بالاتری نسبت به الگوریتم‌های مبتنی بر تکرار رایج مانند لونبرگ- مارکوآردت (Levenberg-Marquardt) که در آن هیچ نوع روالی از بهینه‌سازی غیرخطی را دربر نمی‌گیرد، برخوردار است. بنابراین زمان آموزش شبکه به‌طور قابل توجهی کاهش می‌یابد (هوآنگ، ۴). همچنین، مدل ELM با استفاده از تعداد زیادی از پیش‌بینی فضای ورودی تصافی غیرخطی کار می‌کند به‌طوری که 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 (۱۲) ارائه شده است. در سال‌های اخیر 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. مانند دیگر الگوریتم‌های تکاملی، این الگوریتم با ایجاد یک جمعیت اولیه شروع به‌کار 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 برای میزان شایستگی که توسط تابع هدف سنجیده می‌شود، مقایسه می‌شود. سپس بهترین اعضا به‌عنوان نسل بعدی وارد مرحله بعد می‌شوند. این عمل تا رسیدن به نتایج مطلوب ادامه می‌یابد.

ماشین آموزش نیرومند خود تطبیقی

در این مطالعه، برای بهینه‌سازی ماشین آموزش نیرومند از الگوریتم تکامل تفاضلی بهره گرفته می‌شود. استفاده از الگوریتم تکامل تفاضلی به‌صورت خودتطبیقی توانایی غلبه بر محدودیت‌های موجود مانند پارامترهای کنترل در الگوریتم و انتخاب استراتژی بردار آموزش را دارد. بنابراین، الگوریتم ماشین آموزش نیرومند خود تطبیقی (SAELM) برای بهینه‌سازی وزن‌های ورودی شبکه و بایاس‌های گره مخفی، توسط کائو و همکاران (۲) ارائه شد. با داشتن مجموعه داده‌های آموزشی، تعداد L گره مخفی و تابع فعال‌سازی g(x)، می‌توان الگوریتم SAELM را فرمول‌نویسی کرد. بدین منظور، ابتدا جمعیت اولیه با استفاده از بردارهای جمعیت (NP) که گره‌های مخفی را دربر می‌گیرند تولید می‌شود.

www.SID.ir

Archive of SID

تبدیل موجک

موجک تبدیلی است که برای بهینه‌سازی مدل‌های هوش مصنوعی استفاده می‌شود. این روش یک آنالیز طیفی مستقل از زمان است که به‌منظور توصیف مقیاس زمانی فرایندها و روابط آنها، سری‌های زمانی را در فضای زمان- فرکانس از هم جدا می‌کند. تبدیل موجک همانند تبدیل فوریه، سری زمانی را به‌صورت ترکیب خطی از چند تابع اصلی (base)، درنظر می‌گیرد. یکی از مشخصات اصلی تبدیل موجک این است که این تبدیل توانایی به‌دست آوردن اطلاعات در زمان، تناوب و موقعیت را به‌طور همزمان دارد (۹). تبدیل موجک پیوسته توانایی عملکرد در هر مقیاس را دارد هر چند که محاسبه ضرایب موجک در هر مقیاس بسیار مشکل است و نیازمند زمان محاسباتی بالا و تولید مقدار زیادی داده است. در انفصال تبدیل موجک یک زیر مجموعه از مقیاس‌ها و موقعیت‌ها به‌منظور انجام محاسبات انتخاب می‌شود. در مدل‌سازی یک مسئله خاص با استفاده از روش‌های مبتنی بر هوش محاسباتی، علاوه بر توانایی روش مورد نظر، انتخاب پارامترهای مؤثر بر پارامتر هدف به‌عنوان ورودی‌های مدل، نقش قابل توجهی در دقت مدل دارد. در مدل‌سازی‌های سری زمانی که به‌صورت تاریخچه زمانی ارائه می‌شود، با درنظر گرفته تأخیرهای مؤثر، می‌توان به یک نتیجه قابل قبول دست یافت. در این مطالعه، ورودی‌های مدل شامل تأخیرهای مؤثر هستند و با استفاده از روش برازش گام‌به‌گام (stepwise fitting) در محیط MATLAB صورت می‌گیرد (۱۱). به‌عبارت دیگر، انتخاب ترکیب ورودی‌ها که برگرفته از تأخیرهای مختلف هستند، تأثیر قابل توجهی بر نتایج مدل‌سازی دارند. به‌منظور تعیین تأخیرهای مؤثر در برآورد تراز آب زیرزمینی، اصول خاصی وجود ندارد. اما در این مطالعه با استفاده از تحلیل تابع خودهمبستگی و خودهمبستگی نسبی و به‌کمک تأخیرهای مؤثر پارامترهای ورودی انتخاب شده و هشت مدل SAELM و WA-SAELM توسعه داده شده به‌صورت زیر ارائه می‌شوند.

Model ۱: $GWL(t) = f(GWL(t-۱))$

Model ۲: $GWL(t) = f(GWL(t-۱), GWL(t-۲))$

Model ۳: $GWL(t) = f(GWL(t-۱), GWL(t-۲), GWL(t-۳))$

Model ۴: $GWL(t) = f(GWL(t-۱), GWL(t-۲), GWL(t-۳), GWL(t-۴))$

Model ۵: $GWL(t) = f(GWL(t-۱), GWL(t-۲), GWL(t-۳), GWL(t-۴), GWL(t-۵))$

Model ۶: $GWL(t) = f(GWL(t-۱), GWL(t-۲), GWL(t-۳), GWL(t-۴), GWL(t-۵), GWL(t-۶))$

Model ۷: $GWL(t) = f(GWL(t-۱), GWL(t-۲), GWL(t-۳), GWL(t-۴), GWL(t-۵), GWL(t-۶), GWL(t-۷))$

Model ۸: $GWL(t) = f(GWL(t-۱), GWL(t-۲), GWL(t-۳), GWL(t-۴), GWL(t-۵), GWL(t-۶), GWL(t-۷), GWL(t-۸))$

معیارهای بررسی دقت مدل‌های عددی

در مطالعه حاضر به‌منظور ارزیابی دقت مدل‌های عددی معرفی شده از شاخص‌های آماری ضریب همبستگی (R)، ضریب تغییرات (VAF)، خطای مربعات میانگین ریشه (RMSE)، شاخص پراکندگی (SI)، خطای مطلق میانگین (MAE)، درصد خطای مطلق میانگین (MAPE)، خطای نسبی مربعات میانگین ریشه (RMSRE)، BIAS و ضریب بهره‌وری نش ساتکلیف (NSC) به‌صورت زیر استفاده می‌شود:

$$R = \frac{\sum_{i=۱}^{n}(F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=۱}^{n}(F_i - \bar{F})^۲ \sum_{i=۱}^{n}(O_i - \bar{O})^۲}} \quad (۱۰)$$

$$VAF = \left(۱ - \frac{var(F_i - O_i)}{var(F_i)}\right) \times ۱۰۰ \quad (۱۱)$$

$$RMSE = \sqrt{\frac{۱}{n}\sum_{i=۱}^{n}(F_i - O_i)^۲} \quad (۱۲)$$

$$SI = \frac{RMSE}{\bar{O}} \quad (۱۳)$$

$$MAE = \frac{\sum_{i=۱}^{n}|F_i - O_i|}{n} \quad (۱۴)$$

www.SID.ir

Archive of SID

جدول ۱. ضرایب نرمال‌سازی برای شرایط مختلف

ضرایب نرمال‌سازی	a	b
نرمال ۱	۲	-۱
نرمال ۲	۱	۰
نرمال ۳	۰/۸	۰/۱
نرمال ۴	۰/۶	۰/۲
بدون نرمال	۱	۰

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\left(\frac{|F_i - O_i|}{O_i}\right) \quad (15)$$

$$RMSRE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(\frac{O_i - F_i}{O_i}\right)^2} \quad (16)$$

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

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

در اینجا O_i مقادیر مشاهداتی، F_i مقادیر پیش‌بینی شده به‌وسیله مدل‌های عددی، $\bar{O}$ میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی است.

بحث و نتایج

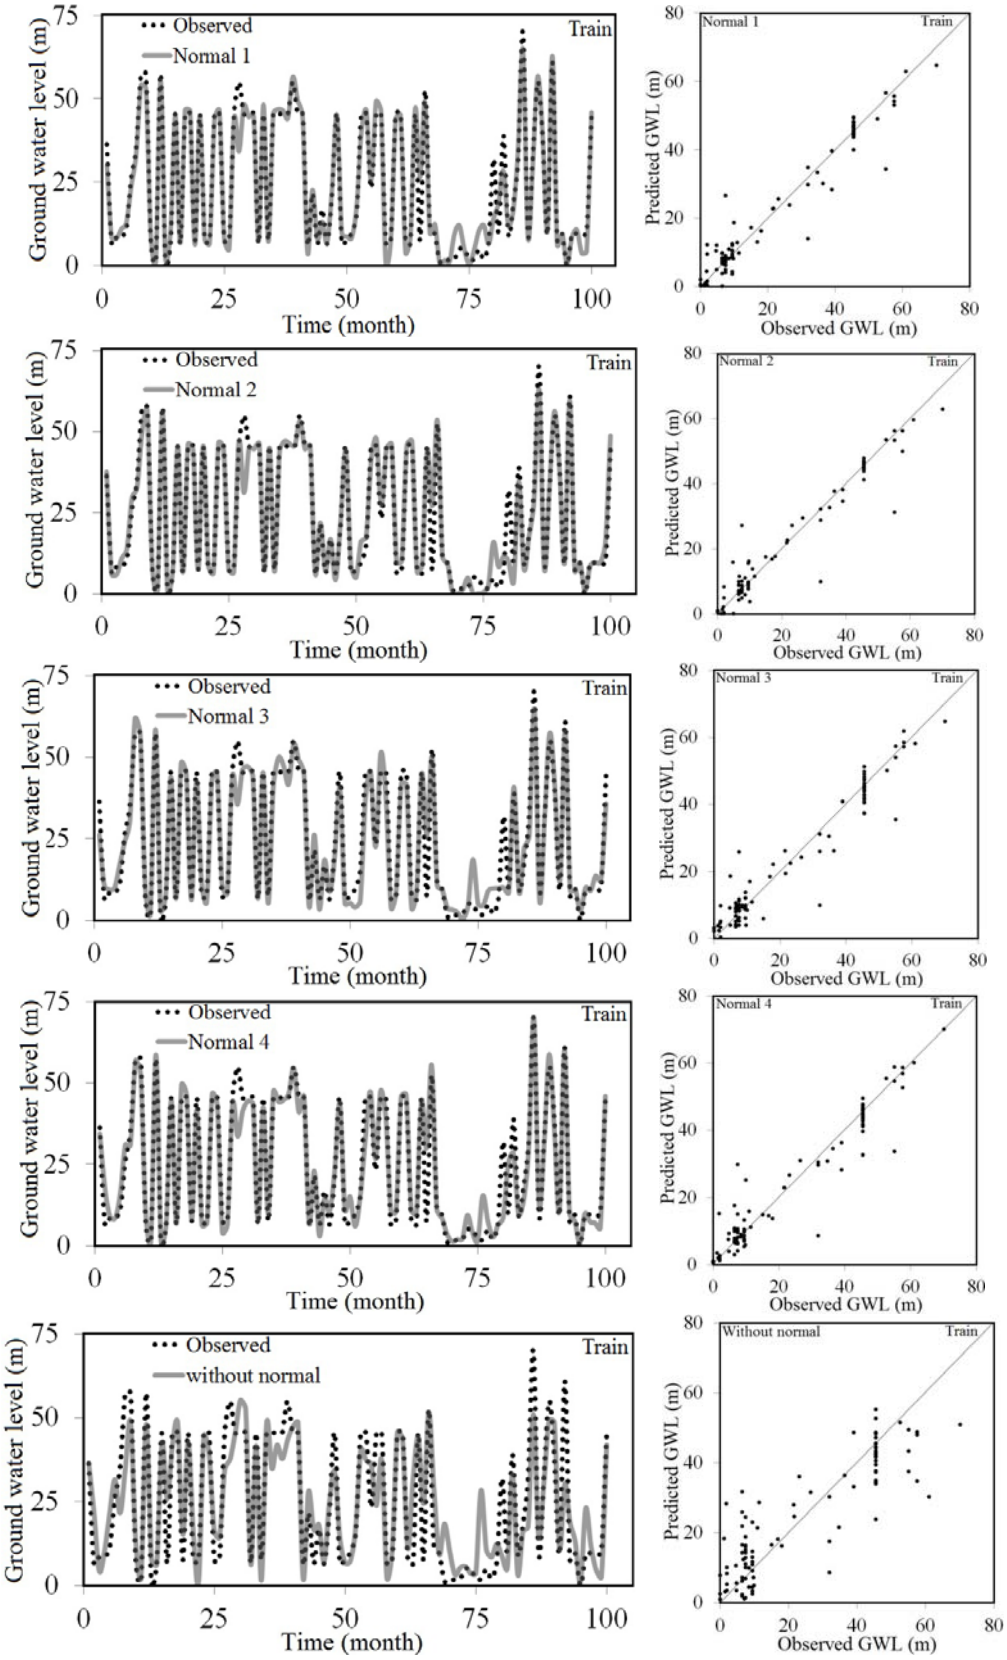
در ادامه، ابتدا به نرمال‌سازی نتایج مشاهداتی پرداخته می‌شود و بهینه‌ترین ضرایب نرمال‌سازی انتخاب می‌شوند. سپس به ارزیابی انتخاب خانواده موجک پرداخته می‌شود و بهترین خانواده موجک شناسایی می‌شود. در قسمت بعدی، هشت مدل مختلف برای هر یک از مدل‌های SAELM و WA-SAELM توسعه داد شده و با تجزیه و تحلیل نتایج مدل‌سازی مدل‌های برتر معرفی می‌شوند. همچنین توزیع خطای این مدل‌ها نیز اجرا شد. علاوه بر این، تحلیل عدم قطعیت برای مدل‌های برتر SAELM و WA-SAELM اجرا می‌شود.

نرمال‌سازی

با توجه به اینکه اختلاف بین حداقل و حداکثر مقدار تراز آب زیرزمینی در چاه مشاهداتی ناچیز است بنابراین مقادیر تراز آب زیرزمینی با استفاده از $X = a\left(\frac{x - x_{min}}{x_{max} - x_{min}}\right) + b$ نرمال‌سازی می‌شود. X مقادیر نرمال‌شده، x مقدار مشاهداتی، x_{min} مقدار حداقل، x_{max} مقدار حداکثر، a و b نیز ضرایب نرمال‌سازی هستند. به‌عبارت دیگر، برای اینکه مقادیر مشاهداتی بین صفر و یک محاسبه شوند، از مقادیر مختلف ضرایب نرمال سازی (a و b) مختلف استفاده می‌شود. همچنین ضرایب نرمال‌سازی مختلف در جدول (۱) نشان داده شده است. در شکل‌های (۲) و (۳) مقایسه مقادیر تراز آب پیش‌بینی شده توسط ضرایب نرمال‌سازی مختلف به تصویر کشیده شده است. بر اساس نتایج نرمال‌سازی، در شرایطی که ضرایب a و b به‌ترتیب مساوی ۲ و ۱- هستند، دقت مدل سازی به شکل قابل ملاحظه‌ای افزایش می‌یابد. به‌عنوان مثال در حالت تست، مقادیر R و RMSE برای ضرایب a = ۲ و b = -۱ به‌ترتیب برابر ۰/۹۵۱ و ۳/۳۴۶ هستند. با توجه به نتایج نرمال‌سازی، برای normal 1 مقادیر NSC، BIAS و MAE به‌ترتیب مساوی ۰/۸۹۹، ۰/۴۹۷- و ۳/۳۰۳ به‌دست آمده است. این در حالی است که مقادیر correlation coefficient و scatter index برای حالت without normal به‌ترتیب مساوی ۰/۸۴۴ و ۰/۴۶۹ محاسبه شده‌اند. بر اساس نتایج مدل‌سازی، normal 1 دارای بیشترین همبستگی با مقادیر مشاهداتی است. بنابراین در ادامه ضرایب a = ۲ و b = -۱ برای تخمین تغییرات تراز آب زیرزمینی استفاده می‌شود. نتایج شاخص‌های آماری در حالت تست برای نرمال‌سازی‌های مختلف در جدول (۲) مرتب شده است.

www.SID.ir

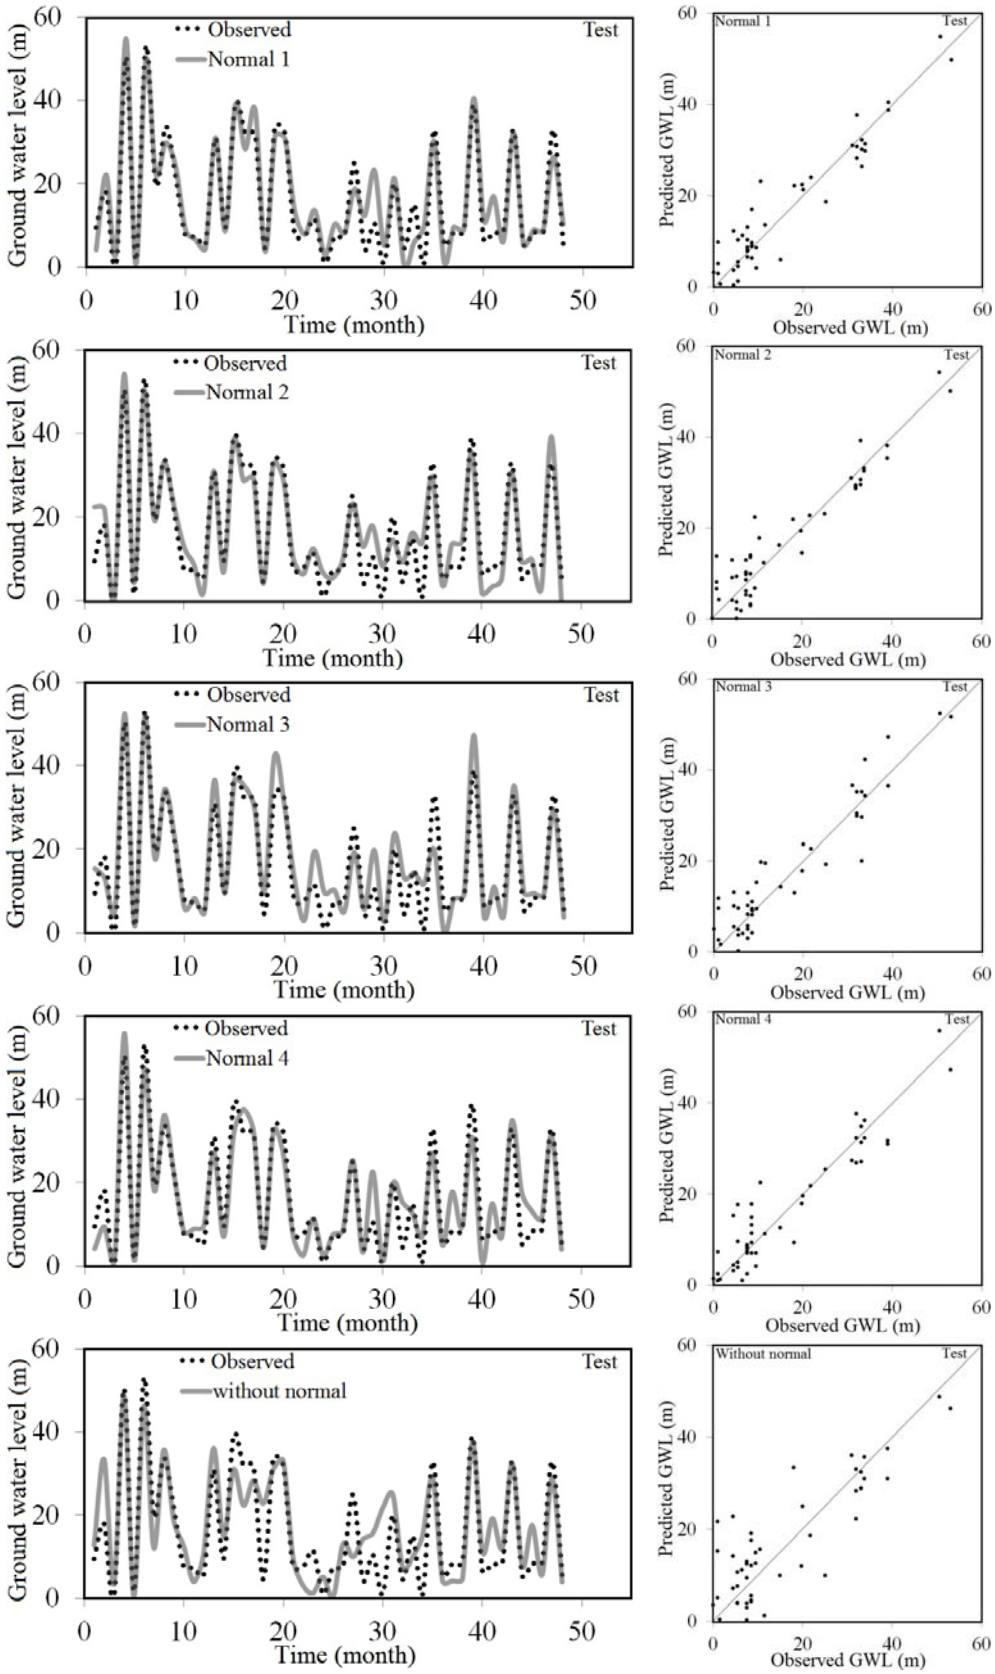
Archive of SID



شکل ۲. مقایسه نتایج نرمال‌سازی شده با مقادیر مشاهداتی برای حالت‌های مختلف در حالت آموزش

www.SID.ir

Archive of SID



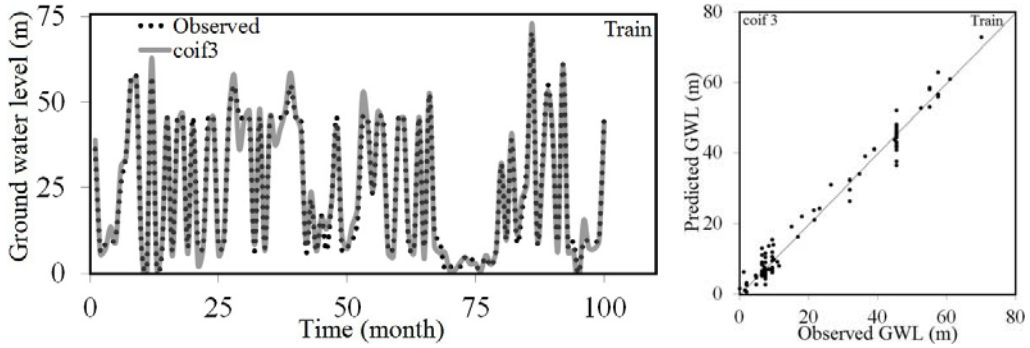
شکل ۳. مقایسه نتایج نرمال‌سازی‌شده با مقادیر مشاهداتی برای حالت‌های مختلف در حالت تست

www.SID.ir

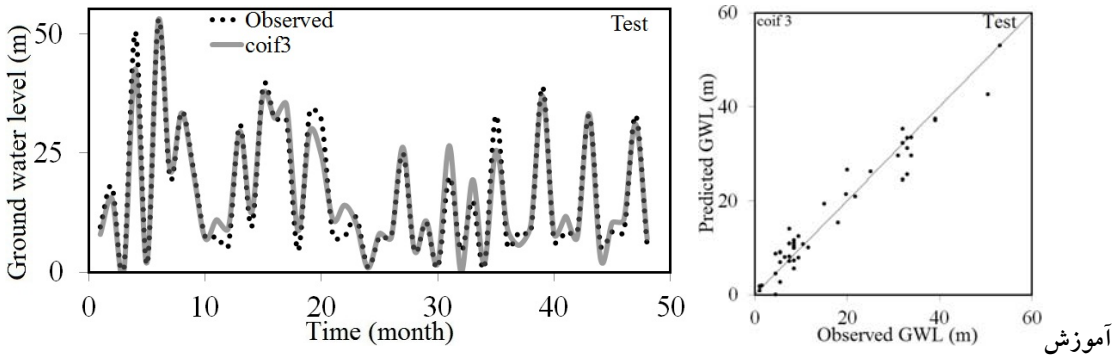
Archive of SID

جدول ۲. نتایج شاخص‌های آماری برای نرمال‌سازی‌های مختف در حالت تست

تست	R	VAF	RMSE	SI	MAE	MAPE	RMSRE	BIAS	NSC
نرمال ۱	۰/۹۵۱	۹۰/۳۰۸	۴/۳۴۶	۰/۲۶۸	۳/۳۰۳	۰/۶۴۲	۱/۵۴۱	−۰/۴۹۷	۰/۸۹۹
نرمال ۲	۰/۹۴۴	۸۸/۸۵۲	۴/۶۵۷	۰/۲۸۷	۳/۶۵۷	۰/۹۶۰	۲/۴۹۹	−۰/۵۰۱	۰/۸۸۴
نرمال ۳	۰/۹۴۳	۸۸/۵۸۷	۴/۸۳۲	۰/۲۹۸	۳/۷۰۳	۰/۷۵۲	۲/۰۷	−۱/۱۸۳	۰/۸۷۹
نرمال ۴	۰/۹۲۴	۸۵/۰۴۹	۵/۳۶۳	۰/۳۳۱	۳/۸۶۵	۰/۵۸۷	۱/۱۹۳	۰/۰۹۲	۰/۸۴۵
بدون نرمال	۰/۸۴۴	۷۰/۲۲۶	۷/۵۹۵	۰/۴۶۹	۶/۰۱۶	۱/۴۱۵	۳/۸۴۲	−۰/۶۴۱	۰/۶۶۴



شکل ۴. مقایسه نتایج mother wavelet selection با مقادیر مشاهداتی برای حالت آموزش



شکل ۵. مقایسه نتایج mother wavelet selection با مقادیر مشاهداتی برای حالت تست

بررسی خانواده‌های موجک

مدل wavelet دارای پنج خانواده مختلف با عنوان خانواده موجک که شامل خانواده haar یک عضو، خانواده db ۱۰ عضو، خانواده dmey یک عضو، خانواده sym هفت عضو و خانواده coif پنج عضو هستند. بر اساس نتایج شبیه‌سازی، خانواده موجک با عنوان coif۳ مقادیر تراز آب زیرزمینی را در مقایسه با سایر خانواده‌های موجک با دقت بیشتری مدل‌سازی کرده است. نتایج شاخص‌های آماری برای خانواده موجک مختلف در حالت تست در جدول (۳) نشان داده شده است. به‌عنوان مثال، مقادیر correlation coefficient، VAF و RMSE برای coif۳ به‌ترتیب مساوی ۰/۹۷۵، ۹۴/۸۳۳ و ۳/۱۵۷ تخمین زده شده است. همچنین مقدار شاخص NSC برای این خانواده موجک مساوی ۰/۹۴۰ محاسبه شده است. در شکل‌های (۴) و (۵) مقادیر تراز آب پیش‌بینی شده توسط برای خانواده موجک برتر (coif۳) در حالت‌های آموزش و تست نشان داده شده است. بنابراین در ادامه برای تخمین تراز آب زیرزمینی توسط مدل

www.SID.ir

Archive of SID

جدول ۳. نتایج شاخص‌های آماری برای خانواده موجک مختلف در حالت تست

خانواده موجک	R	VAF	RMSE	SI	MAE	MARE	RMSRE	BIAS	AIC	NSC
haar	۰/۹۵۴	۹۰/۸۲۳	۴/۲۱۹	۰/۲۶۰	۳/۰۷۷	۰/۳۸۳	۰/۶۰۸	−۰/۳۸۵	۷۳/۱۰۱	۰/۹۰۶
db۱	۰/۹۴۸	۸۹/۶۹۷	۴/۴۵۲	۰/۲۷۵	۳/۲۷۸	۰/۶۷۸	۲/۱۷۶	−۰/۰۷۵	۷۵/۶۸۳	۰/۸۹۴
db۲	۰/۹۵۹	۹۱/۱۹۹	۴/۱۱۸	۰/۲۵۴	۳/۲۲۷	۰/۶۳۴	۱/۴۰۶	−۰/۱۶۱	۷۱/۹۳۲	۰/۹۲۰
db۳	۰/۹۵۷	۹۱/۰۲۶	۴/۲۱۰	۰/۲۶۰	۳/۴۷۳	۰/۴۶۹	۰/۷۵۴	−۰/۶۸۴	۷۲/۹۹۸	۰/۹۱۳
db۴	۰/۹۶۸	۹۳/۴۴۸	۳/۶۱۵	۰/۲۲۳	۲/۸۹۶	۰/۴۵۹	۰/۸۸۰	−۰/۶۸۰	۶۵/۶۷۹	۰/۹۳۹
db۵	۰/۹۷۲	۹۳/۹۴۴	۳/۴۷۹	۰/۲۱۴	۲/۸۹۴	۰/۴۵۴	۰/۸۱۲	−۰/۶۷۷	۶۳/۸۴۹	۰/۹۴۳
db۶	۰/۹۷۰	۹۳/۹۶۲	۳/۴۴۰	۰/۲۱۲	۲/۸۱۳	۰/۴۷۲	۰/۹۷۴	−۰/۴۶۵	۶۳/۲۹۵	۰/۹۴۰
db۷	۰/۹۶۸	۹۳/۴۸۶	۳/۶۳۲	۰/۲۲۴	۲/۷۳۱	۰/۵۸۹	۱/۵۲۸	−۰/۸۱۲	۶۵/۹۰۵	۰/۹۳۴
db۸	۰/۹۶۹	۹۳/۷۳۲	۳/۴۷۴	۰/۲۱۴	۲/۶۷۷	۰/۴۲۵	۰/۸۳۸	−۰/۱۰۱	۶۳/۷۷۲	۰/۹۳۷
db۹	۰/۹۷۲	۹۴/۲۹۸	۳/۳۱۸	۰/۲۰۵	۲/۴۹۵	۰/۴۱۴	۰/۹۵۳	−۰/۲۰۵	۶۱/۵۷۲	۰/۹۴۴
db۱۰	۰/۹۶۹	۹۳/۲۶۳	۳/۶۰۰	۰/۲۲۲	۲/۸۰۲	۰/۴۲۵	۰/۸۱۶	۰/۰۶۴	۶۵/۴۸۸	۰/۹۳۸
dmey	۰/۹۶۴	۹۲/۹۷۹	۳/۷۰۱	۰/۲۲۸	۲/۷۵۹	۰/۵۵۷	۱/۴۵۹	−۰/۴۳۸	۶۶/۸۱۱	۰/۹۲۵
sym۲	۰/۹۶۷	۹۳/۳۲۲	۳/۷۳۸	۰/۲۳۱	۲/۹۶۳	۰/۳۸۵	۰/۷۳۵	−۱/۰۶۳	۶۷/۲۹۴	۰/۹۲۷
sym۳	۰/۹۷۱	۹۴/۱۲۷	۳/۴۰۶	۰/۲۱۰	۲/۶۳۳	۰/۴۲۶	۰/۹۷۳	−۰/۵۵۴	۶۲/۸۳۰	۰/۹۴۱
sym۴	۰/۹۶۳	۹۲/۶۶۶	۳/۸۶۱	۰/۲۳۲	۳/۰۳۰	۰/۵۵۱	۱/۰۷۵	−۰/۸۹۶	۶۸/۸۴۸	۰/۹۲۳
sym۵	۰/۹۵۰	۸۹/۳۸۸	۴/۵۳۹	۰/۲۸۰	۳/۵۱۰	۰/۴۹۴	۰/۹۶۸	−۰/۴۳۶	۷۶/۶۰۹	۰/۹۰۱
sym۶	۰/۹۸۰	۹۵/۹۱۵	۲/۸۱۹	۰/۱۷۴	۲/۲۴۱	۰/۴۴۶	۱/۲۰۶	−۰/۳۰۱	۵۳/۷۵۲	۰/۹۵۸
sym۷	۰/۹۷۵	۹۴/۹۸۹	۴/۱۸۱	۰/۱۹۶	۲/۵۶۹	۰/۴۱۴	۰/۷۱۴	−۰/۷۰۷	۵۹/۵۹۰	۰/۹۴۸
sym۸	۰/۹۷۶	۹۵/۰۶۷	۳/۰۸۲	۰/۱۹۰	۲/۴۷۳	۰/۴۱۵	۰/۷۶۵	۰/۰۹۳	۵۸/۰۲۳	۰/۹۵۲
coif۱	۰/۹۵۸	۹۰/۴۵۰	۴/۳۳۳	۰/۲۶۷	۳/۴۰۹	۰/۴۸۰	۱/۰۴۰	−۰/۶۳۷	۷۴/۳۸۱	۰/۹۱۶
coif۲	۰/۹۶۴	۹۲/۳۷۴	۳/۸۳۱	۰/۲۳۶	۲/۹۶۷	۰/۵۳۵	۱/۲۹۴	−۰/۰۸۴	۶۸/۴۶۸	۰/۹۲۹
coif۳	۰/۹۷۱	۹۴/۸۳۳	۳/۱۵۷	۰/۱۹۵	۲/۳۶۷	۰/۲۸۱	۰/۴۰۳	−۰/۱۷۵	۵۹/۱۸۸	۰/۹۴۰
coif۴	۰/۹۷۵	۹۴/۹۰۷	۳/۲۰۳	۰/۱۹۸	۲/۶۰۴	۰/۴۸۱	۱/۰۷۰	−۰/۶۸۰	۵۹/۸۷۵	۰/۹۴۹
coif۵	۰/۹۷۳	۹۴/۶۰۶	۳/۲۸۵	۰/۲۰۲	۲/۵۹۶	۰/۳۴۸	۰/۵۷۰	−۰/۶۴۳	۶۱/۰۸۴	۰/۹۴۵

Wavelet-SAELM از coif۳ استفاده می‌شود.

مدل‌های برتر

همان‌گونه که بیان شد هشت مدل متمایز برای هر یک از مدل‌های SAELM و WA-SAELM توسعه داده شده است و در ادامه به معرفی مدل‌های برتر SAELM و WA-SAELM پرداخته می‌شود. در ابتدا مدل‌های SAELM ارزیابی می‌شوند.

در میان کلیه مدل‌های SAELM مدل ۳ SAELM مقادیر تراز آب زیرزمینی را با دقت بیشتری پیش‌بینی کرده است. در حالت تست، مقادیر SI، MAE و BIAS برای ۳ SAELM به‌ترتیب مساوی ۰/۱۴۷، ۱/۳۰۰ و ۰/۵۳۹محاسبه شده است. همچنین، مقدارNSC-Sutcliffe efficiency coefficient برای این مدل برابر ۰/۹۶۸ است.

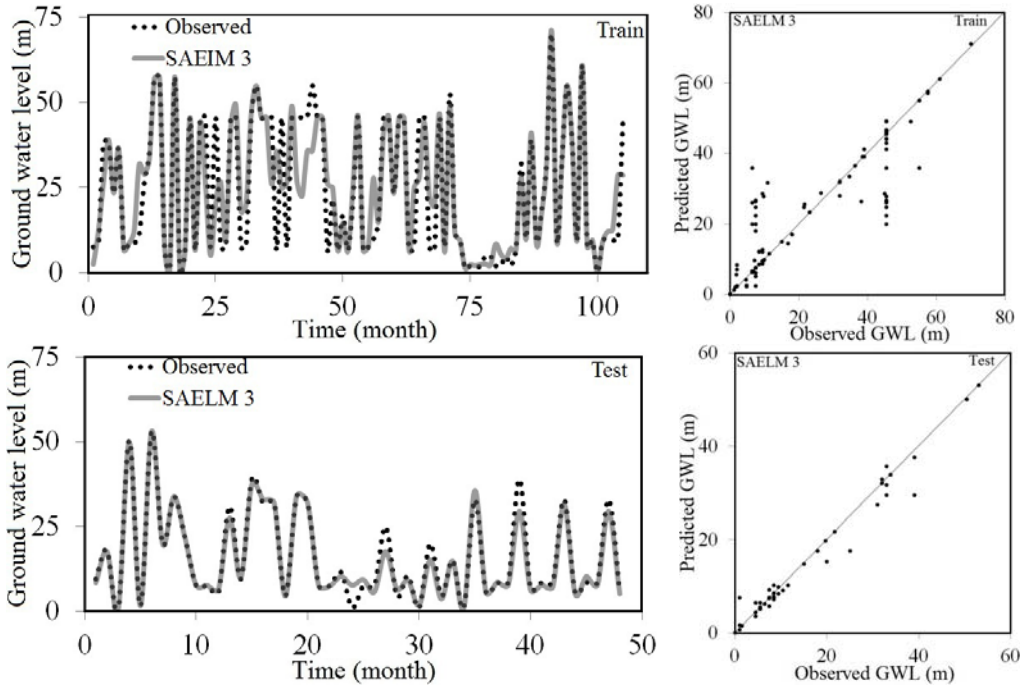
علاوه بر این، در شکل (۶) نحوه مدل‌سازی تراز

www.SID.ir

Archive of SID

جدول ۴. نتایج شاخص‌های آماری برای مدل‌های مختلف SAELM در حالت تست

NSC	BIAS	RMSRE	MARE	MAE	SI	RMSE	VAF	R	
−۲/۵۰۷	−۱/۵۱۶	۴/۲۶۶	۱/۷۴۳	۱۰/۷۳۶	۰/۸۳۱	۱۳/۴۷۳	۶/۸۲۰	۰/۳۲۱	SAELM ۱
۰/۷۸۸	−۰/۸۳۹	۱/۰۴۳	۰/۳۱۰	۲/۴۵۳	۰/۳۷۴	۶/۰۶۱	۸۱/۲۶۶	۰/۹۰۲	SAELM ۲
۰/۹۶۸	۰/۵۳۹	۰/۹۸۰	۰/۲۵۸	۱/۳۰۰	۰/۱۴۷	۲/۳۸۰	۹۷/۲۰۶	۰/۹۸۶	SAELM ۳
۰/۹۳۰	۰/۳۰۲	۱/۰۶۲	۰/۴۳۳	۲/۳۶۳	۰/۲۱۷	۳/۵۰۹	۹۳/۶۴۷	۰/۹۶۸	SAELM ۴
۰/۹۳۵	−۰/۱۷۲	۱/۳۵۰	۰/۵۳۳	۲/۵۵۰	۰/۲۲۰	۳/۵۵۸	۹۳/۴۳۶	۰/۹۶۸	SAELM ۵
۰/۹۳۱	−۰/۳۹۴	۱/۷۹۲	۰/۶۵۸	۲/۷۶۸	۰/۲۲۵	۳/۶۳۹	۹۳/۱۹۸	۰/۹۶۶	SAELM ۶
۰/۸۸۰	−۰/۴۳۱	۱/۰۷۱	۰/۶۲۳	۳/۵۵۳	۰/۲۹۱	۴/۷۲۱	۸۸/۵۱۰	۰/۹۴۲	SAELM ۷
۰/۸۹۹	−۰/۴۹۷	۱/۵۴۱	۰/۶۴۲	۳/۳۰۳	۰/۲۶۸	۴/۳۴۶	۹۰/۳۰۸	۰/۹۵۱	SAELM ۸

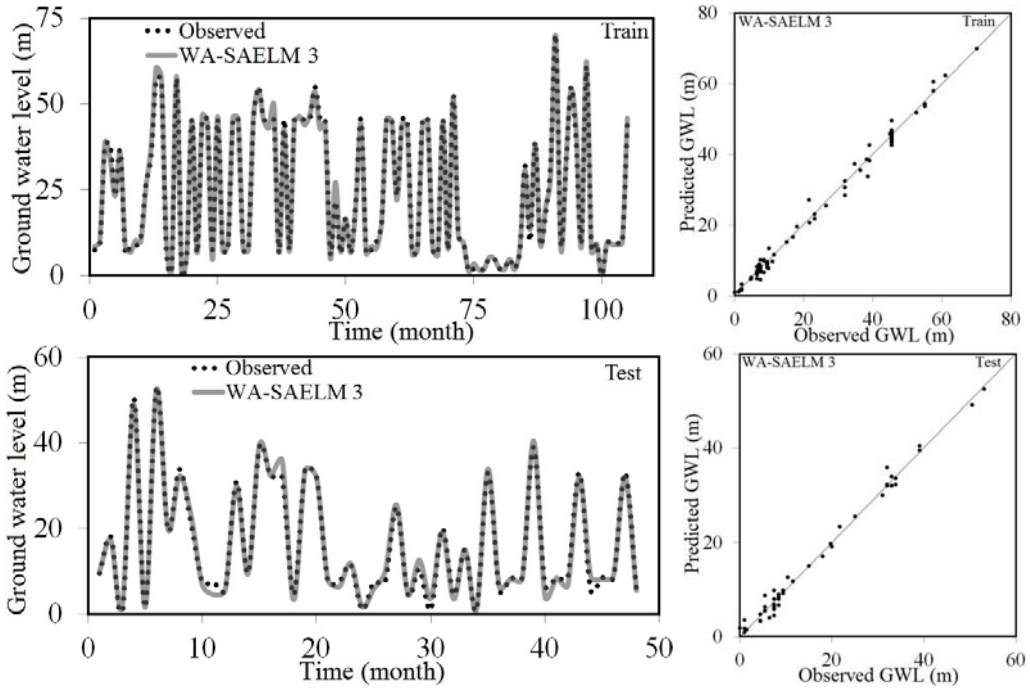


شکل ۶. مقایسه نتایج SAELM ۳ با مقادیر مشاهداتی برای حالت‌های آموزش و تست

آب زیرزمینی مدل SAELM ۳ در هر دو حالت آموزش و تست به تصویر کشیده شده است. در جدول (۴) نتایج شاخص‌های آماری برای مدل‌های مختلف SAELM در حالت تست مرتب شده است. همچنین در ادامه به بررسی مدل برتر WA-SAELM پرداخته می‌شود. با توجه به نتایج مدل‌های WA-SAELM مدل WA-SAELM ۳ دارای بیشترین همبستگی و کمترین مقدار خطا است. به‌عنوان مثال، مقادیر همچنین مقادیر R، MAE و NSC برای این مدل به‌ترتیب برابر ۰/۹۹۵، ۰/۹۸۸ و ۰/۹۹۰ محاسبه شده است. نحوه مدل‌سازی تراز آب زیرزمینی در شرایط آموزش و تست توسط این مدل در شکل (۷) نشان داده شده است. بر اساس تجزیه‌وتحلیل نتایج مدل‌سازی‌های عددی، در بین کلیه مدل‌های معرفی شده، WA-SAELM ۳ به‌عنوان مدل برتر معرفی می‌شود. همچنین در جدول (۵) نتایج شاخص‌های آماری محاسبه شده برای مدل‌های

www.SID.ir

Archive of SID



شکل ۷. مقایسه نتایج WA-SAELM ۳ با مقادیر مشاهداتی برای حالت‌های آموزش و تست

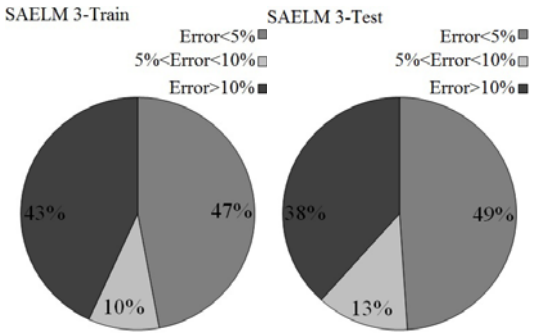
جدول ۵. نتایج شاخص‌های آماری برای مدل‌های مختلف WA-SAELM در حالت تست

NSC	BIAS	RMSRE	MARE	MAE	SI	RMSE	VAF	R	
۰/۸۰۱	۰/۳۱۸	۰/۷۴۰	۰/۴۰۷	۳/۶۰۱	۰/۳۶۳	۵/۸۸۰	۸۲/۰۸۱	۰/۹۰۷	WA-SAELM ۱
۰/۹۰۷	۰/۳۶۹	۱/۵۴۱	۰/۵۶۶	۳/۲۶۷	۰/۲۶۷	۴/۳۲۵	۹۰/۳۴۷	۰/۹۵۳	WA-SAELM ۲
۰/۹۹۰	−۰/۰۶۰	۰/۴۴۵	۰/۱۷۸	۰/۹۸۸	۰/۰۸۴	۱/۳۵۷	۹۹/۰۴۴	۰/۹۹۵	WA-SAELM ۳
۰/۹۴۹	−۰/۷۲۹	۰/۵۷۸	۰/۳۴۰	۲/۵۷۹	۰/۲۰۱	۳/۲۶۴	۹۴/۷۳۶	۰/۹۷۵	WA-SAELM ۴
۰/۹۵۹	−۰/۰۶۱	۰/۴۶۳	۰/۲۸۷	۲/۲۹۰	۰/۱۷۷	۲/۸۷۴	۹۵/۷۰۷	۰/۹۷۹	WA-SAELM ۵
۰/۹۵۵	−۰/۱۸۲	۰/۷۲۰	۰/۴۰۳	۲/۵۰۱	۰/۱۸۹	۳/۰۶۵	۹۵/۱۳۴	۰/۹۷۷	WA-SAELM ۶
۰/۹۲۶	−۰/۶۱۱	۰/۷۷۲	۰/۴۱۶	۲/۹۵۱	۰/۲۳۰	۳/۷۲۰	۹۲/۹۹۹	۰/۹۶۵	WA-SAELM ۷
۰/۹۴۰	−۰/۱۷۵	۰/۴۰۳	۰/۲۸۱	۲/۳۶۷	۰/۱۹۵	۳/۱۵۷	۹۴/۸۳۳	۰/۹۷۵	WA-SAELM ۸

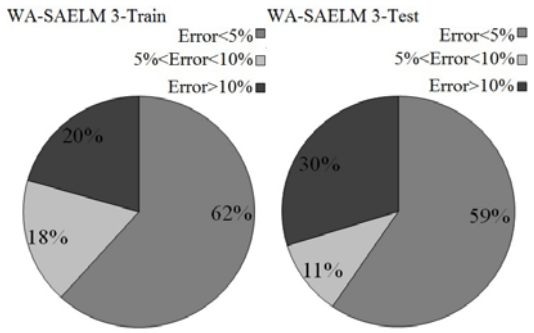
مختلف WA-SAELM نشان داده شده است. همچنین در ادامه به نحوه توزیع خطا برای مدل‌های برتر (WA-SAELM ۳ and SAELM ۳) پرداخته می‌شود. در شکل‌های (۸) و (۹) نتایج توزیع خطا برای مدل‌های برتر در هر دو حالت آموزش و تست نشان داده شده است. به‌عنوان مثال در حالت آموزش، مدل SAELM ۳ تقریبا ۴۷ درصد نتایج مشاهداتی را با خطای کمتر از پنج درصد تخمین می‌زند. همچنین در حدود ۱۰ درصد نتایج این مدل دارای خطایی بین ۵ تا ۱۰ درصد دارند. علاوه بر این با توجه به نتایج توزیع خطا، در حدود ۴۳ مقادیر آب زیرزمینی پیش‌بینی شده توسط SAELM ۳ خطایی بیشتر از ۱۰ درصد به خود اختصاص داده‌اند. در حالت تست، مدل WA-SAELM ۳ بیش از نیمی از مقادیر شبیه‌سازی شده را با خطایی کمتر از پنج درصد محاسبه کرده است و یک سوم تراز آب زیرزمینی تخمین زده شده خطایی بیشتر از ۱۰ درصد دارند. لازم به‌ذکر است که در حدود ۱۱ درصد نتایج مدل WA-SAELM ۳ در حالت تست خطایی بین ۵ تا ۱۰ درصد دارند.

www.SID.ir

Archive of SID



شکل ۸. توزیع خطا برای مدل ۳ SAELM در حالت‌های آموزش و تست



شکل ۹. توزیع خطا برای مدل ۳ WA-SAELM در حالت‌های آموزش و تست

جدول ۶. نتایج تحلیل عدم قطعیت برای مدل‌های ۳ SAELM و ۳ WA-SAELM در حالت تست

مدل‌ها	تعداد نمونه‌ها	میانگین خطای پیش‌بینی	انحراف استاندارد	S_e	پهنای باند عدم قطعیت	حدود اعتماد ۹۵ درصد
SAELM ۳	۴۷	۰/۵۵۲	۲/۳۶۶	۰/۳۴۵	۰/۶۹۵ ±	۰/۱۴۲- و ۱/۲۴۷
WA-SAELM ۳	۴۷	-۰/۰۲۲	۱/۳۵۹	۰/۱۹۸	۰/۳۹۹ ±	۰/۴۲۱- و ۰/۳۷۷

تحلیل عدم قطعیت

در این قسمت تحلیل عدم قطعیت مدل‌های SAELM ۳ and WA-SAELM ۳ اجرا می‌شود. تحلیل عدم قطعیت برای ارزیابی خطای پیش‌بینی‌شده توسط مدل‌های عددی استفاده می‌شود که در آن مقدار خطای پیش‌بینی‌شده توسط مدل عددی (e_j) به‌صورت تفاضل بین مقادیر تراز آب زیرزمینی پیش‌بینی شده (P_j) و مقادیر مشاهداتی (T_j) محاسبه می‌شود ($e_j = P_j - T_j$). همچنین مقدار میانگین خطای پیش‌بینی‌شده به‌صورت $\bar{e} = \sum_{j=1}^{n} e_j$ به‌دست می‌آید. علاوه بر این، مقدار انحراف استاندارد مقادیر خطای پیش‌بینی شده نیز به‌صورت $S_e = \sqrt{\sum_{j=1}^{n} (e_j - \bar{e})^2 / n-1}$ تعریف می‌شود. منفی بودن مقدار $\bar{e}$ نشان‌دهنده عملکرد کمتر از مقدار واقعی بودن مدل عددی است. در مقابل مثبت بودن $\bar{e}$ به معنای عملکرد بیشتر از مقدار واقعی بودن مدل عددی مذکور است. لازم به ذکر است که، با استفاده از پارامترهای $\bar{e}$ و S_e یک باند اطمینان در اطراف مقادیر پیش‌بینی از یک خطا توسط روش ویلسون تولید می‌شود. در ادامه با استفاده از $1/64 S_e \pm$ به‌صورت تقریبی منجر به ۹۵ درصد باند اطمینان می‌شود. در جدول (۶) نیز پارامترهای به‌دست آمده برای تحلیل عدم قطعیت مدل‌های SAELM ۳ and WA-SAELM ۳ در حالت تست مرتب شده است. با توجه به تحلیل عدم قطعیت، مدل SAELM ۳ دارای عملکردی بیشتر از مقدار واقعی و WA-SAELM ۳ نیز عملکردی کمتر از مقدار واقعی هستند. علاوه بر این ۹۵ درصد

www.SID.ir

Archive of SID

خطای پیش‌بینی شده نتایج تخمین زده شده توسط WA-SAELM ۳ بین ۰/۱۴۲- و ۱/۲۴۷ هستند.

نتیجه‌گیری

در این مطالعه، نشان داده شد که مدل هوش مصنوعی نوین با عنوان ماشین آموزش نیرومند خودتطبیقی تغییرات تراز آب زیرزمینی، در چاه سراب قنبر واقع در شهر کرمانشاه را برای یک بازه زمانی ۱۳ ساله توسعه داده شد. برای انجام این کار، مدل ماشین آموزش نیرومند با الگوریتم تکامل تفاضلی ترکیب شدند. به بیان دیگر، برای بهینه‌سازی مدل ماشین آموزش نیرومند از الگوریتم تکامل تفاضلی استفاده شد، سپس اعضای مختلف خانواده‌های موجک نیز برای افزایش دقت مدل ترکیبی و تجزیه نوسان‌های داده‌های سری زمانی ارزیابی شدند. همچنین، به‌کمک تابع خود همبستگی، خودهمبستگی نسبی و به‌کمک تأخیرهای مؤثر، هشت مدل متمایز SAELM و WA-SAELM معرفی شد. تجزیه‌وتحلیل نتایج مدل‌های عددی نشان داد که، الگوریتم تفاضل تکاملی توانایی قابل توجهی در افزایش دقت مدل ماشین آموزش نیرومند داشت. همچنین، coif۳ به‌عنوان عضو برتر خانواده‌های موجک معرفی شد که دقت مدل ماشین آموزش نیرومند خود تطبیقی را بهبود بخشید. سپس مدل های برتر برای تخمین تراز آب زیرزمینی معرفی شدند. تجزیه‌وتحلیل نتایج مدل‌سازی نشان داد که مدل‌های WA-SAELM در مقایسه با مدل‌های SAELM مقادیر تابع هدف را با دقت بیشتری مقایسه کرد. به‌عنوان مثال برای مدل برتر مقادیر مقادیر VAF، SI و NSC برای این مدل به‌ترتیب برابر ۹۹/۰۴۴، ۰/۰۸۴ و ۰/۹۹۰ محاسبه شدند. علاوه بر این نتایج تحلیل عدم قطعیت نشان داد که مدل برتر WA-SAELM دارای عملکردی کمتر از مقدار واقعی است. لازم به‌ذکر است که عرض باند عدم قطعیت برای مدل برتر بین مثبت ۰/۳۹۹ و منفی ۰/۳۹۹ به‌دست آمد.

سپاسگزاری

پژوهش حاضر با حمایت مالی دانشگاه آزاد اسلامی واحد کرمانشاه انجام شده است. بنابراین نویسندگان این مقاله مراتب قدردانی و تشکر خود را از دانشگاه آزاد اسلامی واحد کرمانشاه برای حمایت مالی از این پژوهش ابراز می‌دارند.

منابع مورد استفاده

1. Barzegar, R., E. Fijani, A. A. Moghaddam and E. Tziritis. 2017. Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models. *Science of the Total Environment* 599: 20-31.
2. Cao, J., Z. Lin and G. B. Huang. 2012. Self-adaptive evolutionary extreme learning machine. *Neural Processing Letters* 36(3): 285-305.
3. Huang, G. B., Q. Y. Zhu and C. K. Siew. 2004. Extreme learning machine: A new learning scheme of feedforward neural networks. In: Proceedings of the International Joint Conference on Neural Networks, Budapest, Hungary, 2: 985–990.
4. Huang, G. B., Q. Y. Zhu and C. K. Siew. 2006. Extreme learning machine: theory and applications. *Neurocomputing* 70(1): 489-501.
5. Khaki, M., I. Yusoff and N. Islami. 2015. Simulation of groundwater level through artificial intelligence system. *Environmental Earth Sciences* 73(12): 8357-8367.
6. Lerner D. N., A. S. Issar and I. Simmers. 1990. Groundwater Recharge: A Guide to Understanding and Estimating Natural Recharge. Report 8. Int. Assoc. Hydrogeol., Kenilworth, UK.
7. Makungo, R and J. O. Odiyo. 2017. Estimating groundwater levels using system identification models in Nzhelele and Luvuvhu areas, Limpopo Province, South Africa. *Physics and Chemistry of the Earth, Parts A/B/C* 100: 44-50.
8. Malekzadeh, M., S. Kardar, K. Saeb, S. Shabanlou and L. Taghavi. 2019. A novel approach for prediction of monthly ground water level using a hybrid wavelet and non-tuned self-adaptive machine learning model. *Water Resources Management* 33(4): 1609-1628.
9. Misiti M., Y. Misiti, G. Oppenheim and J. M. Poggi. 1996. Wavelet Toolbox for Use with Matlab. The Mathworks, Inc.: Natick, Massachusetts, USA.
10. Sahoo, S. and M. K. Jha. 2013. Groundwater-level prediction using multiple linear regression and artificial neural

www.SID.ir

Archive of SID

network techniques: a comparative assessment. *Hydrogeology Journal* 21(8): 1865-1887.
11. Silhavy, R., P. Silhavy and Z. Prokopova. 2017. Analysis and selection of a regression model for the use case points method using a stepwise approach. *Journal of systems and Software* 125: 1-14.
12. Storn, R and K. Price. 1997. Differential evolution–a simple and efficient heuristic for global optimization over continuous spaces. *Journal of Global Optimization* 11(4): 341-359.
13. Suryanarayana, C., C. Sudheer, V. Mahammood and B. K. Panigrahi. 2014. An integrated wavelet-support vector machine for groundwater level prediction in Visakhapatnam, India. Neurocomputing, 145: 324-335.
14. Yoon, H., Y. Hyun, K. Ha, K. K. Lee and G. B. Kim. 2016. A method to improve the stability and accuracy of ANN-and SVM-based time series models for long-term groundwater level predictions. *Computers & Geosciences* 90: 144-155.

www.SID.ir

Archive of SID

Journal of Water and Soil Science
Vol. 23, Winter 2020, Isfahan University of Technology, Isfahan, Iran.

Prediction of Groundwater Level Changes Using Hybrid Wavelet Self- Adaptive Extreme Learning Machine Model- Observation Well of Sarab Qanbar, Kermanshah

F. Yosefvand* and S. Shabanlou[1]

(Received: November 25-2018 ; Accepted: May 21-2019)

Abstract

In this study, the groundwater level (GWL) of the Sarab Qanbar region located in the south of Kermanshah, Iran, was estimated using the Wavelet- Self- Adaptive Extreme Learning Machine (WA- SAELM) model. An artificial intelligence method called "Self- Adaptive Extreme Learning Machine" and the "Wavelet transform" method were implemented for developing the numerical model. First, by using the autocorrelation function (ACF), the partial autocorrelation function (PACF) and the effective lags in estimating GWL, eight distinctive SAELM and WA- SAELM models were developed. Later, the values of the observational well were normalized for estimating GWL. Next, the most optimized mother wavelet was chosen for the modeling. By evaluating the results of SAELM and WA- SAELM, it was concluded that the WA- SAELM models could estimate the values of the objective function with higher accuracy. Then, the superior model was introduced, showing that it could be very accurate in forecasting the GWL. In the test mode, for example, the values of *R* (correlation coefficient), Main absolute error (*MAE*) and the *NSC*- Sutcliffe efficiency coefficient (*NSC*) for the superior model were calculated to be 0.995, 0.988 and 0.990, respectively. Furthermore, an uncertainty analysis was conducted for the numerical models, proving that the superior model had an underestimated performance.

Keywords: Groundwater level, Self- Adaptive Extreme Learning Machine (SAELM), Uncertainty analysis, Wavelet transform

1. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.
*: Corresponding author: fariborzyosefvand@gmail.com

www.SID.ir