

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 تجزیه و تحلیل 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 MAE, R و NSC برای مدل برتر به ترتیب 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: fariborzosefvand@gmail.com

مقدمه

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. به عبارت 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 به صورت 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

آب‌های زیرزمینی یکی از منابع آب شرب محسوب می‌شوند. به طور 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. به دلیل اهمیت پیش‌بینی و تخمین تراز آب‌های زیرزمینی مطالعات مختلفی در این زمینه انجام شده است. همچنین به تازگی استفاده از تکنیک‌های مختلف هوش مصنوعی در پیش‌بینی تراز آب زیرزمینی به صورت گسترده مورد استفاده قرار گرفته‌اند. به عنوان 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 به وسیله 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 درون چاه‌های مشاهداتی واقع در کره جنوبی را توسط شبکه عصبی مصنوعی و ماشین بردار پشتیبان در یک بازه زمانی درازمدت شبیه‌سازی کردند. آنها با تجزیه و تحلیل 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

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 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 ۲۰۰۲ تا ۲۰۱۵ به صورت 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 به گونه‌ای 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 پایین تری نسبت به سال‌های قبل به تعادل نسبی رسید.

به عبارت 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 به صورت تصادفی تعیین و وزن‌های خروجی را به صورت تحلیلی (Analytical) تعیین می‌کند. تنها تفاوت ELM با شبکه عصبی پیش‌خور تک‌لایه (single layer feed forward neural network)

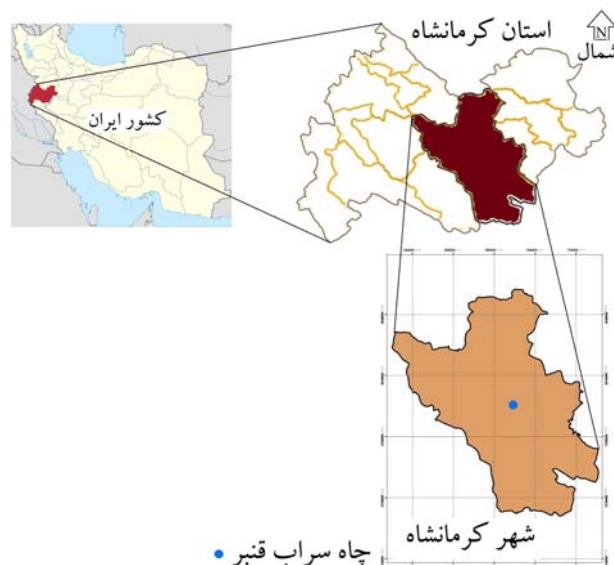
است. مختصات جغرافیایی منطقه مذکور ۳۴/۲۸۷۰ درجه شمالی و ۴۷/۰۵۴۷ درجه شرقی است. در این مطالعه برای صحت‌سنجی مدل‌های هوش مصنوعی از چاه مشاهداتی واقع در این منطقه استفاده شد.

سرتاسر حاشیه شمالی و شرقی و قسمتی از حاشیه شمال غربی این دشت به وسیله 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 و آهک سیلیسی و رادیولاریت در قسمت جنوب هستند. منطقه مورد مطالعه از نظر زمین‌شناسی جزء دو ساختار زون زاگرس و زون خرد شده است. این دو بخش به همراه دشت خوزستان تمامی ساختار زاگرس را تشکیل می‌دهد. قدیمی‌ترین واحد سنگی پیرامون دشت میاندر بند متعلق به ژوراسیک است. با توجه به این مسئله ضخامت، نوع و دانه‌بندی آبرفت در این دشت در نقاط مختلف متفاوت است. در این دشت آب زیرزمینی در آبرفت‌هایی به ضخامت ۲۰۰-۵۰ متر وجود دارد که بیشتر تناوبی از رس سیلیت‌دار، ماسه‌های ریز و درشت و ریگ هستند. به طور 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

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)، سیگموئید (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:

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

که در اینجا $g(\cdot)$ 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 i 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 i 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،



شکل ۱. موقعیت جغرافیایی چاه سراب قنبر 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 درحالی‌که برای نرون لایه خروجی به‌صورت خطی است. مدل ELM از الگوریتم‌های مختلفی برای محاسبه وزن‌ها و بایاس‌ها استفاده می‌کند که در نتیجه کاهش قابل توجه زمان آموزش شبکه را به‌همراه دارد. توصیف ریاضی شبکه عصبی پیش‌خور تک‌لایه با تعداد n گره مخفی، به‌صورت زیر بیان می‌شود:

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

که β_i وزن بین گره مخفی i ام و گره خروجی، a_i ($a_i \in \mathbb{R}^n$) 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 هستند) برای گره مخفی افزاینده (additive) $G(a_i, b_i, x)$ را می‌توان به شکل زیر بازنویسی کرد:

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

از توابع فعال‌سازی به‌منظور محاسبه خروجی پاسخ نرون‌ها

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 فراکوشی 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 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 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.

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

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

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

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:

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

در نهایت وزن‌ها را می‌توان از رابطه زیر محاسبه کرد:

$$\beta = H^T T \quad (7)$$

که در آن:

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

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

که $\tilde{a} = a_1, \dots, a_L$ ، $\tilde{b} = b_1, \dots, b_L$ ، $\tilde{x} = x_1, \dots, x_L$ 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-Penrose ماتریس لایه پنهان (H)، سریع است به‌صورتی که از سرعت بالاتری نسبت به الگوریتم‌های مبتنی بر تکرار رایج مانند لوبنبرگ-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

تبدیل موجک

Model ۲: $GWL(t) = f(GWL(t-1), GWL(t-2))$

Model ۳: $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3))$

Model ۴: $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3), GWL(t-4))$

Model ۵: $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3), GWL(t-4), GWL(t-5))$

Model ۶: $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3), GWL(t-4), GWL(t-5), GWL(t-6))$

Model ۷: $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3), GWL(t-4), GWL(t-5), GWL(t-6), GWL(t-7))$

Model ۸: $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3), GWL(t-4), GWL(t-5), GWL(t-6), GWL(t-7), GWL(t-8))$

معیارهای بررسی دقت مدل‌های عددی

در مطالعه حاضر به منظور 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) به صورت زیر استفاده می‌شود:

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (10)$$

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)} \right) \times 100 \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad (12)$$

$$SI = \frac{RMSE}{\bar{O}} \quad (13)$$

$$MAE = \frac{\sum_{i=1}^n |F_i - O_i|}{n} \quad (14)$$

موجک تبدیلی است که برای بهینه‌سازی مدل‌های هوش مصنوعی استفاده می‌شود. این روش یک آنالیز طیفی مستقل از زمان است که به منظور 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 به صورت ترکیب خطی از چند تابع اصلی (base)، در نظر می‌گیرد. یکی از مشخصات اصلی تبدیل موجک این است که این تبدیل توانایی به دست آوردن اطلاعات در زمان، تناوب و موقعیت را به طور 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 به منظور 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 به عنوان ورودی‌های مدل، نقش قابل توجهی در دقت مدل دارد. در مدل‌سازی‌های سری زمانی که به صورت تاریخچه زمانی ارائه می‌شود، با در نظر 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 برآزش گام‌به‌گام (stepwise fitting) در محیط MATLAB صورت می‌گیرد (۱۱). به عبارت دیگر، انتخاب ترکیب ورودی‌ها که برگرفته از تأخیرهای مختلف هستند، تأثیر قابل توجهی بر نتایج مدل‌سازی دارند. به منظور 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 به کمک تأخیرهای مؤثر پارامترهای ورودی انتخاب شده و هشت مدل SAELM و WA-SAELM توسعه داده شده به صورت زیر ارائه می‌شوند.

Model ۱: $GWL(t) = f(GWL(t-1))$

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

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. به عبارت دیگر، برای اینکه مقادیر مشاهداتی بین صفر و یک محاسبه شوند، از مقادیر مختلف ضرایب نرمال‌سازی (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 به ترتیب مساوی ۲ و -۱ هستند، دقت مدل‌سازی به شکل قابل ملاحظه‌ای افزایش می‌یابد. به عنوان مثال در حالت تست، مقادیر R و $RMSE$ برای ضرایب $a = 2$ و $b = -1$ به ترتیب برابر ۰/۹۵۱ و ۳/۳۴۶ هستند. با توجه به نتایج نرمال‌سازی، برای $normal\ 1$ مقادیر NSC ، $BIAS$ و MAE به ترتیب مساوی ۰/۸۹۹، ۰/۴۹۷- و ۳/۳۰۳ به دست آمده است. این در حالی است که مقادیر $correlation\ coefficient$ و $scatter\ index$ برای حالت $without\ normal$ به ترتیب 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 $a = 2$ و $b = -1$ برای تخمین تغییرات تراز آب زیرزمینی استفاده می‌شود. نتایج شاخص‌های آماری در حالت تست برای نرمال‌سازی‌های مختلف در جدول (۲) مرتب شده است.

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

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

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

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

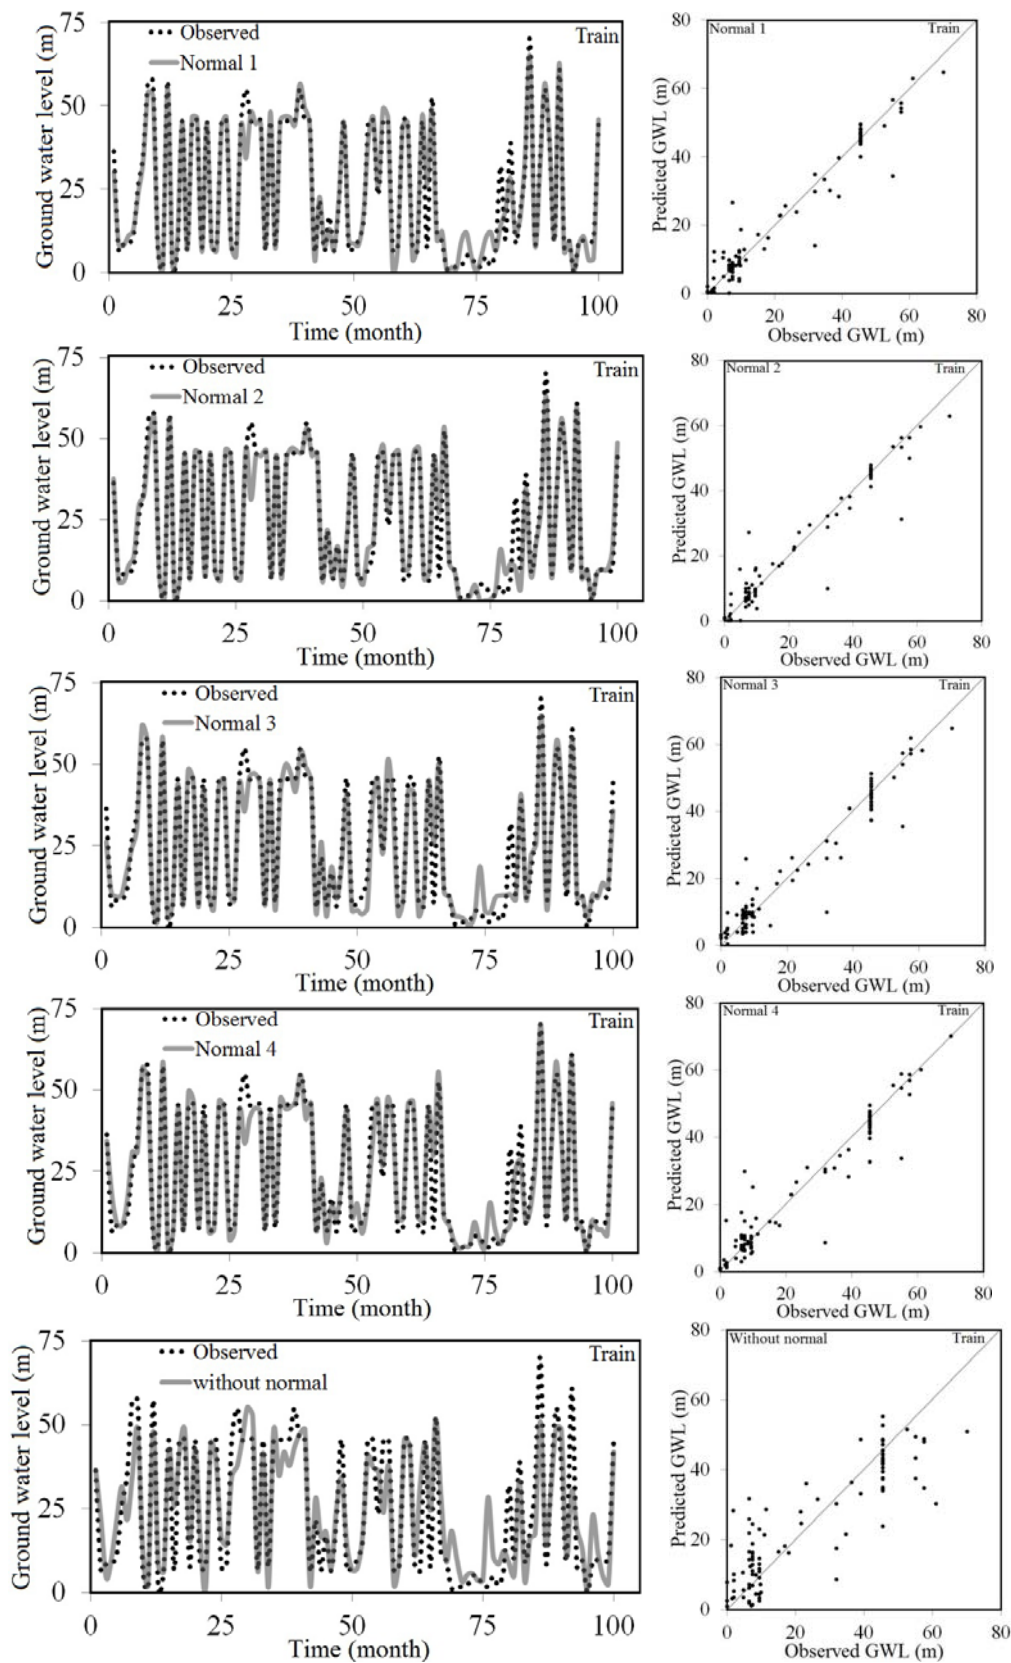
در اینجا O_i مقادیر مشاهداتی، F_i مقادیر پیش‌بینی شده به وسیله مدل‌های عددی، \bar{O} میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی است.

بحث و نتایج

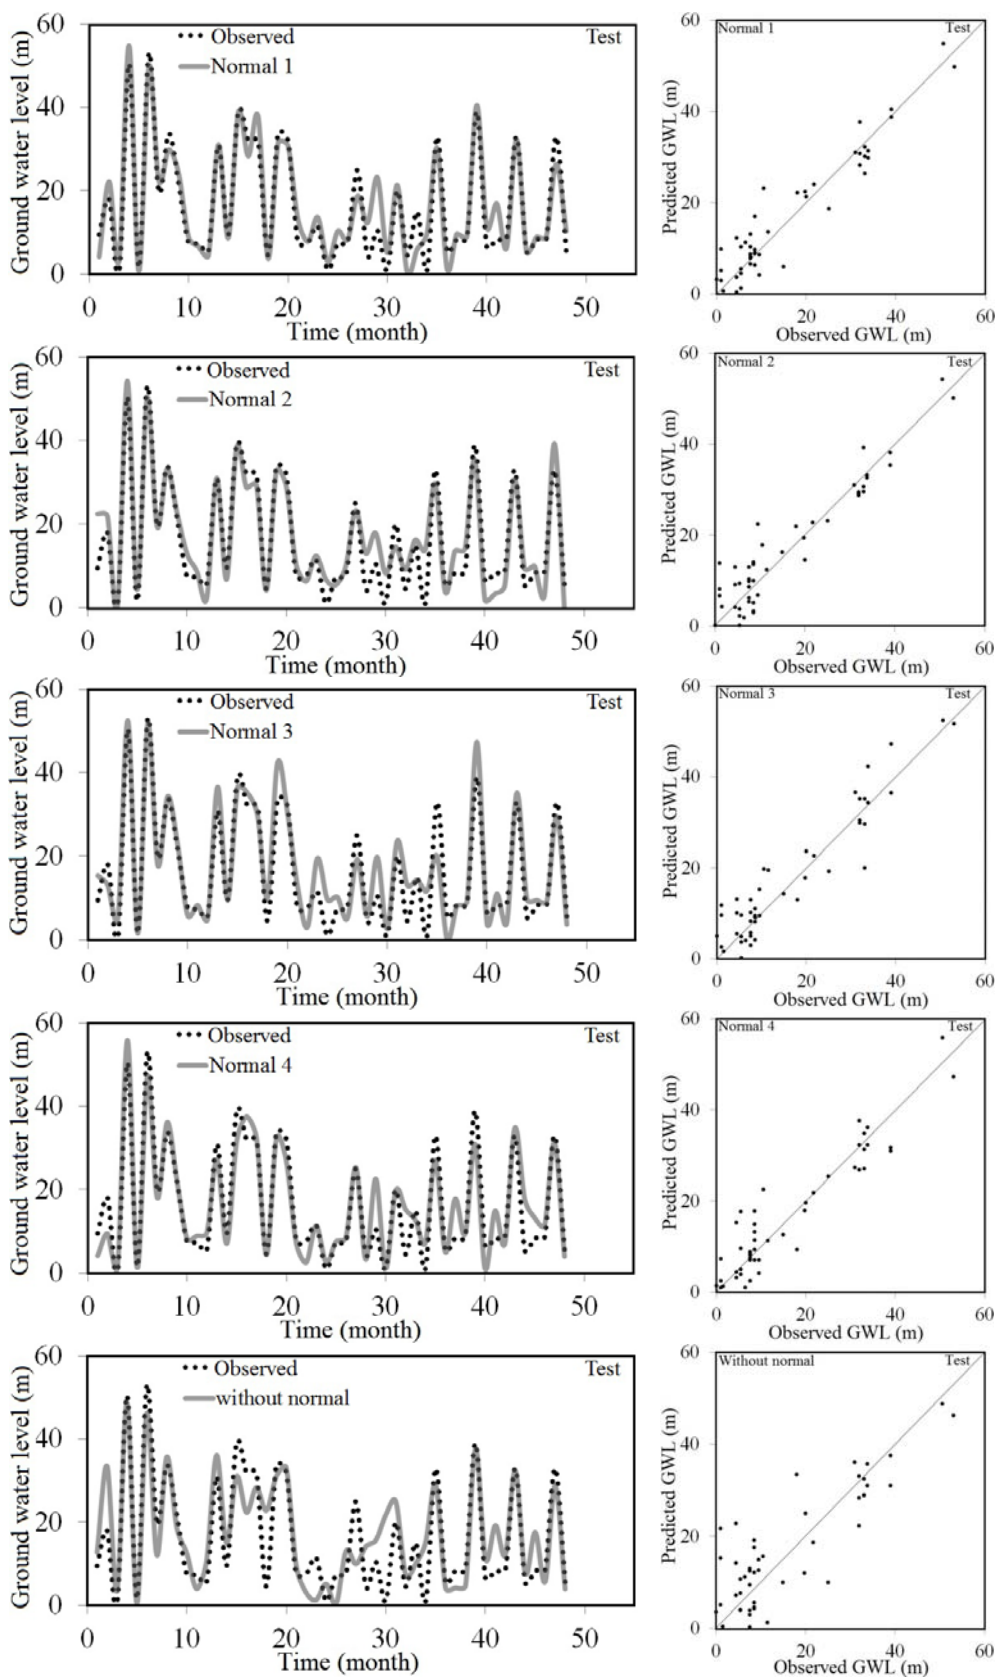
در ادامه، ابتدا به نرمال‌سازی نتایج مشاهداتی پرداخته می‌شود و بهینه‌ترین ضرایب نرمال‌سازی انتخاب می‌شوند. سپس به ارزیابی انتخاب خانواده موجک پرداخته می‌شود و بهترین خانواده موجک شناسایی می‌شود. در قسمت بعدی، هشت مدل مختلف برای هر یک از مدل‌های $SAELM$ و $WA-SAELM$ توسعه داده شده و با تجزیه و تحلیل نتایج 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




شکل ۲. مقایسه نتایج نرمال سازی شده با مقادیر مشاهداتی برای حالت های مختلف در حالت آموزش




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

جدول ۲. نتایج شاخص‌های آماری برای نرمال‌سازی‌های مختلف 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 مشاهده‌ای برای حالت آموزش



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

حالت تست در جدول (۳) نشان داده شده است. به‌عنوان مثال، مقادیر correlation coefficient، VAF و RMSE برای $coif^3$ 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 ($coif^3$) در حالت‌های آموزش و تست نشان داده شده است. بنابراین در ادامه برای تخمین تراز آب زیرزمینی توسط مدل

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 $coif^3$ 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

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

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

Wavelet-SAELM از coif۳ استفاده می‌شود.

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 به ترتیب مساوی ۰/۱۴۷، ۰/۳۰۰ و ۰/۵۳۹ محاسبه شده است. همچنین، مقدار NSC-Sutcliffe efficiency coefficient برای این مدل برابر ۰/۹۶۸ است.


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

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.

مدل‌های برتر

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

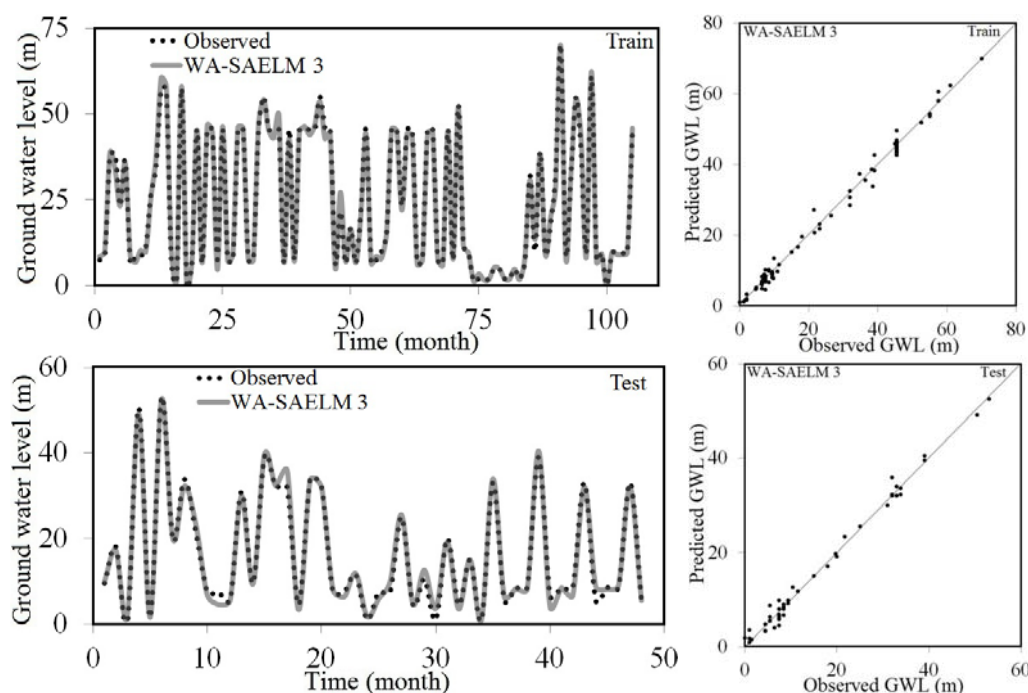
NSC	BIAS	RMSRE	MARE	MAE	SI	RMSE	VAF	R	
-۲/۵۰۷	-۱/۵۱۶	۴/۲۶۶	۱/۷۴۳	۱۰/۷۳۶	۰/۸۳۱	۱۳/۴۷۳	۶/۸۲۰	۰/۳۲۱	SAELM ۱
۰/۷۸۸	-۰/۸۳۹	۱/۰۴۳	۰/۳۱۰	۲/۴۵۳	۰/۳۷۴	۶/۰۶۱	۸۱/۲۶۶	۰/۹۰۲	SAELM ۲
۰/۹۶۸	۰/۵۳۹	۰/۹۸۰	۰/۲۵۸	۱/۳۰۰	۰/۱۴۷	۲/۳۸۰	۹۷/۲۰۶	۰/۹۸۶	SAELM ۳
۰/۹۳۰	۰/۳۰۲	۱/۰۶۲	۰/۴۳۳	۲/۳۶۳	۰/۲۱۷	۳/۵۰۹	۹۳/۶۴۷	۰/۹۶۸	SAELM ۴
۰/۹۳۵	-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

مقادیر R، MAE و NSC برای این مدل به ترتیب برابر ۰/۹۹۵، ۰/۷۸۸ 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 تجزیه و تحلیل نتایج مدل‌سازی‌های عددی، در بین کلیه مدل‌های معرفی شده، WA-SAELM ۳ به عنوان مدل برتر معرفی می‌شود. همچنین در جدول (۵) نتایج شاخص‌های آماری محاسبه شده برای مدل‌های

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. به عنوان مثال، مقادیر همچنین




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

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

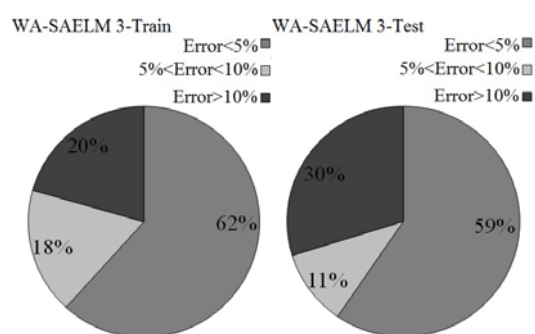
NSC	BIAS	RMSRE	MARE	MAE	SI	RMSE	VAF	R	
۰/۸۰۱	۰/۳۱۸	۰/۷۴۰	۰/۴۰۷	۳/۶۰۱	۰/۳۶۳	۵/۸۸۰	۸۲/۰۸۱	۰/۹۰۷	WA-SAELM ۱
۰/۹۰۷	۰/۳۶۹	۱/۵۴۱	۰/۵۶۶	۳/۲۶۷	۰/۲۶۷	۴/۳۲۵	۹۰/۳۴۷	۰/۹۵۳	WA-SAELM ۲
۰/۹۹۰	-۰/۰۶۰	۰/۴۴۵	۰/۱۷۸	۰/۹۸۸	۰/۰۸۴	۱/۳۵۷	۹۹/۰۴۴	۰/۹۹۵	WA-SAELM ۳
۰/۹۴۹	-۰/۷۲۹	۰/۵۷۸	۰/۳۴۰	۲/۵۷۹	۰/۲۰۱	۳/۲۶۴	۹۴/۷۳۶	۰/۹۷۵	WA-SAELM 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

توجه به نتایج توزیع خطا، در حدود ۴۳ مقادیر آب زیرزمینی پیش‌بینی شده توسط ۳ SAELM خطایی بیشتر از ۱۰ درصد به خود اختصاص داده‌اند. در حالت تست، مدل ۳ WA-SAELM 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 به ذکر است که در حدود ۱۱ درصد نتایج مدل ۳ WA-SAELM در حالت تست خطایی بین ۵ تا ۱۰ درصد دارند.

مختلف WA-SAELM نشان داده شده است. همچنین در ادامه به نحوه توزیع خطا برای مدل‌های برتر (WA-SAELM ۳ and WA-SAELM ۲) پرداخته می‌شود. در شکل‌های (۸) و (۹) نتایج توزیع خطا برای مدل‌های برتر در هر دو حالت آموزش و تست نشان داده شده است. به عنوان مثال در حالت آموزش، مدل SAELM ۳ تقریباً ۴۷ درصد نتایج مشاهده‌ای 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



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



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

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

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

تحلیل عدم قطعیت

در این قسمت تحلیل عدم قطعیت مدل‌های SAELEM ۳ and WA-SAELEM ۳ اجرا می‌شود. تحلیل عدم قطعیت برای ارزیابی خطای پیش‌بینی شده توسط مدل‌های عددی استفاده می‌شود که در آن مقدار خطای پیش‌بینی شده توسط مدل عددی (e_j) به صورت 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 پیش‌بینی شده به صورت $\bar{e} = \sum_{j=1}^n e_j$ به دست می‌آید. علاوه بر این، مقدار انحراف استاندارد مقادیر خطای پیش‌بینی شده نیز به صورت $S_e = \sqrt{\sum_{j=1}^n (e_j - \bar{e})^2 / n - 1}$ 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 $1/64 S_e \pm$ به صورت تقریبی منجر به ۹۵ درصد باند اطمینان می‌شود. در جدول (۶) نیز پارامترهای به دست آمده برای تحلیل عدم قطعیت مدل‌های SAELEM ۳ and WA-SAELEM ۳ در حالت تست مرتب شده است. با توجه به تحلیل عدم قطعیت، مدل SAELEM ۳ دارای عملکردی بیشتر از مقدار واقعی و WA-SAELEM ۳ نیز عملکردی کمتر از مقدار واقعی هستند. علاوه بر این ۹۵ درصد

coif4 به‌عنوان عضو برتر خانواده‌های موجک معرفی شد که دقت مدل ماشین آموزش نیرومند خود تطبیقی را بهبود بخشید. سپس مدل‌های برتر برای تخمین تراز آب زیرزمینی معرفی شدند. تجزیه و تحلیل 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 به ترتیب برابر ۹۹/۰۴۴، ۸۴/۰ و ۹۹/۰ محاسبه شدند. علاوه بر این نتایج تحلیل عدم قطعیت نشان داد که مدل برتر WA-SAELM دارای عملکردی کمتر از مقدار واقعی است. لازم به ذکر است که عرض باند عدم قطعیت برای مدل برتر بین مثبت ۳۹۹/۰ و منفی ۳۹۹/۰ به دست 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.

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

نتیجه‌گیری

در این مطالعه، نشان داده شد که مدل هوش مصنوعی نوین با عنوان ماشین آموزش نیرومند خود تطبیقی 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، به کمک تابع خود همبستگی، خود همبستگی نسبی و به کمک تأخیرهای مؤثر، هشت مدل متمایز SAELM و WA-SAELM معرفی شد. تجزیه و تحلیل نتایج مدل‌های عددی نشان داد که، الگوریتم تفاضل تکاملی توانایی قابل توجهی در افزایش دقت مدل ماشین آموزش نیرومند داشت. همچنین،

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

- 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. Mahamood 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.

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

F. Yosefvand* and S. Shabanlou¹

(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: fariborzosefvand@gmail.com