

پیش‌بینی تراز سطح آب زیرزمینی آبخوان دشت ارومیه با استفاده از مدل هیبرید تبدیل موجک-ماشین یادگیری بیشینه و بهینه‌سازی با ازدحام ذرات کوانتومی

سعید افخمی فر^۱ و امیرپویا صراف^{۲*}

^۱ دانشجوی کارشناسی ارشد مهندسی و مدیریت منابع آب، گروه مهندسی عمران، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران و
^۲ استادیار گروه مهندسی عمران، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران

تاریخ پذیرش: ۱۳۹۸/۰۵/۰۶

تاریخ دریافت: ۱۳۹۸/۰۳/۱۱

چکیده

امروزه با توجه به اهمیت بالای مدیریت پایدار آب‌های زیرزمینی، برای بررسی و ارزیابی منابع آب از مدل‌سازی و پیش‌بینی تراز آب‌های زیرزمینی (GWL) استفاده می‌شود. هدف از این پژوهش، ارزیابی عملکرد دو مدل ماشین یادگیری بیشینه (ELM) و شبکه عصبی مصنوعی (ANN) و همچنین، تلفیق آن دو مدل با الگوریتم تبدیل موجک (W-ELM و W-) است که در نهایت برای بالا بردن قدرت پیش‌بینی و بهینه‌کردن وزن‌های ورودی (وزن‌های بین لایه ورودی و پنهان) مدل‌ها، از الگوریتم بهینه‌ساز ازدحام ذرات کوانتومی (QPSO) استفاده شده است. همچنین، در این مطالعه، از داده‌های تراز آب زیرزمینی چاه‌های مشاهده‌ای (GWL)، میزان بارش (P) و همچنین، دمای متوسط (T) مربوط به حوضه دشت ارومیه با سری زمانی ۳۶ ساله (۱۳۶۰-۱۳۹۶) که در مقیاس ماهانه جمع‌آوری شده، استفاده شده و به منظور بررسی عملکرد مدل‌ها از سه معیار ضریب همبستگی (R)، جذر میانگین مربع خطا (RMSE) و میانگین قدر مطلق خطا (MAE) استفاده شده است. در این راستا، از ۸۰ درصد داده‌ها (مهر ۱۳۶۰ تا شهریور ۱۳۸۹) به منظور آموزش مدل‌ها و از ۲۰ درصد داده‌ها (مهر ۱۳۸۹ تا شهریور ۱۳۹۶) به منظور بخش آزمون استفاده شده است. بر اساس نتایج پژوهش حاضر، مدل هیبرید تبدیل موجک-ماشین یادگیری بیشینه-بهینه‌ساز ازدحام ذرات کوانتومی (W-ELM-QPSO) با داشتن ضریب همبستگی (R) به ترتیب ۰/۹۹۱، ۰/۹۸۳ و ۰/۹۷۵ برای دوره‌های یک، دو و سه ماهه در بخش آزمون، عملکرد بهتری نسبت به دیگر مدل‌ها داشته، همچنین، این مدل علاوه بر قدرت پیش‌بینی، از لحاظ سرعت آموزش و آزمون نیز نسبت به مدل‌های دیگر از سرعت بالایی برخوردار است.

واژه‌های کلیدی: شبکه عصبی مصنوعی، ELM، GWL، QPSO، WT

مقدمه

شناخت دقیق مشخصات هر آبخوان است که یکی از مهمترین مشخصات آن، سطح آب زیرزمینی (GWL) است. در این راستا، محققان راه‌حلی برای مدیریت آب‌های زیرزمینی (با توجه به روش‌های شبیه‌سازی-پیش‌بینی و اقدامات کنترل شده) و مقابله با مشکلات

در کشورهایی مانند ایران که با کمبود منابع آبی مواجه‌اند، توجه به کلیه منابع آبی از اهمیت بالایی برخوردار است. به همین خاطر، برای توسعه پایدار از مدیریت یکپارچه استفاده می‌شود. اولین قدم در آن،

موجک می‌توان یک سری زمانی غیرایستا را به چندین سری زمانی ایستا تجزیه کرد (Rajaei و Zeinivand, ۲۰۱۵). مدل‌های هیبریدی در مقایسه با مدل‌های دیگر نتایج بهتری را ارائه می‌دهند که با توجه به مطالعه‌ای که Sezen و Partal (۲۰۱۷) بر روی منطقه آنتالیا در ترکیه انجام دادند، دریافتند که مدل هیبریدی WGANN نسبت به سایر مدل‌ها و همچنین مدل GANN نسبت به مدل ANN از عملکرد بهتری برخوردار است. همچنین، در پژوهشی به‌وسیله Rajaei و همکاران (۲۰۱۴) پیش‌بینی بار رسوب معلق ایستگاه آب‌سنجی I واقع در آمریکا به‌وسیله مدل ترکیبی موجک-عصبی بررسی شد که نتایج نشان‌دهنده برتری روش مدل ترکیبی نسبت به سایر روش‌ها بود. در مطالعه‌ای دیگر، Adamowski و Chan (۲۰۱۱) با استفاده از مدل عصبی-موجک، به پیش‌بینی سطح آب زیرزمینی حوضه شاتوگای در کانادا پرداختند که نتایج این پژوهش نشان داد که مدل تلفیقی کارکرد بالاتری برای پیش‌بینی سطح آب زیرزمینی دارد.

علاوه بر مدل‌های بیان شده، در مطالعات پیش‌بینی هیدرولوژیکی مدل‌های دیگری هم وجود دارد که کمتر مورد بررسی قرار گرفته‌اند که از آن جمله می‌توان مدل ماشین یادگیری بیشینه (ELM) را نام برد که به‌عنوان یک روش هوش مصنوعی بهبودیافته تلقی می‌شود و این مدل به‌دلیل انتخاب تصادفی وزن ورودی و لایه پنهان داده‌ها، نیاز به زمان بسیار کمتر محاسباتی نسبت به مدل شبکه عصبی مصنوعی کلاسیک دارد. در این راستا، می‌توان به مطالعه‌ای که Deo و Sahin (۲۰۱۴) انجام داده‌اند، اشاره کرد. همچنین، برای حل مشکلات پیش‌بینی در پژوهش‌های مختلف از مدل ماشین یادگیری بیشینه (ELM) استفاده شده است (Li و همکاران، ۲۰۱۶). از مهمترین مزیت ماشین یادگیری بیشینه در مقایسه با مدل‌های دیگری همچون الگوریتم‌های پسانتشار خطا (BP) و ماشین‌های بردار پشتیبانی (SVM) سرعت بالای آن است (Rajesh و Prakash, ۲۰۱۱) که در این روش، بر خلاف مدل‌های دیگر شبکه عصبی مصنوعی، مرحله آموزش در عرض چند ثانیه انجام می‌شود (Acharya و همکاران، ۲۰۱۳). علاوه بر موارد مربوط به مدل‌سازی، در برخی پژوهش‌ها برای بهینه‌سازی عملیات پیش‌بینی از

برای مقابله طولانی مدت با کاهش منابع زمین و منابع آب زیرزمین ارائه کرده‌اند (Mohanty و همکاران، ۲۰۱۵). طی سال‌های اخیر پژوهش‌های زیادی در موضوع مدل‌سازی و پیش‌بینی انجام شده، همانند شبکه‌های عصبی مصنوعی (ANN)، سامانه‌های فازی (Fuzzy)، سامانه استنتاجی عصبی-فازی تطبیقی (ANFIS) و الگوریتم ژنتیک (Genetic) و غیره. شبکه‌های عصبی مصنوعی بر مبنای ایجاد سامانه‌ای که توانایی شبیه‌سازی محاسبات مغز را دارا است، به‌وجود آمده‌اند. این ساختار شبکه که به‌وسیله اتصال گره‌هایی به یکدیگر به‌وجود آمده، برای پیش‌بینی نتایج خروجی به‌کار می‌رود. همچنین، در این سامانه، هر گره یک واحد پردازش و اتصال بین گره‌ها نشان‌دهنده نحوه ارتباط آن‌ها است.

در این راستا، Yang و همکاران (۲۰۰۹) برای بررسی سطح آب زیرزمینی مناطق خشک و نیمه‌خشک استان جیلین در کشور چین، مدل‌های شبکه عصبی پسانتشار و سری زمانی را با هم مقایسه کردند که نتیجه پژوهش نشان‌دهنده برتری شبکه عصبی پسگرد خطا بوده است. همچنین، تحقیقات زیادی در زمینه استفاده از مدل (ANN) برای پیش‌بینی جریان رودخانه صورت گرفته که نتایج خوبی از آن‌ها گزارش شده‌اند (Coulbaly و همکاران، ۲۰۰۱). Taormina و همکاران (۲۰۱۵) سطح آب زیرزمینی آبخوانی در ونیز ایتالیا را با استفاده از شبکه عصبی با الگوریتم پس انتشار خطا، برای ساعات آینده پیش‌بینی کردند. Mokhtari و همکاران (۲۰۱۲) نیز با مدل شبکه عصبی، تراز آب زیرزمینی دشت شبستر را به‌صورت ماهانه مورد بررسی قرار دادند. همچنین، Yoon و همکاران (۲۰۱۶) در منطقه‌ای در کره جنوبی، پژوهشی در مورد پیش‌بینی آب‌های زیرزمینی در بازه زمانی بلندمدت انجام دادند که طی آن برتری پیش‌بینی برگشتی مدل ماشین بردار پشتیبان نسبت به شبکه عصبی مصنوعی نشان داده شد.

یکی از مشخصات فرایندهای هیدرولوژیکی دارا بودن داده‌های غیرایستا است. با وجود این‌که شبکه عصبی انعطاف‌پذیری بالایی دارد، ولی گاهی اوقات در پیش‌بینی سری‌های زمانی به‌شدت غیرایستا، دچار مشکل می‌شوند که در این صورت با استفاده از تبدیل


به‌خاطر داشتن قدرت بالای پیش‌بینی انتخاب شد. هدف از انجام پژوهش حاضر، پیش‌بینی تراز آب زیرزمینی حوضه آبخوان دشت ارومیه در استان آذربایجان غربی است که با بهره‌گیری از چهار مدل هوشمند، مدل ماشین یادگیری بیشینه (ELM)، مدل هیبرید تبدیل موجک-ماشین یادگیری بیشینه (W-ELM)، مدل شبکه عصبی مصنوعی (ANN) و مدل هیبرید تبدیل موجک-شبکه عصبی مصنوعی (W-ANN) و همچنین، بهینه‌کردن این چهار مدل به‌وسیله بهینه‌ساز ازدحام ذرات کوانتومی (QPSO) است.

مواد و روش‌ها

معرفی منطقه مورد پژوهش: دشت ارومیه با داشتن مساحتی به اندازه ۶۹۲ کیلومتر مربع در بخش ضلع غربی دریاچه ارومیه در استان آذربایجان غربی واقع شده است. طول این دشت در امتداد شمال-جنوب به‌طور متوسط حدود ۵۵ کیلومتر و در امتداد شرق-غرب حدود ۲۲ کیلومتر و ارتفاع دشت به‌طور متوسط حدود ۱۳۱۰ متر بالاتر از سطح آب‌های آزاد است. این دشت از لحاظ مشخصات جغرافیایی بین طول شرقی ۴۴° ۵۵' و ۴۵° ۱۸' و عرض شمالی ۲۰° ۳۷' و ۴۹° ۳۷' قرار دارد. همچنین، چهار رودخانه روضه‌چای، نازلوچای، شهرچای و باراندوزچای پس از عبور از ارتفاعات غربی وارد دشت ارومیه شده، به دریاچه ارومیه می‌ریزند (شکل ۱). این دشت دارای اقلیم سرد و خشک بوده، میانگین بارندگی سالانه در این دشت حدود ۳۲۹/۲ میلی‌متر است و همچنین، بارش‌ها در این منطقه به‌طور عمده بین ماه‌های مارس و می رخ می‌دهد. با توجه به کمینه دمای متوسط ۰/۳- درجه سانتی‌گراد و بیشینه دمای متوسط ۲۸/۲ درجه سانتی‌گراد، دمای متوسط سالانه این دشت حدود ۱۳/۵ درجه سانتی‌گراد است. در این دشت، برای جریان آب‌های زیرزمینی از سمت غرب به شرق بوده، با توجه به قرارگیری این دشت در ضلع غربی دریاچه ارومیه، مطالعه تراز آب‌های زیرزمینی این منطقه دارای اهمیت بالایی است و همچنین، در سال‌های اخیر با توجه به شرایط نامساعد دریاچه ارومیه و تاثیر آن بر پایین آمدن سطح آب‌های زیرزمینی این منطقه، تغییرات فراوانی در کیفیت آب‌های زیرزمینی رخ داده است.

الگوریتم‌های بهینه‌ساز ازدحام ذرات (PSO) و الگوریتم بهینه‌ساز ازدحام ذرات کوانتومی (QPSO) استفاده شده است. در این راستا، طی مطالعه‌ای MA و دیگران (۲۰۱۷) برای بهبود عملکرد ماشین یادگیری بیشینه (ELM)، طرحی را ارائه دادند که در این طرح برای پیش‌بینی پارامترهای عملکرد سامانه حرارتی و همچنین، افزایش عملکرد و کارایی الگوریتم ELM از بهینه‌ساز PSO استفاده کردند. در مطالعه‌ای دیگر، Liu و همکاران (۲۰۱۷) برای ارزیابی دقیق‌تر تبخیر با داده‌های محدود محیطی در شهر شانگ‌های کشور چین، از روش ترکیبی ماشین یادگیری بیشینه (ELM) با بهینه‌ساز ازدحام ذرات (PSO) استفاده کردند. نتایج حاکی از آن بود که روش تلفیقی ماشین یادگیری بیشینه-بهینه‌ساز ازدحام ذرات (ELM-PSO) نتایج بهتری نسبت به مدل‌های ELM، SVM، BP-PSO و BP دارد. طی پژوهشی دیگر، Alizamir و Sobhani Ardakani (۲۰۱۸) برای پیش‌بینی آلودگی فلزات سنگین در منابع آب زیرزمینی دشت تویسرکان استان همدان، از مدل تلفیقی شبکه عصبی مصنوعی بهینه‌ساز ازدحام ذرات (ANN-PSO) استفاده کردند که بر اساس نتایج، مدل فوق یک ابزار مفید در زمینه مسایل محیط زیست پیشنهاد شد. همچنین، Kisi و دیگران (۲۰۱۷) پژوهشی در بخش دشت شامیل-آشکارا در استان هرمزگان انجام دادند که طی این پژوهش برای بررسی نوسانات آب‌های زیرزمینی از سه الگوریتم (ANN-PSO)، (ANN-GA) و (ANN-ICA) استفاده شد. نتایج این پژوهش حاکی از آن بود که ANN-PSO قدرت پیش‌بینی بالاتری نسبت به دیگر مدل‌ها دارد.

در ادامه، Feng و Niu (۲۰۱۷) طی مطالعه‌ای بیان کردند که بهینه‌ساز ازدحام ذرات کوانتومی (QPSO) هر ذره، دارای رفتار کوانتومی است و نمی‌شود، مقادیر دقیق بردار موقعیت و بردار سرعت را در همان زمان به‌دست آورد. همچنین، Cheng و همکاران (۲۰۱۵) مطالعه‌ای در مورد رواناب روزانه، برای کنترل عملیات نیروگاه آبی و شبکه برق انجام دادند که در این مطالعه برای پیش‌بینی رواناب روزانه مخزن Hongjiadu در جنوب شرقی چین از مدل‌های متفاوتی استفاده شد که در نتیجه مدل هیبرید شبکه عصبی مصنوعی-الگوریتم بهینه‌ساز ازدحام ذرات کوانتومی (ANN-QPSO)



شکل ۱- موقعیت محدوده مطالعاتی

ایده‌ای برای پردازش اطلاعات بوده که از سامانه عصبی زیستی الهام گرفته، مانند مغز به پردازش اطلاعات می‌پردازد. عنصر کلیدی این ایده، ساختار جدید سامانه پردازش اطلاعات است. این سامانه از شمار زیادی عناصر پردازشی فوق‌العاده به هم پیوسته به نام نورون‌ها (Neurons) تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند. در این راستا، الگوریتم Levenberg-Marquardt یکی از سریع‌ترین روش‌های اجرا شده با عملکرد بالا، برای آموزش شبکه عصبی است (Huang و همکاران، ۲۰۰۶). در این مطالعه نیز، الگوریتم انتشار لونیگ-مارکارد برای آموزش داده‌های ورودی در مدل ANN مورد استفاده قرار گرفت.

تبدیل موجک: یک تبدیل ریاضی است که از تجزیه یک تابع بر مبنای توابعی به نام موجک است و ابزار مناسبی برای بررسی پدیده‌های گذراست. با تحلیل موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد که این موجک‌های تفکیک شده به نام موجک دختر شناخته می‌شوند. یافته‌های سال‌های اخیر نشان داده است که برای تحلیل و بدون ایجاد اختلال داده‌ها، بهتر است، از تبدیل‌های موجک استفاده کنیم. دو نوع تبدیل موجک وجود دارد، تبدیل موجک پیوسته (CWT) و تبدیل موجک گسسته (DWT)، که بر این اساس، فرمول موجک برابر است با.

در این پژوهش، به منظور انجام بررسی‌های لازم در سطح دشت، از داده‌های کمی ۴۷ حلقه چاه‌های مشاهداتی که دارای آمار بالای ۳۶ سال بودند (از سال ۱۳۶۰ تا ۱۳۹۶) استفاده شد که اطلاعات مربوطه از شرکت آب منطقه ای استان آذربایجان غربی و شرکت مدیریت منابع آب ایران دریافت شده است. با توجه به این‌که در دیگر مطالعات آب‌های زیرزمینی آبخوان دشت ارومیه از نمونه چاه‌های مشاهداتی استفاده شده، در این پژوهش، برای پیش‌بینی، از میانگین سطح آب‌های زیرزمینی کل آبخوان و همچنین، دما و میزان بارش متوسط ماهانه استفاده شده است. به همین خاطر، برای محاسبه میزان متوسط سطح آب زیرزمینی دشت، از رویکرد تیس‌بندی استفاده می‌شود، بدین‌صورت که دشت به چند بخش تقسیم می‌شود که در این تقسیم‌بندی، هر یک از ناحیه‌ها شامل یک نقطه اندازه‌گیری (چاه مشاهداتی) است. سپس، یک میانگین وزنی از اندازه‌گیری‌ها بر اساس اندازه چندضلعی هر یک از چاه‌ها به دست می‌آید، بدین‌صورت که در چند ضلعی‌های بزرگ اندازه‌گیری‌ها وزن بیشتری نسبت به چند ضلعی کوچک دارند. سطح آب زیرزمینی وزنی با استفاده از معادله زیر به دست می‌آید.

$$\overline{GWL} = \frac{GWL_1 A_1 + GWL_2 A_2 + \dots + GWL_n A_n}{A_1 + A_2 + \dots + A_n} = \frac{\sum_{i=1}^n GWL_i A_i}{\sum_{i=1}^n A_i} \quad (1)$$


شبکه عصبی مصنوعی: شبکه عصبی مصنوعی

است، معرفی کرد که طبق آن، خروجی هدف ELM برابر است با:

$$O_k = \sum_{i=1}^L \beta_i G(x_i) = \sum_{i=1}^L \beta_i G(a_i, b_i, x) \quad (3)$$

$k = 1.2 \dots N$

با توجه به بردار ورودی (x_i) و $\beta_1, b_1, a_1, O_i \in R^m$ و $G(a_i, b_i, x_i)$ به ترتیب برابر هستند با وزن‌های ورودی، بایاس، وزن‌های خروجی و تابع فعال‌سازی گره پنهان لایه L ام.



شکل ۲- معماری مدل ماشین یادگیری پیشینه

با توجه به یافته‌های هوآنگ و همکاران ماشین یادگیری پیشینه توانایی تقریب تمام نمونه‌های آموزش با خطای صفر در شبکه تک لایه رو به جلو را دارد (Jang و همکاران، ۱۹۹۷)، همچنین، بر اساس β_1, a_1 و b_1 روابط به‌صورت زیر است.

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

$$H = \begin{bmatrix} G(a_1, b_1, x_1) & G(a_2, b_2, x_1) & \dots & G(a_L, b_L, x_1) \\ G(a_1, b_1, x_2) & G(a_2, b_2, x_2) & \dots & G(a_L, b_L, x_2) \\ \dots & \dots & \dots & \dots \\ G(a_1, b_1, x_N) & G(a_2, b_2, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (5)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad (6)$$

$$T = \begin{bmatrix} t_1^T \\ t_2^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (7)$$

ماتریس $H = [g(a_i, b_i, x_i)]_{N \times L}$ نشان‌دهنده

ماتریس خروجی لایه پنهان، $\beta = (\beta_1, \beta_2, \dots, \beta_L)^T$ برابر است با وزن بین لایه پنهان و لایه خروجی و همچنین، $T = (t_1, t_2, \dots, t_N)^T$ نشان‌دهنده ماتریس خروجی هدف می‌باشد.

این معادلات را می‌توان به‌عنوان یک سامانه خطی خاص در نظر گرفت که در آن H متغیر مستقل از N

$$CWT_y(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} y(t) \psi \times \left(\frac{t-b}{a} \right) dt \quad (2)$$

که در آن، ψ موجک مادر، a پارامتر مقیاس و b پارامتر تبدیل است. همچنین، مقدار CWT ضریب موجک نامیده می‌شود. با توجه به نبود اجزای اضافی در داده‌های تبدیل‌یافته با DWT ، برای پردازش و تحلیل سری‌های زمانی، تبدیل گسسته موجکی عملکرد بهتری نسبت به تبدیل پیوسته موجکی دارد.

از تحلیل موجک می‌توان به‌عنوان یکی از بهترین روش‌ها در زمینه‌های هیدرولوژی و مطالعات منابع آب اشاره کرد که با استفاده از آن می‌توان یک سری زمانی را به فرکانس‌های پایین و بالا تجزیه کرد (Adamowski و همکاران، ۲۰۰۹؛ Nalley و همکاران، ۲۰۱۳). بر این اساس، می‌توان سری‌های زمانی جدید حاصل از این تحلیل را به شکل‌های مختلف به‌عنوان ورودی در مدل‌های ANN و ELM مورد استفاده قرار داد. از مهمترین موجک‌های مادر می‌توان به موجک‌های هار، دابوچی، سیملت، کویفلت، میر، گوسین و مورلت اشاره کرد. یکی دیگر از مزایای تبدیل موجک، انعطاف‌پذیری در انتخاب یک موجک مادر با توجه به خواص سری زمانی است (Pingale و همکاران، ۲۰۱۴). در این پژوهش، از تبدیل موجک گسسته (DWT) برای تجزیه داده‌های سری زمانی مربوط به سطح آب‌های زیرزمینی و دما و بارش استفاده شد.

ماشین یادگیری پیشینه (ELM): مدل ماشین یادگیری پیشینه به‌وسیله Huang و همکاران (۲۰۰۶) تهیه شده است. این مدل یک روش یادگیری موثر برای شبکه‌های رو به جلو تک لایه است که از سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) تشکیل یافته است (Zhu و همکاران، ۲۰۰۵). در ساختار ELM ، وزن ورودی (اتصال بین لایه ورودی و لایه پنهان) و مقادیر بایاس (در لایه پنهان) به‌طور تصادفی تولید می‌شوند. به‌طور کلی، ELM دارای توانایی درون‌یابی و تقریب‌پذیری و همچنین، ابزاری مناسب برای پیش‌بینی سری زمانی است (Abdullah و همکاران، ۲۰۱۵). در شکل ۲، ساختار مدل ماشین یادگیری پیشینه نشان داده شده است.

به زبان ریاضی، ELM را می‌توان به‌عنوان یک تابع با تعداد N نمونه آموزشی که $(x_i, t_i) \in R^t \times R^m$

تعداد نمونه، β ماتریس ضریب حل و T ماتریس ارزش مشاهده است. در این راستا، پس از تولید ماتریس ضریب لایه ورودی-پنهان، ELM به صورت تحلیلی ماتریس وزن لایه پنهان-خروجی را با یافتن کوچکترین راه حل مقادیر کمینه مربعات سامانه پیشین خطی (Huang و همکاران، ۲۰۱۲) تعیین می کند. معادله مربوطه برابر است با:

$$\beta = H^{\dagger} T \quad (8)$$

نهایتاً، ELM تمایل دارد که عملکرد تعمیم پذیری مطلوب را، با سرعت آموزش سریع تر از سایر الگوریتم های سنتی به دست آورد (Huang و همکاران، ۲۰۱۵).

بهینه سازی ازدحام ذرات (PSO): الگوریتم PSO یک تکنیک بهینه سازی است که برای اولین بار به وسیله دکتر راسل ابرهات و جیمز کندی در سال ۱۹۹۵ به عنوان یک الگوریتم تکاملی بر پایه جمعیت، ارائه شد (Eberhart و Shi، ۲۰۰۱). اصول این الگوریتم پیشنهادی، از رفتار اجتماعی پرندگان و ماهی ها الهام گرفته شده است. راهبرد به کار رفته این است که پرندگان به دنبال پرندگی حرکت می کنند که نزدیک ترین فاصله را تا غذا دارد و هم زمان از تجربه قبلی خود برای پیدا کردن غذا استفاده می کنند (Kennedy و Eberhart، ۱۹۹۵). هر ذره با داشتن دو بردار سرعت و وضعیت، بیانگر یک جواب در فضای D بعدی مسئله است. در این راستا با توجه به دو پارامتر بهترین وضعیت ملاقات شده به وسیله ذره ($pbest$) و بهترین وضعیت ملاقات شده در تمامی ذرات ($gbest$)، حرکت هر ذره در فضای جستجو تعیین می شود. با توجه به معادلات زیر، در هر بار پردازش الگوریتم، بردارهای سرعت و وضعیت به روزرسانی می شوند.

$$v_{id}^{n+1} = x(wv_{id}^n + c_1 r_1^n (p_{id}^n - x_{id}^n) + \quad (9)$$

$$c_2 r_2^n (p_{gd}^n - x_{id}^n) \\ x_{id}^{n+1} = x_{id}^n + v_{id}^{n+1} \quad (10)$$

که در آن ها، $d=(1,2,\dots,D)$ برابر تعداد ابعاد بردار هر ذره و در $i=(1,2,\dots,N)$ که N برابر است با اندازه جمعیت، c_1 و c_2 دو ثابت به نام های ضرایب شناختی و اجتماعی و پارامترهای r_1 و r_2 نیز اعداد تصادفی با توزیع یکنواخت بین صفر و یک است. همچنین، ω معرف وزن اینرسی و X عامل انقباض نامیده می شوند.

است:

$$mbest = 1/n \times \sum_{i=1}^n Pbest(i) \quad (11)$$

$$P = \alpha \times Pbest(i) + (1 - \alpha) \times Gbest \quad (12)$$

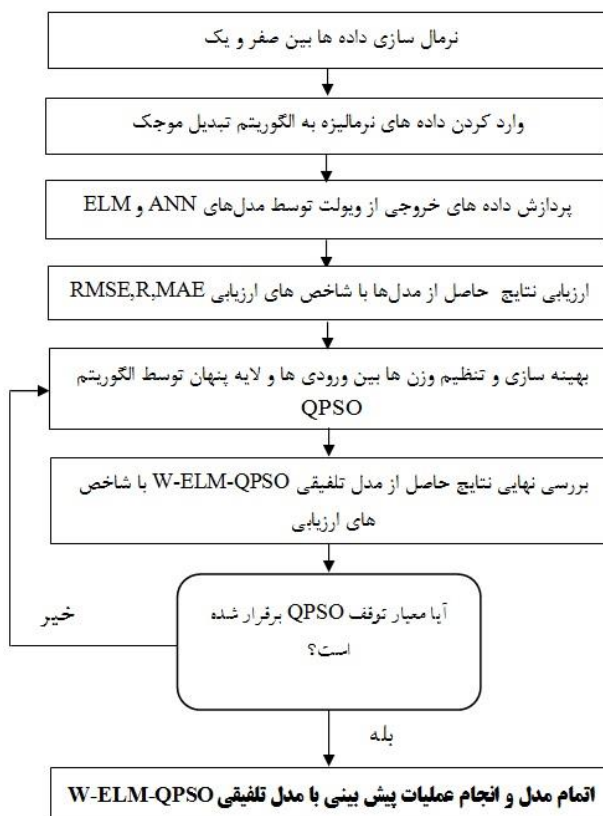
$$\beta = 1 - gen / max\ gen \times 0.5 \quad (13)$$

$$X_i = P \pm \beta \times |mbest - X_i| \times \ln(1/\mu) \quad (14)$$

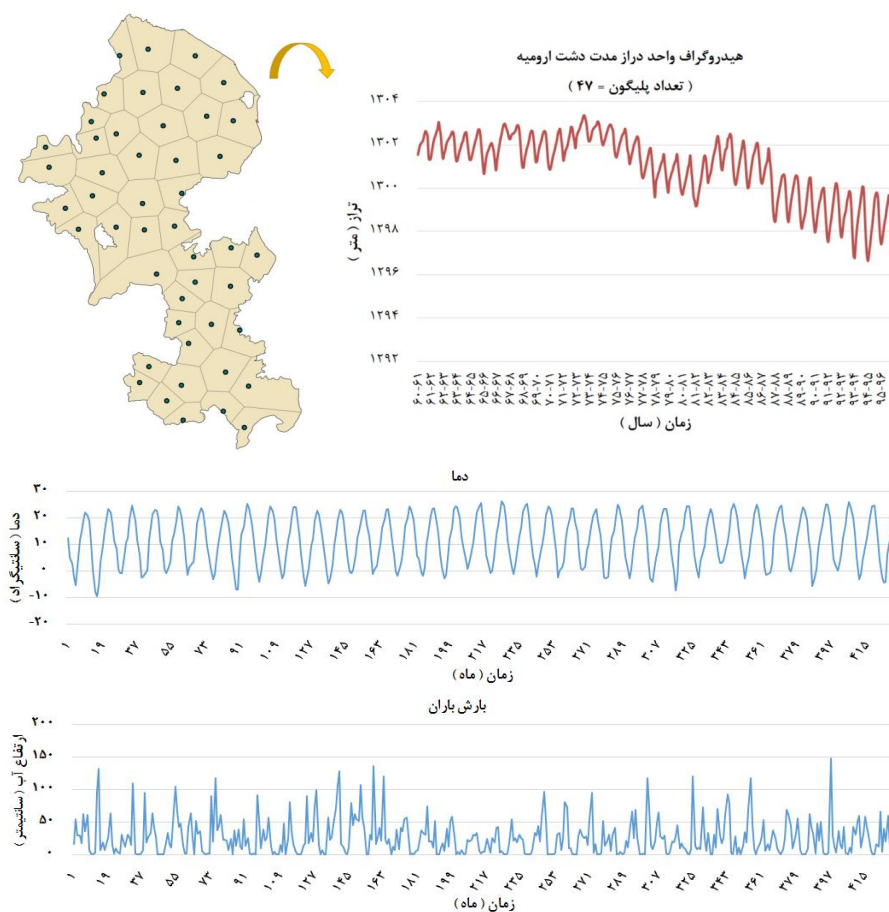
که در آن ها، $mbest$ میانگین بهترین موقعیت ذرات $Pbest(i)$ ، α و μ اعداد تصادفی توزیع شده بین صفر و یک است. همچنین، مقدار gen تعداد فعلی تکرار و $max\ gen$ بیشینه تعداد تکرار است و β ضریب انبساطی-انقباضی و تنها پارامتر در الگوریتم QPSO است.

معماری ماشین یادگیری بیشینه و شبکه عصبی مصنوعی: در این پژوهش، برای پیش بینی در محیط نرم افزار متلب^۱، از مدل های ELM، ANN و همچنین، دو مدل دیگر که تلفیقی از تبدیل موجک با این دو مدل است (W-ANN و W-ELM) استفاده شده است که در نهایت، هر دو مدل به وسیله بهینه ساز ازدحام ذرات کوانتومی (QPSO) بهینه سازی شده اند (شکل ۳). بدین صورت که ابتدا پارامترهای سطح آب زیرزمینی (GWL)، دمای متوسط (T) و بارش متوسط (P) ماهانه به عنوان داده های ورودی (شکل ۴) وارد برنامه می شوند. در این راستا با توجه به توضیحات قبلی (رویکرد تیسن بندی)، ارتفاع متوسط سطح آب زیرزمینی کل آبخوان به دست می آید.

¹ Matlab



شکل ۳- مراحل اجرای مدل W-ELM-QPSO



شکل ۴- تیسنبندی و نمودار سطح آب زیرزمینی و دما و بارش متوسط ماهیانه مربوط به ۳۶ سال

شامل ۲۰ درصد داده‌های نهایی یعنی از مهر سال ۱۳۸۹ تا شهریور سال ۱۳۹۶ است. همچنین، طبق جدول ۱، از ترکیب‌های مختلف داده‌ها به‌عنوان ورودی برای پیش‌بینی آب‌های زیرزمینی یک و دو و سه ماهه استفاده شد.

در ادامه، برای وارد کردن داده‌های ورودی به هر دو مدل ELM و ANN، داده‌های ۳۶ سال موجود (شهریور ۱۳۶۰ تا شهریور ۱۳۹۶) به دو قسمت آموزش و آزمون تقسیم شد. بدین‌صورت که ابتدا بخش آموزش که شامل ۸۰ درصد داده‌ها یعنی از مهر سال ۱۳۶۰ تا شهریور سال ۱۳۸۹ و مرحله بعدی بخش آزمون که

جدول ۱- داده‌های ترکیبی استفاده شده در مدل‌های ELM و ANN

ردیف	داده‌های ترکیبی
۱	$GWL_t \cdot GWL_{t-1} \cdot GWL_{t-2} \cdot GWL_{t-3}$
۲	$GWL_{t-1} \cdot T_{t-1} \cdot GWL_{t-1} \cdot T_{t-2} \cdot GWL_{t-1} \cdot T_{t-3} \cdot GWL_t \cdot GWL_{t-1} \cdot T_{t-2} \cdot GWL_t, GWL_{t-1} \cdot T_{t-3} \cdot GWL_t, GWL_{t-1} \cdot P_{t-1} \cdot GWL_t, GWL_{t-1} \cdot P_{t-2} \cdot GWL_t, GWL_{t-1} \cdot P_{t-3} \cdot GWL_t, GWL_{t-1} \cdot P_{t-1} \cdot T_{t-1} \cdot GWL_t, GWL_{t-1} \cdot P_{t-2} \cdot T_{t-2} \cdot GWL_t, GWL_{t-1} \cdot P_{t-3} \cdot T_{t-3}$
۳	$GWL_t, GWL_{t-1} \cdot GWL_{t-2} \cdot T_{t-1} \cdot T_{t-2} \cdot GWL_t, GWL_{t-1} \cdot GWL_{t-2} \cdot P_{t-1} \cdot P_{t-2} \cdot GWL_t, GWL_{t-1} \cdot GWL_{t-2} \cdot T_{t-1} \cdot T_{t-2} \cdot P_{t-1} \cdot P_{t-2} \cdot GWL_t, GWL_{t-1} \cdot GWL_{t-2} \cdot T_{t-1} \cdot T_{t-2} \cdot P_{t-1} \cdot P_{t-2} \cdot GWL_t, GWL_{t-1} \cdot GWL_{t-2} \cdot GWL_{t-3} \cdot T_{t-1} \cdot T_{t-2} \cdot T_{t-3} \cdot GWL_t, GWL_{t-1} \cdot GWL_{t-2} \cdot GWL_{t-3} \cdot P_{t-1} \cdot P_{t-2} \cdot P_{t-3} \cdot GWL_t, GWL_{t-1} \cdot GWL_{t-2} \cdot T_{t-1} \cdot T_{t-2} \cdot P_{t-1} \cdot P_{t-2} \cdot GWL_t, GWL_{t-1} \cdot GWL_{t-2} \cdot GWL_{t-3} \cdot T_{t-1} \cdot T_{t-2} \cdot T_{t-3} \cdot P_{t-1} \cdot P_{t-2} \cdot P_{t-3}$


آید که در نهایت تعداد ۱۴، ۲۵ و ۳۲ گره در وضعیت بهینه برای ELM در دوره‌های یک و دو و سه ماهه معین و برای معماری مدل ELM حالت ۱-۱۴-۳، ۱-۲۵-۳ و ۱-۳۲-۳ نوروں انتخاب شد. در ادامه، برای حذف پارامترهای لحظه‌ای و بالابردن دقت پیش‌بینی (بالابردن ضریب همبستگی) علاوه بر مدل ELM از مدل W-ELM نیز استفاده شد.

این مدل هم مانند مدل ELM دارای سه لایه است، به این صورت که ابتدا در لایه ورودی، داده‌های تجزیه شده به‌وسیله تبدیل موجک کویفلت ۵ (به‌عنوان تابع منتخب) با سطح ۴، در نظر گرفته شدند، سپس، همانند مدل ELM، با به‌کارگیری تابع سیگموئید و تغییر دادن تعداد نوروں‌های لایه پنهان، بهترین حالت را یعنی ۴۶، ۳۶ و ۴۰ گره به‌ترتیب برای دوره زمانی یک، دو و سه ماهه به‌دست آوردیم که در نهایت در لایه خروجی یک نوروں به‌عنوان پیش‌بینی ماهانه سطح آب زیرزمینی به‌دست آمد (شکل ۶). در ادامه، برای نشان دادن قابلیت مدل ELM و W-ELM برای پیش‌بینی سطح آب زیرزمینی، مقایسه‌ای بین عملکرد آن‌ها و مدل‌های ANN و W-ANN که به‌عنوان برآوردگرهای جهانی شناخته شده‌اند، انجام گرفت.

نتایج و بحث

در پژوهش حاضر، داده‌های ورودی در محدوده صفر و یک استاندارد شدند و همان‌طور که قبلاً نیز اشاره شد، برای بالابردن هرچه بیشتر دقت پیش‌بینی علاوه بر الگوریتم‌های بالا از دو مدل دیگر که تلفیقی از تبدیل موجک با مدل‌های ELM و ANN است، استفاده شد. بدین‌صورت که ابتدا داده‌های ورودی به‌وسیله توابع مختلف تبدیل موجک مورد تجزیه قرار گرفتند و در نهایت موجک کویفلت ۵ به‌عنوان تابع منتخب انتخاب شد (شکل ۵). در مرحله بعد، از داده‌های خروجی الگوریتم تبدیل موجک به‌عنوان داده‌های ورودی به هر دو مدل استفاده شد.

در ادامه، برای طراحی مدل ELM از سه لایه استفاده شد تا به‌وسیله آن پیش‌بینی سطح آب زیرزمینی به‌صورت ماهانه انجام شود. در این مدل، از توابع مختلف همچون Sigmoid، Hard Limit و Sine استفاده شد که نهایتاً با توجه به نتایج به‌دست آمده در دوره‌های یک، دو و سه ماهه، تابع سیگموئید (Sigmoid) با داشتن نتایج مطلوب‌تری نسبت به دیگر توابع، برای مدل ELM انتخاب شد. سپس در هر بار آزمایش تعداد گره‌ها در لایه پنهان تغییر پیدا کرد (تعداد گره‌ها بین یک تا ۱۲۰) تا حالت بهینه به‌دست



شکل ۵- تجزیه داده‌های مربوط به سطح آب زیرزمینی و دما و بارش به‌وسیله موجک Coif5 (سطح چهارم)

بهینه‌ساز ازدحام ذرات کوانتومی (QPSO) استفاده شد تا در نهایت با انجام دادن این امر نتایج مربوط به ضریب همبستگی (R) بهبود یابد. در نهایت، با توجه

پس از بررسی و نتیجه‌گیری مدل‌ها، برای بهینه کردن هر چه بیشتر وزن‌های تصادفی بین لایه ورودی و لایه پنهان مدل ماشین یادگیری پیشینه (ELM) از

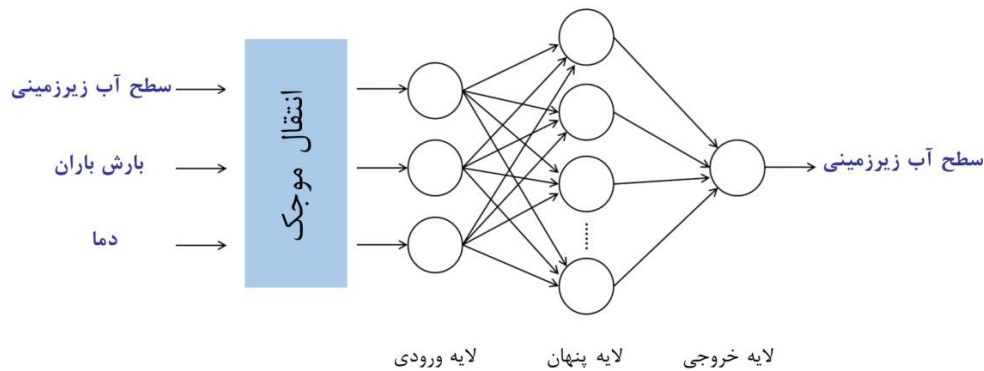
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - o_i)^2} \quad (16)$$

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(o_i - \bar{o})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (o_i - \bar{o})^2}} \quad (17)$$

در ادامه، با توجه به ترکیب داده‌های ورودی در نظر گرفته شده، طبق جدول ۲ بهترین نتایج مربوط به مدل‌ها به دست آمدند.

به داده‌های ورودی، قابلیت پیش‌بینی ماهانه هر شش الگوریتم با استفاده از شاخص‌های متفاوت خطای جذر میانگین مربعات (RMSE)، میانگین مطلق خطا (MAE) و ضریب همبستگی (R) مورد ارزیابی قرار گرفتند.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - o_i| \quad (15)$$



شکل ۶- معماری ماشین یادگیری پیشینه

جدول ۲- شاخص‌های متفاوت RMSE-R-MAE برای بررسی مدل‌ها

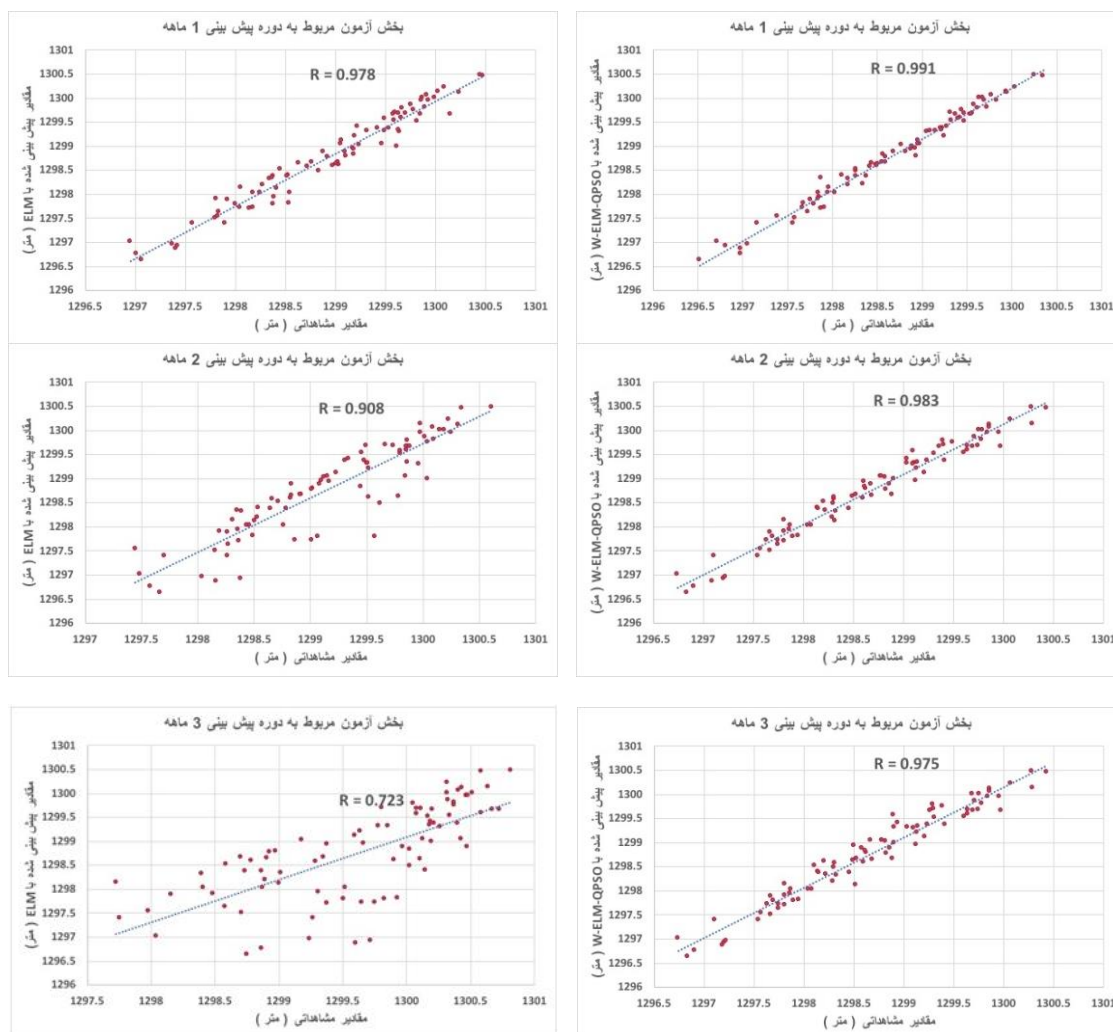
دوره	مدل	آموزش			آزمون			آموزش	آزمون
		RMSE	R	MAE	RMSE	R	MAE		
یک ماهه	ELM	۰/۴۶۷	۰/۹۸۷	۰/۳۸۷	۰/۷۶۸	۰/۹۷۸	۰/۸۲۱	۰/۰۰۱	۰/۱
	W-ELM	۰/۴۱۰	۰/۹۹۴	۰/۳۱۷	۰/۸۶۷	۰/۹۸۷	۰/۷۳۸	۰/۱	۰/۱۲
	W-ELM-QPSO	۰/۳۹۷	۰/۹۹۶	۰/۲۹۷	۰/۶۷۸	۰/۹۹۱	۰/۵۱۲	۰/۰۱	۰/۲
	ANN	۱/۳۷۱	۰/۹۴۵	۱/۰۴۷	۲/۱۴۲	۰/۹۴۵	۲/۲۱۸	۰/۱۲	۱/۸۷
	W-ANN	۱/۲۹۸	۰/۹۸۱	۱/۱۴۵	۲/۲۷۰	۰/۹۷۶	۲/۱۱۵	۰/۱۴	۲/۱۳
۲ ماهه	W-ANN-QPSO	۱/۱۴۲	۰/۹۸۴	۱/۰۸۹	۲/۱۸۵	۰/۹۸۰	۲/۲۴۶	۰/۲۸	۲/۳۹
	ELM	۰/۴۱۷	۰/۹۴۳	۰/۴۸۷	۰/۷۱۲	۰/۹۰۸	۰/۷۸۹	۰/۰۰۱	۰/۱۴
	W-ELM	۰/۳۸۷	۰/۹۸۷	۰/۲۴۷	۰/۵۷۸	۰/۹۷۱	۰/۴۷۶	۰/۰۰۲	۰/۱۵
	W-ELM-QPSO	۰/۳۱۴	۰/۹۹۰	۰/۲۷۸	۰/۵۴۸	۰/۹۸۳	۰/۳۸۷	۰/۰۳	۰/۲۱
	ANN	۱/۲۲۳	۰/۸۹۴	۱/۰۲۵	۲/۴۱۶	۰/۸۷۶	۲/۲۳۲	۰/۱۲	۱/۹۴
۳ ماهه	W-ANN	۱/۳۱۵	۰/۹۲۱	۱/۰۶۱	۲/۰۳۴	۰/۹۱۸	۱/۶۶۰	۰/۲۱	۲/۵۴
	W-ANN-QPSO	۰/۹۸۷	۰/۹۴۳	۰/۹۱۲	۱/۸۹۸	۰/۹۳۶	۱/۶۸۵	۰/۳۹	۲/۶۸
	ELM	۰/۳۸۹	۰/۸۵۲	۰/۴۱۶	۰/۶۹۸	۰/۷۲۳	۰/۷۵۴	۰/۰۰۱	۰/۱۴
	W-ELM	۰/۳۵۷	۰/۹۸۲	۰/۲۳۴	۰/۵۱۴	۰/۹۶۵	۰/۴۲۸	۰/۰۰۳	۰/۱۸
	W-ELM-QPSO	۰/۲۸۷	۰/۹۸۷	۰/۲۶۷	۰/۴۷۸	۰/۹۷۵	۰/۳۵۱	۰/۰۴	۰/۲۱
QPSO	ANN	۰/۹۶۶	۰/۸۲۴	۰/۸۱۷	۲/۳۳۵	۰/۷۲۴	۰/۸۶۹	۰/۱۵	۲/۰۲
	W-ANN	۱/۲۴۰	۰/۸۶۷	۱/۳۲۴	۱/۶۸۲	۰/۸۸۴	۱/۵۶۵	۰/۲۴	۲/۶۱
	W-ANN-QPSO	۰/۹۱۳	۰/۹۱۸	۰/۸۷۹	۱/۷۴۰	۰/۹۱۲	۱/۵۴۷	۰/۴۲	۲/۸۳

بررسی حالت‌های مختلف در جدول بالا نشان داد که برای دوره‌های یک، دو و سه ماهه، ترکیب داده‌های سطح آب زیرزمینی (GWL)، بارش (P) و دمای متوسط (T) ماهانه بهترین نتایج را نسبت به دیگر ترکیب‌های به کار رفته می‌دهند. همچنین، با بررسی معیارهای پیش‌بینی هر شش مدل ELM، W-ELM، W-ANN- و W-ANN، ANN، W-ELM-QPSO در دوره‌های زمانی مختلف این نتایج به دست

تاریک‌ترین نتایج را نسبت به دیگر ترکیب‌های به کار رفته می‌دهند. همچنین، با بررسی معیارهای پیش‌بینی هر شش مدل ELM، W-ELM، W-ANN- و W-ANN، ANN، W-ELM-QPSO در دوره‌های زمانی مختلف این نتایج به دست

برای انتخاب مدل برتر، سرعت فرایند پیش‌بینی است که با توجه به سرعت آموزش و آزمون در الگوریتم‌های یادگیری ماشین بیشینه (ELM) و الگوریتم‌های هیبرید آن (W-ELM و W-ELM-QPSO)، این نتیجه به‌دست آمد که در بحث پیش‌بینی منابع آب، سرعت آموزش و آزمون در مدل‌های ماشین یادگیری بیشینه نسبت به دیگر مدل‌های به‌کار گرفته شده از مقدار بالایی برخوردار هستند.

آمد که مدل W-ELM-QPSO در مقایسه با مدل‌های دیگر از نتایج بهتری برخوردار هست که طبق شکل ۷، نتایج نهایی به‌دست آمده از مدل‌ها در حالت ساده (ELM) و بهینه شده (W-ELM-QPSO) با مقادیر مشاهده شده (واقعی) مورد مقایسه قرار گرفتند. همچنین، با توجه به اینکه در مطالعات آب‌های زیرزمینی از داده‌های نسبتاً زیادی استفاده می‌شود، علاوه بر قدرت پیش‌بینی، یکی از مهمترین ویژگی‌ها



شکل ۷- ارزیابی ضریب همبستگی مربوط به هر شش مدل در مرحله آزمون

ماشین یادگیری بیشینه (ELM) و همچنین، تلفیق آن با تبدیل موجک و بهینه‌سازی با الگوریتم ازدحام ذرات کوانتومی استفاده شود و همچنین، برای بررسی، این مدل‌ها با مدل‌های ANN، W-ANN و W-ANN-QPSO مورد مقایسه قرار گیرند. نهایتاً، با مقایسه عملکرد هر شش مدل و تجزیه و تحلیل ضرایب

نتیجه‌گیری

اساس این مطالعه، بررسی امکان‌سنجی مدل‌های ELM، W-ELM و W-ELM-QPSO برای پیش‌بینی رابطه غیرخطی متغیرهای ورودی و مقادیر ماهانه سطح آب زیرزمینی است. در این پژوهش، تلاش بر آن شد که برای پیش‌بینی سطح آب زیرزمینی از مدل

زیرزمینی ماهانه بیش از دیگر مدل‌ها از قابلیت بالایی برخوردار است.

۳. در این پژوهش، در راستای استفاده از الگوریتم تبدیل موجک و کم شدن میزان خطا و بالا رفتن دقت پیش‌بینی در هر دو مدل W-ELM و W-ANN این نتیجه به دست آمد که برای تجزیه داده‌های ورودی، استفاده از الگوریتم تبدیل موجک Coif5 نسبت به دیگر توابع موجک (haar, db, sym) از نتایج مطلوب‌تری برخوردار است که با توجه به نتایج به دست آمده با بالا بردن بازه زمانی پیش‌بینی (دو و سه ماهه) نتایج بهتری به دست می‌آید.

۴. با استفاده از بهینه‌ساز ازدحام ذرات کوانتومی (QPSO) می‌توان وزن بین لایه ورودی و لایه پنهان مدل‌ها را بهینه کرد. در این راستا، به‌خاطر تصادفی انتخاب شدن وزن بین لایه‌ها در بخش آموزش مدل ماشین یادگیری بیشینه و مدل‌های تلفیقی آن می‌توان با انتخاب بهترین وزن‌ها و بهینه کردن آن‌ها، باعث بالا رفتن ضریب همبستگی و در کل بالا رفتن درصد پیش‌بینی مدل شد.

بر اساس این پژوهش، برای پیش‌بینی ماهانه سطح آب زیرزمینی، مدل W-ELM-QPSO نسبت به دیگر مدل‌های به کار رفته، از لحاظ قدرت پیش‌بینی و سرعت پردازش دارای مهارت بالایی است. همچنین، علاوه بر داده‌های سطح آب زیرزمینی، استفاده از داده‌های دما و بارش متوسط ماهانه به‌عنوان ورودی مدل، کمک زیادی برای پیش‌بینی هر چه دقیق‌تر و سریع‌تر سطح آب زیرزمینی و همچنین، مدیریت منابع آب دارد.

ارزیابی مختلف (RMSE, MAE و R)، نتیجه این‌گونه به دست آمد که در پیش‌بینی سطح آب زیرزمینی ماهانه، مدل W-ELM-QPSO دارای مقدار بالایی ضریب همبستگی (R) است که در این صورت به‌طور قابل ملاحظه‌ای نسبت به مدل‌های دیگر از عملکرد بالایی برخوردار است.

با توجه به نتایج به دست آمده علاوه بر دقت پیش‌بینی، سرعت پیش‌بینی مدل W-ELM-QPSO در بخش آموزش برای دوره یک ماهه به ترتیب نه، ۱۱ و ۱۲ برابر سریع‌تر و در بخش آزمون به ترتیب ۱۲، ۱۴ و ۲۸، برای دوره دو ماهه به ترتیب نه، ۱۲ و ۱۳ برابر سریع‌تر و در بخش آزمون به ترتیب چهار، هفت و ۱۳ و برای دوره سه ماهه به ترتیب ۱۰، ۱۲ و ۱۳ برابر سریع‌تر و در بخش آزمون به ترتیب چهار، شش و ۱۱ برابر سریع‌تر از مدل‌های ANN، W-ANN و W-ANN-QPSO است.

با توجه به توضیحات بالا به‌طور خلاصه، یافته‌های زیر ذکر شده‌اند.

۱. با بررسی قابلیت برآورد و سرعت محاسبات مدل ماشین یادگیری بیشینه (ELM) و مدل‌های تلفیقی آن در مقایسه با مدل‌های دیگر، این نتیجه به دست آمد که سرعت مرحله آموزش و آزمون هر سه مدل در مقایسه با دیگر مدل‌ها بالا بوده، بنابراین، به‌طور قابل توجهی، زمان محاسباتی را نسبت به مدل‌های دیگر کاهش می‌دهند.
۲. با توجه به داده‌های منطقه‌ای از لحاظ مطابقت بین مقادیر پیش‌بینی شده و مشاهده شده، مدل W-ELM-QPSO دارای مقدار بالایی ضریب همبستگی (R) است که در این صورت برای پیش‌بینی سطح آب

منابع مورد استفاده

1. Acharya, N., N.A. Shrivasta, B.K. Panigrahi and U.C. Mohanty. 2013. Development of an artificial neural network based multi-model ensemble to estimate the northeast monsoon rainfall over south peninsular India: an application of extreme learning machine. *Climate Dynamics*, 43: 1303-1310.
2. Adamowski, J. and H. Fung Chan. 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407(1-4): 28-40.
3. Adamowski, K., A. Prokoph and J. Adamowski. 2009. Development of a new method of wavelet aided trend detection and estimation. *Hydrological Processes*, 23(18): 2686-2696.
4. Alizamir, M. and S. Sobhanardakani. 2018. An Artificial Neural Network-Particle Swarm Optimization (ANN-PSO) approach to predict heavy metals contamination in groundwater resources. *Jundishapur Journal of Health Sciences*, doi: 10.5812/jjhs.67544.
5. Cheng, C.T., W.J. Niu, Z.K. Feng, J.J. Shen and K.W. Chau. 2015. Daily reservoir runoff forecasting method using artificial neural network based on quantum-behaved particle swarm optimization.

- Water, 7(8): 4232-4246.
6. Coulibaly, P., F. Anctil, R. Aravena and B. Bobde. 2001. Artificial neural network modeling of water table depth fluctuations. *Water Resources Research*, 37(4): 885-896.
 7. Deo, R.C. and M. Şahin. 2014. Application of the extreme learning machine algorithm for the prediction of monthly effective drought index in eastern Australia. *Atmospheric Research*, 153: 512-525.
 8. Fang, W., L. Juan, Y. Ding and X. Wu. 2010. A Review of quantum-behaved particle swarm optimization. *IETE Technical Review*, 27(4): 10-26.
 9. Feng, Z.K., W.J. Niu and C.T. Cheng. 2017. Multi-objective quantum-behaved particle swarm optimization for economic environmental hydrothermal energy system scheduling. *Energy*, 131: 15-26.
 10. Huang, G., G.B. Huang, S. Song and K. You. 2015. Trends in extreme learning machines: a review. *Neural Networks*, 61: 32-48.
 11. Huang, G.B., L. Chen and C.K. Siew. 2006. Universal approximation using incremental constructive feedforward networks with random hidden nodes. *Ieee Transactions on Neural Networks*, 17(4): 879-892.
 12. Huang, G.B., H. Zhou, X. Ding and R. Zhang. 2012. Extreme learning machine for regression and multiclass classification. *Ieee Transactions on Systems, Man and Cybernetics*, 42(2): 513-529.
 13. Huang, G.B., Q.Y. Zhu and C.K. Siew. 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70: 489-501.
 14. Jang, J.S.R., C.T. Sun and E. Mizutani. 1997. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. *IEEE Transactions on Automatic Control*, 42(10): 1482-1484.
 15. Kisi, O., M. Alizamir and M. Zounemat-Kermani. 2017. Modeling groundwater fluctuations by three different evolutionary neural network techniques using hydroclimatic data. *Natural Hazards*, 87: 367-381.
 16. Li, Z., L. Ye, Y. Zhao, X. Song, J. Teng and J. Jin. 2016. Short-term wind power prediction based on extreme learning machine with error correction. *Protection and Control of Modern Power Systems*. doi: 10.1186/s41601-016-0016-y.
 17. Liu, T., Y. Ding, X. Cai and X. Zhang. 2017. Extreme learning machine based on particle swarm optimization for estimation of reference evapotranspiration. *Proceedings of the 36th Chinese Control Conference*, July 26-28, 2017, Dalian, China.
 18. Mokhtari, Z., A. Nazemi and A. Nadiri. 2012. Prediction of groundwater level using artificial neural networks, case study: Shabestar Plain. *Journal of Geotechnical Geology*, 8(4): 345-353.
 19. Nalley, D., J. Adamowski, B. Khalil and B. Ozga-Zielin. 2013. Trend detection in surface air temperature in Ontario and Quebec, Canada during 1967-2006 using the discrete wavelet transform. *Atmospheric Research*, 132-133(2013): 375-398.
 20. Pingale, S.M., D. Khare, M.K. Jat and J. Adamowski. 2014. Patial and temporal trends of mean and extreme rainfall and temperature for the 33 urban centers of the arid and semi-arid state of Rajasthan, India. *Atmospheric Research*, 138: 73-90.
 21. Rajaei, T., V. Nourani, M. Zounemat-Kermani and O. Kisi. 2011. River suspended sediment load prediction: application of ANN and wavelet conjunction model. *Journal of Hydrologic Engineering*, 16(8): 10-26.
 22. Rajaei, T. and A. Zeinivand. 2014. Modeling of groundwater level using a wavelet-hybrid model-artificial neural network, case study: Sharifabad Plain. *Journal of Civil and Environmental Engineering*, 44(4): 12-36.
 23. Sezen, C. and T. Partal. 2017. A wavelet transformation-genetic algorithm-artificial neural network combined model for precipitation forecasting. *The Eurasia Proceedings of Science, Technology, Engineering and Mathematics (EPSTEM)*, 1: 372-378.
 24. Shi, Y. and R. Eberhart. 2001. Fuzzy adaptive particle swarm optimization. *Proceedings of the 2001 Congress on Evolutionary Computation*, Seoul, South Korea, doi: 10.1109/CEC. 2001. 934377
 25. SultanAbdulla, S., M. Malek, N. SultanAbdullah, O. Kisi and K. Siah Yap. 2015. Extreme learning machines: a new approach for prediction of reference evapotranspiration. *Journal of Hydrology*, 527: 184-195.
 26. Taormina, R., K.W. Chau and B. Sivakumar. 2015. Neural network river forecasting through baseflow separation and binary-coded swarm optimization. *Journal of Hydrology*, 529(3): 1788-1797.

27. Yang, Z., W. Lu, Y. Long and P. Li. 2009. Application and comparison of two prediction models for groundwater levels, a case study in Western Jilin Province, China. *Journal of Arid Environments*, 73: 487-492.
28. 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 longterm groundwater level predictions. *Computers and Geosciences*, 90: 144-155.
29. Zhu, Q.Y., A. Qin, P. Suganthan and G.B. Hu. 2005. Evolutionary extreme learning machine. *Pattern Recognition*, 38: 1759-1763.