



Prediction of fluctuations in the groundwater level of Sonqor Plain using machine learning methods

Abbas Rasool Javad Al-Suraifi¹ , Reza Shirinabadi^{2✉} , HamidReza Rabieifar³ , Mohsen Najarchi⁴ 

¹ Ph.D. student of Civil Engineering, Department of Civil Engineering and Research Center for Modeling and Optimization in Science and Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran. E-mail: abbasarsarifi@gmail.com

² Corresponding Author, Associate Professor, Department of Civil Engineering and Research Center for Modeling and Optimization in Science and Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran. E-mail: re.shirinabadi@gmail.com

³ Assistant Professor, Department of Civil Engineering and Research Center for Modeling and Optimization in Science and Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran. E-mail: H_rabieifar@azad.ac.ir

⁴ Associate Professor, Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran. E-mail: mohsennajarchi@yahoo.com

ABSTRACT

The fluctuation of groundwater level is one of the important criteria required for decision-making in many water resources exploitation models. The lack of reliable and complete data is one of the most important challenges in analyzing the decline and predictions of the groundwater level in water management. In recent years, the use of different numerical models has been noticed as a reliable solution. These models are able to estimate based on extensive statistics and information and based on various land maps and measurements such as pumping tests, geophysics, soil and land use maps, topography and slope data, different boundary conditions and using complex equations. The level of groundwater in any region. In the present research, first, by using available statistics and information and maps, the fluctuations of the groundwater level of Sonqor Plain were simulated by the GMS model, and the accuracy of the model was evaluated in two stages of calibration and validation. Then, due to the need for much less data in machine learning methods, GWO-ANN and PSO-ANN hybrid methods and LSTM and SAELM models were used. The results showed that the output of the SAELM model had the best fit with the observational data with a correlation coefficient equal to 0.97, and it also had the best and closest distribution of points around the 45 degree line, and in this sense, it is considered the most accurate model. Therefore, to predict the level of groundwater in the whole plain, instead of using the complex GMS model with a very large volume of data and also a very time-consuming calibration and validation process, SAELM model can be used with confidence. This approach greatly helps the researchers of the groundwater sector to predict the changes of the groundwater level in dry and wet years without using numerical models with a complex and time-consuming structure using artificial intelligence with high accuracy.

Keywords: Groundwater level, GMS, Hybrid models, LSTM, SAELM

Article Type: Research Article

Article history: Received: 16 December 2023 Revised: 19 February 2024 Accepted: 07 March 2024 ePublished: 26 March 2024

1. Introduction

The fluctuation of groundwater level is one of the important criteria required for decision-making in many water resources exploitation models. The lack of reliable and complete data is one of the most important challenges in analyzing the decline and predictions of the groundwater level in water management. In recent years, the use of different numerical models has been noticed as a reliable solution. These models are able to estimate based on extensive statistics and information and based on various land maps and measurements such as pumping tests, geophysics, soil and land use maps, topography and slope data, different boundary conditions and using complex equations. The level of groundwater in any region.

The studied area is Sonqor plain in the west of Iran, located at a distance of 100 km northwest of Kermanshah city (Figure (1)). Sonqor plain is one of the fertile plains in Kermanshah province, whose needs are provided by two systems of surface water and groundwater. Part of the water needed in the plain is provided by Shohada Dam and the rest is provided by 278 deep wells dug in the south and west of the plain.

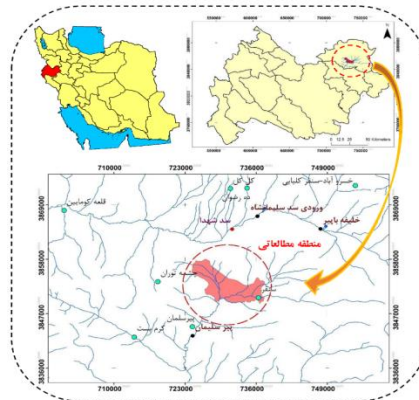


Figure 1. The location of the study area

2. Methodology

In the present research, first, by using available statistics and information and maps, the fluctuations of the groundwater level of Sonqor Plain were simulated by the GMS model, and the accuracy of the model was evaluated in two stages of calibration and validation. Then, due to the need for much less data volume in machine learning methods, GWO-ANN and PSO-ANN hybrid methods and LSTM and SAELM models were used.

Based on the general direction of the groundwater flow in the entire Sonqor plain, the grid direction was considered to be 250x250 meters in the north direction. Therefore, the model network was built with 2596 cells (44 rows and 59 columns) with 250 meters intervals, which included 908 active cells and 1688 inactive cells. In this study, the general head boundary package was used to simulate the entry and exit borders of Sangar plain. In this package, the inlet or outlet flow is affected by the hydraulic gradient at the boundary and the conductance of the boundary cell. Using the prepared geophysical sections and the data log of the wells, a bedrock map of the plain was prepared. Also, the DEM map of the plain was used to determine the upper limits of the layer in the groundwater model. In the GMS model, the WELL package was used to simulate exploitation wells in Sonqor Plain (278 wells) and well cells were identified. The recharge of the plain is one of the important parameters in the groundwater model. Usually, due to the different characteristics of soil, geology, vegetation, rainfall intensity and the slope of the land, the amount of groundwater recharge is different in different places. In the GMS model, the RCH package is used to consider the recharge. The zoning method was used to estimate the hydrodynamic parameters of the aquifer. The zoning of the area for hydraulic guidance and specific yield was done based on the well log, exploratory and piezometric wells, as well as geophysical sections prepared from the area. According to the type of soil and sediments of each zone, the initial values of hydraulic conductivity and specific yield were estimated. Finally, after performing the calibration process, for each zone, the optimized value of hydraulic conductivity and specific drainage was taken into account. In the groundwater simulation section, after the calibration and validation tests of the model in two permanent and non-permanent modes and ensuring its accuracy, the final zoning of the main parameters of the model, i.e. hydraulic conductivity and specific drainage, was prepared so that the model can predict the changes in the groundwater level for 6 years. Simulate consecutively. Because all the required information was available for 6 years (October 2019 to September 2015).

3. Results and discussion

The results of calibration and validation of the GMS model in transient state during the 6-year period from October 2009 to September 2015 showed that the model is able to accurately predict the changes in the groundwater level due to the stresses applied to it. So that the value of RMSE considering all simulation months is around 0.42. The results showed that the output of the SAELM model had the best fit with the observational data with a correlation coefficient equal to 0.97, and it also had the best and closest distribution of points around the 45 degree line, and in this sense, it is considered the most accurate model. Therefore, to predict the level of groundwater in the whole plain, instead of using the complex GMS model with a very large volume of data and also a very time-consuming calibration and validation process, SAELM model can be used with confidence.

4. Conclusions

This approach greatly helps the researchers of the groundwater sector to predict the changes of the groundwater level in dry and wet years without using numerical models with a complex and time-consuming structure using artificial intelligence with high accuracy.

5. Conflict of Interest

Authors declared no conflict of interest.

Cite this article: Al-Suraifi, A.R.J., Shirinabadi, R., Rabiefar, H.R., & Najarchi, M. (2024). Prediction of fluctuations in the groundwater level of Sonqor Plain using machine learning methods, *Advanced Technologies in Water Efficiency*, 4(1), 99-118. DOI: 10.22126/atwe.2024.10418.1117



پیش بینی نوسانات تراز آب زیرزمینی دشت سنقر با استفاده از روش های یادگیری ماشین

عباس رسول جواد الصریفی^۱، رضا شیرین آبادی^۲، حمید رضا ربیعی فر^۳، محسن نجارچی^۴

^۱ دانشجوی دکتری مهندسی عمران، گروه مهندسی عمران و مرکز تحقیقات مدل سازی و بهینه سازی در علوم و مهندسی واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، تهران، رایانامه: abbasalsarifi@gmail.com

^۲ نویسنده مسئول، دانشیار، گروه مهندسی عمران و مرکز تحقیقات مدل سازی و بهینه سازی در علوم و مهندسی واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، تهران، رایانامه: re.shirinabadi@gmail.com

^۳ استادیار، گروه مهندسی عمران و مرکز تحقیقات مدل سازی و بهینه سازی در علوم و مهندسی واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، تهران، رایانامه: H_rabieifar@azad.ac.ir

^۴ دانشیار، گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی واحد اراک، اراک، ایران. رایانامه: mohsennajarchi@yahoo.com

چکیده

نوسانات تراز آب زیرزمینی از معیارهای مهم مورد نیاز برای تصمیم گیری در بسیاری از مدل های بهره برداری از منابع آب است. کمبود داده های قابل اعتماد و کامل از مهم ترین چالش ها در واکاوی افت و پیش بینی های تراز آب زیرزمینی در مدیریت آب است. طی سالیان اخیر استفاده از مدل های عددی مختلف توانسته است به عنوان یک راهکار قابل اطمینان مورد توجه قرار گیرد. این مدل ها بر اساس آمار و اطلاعات گسترده و بر اساس نقشه ها و اندازه گیری های متنوع زمینی مانند آزمایش های پمپاژ، ژئوفیزیک، نقشه های خاک و کاربری اراضی، داده های توپوگرافی و شیب، شرایط مرزی مختلف و بهره گیری از معادلات پیچیده قادر به تخمین تراز آب زیرزمینی در هر منطقه ای هستند. در تحقیق حاضر ابتدا با استفاده از آمار و اطلاعات و نقشه های موجود نوسانات تراز آب زیرزمینی دشت سنقر توسط مدل GMS شبیه سازی شد و دقت مدل در دو مرحله واسنجی و صحت سنجی مورد ارزیابی قرار گرفت. سپس به دلیل نیاز به حجم داده بسیار کمتر در روش های یادگیری ماشین، روش های هیبرید GWO-ANN و PSO-ANN و مدل های LSTM و SAELM مورد استفاده قرار گرفت. نتایج نشان داد خروجی مدل SAELM دارای بهترین برازش با داده های مشاهداتی با ضریب همبستگی برابر با ۰/۹۷ بود، همچنین دارای بهترین و نزدیک ترین پراکندگی نقاط در اطراف خط $x=y$ بود و از این نظر دقیق ترین مدل در بین مدل های مورد استفاده محسوب می شود. لذا برای پیش بینی تراز آب زیرزمینی در کل دشت بجای استفاده از مدل پیچیده GMS با حجم داده های بسیار زیاد و همچنین فرآیند واسنجی و صحت سنجی بسیار وقت گیر در آن، می توان با اطمینان از مدل SAELM استفاده کرد. این رویکرد کمک زیادی به محققین بخش آب زیرزمینی می کند تا بدون استفاده از مدل های عددی با ساختار پیچیده و وقت گیر با استفاده از هوش مصنوعی با دقت بالا تغییرات تراز آب زیرزمینی را در سال های خشک و تر پیش بینی نمایند.

واژه های کلیدی: تراز آب زیرزمینی، GMS، مدل های هیبرید، LSTM، SAELM

نوع مقاله: مقاله پژوهشی

سابقه مقاله: دریافت: ۲۵ آذر ۱۴۰۲ اصلاح: ۳۰ بهمن ۱۴۰۲ پذیرش: ۱۷ اسفند ۱۴۰۲ چاپ الکترونیکی: ۰۷ فروردین ۱۴۰۳

استناد: الصریفی، ع. ر. ج.، شیرین آبادی، ر.، ربیعی فر، ح. ر.، و نجارچی، م. (۱۴۰۳). پیش بینی نوسانات تراز آب زیرزمینی دشت سنقر با استفاده از روش های یادگیری ماشین، فناوری های پیشرفته در بهره وری آب، ۴(۱)، ۹۹-۱۱۸. شناسه دیجیتال: 10.22126/atwe.2024.10418.1117



مقدمه

افزایش بی‌رویه جمعیت، محدودیت منابع آب‌های سطحی و بهره‌برداری بیش‌ازاندازه از آبخوان‌ها باعث وارد آمدن خسارات جبران‌ناپذیری به منابع طبیعی ایران در سال‌های گذشته شده است. علاوه برافت شدید سطح آب در آبخوان‌ها، فعالیت‌های کشاورزی، صنعتی و شهری آلاینده‌های مختلفی را به آبخوان‌ها تحمیل می‌کنند که برای جلوگیری از ادامه افت کمی و کیفی، مدیریت بهره‌برداری و حفاظت از آب‌های زیرزمینی باید به‌عنوان یک اصل و پایه در برنامه‌ریزی‌های کشور قرار گیرد. با گسترش سکونت در مناطقی که آب سطحی وجود ندارد یا مقدار آن کم است، استفاده از منابع آب زیرزمینی به‌عنوان جایگزینی مطمئن، موردتوجه قرار گرفت. به‌طوری‌که در برخی مناطق آب‌های زیرزمینی به‌عنوان تنها منبع تأمین آب محسوب می‌شوند. لذا برای برنامه‌ریزی بهتر و استفاده بنی از منابع آب زیرزمینی باید راهکارهایی برای پیش‌بینی دقیق نوسانات آب زیرزمینی بخصوص در سالهای خشک و کم آب بکار گرفته شود. به‌منظور ارزیابی اثرات ناشی از توسعه، بر روی منابع آب‌های زیرزمینی چه از نقطه‌نظر کمی و چه کیفی، شبیه‌سازی ریاضی و کامپیوتری این منابع ابزاری قوی در بهره‌برداری بهینه از این منابع محسوب می‌گردد. در سال‌های اخیر مدل‌های ریاضی و کامپیوتری متعددی به‌منظور شبیه‌سازی رفتار هیدرولیکی منابع آب‌های زیرزمینی و پیش‌بینی نوسانات تراز آب زیرزمینی موردتوجه قرار گرفته است.

مبانی نظری و پیشینه پژوهش

بررسی روند پیشرفت مدل‌های عددی نشان می‌دهد مجموعه‌ای از عوامل مختلف مانند شرایط مرزی و محیطی، خصوصیات فیزیکی و هیدرولیکی آبخوان، مقاطع رودخانه و سطح خیس شده، پارامترهای هیدرولیکی آبخوان، نحوه توزیع و برداشت آب در دشت، پارامترهای تغذیه آبخوان، عوامل توپوگرافی و زمین‌شناسی و غیره در شبیه‌سازی تغییرات تراز آب زیرزمینی مؤثر هستند (یوسف‌اند و شعبانلو^۱، ۲۰۲۰؛ پورسعید و همکاران^۲، ۲۰۲۰، ۲۰۲۱، ۲۰۲۲، گورانی و شعبانلو^۳، ۲۰۲۱؛ ترابی و همکاران^۴، ۲۰۲۴، و عزیزی و همکاران^۵، ۲۰۲۳، ۲۰۲۴). بسیاری از این مدل‌ها مانند MODFLOW و GMS بر مبنای روش عددی تفاضل محدود توسعه‌یافته‌اند و در تحقیقات مختلف به تعریف و آماده‌سازی اطلاعات و نقشه‌های ورودی و خروجی بر اساس یک استاندارد خاص نیاز دارند (محمد و همکاران^۶، ۲۰۲۳، عزیز پور و همکاران^۷، ۲۰۲۱، ۲۰۲۲، مزرعه و همکاران^۸، ۲۰۲۳، ۲۰۲۴، رجبی و شعبانلو^۹، ۲۰۱۲، و فلاحی و همکاران^{۱۰}، ۲۰۲۳).

در چنین ساختارهایی بررسی پارامترهای اقلیمی مانند دما و بارش بر کل سیستم و پیش‌بینی تغییرات تراز آب زیرزمینی در سال‌های آتی تحت تأثیر این پارامترها با استفاده از مدل‌سازی ریاضی موضوع را پیچیده‌تر می‌کند و استخراج نتایج معتبر در این زمینه نیاز به زمان و هزینه زیادی دارد (شرستا و همکاران^{۱۱}، ۲۰۱۶، و لمیووکس و همکاران^{۱۲}، ۲۰۱۵).

به خاطر ارتباط غیرقابل‌انکار آب‌های سطحی و زیرزمینی، استفاده از مدل‌های تلفیقی و بررسی اثر متقابل برداشت از آب سطحی و زیرزمینی بر تغییرات تراز آبخوان موردتوجه محققان قرار گرفت که نیازمند اضافه کردن اطلاعات و پارامترهای جدید مرتبط با آب سطحی و زیرزمینی است که گاهی این اطلاعات در دسترس نیستند (گراهام و همکاران^{۱۳}، ۲۰۱۵، جورج و همکاران^{۱۴}، ۲۰۱۳، و ژی و همکاران^{۱۵}، ۲۰۱۶).

¹ Yosefvand & Shabanlou

² Poursaeid et al

³ Goorani & Shabanlou

⁴ Torabi et al

⁵ Azizi et al

⁶ Mohammad et al

⁷ Azizpour et al

⁸ Mazraeh et al

⁹ Rajabi & Shabanlou

¹⁰ Fallahi et al

¹¹ Shrestha et al

¹² Lemieux et al

¹³ Graham et al

¹⁴ Jorge et al

¹⁵ Xie et al

در برخی تحقیقات، برای پیش‌بینی تغییرات تراز آب زیرزمینی در کل دشت، اتصال مدل‌های آب سطحی و زیرزمینی بر اساس شبیه‌سازی ناحیه اشباع و غیراشباع صورت گرفته است. منطقه غیراشباع مرز بین سطح زمین و سطح آب زیرزمینی است. مزیت شبیه‌سازی هم‌زمان منطقه اشباع و غیراشباع خاک در مدل لینک شده آب سطحی و زیرزمینی این است که می‌تواند تبادل بین آب‌های سطحی و زیرزمینی را در فواصل زمانی و مکانی مختلف بر اساس بیلان کامل هیدروکلیماتولوژی در هر منطقه محاسبه نماید اما به دلیل نیاز به طیف وسیعی از داده‌ها و نقشه‌های پیچیده اجرای این روش در بسیاری از آبخوان‌ها امکان‌پذیر نیست (زینعلی و همکاران^۱، ۲۰۲۰ الف و ب).

مزیت روش‌های شبیه‌سازی در توانایی آن‌ها برای حل مسائل مربوط به سیستم‌های پیوسته منابع آب سطحی و زیرزمینی است که دارای روابط و معادلات پیچیده هستند. لذا نیاز به یک یا چند ابزار شبیه‌سازی قدرتمند که بتواند سیستم‌های پیچیده را بر اساس واقعیت موجود شرح داده و به کاربر اجازه شرکت در توسعه مدل را به‌منظور افزایش اعتماد در فرآیند مدل‌سازی بدهد، وجود دارد که معمولاً این مدل‌ها گران‌قیمت هستند (هو و هوانگ^۲، ۲۰۱۶، ایوکوویچ^۳، ۲۰۰۹، پاهار و دهار^۴، ۲۰۱۴، و بایسته و آذری^۵، ۲۰۲۱).

از طرفی جزئیات سیستم واقعی و رفتار آن ممکن است بسیار پیچیده‌تر از آن چیزی باشد که در مدل در نظر گرفته شده است. اگر سیستم مورد مطالعه بیشتر از حد مورد نیاز ساده‌سازی گردد ممکن است نتوانیم اطلاعات مورد نیاز را از مدل به دست آوریم (بیرر^۶، ۲۰۱۰). از این‌رو جایگزینی روش‌های ساده و قابل‌اعتمادی که نیاز به حجم اطلاعات کمی داشته و درعین حال با صرف وقت و هزینه بسیار کم نتایج دقیقی را در مقایسه با روش‌های عددی و مدل‌های ریاضی داشته باشند بسیار پراهمیت است. در اکثر این روش‌ها پیش‌بینی تراز آب زیرزمینی بدون استفاده از مدل‌های شبیه‌سازی معمولاً به‌صورت یک سری میانگین بوده و نقشه توزیعی برای دشت ارائه نمی‌دهد اما در زمان کمتر و با دقت بالا قادر به پیش‌بینی نوسانات آب زیرزمینی و حجم ذخیره آب زیرزمینی هستند (سلطانی و آذری^۷، ۲۰۲۲، گوزمان و همکاران^۸، ۲۰۱۹، و نادیری و همکاران^۹، ۲۰۱۹).

در سال‌های اخیر در کنار روش‌های استوکاستیک (ابتهاج و همکاران^{۱۰}، ۲۰۲۰، زین‌الدین و همکاران^{۱۱}، ۲۰۲۰، و آذری و همکاران^{۱۲}، ۲۰۲۱) به‌صورت گسترده از روش‌های مبتنی بر هوش مصنوعی مانند GMDH، ELM، ORELM و روش‌های هیبرید برای پیش‌بینی پارامترهای هیدروکلیماتولوژی مانند دما، بارندگی، جریان رودخانه‌ها و تغییرات تراز آب مخازن سطحی و آب زیرزمینی استفاده شده است (اسماعیلی و همکاران^{۱۳}، ۲۰۲۱، سلطانی و همکاران^{۱۴}، ۲۰۲۱، زین‌الدین و همکاران^{۱۵}، ۲۰۱۸، ابتهاج و همکاران^{۱۶}، ۲۰۱۶، گرامی مقدم و همکاران^{۱۷}، ۲۰۱۹، غریب و همکاران^{۱۸}، ۲۰۲۰، شعبانلو^{۱۹}، ۲۰۲۰، عظیمی و همکاران^{۲۰}، ۲۰۱۶، علینزاده و همکاران^{۲۱}، ۲۰۲۱، و زارعی و همکاران^{۲۲}، ۲۰۲۰). روش‌های یادگیری ماشین به دلیل سرعت عمل بالا و نیاز به حجم داده‌های کم برای پیش‌بینی پارامترهای هیدروکلیماتولوژی، دبی رودخانه‌ها و نوسانات تراز آب زیرزمینی توسط محققین زیادی توصیه شده‌اند (نورمحمدی ده بالایی و همکاران^{۲۳}، ۲۰۲۳، پاول و همکاران^{۲۴}، ۲۰۲۳، مرادی و همکاران^{۲۵}، ۲۰۲۳، سامانی و همکاران^{۲۶}، ۲۰۲۲، بلالی و همکاران^{۲۷}، ۲۰۲۲، و پناهی و همکاران^{۲۸}، ۲۰۲۲).

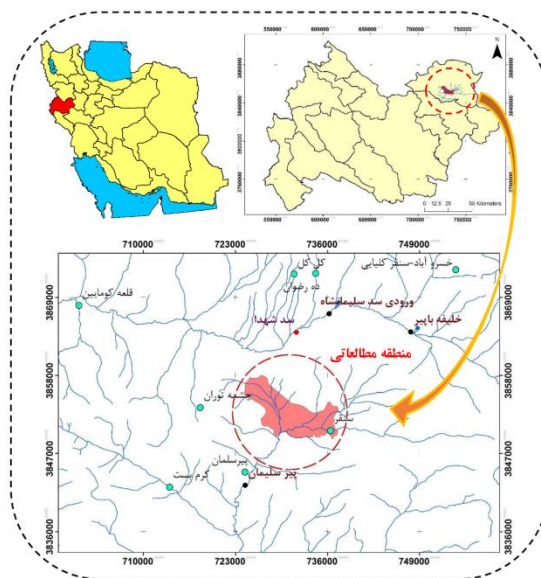
¹ Zeinali et al
² Hu & Huang
³ Ivkovic
⁴ Pahar & Dhar
⁵ Bayesteh & Azari
⁶ Bear
⁷ Soltani & Azari
⁸ Guzman et al
⁹ Nadiri et al
¹⁰ Ebtehaj et al
¹¹ Zeynoddin et al
¹² Azari et al
¹³ Esmaeili et al
¹⁴ Gerami Moghadam et al
¹⁵ Gharib et al
¹⁶ Shabanlou et al
¹⁷ Azimi et al
¹⁸ Alizadeh et al
¹⁹ Zarei
²⁰ Paul et al
²¹ Bilali et al
²² Panahi et al

بررسی تحقیقات انجام شده نشان می‌دهد اکثریت مدل‌های ریاضی بکار گرفته شده در هر آبخوان نیازمند تعریف شرایط مرزی جدید و اطلاعات و نقشه‌های مربوط به آن منطقه است و عملاً کاربردی نمودن مدل مستلزم انطباق آن با شرایط خاص منطقه مورد مطالعه است. به دلیل حجم زیاد آمار و اطلاعات مورد نیاز و همچنین لزوم انجام فرآیند واسنجی و صحت سنجی در این مدل‌ها که فرآیندی بسیار وقت‌گیر و پیچیده است، استفاده از یک روش جایگزین که در مقایسه با مدل‌های ریاضی بتواند با همان دقت و در زمان کمتر و با استفاده از داده‌ها و اطلاعات ناچیز نوسانات تراز آب زیرزمینی را پیش‌بینی نماید بسیار حائز اهمیت است. از طرفی در بسیاری از دشت‌ها اطلاعات کافی برای تحلیل هیدرولیکی و شبیه‌سازی سیستمی منابع آب زیرزمینی برای پیش‌بینی تراز آب زیرزمینی وجود ندارد یا از دقت کافی برخوردار نیست. هدف از این تحقیق استفاده از ابزار هوش مصنوعی به‌عنوان ابزاری جایگزین و مقایسه آن با نتایج مدل عددی برای پیش‌بینی نوسانات تراز آب زیرزمینی است. در این راستا از روش‌های هیبرید GWO-ANN و PSO-ANN و مدل‌های LSTM و SAELM استفاده شد و نتایج آن با مدل عددی GMS مورد مقایسه قرار گرفت.

روش پژوهش

منطقه مورد مطالعه

محدوده مورد مطالعه دشت سنقر در غرب ایران واقع در فاصله ۱۰۰ کیلومتری شمال غرب شهرستان کرمانشاه است که در شکل (۱) نشان داده شده است. دشت سنقر یکی از دشت‌های حاصلخیز در محدوده استان کرمانشاه بوده که نیاز آن توسط دو سیستم آب‌های سطحی و آب زیرزمینی تأمین می‌گردد. بخشی از آب مورد نیاز دشت توسط سد شهدا تأمین می‌گردد و بقیه آن توسط ۲۷۸ چاه عمیق جنوب و غرب دشت حفر شده‌اند تأمین می‌گردد. یکی از مشکلاتی که همواره قابل طرح بوده است بررسی نقش چاه‌های بهره‌برداری در تخلیه و کاهش آبدی رودخانه‌ها بخصوص در نواحی جنوبی دشت است. در صورت ایجاد گرادیان هیدرولیکی بالا بین سطح آب رودخانه و تراز سطح آب زیرزمینی در اثر کاهش تراز در ناحیه جنوبی و غربی آبخوان، دبی نشت رودخانه به آبخوان افزایش پیدا می‌کند. از طرفی تأمین بخشی از نیازهای منطقه توسط سد شهدا و نفوذ آب سطحی به آبخوان در مناطق شمالی دشت باعث شده تبادل رودخانه و آبخوان در این منطقه با پیچیدگی‌هایی همراه باشد. لذا ارائه مدلی ساده و با دقت زیاد بر اساس ساختار هوش مصنوعی بدون نیاز به بررسی اندرکنش رودخانه و آبخوان و بدون کمک معادلات پیچیده بجای مدل‌های ریاضی بسیار حائز اهمیت است. در این تحقیق برای اطمینان از توانایی چنین مدل‌هایی عملکرد آن‌ها در مقایسه با مدل‌های ریاضی معتبر مانند GMS مورد ارزیابی قرار گرفت.



شکل ۱. موقعیت منطقه مطالعاتی

ساخت مدل آب زیرزمینی

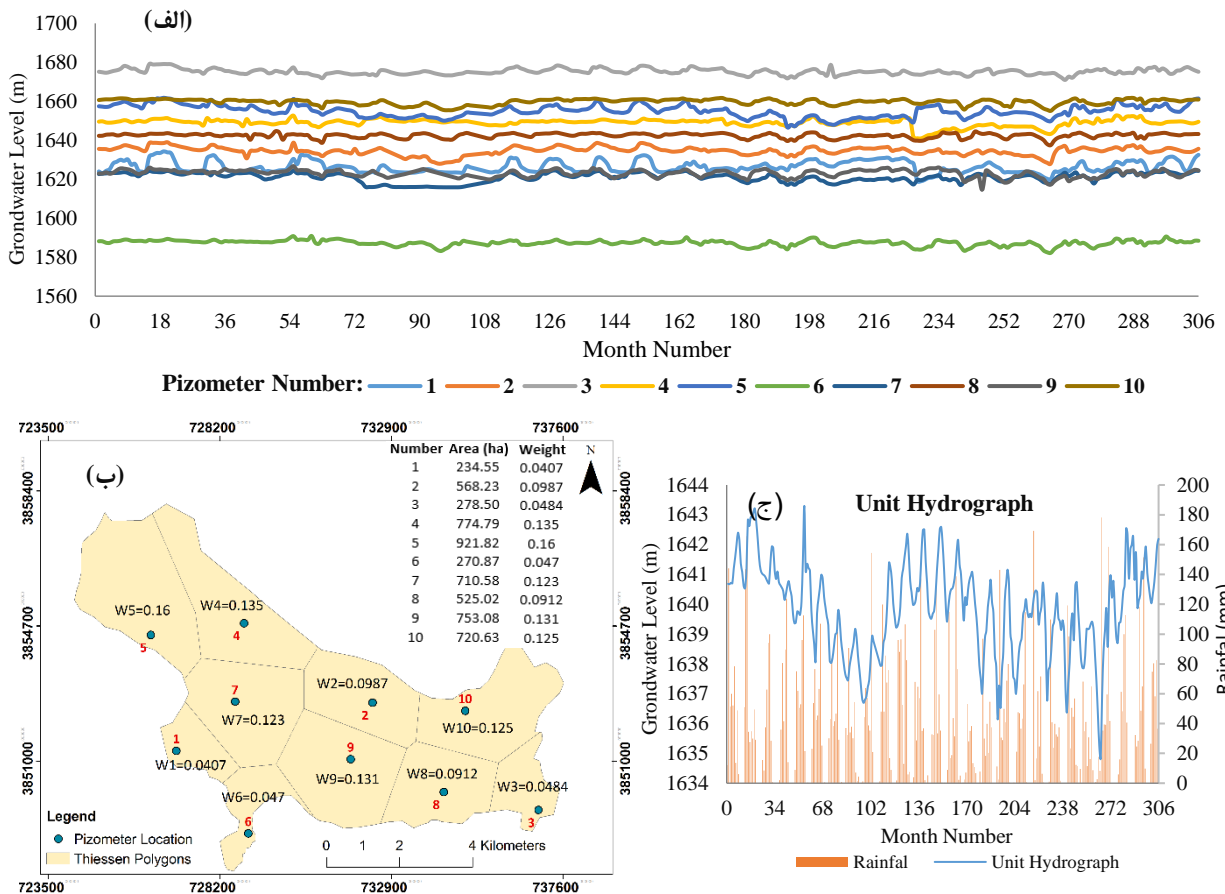
بر اساس جهت عمومی جریان آب زیرزمینی در کل دشت سنقر جهت شبکه‌بندی در راستای شمال شبکه 250×250 متر در نظر گرفته شد. لذا شبکه‌بندی مدل با تعداد ۲۵۹۶ سلول (۴۴ ردیف و ۵۹ ستون) بافاصل ۲۵۰ متر ساخته شد که شامل ۹۰۸ سلول فعال و ۱۶۸۸ سلول غیرفعال بود. در این مطالعه برای شبیه‌سازی مرزهای ورودی و خروجی دشت سنقر از بسته مرز بار عام استفاده شد. در این بسته دبی جریان ورودی یا خروجی متأثر از گرادیان هیدرولیکی در مرز و کاندکتانس^۱ سلول مرزی است. با استفاده از مقاطع ژئوفیزیکی تهیه‌شده و لوگ (Log) اطلاعات چاه‌ها، نقشه سنگ کف دشت تهیه شد. همچنین نقشه DEM دشت برای تعیین حدود بالای لایه در مدل آب زیرزمینی مورداستفاده قرار گرفت. در مدل GMS برای شبیه‌سازی چاه‌های بهره‌بردار در دشت سنقر (۲۷۸ چاه) از بسته WELL استفاده شد و سلول‌های چاه مشخص گردید. تغذیه دشت یکی از پارامترهای مهم در مدل آب زیرزمینی است. معمولاً به دلیل ویژگی‌های مختلف خاک‌شناسی، زمین‌شناسی، پوشش گیاهی، شدت بارندگی و شیب زمین، در نقاط مختلف میزان تغذیه آب‌های زیرزمینی متفاوت است. در مدل GMS برای در نظر گرفتن تغذیه از بسته RCH استفاده می‌گردد. برای تخمین پارامترهای هیدرودینامیکی آبخوان از روش زون‌بندی استفاده گردید. زون‌بندی منطقه برای هدایت هیدرولیکی و آبدهی ویژه بر اساس لوگ حفاری چاه‌های مشاهداتی، اکتشافی و پیژومتری و همچنین مقاطع ژئوفیزیکی تهیه‌شده از منطقه انجام گرفت. با توجه به جنس خاک و رسوبات هر زون مقادیر اولیه هدایت هیدرولیکی و آبدهی ویژه تخمین زده شد. درنهایت پس از انجام فرآیند واسنجی، برای هر زون مقدار بهینه‌شده هدایت هیدرولیکی و آبدهی ویژه لحاظ شد. در بخش شبیه‌سازی آب زیرزمینی، پس از آزمون‌های واسنجی و صحت‌سنجی مدل در دو حالت ماندگار و غیر ماندگار و اطمینان از دقت آن، پهنه‌بندی نهایی پارامترهای اصلی مدل یعنی هدایت هیدرولیکی و آبدهی ویژه تهیه شد تا مدل بتواند تغییرات تراز آب زیرزمینی را برای ۶ سال متوالی شبیه‌سازی کند؛ زیرا کلیه اطلاعات موردنیاز برای ۶ سال (مهر ۱۳۸۹ تا شهریور ۱۳۹۵) موجود بود.

مدل‌های هوش مصنوعی

همان‌طور که گفته شد برای صرفه‌جویی در زمان و پرهیز از پردازش حجم اطلاعات زیاد و با توجه به پیچیدگی‌های مدل‌های ریاضی، در این مطالعه علاوه بر مدل عددی GMS از مدل‌های مبتنی بر هوش مصنوعی نیز برای پیش‌بینی نوسانات آب زیرزمینی در دشت سنقر استفاده شد. ابتدا برای ترسیم نوسانات تراز آب زیرزمینی در کل دشت از مجموعه داده‌های تراز آب ۱۰ پیژومتر واقع در دشت سنقر برای به دست آوردن هیدرو گراف واحد آب زیرزمینی دشت در یک دوره آماری ۳۰۶ ماهه (مهر ۱۳۷۳ تا اسفند ۱۳۹۹) استفاده شد. نوسانات سطح آب در این پیژومترها، هیدرو گراف واحد آب زیرزمینی^۲ و بارندگی در طول دوره مطالعاتی در شکل (۲) نشان داده‌شده است.

¹ conductance

² groundwater unit hydrograph



شکل ۲. الف) نوسانات تراز آب زیرزمینی در هر یک از پیزومترهای دشت، ب) پلیگون های تیسن و وزن هر پیزومتر، ج) هیدروگراف واحد در کل دوره مطالعاتی در دشت (mm) و بارندگی (m) آب زیرزمینی

هیدرو گراف واحد آب زیرزمینی پس از ترسیم پلیگون های تیسن در محیط GIS و به دست آوردن وزن هر پیزومتر ترسیم شد. پس از تنظیم اطلاعات موردنیاز، از روش های هیبرید GWO-ANN و PSO-ANN و مدل های LSTM و SAELM برای پیش بینی تراز آب زیرزمینی در کل دشت استفاده شد. برای این کار، پارامترهای هیدرو گراف واحد آب زیرزمینی (UH) و بارندگی (P) در ماه های قبل و با تأخیرهای مختلف به عنوان ورودی های مدل و مقادیر تراز آب زیرزمینی در ماه حاضر به عنوان خروجی مدل در نظر گرفته شد. با در نظر گرفتن ۷۰ درصد داده ها به عنوان داده های train و ۳۰ درصد داده ها به عنوان داده های test بهترین ساختار مدل با تعداد مختلف ورودی با کمترین میزان خطا و بیشترین ضریب همبستگی با داده های مشاهداتی به دست آمد. برای انتخاب بهترین مدل از شاخص های آماری RMSE، NRMSE، NSE و R استفاده شد که در معادلات (۱) تا (۴) نشان داده شده اند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i^{obs} - X_i^{sim})^2} \quad (1)$$

$$NRMSE = \frac{RMSE}{(X_{Max}^{obs} - X_{Min}^{obs})} \quad (2)$$

$$NSE=1-\left[\frac{\sum_{i=1}^n (X_i^{obs}-X_i^{sim})^2}{\sum_{i=1}^n (X_i^{obs}-X_{Mean}^{obs})^2}\right] \quad (۳)$$

$$R=\left(\frac{\sum_{i=1}^n (X_i^{obs}-X_{Mean}^{obs})(X_i^{sim}-X_{Mean}^{sim})}{\sqrt{\sum_{i=1}^n (X_i^{obs}-X_{Mean}^{obs})^2 \sum_{i=1}^n (X_i^{sim}-X_{Mean}^{sim})^2}}\right) \quad (۴)$$

که X_i^{obs} داده‌های مشاهداتی مربوط به همراه، X_i^{sim} داده‌های شبیه‌سازی شده مربوط به همراه، X_{Mean}^{sim} و X_{Mean}^{obs} به ترتیب میانگین داده‌های مشاهداتی و شبیه‌سازی شده و n تعداد کل داده‌هاست.

ماشین آموزش نیرومند^۱

ماشین آموزش نیرومند (ELM) یک شبکه عصبی پیشخور^۲ تک لایه بوده و توسط هوانگ و همکاران^۳ (۲۰۰۴، ۲۰۰۶) ارائه شده است. ELM وزن‌های ورودی را به صورت تصادفی وزن‌های خروجی را به صورت تحلیلی^۴ تعیین می‌کند. ساختار کلی این الگوریتم در شکل (2.a) ارائه شده است. تنها تفاوت ELM با شبکه عصبی پیشخور تک لایه^۵ (SLFFNN)، عدم استفاده از بایاس^۶ برای نرون خروجی است. نرون‌های لایه ورودی با همه نرون‌های لایه مخفی در ارتباط است. تابع فعال‌سازی نرون‌های مخفی می‌تواند به صورت تابع پیوسته تکه‌ای^۷ باشد درحالی‌که برای نرون لایه خروجی به صورت خطی است. مدل ELM از الگوریتم‌های مختلفی جهت محاسبه وزن‌ها و بایاس‌ها استفاده می‌کند که در نتیجه کاهش قابل توجه زمان آموزش شبکه را به همراه دارد. توصیف ریاضی شبکه عصبی پیشخور تک لایه با تعداد n گره مخفی، به صورت زیر بیان می‌شود:

$$f_n(x) = \sum_{i=1}^n \beta_i G(a_i, b_i, x) \quad (۵)$$

که β_i وزن بین گره مخفی i ام و گره خروجی، $(a_i \in R^n)$ و b_i فاکتورهای آموزش گره‌های مخفی و $G(a_i, b_i, x)$ خروجی گره i ام برای ورودی x است. تابع فعال‌سازی $g(x)$ (که دارای انواع مختلفی می‌باشند) برای گره مخفی افزایشده^۸ $G(a_i, b_i, x)$ را می‌توان به شکل زیر بازنویسی کرد:

$$G(a_i, b_i, x) = g(a_i \cdot x + b_i) \quad (۶)$$

از توابع فعال‌سازی به منظور محاسبه خروجی پاسخ نرون‌ها استفاده می‌شود. زمانی که مجموعه‌ای از سیگنال ورودی وزن‌دار اعمال می‌شود، برای به دست آوردن پاسخ از توابع فعال‌سازی استفاده می‌شود (پندی و گوویند^۹، ۲۰۱۶). توابع فعال‌سازی غیرخطی ELM که در این مطالعه مورد بررسی قرار گرفته است شامل تابع پله‌ای (hardlim)، سیگموئید^{۱۰} (sig)، سینوسی (sin)، بایاس مثلثی (tribas) و بایاس شعاعی (radbas) است که به صورت شکل (۳) تعریف می‌شوند.

¹ Extreme Learning Machine (ELM)

² feed-forward

³ Huang et al

⁴ Analytical

⁵ single layer feed forward neural network

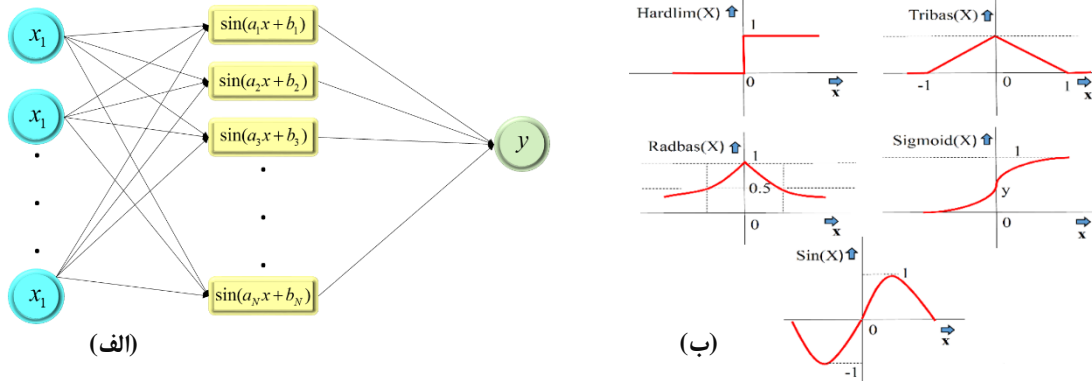
⁶ bias

⁷ piecewise continuous function

⁸ additive

⁹ Pandey & Govind

¹⁰ sigmoid



شکل ۳. الف) ساختار شبکه ELM، ب) توابع فعال‌سازی مختلف در مدل ELM

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:

$$H_{jk} = g\left(\sum (W_{ji} X_{ik}) + B_j\right) \quad (7)$$

که $g(\cdot)$ می‌تواند هر تابع فعال‌سازی غیرخطی پیوسته باشد، W_{ji} وزن نرون ورودی i ام و نرون لایه مخفی j ام، B_j بایاس نرون لایه مخفی j ام، X_{ik} ورودی نرون i ام برای k امین نمونه آموزشی و H_{ik} ماتریس فعال‌سازی i امین نرون لایه مخفی برای k امین نمونه آموزشی است. بطوریکه فعال‌سازی همه نرون‌های لایه مخفی برای نمونه‌های مورداستفاده 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، بکار برده می‌شود که معادل ریاضی آن را می‌توان به شکل زیر بیان کرد:

$$H\beta = T \quad (8)$$

$$\beta = (\beta_1, \dots, \beta_j)_{j \times 1} \quad (9)$$

که β نشان‌دهنده وزن بین نرون لایه خورجی و نرون‌های لایه مخفی است و T بردار نشان‌دهنده مقادیر هدف برای نمونه‌های آموزش است که به‌صورت معادله (۱۰) بیان می‌شود:

$$T = (T_1, \dots, T_k)_{k \times 1} \quad (10)$$

نهایتاً وزن‌ها را می‌توان از رابطه (۱۱) محاسبه کرد:

$$\beta = H^+ T \quad (11)$$

که در آن:

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_L) \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (12)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad \text{and} \quad T = \begin{bmatrix} T_1^T \\ \vdots \\ T_L^T \end{bmatrix}_{L \times m} \quad (13)$$

که $\tilde{a} = a_1, \dots, a_L; \tilde{b} = b_1, \dots, b_L; \tilde{x} = x_1, \dots, x_L$ بردار وزن بین نرون‌های لایه‌های مخفی و لایه پنهان و H^+ شبه معکوس Moore-Penrose ماتریس H است. T بردار بین وزن‌های نمونه‌های آموزشی است. با توجه به توضیحات ارائه‌شده می‌توان گفت که آموزش ELM شامل دو مرحله است: مرحله اول، اختصاص تصادفی وزن‌ها و بایاس‌ها به نرون‌های لایه پنهان و محاسبه خروجی لایه پنهان ماتریس H و مرحله دوم، محاسبه وزن‌های خروجی با استفاده از شبه معکوس Moore-Penrose ماتریس H و مقادیر هدف برای نمونه‌های آموزشی

مختلف. روند آموزش جهت پیدا کردن ماتریس لایه پنهان (H)، سریع است بطوریکه از سرعت بالاتری نسبت به الگوریتم‌های مبتنی بر تکرار رایج مانند لونیگ-مارکوآردت^۱ که در آن هیچ نوع روایی از بهینه‌سازی غیرخطی را در بر نمی‌گیرد، برخوردار است؛ بنابراین زمان آموزش شبکه به‌طور قابل توجهی کاهش می‌یابد (هوآنگ، ۲۰۰۶).

استفاده از الگوریتم تکامل تفاضلی به‌صورت خود تطبیقی توانایی غلبه بر محدودیت‌های موجود مانند پارامترهای کنترل در الگوریتم، انتخاب استراتژی بردار trial را داراست. از این‌رو، الگوریتم ماشین آموزش نیرومند خود تطبیقی^۲ (SAELM) جهت بهینه‌سازی وزن‌های ورودی شبکه و بایاس‌های نود مخفی، توسط وانگ و همکاران^۳ (۲۰۱۶) ارائه شده است. با داشتن مجموعه داده‌های آموزشی، تعداد L نود مخفی و تابع فعال‌سازی $g(x)$ ، می‌توان الگوریتم SAELM را فرمول نویسی کرد. بدین منظور، ابتدا جمعیت اولیه با استفاده از بردارهای جمعیت (NP) که نودهای مخفی را در بر می‌گیرند، تولید می‌شود. سپس با مقایسه مقادیر پیش‌بینی با مقادیر مشاهداتی بهترین وزن‌ها برای انتقال به مرحله بعد انتخاب می‌شوند و بعد از تولید وزن‌های جدید الگوریتم مجدداً اجرا می‌شود. این فرآیند تا رسیدن به بهترین نتایج پیش‌بینی ادامه پیدا می‌کند.

مدل یادگیری عمیق حافظه کوتاه مدت-بلند مدت (LSTM)

مدل‌های یادگیری عمیق زیرمجموعه‌ای از مدل‌های هوش مصنوعی هستند که برای حل مسائل غیرخطی توالی بهبود یافته‌اند. یک مدل یادگیری عمیق معروف، شبکه حافظه کوتاه مدت-بلند مدت^۴ (LSTM) است. معماری LSTM برای مدل‌سازی داده‌های دنباله‌ای مانند سری‌های زمانی مناسب است و می‌تواند وابستگی‌های بلندمدت را به‌صورت سری برای پیش‌بینی مراحل آینده بیاموزد. یک بلوک حافظه ساده LSTM در شکل (۳) ارائه شده است. مدل LSTM از چندین گیت تشکیل شده است که جریان اطلاعات را کنترل کرده و بر نتایج تولیدشده تأثیر می‌گذارد. این گیت‌ها ورودی، فراموشی و خروجی هستند که داده‌های ورودی به بلوک‌های حافظه C_t را کنترل می‌کنند که باید فراموش شوند و اجازه ادامه فرآیندهای بعدی را دارند.

LSTM یک نگاهت را از یک دنباله ورودی x به یک دنباله خروجی y با استفاده از معادلات بعدی به‌صورت تکراری از $t = 1$ تا $t = t$ با مقادیر اولیه $h_0 = 0$ و $C_0 = 0$ (لانگریج و همکاران^۵، ۲۰۲۰):

$$f_t = \sigma(W_f A_{L,t} + U_f h_{t-1} + b_f) \quad (14)$$

$$E_t = \tanh(W_E A_{L,t} + U_E h_{t-1} + b_{E_f}) \quad (15)$$

$A_{L,t}$ ورودی بردار در زمان t و h_{t-1} حالت سلول پنهان در زمان $t-1$ است. W ، U به ترتیب ماتریس‌های وزن برای اتصالات ورودی به پنهان و پنهان به پنهان هستند.

f_t یک بردار نتیجه با مقادیر در محدوده (۰، ۱) است، $\sigma(\cdot)$ تابع سیگموئید لجستیک را نشان می‌دهد و W_f ، U_f و b_f مجموعه پارامترهای قابل یادگیری را برای دریچه فراموشی تعریف می‌کنند. $C_t^{\%}$ یک بردار به‌روزرسانی با بازه (۱، -۱) برای حالت سلول است که در زمان t محاسبه شده است. (*) \tanh تانژانت هذلولی است و $W_{C_t^{\%}}$ ، $U_{C_t^{\%}}$ و $b_{C_t^{\%}}$ مجموعه‌های پارامترهای قابل یادگیری دیگر هستند.

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (16)$$

i_t دریچه فراموشی با برد (۰، ۱) است. W_i ، U_i و b_i مجموعه‌ای از پارامترهای قابل یادگیری هستند که برای دریچه ورودی تعریف شده‌اند. نتایج معادلات ۱۴ تا ۱۶ باعث به‌روزرسانی وضعیت سلول می‌گردد:

$$c_t = f_t O_{c,t-1} + i_t O E_t \quad (17)$$

O به معنای ضرب متناظر عناصر ماتریکس است و دریچه خروجی به‌عنوان آخرین دریچه، وضعیت سلول C_t را کنترل می‌کند.

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (18)$$

¹ Levenberg-Marquardt

² Self-adaptive extreme learning machine algorithm


³ Wang et al

⁴ Long-Short-Term Memory

⁵ Langridge et al

O_t در محدوده (۰، ۱) است و W_o ، U_o و b_o مجموعه‌ای از پارامترهای قابل یادگیری هستند که برای دروازه خروجی تعریف شده‌اند. به صورت زیر محاسبه می‌شود:

$$h_t = \tanh(c_t) O_o \quad (19)$$



شکل ۴. یک بلوک ساده LSTM

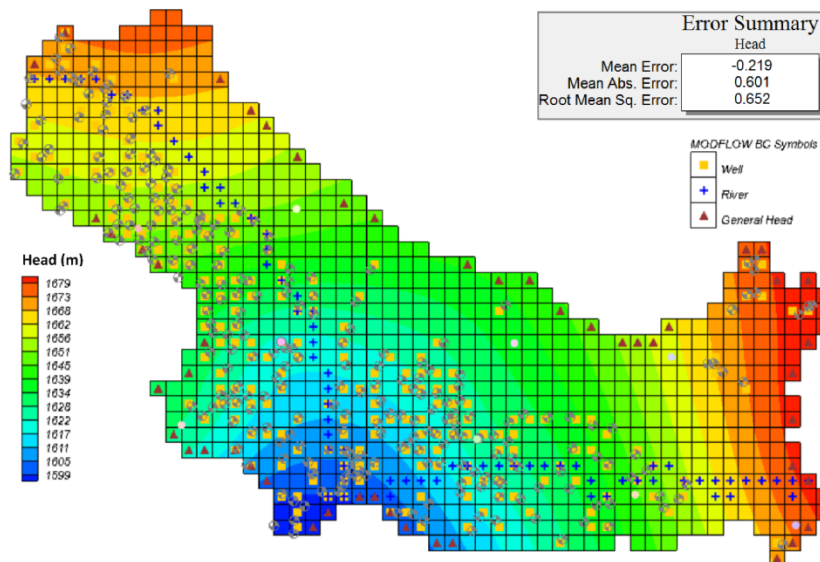
مدل‌های هیبرید PSO-ANN و GWO-ANN

یکی از ساده‌ترین و کارآمدترین روش‌های پیشنهادی برای استفاده در طراحی شبکه‌های عصبی، مدل پرسپترون چندلایه (Multi layer perceptron (MLP)) است که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل یافته است. در این ساختار، تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصل هستند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می‌دهد. برخلاف شبکه‌های عصبی پرسپترون تک لایه، شبکه‌های چندلایه می‌توانند برای یادگیری مسائل غیرخطی و همچنین مسائلی با تصمیم‌گیری‌های متعدد بکار روند. اگر مجموعه داده دارای m ویژگی باشد بنابراین در شبکه‌های عصبی لایه ورودی نیز دارای m نرون است و از این رو نیاز به n تا وزن W نیز هست که در ورودی‌ها ضرب شوند. ویژگی‌های مجموعه داده‌ها، متغیرهای مستقلی هستند که بر خروجی یا متغیر وابسته تأثیر می‌گذارند. همچنین با داشتن n نرون درون لایه پنهان، نیاز به n تا مجموعه وزن‌های (W_1, W_2, \dots, W_n) دارید تا بتوان عملیات ضرب وزن‌ها در ورودی‌های X انجام شود. برای پیش‌بینی دقیق خروجی مدل، باید وزن‌های شبکه در تمام لایه‌ها اصلاح شده و مقادیر بهینه آن‌ها به دست آید. به منظور آموزش شبکه و اصلاح وزن‌ها تا رسیدن به یک خطای معنادار، روش‌های بسیار زیادی وجود دارد. یکی از روش‌های مؤثر در این زمینه ترکیب مدل MLP با الگوریتم بهینه‌سازی در قالب یک مدل هیبرید است. در این تحقیق از دو مدل هیبرید PSO-ANN و GWO-ANN استفاده شد. در ساختار این مدل‌ها، وزن‌های بهینه توسط الگوریتم‌های بهینه‌سازی ژنتیک و رقابت استعماری به دست می‌آیند. تابع هدف در این مدل‌ها کمینه‌سازی مقدار RMSE است. تولید و اصلاح وزن‌ها در ساختار مدل تا رسیدن به کمترین خطا ادامه می‌یابد و تعداد تکرار الگوریتم بر این اساس تنظیم می‌شود.

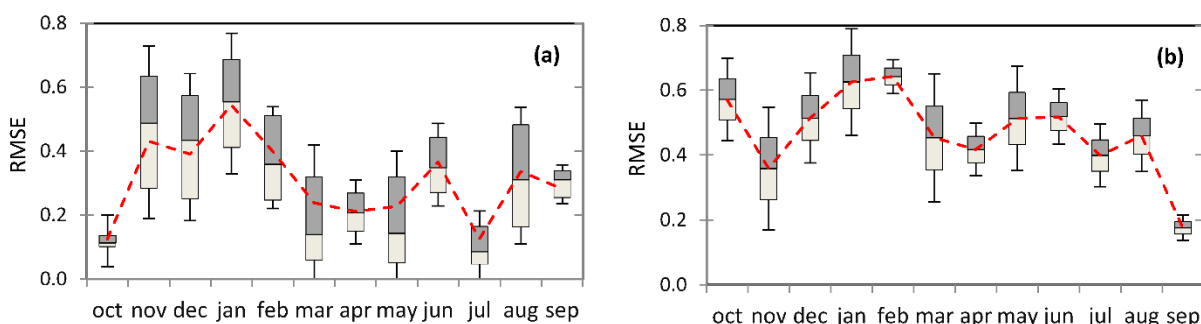
یافته‌ها

نتایج شبیه‌سازی عددی

مدل آب زیرزمینی برای پارامترهای اصلی مدل یعنی هدایت هیدرولیکی و آبدهی ویژه، واسنجی و صحت‌سنجی شد. در این مرحله برای مقایسه آماری مقادیر محاسباتی و مشاهداتی تراز آب زیرزمینی در محل چاهک‌های مشاهده‌ای در دشت سنقر از آماره RMSE استفاده شد. نتایج حاصل از این بررسی در شکل (۵) نشان می‌دهد مقدار این آماره در مدل ماندگار در حدود ۰/۶۵ است. نتایج واسنجی و صحت‌سنجی مدل آب زیرزمینی در حالت غیر ماندگار در طول دوره ۶ ساله از اکتبر ۲۰۰۹ تا سپتامبر ۲۰۱۵ (شکل (۶))، نشان داد مدل با دقت خوبی قادر به پیش‌بینی تغییرات تراز آب زیرزمینی در اثر تنش‌های وارد شده به آن است طوری که مقدار RMSE با در نظر گرفتن تمامی ماه‌های شبیه‌سازی در حدود ۰/۴۲ است.



شکل ۵. اجزای مدل عددی تهیه‌شده و تراز آب زیرزمینی دشت در حالت ماندگار



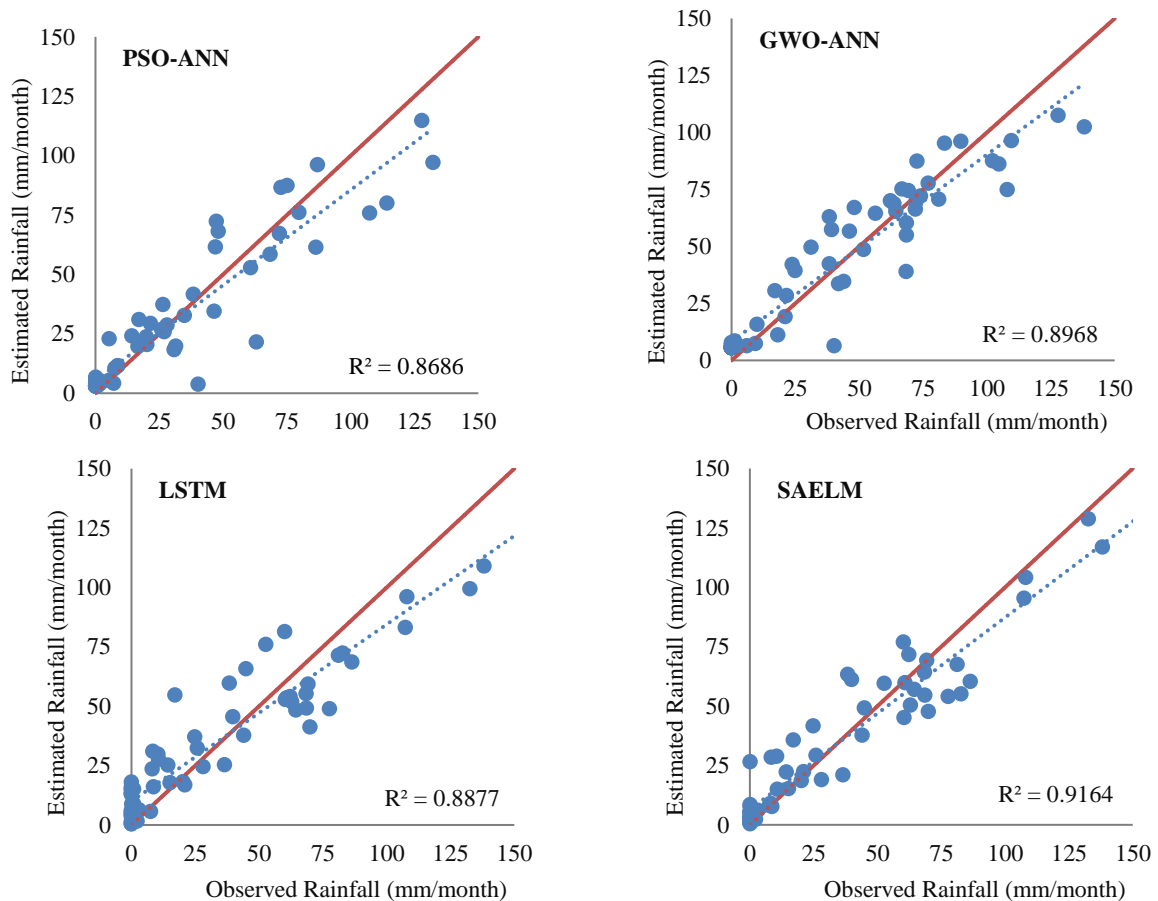
شکل ۶. مقادیر آماره میانگین قدر مطلق خطای تراز آب در مدل مادفلو در حالت غیر ماندگار در طول دوره الف- واسنجی ب- صحت سنجی

شکل (۶) نمودار جعبه‌ای مربوط به مقادیر میانگین، حداقل و حداکثر خطای شبیه‌سازی سطح آب زیرزمینی را در ماه‌های مختلف در کل منطقه دشت نشان می‌دهد.

پیش‌بینی تراز آب زیرزمینی بر اساس هوش مصنوعی

در این مطالعه از روش‌های مبتنی بر شبکه‌های عصبی مصنوعی برای پیش‌بینی سری زمانی تراز آب زیرزمینی در مقایسه با مدل‌های عددی پیچیده با حجم داده‌های انبوه مانند GMS استفاده شده است تا بتوان قابلیت جایگزینی این روش‌ها با مدل‌های پیچیده را بررسی کرد. این امر برای جایی که شرایط مطلوب برای به‌کارگیری مدل‌های عددی پیچیده برقرار نیست و یا اینکه اطلاعات کافی در دست نیست بسیار حائز اهمیت است. طوری که بتوان بر اساس تعداد ورودی‌های بسیار اندک، نوسانات تراز آب زیرزمینی را بتوان با دقت زیاد پیش‌بینی نمود. با توجه به اهداف این تحقیق در تمامی روش‌های هوش مصنوعی و مدل‌های هیبرید از داده‌های ماهیانه بارندگی و تراز آب زیرزمینی در ماه‌های قبل ($t-1$, $t-2$, $t-3$, $t-6$, $t-12$, $t-24$) به‌عنوان داده‌های ورودی به مدل استفاده شد. خروجی مدل نیز داده‌های تراز آب زیرزمینی دشت (هیدرو گراف واحد آب زیرزمینی) در ماه حاضر (t) است که بر اساس داده‌های مشاهداتی در پیزومترها استخراج شده است. برای پیش‌بینی نوسانات تراز

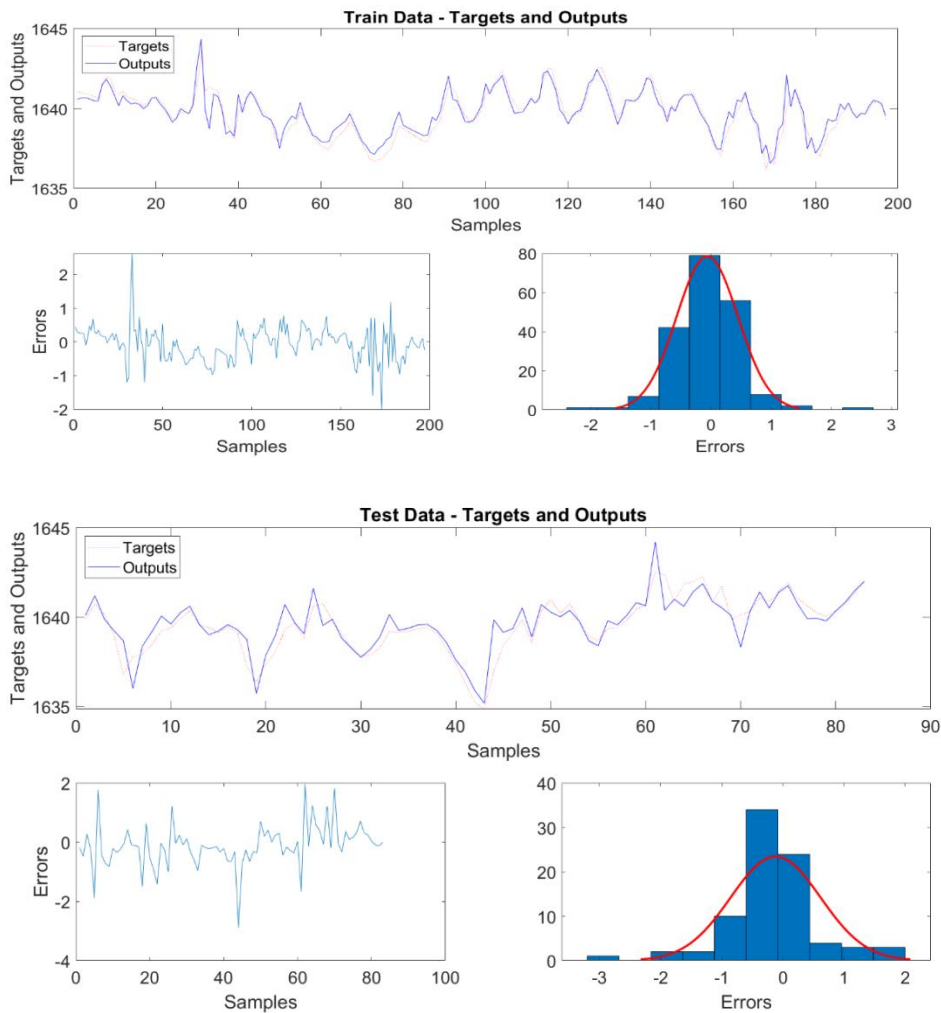
آب زیرزمینی در دشت سنقر، عملکرد این مدل‌ها بر اساس شاخص‌های RMSE، NRMSE، NASH و R مورد ارزیابی قرار گرفت. بهترین نتایج حاصل از اجرای هرکدام از این مدل‌ها در جدول (۱) ارائه شده است. بر اساس این جدول مدل SAELM با توجه به تمامی شاخص‌ها دارای دقت بیشتری نسبت به سایر مدل‌ها در مراحل آموزش و آزمون است. پس از آن مدل ELM در رده دوم از نظر دقت پیش‌بینی قرار دارد. شکل (۷) پراکندگی نقاط در اطراف خط $Y=X$ و مقدار مجذور ضریب همبستگی برای انتخاب بهترین مدل هوش مصنوعی در مرحله تست مدل‌سازی برای هر یک از مدل‌های PSO-ANN، LSTM، SAELM و GWO-AN نشان می‌دهد. پراکنش منظم‌تر و نزدیک‌تر نقاط در اطراف خط $Y=X$ در مدل SAELM نیز حاکی از دقت بیشتر این مدل در مقایسه با سایر مدل‌ها است. بر این اساس سری زمانی مقادیر پیش‌بینی شده تراز آب زیرزمینی بر اساس مدل برتر (SAELM) در مقایسه با داده‌های مشاهداتی در مراحل آموزش و تست در شکل (۸) نشان داده شده است.



شکل ۷. نمایش گرافیکی پراکندگی نقاط در اطراف خط $Y=X$ و مقدار مجذور ضریب همبستگی برای انتخاب بهترین مدل هوش مصنوعی در مرحله تست مدل‌سازی

جدول ۱. ارزیابی عملکرد مدل‌های LSTM، PSO-ANN، GWO-AN و SAELM در پیش‌بینی تراز آب زیرزمینی بر اساس شاخص‌های آماری در مراحل آموزش و تست

Model Type	Input combination		Train				Test			
	GWL	Rainfal	RMSE	NRMSE	NASH	R	RMSE	NRMSE	NASH	R
PSO-ANN	t-1	t, t-1	0.5459	0.0827	0.882	0.942	0.5608	0.0696	0.865	0.93
GWO-ANN	t-1	t-1	0.585	0.0817	0.866	0.932	0.5954	0.0713	0.845	0.919
LSTM	t-1, t-2	-	0.5372	0.075	0.854	0.924	0.823	0.1073	0.722	0.858
SAELM	t-1, t-2, t-3	-	0.3731	0.0521	0.93	0.966	0.4189	0.0546	0.928	0.966



شکل ۷. سری زمانی مقادیر پیش‌بینی شده تراز آب زیرزمینی بر اساس مدل برتر (SAELM) در مقایسه با داده‌های مشاهده‌ای در مراحل آموزش و تست

نتایج حاصل از کاربرد مدل هوش مصنوعی SAELM نشان می‌دهد این روش توانسته است در دوره آماری ۳۰۶ ماهه با کمترین میزان خطا در مراحل train و test تراز آب زیرزمینی را پیش‌بینی نماید. به طوری که مقدار RMSE در این روش در دو مرحله train و test به

ترتیب ۰/۳۷ و ۰/۴۲ بود. مقدار RMSE در مدل عددی GMS با در نظر گرفتن دوره غیر ماندگار ۶ ساله در حدود ۰/۴۲ بود که این مقدار نشان می‌دهد مدل SAELM بدون نیاز به اطلاعات و داده‌های فراوان و بدون بهره‌گیری از فرآیند پیچیده مدل‌سازی بر اساس معادلات حاکم و با صرف زمان بسیار کمتر نوسانات تراز آب زیرزمینی را به‌درستی و با دقت زیاد پیش‌بینی نماید. لازم به ذکر است طول دوره شبیه‌سازی در مدل GMS به دلیل نیاز به حجم وسیعی از اطلاعات و نقشه‌های مرتبط و عدم وجود اطلاعات کافی حدود ۷۲ ماه بود؛ اما در مدل‌های هوش مصنوعی به دلیل اینکه تنها از اطلاعات بارش و تراز آب زیرزمینی ثبت‌شده پیرومترها استفاده می‌کنند بر اساس موجود بودن داده‌ها طول دوره پیش‌بینی ۳۰۶ ماه در نظر گرفته شد.

بحث

امکان پیش‌بینی تراز آب زیرزمینی برای یک دوره بلندمدت بر اساس حجم اطلاعات بسیار کم نسبت به مدل‌های عددی و تنها با استفاده از داده‌های پیرومتری و اطلاعات بارندگی یکی از مهم‌ترین دستاوردهای این تحقیق است. در این حالت بدون نیاز به پارامترهای هواشناسی، خاک، زمین‌شناسی، اطلاعات لایه‌بندی و ژئوفیزیک، جایگاه (Log) چاه‌های بهره‌برداری، اطلاعات برداشت آب از چاه‌ها، چشمه‌ها و قنات‌ها، داده‌های اندرکنش آب سطحی و زیرزمینی و بدون نیاز به نقشه‌ها و نرم‌افزارهای پیچیده و بدون صرف زمان و هزینه زیاد برای واسنجی و صحت‌سنجی مدل‌های ریاضی، تراز آب زیرزمینی بر اساس روش‌های هوش مصنوعی پیش‌بینی می‌گردد. این امر کمک بزرگی به متخصصین بخش منابع آب در حوضه‌های فاقد آمار یا آبخوان‌هایی که فاقد اطلاعات پایه‌ای و نقشه‌های دقیق بوده و یا دشت‌هایی که با نقص آمار مواجه هستند می‌کند؛ زیرا با استفاده از مدل‌های هوش مصنوعی با صرف زمان و هزینه بسیار کم اطلاعات مدیریتی بسیار ارزشمندی در خصوص پیش‌بینی نوسانات تراز آب زیرزمینی در سال‌های خشک و تر به دست می‌آید. ارزیابی عملکرد مدل‌های هوش مصنوعی (PSO-ANN, GWO-AN, LSTM و SAELM) در دشت سنقر نشان داد این مدل‌ها دقت بسیار خوبی در پیش‌بینی نوسانات تراز آب زیرزمینی در مقایسه با مدل عددی GMS دارند. طوری که از بین این مدل‌ها، مدل SAELM با مقدار RMSE در حدود ۰/۳۷ و ۰/۴۲ در دو مرحله train و test دارای بیشترین دقت بود. در تمامی روش‌های مورد استفاده تعداد تکرار برای رسیدن به بهترین جواب ۱۰۰۰۰ تکرار در نظر گرفته شد.

نتیجه‌گیری

بر اساس نتایج، از بین همه روش‌ها، مدل SAELM به دلیل ساختار پیشرفته‌تر شبکه در مدت‌زمان کمتری به جواب رسید. با توجه به اهمیت آگاهی از تغییرات تراز آب زیرزمینی به‌عنوان یکی از مهم‌ترین پارامترهای بیابان منابع آب می‌توان مدل‌های هوش مصنوعی مورد استفاده در این تحقیق را بخصوص برای مناطق فاقد آمار پایه و یا در شرایطی که امکان استفاده از مدل‌های ریاضی وجود ندارد توصیه نمود. بر اساس نتایج به‌دست‌آمده می‌توان مدل‌های توسعه داده‌شده در این تحقیق را برای سایر مناطق مطالعاتی با رویکرد بهره‌برداری تلفیقی از رودخانه و آبخوان مانند دشت سنقر نیز پیشنهاد داد. در این صورت بدون نیاز به روابط و معادلات پیچیده برای بررسی اثر برهمکنش آب سطحی و زیرزمینی و تنها بر اساس اطلاعات پیرومتری و داده‌های بارندگی می‌توان تراز آب زیرزمینی را در دشت مورد مطالعه در دوره‌های خشک و تر با دقت زیاد پیش‌بینی نمود.

References

- Alizadeh, A., Rajabi, A., Shabanlou, S., Yaghoubi, B., & Yosefvand, F. (2021). Modeling long-term rainfall-runoff time series through wavelet-weighted regularization extreme learning machine. *Earth Sci Inform*, 14, 1047–1063. <https://link.springer.com/article/10.1007/s12145-021-00603-8>
- Amiri, S., Rajabi, A., Shabanlou, S., Yosefvand, F., & Izadbakhsh, M.A. (2023). Prediction of groundwater level variations using deep learning methods and GMS numerical model. *Earth Science Informatic*. <https://doi.org/10.1007/s12145-023-01052-1>
- Azari, A., Zeynoddin, M., Ebtehaj, I., Sattar, A. M. A., Gharabaghi, B., & Bonakdari, H. (2021). Integrated preprocessing techniques with linear stochastic approaches in groundwater level forecasting. *Acta Geophysica*, 69, 1395–1411. <https://doi.org/10.1007/s11600-021-00617-2>
- Azimi, H., Shabanlou, S., Ebtehaj, I., & Bonakdari, H. (2016). Discharge Coefficient of Rectangular Side Weirs on Circular Channels. *International Journal of Nonlinear Sciences and Numerical Simulation*, 17(7-8), 391-399. <http://dx.doi.org/10.1515/ijnsns-2016-0033>
- Azizi, E., Yosefvand, F., Yaghoubi, B., Izadbakhsh, M.A., & Shabanlou, S. (2023). Modelling and prediction of groundwater level using wavelet transform and machine learning methods: A case study for the Sahneh Plain, Iran. *Irrigation and Drainage*, 72(3), 747–762. Available from: <https://doi.org/10.1002/ird.2794>
- Azizi, E., Yosefvand, F., Yaghoubi, B., Izadbakhsh, M.A., & Shabanlou, S. (2024). Prediction of groundwater level using GMDH artificial neural network based on climate change scenarios. *Appl Water Sci* 14, 77 (2024). <https://doi.org/10.1007/s13201-024-02126-1>
- Azizpour, A., Izadbakhsh, M.A., Shabanlou, S., Yosefvand, F., & Rajabi, A. (2021). Estimation of water level fluctuations in groundwater through a hybrid learning machine. *Groundwater for Sustainable Development*, 15, 100687. <https://doi.org/10.1016/j.gsd.2021.100687>
- Azizpour, A., Izadbakhsh, M.A., Shabanlou, S., Yosefvand, F., & Rajabi, A. (2022). Simulation of time-series groundwater parameters using a hybrid metaheuristic neuro-fuzzy model. *Environment Science and Pollution Research*. <https://doi.org/10.1007/s11356-021-17879-4>
- Bayesteh, M., & Azari, A. (2021). Stochastic Optimization of Reservoir Operation by Applying Hedging Rules. *J Water Resour Plann Manage*, 147(2), 04020099. [http://dx.doi.org/10.1061/\(ASCE\)WR.1943-5452.0001312](http://dx.doi.org/10.1061/(ASCE)WR.1943-5452.0001312)
- Bear, J. (2010). *Modeling Groundwater Flow and Contaminant Transport*. Springer Verlag, 23, 834. <http://dx.doi.org/10.1007/978-1-4020-6682-5>
- Bilali, A. E., Lamane, H., Taleb, A., & Naffii, A. (2022). A framework based on multivariate distribution-based virtual sample generation and DNN for predicting water quality with small data. *Journal of Cleaner Production*, 368, 133227. <http://dx.doi.org/10.1016/j.jclepro.2022.133227>
- Ebtehaj, I., Bonakdari, H., Shamshirband, S. (2016). Extreme learning machine assessment for estimating sediment transport in open channels. *Eng Comput*, 32, 691–704. <https://doi.org/10.1007/s00366-016-0446-1>
- Ebtehaj, I., Bonakdari, H., Zeynoddin, M., Gharabaghi, B., & Azari, A. (2020). Evaluation of preprocessing techniques for improving the accuracy of stochastic rainfall forecast models. *International Journal of Environmental Science and Technology*. 17, 505–524. <https://doi.org/10.1007/s13762-019-02361-z>
- Esmaili, F., Shabanlou, S. & Saadat, M. A. (2021). Wavelet-outlier robust extreme learning machine for rainfall forecasting in Ardabil City, Iran. *Earth Sci Inform*, <https://doi.org/10.1007/s12145-021-00681-8>
- Fallahi, M.M., Shabanlou, S., & Rajabi, A. (2023). Effects of climate change on groundwater level variations affected by uncertainty (case study: Razan aquifer). *Appl Water Sci*, 13, 143. <https://doi.org/10.1007/s13201-023-01949-8>
- Gharib, R., Heydari, M., Kardar, S., & Shabanlou, S. (2020). Simulation of discharge coefficient of side weirs placed on convergent canals using modern self-adaptive extreme learning machine. *Appl Water Sci*, 10, 50. <https://doi.org/10.1007/s13201-019-1136-0>

- Goorani, Z., Shabanlou, S. Multi-objective optimization of quantitative-qualitative operation of water resources systems with approach of supplying environmental demands of Shadegan Wetland. *Journal of Environmental Management*, 292, 112769. <https://doi.org/10.1016/j.jenvman.2021.112769>
- Graham, P. W., Andersen, M. S., McCabe, M. F., Ajami, H., Baker, A., & Acworth, I. (2015). To what extent do long-duration high-volume dam releases influence river-aquifer interactions? A case study in New South Wales, Australia. *Hydrogeology Journal*, 23, 319–334. <https://10.1007/s10040-014-1212-3>
- Guzman, S. M., Paz, J. O., Tagert, M. L. M., & Mercer, A. E. (2019). Evaluation of Seasonally Classified Inputs for the Prediction of Daily Groundwater Levels: NARX Networks Vs Support Vector Machines. *Environmental Modeling & Assessment*, 24(2), 223-234. <https://link.springer.com/article/10.1007/s10666-018-9639-x>
- Hu, L., Xu, Z., & Huang, W. (2016). Development of a river-groundwater interaction model and its application to a catchment in Northwestern China. *Journal of Hydrology*, 543, 483–500. <http://dx.doi.org/10.1016/j.jhydrol.2016.10.028>
- Huang, G. B., & Siew, C. K. (2004). Extreme learning machine: RBF network case, in: *Proceedings of the Eighth International Conference on Control, Automation, Robotics and Vision (ICARCV 2004)*, Kunming, China. https://doi.org/10.1007/11760191_17
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Ivkovic, K. M. (2009). A top-down approach to characterise aquifer-river interaction processes. *Journal of Hydrology*, 365, 145–155. <http://dx.doi.org/10.1016/j.jhydrol.2008.11.021>
- Jorge Ramírez-Hernández., OsvelHinojosa-Huerta., MauricioPeregrina-Llanes., Alejandra Calvo-Fonseca and EdgarCarrera-Villa. (2013). Groundwater responses to controlled water releases in the limitrophe region of the Colorado River: Implications for management and restoration. *J. of Ecological Engineering*, 59, 93–103. <https://doi.org/10.1016/j.ecoleng.2013.02.016>
- Langridge, M., Gharabaghi, B., McBean, E., Bonakdari, H., & Walton, R. (2020). Understanding the dynamic nature of Time-to-Peak in UK streams. *J. Hydrol*, 583, 124630. <https://doi.org/10.1016/j.jhydrol.2020.124630>
- Lemieux, J., Hassaoui, J., Molson, J., Therrien, R., Therrien, P., Chouteau, M., & Ouellet, M. (2015). Simulating the impact of climate change on the groundwater resources of the Magdalen Islands. *Journal of Hydrology*, 3, 400–423. <https://doi.org/10.1016/j.ejrh.2015.02.011>
- Mazraeh, A., Bagherifar, M., Shabanlou, S., & Ekhlasmand, R. (2023). A Hybrid Machine Learning Model for Modeling Nitrate Concentration in Water Sources. *Water, Air, & Soil Pollution*, 234(11), 1-22. <http://dx.doi.org/10.1007/s11270-023-06745-3>
- Mazraeh, A., Bagherifar, M., Shabanlou, S., & Ekhlasmand, R. (2024). A novel committee-based framework for modeling groundwater level fluctuations: A combination of mathematical and machine learning models using the weighted multi-model ensemble mean algorithm, *Groundwater for Sustainable Development*, 24, 101062. <https://doi.org/10.1016/j.gsd.2023.101062>
- Moghadam, R.G., Izadbakhsh, M.A., Yosefvand, F., & Shabanlou, S. (2019). Optimization of ANFIS network using firefly algorithm for simulating discharge coefficient of side orifices. *Appl Water Sci*, 9, 84. <https://doi.org/10.1007/s13201-019-0950-8>
- Mohammed, K.S., Shabanlou, S., Rajabi, A., Yosefvand, F., & Izadbakhsh, M.A. (2023). Prediction of groundwater level fluctuations using artificial intelligence-based models and GMS. *Applied Water Science*, 13, 54. <https://doi.org/10.1007/s13201-022-01861-7>
- Moradi, A., Akhtari, A., & Azari, A. (2023). Prediction of groundwater level fluctuation using methods based on machine learning and numerical model. *Journal of Applied Research in Water and Wastewater*, 10 (1), 20-28. <https://doi.org/10.22126/arww.2023.7707.1246>
- Nadiri, A. A., Naderi, K., Khatibi, R., & Gharekhani, M. (2019). Modelling groundwater level variations by learning from multiple models using fuzzy logic. *Hydrological sciences journal*, 64(2), 210-226. <https://doi.org/10.1080/02626667.2018.1554940>

- Nourmohammadi Dehbalaei, F., Azari, A., & Akhtari, A. A. (2023). Development of a linear–nonlinear hybrid special model to predict monthly runoff in a catchment area and evaluate its performance with novel machine learning methods. *Applied Water Science*, 13 (5), 1-23. <https://doi.org/10.1007/s13201-023-01917-2>
- Pahar, G., & Dhar, A. (2014). A Dry Zone-Wet Zone Based Modeling of Surface Water and Groundwater Interaction for Generalized Ground Profile. *Journal of Hydrology*, 519(27), 2215-2223. <http://dx.doi.org/10.1016/j.jhydrol.2014.09.088>
- Panahi, J., Mastouri, R., & Shabanlou, S. (2022) Insights into enhanced machine learning techniques for surface water quantity and quality prediction based on data pre-processing algorithms. *Journal of Hydroinformatics*, 24 (4), 875–897. <https://doi.org/10.2166/hydro.2022.022>
- Paul, A., Afroosa, M., Baduru, B., & Paul, B. (2023). Showcasing model performance across space and time using single diagrams. *Ocean Modelling*, 181, 102150. <https://doi.org/10.1016/j.ocemod.2022.102150>
- Poursaeid, M., Mastouri, R., & Shabanlou, S. (2020). Estimation of total dissolved solids, electrical conductivity, salinity and groundwater levels using novel learning machines. *Environ Earth Sci*, 79, 453. <https://link.springer.com/article/10.1007/s12665-020-09190-1>
- Poursaeid, M., Mastouri, R., Shabanlou, S., & Najarchi, M. (2021). Modelling qualitative and quantitative parameters of groundwater using a new wavelet conjunction heuristic method: wavelet extreme learning machine versus wavelet neural networks. *Water Environ. J*, 35, 67-83. <https://doi.org/10.1111/wej.12595>
- Poursaeid, M., Poursaeid, A.H., & Shabanlou, S. (2022). A Comparative Study of Artificial Intelligence Models and A Statistical Method for Groundwater Level Prediction. *Water Resour Manage*, 36, 1499–1519. <http://dx.doi.org/10.1007/s11269-022-03070-y>
- Rajabi, A., & Shabanlou, S. (2012). Climate index changes in future by using SDSM in Kermanshah, Iran. *Journal of Environmental Research and Development*, 7(1), 37-44. <https://www.cabidigitallibrary.org/doi/full/10.5555/20123377231>
- Shabanlou, S. (2018). Improvement of extreme learning machine using self-adaptive evolutionary algorithm for estimating discharge capacity of sharp-crested weirs located on the end of circular channels. *Flow Measurement and Instrumentation*, 59, 63-71. <https://doi.org/10.1016/j.flowmeasinst.2017.11.003>
- Shrestha, S., Bach, T. V., & Pandey, V. P. (2016). Climate change impacts on groundwater resources in Mekong Delta under representative concentration pathways (RCPs) scenarios. *Environmental Science and Policy*, 61, 1–13. <http://10.1016/j.envsci.2016.03.010>
- Samani, S., Vadiati, M., Delkash, M., & Bonakdari, H. (2022). A hybrid wavelet–machine learning model for qanat water flow prediction. *Acta Geophysica*, 1-19. <http://dx.doi.org/10.1007/s11600-022-00964-8>
- Soltani, K., Ebtehaj, I., Amiri, A., Azari, A., Gharabaghi, B., & Bonakdari, H. (2021). Mapping the spatial and temporal variability of flood susceptibility using remotely sensed normalized difference vegetation index and the forecasted changes in the future. *Science of The Total Environment*, 770, 145288. <https://doi.org/10.1016/j.scitotenv.2021.145288>
- Soltani, K., & Azari, A. (2022). Forecasting groundwater anomaly in the future using satellite information and machine learning. *Journal of Hydrology*, 612 (2), 128052. <https://doi.org/10.1016/j.jhydrol.2022.128052>
- Torabi, A., Yosefvand, F., Shabanlou, S., Rajabi, A., & Yaghoubi, B. (2024). Optimization of Integrated Operation of Surface and Groundwater Resources using Multi-Objective Grey Wolf Optimizer (MOGWO) Algorithm. *Water Resour Manage* 38, 2079–2099. <https://doi.org/10.1007/s11269-024-03744-9>
- Xie, Y., Cook, P G., Shanafield, M., Simmons, C T., & Zheng, C. (2016). Uncertainty of natural tracer methods for quantifying river–aquifer interaction in a large river. *Journal of Hydrology*, 535 ,135–147. <https://doi.org/10.1016/j.jhydrol.2016.01.071>

- Yosefvand, F., & Shabanlou, S. (2020). Forecasting of Groundwater Level Using Ensemble Hybrid Wavelet–Self-adaptive Extreme Learning Machine-Based Models. *Nat Resour Res*, 29, 3215–3232. <http://dx.doi.org/10.1007/s11053-020-09642-2>
- Wang, G. G, Lu, M., Dong, Y. Q., & Zhao, X. J. (2016). Self-adaptive extreme learning machine. *Neural Computing and Applications*, 27(2), 291-303. <http://dx.doi.org/10.1007/s00521-015-1874-3>
- Zarei, S., Yosefvand, F., & Shabanlou, S. (2020). Discharge coefficient of side weirs on converging channels using extreme learning machine modeling method. *Measurement*, 152, 107321. <https://doi.org/10.1016/j.measurement.2019.107321>
- Zeinali, M., Azari, A., & Heidari, M. (2020a). Simulating Unsaturated Zone of Soil for Estimating the Recharge Rate and Flow Exchange Between a River and an Aquifer. *Water Resources Management*, 34, 425–443. <https://link.springer.com/article/10.1007/s11269-019-02458-7>
- Zeinali, M., Azari, A., & Heidari, M. (2020b). Multiobjective Optimization for Water Resource Management in Low-Flow Areas Based on a Coupled Surface Water–Groundwater Model. *Journal of Water Resource Planning and Management (ASCE)*, 146(5), 04020020. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001189](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001189)
- Zeynoddin, M., Bonakdari, H., Ebtehaj, I., Azari, A., & Gharabaghi, B. (2020). A generalized linear stochastic model for lake level prediction. *Science of The Total Environment*, 723, 138015. <https://doi.org/10.1016/j.scitotenv.2020.138015>
- Zhang, K., & Luo, M. (2015). Outlier-robust extreme learning machine for regression problems. *Neurocomputing*, 151, 1519-1527. <https://doi.org/10.1016/j.neucom.2014.09.022>