






Comparison of artificial intelligence and Markov chain-based methods in river discharge forecasting based on satellite signals

Afshin Kiani¹, Ahmad Rajabi², Saeid Shabanlou³, Mohammad Ali Izadbakhsh⁴, and Mohammad Ali Izadbakhsh⁵

1. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. Email: afshin.kiani.ac@gmail.com
2. Corresponding author, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. Email: ahmad.rajabi1974@gmail.com
3. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. Email: saeid.shabanlou@gmail.com
4. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. Email: izadbakhsh.mohammad.ali@gmail.com
5. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. Email: fariborzosefvand@gmail.com

Article Info.

Article type:

Research Article

Article history:

Received 20 January 2025

Received in revised form 19
May 2025

Accepted 12 November 2025

Available online 22 June 2026

Keywords:

river discharge,

Markov chain,

Maroon dam,

ORELM,

hybrid Models.

ABSTRACT

Objective: To predict inflow into the Maroon Dam in Khuzestan using low-cost global satellite data as an alternative to expensive in-situ measurements and to compare the performance of AI-based models with the conventional Markov chain method.

Method: Available global satellite data were employed to estimate dam inflow. The performance of three artificial intelligence-based models (GA-ANN, ICA-ANN, and ORELM) was evaluated and compared with the conventional Markov chain method. These approaches required substantially less data than complex numerical models.

Results: The ORELM model showed the best agreement with observational data, achieving a correlation coefficient of 0.874 during the test phase. It also exhibited the closest distribution of points around the 45-degree line, indicating superior accuracy compared to the other models.

Conclusions: The ORELM method based on satellite signals can reliably predict inflow into dam reservoirs, eliminating the need for complex numerical models with large data requirements and time-consuming calibration and validation processes. This approach provides water resources researchers and planners with an accurate and efficient tool for forecasting inflow variations during dry and wet years.

Cite this article: Kiani, A., Rajabi, A., Shabanlou, S., Izadbakhsh, M.A., & Yosefvand, F. (2026). Comparison of Artificial Intelligence and Markov Chain-Based Methods in River Discharge Forecasting Based on Satellite Signals. *Advanced Technologies in Water Efficiency*, 6(2), 44-64. <https://doi.org/10.22126/atwe.2025.11669.1151>



© The Author(s)

<https://doi.org/10.22126/atwe.2025.11669.1151>

Publisher: Razi University.

Introduction

The inflow of dams is one of the main components of the hydrogeological cycle and one of the required methods of water resources exploitation models. Reliable and complete data is one of the most important challenges in analyzing the change in inflow to dams in water resources management. In recent years, different numerical models have been used, which are a reliable solution to be considered. These models are able to estimate the inflow to dams in each region based on data and information, maps, various ground measurements, boundary conditions, and the use of complex equations. In the present study, global satellite data was used in a cheap and affordable way as an alternative to expensive on-site measurements to predict the inflow to Maroon Dam in Khuzestan.

Method

The study area is the Marun River in Khuzestan Province in southwestern Iran. The Marun River originates from the Nil and Sefid Kooch Mountains and flows into the Maroon Dam Lake after a distance of 120 km. Forecasting the inflow to the Marun Dam is very important due to the role of this dam in meeting agricultural, drinking, and industrial demands, as well as meeting the environmental demands of the Shadegan Wetland downstream. In this study, the Markov Chain (MC) method, developed in MATLAB, was used to predict the flow of the Maru River based on short-term satellite signals. MC is a simple prediction and modeling method that works based on a stochastic method to describe a sequence of possible events. Then, considering the much lower computational complexity and limited data required and very low processing time in artificial intelligence-based methods, the performance of the combined GA-ANN, ICA-ANN, and ORELM methods was tested in comparison with the conventional Markov Chain method.

Results

The results showed that the output of the ORELM model had the best fit to the observational data with a correlation coefficient of 0.874 in the test phase compared to models GA-ANN, ICA-ANN and MC. Also had the best and closest scatter points around the 45-degree line, making it the most accurate model. Instead of using complex models with a very large data volume and also very time-consuming evaluation and accuracy of the evaluation in it, ORELM methods based on satellite information can be used with confidence. This greatly helps water researchers and planners to use numerical models with a complex and time-consuming structure using a combination of artificial intelligence and satellite systems to predict the inflows to dam reservoirs with high accuracy in dry and wet years.

Conclusions

Regarding the amount of inflow into dam reservoirs as one of the most important sources of water resources balance, artificial intelligence models can be used in this study for specific areas of basic statistics or in situations where it is not possible to use mathematical models. By using satellite data, it is recommended. Based on the results obtained, the models developed in this study can also be recommended for studies of other areas using the selection of dams and rivers. In this case, without the need for complex and time-consuming relationships and equations, and only based on satellite maps and at a very low cost, the river discharge in the study area can be predicted with great accuracy during dry periods.

Author Contributions

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data available on request from the authors.

Acknowledgements

The authors would like to thank all participants in the present study.

Ethical Considerations


The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors .

Conflict of Interest

The authors declare no conflict of interest



مقایسه روش‌های مبتنی بر هوش مصنوعی و زنجیره مارکوف در پیش‌بینی دبی رودخانه بر اساس سیگنال‌های ماهواره‌ای

افشین کیانی^۱، احمد رجبی^۲، سعید شعبانلو^۳، محمدعلی ایزدبخش^۴، و فریبرز یوسفوند^۵

۱. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران. رایانامه: afshin.kiani.ac@gmail.com

۲. نویسنده مسئول، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران. رایانامه: ahmad.rajabi1974@gmail.com

۳. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران. رایانامه: saeid.shabanlou@gmail.com

۴. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران. رایانامه: izadbakhsh.mohammad.ali@gmail.com

۵. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران. رایانامه: fariborzoyosefvand@gmail.com

چکیده	در باره مقاله
<p>هدف: هدف از این پژوهش، توسعه مدل‌هایی برای شبیه‌سازی دقیق توزیع و توزیع مجدد رطوبت در خاک‌های دولایه تحت آبیاری قطره‌ای سطحی بود.</p> <p>روش پژوهش: برای دستیابی به این هدف، آزمایش‌هایی بر روی یک مدل فیزیکی شفاف پلکسی گلاس و با استفاده از شش پروفیل مختلف از خاک‌های دولایه (با ترکیبات سبک تا سنگین) انجام شد و مدل‌های رگرسیون غیرخطی بر پایه ویژگی‌های هیدرولیکی خاک و قطره‌چکان توسعه یافتند.</p> <p>یافته‌ها: افته‌ها نشان داد که مدل‌های پیشنهادی در فاز توزیع رطوبت دقت بسیار بالایی دارند (با ضرایب همبستگی ۸۵٪ و ۸۸٪)، اما در فاز توزیع مجدد، به‌ویژه در جهت افقی، دقت آن‌ها کاهش می‌یابد. همچنین مشخص شد که مدل‌ها در جهت افقی تمایل به بیش‌برآورد و در جهت عمودی تمایل به کم‌برآورد دارند.</p> <p>نتیجه‌گیری: با اعمال اصلاحات بر روی این خطاهای سیستماتیک، می‌توان دقت پیش‌بینی مدل‌ها را برای طراحی بهینه سامانه‌های آبیاری بهبود بخشید.</p>	<p>نوع مقاله: مقاله پژوهشی</p> <p>تاریخ دریافت: ۱۴۰۳/۱۱/۰۱</p> <p>تاریخ بازنگری: ۱۴۰۴/۰۲/۲۹</p> <p>تاریخ پذیرش: ۱۴۰۴/۰۸/۲۱</p> <p>تاریخ انتشار: ۱۴۰۵/۰۴/۰۱</p> <p>کلیدواژه‌ها: دبی رودخانه، زنجیره مارکوف، سد مارون، ORELM، Hybrid Models</p>

استناد: کیانی، افشین؛ رجبی، احمد؛ شعبانلو، سعید؛ ایزدبخش، محمدعلی، و یوسفوند، فریبرز. (۱۴۰۵). مقایسه روش‌های مبتنی بر هوش مصنوعی و زنجیره مارکوف در پیش‌بینی دبی رودخانه بر اساس سیگنال‌های ماهواره‌ای. *فناوری‌های پیشرفته در بهره‌وری آب*، ۶(۲)، ۴۴-۶۴.

<https://doi.org/10.22126/atwe.2025.11669.1151>



مقدمه

افزایش بی‌رویه جمعیت، محدودیت منابع آب‌های سطحی و بهره‌برداری بیش از منابع آب بدون توجه به کاهش جریان‌ات وردی به سدها و عدم پیش‌بینی دقیق آن باعث وارد آمدن خسارات جبران‌ناپذیری به منابع طبیعی ایران در سال‌های گذشته شده است. علاوه بر کاهش شدید جریان رودخانه‌ها در اثر کاهش بارندگی، گسترش بی‌رویه فعالیت‌های کشاورزی، صنعتی و شهری برداشت مازادی را به منابع آب در دسترس تحمیل می‌کنند که لزوم پیش‌بینی جریان‌ات رودخانه‌ها برای مدیریت بهره‌برداری و حفاظت از منابع آب به‌عنوان یک اصل و پایه در برنامه‌ریزی‌های کشور را گوشزد می‌کند؛ لذا برای برنامه‌ریزی بهتر و استفاده بهینه از منابع آب باید راهکارهایی برای پیش‌بینی دقیق نوسانات جریان رودخانه‌ها بخصوص در سال‌های خشک و کم آب بکار گرفته شود. به‌منظور ارزیابی اثرات ناشی از توسعه، بر روی منابع آب 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 آب و پیش‌بینی دبی رودخانه‌ها مورد توجه قرار گرفته است. بررسی روند پیشرفت مدل‌های عددی نشان می‌دهد مجموعه‌ای از عوامل مختلف مانند شرایط مرزی و محیطی، خصوصیات فیزیکی و هیدرولیکی رودخانه‌ها، مقاطع رودخانه و سطح خیس شده، کاربری اراضی و پوشش گیاهی حوضه، نحوه پراکنش آبراهه‌ها و جریان آب در حوضه، پارامترهای مربوط به زمان پیمایش، عوامل توپوگرافی و زمین‌شناسی و غیره در شبیه‌سازی تغییرات رواناب تولیدی در حوضه‌ها مؤثر هستند (زامپیری و همکاران^۱، ۲۰۱۲). در چنین ساختارهایی بررسی پارامترهای اقلیمی مانند دما و بارش بر کل سیستم و پیش‌بینی تغییرات رواناب 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 (کلوو و همکاران^۲، ۲۰۱۴؛ عزیزی و همکاران^۳، ۲۰۲۳)؛ امیری و همکاران^۴، ۲۰۲۱؛ شهبانلو^۵، ۲۰۱۸؛ شرستا و همکاران^۶، ۲۰۱۶؛ لمیوکس و همکاران^۷، ۲۰۱۵؛ پاندا و همکاران^۸، ۲۰۱۲.

در برخی تحقیقات، برای پیش‌بینی دبی جریان در حوضه، اتصال مدل‌های آب سطحی و زیرزمینی بر اساس شبیه‌سازی ناحیه اشباع و غیراشباع صورت گرفته 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 مناطق امکان‌پذیر نیست (زینعلی و همکاران^۹، ۲۰۲۰؛ زینعلی و همکاران^{۱۰}، ۲۰۲۰). 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. با این حال، مشکل این است که در همه این روش‌ها از اطلاعات در محل استفاده می‌شود. به طوری که روش‌های پیشنهادی را نمی‌توان در مناطق بدون سنجش در محل (بدون داده تاریخی) استفاده کرد. باید این واقعیت را در نظر گرفت که تعداد ایستگاه‌های هیدرومتری موجود در برخی از کشورها از جمله ایران کم است و دارای پراکنش مناسب نیست. روش‌های شبیه‌سازی برای حل مسائل مربوط به سیستم‌های آب سطحی دارای روابط و معادلات پیچیده هستند؛ لذا مدل‌های ریاضی که بتواند سیستم‌های پیچیده را بر اساس واقعیت موجود شبیه‌سازی کرده و امکان توسعه و به‌روزرسانی آنها به‌منظور افزایش دقت وجود داشته باشد معمولاً گران هستند (هوو و همکاران^{۱۰}، ۲۰۱۶؛

¹ Zampieri et al

² Klove et al

³ Azizi et al

⁴ Amiri et al

⁵ Shabanlou

⁶ Shrestha et al

⁷ Lemieux et al

⁸ Panda et al

⁹ Zeinali et al

¹⁰ Hu et al

ایوکوویچ^۱، ۲۰۰۹؛ فلاحی و همکاران^۲، ۲۰۲۳؛ پناهی و همکاران^۳، ۲۰۲۲؛ جلیلیان و همکاران^۴، ۲۰۲۲؛ و امان جلیلی^۵ و همکاران^۶، ۲۰۲۳؛ پاهار و دهار^۶، ۲۰۱۴؛ بایسته و آذری^۷، ۲۰۲۱).

از این رو جایگزینی روش های ساده و قابل اعتمادی که نیاز به حجم اطلاعات کمی داشته و در عین حال با صرف وقت و هزینه بسیار کم نتایج دقیقی را در مقایسه با روش های عددی و مدل های ریاضی داشته باشند بسیار پر اهمیت است (نورمحمدی دهبالایی و همکاران^۸، ۲۰۲۳). در اکثر این روش ها پیش بینی وقایع هیدرولوژیکی بدون استفاده از مدل های شبیه سازی بر اساس تجزیه و تحلیل سری های زمانی، روش های مبتنی بر زنجیره مارکوف و یا ابزار هوش مصنوعی است و در زمان کمتر، با صرف هزینه کمتر و بادقت بالا قادر به پیش بینی این وقایع هستند (سلطانی و آذری^۹، ۲۰۲۲؛ گوزمان و همکاران^{۱۰}، ۲۰۱۹؛ ندیری و همکاران^{۱۱}، ۲۰۱۹). در سال های اخیر در کنار روش های استوکاستیک (ابتهاج و همکاران^{۱۲}، ۲۰۲۰؛ زین الدین و همکاران^{۱۳}، ۲۰۲۰؛ مزرعه و همکاران^{۱۴}، ۲۰۲۳ و ۲۰۲۴؛ آذری و همکاران^{۱۵}، ۲۰۲۱) به صورت گسترده از روش های مبتنی بر هوش مصنوعی مانند ORELM، LS-SVM، ELM، GMDH و روش های هیبرید برای پیش بینی پارامترهای هیدروکلیماتولوژی مانند دما، بارندگی، جریان رودخانه ها و تغییرات تراز آب مخازن سطحی و آب زیرزمینی استفاده شده است (ابتهاج و همکاران، ۲۰۱۶؛ زین الدین و همکاران، ۲۰۱۸؛ سلطانی و همکاران، ۲۰۲۱؛ اسماعیلی و همکاران^{۱۶}، ۲۰۲۱).

نکته مهم دیگر برای استفاده جامع از این روش ها بخصوص در مناطق فاقد داده های زمینی، امکان استفاده از داده ها و اطلاعات ماهواره ای مربوط به سری زمانی داده های هیدرولوژیکی مانند دبی، بارندگی و دما است. این داده ها توسط برخی از ماهواره ها برای اکثر نقاط کره زمین ارائه می شوند و کاملاً رایگان و در دسترس محققان قرار دارد. بر این اساس موضوع جدیدی بر اساس تحلیل اطلاعات ماهواره ای اخیراً ظهور یافته است. علاقه مندی اصلی محققان این زمینه استفاده از اطلاعات ماهواره ای برای مدل سازی و پیش بینی وقایع هیدرولوژیکی است. دبی رودخانه ها می تواند توسط سیگنال های ماهواره ای پیش بینی شود. برای پیش بینی دبی رودخانه ها برای آینده با استفاده از اطلاعات ماهواره ای به منظور نظارت بر سیل یا طراحی درست سازه های هیدرولیکی لازم است سیگنال های ماهواره ای به طور دقیق تری مورد ارزیابی قرار گیرد. استفاده از اطلاعات موجود ماهواره ای در دسترس و ارزان برای پیش بینی ویژگی های هیدرولوژیکی رودخانه ها، به عنوان جایگزینی برای اندازه گیری های گران قیمت در محل، یکی از جالب ترین زمینه های تحقیقاتی در هیدرولوژی است. تحقیقات نشان داده اند که با استفاده از اطلاعات مبتنی بر ماهواره، دبی رودخانه ها را می توان بادقت زیاد پیش بینی کرد. پیش بینی ویژگی های آینده رودخانه ها با استفاده از اطلاعات ماهواره ای تنها زمانی امکان پذیر است که سیگنال های مبتنی بر فضا بادقت قابل پیش بینی شده باشد.

¹ Ivkovic

² Fallahi et al

³ Panahi et al

⁴ Jalilian et al

⁵ Aman Jalili et al

⁶ Pahar & Dhar

⁷ Bayesteh & Azari

⁸ Nourmohammadi Dehbalaei et al

⁹ Soltani & Azari

¹⁰ Guzman et al

¹¹ Nadiri et al

¹² Ebtehaj et al

¹³ Zeynoddin et al

¹⁴ Mazraeh et al

¹⁵ Azari et al

¹⁶ Esmacili et al

ادبیات موضوع و پیشینه پژوهش

برینریج و همکاران^۱ (۲۰۱۲) اطلاعات ارائه شده توسط ماهواره AMSR را با دبی ثبت شده در رودخانه‌ها مقایسه کرده و میزان دقت آن را مورد ارزیابی قرار دادند. کوهن و همکاران^۲ (۲۰۱۲) یک مدل هیدرولوژیکی برای محاسبه دبی رودخانه‌ها با استفاده از اطلاعات ماهواره‌ای به صورت real time ایجاد کردند و نتیجه گرفتند که سیگنال‌های ماهواره‌ای AMSR توانایی مدل‌سازی دقیق در جریان رودخانه‌ها در محل را دارد.

بنکداری و همکاران^۳ (۲۰۱۹) به منظور بررسی کارایی مدل زنجیره مارکوف استاندارد (MC)، تغییرات شش رودخانه را بررسی کردند و نتایج مدل‌سازی را با روش LR و سه روش MLP، ELM و RBF مقایسه کردند و دریافتند که توانایی MC برای تولید چند روزه بدون نیاز به اطلاعات روز گذشته خود برای استفاده به عنوان متغیر ورودی مدل است. براین اساس با توجه به تاریخچه، دبی رودخانه‌ها را می‌توان با سیگنال‌های ماهواره‌ای پیش‌بینی کرد. روش MC به صورت گسترده برای پیش‌بینی تغییرات کیفی آب زیرزمینی (سو و همکاران^۴، ۲۰۱۹)، مدل‌سازی الگوی خطر خشکسالی کشاورزی (کامروززaman و همکاران^۵، ۲۰۱۸) و پیش‌بینی اثر فرآیندهای هیدرولوژیکی بر حوضه آبریز سریع شهری (کاپیان و همکاران^۶، ۲۰۲۰) مورد استفاده قرار گرفته است. بارندگی یکی از پارامترهای مهم سیکل هیدروکلیماتولوژی است که به صورت مستقیم بر دبی رودخانه‌ها و وقوع سیلاب تاثیر می‌گذارد؛ لذا محققان زیادی با استفاده از روش MC به پیش‌بینی این پارامتر در مناطق مختلف جهان پرداخته‌اند (دهامشه و همکاران^۷، ۲۰۱۴؛ گوویی و همکاران^۸، ۲۰۱۷؛ ژوو و همکاران^۹، ۲۰۱۷؛ آکسوی و همکاران^{۱۰}، ۲۰۱۸؛ لیبو و همکاران^{۱۱}، ۲۰۲۰). یکی از مباحث مهم در پیش‌بینی وقایع هیدرولوژیکی مانند بارندگی و سیلاب در نظر گرفتن عدم قطعیت‌های ناشی از مدل‌سازی است و روش ترکیبی زنجیره مارکوف-مونت کارلو (MCMC) یکی از راهکارهای پرکاربرد در این زمینه است (ونگ و ونگ^{۱۲}، ۲۰۱۹؛ ونگ و همکاران^{۱۳}، ۲۰۲۱؛ نگووین-هوی و همکاران^{۱۴}، ۲۰۲۱).

بررسی تحقیقات انجام شده نشان می‌دهد اکثریت مدل‌های ریاضی بکار گرفته شده برای شبیه‌سازی دبی جریان نیازمند تعریف شرایط مرزی جدید و اطلاعات پایه زیاد و نقشه‌های مربوط به آن منطقه است. کاربردی نمودن این مدل مستلزم انطباق آن با شرایط خاص منطقه مورد مطالعه است. به دلیل حجم زیاد آمار و اطلاعات مورد نیاز و همچنین لزوم انجام فرایند واسنجی و صحت‌سنجی در این مدل‌ها که فرایندی بسیار وقت‌گیر و پیچیده است، استفاده از یک روش جایگزین مانند روش‌های استوکاستیک (زنجیره مارکوف یا روش‌های مبتنی بر هوش مصنوعی) که در مقایسه با مدل‌های ریاضی بتواند با همان دقت و در زمان کمتر و با استفاده از داده‌ها و اطلاعات ناچیز، ویژگی‌های هیدرولوژیکی رودخانه را پیش‌بینی نماید بسیار حائز اهمیت است. از طرفی در بسیاری از رودخانه‌ها اطلاعات کافی برای تحلیل هیدرولیکی و شبیه‌سازی سیستمی منابع آب سطحی برای پیش‌بینی دبی وجود ندارد یا از دقت کافی برخوردار نیست. در چنین حوضه‌هایی استفاده از اطلاعات و سیگنال‌های ماهواره‌ای برای پیش‌بینی دبی رودخانه‌ها می‌تواند راهگشا باشد.

بررسی منابع نشان داد در بسیاری از تحقیقات از روش زنجیره مارکوف که فقط از آخرین وضعیت مجموعه داده‌های آموزشی برای توسعه مجموعه داده‌های غیر مشاهداتی استفاده می‌کند، برای پیش‌بینی جریان بر اساس سیگنال‌های ماهواره‌ای کوتاه‌مدت

¹ Brainerridge et al

² Cohen et al

³ Bonakdari et al

⁴ Su et al

⁵ Kamruzzaman et al

⁶ Kavian et al

⁷ Dahamsheh et al

⁸ Gui et al

⁹ Zhou et al

¹⁰ Aksoy et al

¹¹ Liu et al

¹² Wang & Wang

¹³ Wang et al

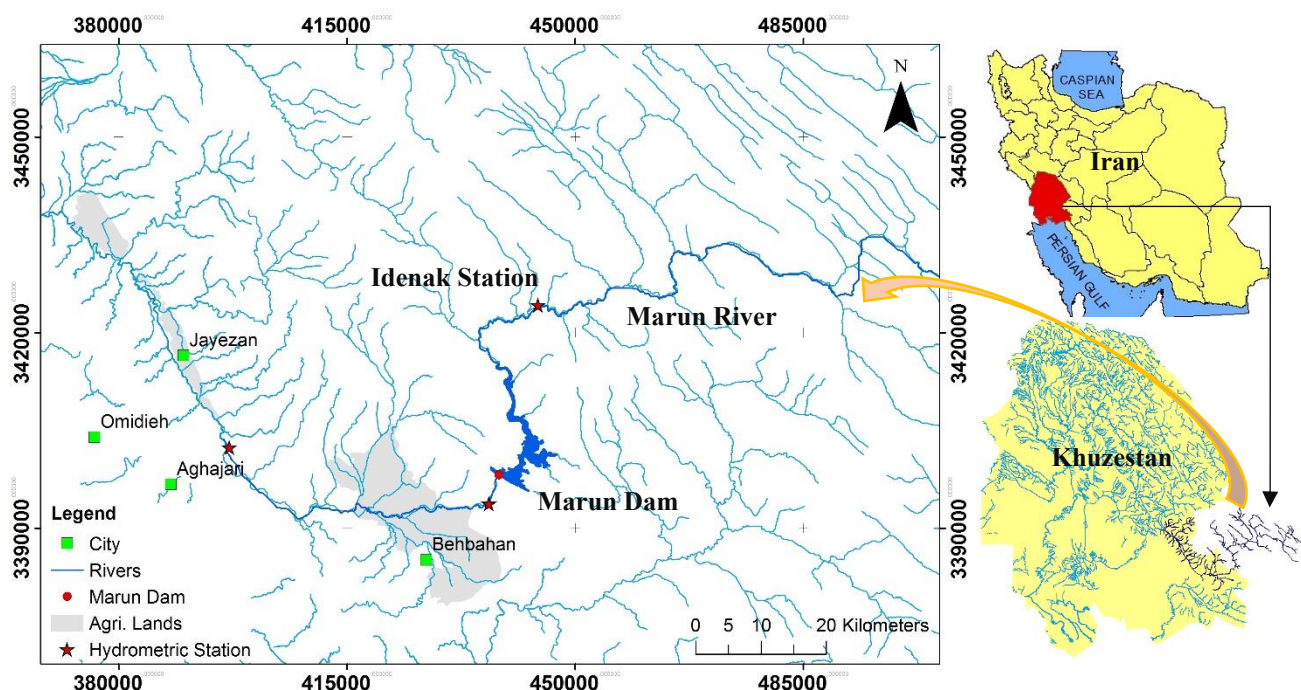
¹⁴ Nguyen-Huy et al

استفاده شده است. هدف از این تحقیق مقایسه عملکرد روش های هیبرید GA-ANN و ICA-ANN و ORELM در مقایسه با روش معمول زنجیره مارکوف (MC) در ترکیب با سیگنال های ماهواره ای برای پیش بینی جریان ورودی به مخزن سد مارون است تا بتوان از آن به عنوان راهکاری ارزان و بدون نیاز به مدل ها و معادلات پیچیده که غالباً نیاز به حجم داده ها و اطلاعات زیادی دارند استفاده کرد. در این صورت می توان به نتایج این مدل ها در رودخانه های با تعداد داده بسیار کم اعتماد کرد.

روش پژوهش

۱. منطقه مورد مطالعه

منطقه مورد مطالعه رودخانه مارون در استان خوزستان در جنوب غربی ایران است. رودخانه مارون از کوه های نیل و سفید کوه سرچشمه گرفته و پس از طی مسافت ۱۲۰ کیلومتر به دریاچه سد مارون وارد می شود. سد مخزنی مارون بر روی رودخانه مارون در فاصله ۱۹ کیلومتری شمال شرق بهبهان در استان خوزستان و قسمت جنوبی ایران است. جانمایی رودخانه ها و مصارف موجود در منطقه در شکل (۱) آمده است.



شکل ۱. موقعیت محدوده مطالعاتی در ایران، رودخانه مارون و سد مارون

۲. داده های ماهواره^۱ (AMSR)

راديو متر اسکن مایکروویو پیشرفته (AMSR) سیگنال های ضعیف مایکروویو ساطع شده از منابع طبیعی مانند سطح زمین و جو را اندازه گیری می کند. توسعه رادیومترهای مایکروویو در ژاپن در دهه ۱۹۷۰ آغاز شد. اولین رادیومتر مایکروویو رادیومتر اسکن مایکروویو (MSR) بود. در فوریه ۱۹۸۷ بر روی ماهواره رصد دریایی (MOS-1) پرتاب شد. MOS-1 در نوامبر ۱۹۹۵ پس از به دست آوردن اطلاعات در نزدیکی ژاپن و تأیید عملکرد سنسور، کار خود را متوقف کرد. در فوریه ۱۹۹۰، جانشین آن، MOS-1b که عملکردی مشابه MOS-1 داشت، نیز به فضا پرتاب شد. بعداً در سال ۲۰۰۲، NASDA (در حال حاضر JAXA) دو

^۱ Advanced Microwave Scanning Radiometer

رادیومتر پیشرفته اسکن مایکروویو (AMSR; Advanced MSR) را توسعه داد. یکی AMSR-E در ماهواره NASA Aqua (پرتاب شده در می ۲۰۰۲)، و دیگری AMSR در ماهواره ADEOS-II JAXA (پرتاب شده در دسامبر ۲۰۰۲). رادیومتر اسکن مایکروویو پیشرفته ۲ (AMSR2) روی برد GCOM-W در حال حاضر در حال کار است. AMSR3 در سال مالی ۲۰۲۳ راه اندازی شد.

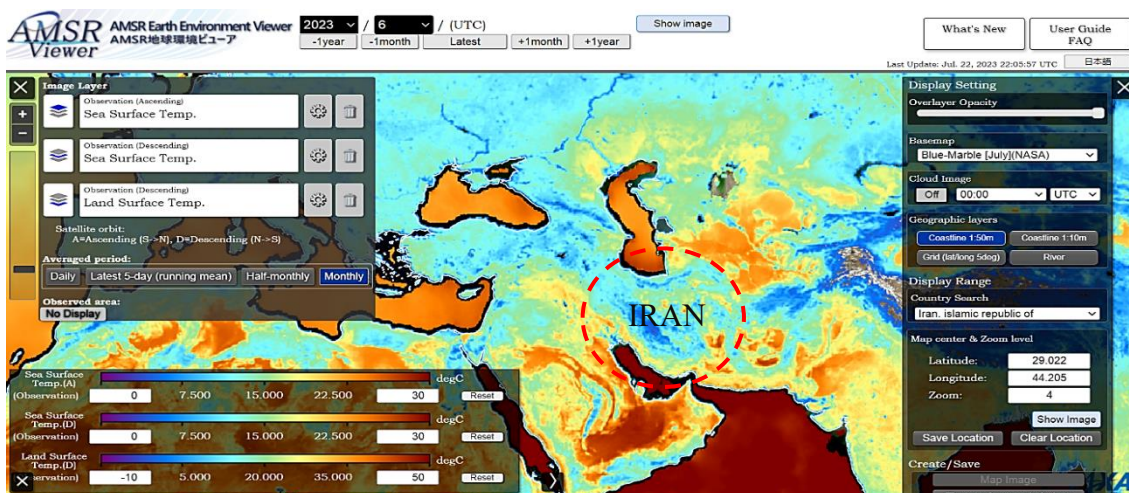
رادیومتر اسکن مایکروویو پیشرفته (AMSR) روی سه ماهواره کار می‌کند.

۱. AMSR در فضاپیما ADEOS-II JAXA که در ۱۴ دسامبر ۲۰۰۲ پرتاب شد. پانل‌های خورشیدی ماهواره‌ای در ۲۵ اکتبر ۲۰۰۳ از کار افتادند.

۲. AMSR-E در فضاپیما آبی سیستم مشاهده زمین (EOS) ناسا که در ۴ می ۲۰۰۲ پرتاب شد. چرخش این ابزار در ۴ اکتبر ۲۰۱۱ متوقف شد.

۳. AMSR-2 در فضاپیما GCOM-W1 JAXA که در ۱۸ می ۲۰۱۲ پرتاب شد. این ابزار در حال حاضر در حال کار است.

AMSR-E پارامترهای ژئوفیزیکی را اندازه‌گیری می‌کند که از چندین علم تغییر جهانی و تلاش‌های نظارتی پشتیبانی می‌کند، از جمله بارش، بخار آب اقیانوسی، آب ابر، سرعت باد نزدیک به سطح، دمای سطح دریا، رطوبت خاک، پوشش برف و پارامترهای یخ دریا. همه این اندازه‌گیری‌ها برای درک آب‌وهوای زمین حیاتی هستند. AMSR-2 انتشار مایکروویو ضعیف از سطح و جو زمین را اندازه‌گیری می‌کند. از ارتفاع حدود ۷۰۰ کیلومتری زمین، AMSR-2 اندازه‌گیری‌های بسیار دقیقی از شدت انتشار و پراکندگی امواج مایکروویو ارائه می‌دهد. آنتن AMSR-2 یک‌بار در ۱/۵ ثانیه می‌چرخد و داده‌ها را در طول ۱۴۵۰ کیلومتر به دست می‌آورد. این امر AMSR-2 را قادر می‌سازد تا مجموعه‌ای از داده‌های روز و شب را با بیش از ۹۹ درصد پوشش زمین هر روز به دست آورد (شکل ۲). داده‌های این ماهواره به‌صورت روزانه و ماهیانه ارائه شده است که در این تحقیق از داده‌های روزانه استفاده شده است.



شکل ۲. نمونه تصویر ماهواره AMSR مربوط به ایران و جهان در سال ۲۰۲۳

باتوجه به اینکه اندازه مساحتی که AMSR تحت پوشش قرار می‌دهد $8 \times 12 \text{ km}^2$ است به دلیل پوشش کلی زمین، کل زمین را به 4000×2000 پیکسل تقسیم می‌کند به این دلیل که یک رویکرد جهانی داشته باشد. سیگنال‌های ماهواره‌ای با استفاده از دمای روشنایی (Tb) محاسبه می‌شود که با استفاده از معادله (۱) محاسبه می‌شود.

$$T_b = \varepsilon \times T \quad (1)$$

ε ضریب اشباع است و T دما فیزیکی منطقه موردنظر است. مقدار آب موجود در زمین با استفاده از تفاوت ε به دست می آید که ε حدود ۰.۵ برای سطوح مرطوب است و ε بین ۰.۷۵ تا ۰.۹۵ برای سطوح خشک است. با فرض داشتن ۲ پیکسل خشک و مرطوب که دارای دمای فیزیکی یکسان هستند تنها راه شناخت آن‌ها بررسی T_b هر دو است. پیکسل‌های خشک و مرطوب دارای دمای فیزیکی مشابه T_b های متفاوتی دارند به این صورت که T_b پیکسلی که دارای آب است به طور قابل توجهی از T_b پیکسلی که خشک است کمتر است. همان‌طور که قبلاً بیان شد پیکسل‌های سنسور *AMSR* مساحت نسبتاً بزرگی را پوشش می‌دهند و زمانی که ما بخواهیم خصوصیات یک رودخانه بررسی و اندازه‌گیری کنیم این پیکسل‌ها به دلیل بزرگ بودن ابعادشان تقریباً در هر زمانی بر روی سطوح آبی و سطوح خشکی قرار می‌گیرند. به این صورت که قسمتی از پیکسل که بر روی رودخانه افتاده باشد را با (W) و منطقه باقی مانده از پیکسل که بر روی خشکی افتاده باشد را با $(I-W)$ نشان داده می‌شود. دمای روشنایی هر پیکسل با استفاده از معادله (۲) محاسبه می‌شود.

$$T_b = (1-w)T_{b,l} + wT_{b,w} \quad (2)$$

در معادله مزبور $T_{b,w}$ درجه‌حرارت روشنایی قسمت‌های زمین از پیکسل در نظر گرفته شده است و همچنین $T_{b,l}$ درجه‌حرارت روشنایی قسمت‌های آب از پیکسل در نظر گرفته شده است. به دلیل اینکه مناطق خشک و مرطوب از یک پیکسل به هم نزدیک هستند می‌توان درجه‌حرارت فیزیکی را برای هر دو ناحیه ثابت در نظر گرفت و در معادله (۲) ضرایب انتشار را جای داد تا معادله (۳) حاصل شود.

$$T_b = T((1-w)\varepsilon_l + w\varepsilon_w) \quad (3)$$

در معادله بالا L ضریب انتشار مناطق خشک است و w ضریب انتشار مناطق مرطوب است. همچنین به منظور از بین بردن اثر دمای مختلف فیزیکی در زمین‌های مختلف سال و حذف اصطلاح T ، معادله روشنایی رودخانه (معادله ۳) را به دلیل اینکه هر دو پیکسل دارای دمای فیزیکی مشابه هستند بر یک پیکسل کاملاً خشک مجاورش $(T_{b,c})$ به عنوان یک پیکسل کالیبراسیون تقسیم می‌شود؛ بنابراین شرایط T در آخرین معادله برابر در نظر گرفته می‌شود و معادله سیگنال ماهواره‌ای نهایی که برای محاسبه مشخصات رودخانه‌ها استفاده می‌شود، به شرح زیر به دست می‌آید.

$$S = \frac{T_{b,c}}{T_{b,m}} = \frac{T((1-w)\varepsilon_l + 0 \times \varepsilon_w)}{T((1-w)\varepsilon_l + w \times \varepsilon_w)} = \frac{\varepsilon_l}{(1-w)\varepsilon_l + w \times \varepsilon_w} \quad (4)$$

در این معادله ε_l و ε_w ثابت و w یک متغیر است؛ بنابراین تمام تغییرات سیگنال به مقدار w مربوط است. با توجه به معادله S مشخص است که تغییرات در سیگنال‌های ماهواره‌ای می‌تواند به عنوان نشانه‌ای از تغییرات در دبی رودخانه‌ها در نظر گرفته شود. چون همان‌گونه که معلوم است با افزایش بخش آب پیکسل مقدار S افزایش می‌یابد و بالعکس. پس همان‌طور که معلوم است سیگنال‌های ماهواره‌ای متناسب با آب موجود در پیکسل تغییر می‌کنند. دبی رودخانه با استفاده از مفهوم تداوم و کمیت‌های عرض (b) و عمق (d) رودخانه و سرعت جریان (v) به صورت معادله (۵) زیر نشان داده می‌شود.

$$Q = b \times d \times v \quad (5)$$

در یک رودخانه کانال غیر عمودی، اثرات تغییر w و d روی دبی تقریباً مشابه هم هستند و هر دوی آن‌ها پیش‌بینی‌های بهتری نسبت به v دارند؛ بنابراین با در نظر گرفتن عرض یک رودخانه به عنوان محل ساکن خود در پیکسل در نظر گرفته شده، مشخص است که تخلیه رودخانه‌ها را می‌توان بادقت به سیگنال‌های ماهواره‌ای تنظیم نمود.

۳. زنجیره مارکوف

زنجیره مارکوف مدلی تصادفی برای توصیف یک توالی از رویدادهای احتمالی است که در آن احتمال هر رویداد فقط به حالت رویداد قبلی بستگی دارد. در واقع MC یک روش پیش‌بینی و مدل‌سازی ساده است که بر اساس روش تصادفی به‌منظور توصیف توالی وقایع احتمالی کار می‌کند. این روش به نام آندری مارکوف که یک ریاضی‌دان روسی بود، نام‌گذاری شد. در این روش تصادفی، ویژگی مارکوف باید ارضا شود. اگر پیش‌بینی آینده فرایندی مستقل از تاریخچه آن فرایند باشد، خاصیت مارکوف ارضا می‌شود.

$$X_n, \quad n = 0, 1, 2, \dots \quad (۶)$$

در اینجا، X_n یک رویه تصادفی است که تعداد محدودی از مقادیر ممکن را دارد. عبارت $X_n = i$ می‌گوید که در زمان n ، رویه کار در حالت i است. در اینجا یک فرض وجود دارد که وقتی رویه در حالت i است، پس یک احتمال ثابت برای P_{ij} وجود دارد که حالت رویه بعدی j باشد.

$$P_{ij} = P\{X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0\} \quad (۷)$$

لازم به ذکر است که تمام مقادیر n و j ، i ، i_{n-1} ، i_0 ، i_1 ، i_2 ، i_3 ، i_4 ، i_5 ، i_6 ، i_7 ، i_8 ، i_9 ، i_{10} ، i_{11} ، i_{12} ، i_{13} ، i_{14} ، i_{15} ، i_{16} ، i_{17} ، i_{18} ، i_{19} ، i_{20} ، i_{21} ، i_{22} ، i_{23} ، i_{24} ، i_{25} ، i_{26} ، i_{27} ، i_{28} ، i_{29} ، i_{30} ، i_{31} ، i_{32} ، i_{33} ، i_{34} ، i_{35} ، i_{36} ، i_{37} ، i_{38} ، i_{39} ، i_{40} ، i_{41} ، i_{42} ، i_{43} ، i_{44} ، i_{45} ، i_{46} ، i_{47} ، i_{48} ، i_{49} ، i_{50} ، i_{51} ، i_{52} ، i_{53} ، i_{54} ، i_{55} ، i_{56} ، i_{57} ، i_{58} ، i_{59} ، i_{60} ، i_{61} ، i_{62} ، i_{63} ، i_{64} ، i_{65} ، i_{66} ، i_{67} ، i_{68} ، i_{69} ، i_{70} ، i_{71} ، i_{72} ، i_{73} ، i_{74} ، i_{75} ، i_{76} ، i_{77} ، i_{78} ، i_{79} ، i_{80} ، i_{81} ، i_{82} ، i_{83} ، i_{84} ، i_{85} ، i_{86} ، i_{87} ، i_{88} ، i_{89} ، i_{90} ، i_{91} ، i_{92} ، i_{93} ، i_{94} ، i_{95} ، i_{96} ، i_{97} ، i_{98} ، i_{99} ، i_{100} ، i_{101} ، i_{102} ، i_{103} ، i_{104} ، i_{105} ، i_{106} ، i_{107} ، i_{108} ، i_{109} ، i_{110} ، i_{111} ، i_{112} ، i_{113} ، i_{114} ، i_{115} ، i_{116} ، i_{117} ، i_{118} ، i_{119} ، i_{120} ، i_{121} ، i_{122} ، i_{123} ، i_{124} ، i_{125} ، i_{126} ، i_{127} ، i_{128} ، i_{129} ، i_{130} ، i_{131} ، i_{132} ، i_{133} ، i_{134} ، i_{135} ، i_{136} ، i_{137} ، i_{138} ، i_{139} ، i_{140} ، i_{141} ، i_{142} ، i_{143} ، i_{144} ، i_{145} ، i_{146} ، i_{147} ، i_{148} ، i_{149} ، i_{150} ، i_{151} ، i_{152} ، i_{153} ، i_{154} ، i_{155} ، i_{156} ، i_{157} ، i_{158} ، i_{159} ، i_{160} ، i_{161} ، i_{162} ، i_{163} ، i_{164} ، i_{165} ، i_{166} ، i_{167} ، i_{168} ، i_{169} ، i_{170} ، i_{171} ، i_{172} ، i_{173} ، i_{174} ، i_{175} ، i_{176} ، i_{177} ، i_{178} ، i_{179} ، i_{180} ، i_{181} ، i_{182} ، i_{183} ، i_{184} ، i_{185} ، i_{186} ، i_{187} ، i_{188} ، i_{189} ، i_{190} ، i_{191} ، i_{192} ، i_{193} ، i_{194} ، i_{195} ، i_{196} ، i_{197} ، i_{198} ، i_{199} ، i_{200} ، i_{201} ، i_{202} ، i_{203} ، i_{204} ، i_{205} ، i_{206} ، i_{207} ، i_{208} ، i_{209} ، i_{210} ، i_{211} ، i_{212} ، i_{213} ، i_{214} ، i_{215} ، i_{216} ، i_{217} ، i_{218} ، i_{219} ، i_{220} ، i_{221} ، i_{222} ، i_{223} ، i_{224} ، i_{225} ، i_{226} ، i_{227} ، i_{228} ، i_{229} ، i_{230} ، i_{231} ، i_{232} ، i_{233} ، i_{234} ، i_{235} ، i_{236} ، i_{237} ، i_{238} ، i_{239} ، i_{240} ، i_{241} ، i_{242} ، i_{243} ، i_{244} ، i_{245} ، i_{246} ، i_{247} ، i_{248} ، i_{249} ، i_{250} ، i_{251} ، i_{252} ، i_{253} ، i_{254} ، i_{255} ، i_{256} ، i_{257} ، i_{258} ، i_{259} ، i_{260} ، i_{261} ، i_{262} ، i_{263} ، i_{264} ، i_{265} ، i_{266} ، i_{267} ، i_{268} ، i_{269} ، i_{270} ، i_{271} ، i_{272} ، i_{273} ، i_{274} ، i_{275} ، i_{276} ، i_{277} ، i_{278} ، i_{279} ، i_{280} ، i_{281} ، i_{282} ، i_{283} ، i_{284} ، i_{285} ، i_{286} ، i_{287} ، i_{288} ، i_{289} ، i_{290} ، i_{291} ، i_{292} ، i_{293} ، i_{294} ، i_{295} ، i_{296} ، i_{297} ، i_{298} ، i_{299} ، i_{300} ، i_{301} ، i_{302} ، i_{303} ، i_{304} ، i_{305} ، i_{306} ، i_{307} ، i_{308} ، i_{309} ، i_{310} ، i_{311} ، i_{312} ، i_{313} ، i_{314} ، i_{315} ، i_{316} ، i_{317} ، i_{318} ، i_{319} ، i_{320} ، i_{321} ، i_{322} ، i_{323} ، i_{324} ، i_{325} ، i_{326} ، i_{327} ، i_{328} ، i_{329} ، i_{330} ، i_{331} ، i_{332} ، i_{333} ، i_{334} ، i_{335} ، i_{336} ، i_{337} ، i_{338} ، i_{339} ، i_{340} ، i_{341} ، i_{342} ، i_{343} ، i_{344} ، i_{345} ، i_{346} ، i_{347} ، i_{348} ، i_{349} ، i_{350} ، i_{351} ، i_{352} ، i_{353} ، i_{354} ، i_{355} ، i_{356} ، i_{357} ، i_{358} ، i_{359} ، i_{360} ، i_{361} ، i_{362} ، i_{363} ، i_{364} ، i_{365} ، i_{366} ، i_{367} ، i_{368} ، i_{369} ، i_{370} ، i_{371} ، i_{372} ، i_{373} ، i_{374} ، i_{375} ، i_{376} ، i_{377} ، i_{378} ، i_{379} ، i_{380} ، i_{381} ، i_{382} ، i_{383} ، i_{384} ، i_{385} ، i_{386} ، i_{387} ، i_{388} ، i_{389} ، i_{390} ، i_{391} ، i_{392} ، i_{393} ، i_{394} ، i_{395} ، i_{396} ، i_{397} ، i_{398} ، i_{399} ، i_{400} ، i_{401} ، i_{402} ، i_{403} ، i_{404} ، i_{405} ، i_{406} ، i_{407} ، i_{408} ، i_{409} ، i_{410} ، i_{411} ، i_{412} ، i_{413} ، i_{414} ، i_{415} ، i_{416} ، i_{417} ، i_{418} ، i_{419} ، i_{420} ، i_{421} ، i_{422} ، i_{423} ، i_{424} ، i_{425} ، i_{426} ، i_{427} ، i_{428} ، i_{429} ، i_{430} ، i_{431} ، i_{432} ، i_{433} ، i_{434} ، i_{435} ، i_{436} ، i_{437} ، i_{438} ، i_{439} ، i_{440} ، i_{441} ، i_{442} ، i_{443} ، i_{444} ، i_{445} ، i_{446} ، i_{447} ، i_{448} ، i_{449} ، i_{450} ، i_{451} ، i_{452} ، i_{453} ، i_{454} ، i_{455} ، i_{456} ، i_{457} ، i_{458} ، i_{459} ، i_{460} ، i_{461} ، i_{462} ، i_{463} ، i_{464} ، i_{465} ، i_{466} ، i_{467} ، i_{468} ، i_{469} ، i_{470} ، i_{471} ، i_{472} ، i_{473} ، i_{474} ، i_{475} ، i_{476} ، i_{477} ، i_{478} ، i_{479} ، i_{480} ، i_{481} ، i_{482} ، i_{483} ، i_{484} ، i_{485} ، i_{486} ، i_{487} ، i_{488} ، i_{489} ، i_{490} ، i_{491} ، i_{492} ، i_{493} ، i_{494} ، i_{495} ، i_{496} ، i_{497} ، i_{498} ، i_{499} ، i_{500} ، i_{501} ، i_{502} ، i_{503} ، i_{504} ، i_{505} ، i_{506} ، i_{507} ، i_{508} ، i_{509} ، i_{510} ، i_{511} ، i_{512} ، i_{513} ، i_{514} ، i_{515} ، i_{516} ، i_{517} ، i_{518} ، i_{519} ، i_{520} ، i_{521} ، i_{522} ، i_{523} ، i_{524} ، i_{525} ، i_{526} ، i_{527} ، i_{528} ، i_{529} ، i_{530} ، i_{531} ، i_{532} ، i_{533} ، i_{534} ، i_{535} ، i_{536} ، i_{537} ، i_{538} ، i_{539} ، i_{540} ، i_{541} ، i_{542} ، i_{543} ، i_{544} ، i_{545} ، i_{546} ، i_{547} ، i_{548} ، i_{549} ، i_{550} ، i_{551} ، i_{552} ، i_{553} ، i_{554} ، i_{555} ، i_{556} ، i_{557} ، i_{558} ، i_{559} ، i_{560} ، i_{561} ، i_{562} ، i_{563} ، i_{564} ، i_{565} ، i_{566} ، i_{567} ، i_{568} ، i_{569} ، i_{570} ، i_{571} ، i_{572} ، i_{573} ، i_{574} ، i_{575} ، i_{576} ، i_{577} ، i_{578} ، i_{579} ، i_{580} ، i_{581} ، i_{582} ، i_{583} ، i_{584} ، i_{585} ، i_{586} ، i_{587} ، i_{588} ، i_{589} ، i_{590} ، i_{591} ، i_{592} ، i_{593} ، i_{594} ، i_{595} ، i_{596} ، i_{597} ، i_{598} ، i_{599} ، i_{600} ، i_{601} ، i_{602} ، i_{603} ، i_{604} ، i_{605} ، i_{606} ، i_{607} ، i_{608} ، i_{609} ، i_{610} ، i_{611} ، i_{612} ، i_{613} ، i_{614} ، i_{615} ، i_{616} ، i_{617} ، i_{618} ، i_{619} ، i_{620} ، i_{621} ، i_{622} ، i_{623} ، i_{624} ، i_{625} ، i_{626} ، i_{627} ، i_{628} ، i_{629} ، i_{630} ، i_{631} ، i_{632} ، i_{633} ، i_{634} ، i_{635} ، i_{636} ، i_{637} ، i_{638} ، i_{639} ، i_{640} ، i_{641} ، i_{642} ، i_{643} ، i_{644} ، i_{645} ، i_{646} ، i_{647} ، i_{648} ، i_{649} ، i_{650} ، i_{651} ، i_{652} ، i_{653} ، i_{654} ، i_{655} ، i_{656} ، i_{657} ، i_{658} ، i_{659} ، i_{660} ، i_{661} ، i_{662} ، i_{663} ، i_{664} ، i_{665} ، i_{666} ، i_{667} ، i_{668} ، i_{669} ، i_{670} ، i_{671} ، i_{672} ، i_{673} ، i_{674} ، i_{675} ، i_{676} ، i_{677} ، i_{678} ، i_{679} ، i_{680} ، i_{681} ، i_{682} ، i_{683} ، i_{684} ، i_{685} ، i_{686} ، i_{687} ، i_{688} ، i_{689} ، i_{690} ، i_{691} ، i_{692} ، i_{693} ، i_{694} ، i_{695} ، i_{696} ، i_{697} ، i_{698} ، i_{699} ، i_{700} ، i_{701} ، i_{702} ، i_{703} ، i_{704} ، i_{705} ، i_{706} ، i_{707} ، i_{708} ، i_{709} ، i_{710} ، i_{711} ، i_{712} ، i_{713} ، i_{714} ، i_{715} ، i_{716} ، i_{717} ، i_{718} ، i_{719} ، i_{720} ، i_{721} ، i_{722} ، i_{723} ، i_{724} ، i_{725} ، i_{726} ، i_{727} ، i_{728} ، i_{729} ، i_{730} ، i_{731} ، i_{732} ، i_{733} ، i_{734} ، i_{735} ، i_{736} ، i_{737} ، i_{738} ، i_{739} ، i_{740} ، i_{741} ، i_{742} ، i_{743} ، i_{744} ، i_{745} ، i_{746} ، i_{747} ، i_{748} ، i_{749} ، i_{750} ، i_{751} ، i_{752} ، i_{753} ، i_{754} ، i_{755} ، i_{756} ، i_{757} ، i_{758} ، i_{759} ، i_{760} ، i_{761} ، i_{762} ، i_{763} ، i_{764} ، i_{765} ، i_{766} ، i_{767} ، i_{768} ، i_{769} ، i_{770} ، i_{771} ، i_{772} ، i_{773} ، i_{774} ، i_{775} ، i_{776} ، i_{777} ، i_{778} ، i_{779} ، i_{780} ، i_{781} ، i_{782} ، i_{783} ، i_{784} ، i_{785} ، i_{786} ، i_{787} ، i_{788} ، i_{789} ، i_{790} ، i_{791} ، i_{792} ، i_{793} ، i_{794} ، i_{795} ، i_{796} ، i_{797} ، i_{798} ، i_{799} ، i_{800} ، i_{801} ، i_{802} ، i_{803} ، i_{804} ، i_{805} ، i_{806} ، i_{807} ، i_{808} ، i_{809} ، i_{810} ، i_{811} ، i_{812} ، i_{813} ، i_{814} ، i_{815} ، i_{816} ، i_{817} ، i_{818} ، i_{819} ، i_{820} ، i_{821} ، i_{822} ، i_{823} ، i_{824} ، i_{825} ، i_{826} ، i_{827} ، i_{828} ، i_{829} ، i_{830} ، i_{831} ، i_{832} ، i_{833} ، i_{834} ، i_{835} ، i_{836} ، i_{837} ، i_{838} ، i_{839} ، i_{840} ، i_{841} ، i_{842} ، i_{843} ، i_{844} ، i_{845} ، i_{846} ، i_{847} ، i_{848} ، i_{849} ، i_{850} ، i_{851} ، i_{852} ، i_{853} ، i_{854} ، i_{855} ، i_{856} ، i_{857} ، i_{858} ، i_{859} ، i_{860} ، i_{861} ، i_{862} ، i_{863} ، i_{864} ، i_{865} ، i_{866} ، i_{867} ، i_{868} ، i_{869} ، i_{870} ، i_{871} ، i_{872} ، i_{873} ، i_{874} ، i_{875} ، i_{876} ، i_{877} ، i_{878} ، i_{879} ، i_{880} ، i_{881} ، i_{882} ، i_{883} ، i_{884} ، i_{885} ، i_{886} ، i_{887} ، i_{888} ، i_{889} ، i_{890} ، i_{891} ، i_{892} ، i_{893} ، i_{894} ، i_{895} ، i_{896} ، i_{897} ، i_{898} ، i_{899} ، i_{900} ، i_{901} ، i_{902} ، i_{903} ، i_{904} ، i_{905} ، i_{906} ، i_{907} ، i_{908} ، i_{909} ، i_{910} ، i_{911} ، i_{912} ، i_{913} ، i_{914} ، i_{915} ، i_{916} ، i_{917} ، i_{918} ، i_{919} ، i_{920} ، i_{921} ، i_{922} ، i_{923} ، i_{924} ، i_{925} ، i_{926} ، i_{927} ، i_{928} ، i_{929} ، i_{930} ، i_{931} ، i_{932} ، i_{933} ، i_{934} ، i_{935} ، i_{936} ، i_{937} ، i_{938} ، i_{939} ، i_{940} ، i_{941} ، i_{942} ، i_{943} ، i_{944} ، i_{945} ، i_{946} ، i_{947} ، i_{948} ، i_{949} ، i_{950} ، i_{951} ، i_{952} ، i_{953} ، i_{954} ، i_{955} ، i_{956} ، i_{957} ، i_{958} ، i_{959} ، i_{960} ، i_{961} ، i_{962} ، i_{963} ، i_{964} ، i_{965} ، i_{966} ، i_{967} ، i_{968} ، i_{969} ، i_{970} ، i_{971} ، i_{972} ، i_{973} ، i_{974} ، i_{975} ، i_{976} ، i_{977} ، i_{978} ، i_{979} ، i_{980} ، i_{981} ، i_{982} ، i_{983} ، i_{984} ، i_{985} ، i_{986} ، i_{987} ، i_{988} ، i_{989} ، i_{990} ، i_{991} ، i_{992} ، i_{993} ، i_{994} ، i_{995} ، i_{996} ، i_{997} ، i_{998} ، i_{999} ، i_{1000} ، i_{1001} ، i_{1002} ، i_{1003} ، i_{1004} ، i_{1005} ، i_{1006} ، i_{1007} ، i_{1008} ، i_{1009} ، i_{1010} ، i_{1011} ، i_{1012} ، i_{1013} ، i_{1014} ، i_{1015} ، i_{1016} ، i_{1017} ، i_{1018} ، i_{1019} ، i_{1020} ، i_{1021} ، i_{1022} ، i_{1023} ، i_{1024} ، i_{1025} ، i_{1026} ، i_{1027} ، i_{1028} ، i_{1029} ، i_{1030} ، i_{1031} ، i_{1032} ، i_{1033} ، i_{1034} ، i_{1035} ، i_{1036} ، i_{1037} ، i_{1038} ، i_{1039} ، i_{1040} ، i_{1041} ، i_{1042} ، i_{1043} ، i_{1044} ، i_{1045} ، i_{1046} ، i_{1047} ، i_{1048} ، i_{1049} ، i_{1050} ، i_{1051} ، i_{1052} ، i_{1053} ، i_{1054} ، i_{1055} ، i_{1056} ، i_{1057} ، i_{1058} ، i_{1059} ، i_{1060} ، i_{1061} ، i_{1062} ،

پیکسل اندازه گیری چندان آسان به نظر نمی رسد. به همین دلیل است که در مطالعه حاضر از روش دی گرو^۱ و همکاران استفاده شده است. باتوجه به این روش، بدیهی است که پیکسل انتخاب شده باید داغ ترین، نزدیک ترین و خشک ترین پیکسل باشد. این فرض در معادله ۱۰ نشان داده شده است.

$$T_{b,max} = T_b(w = 0) \approx T_b(\min(w)) \quad (10)$$

باتوجه به معادله (۱) با کاهش سهم آب از یک پیکسل دمای روشنایی افزایش می یابد؛ زیرا ضریب انتشار مناطق خشک بیشتر از ضریب انتشار مناطق مرطوب است؛ بنابراین طبق معادله (۲) خشک ترین پیکسل، داغ ترین پیکسل نیز است پس این پیکسل به عنوان پیکسل کالیبراسیون انتخاب می شود.

$$T_{b,c} = \max(T_b) \quad (11)$$

طبق مطالعات *De Groeve* و همکاران به دلیل دقت کم یک پیکسل به عنوان داغ ترین پیکسل برای جلوگیری از مشکلات غیرمنتظره یک صفحه پیکسل 9×9 به جای در نظر گرفتن مقدار یک پیکسل به عنوان داغ ترین پیکسل در اطراف هر پیکسل اندازه گیری در نظر گرفته شده و ۹۵ درصد دمای روشنایی آن ها به عنوان دمای روشنایی پیکسل کالیبراسیون برای استفاده در معادله (۴) در روش اندازه گیری سیگنال ماهواره در نظر گرفته شد.

تحقیق حاضر به جای پیش بینی دبی آینده رودخانه ها، بر روی پیش بینی سیگنال های ماهواره ای با استفاده از اطلاعات گذشته خود متمرکز است. این تحقیق بر اساس سیگنال های ماهواره ای، تغییرات دبی رودخانه مارون را با روش زنجیره مارکوف استاندارد (MC) که توسط نویسندگان این تحقیق توسعه داده شده پیش بینی می کند و نتایج را با خروجی مدل های مبتنی بر هوش مصنوعی مقایسه می نماید. برای انتخاب بهترین مدل از شاخص های آماری *RMSE*، *NRMSE*، *NASH* و *R* استفاده شد که در معادلات (۱۲) تا (۱۵) نشان داده شده اند. در نهایت برای اطمینان از انتخاب درست مدل برتر از دیاگرام تیلور استفاده شد. این دیاگرام بر اساس سه شاخص انحراف معیار، ضریب همبستگی و مقدار *RMSE* بهترین مدل که دارای کمترین خطای شبیه سازی است را معرفی می کند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i^{obs} - X_i^{sim})^2} \quad (12)$$

$$NRMSE = \frac{RMSE}{(X_{Max}^{obs} - X_{Min}^{obs})} \quad (13)$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^n (X_i^{obs} - X_i^{sim})^2}{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})^2} \right] \quad (14)$$

$$R = \left(\frac{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})(X_i^{sim} - X_{Mean}^{sim})}{\sqrt{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})^2 \sum_{i=1}^n (X_i^{sim} - X_{Mean}^{sim})^2}} \right) \quad (15)$$

¹ De Groeve

در روابط فوق X_i^{obs} داده مشاهده ای، X_i^{sim} داده شبیه سازی شده، X_{Mean}^{sim} و X_{Mean}^{obs} به ترتیب میانگین داده‌های مشاهده شده و شبیه‌سازی شده، و n تعداد کل مشاهدات است.

۵. ماشین آموزش نیرومند^۱

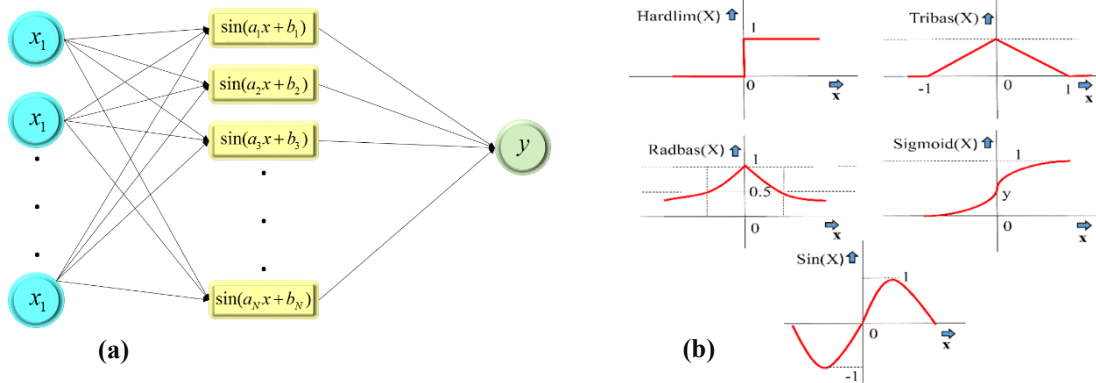
ماشین آموزش نیرومند (ELM) یک شبکه عصبی پیشخور^۲ تک‌لایه بوده و توسط هوانگ^۳ و همکاران (۲۰۰۴، ۲۰۰۶) ارائه شده است. ELM وزن‌های ورودی را به صورت تصادفی و وزن‌های خروجی را به صورت تحلیلی^۴ تعیین می‌کند. ساختار کلی این الگوریتم در شکل (۳. الف) ارائه شده است. تنها تفاوت ELM با شبکه عصبی پیشخور تک‌لایه^۵ (SLFFNN)، 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 تک‌لایه با تعداد n گره مخفی، به صورت زیر بیان می‌شود:

$$f_n(x) = \sum_{i=1}^n B_i G(a_i, b_i, x) \quad (16)$$

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

$$G(a_i, b_i, x) = G(a_i x + b_i) \quad (17)$$

از توابع فعال‌سازی به منظور محاسبه خروجی پاسخ نرون‌ها استفاده می‌شود. زمانی که مجموعه‌ای از سیگنال ورودی وزن‌دار اعمال می‌شود، برای به‌دست‌آوردن پاسخ از توابع فعال‌سازی استفاده می‌شود (پندی^۹ و گوویند^{۱۰} ۲۰۱۶). توابع فعال‌سازی غیرخطی ELM که در این مطالعه مورد بررسی قرار گرفته است شامل تابع پله‌ای (*hardlim*)، سیگموئید^{۱۱} (*sig*)، سینوسی (*sin*)، بایاس مثلثی (*tribas*) و بایاس شعاعی (*radbas*) است که به صورت شکل ۳.ب تعریف می‌شوند.



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

¹ Extreme Learning Machine (ELM)

² Feed-forward

³ Huang

⁴ Analytical

⁵ Single layer feed forward neural network

⁶ Bias

⁷ Piecewise continuous function

⁸ Additive

⁹ Pandey

¹⁰ Govind

¹¹ Sigmoid

فعال سازی نرون های 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 می شود:

$$H_{jk} = g(\sum(w_{ji}X_{ik}) + B_j) \quad (18)$$

که $g(.)$ می تواند هر تابع فعال سازی 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 فعال سازی j امین نرون لایه مخفی برای k امین نمونه آموزشی است به طوری که فعال سازی همه نرون های لایه مخفی برای نمونه های مورد استفاده در آموزش توسط این ماتریس ارائه می شود. در این ماتریس j ستون و k ردیف است. ماتریس H به عنوان ماتریس لایه مخفی خروجی شبکه عصبی بیان می شود. وزن های بین نرون های لایه مخفی و خروجی با استفاده از برازش حداقل مربعات برای مقادیر هدف در حالت آموزش در برابر خروجی های نرون های لایه مخفی برای هر نمونه آموزشی، بکار برده می شود که معادل ریاضی آن را می توان به شکل زیر بیان کرد:

$$H\beta = T \quad (19)$$

$$\beta = (\beta_1, \dots, \beta_j)_{j \times 1} \quad (20)$$

که β نشان دهنده وزن بین نرون لایه خروجی و نرون های لایه مخفی است و T بردار نشان دهنده مقادیر هدف برای نمونه های آموزش است که به صورت معادله (۲۱) بیان می شود:

$$T = (T_1, \dots, T_K)_{K \times 1} \quad (21)$$

نهایتاً وزن ها را می توان از معادله (۲۲) محاسبه کرد:

$$\beta = H^T T \quad (22)$$

که در آن:

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_L) \\ \vdots & \ddots & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (23)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad \text{and} \quad T = \begin{bmatrix} T_1^T \\ \vdots \\ T_L^T \end{bmatrix}_{L \times m} \quad (24)$$

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 نرون های لایه های مخفی و لایه پنهان و H' شبه معکوس $Moore-Penrose$ ماتریس H است. T بردار بین وزن های نمونه های آموزشی است. با توجه به توضیحات ارائه شده می توان گفت که آموزش ELM شامل دو مرحله است: مرحله اول، اختصاص تصادفی وزن ها و بایاس ها به نرون های لایه پنهان و محاسبه خروجی لایه پنهان ماتریس H و مرحله دوم، محاسبه وزن های خروجی با استفاده از شبه معکوس $Moore-Penrose$ ماتریس H و مقادیر هدف برای نمونه های آموزشی مختلف. روند آموزش جهت پیدا کردن ماتریس لایه پنهان (H)، سریع است به طوری که از سرعت بالاتری نسبت به الگوریتم های مبتنی بر تکرار رایج مانند لونیبرگ-مارکوآردت^۱ که در آن هیچ نوع روالی از بهینه سازی غیرخطی را در بر نمی گیرد، برخوردار است؛ بنابراین زمان آموزش شبکه به طور قابل توجهی کاهش می یابد (هوآنگ، ۲۰۰۶).

¹ Levenberg-Marquardt

۶. آموزش نیرومند با داده‌های پرت^۱

به منظور مدل‌سازی با استفاده از مدل‌های مبتنی بر هوش مصنوعی همیشه داده‌های به صورت outlier وجود دارند و به دلیل اینکه عموماً وجود چنین نمونه‌هایی در بسیاری از موارد به طبیعت موجود در مسئله برمی‌گردد، امکان حذف آنها وجود ندارد؛ بنابراین، درصدی از کل خطای آموزش (e) را شامل می‌شود. به منظور برخورد با چنین داده‌هایی، وجود outliers با sparsity تعریف می‌شود. ژانگ^۲ و لو^۳ (۲۰۱۵) با دانش اینکه استفاده از l_0 -norm sparsity را نسبت به l_2 -norm بهتر منعکس می‌کند، جهت محاسبه ماتریس وزن خروجی (β)، به جای استفاده از l_2 -norm، خطای آموزش (e) را به گونه‌ای در نظر می‌گیرند که sparse باشد.

$$\min_{\beta} C \|e\|_0 + \|\beta\|_2^2 \text{ subject to } y - H\beta = e \quad (25)$$

$$\beta = [\beta_1, \dots, \beta_N]^T$$

(β)، ماتریس وزن‌های خروجی است (W_0 یا همان W_{output} است).

(یا در برخی منابع به این شکل نوشته می‌شود (W_0) ماتریس وزن‌های خروجی است):

$$\min_{w_0} C \|e\|_0 + \|w_0\|_2^2 \text{ subject to } T - Hw_0$$

رابطه فوق یک مسئله برنامه‌نویسی غیرمحدب^۴ است. یکی از ساده‌ترین راه‌ها جهت حل این مسئله، نوشتن آن به صورت یک مسئله محدب قابل کنترل بدون از بین رفتن ویژگی پراکندگی^۵ است. ترم پراکنده یا sparse با استفاده از l_1 -norm به دست می‌آید. جای‌گذاری l_0 -norm با l_1 -norm، نه تنها منجر به حداقل‌سازی تحدب^۶ (کم شدن تابع خطا) می‌شود بلکه وجود مشخصات پراکندگی یا وجود وقایع حدی (داده‌های نادر) را نیز تضمین می‌کند.

$$\min_{\beta} \|e\|_1 + \frac{1}{c} \|\beta\|_2^2 \text{ subject to } y - H\beta = e \quad (26)$$

رابطه فوق یک مسئله بهینه‌سازی محدب مقید^۷ است به طوری که به طور کامل دامنه مناسب رویکرد تکمیل شده ضرب لاگرانژی^۸ را تطبیق می‌کند.

$$L_{\mu}(e, \beta, \lambda) = \|e\|_1 + \frac{1}{c} \|\beta\|_2^2 + \lambda^2 (y - H\beta - e) + \frac{\mu}{2} \|y - H\beta - e\|_2^2 \quad (27)$$

که $\mu = 2N/\|y\|_1$ (یانگ^۹ و ژانگ^{۱۰}، ۲۰۱۱) بر پارامتر جریمه^{۱۱} دلالت دارد و $\lambda \in R^n$ بردار ضرب لاگرانژی است.

جواب بهینه (e, β) و بردار ضرب لاگرانژی (λ) با استفاده از حداقل‌سازی تابع زیر طی فرایند تکراری، به دست می‌آید.

$$\begin{cases} (e_{k+1}, \beta_{k+1}) = \arg \min_{e, \beta} L_{\mu}(e, \beta, \lambda) & (a) \\ \lambda_{k+1} = \lambda_k + \mu(y - H\beta_{k+1} - e_{k+1}) & (b) \end{cases} \quad (28)$$

۷. مدل‌های هیبرید ICA-ANN و GA-ANN

یکی از ساده‌ترین و کارآمدترین روش‌های پیشنهادی برای استفاده در طراحی شبکه‌های عصبی، مدل (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،

¹ Outlier Robust Extreme Learning Machine (GMDH)

² Zhang

³ Luo

⁴ Non-convex programming

⁵ Tractable convex relaxation form without loss of the sparsity characteristic

⁶ Minimization convex

⁷ Constrained convex

⁸ Augmented Lagrangian (AL) multiplier

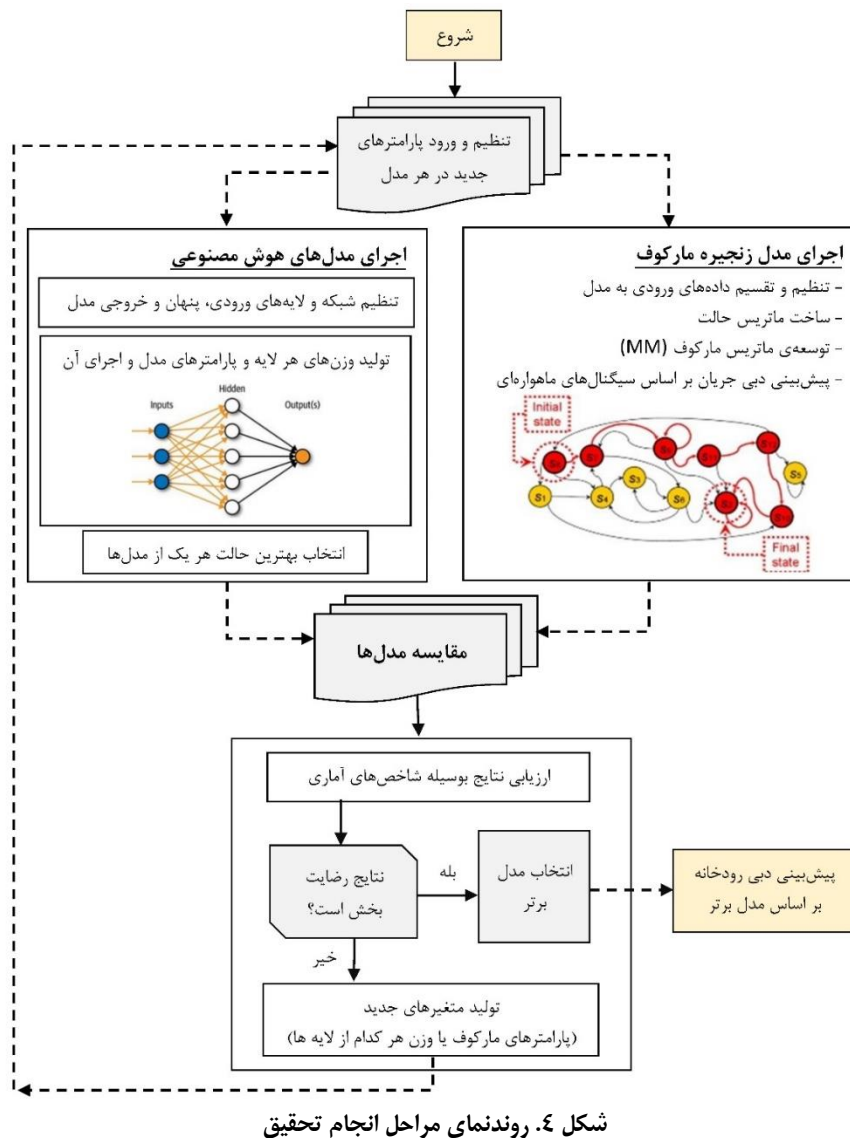
⁹ Yang

¹⁰ Zhang

¹¹ Penalty

تمام نرون‌های یک‌لایه به تمام نرون‌های لایه بعد متصل هستند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می‌دهد. برخلاف شبکه‌های عصبی پرسپترون تک‌لایه، 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، به n عدد مجموعه وزن‌ها (W_1, W_2, \dots, W_n) نیاز است 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 $MILP$ با الگوریتم بهینه‌سازی در قالب یک مدل هیبرید است. در این تحقیق از دو مدل هیبرید $GA-ANN$ و $ICA-ANN$ 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. در هر یک از این مدل‌ها ۸۰ درصد از داده‌های موجود به صورت تصادفی به عنوان داده‌های مرحله آموزش در نظر گرفته شد و داده‌های باقیمانده (۲۰ درصد) به عنوان داده‌های مرحله آزمون بکار گرفته شد.

برای درک بهتر روش تحقیق، مراحل انجام کار به صورت یک روندنما در شکل (۴) نشان داده شده است.



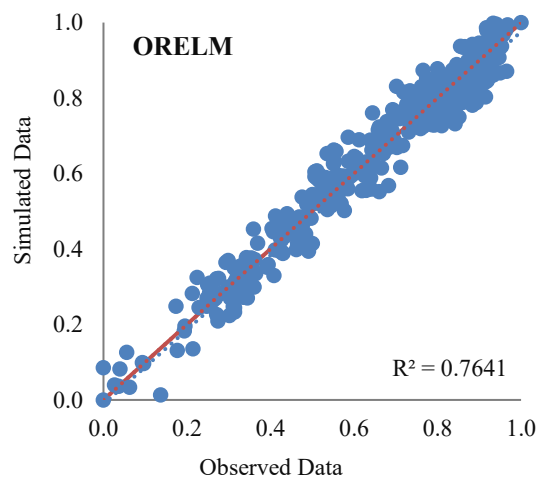

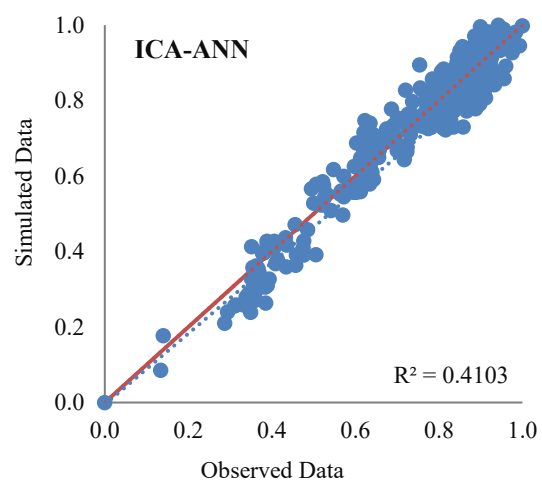
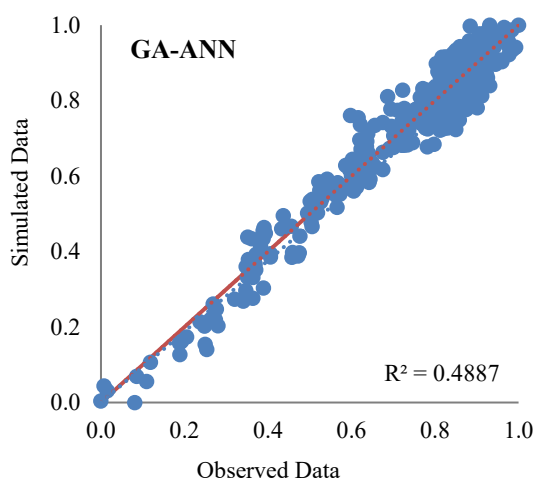
یافته‌های پژوهش

۱. پیش‌بینی دبی رودخانه بر اساس مدل‌های هوش مصنوعی و سیگنال‌های ماهواره‌ای

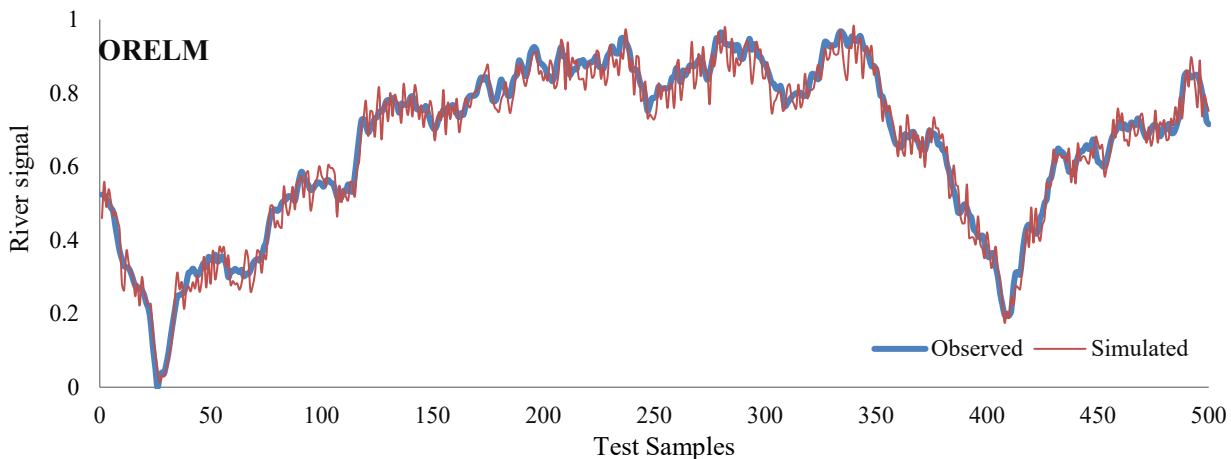
بهترین نتایج حاصل از اجرای هر کدام از این مدل‌ها در جدول (۱) ارائه شده است. بر اساس این جدول مدل ORELM باتوجه به تمامی شاخص‌ها دارای دقت بیشتری نسبت به سایر مدل‌ها در مراحل train و test می‌باشد. پس از آن مدل MC در رده دوم از نظر دقت پیش‌بینی قرار دارد. شکل (۵) پراکندگی نقاط در اطراف خط $Y=X$ و مقدار مجذور ضریب همبستگی برای انتخاب بهترین مدل هوش مصنوعی در مرحله تست مدل‌سازی برای هر یک از مدل‌های MC, ICA-ANN, GA-ANN و ORELM نشان می‌دهد. پراکنش منظم‌تر و نزدیک‌تر نقاط در اطراف خط $Y=X$ در مدل ORELM نیز حاکی از دقت بیشتر این مدل در مقایسه با سایر مدل‌ها است. براین اساس سری زمانی مقادیر پیش‌بینی شده دبی رودخانه مارون بر اساس مدل برتر (ORELM) در مقایسه با داده‌های مشاهده‌ای در مرحله تست در شکل (۶) نشان داده شده است.

جدول ۱. ارزیابی عملکرد مدل های *GA-ANN*، *JCA-ANN*، *MC* و *ORELM* در پیش بینی دبی رودخانه بر اساس سیگنال های ماهواره ای با استفاده از شاخص های آماری در مراحل *train* و *test*

Model Type	Input combination		Terrain				Test		
	Signal Data	RM SE	NR MSE	NA SH	R	RM SE	NR MSE	NA SH	R
GA-ANN	t-1	0.6966	0.0566	0.7748	0.7880	0.5984	0.0563	0.6874	0.6991
JCA-ANN	t-1	0.6178	0.0502	0.7799	0.7898	0.6185	0.0582	0.6325	0.6405
MC	t-1	0.1580	0.0128	0.8488	0.8495	0.1000	0.0260	0.8211	0.8218
ORELM	t-1	0.1333	0.0108	0.8891	0.8899	0.0623	0.0162	0.8733	0.8741



شکل ۵. پراکندگی نقاط در اطراف خط $Y=X$ و مقدار مجذور ضریب همبستگی برای انتخاب بهترین مدل در مرحله تست مدل سازی




شکل ۶. سری زمانی مقادیر پیش‌بینی شده دبی رودخانه بر اساس مدل برتر (ORELM) در مقایسه با داده‌های مشاهده‌ای در مرحله تست

۲. انتخاب مدل برتر بر اساس دیاگرام تیلور

برای اطمینان از انتخاب درست مدل برتر از دیاگرام تیلور استفاده شد. شکل ۷ نمودار تیلور (تیلور، ۲۰۰۱) برای انتخاب روش برتر بین روش‌های GA-ANN، ICA-ANN، MC و ORELM برای پیش‌بینی دبی رودخانه بر اساس سیگنال‌های ماهواره‌ای را نشان می‌دهد. فاصله نقاط ایجاد شده برای هر روش از نقطه مشاهده شده برابر است با RMSE در مرکز؛ بنابراین، مدلی که با مقادیر مشاهده‌شده سازگار است، مجموعه‌ای از مقادیر شبیه‌سازی شده است که دارای ضریب تعیین ۱ و دارای انحراف معیار مشابه با مقادیر مشاهده شده هستند (زین‌الدین و همکاران، ۲۰۱۸). در این دیاگرام نقطه A نشان‌دهنده داده‌های مشاهده‌ای دبی رودخانه و نتایج ارزیابی مدل‌های فوق به ترتیب با نقاط B، C، D و E نشان داده شده‌اند. این نمودار با استفاده از شاخص‌های ضریب همبستگی و انحراف معیار، صحت روش‌های مختلف را ارزیابی می‌کند. این شکل عملکرد روش‌های GA-ANN، MC، ICA-ANN و ORELM را با روش پیشنهادی برای ارزیابی صحت پیش‌بینی‌های انجام شده مقایسه می‌کند. فاصله هر نقطه ایجاد شده برای مدل‌های مختلف (B، C، D، E) از نقطه مشاهده شده (A) به‌عنوان یک مرجع مقایسه در نظر گرفته می‌شود؛ بنابراین، یک مدل سازگار با مقادیر مشاهده شده، مجموعه‌ای از نقاطی است که ضریب همبستگی نزدیک به ۱ دارند و انحراف استاندارد مشابهی با مقادیر مشاهده شده دارند (زین‌الدین و همکاران، ۲۰۱۸). نتایج حاصل از ارزیابی روش‌ها با استفاده از دیاگرام تیلور نشان می‌دهد روش‌های GA-ANN، ICA-ANN و MC (نقاط B، C، D) دقت کمتری در پیش‌بینی دبی رودخانه بر اساس سیگنال‌های ماهواره‌ای دارند، درحالی‌که روش ORELM (نقطه E) تفاوت نسبتاً کمی با مقادیر مشاهده شده دارد؛ بنابراین نزدیک‌ترین نقطه به نقطه مرجع مربوط به روش ORELM (نقطه E) می‌باشد؛ لذا براین اساس روش ORELM دقت بالاتری نسبت به سایر روش‌ها برای پیش‌بینی دبی رودخانه دارد.

نتایج حاصل از کاربرد مدل هوش مصنوعی ORELM نشان می‌دهد این روش توانسته است در دوره آماری منتخب با کمترین میزان خطا دبی ورودی به مخزن سد مارون را پیش‌بینی نماید. به‌طوری‌که مقدار RMSE در این روش در مرحله test حدود ۰/۰۶۲ بود که نسبت به سایر مدل‌ها کمترین بود. نتایج نشان می‌دهد مدل ORELM بدون نیاز به اطلاعات و داده‌های فراوان و بدون بهره‌گیری از فرایندهای پیچیده مدل‌سازی بر اساس معادلات حاکم و با صرف زمان بسیار کمتر دبی رودخانه را بر اساس سیگنال‌های ماهواره‌ای به درستی و با دقت زیاد پیش‌بینی نماید.



شکل ۷. نمودار گرافیکی تیلور برای انتخاب بهترین مدل هوش مصنوعی در مرحله تست مدل سازی

بحث

در این مطالعه از روش‌های مبتنی بر شبکه‌های عصبی مصنوعی برای پیش‌بینی سری زمانی جریان رودخانه بر اساس سیگنال‌های ماهواره‌ای در مقایسه با روش زنجیره مارکوف معمولی استفاده شده است تا بتوان قابلیت جایگزینی این روش‌ها با مدل‌های پیچیده و همچنین استفاده از اطلاعات ماهواره‌ای بجای داده‌های گران‌قیمت زمینی را بررسی کرد. این امر برای جایی که شرایط مطلوب برای به‌کارگیری مدل‌های عددی پیچیده برقرار نیست و یا اینکه اطلاعات کافی زمینی در دست نیست بسیار حائز اهمیت است. طوری که بتوان بر اساس تعداد ورودی‌های بسیار اندک و سیگنال‌های ماهواره‌ای، دبی رودخانه‌ها را با دقت زیاد پیش‌بینی نمود. با توجه به اهداف این تحقیق در تمامی روش‌های هوش مصنوعی و روش زنجیره مارکوف از سیگنال‌های ماهواره‌ای در روزهای قبل به‌عنوان داده‌های ورودی به مدل استفاده شد. خروجی مدل نیز داده‌های مشاهداتی ثبت شده در ایستگاه هیدرومتری در نزدیکی ورودی به سد مارون در ماه حاضر (t) است که بر اساس داده‌برداری زمینی استخراج شده است. برای پیش‌بینی جریان ورودی به مخزن سد مارون، عملکرد این مدل‌ها بر اساس شاخص‌های RMSE، NRMSE، NASH و R مورد ارزیابی قرار گرفت.

نتیجه‌گیری

امکان پیش‌بینی دبی رودخانه مارون در محل ورودی به سد بر اساس حجم اطلاعات بسیار کم نسبت به مدل‌های عددی و تنها با استفاده از سیگنال‌های ماهواره‌ای یکی از مهم‌ترین دستاوردهای این تحقیق است. در این حالت بدون نیاز به پارامترهای هواشناسی، خاک، زمین‌شناسی، اطلاعات توپوگرافی و شیب حوضه، پوشش گیاهی، اطلاعات برداشت آب از رودخانه‌ها، داده‌های اندرکنش آب سطحی و زیرزمینی و بدون نیاز به نقشه‌ها و نرم‌افزارهای پیچیده و بدون صرف زمان و هزینه زیاد برای کالیبراسیون و صحت‌سنجی مدل‌های ریاضی، دبی رودخانه بر اساس روش‌های هوش مصنوعی و سیگنال‌های ماهواره‌ای پیش‌بینی می‌گردد. این امر کمک بزرگی به متخصصین بخش منابع آب در حوضه‌های فاقد آمار یا حوضه‌هایی که فاقد اطلاعات پایه‌ای و نقشه‌های دقیق بوده و یا مناطقی که با نقص آمار گسترده 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 جریان ورودی به مخازن سدها در سال‌های

خشک و تر به دست می‌آید. ارزیابی عملکرد مدل‌های هوش مصنوعی (ORELM و MC ICA-ANN, GA-ANN) در رودخانه مارون نشان داد این مدل‌ها دقت بسیار خوبی در پیش‌بینی نوسانات دبی رودخانه بر اساس سیگنال‌های ماهواره‌ای دارند. از بین این مدل‌ها، مدل ORELM با مقدار RMSE در حدود ۰/۱۳۳ و ۰/۰۶۲ در دو مرحله train و test دارای بیشترین دقت بود. دیاگرام تیلور نیز با بهره‌گیری از معیارهای خطای بیشتر این نتیجه را تأیید کرد تا مدل ORELM با اطمینان زیاد به‌عنوان بهترین مدل هوش مصنوعی برای پیش‌بینی دبی رودخانه در محل ورودی به مخزن سد مارون معرفی گردد. با توجه به اهمیت آگاهی از مقدار جریان ورودی به مخازن سدها به‌عنوان یکی از مهم‌ترین پارامترهای بیلان 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 با به‌کارگیری اطلاعات ماهواره‌ای توصیه نمود. بر اساس نتایج به‌دست آمده می‌توان مدل‌های توسعه داده شده در این تحقیق را برای سایر مناطق مطالعاتی با رویکرد بهره‌برداری از سد و رودخانه نیز پیشنهاد داد. در این صورت بدون نیاز به روابط و معادلات پیچیده و زمان‌بر و تنها بر اساس سیگنال‌های ماهواره‌ای و با هزینه بسیار کم می‌توان دبی رودخانه را در منطقه مورد مطالعه در دوره‌های خشک و تر با دقت زیاد پیش‌بینی نمود.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت نموده‌اند و این موضوع مورد تأیید همه آنهاست. سامانه آبیاری قطره‌ای سطحی با جریان پیوسته به کار گرفته شوند.

تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.

References

- Aman Jalili, A., Najarchi, M., Shabanlou, S., & Jafarinia, R. (2023) Multiobjective optimization of water resources in real time based on integration of NSGA-II and support vector machines. *Environ Sci Pollut Res*, 30,16464–16475. <https://doi.org/10.1007/s11356-022-22723-4>
- 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 Sci Inform*, 16, 3227–3241. <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>
- 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. <https://doi.org/10.1002/ird.2794>
- Bayesteh, M., & Azari, A. (2021). Stochastic Optimization of Reservoir Operation by Applying Hedging Rules. *Journal of Water Resources. Planning. And Management*, 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)
- 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., Yosefvand, F., & IzadBakhsh, M.A. (2023). Effects of climate change on groundwater level variations affected by uncertainty (case study: Razan aquifer). *Appl Water Sci*, 13(143), 1-16. <https://doi.org/10.1007/s13201-023-01949-8>
- 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. <http://dx.doi.org/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>
- Huang, G. B., & Siew, C. K. (2004). Extreme learning machine: RBF network case. *Proceedings of the Eighth International Conference on Control, Automation, Robotics and Vision (ICARCV 2004)*, Kunming, China. <http://dx.doi.org/10.1109/ICARCV.2004.1468985>
- 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>
- 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>
- Irawan, D., Puradimaja, D., & Silaen, H. (2011). Hydrodynamic Relationshipbetween ManMade Lake and Surrounding Aquifer, Cimahi, Banduge, Indonesia. *Journal of World Academy of Science, Engineering and Technology*, 58, 100-103. <http://dx.doi.org/10.13140/2.1.1711.3284>

- Ivkovic, K. M. (2009). A top-down approach to characterise aquifer-river interaction processes. *Journal of Hydrology*, 365, 145–155. <https://doi.org/10.1016/j.jhydrol.2008.11.021>
- Jalilian, A., Heydari, M., Azari, A., & Shabanlou, S. (2022). Extracting optimal rule curve of dam reservoir base on stochastic inflow. *Water Resour Manage*, 36, 1763–1782. <https://doi.org/10.1007/s11269-022-03087-3>
- Klove, B., Ala-Aho, P., Bertrand, G., Gurdak, J. J., Kupfersberger, H., Kværner, J., & PulidoVelazquez, M. (2014). Climate change impacts on groundwater and dependent ecosystems. *Journal of Hydrology*, 518, 250–266. <https://doi.org/10.1016/j.jhydrol.2013.06.037>
- Lachaal, F., Mlayah, A., Bedir, M., Tarhouni, J., & Leduc, Ch. (2012). Implementation of a 3-D and GIS tools: The Zeramidine-Beni Hassen Mioceneaquifer system (east-central Tunisia). *Journal of Computers & Geosciences*, 48, 187-198. <https://doi.org/10.1016/j.cageo.2012.05.007>
- 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., & Ekhlasmad, 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., & Ekhlasmad, 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. <http://dx.doi.org/10.1016/j.gsd.2023.101062>
- 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>
- 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. *J Hydroinf*, 24(4), 875–897. <https://doi.org/10.2166/hydro.2022.022>
- Panda, D.K., Mishra, A., Kumar, A., (2012). Quantification of trends in groundwater levels of Gujarat in western India. *Hydrological Sciences Journal*, 57 (7), 1325–1336. <https://doi.org/10.1080/02626667.2012.705845>
- Pandey, P., & Govind, R. (2016). Analysis of Randomized Performance of Bias Parameters and Activation Function of Extreme Learning Machine. *International Journal of Computer Applications*, 135(1), 23-28. <https://doi.org/10.5120/ijca2016908274>
- Ramírez-Hernández, J., Hinojosa-Huerta, O., Peregrina-Llanes, M., Calvo-Fonseca, A., & Carrera-Villa, E. (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://ui.adsabs.harvard.edu/link_gateway/2013EcEng..59...93R/doi:10.1016/j.ecoleng.2013.02.016
- Rayegani, F., Onwubolu, G. C., (2014). Fused deposition modelling (FDM) process parameter prediction and optimization using group method for data handling (GMDH) and differential evolution (DE). *The International Journal of Advanced Manufacturing Technology*, 73, 509-519. <https://doi.org/10.1007/s00170-014-5835-2>
- 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://dx.doi.org/10.1016/j.envsci.2016.03.010>
- 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>
- Taylor, K.E. (2001). Summarizing multiple aspects of model performance in a single diagram. *J. Geophys. Res. Atmos.* 106, 7183–7192. <https://doi.org/10.1029/2000JD900719>
- Todd, W.R., & Kenneth, R.B. (2001). Report: Delineation of capture zones for municipal wells in fractured dolomite. Sturgeon Bay, Wisconsin, USA. *Hydrogeology Journal*, 9, 432–450. <http://dx.doi.org/10.1007/s100400100154>
- 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>
- Yang, J., & Zhang, Y. (2011). Alternating approximation algorithms for l1-problems in compress sensing. *SIAM J. Sci. Comput*, 33(1), 250-278. <https://doi.org/10.1137/090777761>
- Yanxun, S., Yuan, F., Hui, Q., & Xuedi, Zh. (2011). Research and Application of Groundwater Numerical Simulation-A Case Study in Balasu Water Source. *Procedia Environmental Sciences*, 8, 146-152. <http://dx.doi.org/10.1016/j.proenv.2011.10.024>
- Zampieri, M., Serpetzoglou, E., Anagnostou, E. N., Nikolopoulos, E. I. and Papadopoulos, A. 2012. Improving the representation of river–groundwater interactions in land surface modeling at the regional scale: Observational evidence and parameterization applied in the Community Land Model. *Journal of Hydrology*, 420(421), 72–86. <https://doi.org/10.1016/j.jhydrol.2011.11.041>
- 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. American Society of Civil Engineers. *J. Water Resour. Plann. Manage*, 146(5), 04020020. [http://dx.doi.org/10.1061/\(ASCE\)WR.1943-5452.0001189](http://dx.doi.org/10.1061/(ASCE)WR.1943-5452.0001189)
- Zeynoddin, M., Bonakdari, H., Azari, A., Ebtehaj, I., Gharabaghi, B., & Madavar, H.R. (2018). Novel hybrid linear stochastic with non-linear extreme learning machine methods for forecasting monthly rainfall a tropical climate. *Journal of environmental management*, 222, 190-206. <https://doi.org/10.1016/j.jenvman.2018.05.072>
- 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>