



AI application of the outlier-robust extreme learning machine (ORELM) model in river discharge prediction

Rosa Adibrad¹ , Bitakhosravinejad² , and Mohammad Hossein Adibrad³

1. Department of Computer Engineering, Razi University, Kermanshah, Iran. E-mail: r.adibrad@stu.razi.ac.ir

2. Department of Water Engineering, Razi University, Kermanshah, Iran. E-mail: bitakhosravinejad79@gmail.com

3. Corresponding author, Department of Civil Engineering, Razi University, Kermanshah, Iran. E-mail: m.adibrad@razi.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 11 December 2024

Received in revised form 03

February 2025

Accepted 15 March 2025

Available online 23 September 2025

Keywords:

river discharge prediction,

machine learning,

Pol Kohnneh,

ORELM.

ABSTRACT

Objective: This study focuses on evaluating the effectiveness of the Outlier-robust extreme learning machine (ORELM) model in predicting the discharge of the Qarasu River at the Pol Kohnneh hydrological station in Kermanshah.

Method: The study focuses on the Pol Kohnneh watershed along the Qarasu River, which originates from Sarab Ravansar, 50 kilometers northwest of Kermanshah. This study applies ELM to predict rainfall and river discharge using hydrological and meteorological data. ELM's ability to handle complex, nonlinear relationships makes it suitable for forecasting, especially in real-time applications. To improve accuracy, outlier removal is performed before training. The model efficiently predicts future discharge values, offering a scalable solution for water resource management and flood risk assessment.

Results: The RMSE values for a one-month lag (t-1) were recorded as 12.22 and 4.14 for the training and testing phases, respectively. The findings of this study highlight the potential of artificial intelligence-based models like ORELM in hydrological forecasting. Unlike traditional methods, these models require significantly less time and computational effort while delivering accurate predictions. By leveraging machine learning techniques, water resource managers can efficiently forecast river discharge trends, aiding in effective decision-making for flood management, irrigation planning, and water allocation during dry and wet periods.

Conclusions: The ability of ORELM to handle long-term discharge predictions with minimal input data makes it a valuable tool for hydrological studies, particularly in data-scarce regions where conventional models face limitations.

Cite this article: Adibrad, R., Khosravinejad, B., & Adibrad, M.H. (2025). AI application of the outlier-robust extreme learning machine (ORELM) model in river discharge prediction, *Advanced Technologies in Water Efficiency*, 5(3), 44-55. <https://doi.org/10.22126/atwe.2025.11918.1159>



© The Author(s)

<https://doi.org/10.22126/atwe.2025.11918.1159>

Publisher: Razi University.

Introduction

Accurate prediction of river discharge is crucial for the effective management of surface water resources, influencing areas such as domestic water supply, irrigation, hydropower generation, and environmental sustainability. River discharge forecasting can be categorized into short-term and long-term predictions, where short-term forecasts typically cover periods of less than a week, while long-term predictions extend over several months. Given the complexity and non-linearity of hydrological processes, traditional physical and conceptual models often face challenges in predicting river flow accurately, particularly in ungauged basins or regions with highly variable climatic conditions.

Recent advancements in artificial intelligence (AI) have introduced machine learning (ML) techniques as powerful alternatives to conventional hydrological models. AI-based approaches, such as backpropagation neural networks (BPNN), long short-term memory (LSTM), and extreme learning machines (ELM), have demonstrated significant improvements in discharge prediction. Hybrid models integrating optimization algorithms, signal decomposition methods, and preprocessing techniques have further enhanced accuracy, especially in regions with limited hydrological data.

Method Area

The study focuses on the Pol Kohnesh watershed along the Qarasu River, which originates from Sarab Ravansar, 50 kilometers northwest of Kermanshah. As it flows southeast, the river merges with several tributaries, including the Razavar and Meregh rivers, before passing through Kermanshah. Within the city, it converges with the Cham-Bashir and Abshuran rivers before eventually joining the Gamasiab River near Faraman. Hydrological data from the Pol Kohnesh station on the Qarasu River was used for this research.

ELM

Extreme Learning Machine (ELM) is a fast and efficient machine learning algorithm for classification and regression. Unlike traditional neural networks, it assigns random hidden layer weights and computes output weights analytically, avoiding iterative backpropagation. This study applies ELM to predict rainfall and river discharge using hydrological and meteorological data. ELM's ability to handle complex, nonlinear relationships makes it suitable for forecasting, especially in real-time applications. To improve accuracy, outlier removal is performed before training. The model efficiently predicts future discharge values, offering a scalable solution for water resource management and flood risk assessment.

Results

This study utilizes the ORELM method to predict river flow discharge and assess its potential as an alternative to complex models, especially in cases where numerical models are impractical or data is limited. The model uses past monthly discharge data ($t-1$, $t-2$, $t-3$) as inputs to forecast the current discharge at the Qarasou River's Pol-e Kohnesh station. Results show that the ORELM model with a one-step delay ($t-1$) achieves the highest accuracy during training and testing. The model's predictions closely align with observed data, demonstrating its effectiveness for river flow forecasting. The results of applying the ORELM artificial intelligence model indicate that this method successfully predicted river inflow with minimal error over a 65-year statistical period during both training and testing phases. The RMSE value for a one-month lag time ($t-1$) was 12.22 during training and 4.14 during testing. For lag times of 2 and 3 months, the RMSE in the testing phase was approximately 9.29 and 8, respectively.

These results demonstrate that the ORELM model can accurately predict river discharge without requiring extensive data or complex modeling processes based on governing equations.

Conclusions

One of the most significant achievements of this study is the ability to predict river discharge over a long-term period using minimal data compared to numerical models. This approach relies solely on past river flow data without requiring meteorological, soil, or geological parameters, cross-section information, complex mapping software, or extensive time and costs for model calibration and validation. This is particularly beneficial for water resource specialists working in data-scarce basins or rivers with incomplete records. By utilizing artificial intelligence models, valuable management insights can be obtained with minimal time and cost, allowing for accurate discharge predictions in both dry and wet years. The evaluation of the ORELM artificial intelligence model at the Qarasou River (Pol-e Kohnneh station) demonstrated its high accuracy in predicting river discharge. Over a 65-year statistical period, the model achieved minimal error in both training and testing phases. Specifically, the RMSE for a one-month delay ($t-1$) was 12.22 during training and 4.14 during testing. For delays of two and three months, the RMSE values were 9.29 and 8.00, respectively, indicating that the ORELM model can accurately predict river discharge without requiring extensive data or complex mathematical modeling. Empirical results show that the developed method outperforms traditional approaches based on various performance metrics. Thus, a new, practical evolutionary extreme learning machine model using swarm intelligence has been developed for complex hydrological forecasting tasks. However, applying the proposed method in practice may have limitations, as determining optimal neural network parameters is theoretically challenging, especially given the variations in hydrological characteristics across different locations. With the rapid advancement of computing technology, the effectiveness of the proposed method can be enhanced by introducing more efficient soft computing techniques or developing more robust optimization strategies. Additionally, integrating newly developed signal processing techniques could further improve its performance. Finally, the results confirmed that time delay is a crucial input feature that significantly affects the predictive accuracy of the model.

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 .

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.



فناوری های پیشرفته در بهره وری آب

کاربرد مدل هوش مصنوعی ماشین آموزش نیرومند با حذف داده پرت (ORELM) در پیش‌بینی دبی رودخانه

رزا ادیبراد^۱، بیتا خسروی نژاد^۲، و محمدحسین ادیبراد^۳✉

۱. گروه مهندسی کامپیوتر، دانشگاه رازی، کرمانشاه، ایران. رایانامه: r.adibrad@stu.razi.ac.ir

۲. گروه مهندسی آب، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران. رایانامه: bitakhosravinejad79@gmail.com

۳. نویسنده مسئول، گروه مهندسی عمران، دانشگاه رازی، کرمانشاه، ایران. رایانامه: m.adibrad@razi.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۳/۰۹/۲۱ تاریخ بازنگری: ۱۴۰۳/۱۱/۱۵ تاریخ پذیرش: ۱۴۰۳/۱۲/۲۵ تاریخ انتشار: ۱۴۰۴/۰۷/۰۱ کلیدواژه‌ها: پیش‌بینی دبی رودخانه، یادگیری ماشین، پل کهنه، ORELM	هدف: هدف از این تحقیق بررسی کارایی مدل ماشین آموزش نیرومند (ORELM) برای پیش‌بینی دبی رودخانه قره‌سو در محل ایستگاه پل کهنه (کرمانشاه) است. روش پژوهش: محدوده مورد مطالعه حوضه آبریز پل کهنه واقع بر رودخانه قره‌سو است. 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. جهت محاسبه ماتریس وزن خروجی، خطای آموزش را به گونه‌ای در نظر می‌گیرند که ماتریس sparse باشد. یافته‌ها: نتایج حاصل از کاربرد مدل هوش مصنوعی ORELM نشان می‌دهد این روش توانسته است در دوره آماری ۵ ساله با کمترین میزان خطا در مراحل آموزش و آزمایش دبی ورودی رودخانه را پیش‌بینی نماید. به طوری که مقدار RMSE در این روش در حلات تأخیر یک‌ماهه ($t-1$) در دو مرحله آموزش و آزمایش به ترتیب ۱۲/۲۲ و ۴/۱۴ بود. لذا با استفاده از مدل‌های هوش مصنوعی با صرف زمان و هزینه بسیار کم اطلاعات مدیریتی بسیار ارزشمندی در خصوص پیش‌بینی دبی جریان رودخانه در سال‌های خشک و تر به دست می‌آید. نتیجه‌گیری: نتایج تجربی نشان می‌دهد که روش توسعه یافته باتوجه به شاخص‌های مختلف ارزیابی عملکرد نسبت به روش‌های سنتی برتری دارد؛ بنابراین، یک مدل ماشین یادگیری افراطی تکاملی جدید و عملی با استفاده از هوش ازدحامی برای انجام کار پیچیده پیش‌بینی هیدرولوژیکی توسعه داده شده است. نوآوری این تحقیق عبارت است از توسعه مدل هوش مصنوعی ORELM با قابلیت حذف داده‌های پرت برای پیش‌بینی دبی رودخانه بر اساس کمترین اطلاعات ورودی بدون نیاز به مدل‌های پیچیده در کمترین زمان است.

استناد: ادیبراد، رزا؛ خسروی نژاد، بیتا؛ و ادیبراد، محمدحسین. (۱۴۰۴). کاربرد مدل هوش مصنوعی ماشین آموزش نیرومند با حذف داده پرت (ORELM) در

پیش‌بینی دبی رودخانه. *فناوری های پیشرفته در بهره وری آب*، ۵ (۳)، ۴۴-۵۵.

<https://doi.org/10.22126/atwe.2025.11918.1159>



مقدمه

مدیریت علمی منابع آب‌های سطحی نیازمند پیش‌بینی و تخمین دقیق دبی جریان رودخانه‌ها در آینده است. پیش‌بینی دبی جریان را می‌توان در دو دسته کلی شامل پیش‌بینی کوتاه‌مدت و پیش‌بینی بلندمدت تقسیم نمود. در پیش‌بینی‌های کوتاه مدت معمولاً افق زمانی پیش‌بینی را کمتر از هفت روز در نظر می‌گیرند، در صورتی که در پیش‌بینی‌های بلند مدت این افق زمانی طولانی بوده و می‌تواند تا چندین ماه هم در نظر گرفته شود.

انجام پیش‌بینی دقیق و مطمئن جریان روزانه رودخانه با یک سیستم خبره از وظایف محوری مدیریت منابع آب است. چنین مدل قوی می‌تواند به عنوان یک ابزار مناسب توسط هیدرولوژیست ها برای ارزیابی پایداری موثر منابع آب از جمله استفاده از آن در تقاضای خانگی، آبیاری، برق آبی و کشاورزی مورد استفاده قرار گیرد. علاوه بر این، مدل‌های خبره برای برنامه ریزی کاربردهای آبی در حفاظت از محیط زیست و توسعه سیستم های تعادل آب مفید هستند. به طور کلی، ایجاد یک مدل پیش‌بینی دقیق برای انواع اقلیم‌های آبی و محیط‌های حوضه آبخیز بسیار مهم و در عین حال یک کار دشوار است. با این حال، کارایی پاسخ خروجی هر مدل به طور قابل توجهی بر اساس ویژگی‌های حوضه مدل سازی شده است. به عنوان مثال، مناطق اقلیمی گرمسیری تحت تأثیر بارندگی شدید موسمی (که گاه به گاه، متناوب و اغلب کاملاً غیرقابل پیش‌بینی هستند) هستند که می‌توانند تغییرات الگوهای جریان رودخانه را در مقایسه با حالت عادی آن بسیار پیچیده تر و غیرخطی تر کنند. از آنجایی که پیش‌بینی چنین رفتارهایی با مدل‌های فیزیکی یا هیدرولوژیکی که به شرایط اولیه دقیق نیاز دارند دشوار است، کاوش مدل‌های محاسباتی نرم همه کاره تر و پاسخ گو تر در این حوزه از نیاز، یک ماموریت مطلوب برای پیش‌بینی کنندگان هیدرولوژیکی باقی می‌ماند.

ادبیات موضوع و پیشینه پژوهش

اخیراً یک رویکرد یادگیری نسبتاً جدید پیشنهاد شده است، یعنی ماشین‌های یادگیری افراطی (هوانگ و همکاران^۱، ۲۰۰۶). مزیت اصلی این مدل در ویژگی نگاشت ویژگی داخلی آن بدون نیاز به تنظیم تکراری پارامترهای نورون پنهان است که برای مدل شبکه عصبی مصنوعی معمولی مورد نیاز است. در یک مدل ELM وزن نورون ورودی و پنهان به طور تصادفی از تعداد زیادی نورون از پیش تعیین شده بدون عبور از هر نورون در مدل محاسبه می‌شود. علاوه بر این، مدل ELM از مهارت تعمیم قابل قبولی برخوردار است و هزینه مصرف زمان کمتری بر اساس چندین برنامه کاربردی اجرا شده دارد (هوانگ و همکاران، ۲۰۱۵). و دعو و همکاران^۲، ۲۰۱۷). همچنین طی پنج سال گذشته مشاهده شده است که روند گسترده ای در اجرای مدل ELM با استفاده خاص در تجزیه و تحلیل متن مشاهده شده است: سیستم کنترل، طرح‌ها، مدل سازی و پیش‌بینی‌های سیستم، کاربردهای سنجش از دور، و چندین زمینه علوم و مهندسی (سالسدو سانز و همکاران^۳، ۲۰۱۴).

در مطالعه گرگانی و همکاران (۱۳۹۶) با استفاده از مدل DRASTIC و تحلیل سری زمانی، تأثیر کاهش بارندگی و سطح آب زیرزمینی را بر آسیب پذیری آب‌های زیرزمینی دشت ماهیدشت بررسی شد و پیش‌بینی‌ها نشان داد که تا سال ۲۰۳۲، به دلیل کاهش سطح آب و تغذیه، شاخص DRASTIC کاهش یافته و آسیب پذیری کمتر خواهد شد.

اخیراً، بررسی رویکرد ELM در مسائل عملی مربوط به هیدرولوژی، هواشناسی، مطالعات اقلیمی، مورفولوژی، مهندسی هیدرولیک، مطالعات رطوبت خاک و علوم زیست محیطی یافته‌های بسیار خوش بینانه‌ای را به دست آورده است. بر اساس بررسی دقیق کارهای تحقیقاتی موجود، آشکار است که اکثر برنامه‌های کاربردی مدل ELM بر روی کاربردهای چندمتغیره و به ویژه در مدل سازی سیستم‌های اقلیمی و محیطی توسعه یافته‌اند. این به دلیل این واقعیت است که مدل ELM قادر به شناسایی رابطه

1. Huang et al

2. Deo et al

3. Salcedo-Sanz et al

غیرخطی است که فرایندهای فیزیکی بین پیش‌بینی‌کننده‌ها و پیش‌بینی‌کننده‌ها را نشان می‌دهد و به دلیل شایستگی‌های آن که توسط فرآیند یادگیری تصادفی هدایت می‌شود. در مدل‌سازی پیش‌بینی جریان رودخانه، پارامترهای مختلف هیدرولوژیکی و ژئوفیزیکی معمولاً به‌عنوان پیش‌بینی‌کننده استفاده می‌شوند، درحالی‌که سری زمانی جریان رودخانه در ایستگاه خاص پیش‌بینی‌کننده است. این مدل‌ها فرض ذاتی ایستایی را در رابطه بین پیش‌بینی‌کننده‌ها و پیش‌بینی‌کننده‌ها در نظر می‌گیرند. با این حال، در موارد واقعی، بسته به داده‌های واقعی، این فرض ممکن است درست نباشد. در موارد شناسایی غیرثابت در روابط بین پیش‌بینی‌کننده و پیش‌بینی‌کننده، نتایج مدل نامشخص می‌شود. به این ترتیب، تعیین دلایل احتمالی پس از شناسایی هر گونه غیرایستایی خاص مهم است و باید در انتخاب پیش‌بینی‌کننده‌ها دقت کرد تا از وقوع هر گونه غیرایستایی جلوگیری شود.

در مطالعه انجام شده توسط فاطمی و پروینی^۱ (۲۰۲۲)، به مدل‌سازی سری زمانی برای پیش‌بینی هیدرولوژیکی با استفاده از مدل ANFIS می‌پردازد. تأثیر اشکال تابع خودهمبستگی (ACF) شامل سینوسی و نزولی بر انتخاب ورودی بررسی شده است. نتایج نشان می‌دهد که انتخاب ورودی‌ها از محدوده غیرایستا دقت پیش‌بینی را افزایش می‌دهد و استفاده از معکوس استانداردسازی برای ACF نزولی عملکرد را بهبود می‌بخشد. به‌طور کلی، انتخاب ورودی‌ها بر اساس نمودار ACF مؤثرتر از تنظیم مدل یا تغییر مولدهای فازی است. روش‌های کنونی برای ادغام هوش مصنوعی (AI) در پیش‌بینی بارندگی و دبی رودخانه شامل مجموعه‌ای از تکنیک‌های یادگیری ماشین و مدل‌های ترکیبی است. به‌طور خاص، مطالعات از شبکه‌های عصبی پس‌انتشار (BPNN)، حافظه طولانی - کوتاه مدت (LSTM) و ماشین یادگیری بیشینه (ELM) برای مدل‌سازی دبی رودخانه استفاده کرده‌اند که در این میان، LSTM در برخی موارد دقت بالاتری نشان داده است (باربولسکو و چن، ۲۰۲۴). علاوه بر این، رویکردهای ترکیبی که شبکه‌های عصبی پرسپترون چندلایه (MLPNN) را با الگوریتم‌های بهینه‌سازی مانند NSGA-II و تکنیک‌های پیش‌پردازش داده‌ها مانند تحلیل مؤلفه‌های اصلی (PCA) ترکیب می‌کنند، در حوضه‌های رودخانه‌ای با داده‌های محدود عملکرد بهتری نشان داده‌اند (مروتی و کیسی^۲، ۲۰۲۴). همچنین، مدل‌های ترکیبی پیشرفته که روش‌های تجزیه سیگنال را با LSTM ادغام می‌کنند، نتایج امیدوارکننده‌ای را به‌ویژه در پیش‌بینی رواناب‌های شدید ارائه داده‌اند (ژانگ و همکاران^۳، ۲۰۲۵). رگرسیون جنگل تصادفی^۴ نیز به‌عنوان مدلی قدرتمند برای پیش‌بینی جریان رودخانه شناخته شده است و در برخی از کاربردهای حوضه‌های آبخیز، عملکرد بهتری نسبت به سایر تکنیک‌های هوش مصنوعی داشته است (رجا شکر و متیو^۵، ۲۰۲۴). در نهایت، مدل‌های یادگیری ماشین به‌طور مؤثر در پیش‌بینی سیلاب‌های لحظه‌ای به کار گرفته شده‌اند و در مقایسه با روش‌های سنتی، به‌ویژه زمانی که داده‌های جامع بارندگی مورد استفاده قرار می‌گیرند، دقت پیش‌بینی بهتری نشان داده‌اند (دفونتین و همکاران^۶، ۲۰۲۴).

دارابی چقابلیکی و همکاران^۷ (۲۰۲۴) به ارزیابی پیش‌بینی جریان رودخانه با استفاده از یادگیری ماشین، با تمرکز بر پیش‌پردازش، تنظیم مدل و انتخاب ویژگی می‌پردازد. جریان ماهانه در ایستگاه پل چهار با استفاده از مدل‌های SVR و GA-SVR و دو روش اعتبارسنجی متقاطع k-fold و سری زمانی پیش‌بینی شده است. نتایج نشان می‌دهد که روش k-fold معمولاً عملکرد بهتری نسبت به سری زمانی دارد، به‌ویژه با استفاده از پیش‌پردازش. استانداردسازی دقت پیش‌بینی را بهبود می‌بخشد، درحالی‌که بهینه‌سازی با GA تنها برای داده‌های خام مؤثر است. بهترین نتایج با استفاده از روش k-fold همراه با پیش‌پردازش به دست می‌آید و دقت بالایی را بدون نیاز به تنظیمات اضافی ارائه می‌دهد.


1. Fatemi & Parvini
2. Morovati & Kisi
3. Zhang et al
4. Random Forest Regression
5. Raja Shekar & Mathew
6. Defontaine et al
7. Darabi Cheghabaleki et al

بررسی‌ها نشان می‌دهد با وجود اینکه مدل‌های مفهومی یا مبتنی بر اطلاعات فیزیکی و داده‌های اقلیمی برای درک فرایندهای هیدرولوژیکی اهمیت دارند، حوضه‌های فاقد آماری وجود دارند که پیش‌بینی دقیق جریان در آنها بر اساس داده‌های اقلیمی ممکن نیست. همچنین استفاده از مدل‌های ریاضی علاوه بر پیچیدگی، نیاز به فرآیند وقت‌گیر واسنجی و صحت‌سنجی دارد. در چنین شرایطی ترجیح داده می‌شود که یک مدل ساده (داده‌محور یا یادگیری ماشین) توسعه داده شود تا با ایجاد ارتباط بین ورودی‌ها و خروجی‌ها بدون نیاز به اطلاعات و داده‌های گسترده برای پیش‌بینی مستقیم دبی رودخانه مورد استفاده قرار گیرد؛ لذا هدف از این تحقیق این است که کارایی روش ماشین یادگیری افراطی با حذف داده پرت (ORELM) به عنوان ابزاری برای پیش‌بینی دبی جریان رودخانه مورد بررسی و ارزیابی قرار گیرد.

روش پژوهش

۱. منطقه مورد مطالعه

محدوده مورد مطالعه حوضه آبریز پل کهنه واقع بر رودخانه قره‌سو است که در شکل (۱) نشان داده شده است. رودخانه قره‌سو از سراب روانسر واقع در ۵۰ کیلومتری شمال غرب کرمانشاه سرچشمه می‌گیرد و با جهت شمال غربی به جنوب شرقی جریان پیدا می‌کند. در ۱۵ کیلومتری کرمانشاه رودخانه رازآور و شاخه‌های فرعی آن به قره‌سو می‌ریزد. سپس در سطح دشت جریان یافته و در نزدیکی روستای قزانچی رودخانه مرگ نیز به آن متصل می‌شود. قره‌سو با یک شیب آرام از داخل شهر کرمانشاه عبور کرده و در این محدوده دو رودخانه چم‌بشیر و آبشوران نیز به آن می‌ریزند و در نهایت پس از عبور از کرمانشاه در نزدیکی فرامان به رودخانه گاماسیاب می‌پیوندد. برای این تحقیق از داده‌های ایستگاه پل کهنه واقع بر رودخانه قره‌سو استفاده شد.



شکل ۱. نقشه موقعیت منطقه و ایستگاه مورد مطالعه در کرمانشاه

۲. مدل هوش مصنوعی

ماشین آموزش نیرومند^۱


ماشین آموزش نیرومند (ELM) یک شبکه عصبی پیشخور^۲ تک لایه بوده و توسط هوانگ و همکاران (۲۰۰۴، ۲۰۰۶) ارائه شده است. ELM وزن های ورودی را به صورت تصادفی و وزن های خروجی را به صورت تحلیلی^۳ تعیین می کند. ساختار کلی این الگوریتم در شکل (۲-الف) ارائه شده است. تنها تفاوت ELM با شبکه عصبی پیشخور تک لایه^۴ (SLFFNN)، عدم استفاده از بایاس^۵ برای نرون خروجی است. نرون های لایه ورودی با همه نرون های لایه مخفی در ارتباط است. تابع فعال سازی نرون های مخفی می تواند به صورت تابع پیوسته تکه ای^۶ باشد درحالی که برای نرون لایه خروجی به صورت خطی است. مدل ELM از الگوریتم های مختلفی جهت محاسبه وزن ها و بایاس ها استفاده می کند 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، در رابطه (۱) بیان شده است:

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

که β_i وزن بین گره مخفی i ام و گره خروجی، a_i و b_i فاکتورهای آموزش گره های مخفی و $G(a_i, b_i, x)$ خروجی گره i ام برای ورودی x است. تابع فعال سازی $g(x)$ (که دارای انواع مختلفی می باشد) برای گره مخفی افزاینده^۷ $G(a_i, b_i, x)$ را می توان به شکل رابطه (۲) بازنویسی کرد:

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

از توابع فعال سازی به منظور محاسبه خروجی پاسخ نرون ها استفاده می شود. زمانی که مجموعه ای از سیگنال ورودی وزن دار اعمال می شود، برای به دست آوردن پاسخ از توابع فعال سازی استفاده می شود. توابع فعال سازی غیرخطی ELM که در این مطالعه مورد بررسی قرار گرفته است شامل تابع پله ای (hardlim)، سیگموئید^۸ (sig)، سینوسی (sin)، بایاس مثلثی (tribas) و بایاس شعاعی (radbas) است که به صورت شکل (۲) تعریف می شوند.



شکل ۲. الف) ساختار شبکه ELM ب) توابع فعال سازی مختلف در مدل ELM

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. مطابق شکل (۲-الف) شبکه دارای یک لایه ورودی و یک لایه مخفی و یک لایه خروجی است. در نهایت پس از سعی و خطا و ارزیابی نتایج، تعداد تکرار حل مسئله ۵۰۰۰ تکرار و تعداد نرون های لایه پنهان ۸۰ در نظر گرفته شد:

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

1. Extreme Learning Machine (ELM)
2. feed-forward
3. Analytical
4. Single layer feed forward neural network
5. Bias
6. Piecewise continuous function
7. Additive
8. Sigmoid

که $g(.)$ می‌تواند هر تابع فعال‌سازی غیرخطی پیوسته باشد، W_{ji} وزن نرون ورودی i ام و نرون لایه مخفی j ام، B_j ، بایاس نرون لایه مخفی j ام، X_{ik} ورودی نرون ورودی برای k امین نمونه آموزشی و H_{ik} ماتریس فعال‌سازی k امین نرون لایه مخفی برای k امین نمونه آموزشی است بطوریکه فعال‌سازی همه نرون‌های لایه مخفی برای نمونه‌های مورد استفاده در آموزش توسط این ماتریس ارائه می‌شود. در این ماتریس k ردیف است. ماتریس H به عنوان 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 نرون - های لایه مخفی برای هر نمونه آموزشی، بکار برده می‌شود که معادل ریاضی آن را می‌توان به شکل زیر بیان کرد:

$$HB=T \quad (4)$$

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

که β نشان‌دهنده وزن بین نرون لایه خروجی و نرون‌های لایه مخفی است و T بردار نشان‌دهنده مقادیر هدف برای نمونه‌های آموزش است که به صورت معادله (۶) بیان می‌شود:

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

نهایتاً وزن‌ها را می‌توان از رابطه (۷) محاسبه کرد:

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

که در آن:

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

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

که $\tilde{a} = a_1, \dots, a_L, \tilde{b} = b_1, \dots, b_L, \tilde{x} = x_1, \dots, x_L$ ، β 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 ارائه شده می‌توان گفت که آموزش ELM شامل دو مرحله است: مرحله اول، اختصاص تصادفی وزن‌ها و بایاس‌ها به نرون‌های لایه پنهان و محاسبه خروجی لایه پنهان ماتریس H و مرحله دوم، محاسبه وزن‌های خروجی با استفاده از 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 لوبنبرگ-مارکوآردت^۱ که در آن هیچ نوع روالی از بهینه سازی غیرخطی را در بر نمی‌گیرد، برخوردار است. بنابراین زمان آموزش شبکه به طور قابل توجهی کاهش می‌یابد (هوانگ و همکاران، ۲۰۰۶).

ماشین آموزش نیرومند با داده‌های پرت^۲

برای آموزش مدل داده‌ها را به بخش آموزش و تست تقسیم کردیم. تعداد کل داده‌ها ۷۸۰ داده بود که حدود ۷۰ درصد آن برای مرحله آموزش یا train و ۳۰ درصد آن برای مرحله آزمون یا test در نظر گرفته شد. 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^۳ و لو^۴ (۲۰۱۵) با دانش

1. Levenberg-Marquardt

2. Outlier Robust Extreme Learning Machine (ORELM)

3. Zhang

4. Luo

اینکه استفاده از l_0 -norm، sparsity را نسبت به l_2 -norm بهتر منعکس می کند، جهت محاسبه ماتریس وزن خروجی (β) ، به جای استفاده از l_2 -norm، خطای آموزش (e) را به گونه ای در نظر می گیرند که sparse باشد.

$$\min_{\beta} C\|e\|_0 + \|\beta\|_2^2 \text{ subject to } H\beta = e \quad (10)$$

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

(β) ، ماتریس وزن های خروجی است (w_0 یا همان w_{output} است).

یا در برخی منابع به این شکل نوشته می شود (w_0) ماتریس وزن های خروجی است:

$$\min_{w_0} C\|e\|_0 + \|w_0\|_2^2 \text{ subject to } T-Hw_0 \quad (11)$$

رابطه فوق یک مسئله برنامه نویسی غیرمحدب^۱ است. یکی از ساده ترین راه ها جهت حل این مسئله، نوشتن آن به صورت یک مسئله محدب قابل کنترل بدون از بین رفتن ویژگی پراکندگی^۲ است. ترم پراکنده یا sparse با استفاده از l_1 -norm به دست می آید. جای گذاری l_0 -norm با l_1 -norm، نه تنها منجر به حداقل سازی تحدب^۳ (کم شدن تابع خطا) می شود بلکه وجود مشخصات پراکندگی یا وجود وقایع حدی (داده های نادر) را نیز تضمین می کند.

$$\min_{\beta} \|e\|_1 + \frac{1}{c} \|\beta\|_2^2 \text{ subject to } H\beta = e \quad (12)$$

رابطه فوق یک مسئله بهینه سازی محدب مقید^۴ است به طوری که به طور کامل دامنه مناسب رویکرد تکمیل شده ضرب لاگرانژی^۵ را تطبیق می کند.

$$L_{\mu}(e, \beta, \lambda) = \|e\|_1 + \frac{1}{c} \|\beta\|_2^2 + \lambda^2 (y - H\beta - e) + \frac{\mu}{2} \|y - H\beta - e\|_2^2 \quad (13)$$

که $\mu = 2N/\|y\|_1$ بر پارامتر جریمه^۶ دلالت دارد و $\lambda \in \mathbb{R}^n$ بردار ضرب لاگرانژی است (ژانگ و همکاران، ۲۰۱۱). جواب بهینه (e, β) و بردار ضرب لاگرانژی (λ) با استفاده از حداقل سازی تابع زیر طی فرایند تکراری، به دست می آید.

$$\begin{cases} (e_{k+1}, \beta_{k+1}) = \arg \min_{e, \beta} L_{\mu}(e, \beta, \lambda) & (a) \\ \lambda_{k+1} = \lambda_k + \mu(y - H\beta_{k+1} - e_{k+1}) & (b) \end{cases} \quad (14)$$

یافته های پژوهش

۱. پیش بینی دبی جریان رودخانه بر اساس هوش مصنوعی

در این مطالعه از روش ORELM برای پیش بینی دبی جریان رودخانه استفاده شد. تا بتوان قابلیت جایگزینی این روش با مدل های پیچیده را بررسی کرد. این امر برای جایی که شرایط مطلوب برای به کارگیری مدل های عددی پیچیده برقرار نیست و یا اینکه اطلاعات کافی در دست نیست بسیار حائز اهمیت است. طوری که بتوان بر اساس تعداد ورودی های بسیار اندک، دبی جریان ورودی رودخانه را بادقت زیاد پیش بینی نمود. باتوجه به اهداف این تحقیق در این روش از داده های ماهیانه دبی در گام های زمانی قبل $(t-1, t-2, t-3)$ ، به عنوان داده های ورودی به مدل استفاده شد. خروجی مدل نیز داده های دبی پیش بینی شده رودخانه قره سو در گام زمانی حاضر (t) در ایستگاه پل کهنه است. بهترین نتایج حاصل از اجرای هر کدام از داده های در نظر گرفته شده در شکل های (۳) و (۴) ارائه شده است. در تاخیرهای زمانی بیش از ۳ ماه مانند تاخیرهای ۶، ۱۲ و ۲۴ ماه نتایج پیش بینی دارای دقت بسیار پایین بود. به همین خاطر به ارائه نتایج تاخیرهای ۱ تا ۳ ماه بسنده شد. بر اساس این شکل ها مدل ORELM با یک تأخیر در حالت اول یعنی گام زمانی $(t-1)$ باتوجه به تمامی شاخص ها دارای دقت بیشتری نسبت به سایر مدل ها در مراحل آموزش و آزمایش است. پراکنش منظم تر و نزدیک تر نقاط در اطراف خط $Y=X$ در مدل ORELM در حالت اول $(t-1)$ نیز حاکی از

1. Non-convex programming

2. Tractable convex relaxation form without loss of the sparsity characteristic


3. Minimization convex

4. Constrained convex


5. Augmented Lagrangian (AL) multiplier

6. Penalty


دقت بیشتر مقادیر پیش‌بینی این مدل در مقایسه با داده‌های مشاهداتی است. براین اساس سری زمانی مقادیر پیش‌بینی شده دبی جریان رودخانه بر اساس مدل برتر ORELM (با تأخیر $(t-1)$) در مقایسه با داده‌های مشاهداتی در مراحل آموزش و آزمایش در شکل (۵) نشان داده شده است. نمودار شکل ۵ خروجی‌های مدل در نرم‌افزار متلب است که مقادیر target مربوط به داده‌های مشاهداتی و مقادیر output مربوط به داده‌های پیش‌بینی شده توسط مدل است.



شکل ۳. نمایش گرافیکی پراکندگی نقاط در اطراف خط $Y=X$ و مقدار مجذور ضریب همبستگی برای انتخاب بهترین مدل هوش مصنوعی با تأخیرهای $t-1$ ، $t-2$ و $t-3$ (الف، ب و ج) در مرحله آموزش مدل سازی



شکل ۴. نمایش گرافیکی پراکندگی نقاط در اطراف خط $Y=X$ و مقدار مجذور ضریب همبستگی برای انتخاب بهترین مدل هوش مصنوعی با تأخیرهای $t-1$ ، $t-2$ و $t-3$ (الف، ب و ج) در مرحله آزمایش مدل سازی



شکل ۵. گراف مقادیر پیش‌بینی شده دبی رودخانه بر اساس مدل برتر ORELM (با تاخیر $(t-1)$) در مقایسه با داده‌های مشاهداتی در مراحل آموزش و تست

نتایج حاصل از کاربرد مدل هوش مصنوعی ORELM نشان می‌دهد این روش توانسته است در دوره آماری ۶۵ ساله با کمترین میزان خطا در مراحل آموزش و آزمایش دبی ورودی رودخانه را پیش‌بینی نماید. مقدار ضریب همبستگی در مراحل train و test به ترتیب ۰.۹۲ و ۰.۹۷ است که تایید می‌کند این مدل دقت بسیار خوبی در پیش‌بینی دبی جریان رودخانه دارد. مقدار RMSE در این روش در حالت تاخیر یک‌ماهه $(t-1)$ در دو مرحله آموزش و آزمایش به ترتیب ۱۲/۲۲ و ۴/۱۴ بود. مقدار RMSE در مرحله آزمایش با زمان تاخیرهای ۲ و ۳ به ترتیب در حدود ۹/۲۹ و ۸ بود که این مقدار نشان می‌دهد مدل ORELM در حالت اول بدون نیاز به اطلاعات و داده‌های فراوان و بدون بهره‌گیری از فرآیند پیچیده مدلسازی بر اساس معادلات حاکم مقدار دبی جریان رودخانه را به درستی و بادقت زیاد پیش‌بینی نماید.

بحث

امکان پیش‌بینی دبی رودخانه برای یک دوره بلندمدت بر اساس حجم اطلاعات بسیار کم نسبت به مدل‌های عددی و تنها با استفاده از داده‌های جریان رودخانه در دوره‌های گذشته یکی از مهم‌ترین دستاوردهای این تحقیق است. در این حالت بدون نیاز به پارامترهای هواشناسی، خاک، زمین‌شناسی، اطلاعات مقاطع رودخانه‌ای و بدون نیاز به نقشه‌ها و نرم‌افزارهای پیچیده و بدون صرف زمان و هزینه زیاد برای کالیبراسیون و صحت‌سنجی مدل‌های ریاضی، دبی جریان رودخانه بر اساس روش‌های هوش مصنوعی پیش‌بینی می‌گردد. این امر کمک بزرگی به متخصصین بخش منابع آب در حوضه‌های فاقد آمار یا اطلاعات پایه‌ای و نقشه‌های دقیق بوده و یا رودخانه‌هایی 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 دبی جریان رودخانه در سال‌های خشک و تر به دست می‌آید.

نتیجه‌گیری

ارزیابی عملکرد مدل هوش مصنوعی (ORELM) در رودخانه قره‌سو ایستگاه پل کهنه نشان داد این مدل دقت بسیار خوبی در پیش‌بینی دبی جریان رودخانه دارد. این روش توانسته است در دوره آماری ۵ ساله با کمترین میزان خطا در مراحل آموزش و آزمایش دبی ورودی رودخانه را پیش‌بینی نماید. به‌طوری که مقدار RMSE در این روش در حالت تأخیر یک‌ماهه ($t-1$) در دو مرحله آموزش و آزمایش به ترتیب ۱۲/۲۲ و ۴/۱۴ بود. مقدار RMSE در مرحله آزمایش با زمان تاخیرهای ۲ و ۳ به ترتیب در حدود ۹/۲۹ و ۸ بود که این مقدار نشان می‌دهد مدل ORELM در حالت اول بدون نیاز به اطلاعات و داده‌های فراوان و بدون بهره‌گیری از فرآیند پیچیده مدلسازی بر اساس معادلات حاکم مقدار دبی جریان رودخانه را به درستی و با دقت زیاد پیش‌بینی نماید. نتایج تجربی نشان می‌دهد که روش توسعه‌یافته با توجه به شاخص‌های مختلف ارزیابی عملکرد نسبت به روش‌های سنتی برتری دارد؛ بنابراین، یک مدل ماشین یادگیری افراطی تکاملی جدید و عملی با استفاده از هوش ازدحامی برای انجام کار پیچیده پیش‌بینی هیدرولوژیکی توسعه داده شده است. از سوی دیگر، کاربرد روش پیشنهادی ممکن است در عمل محدود باشد زیرا تعیین پارامترهای بهینه مدل شبکه عصبی در تئوری نسبتاً دشوار است. درحالی که تفاوت‌های زیادی در اطلاعات مشخصه عناصر هیدرولوژیکی در مکان‌های مختلف وجود دارد. با توجه به توسعه سریع فناوری کامپیوتر، چشم انداز روش پیشنهادی را می‌توان با معرفی روش‌های محاسبات نرم موثرتر یا توسعه استراتژی‌های اصلاح شده قوی‌تر بهبود بخشید. علاوه بر این، ترکیبی از تکنیک پردازش سیگنال جدید توسعه یافته نیز می‌تواند برای بهبود عملکرد روش پیشنهادی استفاده شود. از جنبه دیگر، نتایج تأیید کرد که زمان تاخیر به‌عنوان یک ویژگی ورودی بر عملکرد مدل‌سازی مدل پیش‌بینی بسیار مهم است.

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.

تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.

منابع

گرگانی، شهرام، بافکار، علی، و فاطمی، سید احسان. (۱۳۹۶). پیش بینی استعداد آلودگی آب های زیرزمینی با استفاده از شاخص دراستیک و تحلیل سری های زمانی سالانه (مطالعه موردی: دشت ماهیدشت کرمانشاه). *مجله سلامت و محیط زیست*، ۱۰ (۳)، ۳۱۷-۳۲۸. <http://ijhe.ums.ac.ir/article-1-5962-fa.html>

References

- Bărbulescu, A., & Zhen, L. (2024). Forecasting the river water discharge by artificial intelligence methods. *Water*, 16(9), 1248. <https://doi.org/10.3390/w16091248>
- Darabi Cheghabaleki, S., Fatemi, S. E., & Hafezparast Mavadat, M. (2024). Enhancing spatial streamflow prediction through machine learning algorithms and advanced strategies. *Applied Water Science*, 14(6), 110. <http://dx.doi.org/10.1007/s13201-024-02154-x>
- Defontaine, T., Ricci, S., Lapeyre, C. J., Marchandise, A., & Le Pape, E. (2024). Real-time flood forecasting with Machine Learning using scarce rainfall-runoff data. *EGUsphere*, 1-32. <https://doi.org/10.5194/egusphere-2023-2621>
- Deo, R. C., Downs, N., Parisi, A. V., Adamowski, J. F., & Quilty, J. M. (2017). Very short-term reactive forecasting of the solar ultraviolet index using an extreme learning machine integrated with the solar zenith angle. *Environmental research*, 155, 141-166. <https://doi.org/10.1016/j.envres.2017.01.035>
- Fatemi, S. E., & Parvini, H. (2022). The impact assessments of the ACF shape on time series forecasting by the ANFIS model. *Neural Computing and Applications*, 34(15), 12723-12736. <http://dx.doi.org/10.1007/s00521-022-07140-5>
- Gorgani, S., Bafkar, A., & Fatemi, S. (2017). Prediction of groundwater pollution potential using the DRASTIC index and annual time series analysis (case study: plain Mahidasht Kermanshah). *IJHE*, 10 (3), 317-328. <http://ijhe.tums.ac.ir/article-1-5962-en.html> (In Persian)
- Huang, G., Huang, G.-B., Song, S., & You, K. (2015). Trends in extreme learning machines: A review. *Neural Networks*, 61, 32-48. <http://dx.doi.org/10.1016/j.neunet.2014.10.001>
- 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>
- Morovati, R., & Kisi, O. (2024). Utilizing hybrid machine learning techniques and gridded precipitation data for advanced discharge simulation in under-monitored river basins. *Hydrology*, 11(4), 48. <https://doi.org/10.3390/hydrology11040048>
- Raja Shekar, P., & Mathew, A. (2024). AI-Based Rainfall-Runoff Modelling for Sustainable Water Management in Potteruvagu Watershed, India. In *Geospatial Technology to Support Communities and Policy: Pathways to Resiliency*, Springer, Springer, New York Sity, United states. http://dx.doi.org/10.1007/978-3-031-52561-2_6
- Salcedo-Sanz, S., Pastor-Sánchez, A., Prieto, L., Blanco-Aguilera, A., & García-Herrera, R. (2014). Feature selection in wind speed prediction systems based on a hybrid coral reefs optimization–Extreme learning machine approach. *Energy Conversion and Management*, 87, 10-18. <https://doi.org/10.1016/j.enconman.2014.06.041>
- Wang, E., Zhang, Y., Luo, J., Chiew, F. H. S., & Wang, Q. J. (2011). Monthly and seasonal streamflow forecasts using rainfall-runoff modeling and historical weather data. *Water Resources Research*, 47(5). <https://doi.org/https://doi.org/10.1029/2010WR009922>
- Zhang, X., Wang, R., Wang, W., Zheng, Q., Ma, R., Tang, R., & Wang, Y. (2025). Runoff prediction using combined machine learning models and signal decomposition. *Journal of Water and Climate Change*, 16(1), 230-247. <https://doi.org/10.2166/wcc.2024.663>