

Research Paper

Estimation of daily suspended sediment load using a new hybrid artificial neural network model combined with observer-teacher-learner- based- optimization method

Siyamak Doroudi¹, Ahmad Sharafati², *

1. PhD student, Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

2. Assistant Professor, Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

Received: 2024.06.02

Revised: 2024.06.07

Accepted: 2024.07.30

Use your device to scan and read the article online



DOI:

[10.30495/wej.2024.31956.2388](https://doi.org/10.30495/wej.2024.31956.2388)

Keywords:

Suspended sediment load, Optimization algorithm, Artificial neural network

Abstract

Introduction: Suspended sediment load (SSL) is one of the complex hydrological phenomena, and its prediction is difficult. This study uses the artificial neural network method to predict suspended sediment load. Since the accuracy of artificial neural networks depends on their parameters, the benefit of meta-heuristic algorithms can be effective in increasing their performance. The case study is the catchment area of the Kosar Dam located in the southwest of Iran.

Methods: River discharge and rainfall were considered as inputs, and features for predicting models. Five input compounds were selected. OTLBO and PSO meta-heuristic algorithms were used to find the optimal ANN values, and ANN-OTLBO and ANN-PSO prediction models were developed. Predicting models were evaluated using different numerical and visual indicators.

Findings: The results show that the ANN-OTLBO model provides higher prediction performance than other models used in this study. Specifically, the ANN-OTLBO-M5 model shows superior values ($R=0.96358$, $RMSE=258.14$, $PBIAS=2.6752$, and $NSE=0.92674$). Also, based on the Scatter plot, Heat map, and Box plot, the closest predicted data to the observed data belongs to the ANN-OTLBO-M5 model.

Citation: Siyamak Doroudi, Ahmad Sharafati. Estimation of daily suspended sediment load using a new hybrid artificial neural network model combined with observer-teacher-learner- based- optimization method. Water Resources Engineering Journal. 2025; 18 (64): 25-36.

***Corresponding author:** Ahmad Sharafati

Address: Dept. of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

Tell: +989122861557

Email: asharafati@gmail.com

Extended Abstract

Introduction

Despite the importance of suspended sediment load in water resources management issues, the process of assessing suspended sediment load is very complex due to its dependence on numerous hydrological and hydraulic variables. Various physical, numerical, and experimental models have been used to predict SSL. These models have limitations such as complexity in solving equations, dependence on different simplifying assumptions, the need for high knowledge and skill in application, and the availability of high-quality experimental data. Instead, the artificial neural network recognizes complex and non-linear relationships between input and output. Flexibility, simplicity, and pairing with different software are other features of artificial intelligence models. But artificial intelligence models, such as artificial neural networks or support vector machines, must adjust their parameters. Therefore, in this research, the suspended sediment load in the Kosar Dam watershed located in the southwest of Iran has been estimated by combining meta-heuristic algorithms with artificial neural networks

Materials and Methods

The daily hydrological data of the catchment, including the discharge, rainfall, and SSL recorded from 1986 to 2015, are used for prediction modeling. Then all data are rescaled from $x \in [a, b]$ to $x' \in [0, 1]$, and their values are normalized. Input combinations by calculating the correlation between SSL on the day of origin (t) and input variables, including the river discharge (Q_s) from the day of origin (t) to the previous four days ($t-4$) and the amount of precipitation (R_s and R_d) from the day of origin (t) to six days earlier ($t-6$), they are obtained. As a result, using Pearson correlation analysis, five input combinations (M1 to M5) are accepted. Then PSO and OTLBO optimization algorithms are combined with ANN, and two combined models ANN-OTLBO and ANN-PSO, are developed. Hybrid models are executed until the training phase termination criterion is

satisfied. In the testing phase, the developed models estimate the suspended sediment load based on the best solution obtained (the best decision variables). Finally, ANN, ANN-OTLBO, and ANN-PSO are evaluated with four criteria: Pearson correlation coefficient (R), root mean square error (RMSE), percentage bias (PBIAS), and Nash-Sutcliffe efficiency (NSE).

Findings

The results of this study demonstrated that hybrid models based on artificial intelligence significantly outperform the basic artificial neural network model in predicting suspended sediment load. Among them, the ANN-OTLBO-M5 model showed the highest accuracy, with $R = 0.96358$, $RMSE = 258.14$, $PBIAS = -2.6752$, and $NSE = 0.92674$. A comparative analysis revealed that the ANN-M5 model performed best among the basic ANN models, and the ANN-PSO-M5 model showed noticeable improvement over the ANN model; however, its performance was still inferior to the ANN-OTLBO-M5 model. This difference in predictive accuracy can be attributed to the OTLBO algorithm's superior capability in effectively exploring the solution space and optimally tuning ANN parameters. Furthermore, visual analyses including the Heat map, Scatter plot, and Box plot confirmed the numerical results, indicating that the ANN-OTLBO-M5 model is highly effective in reconstructing the distribution, variability, and statistical patterns of suspended sediment data. The predicted values generated by this model closely matched the observed data across low, medium, and high sediment load levels, highlighting its robustness in modeling a wide range of hydrological conditions. Additionally, it was found that input combination M5 (which includes rainfall and discharge data for the current day and one day prior) yielded the best accuracy across all models, emphasizing the critical role of input selection in improving model performance.

Discussion

The proposed hybrid ANN-OTLBO model demonstrated superior predictive accuracy

for suspended sediment load compared to conventional ANN and ANN-PSO models, confirming the effectiveness of meta-heuristic optimization in parameter tuning. Input combination M5 yielded the best results across all models, highlighting the importance of relevant feature selection. Visual analyses supported the numerical outcomes, indicating close alignment between predicted and observed values. In comparison with previous approaches, the developed model provided improved accuracy, particularly in estimating extreme sediment values. Nevertheless, the method requires substantial data and computational resources, suggesting the potential for future improvements through multi-objective optimization.

Conclusion

Based on the findings of this research, it can be concluded that, among all ANN models, ANN-M5 has the highest performance. ANN-OTLBO-M5 has the best performance compared to other ANN-OTLBO models, and ANN-PSO-M5 is the best model among all ANN-PSO models. Among the models with the highest performance, ANN-OTLBO-M5 has the highest performance in both the testing and training phases. The predicted data of the hybrid models are closer to the observed data than the ANN model's output data. Furthermore, ANN-OTLBO-M5 is the closest predicted model to the observed data.

Ethical Considerations compliance with ethical guidelines

The cooperation of the participants in the present study was voluntary and accompanied by their consent.

Funding

No funding.

Authors' contributions

Design and conceptualization: Siyamak Doroudi, Ahmad Sharafati

Methodology and data analysis: Siyamak Doroudi, Ahmad Sharafati,
Supervision and final writing: Ahmad Sharafati.

Conflicts of interest

The authors declared no conflict of interest.

مقاله پژوهشی

برآورد بار رسوب معلق روزانه با استفاده از یک مدل شبکه عصبی مصنوعی ترکیبی جدید همراه با روش بهینه سازی مبتنی بر ناظر - معلم - یادگیرنده

سیامک درودی^۱، احمد شرافتی^{۲*}

۱. دانشجوی دکترا، دانشکده عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲. دانشیار، دانشکده عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

چکیده

مقدمه: بار رسوب معلق SSL یکی از پدیده های پیچیده هیدرولوژیکی است و پیش بینی آن دشوار است. در این مطالعه از روش شبکه عصبی مصنوعی جهت پیش بینی بار رسوب معلق استفاده شده است. از آنجاییکه دقت عملکرد شبکه های عصبی مصنوعی به پارامترهای آن بستگی دارد. استفاده از الگوریتم های فراابتکاری می تواند در جهت افزایش عملکرد آن ها موثر باشد. منطقه مورد مطالعه در حوضه آبریز سد کوثر واقع در جنوب غربی ایران می باشد.

روش: دبی رودخانه و بارش به عنوان ویژگی های ورودی به مدل های پیش بینی در نظر گرفته شد. پنج ترکیب ورودی انتخاب شدند. الگوریتم های فراابتکاری PSO، OTLBO با شبکه عصبی مصنوعی ترکیب شدند و مدل های پیش بینی ANN-OTLBO و ANN-PSO تدوین گردید. مدل های پیش بینی با استفاده از شاخص های عددی و بصری مختلف ارزیابی شدند.

یافته ها: نتایج نشان می دهد که مدل ANN-OTLBO عملکرد پیش بینی بالاتری نسبت به سایر مدل های بکار رفته در مطالعه حاضر ارائه می دهد. مقادیر عبارتند از $R=0/96358$ ، $RMSE=258/14$ ، $BIAS=-2/6752$ و $PBIAS=-0/92674$ ، و همچنین بر اساس نمودار Scatter plot و Heat map و Box plot نزدیک ترین داده های پیش بینی شده به داده های مشاهداتی متعلق به مدل ANN-OTLBO-M5 می باشد.

نتیجه گیری: در بین تمامی مدل های ANN، ANN-OTLBO، ANN-PSO، مدل ANN-OTLBO بهترین عملکرد را دارا می باشد. مدل مذکور توانسته است مقادیر بالا، متوسط و کم رسوب را با دقت مناسبی پیش بینی کند و ترکیب الگوریتم های فراابتکاری با شبکه عصبی مصنوعی باعث افزایش دقت پیش بینی رسوب می شوند.

تاریخ دریافت: ۱۴۰۳/۰۳/۱۳

تاریخ داوری: ۱۴۰۳/۰۳/۱۸

تاریخ پذیرش: ۱۴۰۳/۰۵/۰۹

از دستگاه خود برای اسکن و خواندن مقاله به صورت آنلاین استفاده کنید



DOI:

[10.30495/wej.2024.31956.2388](https://doi.org/10.30495/wej.2024.31956.2388)

واژه های کلیدی:

بار رسوب معلق، الگوریتم بهینه سازی، شبکه های عصبی مصنوعی

* نویسنده مسئول: احمد شرافتی

نشانی: دانشکده عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

تلفن: 09122861557

پست الکترونیکی: asharafati@gmail.com

مقدمه

برآورد مناسب بار رسوب معلق (SSL) در اهداف مهندسی آب مانند طراحی و بهره برداری از سدها، سازه‌های کنترل سیل، کانال‌های انتقال آب و دیگر سازه‌های هیدرولیکی بسیار ضروری است [1]. علیرغم اهمیت SSL، به دلیل وابستگی آن به متغیرهای متعدد هیدرولوژیکی و هیدرولیکی، فرآیند ارزیابی بار معلق رسوب بسیار پیچیده است [2]. تاکنون، مدل‌های مختلف پیش بینی SSL مانند مدل‌های فیزیکی، عددی و تجربی استفاده شده است. مدل‌های فیزیکی از معادله دیفرانسیل جزئی جرم و انتقال جریان تشکیل شده‌اند. اگرچه مدل‌های فیزیکی از دقیق ترین مدل‌های پیش بینی هستند، اما پیچیدگی در حل معادلات و ترکیب و وابستگی به مفروضات ساده کننده مختلف، کاربرد آن‌ها را در مسائل مهندسی عملی محدود می‌کند [3]. مدل‌های عددی که تقریباً گسترده‌ترین رویکرد در سال‌های اخیر هستند، بر اساس حل جابجایی جرم و جریان با استفاده از روش‌های محاسبه عددی و برنامه نویسی رایانه‌ای ساخته شده‌اند [4]. علیرغم محبوبیت این رویکرد، به ویژه در سال‌های اخیر، این مدل‌ها نیازمند دانش در کاربرد، محدودیت‌ها و توانایی‌های طرح‌ها و تکنیک‌های عددی مختلف است. علاوه بر این، مدل‌های عددی به مهارت بالا در برنامه‌نویسی کامپیوتری و سرعت محاسبات بالا نیاز دارند [5]. کلاس دیگری از روش پیش بینی SSL به اندازه گیری تجربی بستگی دارد و به عنوان روش‌های تجربی شناخته می‌شود. محبوب ترین این رویکرد، روش منحنی سنج‌های رسوب می‌باشد. در این رویکرد، معمولاً از یک مدل رگرسیون برای ایجاد رابطه بین دی و SSL استفاده می‌شود [6]. با این حال، روش منحنی‌های رتبه بندی رسوب دارای برخی محدودیت‌های روش شناختی است. همچنین، یک الزام اساسی برای این رویکرد در دسترس بودن داده‌های تجربی با کیفیت بالا است که در فرآیند برازش منحنی استفاده می‌شود [7]. بنابراین نیاز به توسعه یک مدل دقیق و قابل اعتماد برای پیش بینی بار معلق رسوب وجود دارد.

مدل‌های هوش مصنوعی در سال‌های اخیر قابلیت‌های متعددی را برای پیش بینی پارامترها و متغیرهای هیدرولوژیکی از جمله بار معلق رسوب (SSL) نشان داده‌اند [8]. این مدل‌ها قادر به پیش بینی یک رویداد بدون نیاز به درک عمیق از فرآیند پیچیده آن رویداد هستند و با دریافت داده‌های ورودی، روابط پیچیده و غیر خطی بین ورودی و خروجی را تشخیص می‌دهند [9]. انعطاف پذیری، سادگی و جفت شدن با نرم افزارهای مختلف از دیگر ویژگی‌های مدل‌های هوش مصنوعی می‌باشند [10]. در سال‌های اخیر، شبکه‌های عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) [12] و رگرسیون بردار پشتیبان (SVR) برای پیش بینی SSL استفاده شده‌اند [11]. روش SVR ساختار ساده‌ای دارد. در نتیجه، از روش SVR می‌توان در مسأله پیش بینی به راحتی استفاده کرد [13]. اما برای مجموعه داده‌های بزرگ نامناسب و وقتی ویژگی‌ها (متغیرهای ورودی) بیشتر باشند، پیچیدگی‌های محاسباتی آن بیشتر می‌شود [14]. در مقابل شبکه‌های عصبی مصنوعی برای مجموعه داده‌های بزرگ و ویژگی‌های زیاد مناسب هستند [15].

در حالی که مدل‌های هوش مصنوعی برای پیش بینی متغیرهای هیدرولوژیکی بسیار مورد توجه هستند، این مدل‌ها نیاز به تنظیم


پارامترهای خود دارند [10]. الگوریتم‌های بهینه سازی فراابتکاری از قبیل الگوریتم ازدحام ذرات (PSO)، الگوریتم ژنتیک (GA)، الگوریتم (ALO)، الگوریتم خفاش (BA)، الگوریتم کوسه [17]، [16]، [10] برای آموزش مدل‌های هوش مصنوعی استفاده شده‌اند تا پارامتر بهینه آنها تعیین شود. تا آنجا که ما می‌دانیم، هیچ تلاش قبلی برای استفاده از یک مدل ترکیبی ANN-OTLBO بر مبنای بهینه سازی مبتنی بر ناظر، معلم، یادگیرنده (OTLBO) برای پیش بینی SSL انجام نشده است. در این تحقیق اقدام به تدوین مدل ترکیبی جدید ANN-OTLBO شده است. همچنین به دلیل کمبود اطلاعات در مورد داده‌های بار معلق رسوب در برخی از حوضه‌های آبریز ایران، اطلاعات رسوبات پیوسته در دسترس نیست. با این حال، داده‌های بارندگی و دی رودخانه به صورت سری زمانی در دسترس است. بنابراین، یک مجموعه داده از بارندگی و دی رودخانه به عنوان پیش بینی کننده برای شبیه سازی SSL های انتخاب شده، بر اساس رویدادهای مشاهده شده موجود، استفاده می‌شود. مدل ترکیبی ANN-PSO برای مقایسه عملکرد مدل پیشنهادی نیز به کار گرفته شده است. اهداف اصلی این مطالعه به شرح زیر است: (۱) در نظر گرفتن یک مدل هوش مصنوعی ترکیبی جدید (ANN-OTLBO) برای برآورد بار معلق رسوب (۲) ارزیابی پیش بینی پذیری مدل توسعه یافته در یکی از رودخانه‌های ایران (به عنوان مثال، رودخانه چم سیاه) با وجود کمبود اطلاعات رسوب (۳) توسعه یک مدل پیش بینی با استفاده از دی رودخانه و بارندگی به عنوان عوامل اصلی در بار رسوب معلق.

مواد و روش‌ها

برای بررسی عملکرد مدل‌های پیشنهادی، حوضه آبریز رودخانه چم سیاه در استان کهگیلویه و بویراحمد، جنوب غرب ایران، به عنوان منطقه مورد مطالعه مورد استفاده قرار می‌گیرد. حوضه آبریز چم سیاه، که در شکل ۱ نشان داده شده است، ۷۹۳ کیلومتر مربع مساحت دارد. متوسط بارندگی سالانه و دی رودخانه حوضه آبریز ۶۲۳.۵ میلی متر و ۸۰.۲ متر مکعب بر ثانیه است. حداقل و حداکثر ارتفاعات آن ۶۰۰ تا ۱۵۰۰ متر است. شیب متوسط حوضه فرعی ۲۶/۹٪، و حجم رسوب سالانه ۳۲۸۷۱۱ تن در سال است.

داده‌های هیدرولوژیکی روزانه حوضه، شامل دی، بارندگی و SSL ثبت شده از ۱۹۸۶ تا ۲۰۱۵، برای مدل سازی پیش بینی استفاده می‌شود. داده‌های بارندگی روزانه از دو باران سنج، ایستگاه سید آباد، که در ارتفاع ۶۹۰ متر واقع شده است، و دهدشت، که در ارتفاع ۸۴۰ واقع شده است، بدست می‌آید. علاوه بر این، داده‌های روزانه دی رودخانه و رسوبات ایستگاه سید آباد، که در ارتفاع ۶۶۳ متر واقع شده است، ارائه می‌شود. سپس همه داده‌ها از $x \in [a, b]$ به $x' \in [0, 1]$ مجدداً مقیاس بندی می‌شوند و مقدار آنها با استفاده از معادله زیر نرمال سازی می‌شوند:

$$\hat{x} = \frac{x-a}{b-a} \quad (1)$$



شکل ۲- ساختار شماییک یک شبکه عصبی چند لایه پرسپترون

الگوریتم‌های بهینه سازی


برای بهینه کردن پارامترهای شبکه عصبی پرسپترون چند لایه از قبیل تعداد نورون‌ها، مقدار epoch و gradient min در فاز آموزش از الگوریتم‌های بهینه سازی PSO و OTLBO استفاده شده است که در ادامه به توضیح مختصر این دو الگوریتم می‌پردازیم:

الگوریتم بهینه سازی OTLBO

الگوریتم OTLBO یک روش بهینه سازی فراابتکاری قوی است که ابتدا توسط شاهروزی و همکاران معرفی شد [18]. در سال‌های اخیر مورد توجه پژوهشگران قرار گرفته است [20], [19]. اولین مرحله به صورت تصادفی بین فاز معلم و یا فاز ناظر فعال می‌شود. در فاز معلم هدف، بهبود متوسط سطح نمرات دانش آموزان (جمعیت) توسط معلم است و یک راه حل جدید ایجاد می‌شود. در فاز ناظر، اطلاعات همکلاسی‌ها (جمعیت)، به طور تصادفی از دانش آموزان مختلف گرفته می‌شود تا راه حل جدیدی به نام ناظر ایجاد شود. در مرحله بعدی یادگیری از طریق تعامل بین خود دانش آموزان است که فاز یادگیرنده نامیده می‌شود. نخبه گرایی که برای جلوگیری از دست دادن بهترین راه حل‌های تاکنون، با استفاده از تکرار روش جستجو ارائه شده است. مناسبترین راه حل‌های نسل جدید از طریق مکانیسم فاز معلم، ناظر و یادگیرنده در هر تکرار مقایسه و به روز می‌شوند. جزئیات بیشتر OTLBO توسط شاهروزی و همکاران ارائه شده است [18].

الگوریتم بهینه سازی PSO

الگوریتم PSO از حرکت دسته جمعی پرندگان الهام گرفته است. در این رویکرد رفتار هر فرد یا از بهترین محلی یا از بهترین فرد جهانی متأثر می‌شود. این رویکرد از مفهوم جمعیت و اندازه گیری عملکرد شبیه به ارزش تناسب استفاده شده با الگوریتم‌های تکاملی، استفاده می‌کند. همچنین، PSO به افراد امکان می‌دهد از تجربیات گذشته خود استفاده کنند. در نتیجه عوامل جستجو امکان جستجوی گسترده تری را در



شکل ۱- موقعیت محدوده مورد مطالعه در استان و حوضه آبریز در فاز آموزش مدل‌های ترکیبی، پارامترهای شبکه عصبی مصنوعی (تعداد نورون‌ها، مقدار epoch و gradient min) به عنوان متغیر تصمیم در نظر گرفته می‌شوند. برای یافتن بهترین مقادیر متغیرهای تصمیم الگوریتم‌های بهینه سازی OTLBO, PSO به کار گرفته می‌شوند. سپس ANN اقدام به تخمین بار معلق رسوب می‌کند. این مراحل تا ارضای معیار خاتمه فاز آموزش تکرار می‌شوند. در فاز آزمایش مدل‌های تدوین شده بر اساس بهترین جواب بدست آمده، اقدام به برآورد بار رسوب معلق می‌کنند. در انتها عملکرد مدل‌های پیش بینی با چهار معیار ارزیابی می‌شود. جزئیات بیشتر روش ANN، الگوریتم‌های بهینه سازی و روش بهبود یافته ANN در ادامه توضیح داده شده است.

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی شامل اتصالات داخلی مجموعه‌ای از نورون‌های مصنوعی است که با استفاده از آنها به پردازش و محاسبه اطلاعات کاربردی می‌پردازد. ایده اصلی این گونه شبکه‌ها تا حدودی الهام گرفته از شیوه کارکرد سیستم عصبی زیستی برای پردازش داده‌ها و اطلاعات به منظور یادگیری و ایجاد دانش قرار دارد. در این تحقیق از شبکه عصبی پرسپترون چند لایه (MLP) استفاده شده است. مدل MLP عمدتاً از سه لایه (یک لایه ورودی، لایه‌های پنهان و یک لایه خروجی) تشکیل شده است. ساختار یک MLP در شکل ۲ آورده شده است.

فضای جستجو دارند. جزئیات بیشتر PSO توسط ابرهات و همکاران ارائه شده است [21].

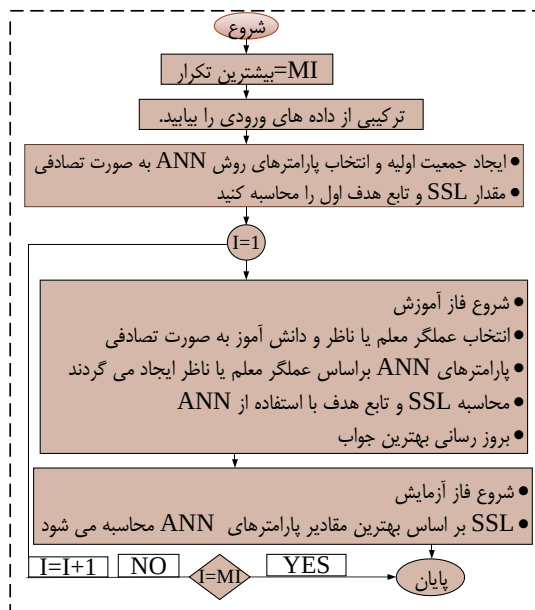
مدل های ترکیبی ANN

همانطور که ذکر شد، پارامترهای ANN، از جمله مقدار تعداد نورون ها، epoch و gradient min، متغیرهای تصمیم گیری در نظر گرفته می شوند که باید از طریق OTLBO یا PSO در یک تابع هدف بهینه شوند. در مورد ANN-OTLBO، توسعه فرآیند از مراحل زیر تشکیل شده است:

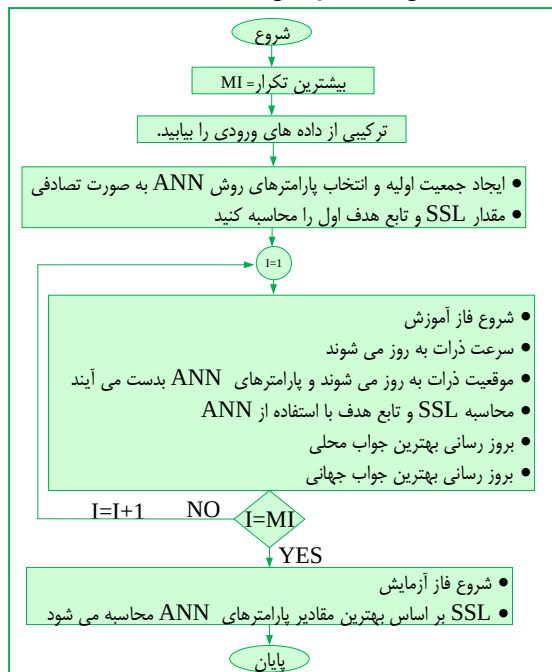
۱. مقادیر اولیه متغیرهای تصمیم به طور تصادفی تعیین می شوند.
۲. جمعیت اولیه تعیین می شوند.
۳. مدل ANN مقادیر رسوب را بر اساس داده های آموزش پیش بینی می کند. مقدار تابع هدف که ضریب همبستگی بین مقادیر رسوب مشاهده شده و پیش بینی شده در این مطالعه است، محاسبه می شود.
۴. مرحله معلم یا ناظر به طور تصادفی برای تعیین پارامترهای ANN (متغیرهای تصمیم) انتخاب می شود. سپس، راه حل جدید بدست می آید و با بهترین راه حل مقایسه می شود.
۵. مرحله یادگیرنده شروع می شود، و بر اساس آن متغیرهای تصمیم انتخاب می شوند و راه حل جدید بدست می آید و با بهترین راه حل مقایسه می شود.

۶. بهترین راه حل به روز می شود.
 ۷. مراحل ۴ تا ۶ تا ارضای معیار خاتمه تکرار می شود.
- الگوریتم گام به گام فوق مدل ANN-OTLBO برای پیش بینی SSL در شکل ۳ ارائه شده است. مدل ترکیبی دوم بر اساس روش ANN-PSO است. مراحل زیر برای توسعه مدل استفاده می شود:

۱. جمعیت اولیه الگوریتم PSO به همراه متغیرهای تصمیم به صورت تصادفی تعیین می شوند.
 ۲. مدل ANN مقادیر رسوب را بر اساس داده های آموزش پیش بینی می کند. مقدار تابع هدف، ضریب همبستگی بین مقادیر رسوب مشاهده شده و پیش بینی شده، مدل محاسبه می شود.
 ۳. مقدار سرعت velocity و موقعیت position ذرات که مقدار بهینه سه پارامتر روش شبکه عصبی مصنوعی می باشد، محاسبه می شود.
 ۴. بهترین راه حل به روز می شود.
 ۵. مراحل ۳ تا ۴ تا برآوردن معیار خاتمه تکرار می شود.
- الگوریتم مدل ANN-PSO برای پیش بینی SSL در شکل ۴ نشان داده شده است.



شکل ۳- ساختار مدل ANN-OTLBO



شکل ۴- ساختار مدل ANN-PSO

ارزیابی توانایی پیش بینی مدل ها

چهار شاخص برای ارزیابی توانایی پیش بینی مدل های ANN-PSO، ANN-OTLBO و ANN استفاده می شود. این شاخص ها از ضریب همبستگی پیرسون (R) (مقدار بیشتر R نشان دهنده دقت بیشتر در پیش بینی)، ریشه میانگین مربعات خطا (RMSE) (مقدار کمتر RMSE نشان دهنده دقت بیشتر در پیش بینی)، سوگیری درصدی (PBIAS)، مقدار کمتر PBIAS نشان دهنده دقت بیشتر در پیش بینی [22] و کارایی نش-ساتکلیف (NSE) (مقدار بیشتر NSE نشان دهنده دقت بیشتر در پیش بینی) [23]، تشکیل شده است که به شرح زیر می باشند:

یعنی M1 تا M5 در جدول ۲ آورده شده است. دبی رودخانه از طریق دو ترکیب (M1) و (M2) نادیده گرفته می‌شود تا تأثیر سایر متغیرهای پیش‌بینی‌کننده بر عملکرد مدل‌ها ارزیابی شود.

جدول ۱- همبستگی بین متغیرهای ورودی و SSL

متغیر	R	متغیر	R	متغیر	R
Q _{s(t)}	0.5	R _{d(t)}	0.5	R _{s(t)}	0.5
Q _{s(t-1)}	0.2	R _{d(t-1)}	0.3	R _{s(t-1)}	0.3
Q _{s(t-2)}	0.2	R _{d(t-2)}	0.1	R _{s(t-2)}	0.2
Q _{s(t-3)}	0.0	R _{d(t-3)}	0.1	R _{s(t-3)}	0.0
Q _{s(t-4)}	0.0	R _{d(t-4)}	0.0	R _{s(t-4)}	0.0
		R _{d(t-5)}	0.0	R _{s(t-5)}	-
		R _{d(t-6)}	0.0	R _{s(t-6)}	0.0

R_d مربوط به ایستگاه باران سنجی دهدشت، R_s مربوط به ایستگاه باران سنجی سیدآباد

جدول ۲- ترکیب‌های ورودی مورد استفاده مدل‌های

پیش‌بینی

Input	Input variables				
M1	R _{s(t)}	-	-	-	-
M2	R _{s(t)}	R _{d(t)}	-	-	-
M3	R _{s(t)}	R _{d(t)}	Q _{s(t)}	-	-
M4	R _{s(t)}	R _{d(t)}	Q _{s(t)}	R _{d(t-1)}	-
M5	R _{s(t)}	R _{d(t)}	Q _{s(t)}	R _{d(t-1)}	R _{s(t-1)}

ارزیابی عملکرد مدل‌ها

برای مقایسه عملکرد پیش‌بینی مدل‌های مورد استفاده در این مطالعه مقادیر شاخص‌های آنها برای ترکیب‌های ورودی مختلف در مرحله آزمایش در جدول ۳ ارائه شده است.

جدول ۳- شاخص‌های عملکرد مدل‌های پیش‌بینی به دست آمده در مرحله آزمایش

Model	R	RMSE	PBIAS	NSE
ANN-OTLBO-M1	-۰/۸۴۰۵۷	۵۷۲/۷۲	۲۴/۳۱۱۴	-۰/۶۳۶۸۶
ANN-OTLBO-M2	-۰/۸۸۵۷۱	۴۷۲/۶۶	۸/۳۲۵۷	-۰/۷۵۴۳۸
ANN-OTLBO-M3	-۰/۹۳۳۲۳	۳۴۲/۷۹	۴/۲۹۷۳	-۰/۸۷۰۰۶
ANN-OTLBO-M4	-۰/۹۴۹۱۹	۳۰۱/۸۵	-۵/۹۸۳۲	-۰/۸۹۹۳۸
ANN-OTLBO-M5	۰/۹۶۳۵۸	۲۵۸/۱۴	-۲/۶۷۵۲	۰/۹۲۶۷۴
ANN-PSO-M1	-۰/۸۲۱۴۹	۶۹۰/۶۷	-۳۱/۸۱۳۶	-۰/۴۷۵۵۶
ANN-PSO-M2	-۰/۸۶۷۲۰	۵۴۰/۳۵	-۲۸/۵۹۸۷	-۰/۶۷۸۹۹
ANN-PSO-M3	-۰/۹۰۴۶۵	۴۱۸/۴۱	-۲۷/۹۴۵۰	-۰/۸۰۷۵۳
ANN-PSO-M4	-۰/۹۰۹۲۵	۴۱۴/۸۵	-۲۳/۶۳۳۰	-۰/۸۱۰۷۹
ANN-PSO-M5	۰/۹۲۴۷۶	۳۷۱/۱۰	-۲۱/۲۶۶۷	۰/۸۴۸۵۹
ANN-M1	-۰/۷۶۰۹۷	۶۳۹/۴۸	-۳۲/۵۵۲۱	-۰/۵۵۴۰۱
ANN-M2	-۰/۷۸۴۵۲	۶۱۸/۴۵	-۴۲/۶۳۰۰	-۰/۵۷۹۴۹
ANN-M3	-۰/۸۲۵۴۴	۶۳۰/۹۰	-۳۷/۷۶۶۹	-۰/۵۶۲۳۹
ANN-M4	-۰/۸۵۶۱۱	۵۲۴/۹۷	-۳۰/۳۵۲۳	-۰/۶۹۷۰۰
ANNM5	۰/۸۸۲۹۲	۴۸۶/۳۱	-۳۴/۵۶۳۱	۰/۷۳۹۹

$$R = \left[\frac{\sum_{i=1}^m (O_i - O_m)(X_i - X_m)}{\sqrt{\sum_{i=1}^m (O_i - O_m)^2 \sum_{i=1}^m (X_i - X_m)^2}} \right] \quad (2)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - O_i)^2} \quad (3)$$

$$PBIAS = 100 \times \left[\frac{\sum_{i=1}^m (O_i - X_i)}{\sum_{i=1}^m X_i} \right] \quad (4)$$

$$NSE = 1.0 - \left[\frac{\sum_{i=1}^m (O_i - X_i)^2}{\sum_{i=1}^m (O_i - \bar{O})^2} \right] \quad (5)$$

که O_i و X_i به ترتیب بار رسوب معلق (SSL) مشاهداتی و محاسباتی هستند، X_m میانگین بار معلق رسوب محاسباتی، O_m میانگین بار معلق رسوب مشاهداتی و m تعداد نمونه‌های SSL می‌باشند.


نتایج

شرح ترکیبات ورودی

بررسی بهترین ترکیبات ورودی برای پیش‌بینی متغیر هدف در اولین قدم ضروری است. همبستگی پیرسون یک روش ساده، موثر و مناسب برای تخمین متغیرهای ورودی است. در اینجا، ترکیبات ورودی با محاسبه همبستگی بین SSL در روز مبدا t و متغیرهای ورودی، از جمله دبی رودخانه (Q_s) از روز مبدا تا چهار روز قبل ($t-4$) و میزان بارش (R_s) و (R_d) از روز مبدا تا شش روز زودتر ($t-6$) بدست می‌آیند.

جدول ۱ ضرایب همبستگی به دست آمده بین $SSL(t)$ و متغیرهای ورودی را نشان می‌دهد. همانطور که در جدول نشان داده شده است. بیشترین همبستگی بین $SSL(t)$ و متغیرهای ورودی در پنج متغیر $R_s(t)$ ، $R_d(t)$ ، $Q_s(t)$ ، $R_d(t-1)$ و $R_s(t)$ یافت می‌شود. چندین ترکیب ورودی با استفاده از متغیرهای معرفی شده توسط تجزیه و تحلیل همبستگی،

همچنین مقادیر R^2 برای مدل‌های انتخاب شده گزارش شده است. بر اساس شکل ۶، مشخص است که مدل‌های هیبریدی به طور کلی نسبت به مدل ANN به بهترین خط نزدیک تر هستند. علاوه بر این، ANN-OTLBO-M5 بالاترین مقادیر R^2 را در هر دو مرحله آموزش $R^2 = 0.94522$ و آزمون $R^2 = 0.92849$ ارائه می‌دهد.




شکل ۶- نمودار Scatterplot (a) فاز آموزش (b) فاز آزمون

برای بررسی تغییرات داده‌های پیش‌بینی شده، از نمودار جعبه (Box plot) استفاده می‌شود. نمودار جعبه‌ای از SSL پیش‌بینی شده برای مدل‌های انتخاب شده در شکل ۷ نشان داده شده است. از لحاظ بصری بر اساس شکل ۷، داده‌های پیش‌بینی شده مدل ANN-OTLBO-M5 به داده‌های مشاهداتی شبیه‌تر و کمترین تغییرات را نسبت به آن دارد. از لحاظ کمی، حداقل و حداکثر SSL_{25} به ترتیب در داده‌های مشاهده شده ($SSL_{25}=63/833$) و مدل ANN-PSO-M4 ($SSL_{25}=132/688$) می‌باشند. تفاوت نسبی بین داده‌های مشاهده شده و مدل‌های انتخابی به ترتیب ۸۵/۴٪، ۱۲/۱٪ و ۱۰۷/۸٪ است که مربوط به ANN-، ANN-M5 و ANN-OTLBO-M5 است. اختلاف نسبی در SSL_{50} بین داده‌های رسوب مشاهداتی و داده‌های رسوب پیش‌بینی شده به ترتیب برابر ۱۱۵/۱٪، ۲۲/۹۷٪ و ۱۱۵/۶٪ است که مربوط به ANN-، ANN-M5 و ANN-OTLBO-M5 می‌باشند. همچنین در مورد SSL_{75} مقادیر به ترتیب برابر (۱۵۶/۶۶۵، ۲۱۵/۰۶۷، ۱۶۲/۰۸۸، ۲۴۰/۹۲۹ میلی گرم بر لیتر) مربوط به داده‌های مشاهداتی، ANN-M5، ANN-OTLBO-M5 و ANN-PSO-M5 می‌باشند. بنابراین نزدیک‌ترین داده‌های پیش‌بینی شده به داده‌های مشاهداتی بر اساس نتایج کمی و شکل ۷ متعلق به مدل ANN-OTLBO-M5 است.

بر اساس جدول ۳ برای مدل ANN-OTLBO بهترین عملکرد مربوط به ANN-OTLBO-M5 می‌باشد ($NSE = 0.92674$ ، $NSE = -2/6752$ ، $R = 0.96358$ ، $RMSE = 258/14$ ، $PBIAS = 371/1$) گزارش شده در جدول ۳ نشان می‌دهد که کمترین مقدار ($RMSE = 371/1$) و بالاترین ($PBIAS = -211/2667$) و ($R = 0.92674$) و ($NSE = 0.92674$) در مدل ANN-PSO-M5 مشاهده می‌شود. در مورد مدل ANN بهترین عملکرد سه شاخص متعلق به مدل ANN-M5 ($NSE = 0.7399$) و شاخص ($PBIAS = -34/5631$) متعلق به مدل ANN-M4 می‌باشد. بنابراین در هر سه روش، ترکیب ورودی M5، که شامل $Rs(t)$ ، $Rd(t)$ ، $Qs(t)$ ، $Rd(t-1)$ و $Rs(t-1)$ بهترین ترکیب برای پیش‌بینی $SSL(t)$ است. از این رو، مدل‌های پیش‌بینی، ANN-OTLBO-M5، ANN-PSO-M5 و ANN-M5 برای ارزیابی بیشتر انتخاب می‌گردند.

برای یافتن بهترین مدل در بین تمامی مدل‌های معرفی شده در مطالعه حاضر، نمودار Heat map (شکل ۵) به عنوان ابزار مقایسه بصری استفاده شده است. نمودار از معیارهای مختلف نرمال سازی شده برای مقایسه سلول‌ها با مقادیر یک و صفر استفاده می‌کند که به ترتیب نشان دهنده بالاترین و کمترین عملکرد است. شکل ۵ نشان می‌دهد که ANN-OTLBO-M5 بهترین عملکرد را در هر دو مرحله آموزش و آزمون دارد.



شکل ۵- نمودار Heat map (a) فاز آموزش (b) فاز آزمون

برای بررسی بیشتر عملکرد مدل‌ها، نمودارهای Scatterplot بار رسوب معلق برآورد شده با استفاده از مدل‌ها و بار رسوب اندازه‌گیری شده در شکل ۶ برای هر دو مرحله آموزش و آزمون نشان داده شده است.

بهترین عملکرد مدل‌ها استفاده شد. به طور کلی یافته‌های زیر در این تحقیق به دست آمده است:

۱. در بین تمامی مدل‌های ANN، عملکرد ANN-M5 بالاترین عملکرد را دارد. ANN-OTLBO-M5 بهترین عملکرد را در مقایسه با سایر مدل‌های ANN-OTLBO دارد و ANN-PSO-M5 بهترین مدل در بین تمام مدل‌های ANN-PSO است.

۲. در میان مدل‌هایی با بالاترین عملکرد، ANN-OTLBO-M5 بالاترین عملکرد را در هر دو مرحله تست و آموزش دارد.

۳. داده‌های پیش‌بینی شده مدل‌های ترکیبی در مقایسه با داده‌های خروجی مدل ANN به داده‌های مشاهده‌ای نزدیک‌تر است. علاوه بر این، ANN-OTLBO-M5 نزدیک‌ترین مدل پیش‌بینی شده با داده‌های مشاهده‌ای است.

پیشنهادهای


با وجود نتایج امیدوارکننده این مطالعه، برخی محدودیت‌ها و زمینه‌های قابل توجه برای تحقیقات آینده وجود دارد. نخست آن‌که مدل توسعه‌یافته تنها بر اساس داده‌های یک حوضه آبریز آموزش دیده و اعتبارسنجی شده است. بنابراین، برای بررسی قابلیت تعمیم‌پذیری و پایداری عملکرد مدل، توصیه می‌شود از داده‌های حوضه‌های مختلف با شرایط اقلیمی و هیدرولوژیکی متفاوت استفاده شود. از طرفی، در مدل حاضر، عدم قطعیت‌های موجود در متغیرهای ورودی مانند بارش و دبی لحاظ نشده‌اند. پیشنهاد می‌شود در پژوهش‌های بعدی، تحلیل حساسیت و تحلیل عدم قطعیت به منظور افزایش قابلیت اطمینان مدل‌سازی لحاظ شود.

از منظر کاربردی، مدل پیشنهادی می‌تواند در پایش و پیش‌بینی رسوب در زمان واقعی، برنامه‌ریزی بهره‌برداری سدها، مدیریت رسوب‌زدایی، و طراحی سازه‌های کنترل فرسایش و رسوب مورد استفاده قرار گیرد. همچنین، در حوزه مدیریت حوضه‌های آبخیز و سامانه‌های هشدار سیل و رسوب، این مدل می‌تواند نقش موثری ایفا کند.

انتخاب ویژگی بر اساس روش‌های همبستگی به دلیل پیچیدگی پدیده‌های هیدرولوژیکی مانند رسوب، رویکرد ناکافی است. استفاده از الگوریتم‌های فراابتکاری روشی مناسب در انتخاب ویژگی‌ها و یافتن بهترین ترکیب‌های ورودی است. این محدودیت را می‌توان در آینده با توسعه یک مدل بهینه‌سازی چند هدفه و ترکیب آن با ANN حل کرد. افزون بر این، توسعه مدل با افزودن داده‌های تکمیلی مانند اطلاعات سنجش از دور، نوع خاک، پوشش گیاهی یا تغییرات کاربری اراضی، می‌تواند دقت پیش‌بینی را در شرایط محیطی پیچیده افزایش دهد. در نهایت، به کارگیری الگوریتم‌های بهینه‌سازی چندهدفه و معماری‌های یادگیری عمیق مانند LSTM، می‌تواند چشم‌اندازهای جدیدی برای بهبود عملکرد و کاربردپذیری مدل فراهم آورد.

ملاحظات اخلاقی پیروی از اصول اخلاق پژوهش

همکاری مشارکت‌کنندگان در تحقیق حاضر به صورت داوطلبانه و با رضایت آنان بوده است.



شکل ۷- نمودار جعبه‌ای داده‌های مشاهداتی و پیش‌بینی شده بار رسوب معلق

بحث و نتیجه‌گیری

بر اساس نتایج بدست آمده ترکیب شبکه‌های عصبی مصنوعی با روش‌های فراابتکاری، عملکرد برتری نسبت به روش شبکه عصبی مصنوعی بدون ترکیب دارند. همچنین عوامل جستجوی الگوریتم OTLBO امکان جستجوی گسترده تری را در فضای جستجو دارند و در نتیجه عملکرد مدل ANN-OTLBO بهتر از مدل‌های دیگر می‌باشد. مدل ANN-OTLBO مقادیر شاخص R را با دقت بسیار بالایی بدست می‌آورند. شاخص R به مقادیر بزرگ حساس‌تر است تا مقادیر کوچک [24]. بنابراین مدل ANN-OTLBO در تخمین مقادیر رسوب‌های زیاد و خیلی زیاد بسیار دقیق می‌باشد. علامت شاخص PBIAS در هر سه مدل منفی است که نشان دهنده تخمین بیش از حد تر مدل‌ها نسبت به داده‌های مشاهداتی رسوب است. عملکرد مناسب شاخص PBIAS تخمین زیر ۱۵٪ است [25]. بنابراین مدل ANN-OTLBO در تخمین مقادیر رسوب کم نیز دقیق است. اگر چه مدل ترکیبی جدید توسعه یافته در مطالعه حاضر، SSL را با موفقیت پیش‌بینی می‌کند، مقایسه عملکرد آن با نتایج به دست آمده در مطالعات دیگر جالب است. کومار و همکاران از ANN، رگرسیون چند خطی MLR، طبقه‌بندی و درخت رگرسیون CART برای پیش‌بینی SSL استفاده کرد که مقدار R^2 برای مدل‌های مذکور به ترتیب ۰/۹۱ و ۰/۹۱ بدست آمد [26]. بنابراین، می‌توان دریافت که مدل‌های ترکیبی گزارش شده در این تحقیق عملکرد پیش‌بینی بهتری در مقایسه با مدل‌های شبکه عصبی در تحقیق کومار دارند.

مطالعه حاضر بر توسعه یک مدل ترکیبی برای تخمین بار رسوب معلق متمرکز شده است. برای این منظور از داده‌های هیدرومتری و باران سنجی حوضه رودخانه چم سیاه متشکل از داده‌های دبی رودخانه، بار رسوب معلق و بارش استفاده شده است. برای پیش‌بینی SSL از روش شبکه‌های عصبی مصنوعی استفاده شد. برای تنظیم پارامترهای روش شبکه عصبی پرسپترون دو مدل ترکیبی توسعه یافته‌اند. این مدل‌های ترکیبی از ANN-PSO و ANN-OTLBO تشکیل شده‌اند. در این مطالعه، پنج ترکیب ورودی مورد بررسی قرار گرفت، همچنین برای هر مدل ANN، ANN-OTLBO و ANN-PSO پنج مدل پیش‌بینی طراحی شد. از شاخص‌های R، RMSE، PBIAS و NSE برای تعیین

تعارض منافع

بنابر اظهار نویسندگان، مقاله حاضر فاقد هرگونه تعارض منافع بوده است.

مشارکت نویسندگان

طراحی و ایده پردازی: سیامک درودی، احمد شرافتی؛
روش شناسی و تحلیل داده ها: سیامک درودی، احمد شرافتی؛

References

- [1] B. Choubin, H. Darabi, O. Rahmati, F. Sajedi-Hosseini, and B. Kløve, "River suspended sediment modelling using the CART model: A comparative study of machine learning techniques," *Sci. Total Environ.*, vol. 615, pp. 272–281, Feb. 2018, doi: 10.1016/j.scitotenv.2017.09.293.
- [2] M. Y. A. Khan, F. Tian, F. Hasan, and G. J. Chakrapani, "Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India," *Int. J. Sediment Res.*, vol. 34, no. 2, pp. 95–107, Apr. 2019, doi: 10.1016/j.ijsrc.2018.09.001.
- [3] O. Kisi, "Modeling discharge-suspended sediment relationship using least square support vector machine," *J. Hydrol.*, vol. 456–457, pp. 110–120, Aug. 2012, doi: 10.1016/j.jhydrol.2012.06.019.
- [4] B. Greimann, Y. Lai, and J. Huang, "Two-Dimensional Total Sediment Load Model Equations," *J. Hydraul. Eng.*, vol. 134, no. 8, pp. 1142–1146, Aug. 2008, doi: 10.1061/(ASCE)0733-9429(2008)134:8(1142).
- [5] M. H. Garcia, "Sedimentation engineering: processes, measurements, modeling and practice. ASCE Manuals and Reports on Engineering Practice No. 110. American Society Civil Engineering Publications, Reston, VA, 1150 pp. ISBN 9780784408148," no. 110, p. 2008, 2008.
- [6] N. E. M. Asselman, "Fitting and interpretation of sediment rating curves," *J. Hydrol.*, vol. 234, no. 3–4, pp. 228–248, Jul. 2000, doi: 10.1016/S0022-1694(00)00253-5.
- [7] K. Vercruysse, R. C. Grabowski, and R. J. Rickson, "Suspended sediment transport dynamics in rivers: Multi-scale drivers of temporal variation," *Earth-Science Reviews*, vol. 166. Elsevier B.V., pp. 38–52, Mar. 01, 2017, doi: 10.1016/j.earscirev.2016.12.016.
- [8] F. Panahi, M. Ehteram, and M. Emami, "Suspended sediment load prediction based on soft computing models and Black Widow Optimization Algorithm using an enhanced gamma test," *Environ. Sci. Pollut. Res.* 2021 2835, vol. 28, no. 35, pp. 48253–48273, Apr. 2021, doi: 10.1007/S11356-021-14065-4.
- [9] S. Q. Salih *et al.*, "River suspended sediment load prediction based on river discharge information: application of newly developed data mining models," *Hydrol. Sci. J.*, vol. 65, no. 4, pp. 624–637, Mar. 2020, doi: 10.1080/02626667.2019.1703186.
- [10] F. B. Banadkooki *et al.*, "Suspended sediment load prediction using artificial neural network and ant lion optimization algorithm," *Environ. Sci. Pollut. Res.* 2020 2730, vol. 27, no. 30, pp. 38094–38116, Jul. 2020, doi: 10.1007/S11356-020-09876-W.
- [11] M. Buyukyildiz and S. Y. Kumcu, "An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models," *Water Resour. Manag.*, vol. 31, no. 4, pp. 1343–1359, Mar. 2017, doi: 10.1007/s11269-017-1581-1.
- [12] A. Sharafati, S. B. Haji Seyed Asadollah, D. Motta, and Z. M. Yaseen, "Application of newly developed ensemble machine learning models for daily suspended sediment load prediction and related uncertainty analysis," *Hydrol. Sci. J.*, pp. 2022–2042, 2020, doi:

- 10.1080/02626667.2020.1786571.
- [13] G. F. Lin, Y. C. Chou, and M. C. Wu, "Typhoon flood forecasting using integrated two-stage support vector machine approach," *J. Hydrol.*, vol. 486, pp. 334–342, Apr. 2013, doi: 10.1016/j.jhydrol.2013.02.012.
- [14] E. Kakaei Lafdani, A. Moghaddam Nia, and A. Ahmadi, "Daily suspended sediment load prediction using artificial neural networks and support vector machines," *J. Hydrol.*, vol. 478, pp. 50–62, Jan. 2013, doi: 10.1016/j.jhydrol.2012.11.048.
- [15] S. Li, Q. Xie, and J. Yang, "Daily suspended sediment forecast by an integrated dynamic neural network," *J. Hydrol.*, vol. 604, p. 127258, Jan. 2022, doi: 10.1016/J.JHYDROL.2021.127258.
- [16] H. A. Afan *et al.*, "Input attributes optimization using the feasibility of genetic nature inspired algorithm: Application of river flow forecasting," *Sci. Reports 2020 101*, vol. 10, no. 1, pp. 1–15, Mar. 2020, doi: 10.1038/s41598-020-61355-x.
- [17] M. F. Allawi, O. Jaafar, M. Ehteram, F. Mohamad Hamzah, and A. El-Shafie, "Synchronizing Artificial Intelligence Models for Operating the Dam and Reservoir System," *Water Resour. Manag.*, vol. 32, no. 10, pp. 3373–3389, Aug. 2018, doi: 10.1007/S11269-018-1996-3.
- [18] M. Shahrouzi, M. Aghabagloua, and F. Rafiee, "Observer-teacher-learner-based optimization: An enhanced meta-heuristic for structural sizing design," *Struct. Eng. Mech.*, vol. 62, no. 5, pp. 537–550, 2017, doi: 10.12989/sem.2017.62.5.537.
- [19] S. H. H. Lavasani and R. Doroudi, "Meta heuristic active and semi-active control systems of high-rise building," *Int. J. Struct. Eng.*, vol. 10, no. 3, pp. 232–253, 2020, doi: 10.1504/IJSTRUCTE.2020.108529.
- [20] S. H. Hosseini Lavassani, S. A. Mousavi Gavani, and R. Doroudi, "Optimal control of jacket platforms vibrations under the simultaneous effect of waves and earthquakes considering fluid-structure interaction," *Ocean Eng.*, vol. 280, p. 114593, Jul. 2023, doi: 10.1016/J.OCEANENG.2023.114593.
- [21] Y. S. J. Kennedy, R. C. Eberhart, *Swarm Intelligence*, First edit. San Francisco: Morgan Kaufmann, 2001.
- [22] D. N. Moriasi, J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, and T. L. Veith, "Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations," *Trans. ASABE*, vol. 50, no. 3, pp. 885–900, 2007, doi: 10.13031/2013.23153.
- [23] J. E. Nash and J. V. Sutcliffe, "River flow forecasting through conceptual models part I — A discussion of principles," *J. Hydrol.*, vol. 10, no. 3, pp. 282–290, Apr. 1970, doi: 10.1016/0022-1694(70)90255-6.
- [24] C. J. Willmott, "On the validation of models," *Phys. Geogr.*, vol. 2, no. 2, pp. 184–194, 1981, doi: 10.1080/02723646.1981.10642213.
- [25] H. H. C. de Salis *et al.*, "Hydrologic Modeling for Sustainable Water Resources Management in Urbanized Karst Areas," *Int. J. Environ. Res. Public Heal. 2019, Vol. 16, Page 2542*, vol. 16, no. 14, p. 2542, Jul. 2019, doi: 10.3390/IJERPH16142542.
- [26] D. Kumar, A. Pandey, N. Sharma, and W. A. Flügel, "Daily suspended sediment simulation using machine learning approach," *Catena*, vol. 138, pp. 77–90, Mar. 2016, doi: 10.1016/j.catena.2015.11.013.