

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 Sharafati^{2, *}

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

Corresponding author: [Ahmad Sharafati](#)

Corresponding email: asharafati@sbiau.ac.ir

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

* نویسنده مسئول: احمد شرافتی

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.

Conclusion: Among all ANN, ANN-OTLBO, and ANN-PSO models, the ANN-OTLBO model has the best performance. The mentioned model can accurately predict high, medium, and low amounts of sediment. Among all ANN, ANN-OTLBO, and ANN-PSO models, the ANN-OTLBO model has the best performance. The mentioned model can accurately predict high, medium, and low amounts of sediment. In addition, the combination of meta-heuristic algorithms with artificial neural networks increases the accuracy of sediment prediction.

Keywords: Suspended sediment load; Optimization algorithm; Artificial neural network,

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.

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).

Results:

According to the results, for the ANN-OTLBO model, the best performance is related to ANN-OTLBO-M5 (NSE=0.92674, PBIAS=-2.6752, RMSE=258.14, R=0.96358). In the case of ANN-PSO, the lowest (RMSE =371.1) and (PBIAS=-21.2667) and the highest (R=0.92476) and (NSE= 0.84859) are observed in the ANN-PSO-M5 model. Regarding the ANN model, the best performance of three indices belongs to the ANN-M5 model (NSE=0.7399, RMSE=486.31, R=0.88292), and the index belonging to the ANN-M4 model (PBIAS=34.5631). Therefore, in all three methods, the input combination M5, which includes $R_{s(t)}$, $R_{d(t)}$, $Q_{s(t)}$, $R_{d(t-1)}$, and $R_{s(t-1)}$, is the best combination for predicting $SSL_{(t)}$. Therefore, the prediction models, ANN-OTLBO-M5, ANN-PSO-M5, and ANN-M5, are selected for further evaluation. The Heat map is used as a visual comparison tool to find the best model among all the models introduced in this study. Based on the Heat map, ANN-OTLBO-M5 performs best in both the training and testing stages. Scatterplot charts have been used to investigate the performance of the models further. Based on the R^2 values, the hybrid models are generally closer to the best line than the ANN model. In addition, ANN-OTLBO-M5 provides the highest R^2 values in the training phase $R^2 = 0.94522$ and testing $R^2 = 0.92849$. A Box plot is used to evaluate the predicted data changes. Visually, based on the shape of the predicted data, the ANN-OTLBO-M5 model is more similar to the observed data and has the most negligible compared modifications to it. Based on the results, combining artificial neural networks with meta-heuristic algorithms has superior performance compared to the artificial neural network method without combination. Also, search agents of the OTLBO algorithm have the possibility of wider search in the search space, and as a result, the performance of the ANN-OTLBO model is better than other models. ANN-OTLBO model can obtain R index values with very high accuracy. Therefore, the ANN-OTLBO model accurately estimates the amounts of high and very high sediments. The sign of the PBIAS index is negative in all three models, which indicates the overestimation of the models compared to the sediment observation data. The appropriate performance of the PBIAS index is estimated to be below 15%. Therefore, the ANN-OTLBO model is also accurate in estimating low sediment values.

Conculotion:

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.

زود بایند و پرایتس نشده

چکیده:

مقدمه: بار رسوب معلق SSL یکی از پدیده‌های پیچیده هیدرولوژیکی است و پیش‌بینی آن دشوار است. در این مطالعه از روش شبکه عصبی مصنوعی جهت پیش‌بینی بار رسوب معلق استفاده شده است. از آنجاییکه دقت عملکرد شبکه‌های عصبی مصنوعی به پارامترهای آن بستگی دارد. استفاده از الگوریتم‌های فراابتکاری می‌تواند در جهت افزایش عملکرد آن‌ها موثر باشد. منطقه مورد مطالعه در حوضه آبریز سد کوثر واقع در جنوب غربی ایران می‌باشد.

روش: دبی رودخانه و بارش به عنوان ویژگی‌های ورودی به مدل‌های پیش‌بینی در نظر گرفته شد. پنج ترکیب ورودی انتخاب شدند. الگوریتم‌های فراابتکاری OTLBO، PSO با شبکه عصبی مصنوعی ترکیب شدند و مدل‌های پیش‌بینی ANN-OTLBO و ANN- PSO تدوین گردید. مدل‌های پیش‌بینی با استفاده از شاخص‌های عددی و بصری مختلف ارزیابی شدند.

یافته‌ها: نتایج نشان می‌دهد که مدل ANN-OTLBO عملکرد پیش‌بینی بالاتری نسبت به سایر مدل‌های بکار رفته در مطالعه حاضر ارائه می‌دهد. مقادیر عبارتند از $R=0.96358$ ، $RMSE=258/14$ ، $PBIAS=-2/6752$ و $NSE=0.92674$ ، و همچنین بر اساس نمودار **Scatter plot** و **Heat map** و **Box plot** نزدیک‌ترین داده‌های پیش‌بینی شده به داده‌های مشاهداتی متعلق به مدل ANN-OTLBO-M5 می‌باشد.

نتیجه‌گیری: در بین تمامی مدل‌های ANN، ANN-OTLBO، ANN-PSO، مدل ANN-OTLBO برترین عملکرد را دارا می‌باشد. مدل مذکور توانسته است مقادیر بالا، متوسط و کم رسوب را با دقت مناسبی پیش‌بینی کند و ترکیب الگوریتم‌های فراابتکاری با شبکه عصبی مصنوعی باعث افزایش دقت پیش‌بینی رسوب می‌شوند.

کلمات کلیدی: "بار رسوب معلق"، "الگوریتم بهینه‌سازی"، "شبکه‌های عصبی مصنوعی"

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 (Choubin et al., 2018). علیرغم اهمیت SSL، به دلیل وابستگی آن به متغیرهای متعدد هیدرولوژیکی و هیدرولیکی، فرآیند ارزیابی بار معلق رسوب بسیار پیچیده است (Khan et al., 2019). 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 دقیق‌ترین 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 (Kisi, 2012). 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 (Greimann et al., 2008). 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 (Garcia, 2008). کلاس دیگری از روش پیش بینی SSL به اندازه گیری تجربی بستگی دارد و به عنوان روش‌های تجربی شناخته می‌شود. محبوب‌ترین این رویکرد، روش منحنی سنج‌های رسوب می‌باشد. در این رویکرد، معمولاً از یک مدل رگرسیون برای ایجاد رابطه بین دبی و SSL استفاده می‌شود (Asselman, 2000). 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 (Verduyck et al., 2017). 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 (Panahi et al., 2021). 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 (Salih et al., 2020). انعطاف پذیری، سادگی و جفت شدن با نرم افزارهای مختلف از دیگر ویژگی‌های مدل‌های هوش مصنوعی می‌باشند (Banadkooki et al., 2020). در سال‌های اخیر، شبکه‌های عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و رگرسیون بردار پشتیبان (SVR) برای پیش بینی SSL استفاده شده‌اند (Buyukyildiz & Kumcu, 2017; Sharafati et al., 2020). روش SVR ساختار ساده‌ای دارد. در نتیجه، از روش SVR می‌توان در مسائل پیش بینی به راحتی استفاده کرد (Lin et al., 2013). اما برای مجموعه داده‌های بزرگ نامناسب و وقتی ویژگی‌ها (متغیرهای ورودی) بیشتر باشند، پیچیدگی‌های محاسباتی آن بیشتر می‌شود (Kakaei

(LafDani et al., 2013). در مقابل شبکه‌های عصبی مصنوعی برای مجموعه داده‌های بزرگ و ویژگی‌های زیاد مناسب هستند (Li et al., 2022).

در حالی که مدل‌های هوش مصنوعی برای پیش‌بینی متغیرهای هیدرولوژیکی بسیار مورد توجه هستند، این مدل‌ها نیاز به تنظیم پارامترهای خود دارند (Banadkooki et al., 2020). الگوریتم‌های بهینه‌سازی فراابتکاری از قبیل الگوریتم ازدحام ذرات (PSO)، الگوریتم ژنتیک (GA)، الگوریتم (ALO)، الگوریتم خفاش (BA)، الگوریتم کوسه (Afan et al., 2020; Allawi et al., 2018; Banadkooki et al., 2020) 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 بهینه‌سازی مبتنی بر ناظر، معلم، یادگیرنده (OTLBO) برای پیش‌بینی 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 دبی رودخانه به صورت سری زمانی در دسترس است. بنابراین، یک مجموعه داده از بارندگی و دبی رودخانه به عنوان پیش‌بینی کننده برای شبیه‌سازی 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 پیش‌بینی پذیری مدل توسعه یافته در یکی از رودخانه‌های ایران (به عنوان مثال، رودخانه چم سیاه) با وجود کمبود اطلاعات رسوب (۳) توسعه یک مدل پیش‌بینی با استفاده از دبی رودخانه و بارندگی به عنوان عوامل اصلی در بار رسوب معلق.

مطالعه موردی و گردآوری داده‌ها

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 دبی رودخانه حوضه آبریز ۶۲۳.۵ میلی‌متر و ۸.۰۲ 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 دبی، بارندگی و SSL ثبت شده از ۱۹۸۶ تا ۲۰۱۵، برای مدل‌سازی پیش‌بینی استفاده می‌شود. داده‌های بارندگی روزانه از دو باران سنج، ایستگاه سیدآباد، که در ارتفاع ۶۹۰ متر واقع شده است، و دهدشت، که در ارتفاع ۸۴۰ متر واقع شده است، بدست می‌آید. علاوه بر این، داده‌های روزانه دبی رودخانه و رسوبات ایستگاه سیدآباد، 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 نرمال‌سازی می‌شوند:

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

شکل ۱- موقعیت محدوده مورد مطالعه در استان و حوضه‌های آبریز

روش‌ها

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 بهینه‌سازی PSO, OTLBO 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 پیش‌بینی با چهار معیار ارزیابی می‌شود. جزئیات بیشتر روش ANN، الگوریتم‌های بهینه‌سازی 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.

شکل ۲- ساختار شماتیک یک شبکه عصبی چند لایه پرسپترون

الگوریتم‌های بهینه‌سازی

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

الگوریتم بهینه‌سازی OTLBO

الگوریتم OTLBO یک روش بهینه‌سازی فراابتکاری قوی است که ابتدا توسط شاهرزوی و همکاران معرفی شد (Shahrouzi et al., 2017). در سال‌های اخیر مورد توجه پژوهشگران قرار گرفته است (Hosseini Lavassani et al., 2023; Lavasani & Doroudi, 2020). 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 حل های تاکنون، با استفاده از تکرار روش جستجو ارائه شده است. مناسبترین راه حل های 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 (Shahrouzi et al., 2017).

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 متاثر می‌شود. این رویکرد از مفهوم جمعیت و اندازه گیری عملکرد شبیه به ارزش تناسب استفاده شده با الگوریتم های 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 فضای جستجو دارند. جزئیات بیشتر PSO توسط ابرهارت و همکاران ارائه شده است (Eberhart et al., 2001).

مدل های ترکیبی ANN

همانطور که ذکر شد، پارامترهای ANN، از جمله مقدار تعداد نوروها، epoch و gradient min، متغیرهای تصمیم گیری در نظر گرفته می‌شوند 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 می‌شوند.
۲. جمعیت اولیه تعیین می‌شوند.
۳. مدل ANN مقادیر رسوب را بر اساس داده های آموزش پیش بینی می‌کند. مقدار تابع هدف که ضریب همبستگی بین مقادیر رسوب مشاهده شده و پیش بینی شده در این مطالعه است، محاسبه می‌شود.
۴. مرحله معلم یا ناظر به طور تصادفی برای تعیین پارامترهای ANN (متغیرهای تصمیم) انتخاب می‌شود. سپس، راه حل جدید بدست می‌آید و با بهترین راه حل مقایسه می‌شود.

۵. مرحله یادگیرنده شروع می‌شود، و بر اساس آن متغیرهای تصمیم انتخاب می‌شوند و راه حل جدید بدست می‌آید و با بهترین راه حل مقایسه می‌شود.

۶. بهترین راه حل به روز می‌شود.

۷. مراحل ۴ تا ۶ تا ارضای معیار خاتمه تکرار می‌شود.

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 می‌شود:

۱. جمعیت اولیه الگوریتم PSO به همراه متغیرهای تصمیم به صورت تصادفی تعیین می‌شوند.

۲. مدل ANN مقادیر رسوب را بر اساس داده‌های آموزش پیش بینی می‌کند. مقدار تابع هدف، ضریب همبستگی بین مقادیر رسوب مشاهده شده و پیش بینی شده، مدل محاسبه می‌شود.

۳. مقدار سرعت velocity و موقعیت position ذرات که مقدار بهینه سه پارامتر روش شبکه عصبی مصنوعی می‌باشد، محاسبه می‌شود.

۴. بهترین راه حل به روز می‌شود.

۵. مراحل ۳ تا ۴ تا برآوردن معیار خاتمه تکرار می‌شود.

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 مدل‌ها

چهار شاخص برای ارزیابی توانایی پیش بینی مدل‌های ANN-PSO، ANN-OTLBO و ANN استفاده می‌شود. این شاخص‌ها 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) (Moriyasi et al., 2007) و کارایی نش-ساتکلیف (NSE) (مقدار بیشتر NSE نشان دهنده دقت بیشتر در پیش بینی) (Nash & Sutcliffe, 1970)، تشکیل شده است که به شرح زیر می‌باشند:

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

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

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

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

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 نمونه های SSL می باشند.

نتایج و بحث

شرح ترکیبات ورودی

بررسی بهترین ترکیبات ورودی برای پیش بینی 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 می آیند. جدول ۱ ضرایب همبستگی به دست آمده بین $SSL(t)$ و متغیرهای ورودی را نشان می دهد. همانطور که در جدول نشان داده شده است. بیشترین همبستگی بین $SSL(t)$ و متغیرهای ورودی در پنج متغیر $RS(t)$ ، $Rd(t)$ ، $QS(t)$ ، $Rd(t-1)$ و $RS(t)$ یافت می شود. چندین ترکیب ورودی با استفاده از متغیرهای معرفی شده توسط تجزیه و تحلیل همبستگی، یعنی $M1$ تا $M5$ در جدول ۲ آورده شده است. دبی رودخانه از طریق دو ترکیب ($M1$) و ($M2$) نادیده گرفته می شود تا تأثیر سایر متغیرهای پیش بینی کننده بر عملکرد مدل ها ارزیابی شود.

جدول ۱- همبستگی بین متغیرهای ورودی و SSL

جدول ۲- ترکیب های ورودی مورد استفاده مدل های پیش بینی

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

بر اساس جدول ۳ برای مدل ANN-OTLBO بهترین عملکرد مربوط به ANN-OTLBO-M5 می‌باشد ($NSE = 0.92674$) مقدار (RMSE) $258/84$ ، (PBIAS) $-2/6752$ ، ($R=0.96358$) در مورد ANN-PSO، مقادیر گزارش شده در جدول ۳ نشان می‌دهد که کمترین مقدار (RMSE) $(371/1)$ و (PBIAS) $(-21/2667)$ و بالاترین ($R=0.92476$) و ($R=0.84859$) در مدل ANN-PSO-M5 مشاهده می‌شود. در مورد مدل ANN بهترین عملکرد سه شاخص متعلق به مدل ANN-M5 ($NSE = 0.7399$)، ($R=0.88292$)، (RMSE) $486/31$ ، و شاخص (PBIAS) $-34/5631$ متعلق به مدل ANN-M4 می‌باشد. بنابراین در هر سه روش، ترکیب ورودی M5، که شامل $R_{s(t)}$ ، $R_{d(t)}$ ، $Q_{s(t)}$ ، $R_{d(t-1)}$ و $R_{s(t-1)}$ 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 آزمایش دارد.

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

برای بررسی بیشتر عملکرد مدل‌ها، نمودارهای Scatterplot بار رسوب معلق برآورد شده با استفاده از مدل‌ها و بار رسوب اندازه گیری شده در شکل ۶ برای هر دو مرحله آموزش و آزمایش نشان داده شده است. 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 آزمایش $R^2 = 0.92849$ ارائه می‌دهد.

شکل ۶- نمودار Scatter plot (a) فاز آموزش (b) فاز آزمایش

برای بررسی تغییرات داده‌های پیش بینی شده، از نمودار جعبه (Box plot) استفاده می‌شود. نمودار جعبه ای از SSL پیش بینی شده برای مدل‌های انتخاب شده در شکل ۷ نشان داده شده است. از لحاظ بصری بر اساس شکل ۷، داده‌های پیش بینی 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 (SSL₂₅=۶۳/۸۳۳) و مدل ANN-PSO-M4 (SSL₂₅=۱۳۲/۶۸۸) می‌باشند. تفاوت نسبی بین داده‌های مشاهده شده و مدل‌های انتخابی به ترتیب ۸۵/۴٪، ۱۲/۱٪ و ۱۰۷/۸٪ است که مربوط به ANN-M5، ANN-OTLBO-M5، ANN-PSO-M5 و ANN-PSO-M5 است. اختلاف نسبی در SSL_{50} بین داده‌های رسوب مشاهداتی و داده‌های رسوب پیش بینی شده به ترتیب برابر ۱۱۵/۱٪، ۲۲/۹۷٪ و ۱۱۵/۶٪ است که مربوط به ANN-M5، ANN-OTLBO-M5، ANN-PSO-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 نزدیک ترین داده‌های پیش بینی شده به داده‌های مشاهداتی بر اساس نتایج کمی و شکل ۷ متعلق به مدل ANN-OTLBO-M5 است.

شکل ۷- نمودار جعبه ای داده‌های مشاهداتی و پیش بینی شده بار رسوب معلق

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 حساس تر است تا مقادیر کوچک (Willmott, 1981). 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٪ (de Salis et al., 2019) است. 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 بدست‌آمده 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 (۰/۹۲، ۰/۹۱ و ۰/۹۱) بدست آمد (Kumar et al., 2016). بنابراین، می‌توان دریافت که مدل‌های ترکیبی گزارش شده در این تحقیق عملکرد پیش بینی بهتری در مقایسه با مدل‌های شبکه عصبی در تحقیق کومار دارند.

نتیجه گیری

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-PSO و ANN-OTLBO پنج مدل پیش‌بینی طراحی شد. از شاخص‌های R ، RMSE، PBIAS و NSE برای تعیین 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.
۴. 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 بر اساس الگوریتم OTLBO حل کرد.

- Afan, H. A., Allawi, M. F., El-Shafie, A., Yaseen, Z. M., Ahmed, A. N., Malek, M. A., Koting, S. B., Salih, S. Q., Mohtar, W. H. M. W., Lai, S. H., Sefelnasr, A., Sherif, M., & El-Shafie, A. (2020). Input attributes optimization using the feasibility of genetic nature inspired algorithm: Application of river flow forecasting. *Scientific Reports 2020 10:1*, 10(1), 1–15. <https://doi.org/10.1038/s41598-020-61355-x>
- Allawi, M. F., Jaafar, O., Ehteram, M., Mohamad Hamzah, F., & El-Shafie, A. (2018). Synchronizing Artificial Intelligence Models for Operating the Dam and Reservoir System. *Water Resources Management*, 32(10), 3373–3389. <https://doi.org/10.1007/S11269-018-1996-3/METRICS>
- Asselman, N. E. M. (2000). Fitting and interpretation of sediment rating curves. *Journal of Hydrology*, 234(3–4), 228–248. [https://doi.org/10.1016/S0022-1694\(00\)00253-5](https://doi.org/10.1016/S0022-1694(00)00253-5)
- Banadkooki, F. B., Ehteram, M., Ahmed, A. N., Teo, F. Y., Ebrahimi, M., Fai, C. M., Huang, Y. F., & El-Shafie, A. (2020). Suspended sediment load prediction using artificial neural network and ant lion optimization algorithm. *Environmental Science and Pollution Research 2020 27:30*, 27(30), 38094–38116. <https://doi.org/10.1007/S11356-020-09876-W>
- Buyukyildiz, M., & Kumcu, S. Y. (2017). An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. *Water Resources Management*, 31(4), 1343–1359. <https://doi.org/10.1007/s11269-017-1581-1>
- Choubin, B., Darabi, H., Rahmati, O., Sajedi-Hosseini, F., & Kløve, B. (2018). River suspended sediment modelling using the CART model: A comparative study of machine learning techniques. *Science of the Total Environment*, 615, 272–281. <https://doi.org/10.1016/j.scitotenv.2017.09.293>
- de Salis, H. H. C., da Costa, A. M., Vianna, J. H. M., Schuler, M. A., Künne, A., Fernandes, L. F. S., & Pacheco, F. A. L. (2019). Hydrologic Modeling for Sustainable Water Resources Management in Urbanized Karst Areas. *International Journal of Environmental Research and Public Health 2019, Vol. 16, Page 2542*, 16(14), 2542. <https://doi.org/10.3390/IJERPH16142542>

- Eberhart, R., Shi, Y., & Kennedy, J. (2001). *Swarm Intelligence - 1st Edition*.
<https://www.elsevier.com/books/swarm-intelligence/eberhart/978-1-55860-595-4>
- Garcia, M. H. (2008). *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. 110, 2008.
- Greimann, B., Lai, Y., & Huang, J. (2008). Two-Dimensional Total Sediment Load Model Equations. *Journal of Hydraulic Engineering*, 134(8), 1142–1146.
[https://doi.org/10.1061/\(ASCE\)0733-9429\(2008\)134:8\(1142\)](https://doi.org/10.1061/(ASCE)0733-9429(2008)134:8(1142))
- Hosseini Lavassani, S. H., Mousavi Gavvani, S. A., & Doroudi, R. (2023). Optimal control of jacket platforms vibrations under the simultaneous effect of waves and earthquakes considering fluid-structure interaction. *Ocean Engineering*, 280, 114593.
<https://doi.org/10.1016/J.OCEANENG.2023.114593>
- Kakaei Lafdani, E., Moghaddam Nia, A., & Ahmadi, A. (2013). Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology*, 478, 50–62. <https://doi.org/10.1016/j.jhydrol.2012.11.048>
- Khan, M. Y. A., Tian, F., Hasan, F., & Chakrapani, G. J. (2019). Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India. *International Journal of Sediment Research*, 34(2), 95–107.
<https://doi.org/10.1016/j.ijsrc.2018.09.001>
- Kisi, O. (2012). Modeling discharge-suspended sediment relationship using least square support vector machine. *Journal of Hydrology*, 456–457, 110–120.
<https://doi.org/10.1016/j.jhydrol.2012.06.019>
- Kumar, D., Pandey, A., Sharma, N., & Flügel, W. A. (2016). Daily suspended sediment simulation using machine learning approach. *Catena*, 138, 77–90.
<https://doi.org/10.1016/j.catena.2015.11.013>
- Lavasani, S. H. H., & Doroudi, R. (2020). Meta heuristic active and semi-active control systems of high-rise building. *International Journal of Structural Engineering*, 10(3), 232–253.
<https://doi.org/10.1504/IJSTRUCTE.2020.108529>

- Li, S., Xie, Q., & Yang, J. (2022). Daily suspended sediment forecast by an integrated dynamic neural network. *Journal of Hydrology*, 604, 127258.
<https://doi.org/10.1016/J.JHYDROL.2021.127258>
- Lin, G. F., Chou, Y. C., & Wu, M. C. (2013). Typhoon flood forecasting using integrated two-stage support vector machine approach. *Journal of Hydrology*, 486, 334–342.
<https://doi.org/10.1016/j.jhydrol.2013.02.012>
- Moriasi, D. N., Arnold, J. G., Liew, M. W. Van, Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions of the ASABE*, 50(3), 885–900.
<https://doi.org/10.13031/2013.23153>
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I — A discussion of principles. *Journal of Hydrology*, 10(3), 282–290.
[https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Panahi, F., Ehteram, M., & Emami, M. (2021). Suspended sediment load prediction based on soft computing models and Black Widow Optimization Algorithm using an enhanced gamma test. *Environmental Science and Pollution Research* 2021 28:35, 28(35), 48253–48273. <https://doi.org/10.1007/S11356-021-14065-4>
- Salih, S. Q., Sharafati, A., Khosravi, K., Faris, H., Kisi, O., Tao, H., Ali, M., & Yaseen, Z. M. (2020). River suspended sediment load prediction based on river discharge information: application of newly developed data mining models.
<https://doi.org/10.1080/02626667.2019.1703186>, 65(4), 624–637.
<https://doi.org/10.1080/02626667.2019.1703186>
- Shahrouzi, M., Aghabagloua, M., & Rafiee, F. (2017). Observer-teacher-learner-based optimization: An enhanced meta-heuristic for structural sizing design. *Structural Engineering and Mechanics*, 62(5), 537–550. <https://doi.org/10.12989/sem.2017.62.5.537>
- Sharafati, A., Haji Seyed Asadollah, S. B., Motta, D., & Yaseen, Z. M. (2020). Application of newly developed ensemble machine learning models for daily suspended sediment load prediction and related uncertainty analysis.

<https://doi.org/10.1080/02626667.2020.1786571>, 2022–2042.

<https://doi.org/10.1080/02626667.2020.1786571>

Vercruyse, K., Grabowski, R. C., & Rickson, R. J. (2017). Suspended sediment transport dynamics in rivers: Multi-scale drivers of temporal variation. In *Earth-Science Reviews* (Vol. 166, pp. 38–52). Elsevier B.V. <https://doi.org/10.1016/j.earscirev.2016.12.016>

Willmott, C. J. (1981). On the validation of models. *Physical Geography*, 2(2), 184–194. <https://doi.org/10.1080/02723646.1981.10642213>

روزدایبند ویرایش نشده