

Forecasting Suspended Sediment Transport in River Using Evolutionary models

Mohammad Salkhordeh Haghighi^{1*} , Babak Masoudi² , Abuzar Nekoei³, Abdorrahman Mostafaie⁴

¹Assistant Professor, Civil Engineering Department, Faculty of Technology and Engineering, University of Zabol, Zabol.

²Department of information technology, Payamenoor University (PNU), P.O.Box, 19395-3697, Tehran, I.R of Iran

³PHD student in civil engineering, water resource management and engineering, Faculty of Technology and Engineering, Islamic Azad University, South Tehran Branch, Tehran.

⁴Assistant Professor, Surveying Engineering Department, Faculty of Technology and Engineering, University of Zabol, Zabol.

Corresponding Author's E-mail: m.haghighi@uoz.ac.ir

Received: 07 Aug. 2025 Accepted: 18 Oct. 2025
Revised: 18 Oct. 2025 Published: 22 Dec. 2023



Homepage: ijwer.uoz.ac.ir

Abstract: Accurate prediction of suspended sediment transport is importance for the sustainability of river engineering. The aim of this study is to investigate the feasibility of a new intelligent model called the M5 tree model with radial function basis (RM5Tree) for predicting suspended sediment load using daily data at the Trenton meteorological station, located on the Delaware River (USA). For this purpose, several combinations of input characteristics have been defined based on sediment and river flow information. The prediction accuracy of the proposed model has been validated by statistical evaluations and graphical displays in comparison with several well-known predictive models, including the ANN method and the classical M5 tree-based model. The results obtained from the values of root mean square error and coefficient of determination show the remarkable prediction accuracy of the proposed RM5Tree model.

Keywords: Sediment transport prediction, river engineering sustainability, RM5Tree

Introduction: Among the types of sediment load, including bed load and suspended load (*SSL*), *SSL* is the main part of sediment transport and has a more complex pattern compared to bed load. Therefore, providing an intelligent and reliable predictive model for *SSL* is a fundamental research topic for water resources researchers. The *SSL* pattern has many stochastic characteristics due to the influence of several hydrological, and morphological variables related to the characteristics of the watershed (Kisi and Yaseen 2019). Laboratory determination of sediment concentration requires extensive efforts to collect samples and perform several analytical processes. In addition, these processes are time-consuming and unreliable in flood conditions. To overcome these disadvantages, computational tools have provided suitable and practical solutions, which are introduced in the form of machine learning models. According to the review of the research literature, very limited studies have addressed the estimation of *SSL* using the potential of decision tree models (MT). Talebi, Mahjoobi et al. (2017) used MT and regression tree (RT) to predict daily sediment discharge using stream discharge and precipitation as predictor variables in the Heidarabad basin of Iran. They compared the used decision MT with ANN and concluded the high performance of decision MT.

The present study emphasizes on the implementation of a new version of the M5Tree model integrated with the radial basis function in the form of a hybrid model for predicting *SSL* on a daily time scale (RM5Tree). The results of the newly developed model are validated in comparison with the classical M5Tree models.

Methodology: This study utilized 32 years of daily river discharge (Q) and suspended sediment load (*SSL*) data from the Trenton Station on the Delaware River, USA (USGS Station No. 01463500). The data were split into training (70%) and testing (30%) sets. Descriptive statistics for the input variables are provided in [Table 1](#), and the

study area is illustrated in [Fig. 1](#).

To capture temporal dependencies, six input combinations (scenarios) were developed using current and lagged values of Q and SSL ([Table 1](#)).

Three predictive models were applied: Multilayer Perceptron Neural Network (MLPNN), classical M5 Model Tree (M5Tree), and the proposed Radial Basis M5Tree (RM5Tree). MLPNN used the Levenberg–Marquardt backpropagation algorithm ([Fig. 2a](#)). M5Tree created regression-based decision trees, while RM5Tree enhanced this by mapping input data into radial space via a normal cumulative distribution function ([Figs. 2b](#) and [2c](#)).

Performance was evaluated using Root Mean Square Error ($RMSE$), Mean Absolute Error (MAE), Nash–Sutcliffe Efficiency (NSE), and Agreement Index (d). These metrics, computed for all models and input combinations, are presented in [Table 2](#) to determine the most effective approach for daily SSL prediction.

Results and Discussion: The proposed Radial Basis M5Tree (RM5Tree) model demonstrated superior performance in predicting daily suspended sediment load (SSL) compared to benchmark models (ANN, and classical M5Tree) across all six input scenarios. Evaluation metrics, including $RMSE$, MAE , NSE , and agreement index (d), are presented in [Table 2](#), revealing that RM5Tree consistently outperformed others in both training and testing phases. The optimal input combination included current discharge (Q_t) and two lagged values each of discharge and sediment load (Q_{t-1} , Q_{t-2} , SSL_{t-1} , SSL_{t-2}). This configuration, combined with a 15-center radial transformation, yielded the lowest $RMSE$ (2090 t/day), highest NSE (0.86), and best overall agreement ($d = 0.92$). The enhanced performance is further illustrated in [Fig. 3](#), showing the highest d/MAE ratio, and [Fig. 4](#), where RM5Tree's predictions most closely align with observed data.

The innovation of this study lies in integrating radial basis transformation with the M5Tree framework to improve generalization and handle nonlinearity more effectively. By mapping input data into a radial space using a normal cumulative distribution function, RM5Tree captures subtle variations in SSL dynamics that traditional models overlook. Compared to previous models such as GEP, ANN, W-GEP, and neuro-fuzzy approaches used by Shiri and Kişi (2012) and Vafakhah (2012), RM5Tree achieved significantly lower $RMSE$ values—improving prediction accuracy by up to 66%. While models like CART (Choubin et al., 2018b) and MT (Talebi et al., 2017) also leveraged decision trees, they lacked the hybrid transformation mechanism that distinguishes RM5Tree, limiting their adaptability to high-stochasticity environments. A major strength of RM5Tree is its adaptability across varying input configurations. Unlike ANN, which is sensitive to input dimensionality and structure, RM5Tree maintained stable performance across all scenarios. Additionally, it avoids overfitting by transforming data into a smoother, radially-distributed input space, improving its generalization capability. In summary, this study introduces a novel hybrid machine learning framework for SSL prediction, which outperforms both conventional and state-of-the-art models in accuracy and robustness. The results contribute a practical and scalable solution for sediment management in river engineering, offering significant implications for sustainable water resource planning.

Conclusion: This study introduced a novel hybrid model (RM5Tree) for predicting daily suspended sediment load (SSL) using river discharge and historical sediment data. Among six tested input scenarios, the best performance was achieved using current discharge and two preceding values of discharge and SSL . The RM5Tree model significantly outperformed benchmark models (ANN, M5Tree), achieving the lowest $RMSE$ (2090 t/day) and highest NSE (0.86), as shown in [Table 2](#). The innovation lies in transforming input data into radial space, enhancing the model's ability to capture nonlinear, stochastic sediment patterns. Compared to previous models such as ANN, GEP, and CART, RM5Tree demonstrated higher accuracy and generalization. This approach offers a reliable tool for sediment prediction and river engineering applications, contributing to better watershed management and infrastructure planning.

© 2022 University of Zabol, Zabol, Iran.



This is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license) (<http://creativecommons.org/licenses/by/4.0/>)

پیش‌بینی انتقال رسوب معلق رودخانه با مدل‌های مختلف فرا تکاملی

محمد سالخورده حقیقی^{۱*}، بابک مسعودی^۲، ابودر نکوئی^۳، عبدالرحمان مصطفائی^۴

^۱استادیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه زابل، زابل، ایران

^۲استادیار، گروه مهندسی فناوری اطلاعات، دانشگاه پیام نور، تهران، ایران

^۳دانشجوی دکتری مدیریت منابع آب، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد تهران جنوب، تهران، ایران

^۴استادیار، گروه مهندسی نقشه‌برداری، دانشکده فنی و مهندسی، دانشگاه زابل، زابل، ایران

پست الکترونیکی نگارنده مسئول: m.haghighi@uoz.ac.ir

وبگاه نشریه: ijwer.uoz.ac.ir



تاریخ دریافت: ۱۴۰۴/۰۵/۱۶ تاریخ پذیرش: ۱۴۰۴/۰۷/۲۶

تاریخ ویرایش: ۱۴۰۴/۰۷/۲۶ تاریخ چاپ: ۱۴۰۲/۱۰/۰۱

چکیده: پیش‌بینی دقیق انتقال رسوب معلق برای مبحث پایداری مهندسی رودخانه از اهمیت بسزایی برخوردار است. به عنوان یک واقعیت مهندسی، انتقال بار رسوب به دلیل دخالت متغیرهای هیدرولوژیکی مختلفی نظیر دبی رودخانه و سایر عوامل، پدیده‌ای بسیار تصادفی، با توزیع مکانی و دارای الگویی با افزونگی ذاتی است. هدف این مطالعه، بررسی امکان‌سنجی یک مدل هوشمند جدید موسوم به مدل درختی M5 با پایه تابع شعاعی (RM5Tree) برای پیش‌بینی بار رسوب معلق با استفاده از داده‌های روزانه در ایستگاه آب‌سنجی ترنتون، واقع در رودخانه دلاور (آمریکا) است. بدین منظور ترکیب‌های متعددی از مشخصه‌های ورودی بر اساس اطلاعات پیشین رسوب و دبی جریان رودخانه تعریف شده‌اند. دقت پیش‌بینی مدل پیشنهادی، بر اساس ارزیابی‌های آماری و نمایش‌های گرافیکی، در مقایسه با چندین مدل پیش‌بین شناخته‌شده از جمله روش شبکه عصبی مصنوعی و مدل کلاسیک مبتنی بر درخت M5 اعتبارسنجی شده است. ترکیب بهینه مشخصه‌های ورودی شامل اطلاعات دبی و رسوب (با دو ماه زمان انتظار) است. نتایج به‌دست‌آمده از مقادیر ریشه میانگین مربعات خطا (تن در روز $RMSE \approx 2091$) و ضریب تعیین ($R^2 \approx 0.86$)، دقت پیش‌بینی قابل توجه مدل پیشنهادی RM5Tree را نشان می‌دهد.

کلیدواژه‌ها: پیش‌بینی انتقال رسوب، اطلاعات جریان، پایداری مهندسی رودخانه، مدل RM5Tree.

۱- مقدمه

نظیر سدهای مخزنی و کانال‌ها است (Özger and Kabataş, 2015). ضمن این که رسوب‌گذاری، مشکل اصلی کاهش ظرفیت مخازن، انسداد ورودی آبیگرهای سد، کاهش ظرفیت تخلیه کانال‌ها و تخریب‌های متعدد دیگر رودخانه‌ای است (Afan et al., 2016). علاوه بر این، انتقال رسوب تاثیر عمده‌ای بر طراحی و مدیریت سامانه‌های آبی

بار رسوب، مسئله‌ای حیاتی در کاربردهای متعدد مهندسی رودخانه، از جمله مسائل زیست‌محیطی (مانند انتقال آلاینده‌ها)، سامانه‌های مدیریت آب (مانند بهره‌برداری از مخازن و نوبری) و همچنین طراحی سازه‌های هیدرولیکی

تجربی محدود بوده و به نمونه‌برداری‌های آزمایشگاهی خاص یا فرضیات ویژه‌ای وابسته هستند. علاوه بر این، وجود پارامترهای مرتبط با عدم قطعیت، محدودیت عمده‌ای است که درک آن از طریق فرمول‌بندی‌های تجربی دشوار است (Aytek and Kişi, 2008; Shamaei and Kaedi, 2016). طی دو دهه گذشته، مدل‌های یادگیری ماشین که در نسخه‌های مختلفی مانند ماشین بردار پشتیبان (SVM)⁴، روش فازی، شبکه عصبی مصنوعی (ANN)⁵ و درخت مدل (MT)⁶ ارائه شده‌اند، به طور گسترده‌ای برای فرآیندهای مهندسی هیدرولوژی بکار گرفته شده است (Afan et al., 2016; Nourani et al., 2014; Yaseen et al., 2015). مدل‌های یادگیری ماشین توانایی کافی برای درک الگوی واقعی فرآیندهای هیدرولوژیکی را دارند. این امر به دلیل ویژگی‌های ریاضی بالقوه آنها برای تقریب رفتار پیچیده مسائل طبیعی است.

در خصوص پیش‌بینی بار رسوب (SL)، تکنیک‌های داده‌محور را می‌توان به گروه‌های زیر طبقه‌بندی کرد:

۱. مدل‌های شبکه عصبی مصنوعی (ANN): یکی از رویکردهای غالب مدل‌سازی هوش مصنوعی که برای شبیه‌سازی بار معلق به کار گرفته شده است (Liu et al., 2022; Ma and Mei, 2021; Wang et al., 2024).

۲. مدل منطق فازی (FL)⁷: در میان نسخه‌های مختلف مدل‌های منطق فازی، سامانه استنتاج فازی-عصبی تطبیقی (ANFIS) به طور قابل توجهی برای تخمین رسوب و تحلیل الگوی عدم قطعیت به کار رفته است (Meles et al., 2021; Vollert et al., 2023).

۳. مدل‌های ماشین بردار پشتیبان (SVM): ماشین بردار پشتیبان نوعی از مدل‌های یادگیری ماشین با هسته آماری است (Gao et al., 2021; Hokanson et al., 2019; Sefati et al., 2021).

۴. مدل‌های محاسبات تکاملی (EC)⁸: این مدل‌ها نوع دیگری از یادگیری ماشین هستند که بر اساس نظریه

(هیدروسیستم‌ها) دارد (Olyaie et al., 2015; Shiau and Chen, 2015). با توجه به تاثیر منفی غلظت بار رسوب بر پایداری مهندسی رودخانه، پیش‌بینی دقیق بار رسوب همواره از دغدغه‌های اصلی مهندسان هیدرولیک و محیط زیست بوده است.

از انواع بار رسوب شامل بار کف (SBL)¹ و بار معلق (SSL)²، بار معلق بخش اصلی انتقال رسوب بوده و در مقایسه با بار کف به دلیل عواملی مانند آشفتگی جریان، ترکیب ذرات و تغییرات زمانی، الگوی پیچیده‌تری را به هنگام پیش‌بینی رفتار رودخانه نشان می‌دهد (Zounemat-Kermani et al., 2016). بنابراین، ارائه یک مدل پیش‌بین هوشمند و قابل اعتماد برای بار معلق، از موضوعات اساسی تحقیق پژوهشگران مهندسی هیدرولیک و منابع آب است. الگوی بار معلق به دلیل ۱- تاثیر چندگانه متغیرهای هیدرولوژیکی و اقلیمی ۲- نوسانات شدید دبی جریان در طول سال ۳- رخداد‌های نادر با شدت بالا (مانند بارش‌های سیلابی و رانش زمین) ۴- فعالیت‌های انسانی (جاده‌سازی، برداشت چوب، چرای بی‌رویه) ۵- توزیع آماری غیرنرمال داده‌ها و ۶- وابستگی پیچیده به دبی جریان و شرایط زمین‌شناسی هر حوضه آبریز، دارای مشخصه‌های تصادفی فراوانی است (Kisi and Yaseen, 2019). تعیین آزمایشگاهی غلظت رسوب، مستلزم تلاش‌های فراوانی برای جمع‌آوری نمونه‌ها و انجام چندین فرآیند تحلیلی است. علاوه بر این، این فرآیندها زمان‌بر بوده و در شرایط سیلابی قابل اعتماد نیست (Ulke et al., 2017). برای غلبه بر این محدودیت‌ها، ابزارهای محاسباتی راه‌حل‌های مناسب و عملی ارائه داده‌اند که در قالب مدل‌های یادگیری ماشین (ML)³ معرفی می‌شوند. در نتیجه مدل‌های یادگیری ماشین، ابزار روش‌شناختی بالقوه‌ای برای شبیه‌سازی و پیش‌بینی غلظت بار معلق فراهم آورده‌اند (Afan et al., 2016).

عموماً کمی‌سازی غلظت بار معلق از طریق روابط تجربی متعددی انجام گرفته است (Colby and Hembree, 1954; Soni et al., 1980; Tang and Knight 2006; Wilcock et

⁵ Artificial neural network

⁶ Model tree

⁷ Fuzzy logic

⁸ Evolutionary computing

¹ Sediment bed load

² Suspended sediment load

³ Machine learning

⁴ Support vector machine

(2014) به کار گرفته می‌شوند. در خصوص کاربرد مدل‌های درخت تصمیم برای پیش‌بینی بار رسوب، (Goyal, 2014) مقایسه‌ای بین درخت مدل (MT)، رگرسیون موجک^۳ و شبکه عصبی مصنوعی برای پیش‌بینی بار معلق در زیرحوضه رودخانه سوانی واقع در هند انجام داد. او برتری مدل MT را در مقایسه با سایر مدل‌ها گزارش کرد. طالبی و همکاران (Talebi et al., 2017) از درخت مدل (MT) و درخت رگرسیون (RT⁴) برای پیش‌بینی دبی روزانه رسوب با استفاده از دبی جریان و بارش به عنوان متغیرهای پیش‌بین در حوضه آبریز حیدرآباد ایران استفاده کردند. آن‌ها مدل‌های درخت تصمیم مورد استفاده را با شبکه عصبی مصنوعی مقایسه کرده و عملکرد مطلوب مدل‌های درخت تصمیم را نتیجه گرفتند. چوبین و همکاران (Choubin et al., 2018) از مدل درخت طبقه‌بندی و رگرسیون (CART^۵) برای پیش‌بینی بار معلق روزانه استفاده کردند. آن‌ها از رسوب و دبی جریان، بارش و تراز آب به عنوان متغیرهای پیش‌بینی بهره بردند. عملکرد CART در پیش‌بینی بار معلق با استفاده از آماره‌های راندمان نش-ساتکلیف (NSE^۶)، درصد بایاس و راندمان کلینگ-گوپتا اندازه‌گیری شد. آن‌ها نتایج CART را با مدل شبکه عصبی مصنوعی مقایسه کرده و برتری CART را گزارش دادند.

مطالعه حاضر بر پیاده‌سازی نسخه جدیدی از مدل درختی M5Tree که با تابع بر پایه شعاعی در قالب یک مدل ترکیبی برای پیش‌بینی بار معلق در مقیاس زمانی روزانه یکپارچه شده است (RM5Tree)، تاکید دارد. نتایج مدل جدید توسعه‌یافته در مقایسه با مدل‌های کلاسیک M5Tree اعتبارسنجی شده است. با توجه به ماهیت بسیار تصادفی، غیرخطی و غیرمانای الگوی بار معلق، این مطالعه به معرفی یک مدل داده‌کاوی ترکیبی تازه توسعه‌یافته

برای تخمین بار رسوب معلق در ایستگاه ترنتون^۷ در رودخانه دلاور^۸ در ایالات متحده آمریکا اختصاص یافته است.

داروینی بنا شده‌اند. مدل‌های محاسبات تکاملی به چهار دسته اصلی شامل الگوریتم‌های تکاملی، الگوریتم‌های ژنتیک، استراتژی‌های تکاملی و برنامه‌ریزی ژنتیک طبقه‌بندی می‌شوند (Allawi et al., 2023; Shah et al., 2021).

۵. مدل‌های یادگیری ماشین مکمل (CML^۱): نوعی از مدل‌ها هستند که در آنها رویکردهای پیش‌پردازش به عنوان مرحله اولیه برای پاک‌سازی و تجزیه داده‌ها، با مدل‌های پیش‌بینی یادگیری ماشین یکپارچه می‌شوند (Corline et al., 2023; Doro et al., 2021; Zeng et al., 2022).

۶. مدل‌های داده‌کاوی: نسخه دیگری از مدل‌های یادگیری ماشین مبتنی بر مدل‌های درخت تصمیم هستند که قابلیت اطمینان خود را به عنوان مدل‌های پیش‌بین برای پیش‌بینی فرآیندهای هیدرولوژیکی به اثبات رسانده‌اند (Pahlavan-Rad et al., 2020; Zhuang et al., 2021). با این حال، تحقیقات محدودی در زمینه تخمین بار معلق با استفاده از آنها انجام شده است.

۷. مدل‌های یادگیری ماشین ترکیبی (HML^۲): مدل‌هایی هستند که به تازگی بر اساس ترکیب مدل‌های یادگیری ماشین با الگوریتم‌های بهینه‌سازی، مانند الگوریتم‌های الهام‌گرفته از طبیعت، توسعه یافته‌اند (Antoniazza et al., 2022; Corline et al., 2023; Liu et al., 2022).

طبق بررسی پیشینه تحقیق، مطالعات بسیار محدودی به تخمین بار معلق با استفاده از پتانسیل مدل‌های درخت تصمیم پرداخته‌اند (Choubin et al., 2018; Goyal, 2014; Talebi et al., 2017).

مدل‌های داده‌کاوی به طور گسترده‌ای در پیش‌بینی پدیده‌های آب و اقلیمی مانند سیل (Solomatine and Marjanović et al., 2013; Taghi Sattari et al., 2004; Xue, 2018) بارش (Choubin et al., 2018)، رانش زمین (Marjanović et al., 2016; Tien Bui et al., 2017; Pham et al., 2018) و آب‌شستگی (Goyal and Ojha, 2011; Samadi et al., 2011).

⁵ classification and regression tree

⁶ Nash-Sutcliffe efficiency

⁷ Trenton station

⁸ Delaware river

¹ Complementary machine learning

² Hybrid Machine Learning

³ Wavelet regression

⁴ Regression tree

۲- روش‌شناسی

۲-۱- منطقه مورد مطالعه و توصیف داده‌های ورودی

مجموعه داده ایستگاه هیدرومتری بررسی‌شده در این پژوهش، مربوط به رودخانه دلاور واقع در ایالات متحده آمریکا است. داده‌های مورد استفاده شامل دبی رودخانه (Q) و بار رسوب معلق (SSL) در مقیاس زمانی روزانه طی یک دوره ۳۲ ساله، از سازمان زمین‌شناسی ایالات متحده (USGS) به آدرس www.co.water.usgs.gov/sediment دریافت شده‌اند. مقادیر Q و SSL از ایستگاه ترنتون (شماره ایستگاه: ۰۱۴۶۳۵۰۰؛ عرض جغرافیایی: $40^{\circ}13'$ شمالی؛ طول جغرافیایی: $74^{\circ}47'$ غربی) با مساحت حوضه آبریز حدود ۱۷۵۶۰ کیلومترمربع (شکل ۱) ثبت شده‌اند.

مشخصات آماری سری زمانی داده‌های ورودی روزانه برای مرحله آموزش (۷۰٪ مجموعه داده) و مرحله آزمون (۳۰٪ مجموعه داده) در جدول ۱ ارائه شده‌است. در این جدول X_{min} ، X_{max} ، STD ، COV و $Skewness$ به ترتیب بیان‌گر حداقل، حداکثر، میانگین، انحراف معیار، ضریب تغییرات (STD/X_{mean}) و چولگی نقاط داده برای بار رسوب (تن در روز) و دبی (مترمکعب بر ثانیه) هستند.

۲-۲- رویکردهای مدل‌سازی

استراتژی‌های مدل‌سازی به کاررفته، بر اساس ترکیب‌های ورودی مختلف تدوین شده‌اند. شش سناریوی ورودی مبتنی بر مولفه‌های سری‌های زمانی فرعی^۱، با استفاده از سری‌های زمانی دبی جریان رودخانه (Q_{t-2} و Q_{t-1} ، Q_t) و




Fig. 1 The location of the studied case study of the Delaware River basin, USA.

شکل ۱ موقعیت مکانی حوضه آبریز رودخانه دلاور، آمریکا

جدول ۱ بانک اطلاعاتی آماری داده‌های پژوهش در فاز آزمایش و آزمون

Table 1 Statistical properties of the Database in test and train studied periods

Period	Dataset	X_{min}	X_{max}	X_{mean}	STD	COV	Skewness
Train (8329 data)	Sediment load (ton/day)	0	1090000	1959.6	18040	9.206	41.13
	Discharge (m^3/s)	35	7812	304.83	312.87	1.026	4.66
Test (3569 data)	Sediment load (ton/day)	5.1	359000	2000.3	11000	5.499	17.92
	Discharge (m^3/s)	53	3052	369.23	349.47	0.947	2.65

¹ Sub-time series components

از طریق سریزمانی دبی (Q_t ، Q_{t-1} و Q_{t-2}) و بار رسوب معلق (SSL_{t-1} و SSL_{t-2}) مطابقت دارند، در حالی که تعداد نورون‌ها (گره‌ها) در لایه پنهان بر اساس سعی و خطا برای دستیابی به بهترین پیش‌بینی رسوب معلق تعیین می‌شود و در محدوده ۵ تا ۱۵ متغیر است. لایه خروجی MLPNN با یک نورون از رسوب معلق روزانه (SSL_t) ساختار یافته است که نمای شماتیک MLP مبتنی بر ANN در شکل ۲ ارائه شده است. تابع پیش‌بینی شده \hat{S}_t برای اتصال نورون‌های داده ورودی (x که با Q_t ، Q_{t-1} ، Q_{t-2} ، SSL_{t-1} و SSL_{t-2}) تعریف می‌شود) به نورون خروجی (SSL_t) توسط توابع ریاضی زیر بیان می‌شود:

$$\hat{S}_t = b + \sum_{j=1}^M w_j \phi_j \quad (1)$$

$$\phi_j = \frac{1}{1 + \exp[-(b_j + \sum_{i=1}^n w_{ji} x_i)]} \quad (2)$$

که در آن، M تعداد نورون‌های پنهان است که بین ۵ تا ۱۵ گره در نظر گرفته می‌شود، b بایاس نورون خروجی است، و w_j وزن‌های اتصال بین نورون خروجی و n آمین نورون لایه پنهان را نشان می‌دهد. ϕ_j مجموعه داده خروجی n آمین نورون پنهان است که با استفاده از معادله (۲) به عنوان تبدیل تابع فعال‌سازی سیگموئید غیرخطی محاسبه می‌شود. در معادله (۲)، b_j بایاس n آمین نورون پنهان را نشان می‌دهد، w_{ji} وزن‌های اتصال n آمین نورون لایه پنهان به i آمین نورون در لایه ورودی را مشخص می‌کند و n تعداد نورون‌های ورودی است که بین ۳ تا ۵ متغیر است (متغیرهای ورودی x_i بر اساس مجموعه داده Q_t ، Q_{t-1} ، Q_{t-2} ، SSL_{t-1} و SSL_{t-2} تعریف می‌شوند). همانطور که در شکل ۲ مشاهده می‌شود، MLPNN دارای سه لایه ورودی، پنهان و خروجی است که در آن تعداد گره‌های ورودی برابر با ۴ (x_1 ، x_2 ، x_3 و x_4) است. رویکرد یادگیری برای تعیین شرایط بهینه وزن‌های اتصال (w) و بایاس‌ها (b) برای لایه‌های پنهان و خروجی اهمیت بیشتری دارد. تعداد $[M+1] \times (n+2)$ ضریب ناشناخته مبتنی بر وزن‌ها (w) و بایاس‌ها (b) وجود دارد که باید با استفاده از یک الگوریتم

بار رسوب معلق (SSL_{t-1} و SSL_{t-2}) به عنوان ویژگی‌های ورودی برای پیش‌بینی رسوب معلق (S_t) در ایستگاه ترنتون در رودخانه دلاور، تعریف شده‌اند. این مجموعه‌های سناریوهای ورودی در جدول ۲ تعریف شده‌است.

سه سناریوی اول از ترکیب‌های ورودی با استفاده از سه داده ورودی سری زمانی تعریف می‌شوند، در حالی که سناریوهای چهارم و پنجم بر اساس چهار داده ورودی فرمول‌بندی شده‌اند. در نهایت، سناریوی ورودی ششم با استفاده از پنج مقدار پیشین از داده‌های ورودی سری زمانی برای پیش‌بینی رسوب معلق (SSL_t) ساخته می‌شود. این مجموعه داده ورودی به منظور نمایش همبستگی غیرخطی داده‌های ورودی در فرامدل‌های ANN، M5Tree و RM5Tree ارائه گردیده‌اند.

۲-۳- شبکه عصبی پرسپترون چندلایه (MLPNN)^۱

شبکه عصبی مصنوعی (ANN) یکی از ابزارهای نگاشت غیرخطی است که عمدتاً برای مرتبط ساختن مجموعه‌ای از متغیرهای ورودی به یک یا چند متغیر خروجی به کار می‌رود. به طور کلی، شبکه‌های عصبی پیش‌خور به طور گسترده‌ای برای کاربردهای تحلیل طبقه‌بندی یا رگرسیون با استفاده از یک رابطه غیرخطی بین مجموعه‌های داده ورودی و خروجی مورد استفاده قرار گرفته‌اند (Hecht-Nielsen, 1992).

جدول ۲ سناریوهای مورد مطالعه

Table 2 Studied scenarios

i	Q_t, S_{t-1}, S_{t-2}
ii	Q_t, Q_{t-1}, S_{t-1}
iii	Q_t, Q_{t-1}, S_{t-1}
iv	Q_t, Q_{t-1}, Q_{t-2}
v	$Q_t, Q_{t-1}, S_{t-1}, S_{t-2}$
vi	$Q_t, Q_{t-1}, Q_{t-2}, S_{t-1}$

شبکه عصبی پرسپترون چندلایه ابزار محبوبی در شبکه‌های عصبی مصنوعی است (Haykin, 1994) که معمولاً از سه لایه ورودی، پنهان و خروجی تشکیل می‌شود. لایه ورودی شامل چندین گره (نورون) است که با مجموعه داده ورودی

¹ Multilayer Perceptron Neural Network

خروجی از مجموعه بالقوه هستند و sd انحراف معیار است. در نتیجه، فرآیند تقسیم داده‌ها در گره‌های فرزند، انحراف معیار کمتری نسبت به گره‌های والد خواهد داشت و از این رو خالص‌تر هستند. مدل M5Tree پس از بررسی تمام تقسیم‌های ممکن، آن تقسیمی را انتخاب می‌کند که کاهش خطای مورد انتظار را بیشینه سازد. این تقسیم‌بندی اغلب ساختار درختی بزرگی ایجاد می‌کند که ممکن است منجر به تعمیم‌پذیری ضعیف شود. برای مقابله با این مشکل، درخت بیش‌ازحد رشد کرده، هرس شده و این زیردرخت‌ها در مرحله دوم با توابع رگرسیون خطی جایگزین می‌شوند. این تکنیک فضای پارامتر را به نواحی (زیرفضاها) گسترش داده و برای هر یک از آن‌ها یک مدل رگرسیون خطی ایجاد می‌کند.

۲-۵- مدل درخت M5 بر پایه تابع شعاعی (RM5Tree)

مدل M5Tree بر اساس کنترل پایگاه داده ورودی توسط تابع پایه شعاعی نرمال در تحلیل قابلیت اطمینان سازه‌ها بهبود یافته است (Keshtegar and Heddad, 2018). در رویکرد مدل‌سازی اصلاح‌شده M5Tree، داده‌های ورودی از فضای اصلی به فضای شعاعی توسط یک تابع توزیع احتمال نرمال (PDF)⁴ نگاشت می‌شوند. این نگاشت می‌تواند بر اساس تابع توزیع تجمعی (CDF)⁵ برای مدل‌سازی رسوب معلق روزانه بهبود یابد. نگاشت CDF مبتنی بر داده ورودی می‌تواند مقداری در بازه ۰ تا ۱ داشته باشد، در حالی که داده‌هایی با فاصله یکسان در رویکرد داده‌محور با استفاده از نگاشت PDF، مقدار یکسانی می‌گیرند. بنابراین، درخت مدل M5 با تابع پایه شعاعی (RM5Tree) با استفاده از نگاشت داده‌های ورودی مبتنی بر CDF برای مدل غیرخطی سری زمانی رسوب معلق روزانه پیشنهاد می‌شود. مدل RM5Tree پیشنهادی با انتقال متغیرهای ورودی از فرمت اصلی به فرمت شعاعی توسط CDF زیر آموزش داده می‌شود:

آموزش برای به دست آوردن رابطه غیرخطی بین مجموعه داده ورودی و رسوب معلق روزانه تعیین شوند. رویکرد پس انتشار خطا (BP)¹ در ANN، رایج‌ترین الگوریتم آموزشی است که می‌توان از آن برای آموزش ANN استفاده کرد و در مطالعه حاضر، از الگوریتم پس انتشار خطای لوبنرگ-مارکوارت² برای محاسبه اتصالات بهینه بین گره‌ها در شبکه عصبی پرسپترون چندلایه استفاده شده است (Hagan and Menhaj, 1994). مجموعه داده‌های ورودی و خروجی در محدوده ۱- تا ۱ نرمال‌سازی می‌شود.

در سال‌های اخیر، MLPNN برای پیش‌بینی رسوب معلق استفاده شده است که کارهای پژوهشی این محققان را می‌توان در مقالات منتشرشده مشاهده کرد (Rajae et al., 2009).

۲-۴- مدل درخت M5 (M5Tree)

مدل M5Tree برای اولین بار توسط کوئینلان (Quinlan, 1992) ارائه شد که مبتنی بر درخت تصمیم دودویی است. این مدل بر اساس تابع رگرسیون بنا شده است و با تکیه بر گره‌های پایانی، مکانیزم داخلی بین ویژگی‌های ورودی و خروجی هدف را توسعه می‌دهد. برخلاف مدل درخت تصمیم، این مدل می‌تواند برای مجموعه داده‌های کمی پیاده‌سازی شود. مدل M5Tree معمولاً طی دو مرحله اصلی ایجاد می‌شود (Yaseen et al., 2018): ابتدا داده‌ها به زیرمجموعه‌هایی تقسیم شده و یک درخت تصمیم آغاز می‌شود. معیار تقسیم‌بندی به انحراف معیار مقادیر کلاس بستگی دارد. علاوه بر این، خطای محاسبه‌شده در نتیجه آزمون هر ویژگی در آن گره نیز مدنظر قرار می‌گیرد. کاهش انحراف معیار (SDR)³ به صورت زیر محاسبه می‌شود (Milion et al., 2016):

$$SDR = sd(T) - \sum \frac{|T_i|}{|T|} sd(T_i) \quad (3)$$

که در آن T مجموعه‌ای از نمونه‌هایی است که به گره می‌رسند، T_i زیرمجموعه‌ای از نمونه‌هاست که دارای i امین

⁴ Probability distribution function
⁵ Cumulative destitution function

¹ Back-propagation
² Levenberg-Marquardt
³ Standard deviation reduction

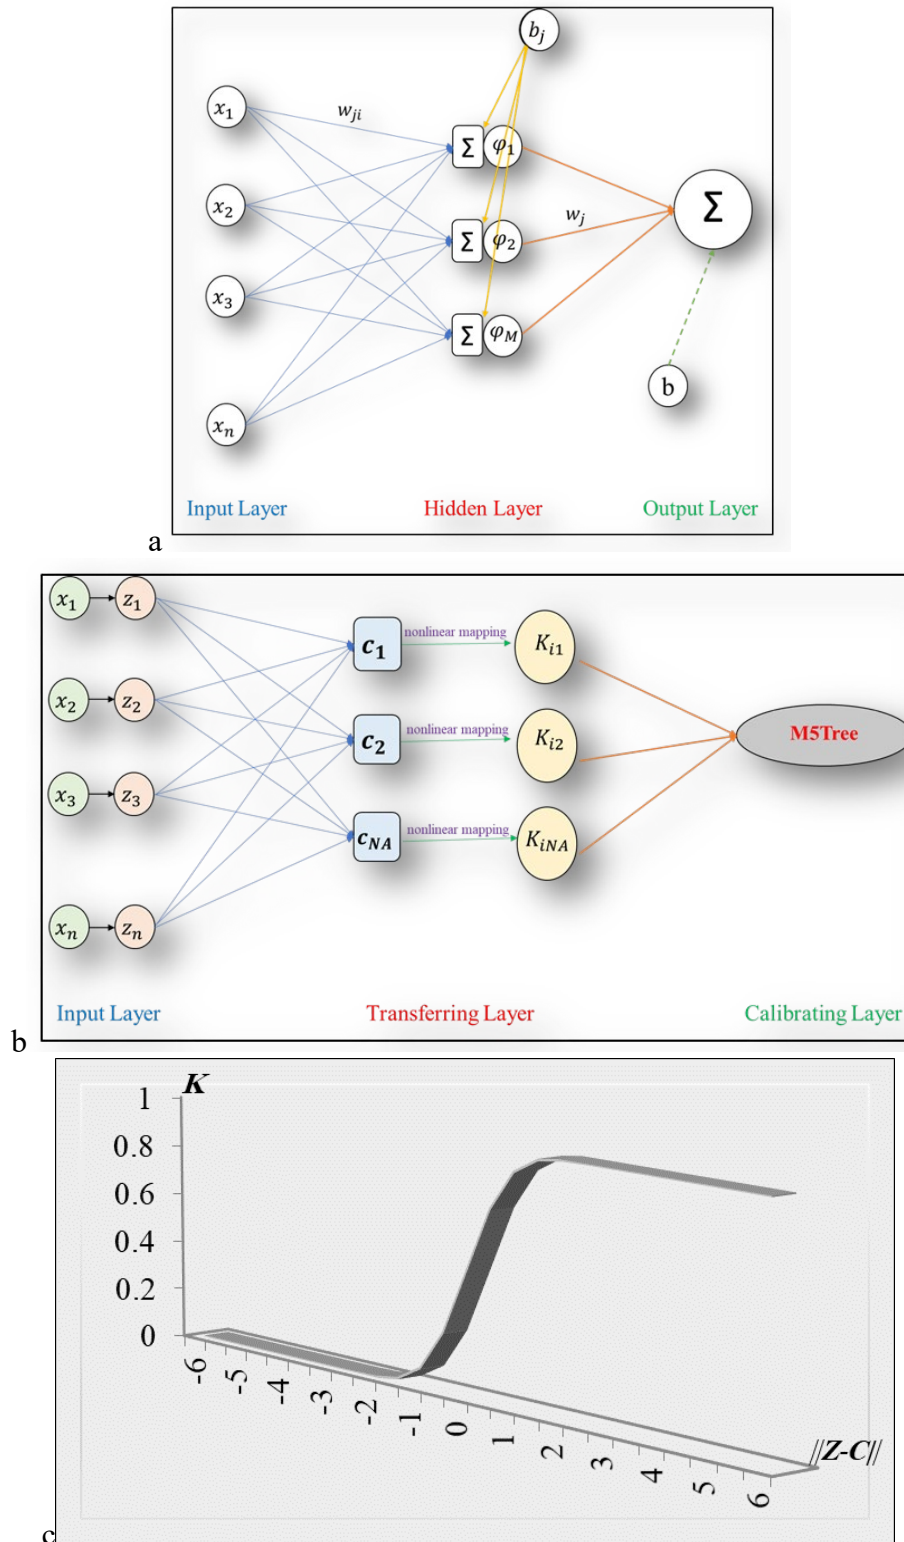


Fig. 2 a) Schematic view of ANN-based multilayer perceptron, b) Schematic view of RM5Tree model-based NA-transferring input database, c) Schematic view of the mapping data point using Eq. (4) with $C=0$.

شکل ۲ الف) شماتیک یک شبکه عصبی مصنوعی بر پایه پرسپترون چند-لایه، ب) شماتیک مدل درختی M5 بر پایه تابع شعاعی (RM5Tree)، و ج) نگاشت نقطه ورودی شعاعی مورد استفاده در معادله (۴) به ازای $C=0$

تصادفی از دامنه مجموعه داده ورودی، یعنی $C=[Z_{min}, Z_{max}]$ برای تمام n مجموعه داده فضای نرمال شده حقیقی انتخاب می‌شود. رویکرد مدل‌سازی شماتیک RM5Tree پیشنهادی با استفاده از NA نقطه مرکزی تصادفی به عنوان پایگاه داده ورودی شعاعی در **شکل b2** ترسیم شده است. از **شکل b2** می‌توان نتیجه گرفت که این رویکرد مدل‌سازی برای ایجاد پایگاه داده ورودی شامل چهار مرحله مهم است: \blacklozenge مرحله (۱) نرمال‌سازی متغیرهای ورودی در فضای حقیقی با استفاده از معادله (۵)،

\blacklozenge مرحله (۲) NA نقطه مرکزی تصادفی در دامنه‌های پایگاه داده ورودی نرمال شده n بعدی حقیقی به صورت زیر است:

$$C_j = [z_1^j, z_2^j, z_3^j, \dots, z_n^j] \quad j = 1, 2, \dots, NA, z_i^j \in [z_{min}^{i,j}, z_{max}^{i,j}]$$

\blacklozenge مرحله (۳) فواصل نقطه نرمال شده $\|Z_i\|$ ، نقاط مرکزی $\|C_i\|$ و طول تفاضل بین نقاط نرمال شده و هر نقطه مرکزی به صورت $\|Z_i - C_j\| \quad i = 1, 2, \dots, n, j = 1, 2, \dots, NA$ است که در آن n تعداد نقاط داده و NA تعداد نقاط مرکزی تصادفی است، و

\blacklozenge مرحله (۴) انتقال نقطه داده ورودی بر اساس نقاط مرکزی با استفاده از نگاشت غیرخطی در معادله (۴). بنابراین، این رویکرد مدل‌سازی شامل سه لایه مهم است: (۱) لایه ورودی که شامل مرحله ۱ است، (۲) لایه انتقال که شامل مراحل ۲ تا ۴ است، و (۳) لایه کالیبراسیون که بر اساس مدل M5Tree با ورودی دیتابیس k انجام می‌شود. تابع شعاعی مبتنی بر نگاشت غیرخطی در معادله (۴) برای انتقال مجموعه داده نرمال شده از فضای n بعدی اصلی به فضای NA بعدی شعاعی استفاده می‌شود، که در آن چندین پایگاه داده ورودی NA بعدی مانند ۵، ۱۰ و ۱۵ برای ساخت مدل M5Tree پیاده‌سازی شده است. همانطور که مشاهده می‌شود، پایگاه داده n بعدی ورودی از لایه ۱ توسط رابطه در معادله (۴) به پایگاه داده NA بعدی ورودی با استفاده از نقطه مرکزی در لایه ۲ به صورت زیر منتقل می‌شود:

$$K_{ij} = \begin{cases} 0.5 + 0.5 \operatorname{erf}(\|Z_i - C_j\| / \|Z_i\|) & \|Z_i\| \geq \|C_j\| \\ 0.5 + 0.5 \operatorname{erf}(-\|Z_i - C_j\| / \|Z_i\|) & \|Z_i\| < \|C_j\| \end{cases} \quad (4)$$

که در آن، erf تابع خطا را نشان می‌دهد، $\|Z_i\|$ طول بردار تفاضل است و C_j نقطه مرکزی زامین مجموعه داده شعاعی انتقالی می‌باشد. نقاط مرکزی به صورت تصادفی با استفاده از تعداد نقاط ورودی شعاعی تعیین می‌شوند. Z_i ، آامین متغیر ورودی استاندارد است که به صورت زیر تعیین می‌شود:

$$Z_i = \frac{X_i - \mu_x}{\sigma_x} \quad (5)$$

که در آن، μ_x و σ_x به ترتیب میانگین و انحراف معیار متغیر ورودی تصادفی x هستند. نگاشت CDF تبدیلی برای نقطه داده ورودی شعاعی با استفاده از معادله (۴) برای $C=0$ در **شکل c2** نشان داده شده است. همانطور که از **شکل c2** مشاهده می‌شود، زمانی که $\|Z_i\| \geq \|C_j\|$ باشد، با افزایش فاصله بین نقاط ورودی و نقاط مرکزی، مقادیر داده‌های ورودی شعاعی به صورت یکنواخت افزایش می‌یابند، در حالی که برای دامنه $\|Z_i\| < \|C_j\|$ ، با افزایش فاصله نقاط ورودی از نقطه مرکزی، مقادیر ورودی شعاعی کاهش می‌یابند. نقاط ورودی شعاعی می‌توانند طیف وسیعی از نقاط داده ورودی را با همان بُعد با استفاده از مقادیری در بازه ۰ تا ۱ پوشش دهند. این نگاشت سیگموئیدی غیرخطی می‌تواند برای انتقال نقاط داده ورودی با چندین نقطه مرکزی به کار رود که هر نقطه مرکزی یک مجموعه داده ورودی برای پایگاه داده ورودی شعاعی را نشان می‌دهد. تابع پایه نگاشت غیرخطی k در معادله (۴) می‌تواند با استفاده از نقطه مرکزی تصادفی، NA نقطه داده شعاعی ورودی را فراهم کند، به طوری که n نقطه داده فضای حقیقی به یک مجموعه داده فضای شعاعی NA بعدی به عنوان پایگاه داده جدید برای آموزش مدل M5Tree تبدیل می‌شوند. همانطور که در **شکل c2** مشاهده می‌شود، مجموعه داده فضای شعاعی NA بعدی توسط نقاط مرکزی به عنوان یک پارامتر مکانی تعیین می‌شود که به طور

یافته است. بدین منظور، تحلیل آماری مدل پیشنهادی RM5Tree پیاده‌سازی شده و مقایسه نتایج با مدل‌های مبنای ANN و M5Tree صورت گرفته است. مطالعه موردی انتخاب شده، رودخانه دلاور واقع در ایالات متحده آمریکا بوده که از مشکل اساسی مرتبط با رسوب‌گذاری رنج می‌برد. معیارهای آماری عملکرد و دقت مدل‌های یادگیری ماشین به کاررفته برای هر ترکیب ورودی ساخته شده در فاز آزمون، در **جدول ۳** ارائه شده است. معیارهای عملکرد بررسی شده شامل خطای جذر میانگین مربعات ($ESMR^1$)، میانگین خطای مطلق (EAM^2)، نسبت شاخص توافق و یلموت ۳ (d) به میانگین خطای مطلق و ضریب کارایی نش-ساتکلیف (NSE) هستند (روابط (۷) تا (۱۰)).

$$RMSE = \sqrt{\frac{\sum(P_i - O_i)^2}{n}} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (8)$$

$$NS = 1 - \frac{\sum(P_i - O_i)^2}{\sum(P_i - \bar{P})^2} \quad (9)$$

$$d = \frac{\sum(P_i - O_i)^2}{\sum(|P_i - \bar{O}_i| + |O_i - \bar{O}_i|)^2} \quad (10)$$

در **معادله‌های بالا** n تعداد کل نمونه‌ها، O و \bar{O} به ترتیب مقادیر پیش‌بینی، مشاهداتی و میانگین مشاهداتی هستند.

در یک نگاه کلی، عملکرد مدل RM5Tree پیشنهادی بر مدل‌های مورد مقایسه ANN و M5Tree برتری دارد. اولین ترکیب ورودی که شامل دبی و مقادیر SSL با یک و دو گام زمانی پیشین بود، بدترین کارایی پیش‌بینی را نشان داد. با این حال، مدل RM5Tree همچنان بهترین نتایج را در مقایسه با سایر مدل‌ها ارائه داده است. در میان تمام ترکیب‌های ورودی بررسی شده، هیچ ثباتی برای بهترین دقت پیش‌بینی مشاهده نشد. به عنوان مثال، نقاط داده شعاعی ورودی NA تایی مختلف با استفاده از NA نقطه مرکزی تصادفی که نقاط داده فضای حقیقی n بعدی را به

$$Z = \begin{bmatrix} Z_{1,1} & Z_{1,2} & \dots & Z_{1,n} \\ Z_{2,1} & Z_{2,2} & \dots & Z_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ Z_{N,1} & Z_{N,2} & \dots & Z_{N,n} \end{bmatrix}$$

$$\rightarrow K = \begin{bmatrix} K_{1,1} & K_{1,2} & \dots & K_{1,NA} \\ K_{2,1} & K_{2,2} & \dots & K_{2,NA} \\ \vdots & \vdots & \ddots & \vdots \\ K_{N,1} & K_{N,2} & \dots & K_{N,NA} \end{bmatrix} \quad (6)$$

که در آن، N و NA و n تعداد داده‌ها در مرحله آموزش (70% کل داده‌ها)، تعداد متغیرهای ورودی انتقالی به صورت ($i = 1, 2, \dots, N, j = 1, 2, \dots, NA$) و تعداد متغیرهای ورودی انتقالی به فضای شعاعی است. نگاشت تبدیل مبتنی بر K_{ij} ابعاد داده‌های ورودی را از n بعد به NA بعد در فرآیند کالیبراسیون M5Tree تغییر می‌دهد.

۳- نتایج و بحث

پیش‌بینی بار رسوب معلق (SSL) برای جنبه‌های مختلف مهندسی رودخانه، طراحی سازه‌های هیدرولیکی و به طور کلی مهندسی منابع آب، اهمیت بسیار زیادی دارد. از این رو در پژوهش حاضر تمرکز اصلی بر تحلیل داده‌های هیدرولوژیکی و بررسی روند انتقال رسوب در رودخانه مورد مطالعه بوده است. اگرچه پارامترهایی مانند بارش و دما از عوامل موثر در فرآیندهای رسوب‌گذاری محسوب می‌شوند، اما به دلیل محدودیت در دسترسی به داده‌های پیوسته و قابل اعتماد در بازه زمانی مورد بررسی، این متغیرها در تحلیل‌ها لحاظ نشده‌اند. از سوی دیگر، مطالعات متعدد نشان داده‌اند که دبی رودخانه به‌عنوان عامل مستقیم و دینامیک، تاثیرگذاری بیشتری نسبت به پارامترهای اقلیمی بر میزان انتقال رسوب دارد. تغییرات لحظه‌ای و فصلی دبی می‌تواند به‌طور مستقیم ظرفیت حمل رسوب را تحت تاثیر قرار دهد، در حالی که اثر بارش و دما معمولاً غیرمستقیم و با تأخیر زمانی همراه است. مطالعه حاضر به پیاده‌سازی و بررسی یک مدل پیش‌بینی یادگیری ماشین ترکیبی جدید و قوی‌تر برای غلظت رسوب روزانه اختصاص

³ Agreement index

¹ Root mean square error

² Mean absolute error

جدول ۳ مقایسه آماری مدل‌های مختلف در فاز آزمون به ازای سناریوهای یک تا شش.

Table 3 Comparative statistics for different models in test periods

Input data	Models	Test			
		MAE (ton/day)	RMSE (ton/day)	d/MAE	NSE
Sce.1	ANN	1950.7	8308.1	0.023	0.351
	M5Tree	718.3	3904.4	0.051	0.761
	RM5Tree(NA=10)	726.3	4401.6	0.052	0.773
	RM5Tree(NA=15)	693.9	4248.7	0.052	0.786
Sce.2	ANN	2012.2	6314.0	0.028	0.331
	M5Tree	633.8	3687.8	0.059	0.789
	RM5Tree(NA=10)	772.6	3667.5	0.097	0.750
	RM5Tree(NA=15)	629.9	3576.0	0.124	0.800
Sce.3	ANN	1499.4	4977.2	0.039	0.501
	M5Tree	648.7	3043.6	0.048	0.784
	RM5Tree(NA=10)	663.7	3000.7	0.070	0.770
	RM5Tree(NA=15)	618.4	2814.5	0.076	0.813
Sce.4	ANN	1200.1	4669.8	0.048	0.601
	M5Tree	611.2	3728.0	0.061	0.797
	RM5Tree(NA=10)	778.1	6365.6	0.072	0.741
	RM5Tree(NA=15)	504.8	3367.9	0.076	0.832
Sce.5	ANN	1387.4	5365.9	0.047	0.539
	M5Tree	579.2	2947.8	0.053	0.807
	RM5Tree(NA=10)	641.2	3192.9	0.076	0.758
	RM5Tree(NA=15)	546.8	2528.2	0.090	0.807
Sce.6	ANN	947.7	4469.0	0.065	0.685
	M5Tree	553.0	2840.8	0.055	0.816
	RM5Tree(NA=10)	450.4	2141.8	0.060	0.840
	RM5Tree(NA=15)	427.2	2091.8	0.076	0.863

برای تفاوت در واریانس پیش‌بینی، مکانیزم‌های مدل‌سازی متفاوت مدل‌های یادگیری ماشین به کاررفته و همچنین تاثیر هر متغیر ورودی منتخب بر الگوی فعلی بار رسوب

مجموعه داده فضای شعاعی NA بعدی به عنوان پایگاه داده جدید برای آموزش مدل M5Tree تبدیل می‌کند، واریانس‌های پیش‌بینی متفاوتی را نشان دادند. دلیل اصلی

آزمون، ترکیب ورودی دوم مدل RM5Tree شامل Q_{t-1} ، Q_t و SSL_{t-1} و با استفاده از (NA-radial فضای پایه = center = 15) بالاترین مقدار نسبت ($d/MAE \approx 0.12$) را نشان داد.

اعتبارسنجی گرافیکی دیگری برای مدل‌های پیش‌بین به کاررفته با استفاده از نمودار پراکندگی انجام شد. واریانس بین مقادیر مشاهده‌شده و پیش‌بینی‌شده SSL در **شکل ۴** نشان داده شده است. نمودارهای پراکندگی برای تمام شش سناریوی ورودی فرموله‌شده تولید شده‌اند. از شکل‌های نمایش داده‌شده واضح است که مدل RM5Tree نسبت به دو مدل دیگر یادگیری ماشین، واریانس نزدیک‌تری به خط ایده‌آل (خط ۴۵ درجه) به‌دست آورده است.

با رجوع به مطالعات پیشین، (Rajae et al. 2009) قابلیت ANFIS و ANN را برای شبیه‌سازی SSL با استفاده از اطلاعات جریان رودخانه و رسوب بررسی کردند. مدل ANFIS بهترین نتایج پیش‌بینی را با ضریب همبستگی ($R^2 \approx 0.835$) ارائه داد. در مطالعه دیگری، (Vafakhah, 2013) سه مدل یادگیری ماشین شامل ANFIS، ANN و cokriging را برای همین منظور توسعه داد. معیارهای آماری مبتنی بر NSE برای سه مدل به کاررفته به ترتیب NSE برابر با ۰/۶۴، ۰/۷۹ و ۰/۸۵ بودند. از دقت‌های مدل‌سازی گزارش شده در **جدول ۲** مشهود است که مدل RM5Tree با موفقیت پیش‌بینی SSL را (با $R^2 \approx 0.88$ و $NSE \approx 0.86$) انجام داده است.

به طور کلی، محاسبات نشان دادند که مدل RM5Tree یک تکنیک مدل‌سازی قوی و قابل اعتماد برای پیش‌بینی بار رسوب معلق است. اطلاعات ضروری را می‌توان بر اساس قابلیت اطمینان مدل‌های به کاررفته برای پایداری حوضه آبریز و کنترل آلودگی آب مورد استفاده قرار داد. رویه مدل‌سازی می‌تواند با استفاده از ابعاد دیگری مانند یکپارچه‌سازی بهینه‌سازی الهام‌گرفته از طبیعت با مدل‌های به کاررفته، بهبود یابد. همچنین، امکان بهبود از طریق انتزاع ویژگی‌های ورودی وجود دارد؛ به عنوان مثال، پیاده‌سازی رویکرد آماری اطلاعات متقابل (MI^4) می‌تواند به عنوان یک

معلق است. لازم به ذکر است که فرمول‌بندی ماتریس ورودی با استفاده از اطلاعات یک و دو گام زمانی پیشین Q و SSL ، به علاوه مقدار فعلی Q ، پتانسیل پیش‌بینی دقیق SSL_t را با مقادیر $MAE \approx 427$ و $RMSE \approx 2090$ تن در روز، در حالی که $d \approx 0.92$ و $NSE \approx 0.86$ بود، به اثبات رساند. نتایج، همبستگی، اطلاعات فرموله‌شده پیشین رسوب و دبی رودخانه را به عنوان اصلی‌ترین ویژگی‌های هیدرولوژیکی تایید کردند. برای اعتبارسنجی بیشتر، نتایج مطالعه حاضر با پژوهش انجام‌شده بر روی همین مطالعه موردی توسط (Shiri and Kişi, 2012) مقایسه شده است. در آن پژوهش، نویسندگان از مدل‌های برنامه‌نویسی بیانی ژنی (GEP^1)، موجک- GEP ($W-GEP^2$)، سیستم عصبی-فازی (3NF)، موجک- NF ($W-NF$) و موجک-شبکه عصبی مصنوعی ($W-ANN$) برای پیش‌بینی بار رسوب معلق استفاده کرده‌اند. دقت پیش‌بینی این مدل‌ها بر اساس شاخص $RMSE$ ارزیابی شده و مقادیر حاصل به ترتیب برابر با ۲۶۸۹، ۲۳۹۶، ۶۱۶۴، ۲۴۹۴ و ۲۵۰۸ تن در روز بوده‌اند. در مقایسه با مطالعه حاضر، مدل پیشنهادی RM5Tree بهبود قابل توجهی در دقت پیش‌بینی نشان داده است، به طوری که به ترتیب بهبودهایی معادل ۲۲/۲٪، ۱۲/۷٪، ۶۶/۱٪، ۱۶/۱٪ و ۱۶/۶٪ نسبت به مدل‌های $W-GEP$ ، $W-ANN$ ، NF ، $W-NF$ و GEP حاصل شده است.

شکل ۳ نسبت d به MAE (d/MAE) را برای تمام شش ترکیب ورودی فرموله‌شده و برای تمام مدل‌های یادگیری ماشین به کاررفته نشان می‌دهد. بر اساس نتایج به‌دست‌آمده، سناریوی با مقدار بالای نسبت (d/MAE) بهترین قابلیت پیش‌بینی ممکن مدل‌سازی را از خود نشان می‌دهد. نسبت عملکرد برای پیش‌بینی‌ها در فازهای آموزش و آزمون محاسبه و در **شکل‌های a۳** و **b۳** نشان داده شده است. بر اساس نمایش گرافیکی به‌دست‌آمده و در طول فرآیند آموزش، سناریوی ورودی ششم مدل RM5Tree شامل (Q_t ، Q_{t-1} ، Q_{t-2} و SSL_{t-1}) و با استفاده از (NA-radial فضای پایه = 15) بالاترین مقدار نسبت ($d/MAE \approx 0.22$) را گزارش کرد. در حالی که، در طول فاز

³ Neuro Fuzzy

⁴ Mutual information

¹ Gene Expression Programming

² Wavelet GEP




Fig. 3 d/MAE ratio for six input data scenarios based on different models in a) Train and b) Test phases.

شکل ۳ نسبت شاخص d به میانگین خطای مطلق (d/MAE) به ازای شش سناریوی داده ورودی در فاز الف) آموزش و ب) آزمون

بالای SSL در رودخانه ایجاد شود؛ مانند کاهش کیفیت آب، کاهش کارایی سازه‌های هیدرولیکی و چندین تاثیر منفی دیگر. از این رو، کمی‌سازی SSL یکی از چالش‌های عمده مرتبط با مدیریت حوضه آبریز است و ارائه یک مدل کامپیوتری قابل اعتماد برای تخمین آن همواره در خط مقدم علائق پژوهشی در مدیریت منابع آب قرار داشته است. مطالعه حاضر به بررسی یک مدل داده‌کاوی ترکیبی تازه توسعه‌یافته به نام مدل یکپارچه الگوریتم پایه شعاعی با $M5Tree$ برای پیش‌بینی بار رسوب معلق در ایستگاه هواشناسی ترنتون در رودخانه دلاور، ایالات متحده آمریکا،

مرحله پیش از مدل‌سازی برای فرآیندهای پیش‌بینی به منظور انتزاع اطلاعات با همبستگی بالا، با آن یکپارچه شود. این رویکرد مبتنی بر نظریه اطلاعات و مفهوم آنتروپی است (Fraser and Swinney, 1986).

۴- نتیجه‌گیری

غلظت بار رسوب معلق (SSL) یکی از عناصر حیاتی در پایداری مهندسی رودخانه است و تعیین آن اهمیت بسیار زیادی دارد. پیامدهای متعددی می‌تواند به دلیل غلظت

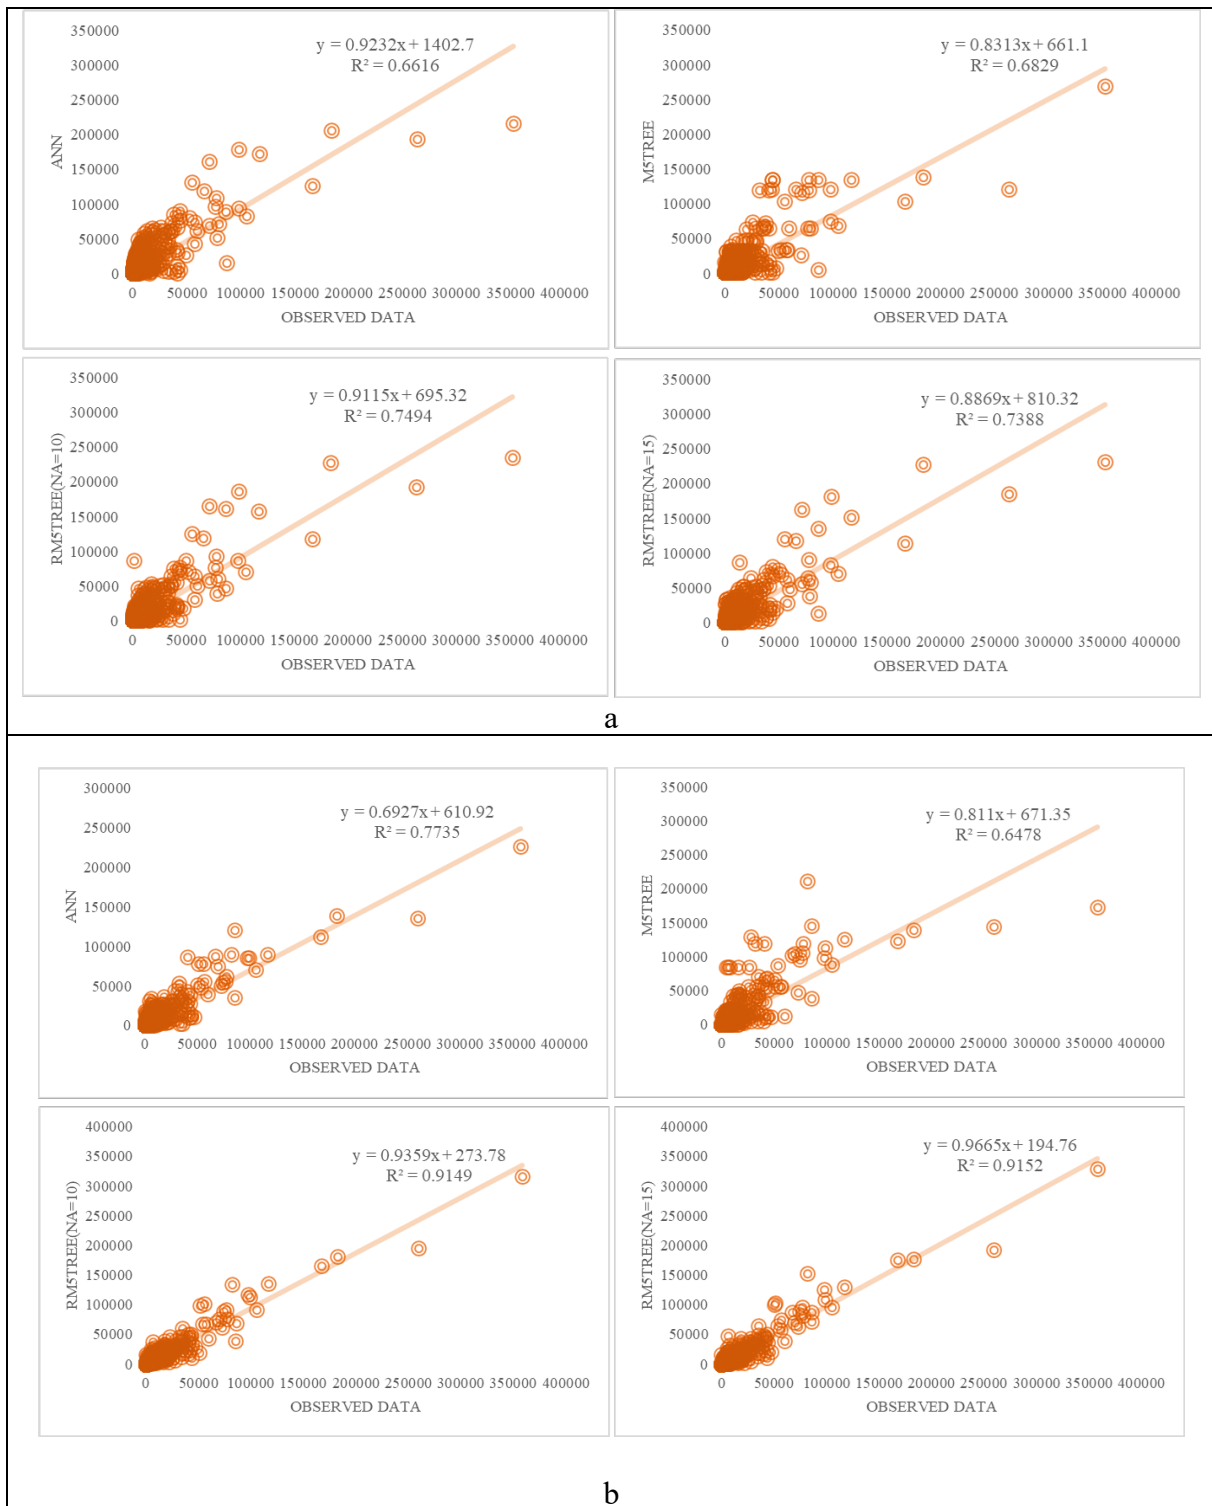


Fig. 4 Observed and predicted suspended sediment scatter plot variation over the applied predictive models for the testing phase modeling Input dataset, a) sce.1, b) sce.2, c) sce.3, d) sce.4, e) sce.5, and f) sce.6

شکل ۴ نمودار داده‌های مشاهداتی در مقابل داده‌های پیش‌بینی مدل‌های مورد استفاده در پژوهش در مرحله آزمون به ازای الف) سناریوی ۱، ب) سناریوی ۲، ج) سناریوی ۳، د) سناریوی ۴، ه) سناریوی ۵، و و) سناریوی ۶.

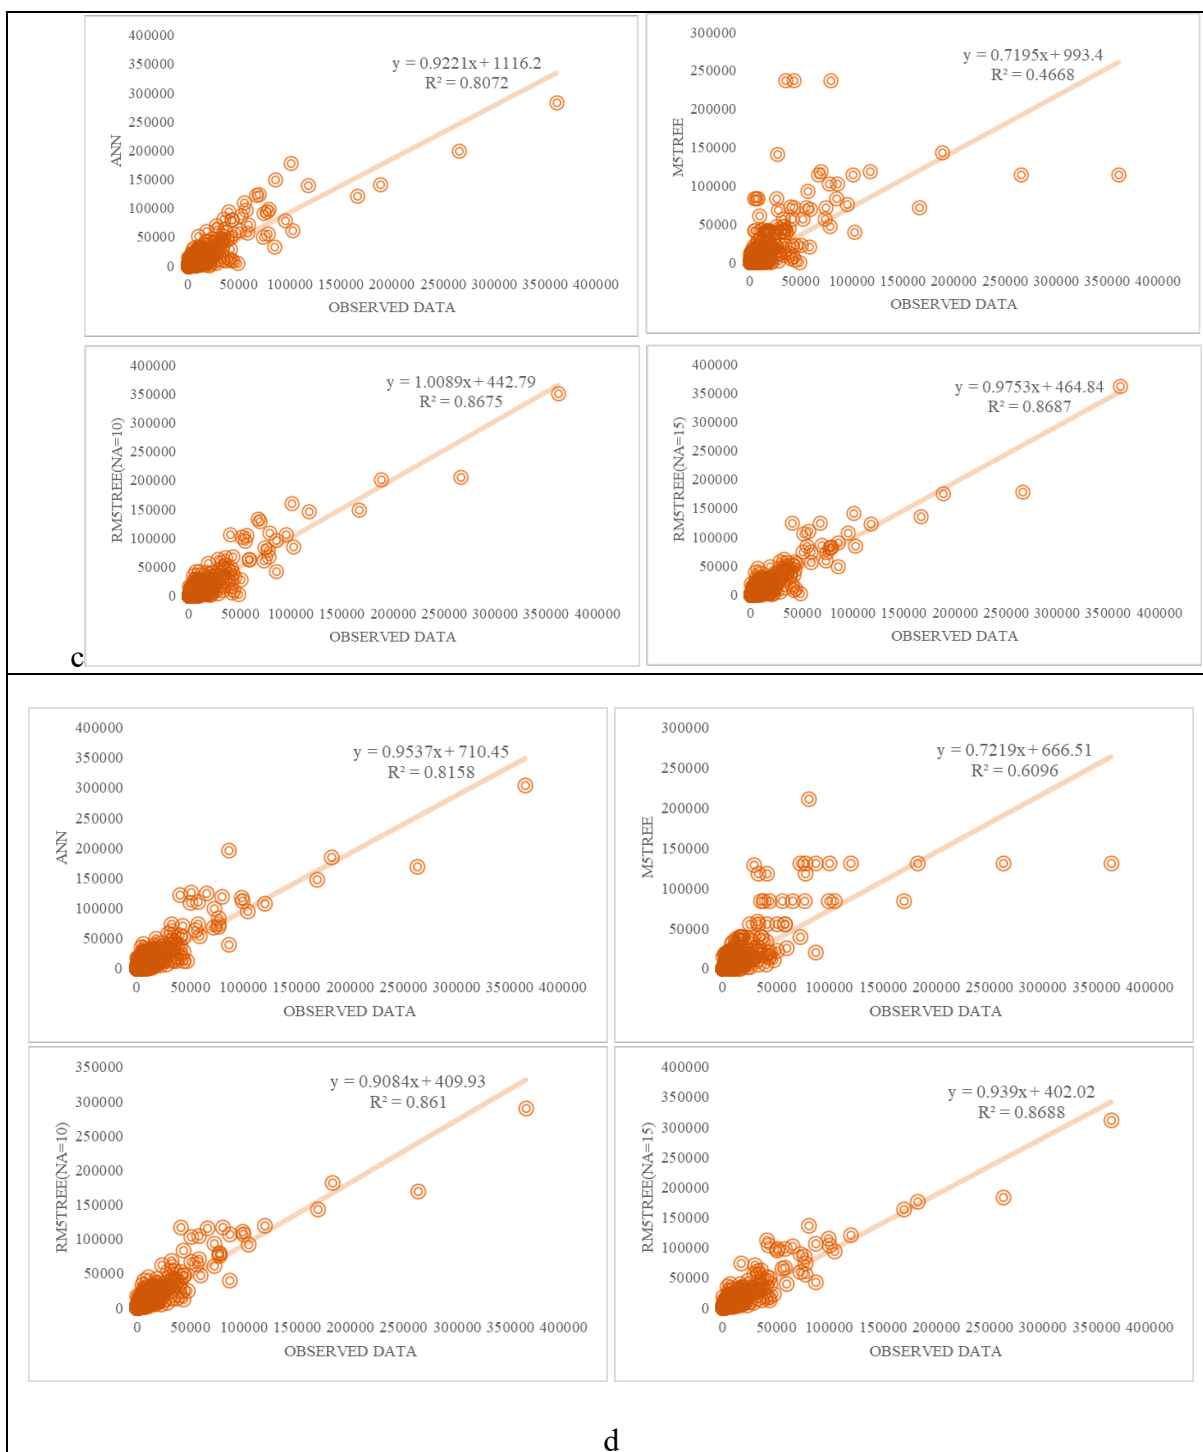


Fig. 4 Observed and predicted suspended sediment scatter plot variation over the applied predictive models for the testing phase modeling Input dataset, a) sce.1, b) sce.2, c) sce.3, d) sce.4, e) sce.5, and f) sce.6 (Continued)

شکل ۴ نمودار داده‌های مشاهداتی در مقابل داده‌های پیش‌بینی مدل‌های مورد استفاده در پژوهش در مرحله آزمون به ازای الف) سناریوی ۱، ب) سناریوی ۲، ج) سناریوی ۳، د) سناریوی ۴، ه) سناریوی ۵، و و) سناریوی ۶ (ادامه)

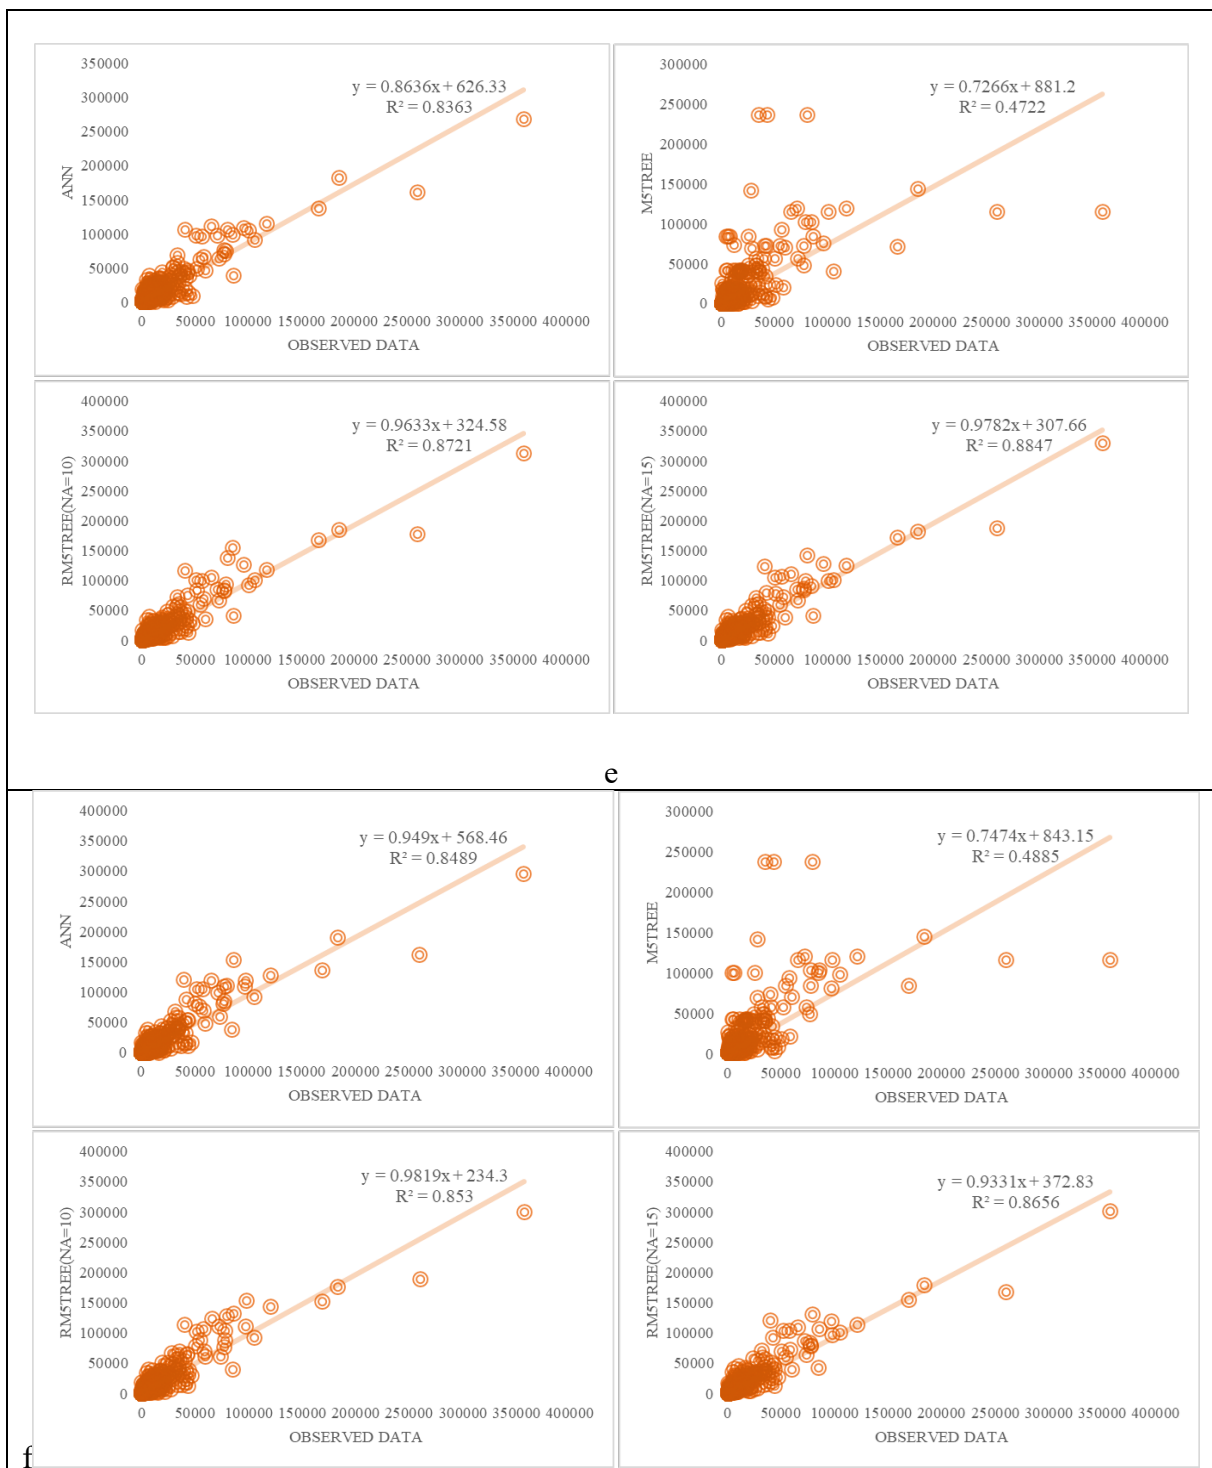


Fig. 4 Observed and predicted suspended sediment scatter plot variation over the applied predictive models for the testing phase modeling Input dataset, a) sce.1, b) sce.2, c) sce.3, d) sce.4, e) sce.5, and f) sce.6 (Continued)

شکل ۴ نمودار داده‌های مشاهداتی در مقابل داده‌های پیش‌بینی مدل‌های مورد استفاده در پژوهش در مرحله آزمون به ازای الف) سناریوی ۱، ب) سناریوی ۲، ج) سناریوی ۳، د) سناریوی ۴، ه) سناریوی ۵، و و) سناریوی ۶ (ادامه)

RM5Tree به مطالعه موردی فعلی محدود نمی‌شود؛ با این حال، امکان‌سنجی پیش‌بینی آن در مقایسه با مدل‌های یادگیری ماشین پیشرفته به طور قابل توجهی متمایز بود. اطلاعات یک و دو گام زمانی پیشین دبی جریان رودخانه و SSL به علاوه مقدار فعلی Q ، بیشترین همبستگی را با مقدار فعلی SSL داشتند که در آن نتایج پیش‌بینی دقیق به دست آمد. به طور کلی، صحت‌سنجی مدل بررسی شده، شایستگی مدل داده‌کاوی ترکیبی را به عنوان یک ابزار کامپیوتری کمکی جدید برای تشخیص الگوی SSL و به طور کلی مدیریت بهتر حوضه آبریز، نشان داد.

اختصاص دارد. با توجه به تاثیر گسترده دبی رودخانه بر میزان انتقال رسوب، رویه مدل‌سازی بر اساس چندین ترکیب ورودی با استفاده از پایگاه داده (Q و SSL) فرمول‌بندی شد. پیش از فرآیند پیش‌بینی، تحلیل تغییرپذیری ورودی برای بهینه‌سازی ویژگی‌های ورودی برای مدل‌های پیش‌بین به‌کاررفته، بررسی شد. نتایج، قابلیت RM5Tree پیشنهادی را در درک مکانیزم واقعی بین ویژگی‌های ورودی ساخته‌شده و SSL هدف، به اثبات رساند. مدل RM5Tree مهارت پیش‌بینی بالاتری را نسبت به سایر مدل‌های یادگیری ماشین مبنا نشان داد. عملکرد مدل

5- List of symbols

Q (m^3s^{-1})	River discharge	φ_j	The output dataset of the j -th hidden neuron
μ ($kgm^{-1}s^{-1}$)	Dynamic viscosity	w_j	The connection weights between output neuron to j -th neuron of the hidden layer
SBL	Sediment bed load	n	Number of input neurons
SSL	Suspended sediment load	BP	Back-propagation
MT	Model tree	SDR	The standard deviation reduction
RM5Tree	M5 tree model with radial function basis	PDF	Probability distribution function
ANN	Artificial neural network	CDF	Cumulative destitution function
ML	Machine learning	erf	The error function
SVM	Support vector machine	$\ \cdot \ $	The length of a difference vector
X_{max}	Maximum	μ_x	Mean deviation of input variable x
X_{min}	minimum	σ_x	Standard deviation of input variable x
X_{mean}	Mean	K_{ij}	The input variables
STD	Standard deviation		
b	Bias of the output neuron		

Acknowledgments

This research was conducted with the full cooperation of the authors.

Credit Authorship Contribution Statement

Conceptualization, M.S.H. and B.M.; Methodology, M.S.H. and B.M.; Software, B.M.; data analysis, M.S.H.; Writing-Original Draft Preparation, M.S.H.; Writing-Review and Editing, M.S.H. Supervision, M.S.H. and B.M.. All authors have read and agreed to the published version of the manuscript.

Funding

The authors state that no financial support was received from any organization for this research. Data Availability Statement
The data that support the findings of this study are available from the corresponding author upon reasonable request. No additional data are available beyond what is presented in the manuscript.

Conflicts of Interest

The authors declare no conflict of interest.

References

- Afan HA, El-shafie A, Mohtar WHMW, Yaseen ZM (2016) Past, present and prospect of an Artificial Intelligence (AI) based model for sediment transport prediction Journal of Hydrology 541:902-913
<https://doi.org/10.1016/j.jhydrol.2016.07.048>
- Allawi MF, Sulaiman SO, Sayl KN, Sherif M, El-Shafie A (2023) Suspended sediment load prediction modelling based on artificial intelligence methods: The tropical region as a case study Heliyon 9:e18506
<https://doi.org/10.1016/j.heliyon.2023.e18506>
- Antoniazza G et al. (2022) Hydrological Drivers of Bedload Transport in an Alpine Watershed

- Water Resources Research 58:e2021WR030663
doi:<https://doi.org/10.1029/2021WR030663>
- Aytek A, Kişi Ö (2008) A genetic programming approach to suspended sediment modelling Journal of hydrology 351:288-298
<https://doi.org/10.1016/j.jhydrol.2007.12.005>
- 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>
- Colby BR, Hembree CH (1954) Computations of total sediment discharge, Niobrara River near Cody, Nebraska Science 119:657-658
- Corline NJ, Bellido-Leiva F, Alarcon A, Dahlgren R, Van Nieuwenhuysse EE, Beakes M, Lusardi RA (2023) Reservoir-derived subsidies provide a potential management opportunity for novel river ecosystems Journal of Environmental Management 345:118852
doi:<https://doi.org/10.1016/j.jenvman.2023.118852>
- Doro L et al. (2021) Improving the simulation of soil temperature within the EPIC model Environmental Modelling & Software 144:105140
doi:<https://doi.org/10.1016/j.envsoft.2021.105140>
- Fraser AM, Swinney HL (1986) Independent coordinates for strange attractors from mutual information Physical review A 33:1134
- Gao L et al. (2021) GPS-ZTD data assimilation and its impact on wintertime haze prediction over North China Plain using WRF 3DVAR and CMAQ modeling system Environmental Science and Pollution Research 28:68523-68538
doi:[10.1007/s11356-021-15248-9](https://doi.org/10.1007/s11356-021-15248-9)
- Goyal MK (2014) Modeling of sediment yield prediction using M5 model tree algorithm and wavelet regression Water resources management 28:1991-2003
<https://doi.org/10.1007/s11269-014-0590-6>
- Goyal MK, Ojha C (2011) Estimation of scour downstream of a ski-jump bucket using support vector and M5 model tree Water Resources Management 25:2177-2195
<https://doi.org/10.1007/s11269-011-9801-6>
- Hagan MT, Menhaj MB (1994) Training feedforward networks with the Marquardt algorithm IEEE transactions on Neural Networks 5:989-993
- Haykin S (1994) Neural networks: a comprehensive foundation. Prentice Hall PTR,
- Hecht-Nielsen R (1992) Theory of the backpropagation neural network. In: Neural networks for perception. Elsevier, pp 65-93
- Hokanson KJ, Thompson C, Devito K, Mendoza CA (2021) Hummock-scale controls on groundwater recharge rates and the potential for developing local groundwater flow systems in water-limited environments Journal of Hydrology 603:126894
doi:<https://doi.org/10.1016/j.jhydrol.2021.126894>
- Keshtegar B, Heddami S (2018) Modeling daily dissolved oxygen concentration using modified response surface method and artificial neural network: a comparative study Neural Computing and Applications 30:2995-3006
doi:10.1007/s00521-017-2917-8
- Kisi O, Yaseen ZM (2019) The potential of hybrid evolutionary fuzzy intelligence model for suspended sediment concentration prediction Catena 174:11-23
<https://doi.org/10.1016/j.catena.2018.10.047>
- Liu W, Lü H, Zhu Y, Wang X, Gao P, Su J (2024) The performance of IMERG near-real-time estimations during the record-breaking Meiyu season in 2020 Journal of Hydrology 634:131024
doi:<https://doi.org/10.1016/j.jhydrol.2024.131024>
- Liu Z, Wang Q, Meng F (2022) A benchmark for multi-class object counting and size estimation using deep convolutional neural networks Engineering Applications of Artificial Intelligence 116:105449
doi:<https://doi.org/10.1016/j.engappai.2022.105449>
- Ma Z, Mei G (2021) Deep learning for geological hazards analysis: Data, models, applications, and opportunities Earth-Science Reviews 223:103858
doi:<https://doi.org/10.1016/j.earscirev.2021.103858>
- Marjanović M, Krautblatter M, Abolmasov B, Đurić U, Sandić C, Nikolić V (2018) The rainfall-induced landsliding in Western Serbia: A temporal prediction approach using Decision Tree technique Engineering Geology 232:147-159
<https://doi.org/10.1016/j.enggeo.2017.11.021>
- Meles MB, Goodrich DC, Gupta HV, Shea Burns I, Unkrich CL, Razavi S, Guertin DP (2021) Multi-criteria, time dependent sensitivity analysis of an event-oriented, physically-based, distributed sediment and runoff model Journal of Hydrology 598:126268
doi:<https://doi.org/10.1016/j.jhydrol.2021.126268>
- Milion RN, Paliari JC, Liboni LHB (2016) Improving consumption estimation of electrical materials in residential building construction

- Automation in Construction 72:93-101
doi:<https://doi.org/10.1016/j.autcon.2016.08.042>
- Nourani V, Baghanam AH, Adamowski J, Kisi O (2014) Applications of hybrid wavelet-artificial intelligence models in hydrology: a review Journal of Hydrology 514:358-377
<https://doi.org/10.1016/j.jhydrol.2014.03.057>
- Olyaie E, Banejad H, Chau K-W, Melesse AM (2015) A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: a case study in United States Environmental monitoring and assessment 187:1-22
<https://doi.org/10.1007/s10661-015-4381-1>
- Özger M, Kabataş MB (2015) Sediment load prediction by combined fuzzy logic-wavelet method Journal of Hydroinformatics 17:930-942
- Pahlavan-Rad MR et al. (2020) Prediction of soil water infiltration using multiple linear regression and random forest in a dry flood plain, eastern Iran CATENA 194:104715
doi:<https://doi.org/10.1016/j.catena.2020.104715>
- Pham BT, Tien Bui D, Prakash I (2017) Application of classification and regression trees for spatial prediction of rainfall-induced shallow landslides in the Uttarakhand area (India) using GIS. In: Climate Change, Extreme Events and Disaster Risk Reduction: Towards Sustainable Development Goals. Springer, pp 159-170
https://doi.org/10.1007/978-3-319-56469-2_11
- Quinlan JR (1992) Learning with Continuous Classes. Paper presented at the Proceedings of Australian Joint Conference on Artificial Intelligence, Hobart, 16-18 November
- Rajaei T, Mirbagheri SA, Zounemat-Kermani M, Nourani V (2009) Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models Science of the total environment 407:4916-4927
<https://doi.org/10.1016/j.scitotenv.2009.05.016>
- Samadi M, Jabbari E, Azamathulla HM (2014) Assessment of M5' model tree and classification and regression trees for prediction of scour depth below free overfall spillways Neural Computing and applications 24:357-366
<https://doi.org/10.1007/s00521-012-1230-9>
- Sefati Z, Khalilimoghdam B, Nadian H (2019) Assessing urban soil quality by improving the method for soil environmental quality evaluation in a saline groundwater area of Iran CATENA 173:471-480
doi:<https://doi.org/10.1016/j.catena.2018.10.040>
- Shah S et al. (2021) Evaluating the added value of multi-variable calibration of SWAT with remotely sensed evapotranspiration data for improving hydrological modeling Journal of Hydrology 603:127046
doi:<https://doi.org/10.1016/j.jhydrol.2021.127046>
- Shamaei E, Kaedi M (2016) Suspended sediment concentration estimation by stacking the genetic programming and neuro-fuzzy predictions Applied Soft Computing 45:187-196
<https://doi.org/10.1016/j.asoc.2016.03.009>
- Shiau J-T, Chen T-J (2015) Quantile regression-based probabilistic estimation scheme for daily and annual suspended sediment loads Water Resources Management 29:2805-2818
<https://doi.org/10.1007/s11269-015-0971-5>
- Shiri J, Kişi Ö (2012) Estimation of daily suspended sediment load by using wavelet conjunction models Journal of Hydrologic Engineering 17:986-1000
[https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000535](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000535)
- Solomatine DP, Xue Y (2004) M5 model trees and neural networks: application to flood forecasting in the upper reach of the Huai River in China Journal of Hydrologic Engineering 9:491-501
[https://doi.org/10.1061/\(ASCE\)1084-0699\(2004\)9:6\(491\)](https://doi.org/10.1061/(ASCE)1084-0699(2004)9:6(491))
- Soni JP, Ranga Raju KG, Garde RJ (1980) Aggradation in streams due to overloading Journal of the Hydraulics Division 106:117-132
- Taghi Sattari M, Pal M, Apaydin H, Ozturk F (2013) M5 model tree application in daily river flow forecasting in Sohu Stream, Turkey Water Resources 40:233-242
<https://doi.org/10.1134/S0097807813030123>
- Talebi A, Mahjoobi J, Dastorani MT, Moosavi V (2017) Estimation of suspended sediment load using regression trees and model trees approaches (Case study: Hyderabad drainage basin in Iran) ISH journal of Hydraulic Engineering 23:212-219
<https://doi.org/10.1080/09715010.2016.1264894>
- Tang X, Knight DW (2006) Sediment transport in river models with overbank flows Journal of Hydraulic Engineering 132:77-86
[https://doi.org/10.1061/\(ASCE\)0733-9429\(2006\)132:1\(77\)](https://doi.org/10.1061/(ASCE)0733-9429(2006)132:1(77))
- Tien Bui D, Pham BT, Nguyen QP, Hoang N-D (2016) Spatial prediction of rainfall-induced shallow landslides using hybrid integration approach of Least-Squares Support Vector Machines and differential evolution optimization: a case study in Central Vietnam International Journal of Digital Earth 9:1077-1097
- Ulke A, Tayfur G, Ozkul S (2017) Investigating a suitable empirical model and performing regional analysis for the suspended sediment

- load prediction in major rivers of the Aegean Region, Turkey Water Resources Management 31:739-764
<https://doi.org/10.1007/s11269-016-1357-z>
- Vafakhah M (2013) Comparison of cokriging and adaptive neuro-fuzzy inference system models for suspended sediment load forecasting Arabian Journal of Geosciences 6:3003-3018
<https://doi.org/10.1007/s12517-012-0550-5>
- Vollert SA, Drovandi C, Monsalve-Bravo GM, Adams MP (2023) Strategic model reduction by analysing model sloppiness: A case study in coral calcification Environmental Modelling & Software 159:105578
 doi:<https://doi.org/10.1016/j.envsoft.2022.105578>
- Wang Y et al. (2022) Estimating the long-term deformation and permanent loss of aquifer in the southern Junggar Basin, China, using InSAR Journal of Hydrology 614:128604
 doi:<https://doi.org/10.1016/j.jhydrol.2022.128604>
- Wilcock PR, Kenworthy ST, Crowe JC (2001) Experimental study of the transport of mixed sand and gravel Water Resources Research 37:3349-3358
<https://doi.org/10.1029/2001WR000683>
- Yang CT, Molinas A, Wu B (1996) Sediment transport in the Yellow River Journal of Hydraulic Engineering 122:237-244
- Yaseen ZM, Deo RC, Hilal A, Abd AM, Bueno LC, Salcedo-Sanz S, Nehdi ML (2018) Predicting compressive strength of lightweight foamed concrete using extreme learning machine model Advances in Engineering Software 115:112-125
<https://doi.org/10.1016/j.advengsoft.2017.09.004>
- Yaseen ZM, El-Shafie A, Jaafar O, Afan HA, Sayl KN (2015) Artificial intelligence based models for stream-flow forecasting: 2000–2015 Journal of Hydrology 530:829-844
<https://doi.org/10.1016/j.jhydrol.2015.10.038>
- Zeng Y, Meng X, Zhang Y, Dai W, Fang N, Shi Z (2022) Estimation of the volume of sediment deposited behind check dams based on UAV remote sensing Journal of Hydrology 612:128143
 doi:<https://doi.org/10.1016/j.jhydrol.2022.128143>
- Zhuang L et al. (2021) Unsaturated flow effects on solute transport in porous media Journal of Hydrology 598:126301
 doi:<https://doi.org/10.1016/j.jhydrol.2021.126301>
- Zounemat-Kermani M, Kişi Ö, Adamowski J, Ramezani-Charmahineh A (2016) Evaluation of data driven models for river suspended sediment concentration modeling Journal of Hydrology 535:457-472
<https://doi.org/10.1016/j.jhydrol.2016.02.012>