

Simulation of suspended sediment using a hybrid intelligent approach based on sediment rating curve and CANFIS network case study: Taleghan Glinak Station

Golaleh Ghaffari^{1*}

¹ Assistant Professor, Soil Conservation and Watershed Management Research Department, Kermanshah Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Kermanshah, Iran

Received: 23 December 2025

Accepted: 21 June 2026

Extended abstract

Introduction

Suspended sediment transport constitutes a critical challenge in water resources engineering, causing reservoir capacity reduction, water quality degradation, and hydraulic infrastructure damage. Conventional sediment rating curve (SRC) methods rely on simplifying assumptions that frequently fail to capture nonlinear and transient flow-sediment dynamics. Recent advances in data-driven approaches, particularly artificial neural networks (ANNs) and adaptive neuro-fuzzy inference systems, have demonstrated substantial potential for modeling such complex hydrological processes. This study develops and rigorously evaluates a hybrid framework that integrates empirical SRCs with a Coactive Neuro-Fuzzy Inference System (CANFIS) to enhance predictive accuracy and model robustness at the Glinak hydrometric station in the Taleghan watershed.

Materials and methods

The analysis utilized 800 paired observations of streamflow and suspended sediment discharge collected from Glinak station between 1971 and 2023. Data preprocessing involved outlier removal, homogeneity assessment using the standard normal homogeneity test, and normalization. Six empirical SRC methods were calibrated and evaluated: logarithmic-linear regression, multi-segment regression, Logged Mean Load within Discharge Classes Method (LMLWDC), modified FAO correction factor, parametric correction factor, and non-parametric correction factor. Performance evaluation employed the coefficient of determination (R^2), Nash-Sutcliffe efficiency (NSE), and relative mean error (RME). In parallel, six ANN architectures—Multilayer Perceptron (MLP), General Feed-Forward (GFF), Radial Basis Function (RBF), Support Vector Machine (SVM), Self-Organizing Feature Map (SOFM), and CANFIS—were trained using a 75%-25% train-test split. Model assessment utilized normalized mean squared error (NMSE), mean absolute error (MAE), and Pearson's correlation coefficient (R). Two hybrid configurations were examined: Hybrid Model 1 used the optimal SRC output as the sole input to CANFIS, whereas Hybrid Model 2 incorporated both SRC output and streamflow as inputs.

Results and discussion

A detailed interrogation of the findings at the Glinak hydrometric station reveals that conventional hydrological models encounter substantive structural constraints when estimating suspended sediment load under conditions of extreme data dispersion, as evidenced by a coefficient of variation of 206.75%. Pronounced fluctuations in sediment discharge, coupled with a right-skewed and heavy-tailed statistical distribution and the identification of 12.88% outliers, collectively suppressed the Nash–Sutcliffe efficiency (NSE) at this station. From a process-based perspective, the 3,700-fold variability in the sediment-to-flow discharge ratio corroborates the occurrence of hysteresis, underscoring the dependence of sediment yield on antecedent catchment states, particularly soil moisture conditions. Against this backdrop, Hybrid Model 1 (LMLWDC –CANFIS) achieved superior performance, attaining an NSE of 0.63 and markedly outperforming standalone empirical sediment rating curve (SRC) and artificial intelligence architectures. The robustness of this configuration stems from the strategic integration of empirically derived sediment rating-curve knowledge with the adaptive learning capacity of the Coactive Neuro-Fuzzy Inference System (CANFIS). By explicitly accommodating uncertainty and nonlinearity inherent in flow-sediment dynamics,

* Corresponding author: g.ghaffari@areeo.ac.ir

the model establishes a coherent balance between numerical prediction and hydromorphological realism, thereby enhancing predictive reliability under highly variable sediment transport regimes.

Conclusion

The results unequivocally demonstrate that the synergistic integration of empirical hydrological reasoning and artificial intelligence provides a resilient and efficient modeling framework for watersheds characterized by pronounced skewness and a high prevalence of anomalous observations. In this context, the CANFIS architecture, leveraging fuzzy logic to resolve complex nonlinear interactions, substantially improves the representation of hysteretic sediment dynamics and offers clear advantages over conventional computational structures, including multilayer perceptron (MLP), general feed-forward (GFF), radial basis function (RBF), support vector machine (SVM), and self-organizing feature map (SOFM) networks. Given the strategic significance of flood events in water resources engineering, the rigorous interrogation of outlier behavior is not optional but imperative. The proposed hybrid framework effectively captures and interprets these statistical anomalies with acceptable precision, thereby reinforcing its applicability in suspended sediment transport management under extreme hydrological conditions. To advance methodological robustness and scientific depth in future investigations, the establishment of comprehensive, high-resolution databases—particularly those documenting peak flood discharges—is strongly recommended. Incorporating auxiliary predictors such as antecedent soil moisture, rainfall intensity, and vegetation cover indices would further strengthen process representation and address hysteresis phenomena. Moreover, deploying advanced machine-learning paradigms, including Long Short-Term Memory (LSTM) networks, alongside robust preprocessing techniques such as quantile regression and outlier treatment methods, has strong potential to attenuate systematic error and enhance model confidence in integrated watershed management applications. Additionally, ensemble methods combining multiple model outputs and uncertainty quantification frameworks are recommended to improve predictive reliability and decision-making support in sediment yield estimation.

Keywords: Artificial Neural Network, Hybrid Model, Sediment Rating Curve, Suspended Sediment, Taleghan Watershed

Cite this article: Ghaffari, G., 2026. Simulation of suspended sediment using a hybrid intelligent approach based on sediment rating curve and CANFIS network case study: Taleghan Glinak Station. *Water. Eng. Manag.* 18(3), 400-419.

© 2026, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)



شبیه‌سازی رسوبات معلق با استفاده از رویکرد هوشمند ترکیبی منحنی سنجه و شبکه CANFIS، مطالعه موردی: ایستگاه گلینک طالقان

گلانه غفاری^{۱*}

^۱ استادیار پژوهشی، بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان کرمانشاه، سازمان تحقیقات آموزش و ترویج کشاورزی، کرمانشاه، ایران

تاریخ پذیرش: ۱۴۰۵/۰۳/۳۱

تاریخ دریافت: ۱۴۰۴/۱۰/۰۲

چکیده مبسوط

مقدمه

انتقال رسوبات معلق یکی از چالش‌های بنیادین در مهندسی منابع آب است که موجب کاهش ظرفیت مخازن، تخریب کیفیت آب و آسیب به زیرساخت‌های هیدرولیکی می‌شود. روش‌های متداول منحنی سنجه رسوب (SRC) بر فروض ساده‌سازی شده‌ای استوارند که اغلب در بازنمایی روابط غیرخطی و دینامیک جریان-رسوب ناکارآمدند. پیشرفت‌های اخیر در رویکردهای داده‌محور، به‌ویژه شبکه‌های عصبی مصنوعی (ANN) و سامانه‌های استنتاج عصبی-فازی تطبیقی، توانمندی قابل‌توجهی در مدلسازی این فرایندهای پیچیده هیدرولوژیکی نشان داده‌اند. این پژوهش چارچوب ترکیبی نوینی را توسعه و ارزیابی می‌کند که منحنی‌های سنجه تجربی را با سامانه استنتاج عصبی-فازی همکارانه (CANFIS) تلفیق می‌نماید تا دقت پیش‌بینی و استحکام مدل را در ایستگاه هیدرومتری گلینک واقع در حوزه آبخیز طالقان ارتقا بخشد.

مواد و روش‌ها

این تحقیق بر پایه ۸۰۰ مشاهده همزمان دبی جریان و دبی رسوب معلق جمع‌آوری شده از ایستگاه گلینک طی دوره ۱۴۰۲-۱۳۵۰ انجام شد. پیش‌پردازش داده‌ها شامل شناسایی داده‌های پرت، آزمون همگنی با روش نرمال استاندارد و نرمال‌سازی بود. شش روش تجربی منحنی سنجه رسوب و اسنجی و ارزیابی شدند: رگرسیون لگاریتمی-خطی، رگرسیون چندبخشی، روش میانگین بار لگاریتمی در دسته‌های دبی (LMLWDC)، ضریب اصلاحی فائو، ضریب اصلاحی پارامتری و ضریب اصلاحی ناپارامتری. ارزیابی عملکرد با استفاده از ضریب تعیین (R^2)، ضریب کارایی ناش-ساتکلیف (NSE) و میانگین خطای نسبی (RME) صورت گرفت. همزمان، شش معماری شبکه عصبی-پرسپترون چندلایه (MLP)، شبکه پیش‌خور تعمیم‌یافته (GFF)، تابع پایه شعاعی (RBF)، ماشین بردار پشتیبان (SVM)، نقشه خودسازمان‌ده (SOFM) و CANFIS با تقسیم ۷۵ درصد آموزش و ۲۵ درصد آزمون آموزش داده شدند. سنجش مدل‌ها با معیارهای خطای مربعات میانگین نرمال‌شده (NMSE)، میانگین قدرمطلق خطا (MAE) و ضریب همبستگی پیرسون (R) انجام شد. دو پیکربندی ترکیبی بررسی شدند: مدل ترکیبی ۱ که تنها از خروجی بهینه SRC به‌عنوان ورودی CANFIS استفاده کرد و مدل ترکیبی ۲ که هم خروجی SRC و هم داده‌های دبی جریان را در نظر گرفت.

* مسئول مکاتبات: g.ghaffari@areeo.ac.ir

نتایج و بحث

واکاوی یافته‌های پژوهش در ایستگاه گلینک مبین آن است که مدل‌های متداول هیدرولوژیک به دلیل پراکندگی افراطی داده‌ها با ضریب تغییرات بالا (۲۰۶/۷۵ درصد)، در برآورد دقیق بار رسوبی با محدودیت‌های ساختاری جدی مواجه هستند. نوسانات شدید دبی رسوب و وجود توزیع آماری چوله به راست و دم‌کلفت، در کنار شناسایی ۱۲/۸۸ درصد داده پرت، منجر به کاهش شاخص کارایی NSE در این ایستگاه شده است. از منظر فیزیکی، نوسان ۳۷۰۰ برابری نسبت دبی رسوب به جریان، وقوع پدیده هیستروسیس را تأیید می‌کند که نشان‌دهنده وابستگی بار رسوبی به شرایط پیشین حوضه نظیر رطوبت خاک است. در این میان، مدل ترکیبی ۱ (حد وسط دسته‌ها - CANFIS) با کسب شاخص NSE معادل ۰/۶۳، برتری قاطعی نسبت به مدل‌های منفرد نشان داد. موفقیت این الگو ریشه در تلفیق هوشمندانه دانش تجربی سنج رسوب با قدرت یادگیری سیستم استنتاج عصبی‌فازی دارد که توانسته است با مدیریت عدم قطعیت‌ها، توازن منطقی میان پیش‌بینی‌های عددی و واقعیت‌های هیدرومورفولوژیک برقرار سازد.

نتیجه‌گیری

یافته‌های این پژوهش به روشنی اثبات می‌کند که تلفیق هم‌افزایانه رویکردهای تجربی و هوش مصنوعی، چارچوبی استوار و کارآمد برای غلبه بر چالش‌های مدلسازی در حوضه‌هایی با چولگی بالا و فراوانی داده‌های پرت فراهم می‌آورد. بر این اساس، معماری CANFIS با بهره‌گیری هوشمندانه از منطق فازی، ظرفیت پردازش روابط غیرخطی پیچیده و تحلیل دقیق پدیده Hysteresis را به‌طور معنی‌داری ارتقا بخشیده و مزایای متمایزی نسبت به ساختارهای کلاسیک محاسباتی ارائه کرده است. با توجه به نقش حیاتی و راهبردی رخدادهای سیلابی در مدیریت منابع آب واکاوی داده‌های پرت امری اجتناب‌ناپذیر تلقی می‌شود. در این راستا، مدل ترکیبی تدوین‌شده توانسته است با دقت قابل‌قبولی این ناهنجاری‌های آماری را پوشش داده و تحلیل نماید. به‌منظور ارتقای کارایی و غنای علمی در مطالعات آتی، توسعه بانک‌های اطلاعاتی جامع با تمرکز ویژه بر ثبت دقیق دبی‌های سیلابی و گنجاندن متغیرهای کمکی نظیر شدت بارندگی و وضعیت پوشش گیاهی اکیداً توصیه می‌شود. شایان ذکر است که به‌کارگیری الگوریتم‌های پیشرفته‌ای همچون یادگیری عمیق در قالب مدل‌های LSTM و استفاده از تکنیک‌های پیش‌پردازش مقاوم مانند رگرسیون کوانتیل^۱، می‌تواند منجر به کاهش چشمگیر خطاهای سیستماتیک و افزایش ضریب اطمینان مدل‌ها در مدیریت یکپارچه حوزه‌های آبخیز شود.

واژه‌های کلیدی: حوزه آبخیز طالقان رسوب معلق، شبکه عصبی مصنوعی، مدل ترکیبی، منحنی سنج رسوب

مقدمه

از آن‌جا که اندازه‌گیری مستقیم بار رسوبی در بسیاری از ایستگاه‌های هیدرومتری به‌صورت محدود و مقطعی انجام می‌شود، پژوهشگران به‌سوی توسعه رویکردهای نوین و هوشمند سوق یافته‌اند. در سال‌های اخیر، شبکه‌های عصبی مصنوعی (ANN) به‌عنوان ابزارهای قدرتمند در شبیه‌سازی پدیده‌های پیچیده و غیرخطی مانند فرایند رسوبگذاری معرفی شده‌اند (Issazadeh and Govay, 2014). این مدل‌ها، با تکیه بر قابلیت یادگیری از داده‌ها، توانسته‌اند دقت بالایی در برآورد بار رسوبات معلق ارائه دهند. برخی مطالعات نیز با تلفیق روش‌های داده‌محور نظیر ANN با مدل‌های

میزان رسوبات معلق یکی از عوامل کلیدی در فرایندهای هیدرولیکی و طراحی سازه‌های آبی محسوب می‌شوند و تأثیر قابل توجهی بر ظرفیت مخازن، کیفیت آب، انسداد مجاری انتقال و تخریب سازه‌ها دارند (Zhang, 2023). برآورد دقیق بار رسوب معلق، با وجود اهمیت آن در مدیریت پایدار منابع آب، همچنان چالشی اساسی است. زیرا بسیاری از روش‌های سنتی رگرسیونی و منحنی سنج، به دلیل اتکا به روابط ساده و محدودیت داده‌ای، در شرایط نوسانی و غیرخطی دقت کافی ندارند (Ahmadi, 2012؛ Karami et al., 2014).

¹ Quantile Regression

روبه‌رشد استفاده از مدل‌های هوشمند در کنار روش‌های رگرسیونی است. در یکی از نخستین پژوهش‌ها، Lohani et al., (2006) نشان دادند که ادغام منحنی سنج رسوب و شبکه‌های عصبی مصنوعی می‌تواند بازده پیش‌بینی مدل‌ها را به‌طور چشمگیری افزایش دهد.

در سال‌های اخیر، شبکه‌های عصبی مصنوعی (ANN) و مدل‌های ترکیبی داده‌مبنا رگرسیونی، به‌ویژه مدل‌های مبتنی بر CANFIS، توانسته‌اند دقت برآورد بار رسوب را به‌طور چشمگیری افزایش دهند. مطالعات متعددی نشان داده‌اند که استفاده از شبکه‌های عصبی در کنار منحنی سنج رسوب، ضمن بهره‌گیری از قابلیت یادگیری غیرخطی شبکه‌ها و کاهش خطاهای ناشی از داده‌های پراکنده، عملکرد پیش‌بینی را بهبود می‌بخشد (Ghaffari, Najafinejad et al., 2010). علاوه بر این، مدل‌های CANFIS با تلفیق منطق فازی و شبکه عصبی، توانایی بیشتری در مدیریت عدم قطعیت داده‌ها و شبیه‌سازی روابط پیچیده بین دبی و رسوب ارائه می‌دهند (Lee et al., Issazadeh and Govay, 2014). (2021)

در ایران، Arabkhedri et al., (2010) با بررسی اثر طراحی نمونه‌برداری خوشه‌ای تطبیقی^۳ بر برآورد منحنی سنج رسوب، نشان دادند که این روش نسبت به روش‌های متداول مبتنی بر تقویم، دقت بالاتری در برآورد بار رسوبی به‌ویژه در دوره‌های اوج سیلاب دارد. نتایج آنها بیانگر این بود که استفاده از نمونه‌برداری تطبیقی باعث افزایش برآورد بار رسوب تا ۳۰ درصد شد و روش LMLWDC در میان سایر روش‌ها کمترین خطا (حدود سه درصد) را ارائه داد.

در مطالعه‌ای دیگر، Arabkhedri et al., (2010) استفاده از روش نمونه‌برداری خوشه‌ای تطبیقی (ACS) در رودخانه گرگان‌رود ایران، عملکرد این روش را در مقایسه با منحنی‌های سنج رسوب متداول و روش SALT^۴ ارزیابی کردند. نتایج نشان داد که هیچ‌یک از منحنی‌های سنج رسوب برآورد دقیقی از بار معلق نداشتند، در حالی که دو روش ACS و SALT توانستند

رگرسیونی مانند منحنی سنج رسوب (SRC)، ساختارهای ترکیبی مؤثری را طراحی کرده‌اند که از مزایای هر دو رویکرد بهره می‌برند (Najafinejad et al., 2010).

در مطالعات عملی و مقایسه‌ای (۲۰۲۲-۲۰۲۴)، مدل‌های هیبریدی مبتنی بر الگوریتم‌های تکاملی، شبکه‌های عصبی و رویکردهای فازی (ازجمله CANFIS/ANFIS و نسخه‌های بهینه‌شده‌ی آنها) نسبت به منحنی سنج ساده در پیش‌بینی نوسانات مقادیر اوج و همچنین در بازه‌های پایه عملکرد برتری نشان داده‌اند (Choubin, Azamathulla et al., 2012). به‌ویژه هنگامی که داده‌ها شامل نویز و عدم تعادل باشند. مدل‌های ترکیبی تمایل دارند سوگیری (bias) و واریانس خطا را کاهش دهند (Yadav et al., 2022).

یکی از رویکردهای موفق در ادبیات، استفاده از «خوشه‌بندی» یا تقسیم‌بندی فضای داده و سپس آموزش مدل‌های محلی^۱ است. این روش‌ها اغلب عملکرد مدل‌های پایه را ارتقا می‌دهند و در برخی از مطالعات CANFIS یا دیگر سامانه‌های فازی-عصبی را به‌عنوان یکی از بهترین یادگیرنده‌ها معرفی کرده‌اند. نتایج تجربی نشان می‌دهد که مدل‌های دسته‌بندی‌شده^۲ به‌ویژه در شرایط داده‌ای ناهمگن (مثلاً دوره‌های کم و زیاد دبی) قادر به کاهش خطای پیش‌بینی SSC و بهبود شاخص‌های آماری مانند RMSE و R² هستند (Mahdavi-Meymand and Sulisz, 2023). به‌عنوان مثال، مدل‌های هیبریدی مبتنی بر بهینه‌سازهای چندهدفه که SVR یا دیگر یادگیرنده‌ها را با الگوریتم‌هایی مانند MOGWO/MOPSO/MOOLBO ترکیب کرده‌اند، به‌خوبی خطا را کاهش داده و پیچیدگی ورودی‌ها را بهینه کرده‌اند، که نشان‌دهنده سودمندی استراتژی‌های ترکیبی برای مسائل ناپایستا و غیرخطی رسوب است (Doroudi and Sharafati, 2024).

مطالعات متعددی در زمینه به‌کارگیری روش‌های داده‌محور و ترکیبی برای برآورد رسوبات معلق در سال‌های اخیر انجام شده است که نشان‌دهنده روند

^۳ Adaptive Cluster Sampling (ACS)

^۴ Selection At List Time

^۱ clustered/ clustered ML

^۲ clustered ML

اقلیمی متنوع ارزیابی کرده و محدودیت آن را در شرایط ناپایدار برجسته ساختند. (Shahidi et al., (2022) نیز در حوضه نکارود مازندران، با تحلیل تغییرات مکانی-زمانی رسوب معلق، نقش بارش و فصل را در رفتار رسوب تأیید کردند.

در مطالعه‌ای جامع، (Ghaffari (2024) در تحقیقی اقدام به ارائه مدل ترکیبی جدیدی متشکل از منحنی سنج رسوب و شبکه عصبی مصنوعی برای برآورد دقیق رسوبات معلق در ایستگاه هیدرومتری نارون (افجه) نمود و داده‌های دبی جریان و رسوب معلق مربوط به ۲۲۲ نمونه را با ۱۴ روش مختلف مورد شبیه‌سازی قرار داد. نتایج نشان داد که مدل ترکیبی با ضریب کارایی ۰/۸۷۶۱ و میانگین درصد خطای نسبی ۵۹/۶۳، ابزاری کارآمد و دقیق برای برآورد رسوبات معلق در رودخانه‌ها است و می‌تواند به‌عنوان یک روش جایگزین مناسب برای روش‌های سنتی مورد استفاده قرار گیرد.

مطالعات وسیع و متعددی در این حوضه در سطح بین‌المللی انجام شده است. (Malik et al., (2017) با هدف شبیه‌سازی غلظت روزانه رسوبات معلق (SSC) در ایستگاه Tekra از حوضه رودخانه Pranhita هند عملکرد چندین روش هوش مصنوعی و آماری را مورد مقایسه قرار دادند. برای این منظور، داده‌های دبی و غلظت رسوب روزانه طی دوره ژوئن ۲۰۰۰ تا نوامبر ۲۰۰۳ به‌کار گرفته شد. مدل‌های مورد استفاده شامل سیستم استنتاج عصبی-فازی CANFIS، شبکه عصبی پرسپترون چندلایه (MLPNN)، رگرسیون خطی چندگانه (MLR)، رگرسیون غیرخطی چندگانه (MNLRL) و منحنی سنج رسوب (SRC) بودند.

ترکیب بهینه متغیرهای ورودی هر مدل با استفاده از آزمون گاما تعیین شد. ارزیابی مدل‌ها بر اساس شاخص‌های آماری نظیر RMSE، ضریب همبستگی پیرسون و ضریب کارایی (NSE) انجام گرفت. نتایج نشان داد که مدل CANFIS نسبت به سایر مدل‌ها عملکرد بهتری داشته و قادر است با دقت بالاتری غلظت روزانه رسوبات معلق را شبیه‌سازی کند. به‌طور کلی، این مطالعه نشان داد که مدل CANFIS می‌تواند به‌عنوان گزینه‌ای برتر برای شبیه‌سازی غلظت روزانه رسوبات

خطای برآورد را به کمتر از پنج درصد کاهش دهند. این پژوهش، کارایی بالای روش ACS را در پایش و برآورد رسوب رودخانه‌ای به‌ویژه در شرایط وقوع سیلاب‌های شدید تأیید کرد.

(Khazaei pool and Talebi, (2013) با ترکیب دو روش منحنی سنج و شبکه عصبی مصنوعی در رودخانه قطورچای، دقت برآورد بار معلق را نسبت به مدل‌های منفرد افزایش دادند. Yousefi and Barzegar, (2015) در پژوهشی در استان لرستان، روش‌های مختلف منحنی سنج را با شبکه عصبی مصنوعی مقایسه کردند. نتایج نشان داد که در بسیاری از موارد، مدل‌های مبتنی بر شبکه عصبی با ورودی‌های مناسب، دقت بالاتری نسبت به مدل‌های سنتی دارند و می‌توانند به‌عنوان جایگزینی مؤثر معرفی شوند.

در ادامه، (Mardoukhpour et al., (2019) در رودخانه بابل‌رود نشان دادند که شبکه‌های عصبی مصنوعی نسبت به منحنی سنج و مدل‌های رگرسیونی دقت بالاتری دارند. به‌گونه‌ای که ضریب همبستگی ANN برابر با ۹۲/۸ درصد بود، درحالی‌که منحنی سنج تنها ۷۸/۱ درصد و رگرسیون آماری حداکثر ۹۰ درصد را ثبت کرده بودند. (Ahmer et al., (2019) نیز با توسعه یک مدل ترکیبی متشکل از ماشین بردار پشتیبان و شبکه عصبی مصنوعی برای رودخانه کابل در افغانستان، دقت بالاتری نسبت به مدل‌های سنتی به‌دست آوردند.

(Eilderemi and Mohamadpanah-Moghadam, (2021) نیز با مقایسه چند مدل در سد آبشینه همدان، برتری ساختارهای ANN چندلایه را نسبت به مدل‌های کلاسیک تأیید کردند. (Biranvand et al., (2021) عملکرد منحنی سنج رسوب را در سه حوضه غرب ایران بررسی کرده و به این نتیجه رسیدند که این روش در شرایط با داده‌های کافی و پایدار عملکرد مناسبی دارد، اما در شرایط پیچیده دچار افت دقت می‌شود. (Asfandiar-Darabad and Gharachorloo, (2022) حوضه قره‌سو با استفاده از داده‌های ماهانه اقدام به استخراج منحنی سنج منطقه‌ای کردند و کاربرد آن را در مقیاس کلان‌مدیریتی پیشنهاد دادند.

(Sepehvand and Biranvand, (2022) در مطالعه‌ای دیگر، عملکرد منحنی سنج را در شرایط

(ANN) و الگوریتم ژنتیک (GA) توسعه دادند. در این روش، تمامی پارامترهای مدل ANN به صورت خودکار و همزمان با استفاده از GA بهینه‌سازی شد. آنها علاوه بر مدل تک‌هدفه، از یک الگوریتم چندهدفه نیز برای بهینه‌سازی دو تابع هدف متضاد (واریانس خطا و بایاس) بهره گرفتند. در ادامه، عملکرد مدل ANN-GA تک‌هدفه با مدل‌های چندمتغیره خودرگرسیو مقایسه شد. نتایج نشان داد که مدل تک‌هدفه ANN-GA در مقایسه با سایر مدل‌ها بالاترین دقت را ارائه کرده و به عنوان مناسب‌ترین گزینه برای پیش‌بینی بار رسوبی معلق معرفی شد. همچنین، نویسندگان تأکید کردند که در شرایطی که داده‌های رسوب در دسترس نباشد، مدل تک‌هدفه ANN-GA به دلیل دقت بالا و سادگی اجرا می‌تواند رویکردی کارآمد برای پیش‌بینی بار رسوب باشد.

Adnan et al., (2025) با تمرکز بر بهبود پیش‌بینی بار روزانه رسوب معلق در حوضه رودخانه Bailong چین، یک رویکرد ترکیبی نوین بر پایه سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) و الگوریتم بهینه‌ساز مبتنی بر گرادیان (GBO) ارائه دادند. برای مقایسه عملکرد، مدل‌های ANFIS استاندارد، بهینه‌سازی ازدحام ذرات ANFIS-PSO و بهینه‌سازی گرگ خاکستری ANFIS-GWO نیز مورد ارزیابی قرار گرفتند. انتخاب ورودی‌ها با استفاده از روش MARS¹ انجام شد و عملکرد مدل‌ها با شاخص‌های آماری RMSE، MAE، NSE و R^2 به همراه ارزیابی‌های بصری نظیر نمودار تیلور و نمودارهای ویولن بررسی شد. نتایج نشان داد که افزودن داده‌های تاریخی رسوب به بهبود قابل توجه دقت پیش‌بینی منجر می‌شود و مدل ترکیبی ANFIS-GBO بهترین نتایج را با کمترین خطا و بالاترین ضرایب کارایی ارائه داد. این پژوهش نشان می‌دهد که استفاده از الگوریتم‌های بهینه‌سازی الهام‌گرفته از طبیعت می‌تواند توانایی مدل‌های هوش مصنوعی را در شبیه‌سازی فرایندهای پیچیده هیدرولوژیکی مانند بار رسوب معلق به طور چشمگیری افزایش دهد.

معلق در رودخانه‌های مشابه معرفی شود (Malik et al., 2017).

در مطالعه‌ای دیگر، Kumar et al., (2020) به‌کارگیری الگوریتم بهینه‌سازی ازدحام ذرات (PSO) در ترکیب با شبکه‌های عصبی مصنوعی، مدلی قدرتمند برای برآورد رسوبات رودخانه گانگا در هند ارائه کردند که عملکرد آن نسبت به مدل‌های مستقل برتر بود. Lee et al., (2021) با معرفی مدلی ترکیبی بر پایه شبکه عصبی و منحنی سنجه، توانستند دقت بالایی در برآورد رسوبات معلق رودخانه به‌دست آورند. به‌طور هم‌زمان، Moradi et al., (2021) نیز از یک شبکه عصبی بازگشتی استفاده کرده و نشان دادند که تلفیق داده‌های هواشناسی در ساختار مدل موجب بهبود عملکرد پیش‌بینی می‌شود. همچنین، Wang and Ding, (2021) با مرور روش‌های موجود، منحنی سنجه رسوب را یکی از رایج‌ترین و پایه‌ای‌ترین ابزارهای برآورد بار معلق معرفی کردند.

Tamrabet et al., (2022) در پژوهشی در پنج حوزه آبخیز بزرگ شرق الجزایر مدل‌سازی غلظت رسوب معلق با استفاده از شبکه‌های عصبی مصنوعی (ANN) و سامانه استنتاج نوروفازی تطبیقی (ANFIS) را انجام دادند. داده‌های ورودی شامل دبی آب و دبی رسوب و خروجی مدل‌ها غلظت روزانه رسوب معلق بود. نتایج نشان داد که هر دو مدل دقت بالایی در پیش‌بینی رسوب معلق دارند. ضریب تعیین (R^2) در محدوده ۰/۷۷ تا ۰/۹۸ و ضریب ناش-ساتکلیف (NSE) بین ۰/۶۷ تا ۰/۹۷ به‌دست آمد. همچنین مقادیر خطا (MAE) بسیار پایین و بین ۰/۰۴ تا ۰/۰۲۸ گرم بر لیتر گزارش شد. مقایسه دو روش نشان داد که ANFIS عملکرد بهتری نسبت به ANN داشته است، هرچند هر دو روش از دقت بسیار خوبی برخوردار بودند. این مطالعه بر قابلیت بالای روش‌های هوش مصنوعی در مدل‌سازی غلظت رسوبات معلق در مناطق خشک و نیمه‌خشک تأکید می‌کند.

Yadav et al., (2022) با هدف پیش‌بینی بار معلق رسوب در رودخانه ماهانادی هند، یک مدل هوش مصنوعی ترکیبی مبتنی بر شبکه عصبی مصنوعی

¹ Multivariate Adaptive Regression Splines

درجه و ۲۳ دقیقه شمالی و طول‌های جغرافیایی ۵۰ درجه و ۲۰ دقیقه تا ۵۱ درجه و ۱۰ دقیقه شرقی قرار دارد. این زیرحوضه با مساحت تقریبی ۹۲ کیلومترمربع، بخشی از حوزه آبخیز وسیع‌تری به نام طالقان را تشکیل می‌دهد که مساحت کل آن حدود ۴۷۰ کیلومترمربع است. حوزه آبخیز طالقان نیز از زیرمجموعه‌های حوزه آبخیز سفیدرود محسوب می‌شود و با وسعتی بالغ بر ۱۳۲۵۰۰ هکتار، حدود ۰/۰۸ درصد از مساحت کل کشور را در بر می‌گیرد. میزان بارندگی سالانه در این حوضه متغیر بوده و بین ۲۵۰ تا ۱۰۰۰ میلی‌متر در سال در نوسان است.


توپوگرافی منطقه دارای تنوع قابل توجهی است؛ به‌طوری‌که ارتفاعات آن از حداقل ۱۷۷۰ متر تا حداکثر ۴۳۷۰ متر از سطح دریا تغییر می‌کند و میانگین ارتفاع منطقه حدود ۲۷۳۴ متر از سطح دریا گزارش شده است. بررسی‌های مورفولوژیکی نشان می‌دهد که بیش از ۵۰ درصد از سطح حوضه دارای شیب بیش از ۴۰ درصد است که این ویژگی، از نظر فرسایش‌پذیری و انتقال رسوب، حائز اهمیت است. از نظر کاربری اراضی، مراتع بیشترین سهم را در پوشش سطحی این حوضه دارا هستند؛ به‌طوری‌که بیش از ۸۵ درصد از اراضی منطقه را اراضی مرتعی تشکیل می‌دهند. با این حال، کیفیت این پوشش مرتعی مطلوب نبوده و بر اساس ارزیابی‌ها، حدود ۶۰ درصد مراتع دارای پوشش ضعیف و تنها ۴۰ درصد دارای پوشش متوسط هستند (Noor et al., 2016).

در این پژوهش، به‌منظور افزایش دقت برآورد رسوبات معلق، یک مدل ترکیبی نوین مبتنی بر منحنی سنج رسوب و شبکه CANFIS توسعه یافته است. این مدل ترکیبی با بهره‌گیری از داده‌های پردازش‌شده و صاف‌شده حاصل از منحنی سنج، ضمن کاهش میانگین مربعات خطا و افزایش شاخص‌های عملکرد نظیر ضریب ناش-ساتکلیف (NSE)، قادر به شبیه‌سازی دقیق فرایندهای رسوبی بدون نیاز به روابط پیچیده فیزیکی است.

نوآوری اصلی این تحقیق در استفاده از خروجی منحنی سنج به‌عنوان ورودی شبکه CANFIS و مقایسه آن با مدل‌های منفرد و سایر مدل‌های ترکیبی است که علاوه بر بهبود دقت برآورد، امکان تعمیم‌پذیری مدل به شرایط هیدرولوژیکی متغیر و پیچیده را فراهم می‌آورد. هدف این مطالعه ارائه یک چارچوب دقیق، ساده و قابل پیاده‌سازی برای برآورد بار رسوب معلق در رودخانه‌ها و ایستگاه‌های هیدرومتری است که خلا علمی موجود در مطالعات داخلی و بین‌المللی را نیز پر می‌کند.

مواد و روش‌ها

منطقه مورد مطالعه: زیرحوضه گلینک به‌عنوان یکی از زیرحوضه‌های اصلی حوزه آبخیز سد طالقان در استان تهران واقع شده است. از نظر جغرافیایی، این حوضه در بین عرض‌های جغرافیایی ۳۶ درجه و ۵ دقیقه تا ۳۶



شکل ۱- موقعیت حوزه آبخیز طالقان و ایستگاه هیدرومتری گلینک

Fig. 1. Location of the Taleghan Watershed and the Glinak Hydrometric Station

روش تحقیق: به‌منظور شبیه‌سازی و برآورد رسوبات معلق رودخانه‌ای، از داده‌های ایستگاه هیدرومتری گلینک در حوزه آبخیز طالقان طی دوره زمانی ۱۳۵۰ تا ۱۴۰۲ استفاده شد. در گام نخست، برای اطمینان از کیفیت و یکنواختی داده‌ها، فرایند پیش‌پردازش شامل ارزیابی همگنی با آزمون همگنی نرمال استاندارد صورت

پذیرفت. در نهایت، تعداد ۸۰۰ نمونه همزمان از داده‌های دبی جریان (مترمکعب بر ثانیه) و دبی رسوب معلق (تن در روز) استخراج و به‌عنوان مجموعه داده نهایی برای شبیه‌سازی مورد استفاده قرار گرفت. ویژگی‌های آماری دبی آب و رسوب در جدول ۱ ارائه شده است.

جدول ۱- ویژگی‌های آماری دبی آب و رسوب در ایستگاه هیدرومتری گلینک

Table 1. Statistical characteristics of streamflow and sediment load at the Glinak Hydrometric Station

90th Percentile	10th Percentile	Skewness	Std. Dev	Median	Mean	Max	Min	Parameter
46.5	3.11	1.47	17.92	15.19	21.38	84.01	0.6	Discharge (m ³ /s)
9,651.33	13.68	3.21	6,342.18	496.97	3,847.52	36,900.62	0.176	Sediment Load (ton/day)

حداکثر دبی مشاهده‌شده ۸۴/۱ مترمکعب بر ثانیه و حداکثر غلظت رسوب ۳۶۹۰۰ میلی‌گرم بر لیتر بوده که در همان دبی رخ داده است. از کل نمونه‌ها (۸۹) نمونه در شرایط جریان سیلابی) دهک بالای دبی‌ها، ۴۶/۵ مترمکعب بر ثانیه و (۸۱) نمونه در شرایط جریان پایه) دهک پایین دبی‌ها ۳/۱۱ مترمکعب بر ثانیه قرار داشتند. در پژوهش حاضر، سه استراتژی مدل‌سازی متمایز برای پیش‌بینی بار رسوبات معلق مورد استفاده قرار گرفت که عبارتند از استفاده از تکنیک‌های رگرسیونی مبتنی بر منحنی‌های سنج رسوب، کاربرد شبکه‌های عصبی مصنوعی و ترکیب این دو رویکرد. جزئیات هر یک از این روش‌ها در ادامه ارائه می‌شود.

الف) رویکردهای مبتنی بر منحنی سنج رسوب: در این بخش، شش تکنیک مختلف برای استخراج رابطه بین دبی آب و میزان رسوب معلق بررسی شد.

۱- رگرسیون لگاریتمی ساده: این روش بر اساس تبدیل لگاریتمی داده‌های دبی جریان و غلظت رسوب و سپس برازش خط رگرسیون خطی با استفاده از روش کمترین مربعات استوار است (Asselman, 2000).

۲- رگرسیون چندبخشی: در صورتی که پراکندگی نقاط در فضای لگاریتمی امکان برازش یک خط واحد را ندهد، می‌توان دامنه داده‌ها را به چندین قطعه تقسیم و برای هر قطعه یک معادله رگرسیونی مستقل تخمین زد. این تکنیک به‌ویژه برای داده‌هایی با نقاط شکست متعدد مناسب است (Glysson, 1987).

۳- روش میانگین دسته‌بندی شده (LMLWDC): در این تکنیک که توسط Jansson (1996) معرفی شد، دبی‌های جریان به گروه‌های همگن با گام‌های منظم تقسیم می‌شوند. سپس برای دبی میانگین هر گروه، متوسط بار رسوبی متناظر محاسبه و منحنی نهایی با روش کمترین مربعات برازش می‌شود (Jansson, 1996).

۴- ضریب اصلاحی فائو: در این روش، پس از برازش معادله توانی $Q_s = aQ_w^b$ به داده‌های لگاریتمی، به‌جای استفاده مستقیم از این معادله، خطی موازی که از میانگین حسابی مقادیر واقعی Q_s و Q_w عبور می‌کند، به‌کار گرفته می‌شود. بدین ترتیب ضریب a از تقسیم میانگین Q_s بر Q_w^b به‌دست می‌آید (Ferguson, 1986).

۵- ضریب تصحیح پارامتریک (Miller): (Miller, 1951) برای کاهش خطای سیستماتیک ناشی از تبدیل لگاریتمی، یک فاکتور تصحیحی پارامتریک CF_1 معرفی کرد که بر اساس انحراف معیار خطاهای برآورد S محاسبه می‌شود (Miller, 1951; Thomas, 1985) (رابطه ۱).

$$CF_1 = 10^{(2.65 \times S^2)} \quad (1)$$

که در آن، S از رابطه (۲) به‌دست می‌آید.

$$S = \sqrt{\frac{\sum_{i=1}^n (\log \bar{C}_i - \log C_i)^2}{n-2}} \quad (2)$$

$$X_n = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5)$$

که در آن، X مقدار اصلی، X_{min} و X_{max} به ترتیب کمترین و بیشترین مقادیر مشاهده شده و X_n داده نرمال شده است. برای دستیابی به بهینه ترین معماری، ترکیبات مختلفی از تعداد لایه ها و نرون ها طراحی، آموزش و مقایسه شدند. آموزش شبکه ها با استفاده از نرم افزار NeuroSolutions انجام و پارامترهای مدل از طریق روش آزمون و خطا تنظیم گردیدند. مدل های استفاده شده عبارتند از:

۱- پرسپترون چندلایه (MLP): این معماری یکی از متداول ترین شبکه های پیش خور است که حداقل از سه لایه (ورودی، پنهان و خروجی) با نرون های کاملاً متصل و توابع فعال سازی غیرخطی تشکیل شده است. فرایند یادگیری بر اساس الگوریتم پس انتشار خطا و تعدیل وزن های سیناپسی انجام می شود (Niha et al., 2023; Rishab et al., 2024).

۲- شبکه پیش خور تعمیم یافته (GFF): برخلاف شبکه های پیش خور معمولی که اتصالات فقط بین لایه های مجاور برقرار است، GFF امکان اتصال مستقیم از هر لایه به لایه های دورتر را فراهم می کند. این ویژگی انعطاف پذیری بیشتری برای یادگیری الگوهای پیچیده ایجاد می کند (Janus and Volna, 2013).

۳- شبکه تابع پایه شعاعی (RBF): این شبکه سه لایه ای از توابع گاوسی در لایه پنهان برای محاسبه فاصله اقلیدسی بین ورودی و مراکز کلاسترها استفاده می کند. مراکز نرون ها معمولاً با الگوریتم های خوشه بندی مانند k-means تعیین می شوند (Srilatha and Sudha, 2024).

۴- شبکه های عصبی خودسازمان ده (SOFM): این شبکه های بدون ناظر بر اساس یادگیری رقابتی عمل کرده و داده های چندبعدی را به فضای کم بعد (معمولاً دوبعدی) نگاشت می کنند، درحالی که روابط توپولوژیکی داده ها حفظ می شود (Shiri and Kisi, 2012).

۵- سیستم استنتاج عصبی-فازی تطبیقی (CANFIS): این معماری ترکیبی با ادغام قابلیت یادگیری شبکه های

۶- ضریب تصحیح ناپارامتریک: Koch and Smillie, (1986) با رد فرض نرمال بودن توزیع خطاها، یک فاکتور تصحیح ناپارامتریک CF_2 پیشنهاد دادند که از میانگین و میانه خطاهای باقی مانده محاسبه می شود (Koch and Smillie, 1986).

$$CF_2 = \frac{\text{mean}(e_i)}{\text{median}(e_i)} \quad (3)$$

$$e_i = \frac{C_i(\text{observed})}{C_i(\text{estimated})} \quad (4)$$

ب) رویکرد مدل سازی با شبکه های عصبی مصنوعی: در این پژوهش، شش معماری متفاوت شبکه عصبی شامل پرسپترون چندلایه^۱، شبکه پیش خور تعمیم یافته^۲، شبکه تابع پایه شعاعی^۳، نقشه خودسازمان ده^۴، سیستم استنتاج عصبی-فازی تطبیقی^۵ و ماشین بردار پشتیبان^۶ مورد ارزیابی قرار گرفتند. شبکه های عصبی به دلیل ظرفیت یادگیری از روابط غیرخطی و سازگاری با ساختارهای پیچیده داده ای، برتری قابل توجهی نسبت به مدل های کلاسیک از خود نشان می دهند. در فرایند مدل سازی، ۷۵ درصد از مجموعه داده برای آموزش شبکه (۶۰۰ نمونه دبی و رسوب همزمان) و ۲۵ درصد باقیمانده (۲۰۰ نمونه دبی و رسوب همزمان) برای ارزیابی عملکرد مدل اختصاص یافت. انتخاب داده های آموزشی باید به گونه ای باشد که تنوع و دامنه کامل شرایط هیدرولوژیکی را پوشش دهد (Dandy and Maier, 2000).

عوامل کلیدی در طراحی شبکه های عصبی شامل تعیین تعداد لایه های پنهان، تعداد نرون ها در هر لایه، انتخاب توابع فعال سازی مناسب و تنظیم الگوریتم های یادگیری است (Mostafa et al., 2024). در این مطالعه، دبی جریان (m^3/s) به عنوان ورودی و بار رسوب لحظه ای (ton/day) به عنوان خروجی سیستم در نظر گرفته شد. پیش از ورود داده ها به شبکه، دو مرحله پیش پردازش شامل تصادفی سازی داده ها و نرمال سازی آنها انجام شد. نرمال سازی به ویژه زمانی که دامنه تغییرات متغیرها گسترده است، تأثیر چشمگیری بر سرعت و کیفیت آموزش دارد (Ren et al., 2023). این فرایند با استفاده از رابطه (۵) صورت گرفت.

⁵ Co-Active Neuro-Fuzzy Inference System (CANFIS)

⁶ The Support Vector Machine (SVM)

¹ Multilayer perceptions (MLPs)

² Generalized feed forward (GFF)

³ Radial basis function (RBF)

⁴ Self-organizing feature maps (SOFMs)

پارامتر دیگر داده‌های حاصل از پیش‌بینی منحنی سنجه رسوب است که در مدل ترکیبی ۱ به تنهایی در ساخت مدل به کار گرفته شد (Najafinejad et al., 2010; Khazaei Pool and Talebi, 2013).

ارزیابی عملکرد مدل‌ها: برای سنجش دقت و کارایی مدل‌های توسعه‌یافته، مجموعه‌ای از معیارهای آماری شامل شاخص‌های بی‌مقیاس و دارای بُعد به کار گرفته شد (Moriasi et al., 2007). شاخص‌های بی‌مقیاس نظیر ضریب تبیین (R^2)، ضریب کارایی ناش-ساتکلیف (NSE) و درصد انحراف (PBIAS) برای ارزیابی میزان تطابق و همبستگی استفاده شدند. معیارهای دارای واحد مانند ریشه میانگین مربعات خطا (RMSE) و میانگین قدرمطلق خطا (MAE) که برحسب "تن در روز" بیان می‌شوند، بزرگی خطاهای مطلق را کمی‌سازی کردند. همچنین، میانگین خطای نسبی (RME) برای مقایسه نسبی عملکرد مدل‌ها به شرح زیر محاسبه شد.

۱- **ضریب تبیین^۱ (R^2):** میزان واریانس داده‌های مشاهده‌شده که توسط مدل تبیین می‌شود را اندازه‌گیری می‌کند. دامنه: صفر تا یک (Legates and McCabe, 1999).

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})]^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \times \sum_{i=1}^n (P_i - \bar{P})^2} \quad (6)$$

۲- **ضریب کارایی ناش-ساتکلیف^۲ (NSE):** نسبت بزرگی واریانس باقیمانده‌ها به واریانس مشاهدات را ارزیابی می‌کند. دامنه $-\infty$ تا یک؛ مقادیر نزدیک به یک بیانگر عملکرد عالی است (Nash and Sutcliffe, 1970).

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (7)$$

۳- **درصد انحراف^۳ (PBIAS):** تمایل سیستماتیک مدل به بیش‌برآوردی یا کم‌برآوردی را نشان می‌دهد. مقدار بهینه: صفر (Gupta et al., 1999).

$$PBIAS = \left(\frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n O_i} \right) \times 100 \quad (8)$$

۴- **ریشه میانگین مربعات خطا^۴ (RMSE):** بزرگی متوسط خطاها را برحسب واحد متغیر اصلی بیان می‌کند و حساسیت بالایی نسبت به خطاهای بزرگ دارد (Willmott and Matsuura, 2005).

عصبی و قدرت استدلال منطق فازی، عملکرد بهتری در مدلسازی پدیده‌های هیدرولوژیکی پیچیده مانند نوسانات سطح آب زیرزمینی و پیش‌بینی خشکسالی ارائه می‌دهد (Zhang and Govindaraju, 2011; Zare and Bayat, 2013).

۶- ماشین بردار پشتیبان (SVM): این الگوریتم نظارت‌شده با یافتن ابرصفحه بهینه که حداکثر حاشیه جداسازی بین کلاس‌ها را ایجاد می‌کند، داده‌ها را طبقه‌بندی می‌کند. SVM در مدلسازی فرسایش، رسوب و سایر پارامترهای منابع آب کارایی مناسبی دارد (Karami et al., 2020).

ج) مدل ترکیبی منحنی سنجه و شبکه‌ی عصبی مصنوعی:

در این قسمت از تحقیق، برای بهبود نتایج مدل منحنی سنجه رسوب، روش شبکه عصبی مصنوعی به کار گرفته شد. بدین صورت که دو مدل ترکیبی ساخته شد. برای ساخت مدل ترکیبی نیاز بود تا نتایج مدل منحنی سنجه رسوب برای کل داده‌ها استخراج شده و مورد استفاده شبکه عصبی مصنوعی قرار گیرد. لذا بعد از ساختن مدل منحنی سنجه رسوب با روش منحنی حد وسط دسته‌ها، از این رابطه استفاده شد. دبی کل داده‌ها به رابطه منحنی سنجه حد وسط دسته‌ها داده شد تا مقادیر نظیر بار معلق به‌عنوان خروجی از آن دریافت شود. در حقیقت بدین صورت مدل یکبار کل داده‌ها را مدلسازی می‌نماید. پس از این مرحله، در مرحله بعد نتایج مربوط به این مدلسازی برای دو مدل ترکیبی ۱ و ۲ تفکیک می‌شوند.

مدل ترکیبی ۱: در این بخش یک مدل سیستم عصبی مصنوعی با کمک نتایج منحنی سنجه که نحوه محاسبه آن در پاراگراف قبل شرح داده شد، ساخته شده تا با کمک آن میزان بار معلق برای داده‌های روش ترکیبی ۱ پیش‌بینی شود. در حقیقت تنها پارامتر ورودی شبکه مصنوعی در این بخش نتایج حاصل از روش منحنی سنجه رسوب است.

مدل ترکیبی ۲: این مدل ترکیبی دقیقاً نظیر مدل ترکیبی ۱ ساخته شد، با این تفاوت که شبکه عصبی مصنوعی تولید شده در این قسمت دارای دو پارامتر ورودی است. یک پارامتر ورودی همان داده‌های دبی و

³ Percent Bias

⁴ Root Mean Square Error

¹ Coefficient of Determination

² Nash-Sutcliffe Efficiency Coefficient

مشاهده‌ای، $\bar{P}$ میانگین مقادیر رسوب پیش‌بینی شده و n تعداد داده‌هاست.

نتایج و بحث

در این پژوهش، به‌منظور دستیابی به دقیق‌ترین الگو برای برآورد دبی رسوب معلق در ایستگاه گلینک، عملکرد روش‌های مختلف منحنی سنج رسوب و شبکه‌های عصبی مصنوعی مورد واکاوی قرار گرفت. در ابتدا پارامترهای اصلی معادله توانی رسوب (ضرایب a و b) برای شش رویکرد مختلف برازش منحنی استخراج شد. ضریب a نشان‌دهنده شاخص فرسایش‌پذیری و ضریب b بیانگر توان حمل رسوب توسط رودخانه است که نتایج آن در جدول ۲ ارائه شده است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (9)$$

۵- میانگین قدرمطلق خطا^۱ (MAE): میانگین مقادیر مطلق خطاها را محاسبه می‌کند و نسبت به داده‌های پرت کمتر حساس است (Chai and Draxler, 2014).

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (10)$$

۶- میانگین خطای نسبی^۲ (RME): خطای نسبی را به‌صورت درصدی بیان کرده و امکان مقایسه در مقیاس‌های مختلف را فراهم می‌آورد (Singh et al., 2004).

$$RME = \left(\frac{\sum_{i=1}^n \frac{P_i - O_i}{O_i}}{n} \right) \times 100 \quad (11)$$

که در آنها، O_i مقادیر رسوب مشاهده‌ای، P_i مقادیر رسوب پیش‌بینی‌شده، $\bar{O}$ میانگین مقادیر رسوب

جدول ۲- نتایج حاصل از رسم منحنی‌های سنج رسوب به روش‌های مختلف (ضرایب a و b)

Table 2. Results of sediment rating curve fitting using different methods (a and b coefficient)

Sediment Rating Curve Method	a	b
Single-line method	2.13	2.02
Two-line method, $Q_w < 5 \text{ m}^3/\text{s}$	1.71	2.16
Two-line method, $Q_w > 5 \text{ m}^3/\text{s}$	4.74	1.78
Logged Mean Load within Discharge Classes Method	22.65	1.44
Division into 15 classes (LMLWDC)		
FAO correction factor	17.32	2.03
Parametric correction factor	2.38	2.03
Non-parametric correction factor	5.47	2.03

است. همچنین عملکرد هریک از مدل‌های منحنی سنج رسوب با استفاده از سه معیار آماری کلیدی شامل میانگین درصد خطای نسبی (RME)، ضریب کارایی مدل (NSE) و ضریب تعیین (R^2) مورد ارزیابی قرار گرفت که نتایج آن در جدول ۳ ارائه شده است.

تحلیل پارامترهای مدل‌سازی در جدول ۲ نشان می‌دهد که ضرایب معادله توانی (a و b) در رویکردهای مختلف، تفاوت‌های معنی‌داری دارند. به‌ویژه در روش دوخطی، افزایش چشمگیر ضریب فرسایش‌پذیری (a) در دبی‌های بیش از پنج مترمکعب بر ثانیه، حاکی از تشدید پاسخ‌های هیدرولوژیکی حوضه در فاز سیلابی

جدول ۳- نتایج حاصل از ارزیابی هر کدام از روش‌ها با معیارهای مختلف

Table 3. Evaluation results of each method based on different criteria

Sediment Rating Curve Method	(R^2)	(NSE)	(RME)
Single-line method	0.73	0.32	420.82
Two-line method	0.43	0.30	423.51
Logged Mean Load within Discharge Classes Method	0.73	0.41	412.67
FAO correction factor	0.73	-4.70	2042.01
Parametric correction factor	0.73	0.35	246.59
Non-parametric correction factor	0.73	0.36	298.51

² Relative Mean Error

¹ Mean Absolute Error (MAE)

کاهش اثر نقاط پرت و پراکندگی داده‌ها، دقت بالاتری نسبت به روش‌های برازش مستقیم در فضای لگاریتمی از خود نشان دهد. پس از انتخاب روش حد وسط دسته‌ها به‌عنوان مدل مرجع، مقادیر رسوب برآوردشده توسط سایر روش‌ها با خروجی این مدل مقایسه شد تا میزان انحراف نسبی آنها با استفاده از شاخص (PBIAS) محاسبه شود. نتایج این مقایسه در جدول ۴ ارائه شده است.

مطابق داده‌های جدول ۳، روش حد وسط دسته‌ها با RME معادل با ۴۱۲/۶۷ درصد، NSE برابر با ۰/۴۱ و R^2 برابر با ۰/۷۳ بهترین عملکرد را در بین تمامی روش‌ها از خود نشان داده است که حاکی از دقت بالاتر آن در برآورد بار رسوبات معلق است و این روش به‌عنوان روش برتر و مبنا در نظر گرفته شد. این روش که مبتنی بر دسته‌بندی داده‌ها به ۱۵ طبقه و محاسبه میانگین‌های نماینده برای هر گروه است، توانسته با

جدول ۴- میزان رسوب برآوردی هر روش نسبت به روش حد وسط دسته‌ها و میزان PBIAS هر روش

Table 4. Estimated sediment load by each method relative to the midpoint of class intervals method and the pbias values of each method


Sediment Rating Curve Method	Model Performance	PBIAS %	Estimated Sediment Load
Single-line method	Unsatisfactory	35.6-	0.65
Two-line method	Good	12.29-	0.58
Logged Mean Load within Discharge Classes Method	Very Good	5.42	1
FAO correction factor	Unsatisfactory	423.78	5.14
Parametric correction factor	Unsatisfactory	96.34-	0.73
Non-parametric correction factor	Unsatisfactory	65.69	1.71

بیش‌برآوردی قابل‌توجه شده است. (PBIAS) محاسبه‌شده در جدول ۴ نسبت به مدل مرجع (حد وسط دسته‌ها) است، نه نسبت به داده‌های مشاهده‌ای واقعی. بنابراین، این مقادیر صرفاً انحراف نسبی بین روش‌ها را نشان می‌دهند و نمی‌توان آنها را به‌عنوان معیار مطلق دقت مدل در نظر گرفت.

در ادامه، نمودار منحنی سنج رسوب روش حد وسط دسته‌ها برای ایستگاه گلینک در شکل ۲ ارائه شده است. این نمودار نمایانگر همبستگی مناسب بین دبی جریان و دبی رسوب در این روش بوده و عملکرد تحلیلی آن را به‌وضوح نشان می‌دهد. خروجی این روش در مراحل بعدی به‌عنوان داده ورودی برای مدل‌های ترکیبی (۱ و ۲) مورد استفاده قرار گرفت. این رویکرد، امکان ترکیب مزایای روش آماری دقیق با قابلیت یادگیری الگوهای پیچیده توسط شبکه‌های عصبی را فراهم می‌آورد.

مطابق جدول ۴، روش‌های تک‌خطی و دوخطی با (PBIAS) برابر ۳۵/۶- و ۱۲/۲۹- به‌ترتیب دچار کم‌برآوردی بار رسوب شده‌اند، بر اساس طبقه‌بندی (Moriasi et al., 2007)، روش دوخطی با (PBIAS) کمتر از $15 \pm$ درصد در محدوده "خوب" و روش تک‌خطی با (PBIAS) بیش از $25 \pm$ درصد در دسته "نامطلوب" قرار می‌گیرند. روش حد وسط دسته‌ها با (PBIAS) معادل ۵/۴۲ درصد تقریباً بدون بایاس بوده و در دسته "خیلی خوب" طبقه‌بندی می‌شود، که نشان‌دهنده دقت بالای این روش در پیش‌بینی بار رسوب معلق است.

روش ضریب اصلاحی فائو با (PBIAS) بسیار بالای ۴۲۳/۷۸ درصد به‌طور شدید بیش‌برآورد کرده (بیش از پنج برابر مقدار مرجع) و روش ضریب اصلاحی پارامتری با (PBIAS) معادل ۹۶/۳۴- دچار کم‌برآورد شدید شده است. روش غیرپارامتری نیز با (PBIAS) برابر ۶۵/۶۹ درصد و برآورد ۱/۷۱ برابر مقدار مرجع، دچار



شکل ۲- نمودار منحنی سنج رسوب حد وسط دسته‌ها در ایستگاه گلینک

Fig. 2. Logged mean loads within discharge classes method at the Glinak Station

(MAE) و ضریب همبستگی (R) در قالب جدول ۵ ارائه شد. شاخص‌های RMSE و MAE به دلیل داشتن واحد اصلی داده‌ها (تن در روز) امکان تفسیر مستقیم خطا را فراهم می‌کنند، در حالی که NMSE و R بیشتر برای مقایسه نسبی عملکرد مدل‌ها مورد استفاده قرار گرفته‌اند.

در گام بعدی با استفاده از روش‌های مختلف شبکه عصبی مصنوعی داده‌های رسوب شبیه‌سازی شدند که نتایج حاصل از ارزیابی آنها در جدول‌های ۵ و ۶ ارائه شده است. برای مقایسه عملکرد مدل‌های هوشمند، در گام نخست نتایج شاخص‌های کمی ارزیابی شامل ریشه میانگین مربعات خطا (RMSE)، میانگین مربعات خطای نرمال‌شده (NMSE)، میانگین قدر مطلق خطا

جدول ۵- نتایج شاخص‌های آماری (RMSE، NMSE، MAE و R) در ارزیابی عملکرد مدل‌های مختلف شبکه عصبی مصنوعی در برآورد رسوب معلق ایستگاه گلینک

Table 5. Statistical indices (RMSE, NMSE, MAE, and R2) for evaluating the performance of different artificial neural network models in predicting suspended sediment at the Glinak station

Model	MAE (ton/day)	R	NMSE	RMSE (ton/day)
MLPs	0.039	0.37	0.935	0.013
GFF	0.05	0.551	0.72	0.013
RBF	0.062	0.614	0.631	0.015
SVM	15.47	0.622	8982.55	251.53
CANFIS	0.06	0.659	0.595	0.014
SOFMs	0.091	0.572	0.896	0.024

همچنین در جدول ۶ جمع‌بندی تحلیلی نتایج حاصل از شبیه‌سازی هر کدام از مدل‌ها ارائه شده است.

جدول ۶- جمع‌بندی تحلیلی نتایج حاصل از شبیه‌سازی هر کدام از مدل‌ها

Table 6. Analytical summary of the simulation results for each model


Final Interpretation	Unrealistic Fluctuation	Low Data Accuracy	Peak Accuracy	Model
Simple model with average performance	Relatively High	Poor	Moderate	MLP
Suitable structure but requires finer tuning	Moderate	Moderate	Good	GFF
Suitable model for uniform data	Low	Good	Poor	RBF
Conservative behavior, suitable for stationary data	Low	Moderate	Poor	SVM
Mostly suitable for cluster analysis	High	Moderate	Poor	SOFM
Most accurate and stable model	Low	Excellent	Excellent	CANFIS

به‌طور کلی، نتایج جدول‌های ۵ و ۶ به‌روشنی نشان می‌دهد که مدل CANFIS به‌عنوان دقیق‌ترین، پایدارترین و قابل‌اعتمادترین مدل در پیش‌بینی رسوبات معلق ایستگاه گلینک معرفی می‌شود. این مدل در اغلب معیارهای ارزیابی از جمله RMSE، NMSE و R نسبت به سایر روش‌ها برتری دارد.

بر پایه این تحلیل، در ادامه پژوهش، مدل CANFIS به‌عنوان گزینه اصلی جهت ترکیب با روش‌های تجربی و توسعه ساختارهای ترکیبی انتخاب شد. در شکل ۳ نمودارهای مقایسه‌ای بین مقادیر مشاهده‌ای رسوب معلق و مقادیر برآوردشده توسط شبکه‌های عصبی مصنوعی مختلف در داده‌های آزمون شبکه (۲۵ درصد داده‌ها) در ایستگاه گلینک ارائه شده است.

تحلیل مقایسه‌ای شاخص‌های آماری نشان می‌دهد که مدل CANFIS علی‌رغم رقابت فشرده با سایر مدل‌ها در برخی معیارها، متعادل‌ترین عملکرد را در کل فرایند برآورد رسوب داشته است. در شاخص RMSE، مدل‌های MLP و GFF با مقدار ۰/۰۱۳ در رتبه نخست قرار دارند و مدل CANFIS در با اختلاف ناچیز (۰/۰۱۴) در جایگاه بعدی است؛ با این حال، برتری قاطع CANFIS در شاخص‌های NMSE و ضریب همبستگی توانمندی بالای این مدل را در درک پیچیدگی‌های غیرخطی و تطابق با داده‌های واقعی اثبات می‌کند.

در نقطه مقابل، مدل SVM با ثبت خطاهای فاحش در تمامی شاخص‌ها (از جمله RMSE برابر با ۲۵۱/۵۳ و NMSE معادل ۸۹۸/۵۵) ضعیف‌ترین و غیرقابل‌اعتمادترین عملکرد را از خود نشان داده است.




شکل ۳- نمودار مقادیر رسوب مشاهده‌ای و برآورد شده توسط شبکه‌های عصبی مصنوعی در ایستگاه گلینک

Fig. 3. Observed and predicted sediment values by the artificial neural networks at Glinak Station

پرت نسبت به سایر الگوریتم‌ها از خود نشان داده است. در مقابل، مدل‌هایی نظیر SOFM و SVM به‌دلیل ناتوانی در بازسازی دقیق مقادیر افراطی و وجود خطاهای سیستماتیک، کمترین انطباق را با واقعیت‌های میدانی ایستگاه گلینک دارند که این امر لزوم بهره‌گیری از مدل‌های عصبی‌فازی منعطف را در تحلیل‌های هیدرولوژیکی تبیین می‌کند. در نهایت شکل ۴ نتایج

تحلیل نمودارهای پراکنش در شکل ۳ حاکی از آن است که علی‌رغم تمرکز مناسب تمامی مدل‌ها در محدوده دبی‌های رسوب پایین، با افزایش مقادیر به سمت رخدادهای سیلابی، انحراف از خط مبنا (۱:۱) و پدیده کم‌برآوردی شدت می‌یابد. در این میان، مدل CANFIS با نمایش کمترین میزان پراکندگی و همگرایی بیشتر نقاط پیرامون خط هدف، توانمندی برتری در درک الگوهای غیرخطی و مدیریت داده‌های

حاصل از شبیه سازی رسوب توسط مدل های ترکیبی ۱ و ۲ ارائه شده است.



شکل ۴- نمودار مقادیر رسوب مشاهده‌ای و برآورد شده توسط مدل ترکیبی ۱ و ۲ در ایستگاه گلینک

Fig. 4. Observed and predicted sediment values by hybrid models at Glinak Station

نتایج به‌دست‌آمده از این دو ساختار ترکیبی نشان می‌دهد که علی‌رغم سادگی ظاهری، مدل ترکیبی ۱ در بازسازی رفتار دینامیک رسوب عملکرد بهتری داشته و می‌توان آن را به‌عنوان گزینه‌ای مناسب و قابل اعتماد برای برآورد رسوبات معلق در ایستگاه گلینک در نظر گرفت.

در نهایت در جدول ۷، نتایج حاصل از ارزیابی عملکرد مدل‌های مختلف ازجمله شبکه‌های عصبی مصنوعی، مدل‌های ترکیبی و روش منحنی سنج‌ه حد وسط دسته‌ها در ایستگاه گلینک با استفاده از دو معیار آماری کلیدی یعنی میانگین درصد خطای نسبی (RME) و ضریب ناش-ساتکلیف (NSE) ارائه شده است. این جدول امکان مقایسه جامع دقت برآورد هریک از مدل‌ها را فراهم می‌سازد.

نمودار حاصل نشان می‌دهد که مدل ترکیبی ۱ در بازه‌های زمانی متعددی، توانسته است روند کلی تغییرات را با دقت قابل قبول بازسازی کند. در نقاط پیک نیز، مقدار برآورد شده اغلب نزدیک به مقدار واقعی قرار گرفته است. استفاده از داده‌های پردازش‌شده و صاف‌شده از منحنی سنج‌ه به‌عنوان تنها ورودی، باعث کاهش نویز و بهبود دقت در دامنه میانی مقادیر شده است. در نتیجه، انطباق خوبی بین خطوط رسوب مشاهده‌ای و رسوب شبیه‌سازی‌شده دیده می‌شود و رفتار مدل نسبت به نوسانات شدید نسبتاً پایدار باقی مانده است.

در حالی که در مدل ترکیبی ۲ اگرچه روند کلی حفظ شده، اما در نقاط اوج و افت شدید رسوب، مدل عملکرد ناپایدارتری داشته و برخی قله‌های رسوب را کمتر از مقدار واقعی برآورد کرده است. به‌طور کلی،

جدول ۷- نتایج حاصل از ارزیابی هر کدام از روش‌ها با معیارهای مختلف

Table 7. Evaluation results of each method based on various criteria

Midpoint of Class Intervals Method	Hybrid 2	Hybrid 1	Artificial Neural Network						Learning Rule / Method
			SOFMs	CANFIS	SVM	RBF	GFF	MLPs	
433.54	1421.11	45.21	11786.5	5711.03	4541252	638.46	2227.50	2227.50	RME
0.37	0.38	0.63	0.43	0.36	0.45	0.33	0.44	0.44	NSE

توازن در توزیع داده‌ها و تمرکز غالب مشاهدات در دبی‌های پایین، موجب سوگیری مدل‌ها به سمت شرایط عادی شده و توانایی آنها را در بازنمایی رخدادهای حدی و سیلابی به شدت کاهش داده است. در میان روش‌های بررسی‌شده، مدل ترکیبی CANFIS مدل ترکیبی ۱ به عنوان کارترین رویکرد شناسایی شد. برتری این مدل ناشی از تلفیق دانش تجربی سنج رسوب با توان یادگیری هوش مصنوعی، استفاده از منطق فازی برای مدیریت عدم قطعیت‌ها و پایداری بالاتر در برابر نویزهای آماری بوده است، به طوری که این ویژگی‌ها موجب بهبود معنی‌دار عملکرد مدل نسبت به رویکردهای کلاسیک شده‌اند.

به طور کلی، نتایج حاصل از این پژوهش با مطالعات پیشین داخلی و بین‌المللی هم‌راستا بوده و بر کارایی بالاتر مدل‌های ترکیبی و هوشمند در شرایط هیدرولوژیکی پیچیده تأکید دارد. بر این اساس، مقادیر NSE به دست‌آمده ۰/۴۰ و ۰/۶۳ با توجه به ماهیت داده‌ها، قابل قبول و در محدوده نتایج گزارش‌شده در مطالعات مشابه ارزیابی می‌شود.

در نهایت، این تحقیق نشان می‌دهد که توسعه مدل‌های کارآمد برای پیش‌بینی بار رسوب نیازمند رویکردی داده‌محور-فرایندمحور ترکیبی است. بر این اساس، بهبود کیفیت داده‌ها، گسترش پایگاه مشاهداتی به‌ویژه در رخدادهای سیلابی، افزودن متغیرهای هیدرومتئورولوژیک مؤثر و استفاده از الگوریتم‌های پیشرفته یادگیری ماشین نظیر Random Forest و LSTM می‌تواند دقت مدلسازی را در مطالعات آینده به طور قابل توجهی ارتقا دهد.

تشکر و قدردانی

بدین‌وسیله نویسنده مراتب قدردانی و سپاس صمیمانه خود را از داوران محترم و سردبیران گرامی

بر اساس نتایج جدول ۷، مدل ترکیبی ۱ با مقدار RME معادل ۴۵/۲۱ درصد و ضریب NSE برابر با ۰/۶۳۲۴، بهترین عملکرد را در بین تمامی روش‌ها از خود نشان داده است. این مدل توانسته است با بهره‌گیری از خروجی منحنی سنج به عنوان تنها ورودی به شبکه عصبی، دقت برآورد رسوبات معلق را به شکل چشمگیری بهبود بخشد. در مجموع، نتایج جدول ۶ تأیید می‌کند که در این مطالعه مدل ترکیبی ۱ با ترکیبی منحنی سنج و شبکه عصبی مصنوعی CANFIS، کارآمدترین مدل برای برآورد رسوبات معلق در ایستگاه گلینک است.

نتیجه‌گیری

این پژوهش نشان داد که برآورد بار رسوب معلق در ایستگاه گلینک با محدودیت‌های ساختاری جدی در مدل‌های هیدرولوژیک متداول مواجه است. بررسی‌ها مشخص می‌سازد که عملکرد نسبتاً پایین شاخص NSE حدود ۰/۴۰ در روش حد وسط دسته‌ها و افزایش خطا در سایر روش‌ها، به طور مستقیم ناشی از پیچیدگی‌های ذاتی، رفتار غیرخطی و ماهیت بسیار متغیر فرایند تولید و انتقال رسوب در این حوضه است. از سوی دیگر، تحلیل آماری داده‌ها بیانگر پراکندگی بسیار شدید CV بالا، وجود توزیع به شدت چوله و دم‌کلفت و همچنین حضور تعداد قابل توجهی داده پرت است که به طور مستقیم موجب افزایش SST و در نتیجه کاهش کارایی مدل‌ها شده است.

علاوه بر این، وجود وابستگی غیرخطی میان دبی و رسوب در کنار پدیده هیستروسیس و نقش عوامل کنترلی نظیر رطوبت پیشین خاک و پوشش گیاهی نشان می‌دهد که بار رسوبی صرفاً تابع دبی لحظه‌ای نیست، بلکه یک سیستم چندمتغیره و وابسته به شرایط پیشین حوضه به شمار می‌رود. شایان ذکر است که عدم

نشریه که با دقت نظر و ارائه پیشنهادهای سازنده، موجب ارتقای کیفیت علمی این پژوهش شدند، صمیمانه تشکر و قدردانی می شود.

تعارض منافع

همچنین از تمامی همکاران و عزیزانی که در مراحل مختلف تهیه، تدوین و تکمیل این مقاله، با ارائه راهنمایی های علمی، همکاری های پژوهشی و در این مقاله تضاد منافع وجود ندارد و این مساله مورد تایید همه نویسندگان است.

فهرست منابع

- Adnan, R.M., Wang, M., Masood, A., Kisi, O., Shahid, S., Zounemat-Kermani, M., 2025. Applications of advanced optimized neuro fuzzy models for enhancing daily suspended sediment load prediction. *Comput. Model. Eng. Sci.* 143(1), 1249–1272. <https://doi.org/10.32604/cmes.2025.062339>
- Ahmadi, M., 2012. Estimating sediment of rivers by RBF and MLP. 11th Hydraulic Conf. in Iran, Urmia Uni. Iran (in Persian).
- Ahmer, M., Qaiser, K., Muhammad, A., 2019. Prediction of suspended sediment load using ANN, SVM and M5Tree machine learning models. *Water* 11(11), 2315.
- Arabkhedri, M., Lai, F.S., Ibrahim, N.A., Mohamad-Kasim, M.R., 2010. Effect of adaptive cluster sampling design on accuracy of sediment rating curve estimation. *J. Hydrol. Eng.* 15(2), 142–151. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000171](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000171)
- Arabkhedri, M., Lai, F.S., Noor-Akma, I., Mohamad-Roslan, M.K., 2010. An application of adaptive cluster sampling for estimating total suspended sediment load. *Hydrol. Res.* 41(1), 63–73. <https://doi.org/10.2166/nh.2010.113>
- Asfandiar-Darabad, F., Gharachorloo, M., 2022. Regional estimation of sediment yield using monthly sediment rating curves, case study: Ghareh-Soo Watershed. *Appl. Res. Geogr. Sci.* 23(69), 33–52 (in Persian).
- Asselman, N.E.M., 2000. Fitting and interpretation of sediment rating curves. *J. Hydrol.* 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)
- Azamathulla, H.M., Ghani, A.A., Fei, S.Y., 2012. ANFIS-based approach for predicting sediment transport in clean sewer. *Appl. Soft Comput.* 12(3), 1227–1230. <https://doi.org/10.1016/j.asoc.2011.08.009>
- Biranvand, N., Sepehvand, A., Haghi-Zadeh, A., 2021. Evaluation of the sediment rating curve method for estimating suspended sediment load, case study: Khorramabad, Alishtar and Beyranshahr Watersheds. *Hydrol. Eng. Res.* (in Persian).
- Chai, T., Draxler, R.R., 2014. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geosci. Model Dev.* 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- 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. *Sci. Total Environ.* 615, 272–281. <https://doi.org/10.1016/j.scitotenv.2017.09.249>
- Doroudi, S., Sharafati, A., 2024. A newly developed multi-objective evolutionary paradigm for predicting suspended sediment load. *J. Hydrol.* 634, 131090. <https://doi.org/10.1016/j.jhydrol.2024.131090>
- Eilderemi, A.R., Mohamadpanah-Moghadam, M., 2021. Optimization of a suitable model for estimating suspended sediment load in river basins. *J. Hydrol. Hydromech.* 69(4), 345–357.
- Ferguson, R.I., 1986. River loads underestimated by rating curves. *Water Resour. Res.* 22(1), 74–76. <https://doi.org/10.1029/WR022i001p00074>
- Ghafari, G., 2025. Prediction of suspended sediments using a hybrid model of sediment rating curve and artificial neural network at the Narvan Afjeh station. *Watershed Manage. Res.* 38(1), 128–146 (in Persian).
- Glysson, G.D., 1987. Sediment-transport curves (No. 87-218). U.S. Geol. Surv. <https://pubs.usgs.gov/of/1987/0218/report.pdf>
- Gupta, H.V., Sorooshian, S., Yapo, P.O., 1999. Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. *J. Hydrol. Engin.* 4(2), 135–143. [https://doi.org/10.1061/\(ASCE\)1084-0699\(1999\)4:2\(135](https://doi.org/10.1061/(ASCE)1084-0699(1999)4:2(135)
- Issazadeh, L., Govay, B., 2014. Reservoir sediment prediction in Duhok Dam using artificial neural network and conventional methods. *Indian J. Fundam. Appl. Life Sci.* 4, 56–67.
- Jansson, M.B., 1996. Estimating a sediment rating curve of the Reventazón River at Palomo using logged mean loads within discharge classes. *J. Hydrol.* 183(3–4), 227–241. [https://doi.org/10.1016/0022-1694\(95\)02988-5](https://doi.org/10.1016/0022-1694(95)02988-5)

- Janus, R., Volna, E., 2013. Feed-forward neural networks training speedup by using generalized activation function. *Int. J. Math. Models Methods Appl. Sci.* 7(8), 768–777.
- Karami, G., Moradi, H., Bahrami, M.R., 2014. Feasibility of predicting suspended sediments using a combination of sediment rating curve and artificial neural network. *Mar. Sci. Technol.* 13(48), 1–12 (in Persian).
- Karami, H., Farzin, S., Sadrabadi, M.T., Moazami, S., 2020. Simulation of water quality parameters using artificial intelligence-based models. *Water Supply* 20(5), 1863–1881. <https://doi.org/10.2166/ws.2020.103>
- Khazaepoul, A., Talebi, A., 2013. Feasibility of predicting suspended sediment using a combination of sediment rating curve and artificial neural network, case study: Ghotourchai River, Yazdekan Bridge. *Environ. Erosion Res.* 3(1), 73–82 (in Persian).
- Kisi, O., Ay, M., 2012. Comparison of ANN and ANFIS techniques in modeling dissolved oxygen. *Proc. 16th Int. Water Technol. Conf. (IWTC16)*, 7–10, Istanbul, Turkey.
- Koch, R.W., Smillie, G.M., 1986. Bias in hydrologic prediction using log-transformed regression models. *J. Am. Water Resour. Assoc.* 22(5), 717–723. <https://doi.org/10.1111/j.1752-1688.1986.tb00744.x>
- Kumar, A., Ahmad, S., Verma, A.K., 2020. Prediction of daily suspended sediments using particle swarm optimization-based artificial neural network models – A case study of Ganga River. *Environ. Monit. Assess.* 192(10), 1–16.
- Lee, B., Yun, T., Choi, J., Jeon, J., Kim, D., 2021. An advanced hybrid artificial neural network–sediment rating curve model for suspended sediment prediction in rivers. *Water* 13(11), 1552.
- Legates, D.R., McCabe, G.J., 1999. Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water Resour. Res.* 35(1), 233–241. <https://doi.org/10.1029/1998WR900018>
- Lohani, A.K., Goel, N.K., Bhatia, K.K.S., 2006. Improving real time flood forecasting using fuzzy inference system. *Water Resour. Manage.* 20(4), 513–529. <https://doi.org/10.1007/s11269-005-9007-3>
- Mahdavi-Meymand, A., Sulisz, W., 2023. Development of clustered machine learning technique for the modeling of scour profile/suspended-sediment related applications. *Ocean Engin.* 288, 115915. <https://doi.org/10.1016/j.oceaneng.2023.115915>
- Maier, H.R., Dandy, G.C., 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environ. Model. Softw.* 15(1), 101–124. [https://doi.org/10.1016/S1364-8152\(99\)00007-9](https://doi.org/10.1016/S1364-8152(99)00007-9)
- Malik, A., Kumar, A., Piri, J., 2017. Daily suspended sediment concentration simulation using hydrological data of Pranhita River Basin, India. *Comput. Electron. Agric.* 138, 20–28. <https://doi.org/10.1016/j.compag.2017.04.005>
- Mardoukhpour, A., Jamasebi, H., Alipour, O., 2019. Evaluation of sediment estimation using the sediment rating method compared with regression and neural network methods, case study: Babolrud River, Mazandaran Province. *Environ. Sci. Technol.* 21(11), 79–91 (in Persian).
- Miller, C.R., 1951. Analysis of flow-duration sediment rating curve method of computing sediment yield. U.S. Bureau of Reclamation.
- Moradi, H., Haghizadeh, A., Ghaemi, A., 2021. Predicting daily suspended sediment load using a novel hybrid artificial recurrent neural network model. *Environ. Monit. Assess.* 193(1), 1–16.
- Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel, R.D., Veith, T.L., 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Trans. ASABE* 50(3), 885–900. <https://doi.org/10.13031/2013.23153>
- Mostafa, R.R., Kisi, O., Adnan, R.M., Sadeghifar, T., Kuriqi, A., 2024. Modeling potential evapotranspiration by improved machine learning methods using limited climatic data. *Water* 15(3), 486. <https://doi.org/10.3390/w15030486>
- Najafinejhad, A., Babaei, A., Saniei, E., Mahmoodi, O., 2010. Comparison of monthly and seasonal suspended load rating curves in several Golestan province rivers. 4th Natl. Seminar on Erosion and Sediment, Noor, Iran, 6p (in Persian).
- Nash, J.E., Sutcliffe, J.V., 1970. River flow forecasting through conceptual models part I—A discussion of principles. *J. Hydrol.* 10(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Niha, K., Kumar, S., Yadav, S., 2023. Streamflow prediction using machine learning models. *J. Hydrol. Hydromech.* 71(1), 84–96. <https://doi.org/10.2478/johh-2022-0039>
- Noor, H., Vafakhah, M., Maghdesi, M., 2016. Decision support tool for optimal spatial planning of watershed management measures, case study: Taleghan Dam Watershed. *Water. Manage. Res.* 113, 71–80 (in Persian).

- Ren, Y., Zi, F., Xiong, L., Yu, G., Zhang, B., 2023. Improved hybrid model for sediment concentration prediction using advanced optimization and machine learning algorithms. *J. Hydrol.* 617, 128865. <https://doi.org/10.1016/j.jhydrol.2022.128865>
- Rishab, M., Kumar, A., Singh, R., 2024. Prediction of sediment transport using neural networks. *Water Resour. Manage.* 38(2), 567–584. <https://doi.org/10.1007/s11269-023-03712-5>
- Sepehvand, A., Biranvand, N., 2022. Evaluation of sediment rating curve method for estimating suspended sediment in karst rivers, case study: Hydrometric stations of Khorramabad, Alishtar and Beyranshahr Watersheds. 17th Natl. Conf. Watershed Sci. Engin. Iran (in Persian).
- Shahidi, K., Manavi-Amri, S.M., Mahmoudi, N., 2022. Spatial and temporal analysis of suspended sediment variations in the Nekaroud watershed, Mazandaran Province. *Spatial Anal. Environ. Hazards* 9(2), 195–208 (in Persian).
- Shiri, J., Kisi, O., 2012. Estimation of daily suspended sediment load by using wavelet conjunction models. *J. Hydrol.* 472–473, 302–317. <https://doi.org/10.1016/j.jhydrol.2012.09.051>
- Singh, J., Knapp, H.V., Arnold, J.G., Demissie, M., 2004. Hydrologic modeling of the Iroquois River watershed using HSPF and SWAT. *J. Am. Water Resour. Assoc.* 41(2), 343–360. <https://doi.org/10.1111/j.1752-1688.2005.tb03740.x>
- Srilatha, K., Sudha, T., 2024. Radial basis function neural networks for water quality prediction. *Environ. Monit. Assess.* 196(1), 45. <https://doi.org/10.1007/s10661-023-12245-8>
- Tamrabet, Z., Marouf, N., Remini, B., 2022. Modeling of suspended sediment concentrations by artificial neural network and adaptive neuro-fuzzy inference system method—study of five largest basins in Eastern Algeria. *Water Pract. Technol.* 17(5), 1058–1081. <https://doi.org/10.2166/wpt.2022.050>
- Thomas, R.B., 1985. Estimating total suspended sediment yield with probability sampling. *Water Resour. Res.* 21(9), 1381–1388. <https://doi.org/10.1029/WR021i009p01381>
- Wang, Y., Ding, J., 2021. A review of sediment prediction methods based on sediment rating curves. *J. Hydrol.* 601, 126543. <https://doi.org/10.1016/j.jhydrol.2021.126543>
- Willmott, C.J., Matsuura, K., 2005. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Clim. Res.* 30(1), 79–82. <https://doi.org/10.3354/cr030079>
- Yadav, A., Chithaluru, P., Singh, A., Albahar, M.A., Jurcut, A., Álvarez, R.M., Mojada, R.K., Joshi, D., 2022. Suspended sediment yield forecasting with single and multi-objective optimization using hybrid artificial intelligence models. *Mathematic.* 10(22), 4263. <https://doi.org/10.3390/math10224263>
- Yousefi, M., Barzegar, F., 2015. Determining the best sediment rating method and comparison with artificial neural network to estimate suspended sediments, case study: Lorestan Province. *Range Water. Manage.* Summer 2015 (in Persian).
- Zare, M., Bayat, M., 2013. Application of CANFIS for groundwater level forecasting. *J. Hydrol. Hydromech.* 61(4), 341–348. <https://doi.org/10.2478/johh-2013-0043>
- Zhang, H., 2023. Prediction of suspended sediment concentration by artificial neural networks at the Vu Gia–Thu Bon Catchment, Vietnam. *Environ. Sci. Eng.* 77–84.
- Zhang, J., Govindaraju, R.S., 2011. Modeling subsurface flow using an adaptive neuro-fuzzy inference system. *J. Hydrol. Eng.* 16(12), 1013–1019. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000392](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000392)