Journal of Water and Soil Science
Vol. 30, No. 2, 2026, Isfahan University of Technology, Isfahan, Iran. DOI: 10.47176/jwss.30.2.72681

Evaluation of a Hybrid Meta-Learning Model for Estimating Scour Depth Around Pile Groups

Shadi Kalantar Hormozi[1], Mohammadreza Zayeri[2*], Mehdi Ghomeshi[3] and Mehdi Daryaee[4]

(Received: September 19-2025; Revised: February 17-2026; Accepted: February 28-2026)

1. Department of Hydraulic Structures, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.
*Corresponding author: m.zayri@scu.ac.ir

Abstract

Scour is a major challenge in river engineering, as it causes bridge failures during flood events and leads to significant economic losses. This study aims to estimate the normalized scour depth (Dse/Dp) around pile groups by examining relevant hydrodynamic and geometric parameters. A dataset comprising 299 laboratory measurements collected from various sources was assembled and divided into training and testing subsets. As machine learning inputs, several models were employed, including Artificial Neural Networks (ANN), Support Vector Regression (SVR), Extreme Gradient Boosting (XGBoost), and a meta-ensemble learning model (Stacking). Hyperparameter tuning was performed using the Grid search method to achieve optimal regression performance. Model performance evaluation indicated that the ANN and SVR models achieved coefficients of determination of $R^2 = 0.87$ and $R^2 = 0.91$, respectively. The XGBoost model outperformed these approaches, yielding $R^2 = 0.94$ with an RMSE of approximately 0.28. Ultimately, the stacking ensemble model, by integrating the outputs of the base learners, demonstrated the highest predictive accuracy with $R^2 = 0.96$ and an RMSE of 0.11, representing an improvement of approximately 15% compared to ANN and 7% compared to XGBoost. Overall, the findings highlight that ensemble machine learning models—particularly the Stacking approach—provide a robust and efficient framework for predicting scour depth around pile groups and for capturing the complex flow behaviors in hydraulic systems.

Keywords: Pile groups; Scour depth; Clear-water conditions; Machine learning; Stacking mode

How to cite this article: Kalantar Hormozi, S., Zayeri, M., Ghomeshi, M. and Daryaee,M. 2026 Evaluation of a Hybrid Meta-Learning Model for Estimating Scour Depth Around Pile Groups. *J. Water and Soil Sci.* 30(2): 56-77. DOI: 10.47176/jwss.30.2.72681

Copyright © 2026 Kalantar Hormozi et al. Published by Isfahan University of Technology.

This work is licensed under a Creative Commons Attribution-Noncommercial 4.0 International license (https://creativecommons.org/licenses/by-nc/4.0/). Non-commercial uses of the work are permitted, provided the original work is properly cited.

نشریه علوم آب و خاک
سال سی‌ام/ شماره دوم / تابستان ۱۴۰۵/مقاله علمی-پژوهشی: صفحات ۵۶ تا ۷۷ 10.47176/jwss.30.2.72681

ارزیابی مدل یادگیری ترکیبی متا در تخمین عمق آبشستگی گروه‌های شمع

شادی کلانتر هرمزی، محمدرضا زایری*، مهدی قمشی و مهدی دریایی[۱]

(تاریخ دریافت: ۱۴۰۴/۶/۲۸ ؛ تاریخ بازنگری: ۱۴۰۴/۱۱/۲۸ ؛ تاریخ پذیرش: ۱۴۰۴/۱۲/۹)

۱. گروه سازه‌های آبی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.
*: مسئول مکاتبات: پست الکترونیکی: m.zayri@scu.ac.ir

چکیده

آبشستگی، چالش اصلی مهندسی رودخانه، با تخریب پل‌ها در سیلاب‌ها، هزینه‌های مالی را به دنبال دارد. این مطالعه با هدف تخمین عمق آبشستگی (Dse/Dp) اطراف گروه‌های شمع، پارامترهای هیدرودینامیکی و هندسی را بررسی کرد. بدین منظور با جمع‌آوری ۲۹۹ داده‌های آزمایشگاهی از منابع مختلف، داده‌ها به دو بخش آزمایش و آزمون تقسیم‌بندی شد. به عنوان ورودی مدل‌های یادگیری ماشین، شامل شبکه عصبی مصنوعی (ANN)، بردار پشتیبان (SVR)، الگوریتم تقویت گرادیان شدید (XGboost) و مدل یادگیری ترکیبی متا (Stacking) همچنین برای تنظیم اَبَرپارامترهای مدل از روش جستجوی شبکه‌ای Gridsearch به منظور ایجاد رگرسیون مؤثر استفاده شد. در ارزیابی عملکرد مدل‌ها، مدل ANN به مقدار R^2 =۰/۸۷ و مدل SVR به R^2 =۰/۹۱ دست یافتند. مدل XGBoost با R^2 =۰/۹۴ و RMSE ≈ ۰/۲۸ توانست عملکرد دقیق‌تری نسبت به دو مدل دیگر ارائه دهد. درنهایت، مدل ترکیبی Stacking با بهره‌گیری از خروجی مدل‌های پایه، بهترین عملکرد را ثبت کرده و مقدار R^2 = ۰/۹۶ و RMSE = ۰/۱۱ را به دست آورد که این نتایج به معنی افزایش حدود ۱۵ درصدی دقت نسبت به ANN و ۷ درصد نسبت به XGBoost است. به‌طور کلی یافته‌ها نشان می‌دهد که استفاده از مدل‌های ترکیبی یادگیری ماشین، به‌ویژه Stacking، می‌تواند رویکردی دقیق و کارآمد برای پیش‌بینی عمق آبشستگی پیرامون گروه‌های شمع و تحلیل رفتارهای پیچیده جریان در سامانه‌های هیدرولیکی باشد.

واژه‌های کلیدی: گروه‌های شمع، عمق آبشستگی، شرایط آب زلال، یادگیری ماشین، مدل stacking

حق انتشار این مستند، متعلق به دانشگاه صنعتی اصفهان است. ۱۴۰۴ ©.

این مقاله تحت گواهی زیر منتشر شده و هر نوع استفاده غیرتجاری از آن مشروط به استناد صحیح به مقاله و با رعایت شرایط مندرج در آدرس زیر مجاز است: (https://creativecommons.org/licenses/by-nc/4.0/)

مقدمه

پیش‌بینی عمق آبشستگی موضعی پیرامون پایه‌های پل در مقاطع عبور رودخانه‌ای و سازه‌های دریایی از جمله مسائل حیاتی در ارزیابی ایمنی و پایداری این زیرساخت‌های حساس به شمار می‌رود (۳۰). زمانی‌که جریان آب از اطراف پایه‌ی پل یا شمع سازه دریایی عبور می‌کند، الگوی جریان و سرعت آن، نیروهای برشی مؤثری ایجاد می‌کند که می‌توانند سبب فرسایش و تشکیل حفره‌های آبشستگی در مجاورت پایه شوند. طبق گزارش‌ها، حدود ۶۰ درصد از خرابی‌های پل‌ها در ایالات متحده و ۸۰ درصد در چین ناشی از شکل‌گیری حفره‌های آبشستگی عمیق طی سیلاب‌های بزرگ بوده است.

گروه‌های شمع به‌طور گسترده‌ای برای محافظت از سازه‌های دریایی و پایه‌های پل در رودخانه‌هایی با بستر آبرفتی و پتانسیل زیاد فرسایش مورد استفاده قرار می‌گیرند (۵). با این حال، مکانیسم آبشستگی در گروه‌های شمع به‌دلیل شکل‌گیری جریان‌های سه‌بعدی پیچیده در اطراف شمع‌ها، پیچیده‌تر بوده و برآورد عمق حفره‌ی آبشستگی در این نوع سازه‌ها را دشوار می‌کند. در مقایسه با مطالعات گسترده روی آبشستگی اطراف شمع منفرد (۱۰)، اطلاعات موجود در مورد پدیده‌ی آبشستگی در گروه‌های شمع (PGs) محدودتر است (۵). عوامل کلیدی مؤثر بر بیشینه عمق آبشستگی پیرامون گروه‌های شمع شامل فاصله بین شمع‌ها، نحوه آرایش هندسی آنها، زاویه برخورد جریان و ویژگی‌های جریان نزدیک‌شونده است (۵).

مطالعات متعددی درباره شکل‌گیری حفره‌های آبشستگی ناشی از جریان اطراف گروه‌های شمع با پیکربندی‌ها و زوایای مختلف، تعداد ستون‌های شمع و فاصله‌گذاری انجام شده است. در پژوهش شاهی‌نژاد و همکاران (۲۷)، ابعاد هندسی کانال‌های آبرفتی پایدار (عرض سطح آب w، عمق جریان h و شیب طولی S) با بهره‌گیری از مدل‌های محاسبات نرم MARS و GMDH و با مقایسه با شبکه عصبی چندلایه (MLP) برآورد شد. ورودی‌های مدل شامل دبی(Q) ، d_{50} و تنش برشی (τ) بود و مدل‌ها در دو حالت خام و بی‌بعد توسعه یافتند. نتایج نشان داد MARS در تخمین عرض سطح آب w برتر است. امینی باغ‌بادورانی و همکاران (۷) با جمع‌آوری پایگاه داده‌ای مشتمل بر ۳۶۵ مجموعه داده آزمایشگاهی، تأثیر مدت‌زمان رویداد جریان را بر عمق حداکثری آبشستگی بررسی کردند. همچنین یانگ و همکاران (۳۵) با بررسی تأثیر عدد فرود و فاصله بین شمع‌ها بر روند زمانی رشد حفرهٔ آبشستگی تحت شرایط جریان یکنواخت، نشان دادند که افزایش فاصله بین شمع‌ها منجر به کاهش عمق تعادلی آبشستگی می‌شود. احمدیان‌فر و همکاران (۳) یک مدل نوآورانه گروهی بوستینگ مبتنی بر حداقل مربعات (Least-squares Boosting Ensemble model)، با ادغام سه روش رگرسیون فرایند گاوسی (GPR)، جنگل تصادفی (RF) و مدل M5Tree به منظور پیش‌بینی دقیق عمق آبشستگی موضعی پیرامون گروه شمع‌های با فاصله‌گذاری غیریکنواخت، توسعه دادند. آنالیز حساسیت ایشان نشان داد که قطر شمع به‌عنوان اثرگذارترین متغیر، نقش کلیدی در پیش‌بینی آبشستگی دارد. علاوه بر این، طبق مطالعه ایشان آنالیز عدم قطعیت آشکار ساخت که مدل گروهی بوستینگ کمترین مقدار عدم قطعیت ($۵۹/۸\times۱۰^{-۳}$) را داراست.

یکی از پارامترهای تأثیرگذار مهم که در تخمین عمق آبشستگی پیرامون گروه‌های شمع نادیده گرفته شده است، فاصله‌گذاری غیر یکنواخت بین شمع‌هاست (۶). طبق مطالعهٔ امینی و سلیمانی (۶)، افزایش یکنواخت در فاصله عرضی می‌تواند منجر به کاهش عمق حداکثری آبشستگی شود؛ در حالی‌که تغییر در فاصله‌گذاری طولی تأثیر چشمگیری بر عمق آبشستگی ندارد. در میان مدل‌های تجربی مختلفی که برای برآورد عمق آبشستگی اطراف گروه‌های شمع توسعه یافته‌اند، پرارجاع‌ترین آنها در جدول ۱ ارائه شده‌اند.

در بیشتر مطالعات، روش‌های مبتنی بر رگرسیون استفاده شده‌اند که در پیش‌بینی دقیق عمق آبشستگی چندان موفق نبوده‌اند (۲۹). در سال‌های اخیر، روش‌های یادگیری ماشین (ML) به‌طور گسترده‌ای در مهندسی عمران به‌کار گرفته شده‌اند (۲) و به‌ویژه در مسائل مرتبط با آبشستگی با موفقیت به‌کار رفته‌اند (۱۵).

جدول ۱. روابط موجود برای تعیین عمق آبشستگی اطراف گروه‌های شمع

منبع	عبارت
آرنسون و همکاران (۸)	$\frac{d_s}{y} = 2K_1K_2K_3K_4\left(D_y^*\right)^{0.65} Fr^{0.43}$ $K_{Smn} = \left[1-\frac{4}{3}(1-n^{-1})\left(\frac{S_n}{D_p}\right)^{-0.6}\right]\times\left[0.9+0.1m-0.0714(m-1)\left(2.4-1.1\left(\frac{S_n}{D_p}\right)+0.1\left(\frac{S_n}{D_p}\right)^2\right)\right]$ $D_p^* = K_{Smn}W$
شپرد و رنا (۳۱)	$\frac{d_s}{D_p} = 2.5f_1\left(\frac{y}{D_p^*}\right)\cdot f_2\left(\frac{U}{U_c}\right)\cdot f_3\left(\frac{D_p^*}{d_{50}}\right), f_1\left(\frac{y}{D_p^*}\right) = \tanh\left[\left(\frac{y}{D_p^*}\right)^{0.4}\right]$ $f_2\left(\frac{U}{U_c}\right) = 1-1.75\left[\ln\left(\frac{U}{U_c}\right)\right]^2$ $f_3\left(\frac{D_p^*}{d_{50}}\right) = \frac{\frac{D_p^*}{d_{50}}}{0.4\left(\frac{D_p^*}{d_{50}}\right)^{1.2}+10.6\left(\frac{D_p^*}{d_{50}}\right)^{-0.13}}$ $K_{Smn} = \left[1-\frac{4}{3}\left(1-n^{-1}\right)\left(\frac{S}{D_p}\right)^{-0.6}\right]\cdot\left[0.045m+0.96\right]$ $D_p^* = K_{Smn}W$
هوارد و اعتمادشهیدی (۲۱)	$\frac{d_s}{D_p} = 2.74n^{0.07}S^* - 0.045\left(\frac{y}{D_p}\right)^{0.25} Fr^{0.37}$ $S^* = \sqrt{S_n^2+S_m^2}$
قائمی و همکاران (۱۸)	$\frac{d_s}{D_p} = 2.09\backslash m^{0.03}n^{0.14}\left(\frac{G}{D_p}\right)^{-0.14}\left(\frac{y}{D_p}\right)^{0.38} Fr^{0.34}$
امینی و همکاران (۵)	$\frac{d_s}{y} = 2K_1K_2K_3K_4\left(D_y^*\right)^{0.65} Fr^{0.43}, be = K_{Smn}W$ $K_{Smn} = 1.31\cdot m^{0.05}\cdot n^{0.44}\cdot\left(\frac{S}{D_p}\right)^{0.38}$
عطایی‌اشتیانی و بهشتی (۹)	$\frac{d_s}{y} = 2K_1K_2K_3K_4\left(D_y^*\right)^{0.65} Fr^{0.43}, be = K_{Smn}W$ $K_{Smn} = 1.11\cdot m^{0.0396}\cdot n^{0.5225}\cdot\left(\frac{S}{D}\right)^{0.1153}$
بهشتی و همکاران (۱۲)	$\frac{d_s}{y} = 2K_1K_2K_3K_4\left(D_y^*\right)^{0.65} Fr^{0.43}$ $K_{Smn} = 0.7\cdot m^{0.38}\cdot n^{0.95}\cdot\left(\frac{S}{D_p}\right)^{0.387}+0.42$

محمدپور (۲۴) سه روش یادگیری ماشین شامل برنامه‌سازی بیان – ژنی(GEP)، ANN و مدل M5Tree را در پیش‌بینی عمق آبشستگی در شمع‌های مرکب به‌کار برد. عملکرد شبکه عصبی RBF بهتر از GEP و M5Tree بود، اما معادلات توسعه‌یافته توسط GEP و M5Tree از نظر کاربردی بودن، مناسب‌تر گزارش شدند. باتنی و همکاران (۱۱) نیز از روش‌های MARS (اسپلاین های رگرسیون تطبیقی چند متغیره) و GEP برای پیش‌بینی عمق آبشستگی در شرایط آب زلال استفاده کردند که مدل MARS نسبت به GEP عملکرد بهتری نشان داد و هر دو مدل از معادلات تجربی دقیق‌تر بودند. ابتهاج و همکاران (۱۶) با بهره‌گیری از ماشین یادگیری سریع (ELM)، SVM و ANN، عمق آبشستگی موضعی گروه‌های شمع در شرایط آب زلال را بر اساس آنالیز ابعادی بررسی کردند. همچنین، صمدی و همکاران (۲۶) عملکرد الگوریتم‌های درختان طبقه‌بندی و رگرسیون (CART)، MARS، ANN و M5Tree را برای پیش‌بینی آبشستگی ناشی از جریان اطراف گروه شمع مقایسه کرده و همانند نتایج باتنی، دقت بیشتر مدل MARS را گزارش کردند. در پژوهش جلالی و همکاران (۲۲)، ارتباط غلظت رسوب معلق رودخانه کن تهران با ویژگی‌های آبخیز با استفاده از رگرسیون مؤلفه‌های اصلی بررسی شد. داده‌ها در ۴ رخداد بارشی و ۳ فصل در زیرحوضه‌ها برداشت و ۱۶ شاخص کاربری اراضی تحلیل شد. نتایج تفاوت مکانی معنادار و بیشترین رسوب‌زایی در فصل بهار را نشان داد.

مدل‌های گروهی (Ensemble models) با ترکیب چندین دسته از درخت‌های تصمیم‌گیری ساده، عملکرد پیش‌بینی بهتری ارائه می‌دهند (۲۸). در واقع، با ادغام گروه‌هایی از یادگیرنده‌های ضعیف، یک یادگیرندهٔ قوی جدید ایجاد می‌شود. مدل‌های گروهی با کاهش نویز، واریانس و بایاس مدل، دقت پیش‌بینی را افزایش می‌دهند. حسینی و همکاران (۲۰) با استفاده از شبکه عصبی مبتنی بر bagging، عمق آبشستگی گروه شمع‌ها را پیش‌بینی کردند. نتایج آنها نشان داد که روش bagging قابل‌اعتمادترین نتایج را ارائه می‌دهد.

هدف اصلی این مقاله توسعه مدل یادگیری ترکیبی متا (Stacking) بر پایه روش تقویتی حداقل مربعات (LSBoost) است که با ادغام نتایج سه مدل یادگیری ماشین شامل MLP، SVR و XGBoost دقت پیش‌بینی عمق آبشستگی موضعی پیرامون گروه‌های شمع با فاصله‌گذاری نامنظم را در شرایط جریان زلال بهبود دهد. در این پژوهش، متغیرهای ورودی بی‌بعد مورد بررسی قرار گرفت و برای اعتبارسنجی مدل یادگیری ترکیبی متا و همچنین سه مدل مستقل یادگیری ماشین، تحلیل‌های گرافیکی متعددی انجام شد. علاوه بر این، چندین رابطه تجربی موجود نیز به‌منظور مقایسه با مدل‌های مبتنی بر هوش مصنوعی در پیش‌بینی عمق آبشستگی گروه‌های شمع بررسی شد. در مرحله بعد، یک تحلیل حساسیت جامع با استفاده از روش SHAP به‌منظور شناسایی مهم‌ترین متغیرهای پیش‌بینی‌کننده انجام شد. درنهایت، تحلیل عدم قطعیت برای ارزیابی میزان قطعیت پیش‌بینی مدل‌های داده‌محور توسعه‌یافته صورت گرفت و نتایج آن با روابط تجربی موجود مقایسه و کمّی‌سازی شد.

مواد و روش‌ها

تحلیل ابعادی و آماده‌سازی داده‌ها

عوامل مؤثر در فرایند عمق آبشستگی موضعی پیرامون گروه‌های شمع و پایه‌های پل، در شرایط جریان زلال پایدار و بستر زنده، شامل مشخصات هیدرولیکی جریان، ویژگی‌های هندسی شمع‌ها، نحوه آرایش شمع‌ها و ویژگی‌های فیزیکی جریان و رسوبات بستر هستند (۵). شکل ۱ نمایی شماتیک از یک نمونه آرایش گروه شمع به‌صورت (۲×۳) را نشان می‌دهد که در آن پارامترهای هندسی مؤثر بر آبشستگی قابل مشاهده است. رابطه میان پارامترهای مستقل و عمق آبشستگی موضعی را می‌توان در قالب ساختاری بی‌بعد تعریف کرد. بر این اساس، عمق آبشستگی بدون بعد در اطراف گروه‌های شمع با در نظر گرفتن تمامی متغیرهای مؤثر، به صورت معادله ۱ بیان می‌شود (۱۱):

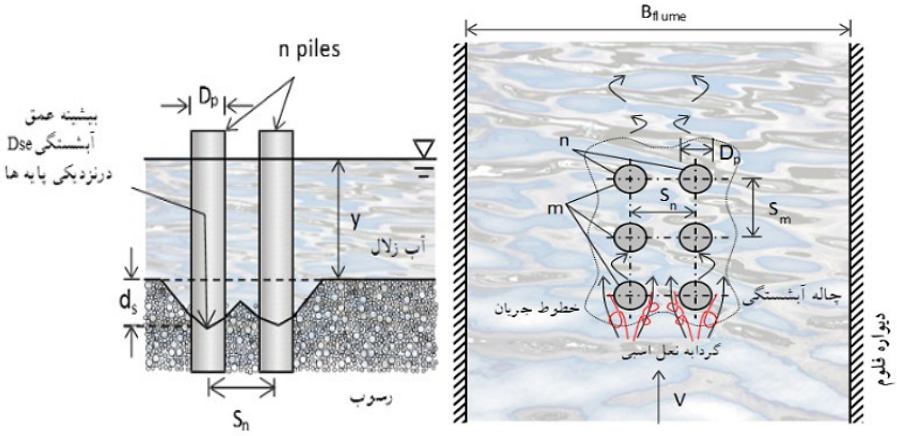

(ب) (الف)

شکل ۱. نمای شماتیک آرایش گروه شمع (۲ × ۳) و پارامترهای هندسی موثر بر عمق آبشستگی: (الف) نمای پلان آرایش شمع‌ها و فواصل هندسی، (ب) نمای جانبی شمع‌ها و شرایط جریان و بستر

$$\frac{d_s}{D_p}=f_2\left(\frac{U}{U_c},Fr=\frac{U^2}{gD_p},\frac{D_p}{d_{50}},\frac{y}{D_p},R_e=\frac{UD_p}{\nu},\frac{S_m}{D_p},\frac{S_n}{D_p},\frac{m}{n}\right) \quad (۱)$$

در این معادله، $\frac{d_s}{D_p}$ نشان‌دهندهٔ نسبت عمق آبشستگی به قطر شمع، $\frac{U}{U_c}$ نسبت سرعت متوسط جریان ورودی به سرعت بحرانی در آغاز حرکت ذرات رسوبی بستر، Fr عدد فرود، $\frac{D_p}{d_{50}}$ نسبت قطر شمع به میانگین اندازه ذرات رسوبی بستر، $\frac{y}{D_p}$ نسبت عمق جریان نزدیک‌شونده به قطر شمع، Re عدد رینولدز و $\nu=\frac{\mu}{\rho}$ ویسکوزیته سینماتیکی جریان سیال، $\frac{S_m}{D_p}$ و $\frac{S_n}{D_p}$ به ترتیب فاصله طولی بین شمع‌ها در راستای جریان و فاصله عرضی بین شمع‌ها عمود بر جهت جریان، بی‌بعدشده با قطر شمع و $\frac{m}{n}$ نسبت تعداد شمع‌ها در راستای جریان به تعداد شمع‌ها در راستای عمود بر جریان است.

به‌منظور توسعه یک مدل پیش‌بینی مبتنی بر روش‌های ترکیبی (Ensemble-based)، تعداد ۲۹۹ ردیف داده از ۸ منبع مختلف گردآوری شد. کل مجموعه داده شامل ۱۲ نوع آرایش مختلف از گروه‌های شمع است که در شکل ۲ نمایش داده شده‌اند.

شکل ۳ رابطه میان متغیرهای پیش‌بینی‌کننده انتخاب‌شده و خروجی مد نظر را نشان می‌دهد. این شکل شامل نمودارهای ماتریس همبستگی است که ارتباط خطی بین متغیرها را با استفاده از ضریب همبستگی پیرسون (Pearson's correlation coefficient) نمایش می‌دهد. مقدار ضریب همبستگی پیرسون (r_p) در بازه [1،-1] قرار دارد؛ به‌طوری‌که مقدار مثبت یک، نشان‌دهندهٔ رابطه مستقیم و متناسب میان متغیرهای ورودی و خروجی است و بالعکس. رابطه محاسبه ضریب همبستگی پیرسون به صورت معادله ۲ تعریف می‌شود (۱۳):

$$r_p=\frac{\sum_{i=1}^{N}(X_i-\bar{X})(T_{ri}-\bar{T}_{ri})}{\sqrt{\sum_{i=1}^{N}(X_i-\bar{X})^2\sum_{i=1}^{N}(T_{ri}-\bar{T}_{ri})^2}} \quad (۲)$$

که در آن؛ X_i متغیرهای پیش‌بینی‌کننده (ورودی) T_{ri} مقدار متغیر هدف (خروجی) $\bar{X}$ میانگین متغیرهای ورودی، $\bar{T}_{ri}$ میانگین متغیر هدف است. مطابق با شکل ۳ ضریب همبستگی دو به دوی هر پارامتر نسبت به یکدیگر نشان داده شده است. برای نمونه بیشترین همبستگی مثبت در میزان آبشستگی گروه‌های شمع مربوط به U/U_c و Re است.

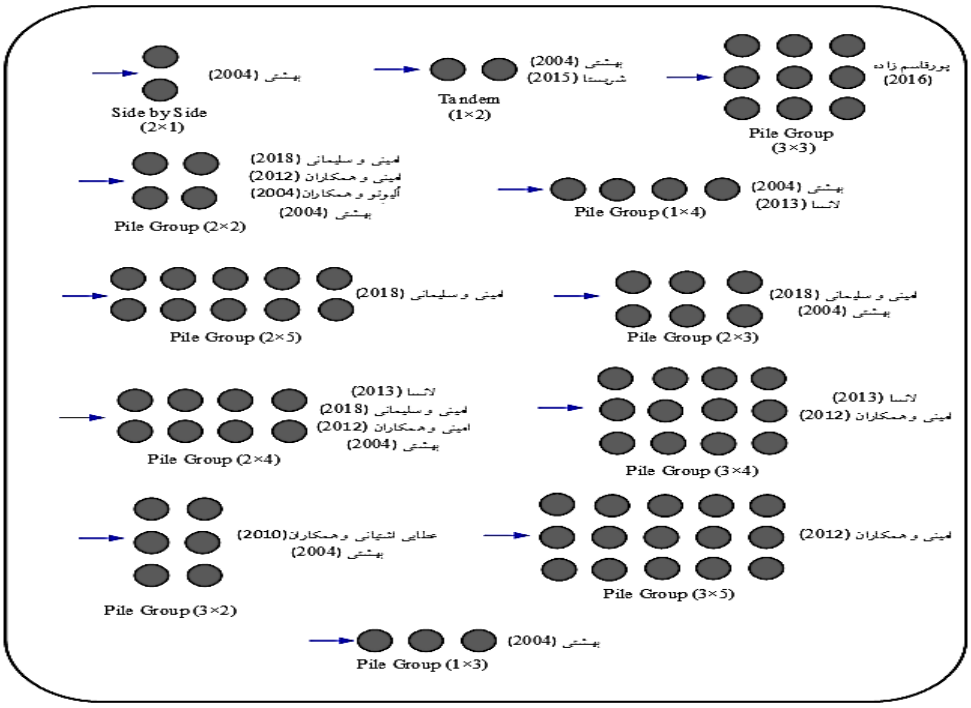

شکل ۲. نمای شماتیک آرایش گروه‌های شمع مورد استفاده در این پژوهش

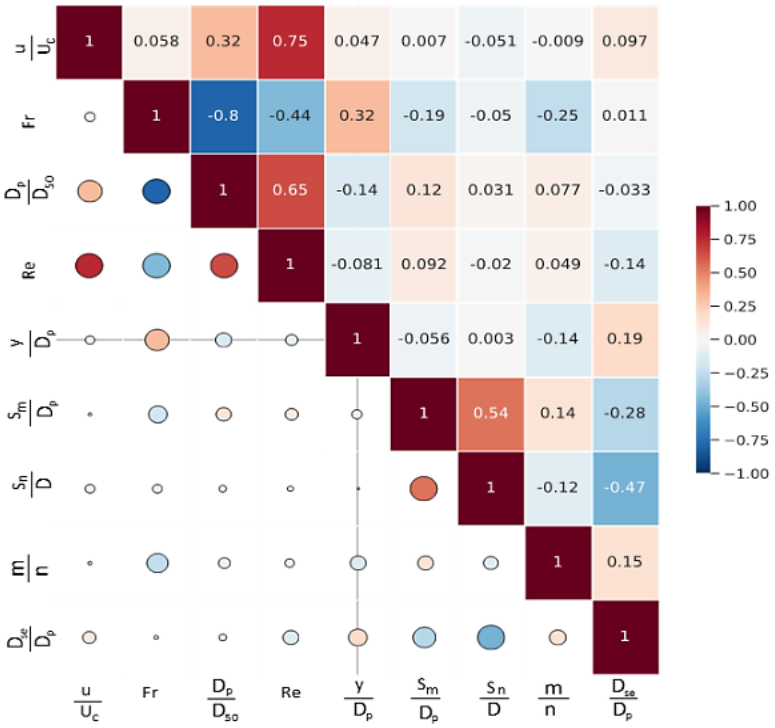

شکل ۳. ماتریس ضریب همبستگی متغیرهای بدون بعد

بررسی نمودارهای کانتور ارائه‌شده در شکل ۴ نشان می‌دهد که نسبت عمق آبشستگی به قطر شمع (D_{se}/D_p) در بازه‌ای حدود ۱/۳ تا ۳/۸ تغییر می‌کند و به‌طور قابل توجهی تحت تأثیر پارامترهای هیدرودینامیکی و هندسی قرار دارد. نتایج مربوط به نسبت سرعت جریان به سرعت بحرانی (U/U_c) حاکی از آن است که با افزایش این نسبت، شدت آبشستگی افزایش یافته و دو بیشینه در حدود $U/U_c \approx$ ۰/۷۵ و ۰/۹۰ مشاهده می‌شود. تغییرات عدد فرود (Fr) نیز روندی مشابه را نشان می‌دهد؛ به‌طوری که بیشترین آبشستگی در مقادیر متوسط Fr، به‌ویژه در حدود ۰/۴۵ و ۰/۸۵ رخ می‌دهد.

پارامتر نسبت قطر شمع به قطر متوسط ذرات بستر (D_p/D_{50})دارای رفتار غیرخطی بوده و دو پیک اصلی آبشستگی در حدود ۲۵ و ۶۵ دیده می‌شود. فاصله عرضی شمع‌ها (y/D_p) بیشترین تأثیر را در فواصل کم و متوسط داشته و بیشینه آبشستگی در حدود $y/D_p \approx$ ۳ و یک پیک ثانویه در حدود ۷ رخ می‌دهد. نتایج عدد رینولدز (Re) بیانگر رفتار غیرخطی آبشستگی است؛ به‌طوری که بیشینه‌ها در حدود $Re \approx$ ۵۰۰۰ و ۱۵۰۰۰ دیده می‌شوند. بررسی فاصله طولی شمع‌ها (S_m/D_p) نشان می‌دهد که آبشستگی نسبت به این پارامتر حساس بوده و بیشینه آن در حدود $S_m/D_p \approx$ ۳ رخ می‌دهد؛ درحالی‌که افزایش S_n/D_p عموماً موجب کاهش آبشستگی می‌شود. درنهایت، افزایش تعداد شمع‌ها در راستای جریان تا مقادیر متوسط، سبب افزایش عمق آبشستگی می‌شود.

در مجموع، نمودارها نشان می‌دهند که پدیدهٔ آبشستگی وابسته به تعامل چندپارامتری و رفتارهای غیرخطی پیچیده است. ازاین‌رو، بهره‌گیری از مدل‌های پیشرفته یادگیری ماشین مانند MLP، SVR و XGBoost برای پیش‌بینی دقیق و تحلیل رفتار آن در این مطالعه مورد بررسی قرار می‌گیرد.

پیش‌پردازش داده‌ها با استفاده از روش SSMD

روش انتخاب زیرمجموعه با بیشینه ناهمگونی (SSMD) به‌منظور گزینش داده‌های آموزش و آزمون از طریق دستکاری تصادفی داده‌ها به‌کار گرفته شد. با توجه به ناهمگونی موجود در پایگاه داده، استفاده از این روش دسته‌بندی و همگون‌سازی داده‌ها برای مدل‌های یادگیری ماشین در دستیابی به پیش‌بینی دقیق، بسیار حیاتی بوده است. تعداد کم داده‌ها منجر به ایجاد نویز در مدل شده و در مقابل، پایگاه‌های داده بسیار بزرگ می‌توانند منجر به ایجاد روابط پیچیده و بروز مشکل بیش‌برازش (Overfitting) شوند (۲۵).

الگوریتم SSMD زیرمجموعه‌ای از نقاط N بعدی را انتخاب می‌کند که به‌صورت یکنواخت در فضای آزمایش توزیع شده‌اند. اگر X به‌عنوان مجموعه‌داده‌ها به صورت $X = (x_1, x_2, ... x_p)$ در نظر گرفته شود و مجموعه‌ای از نقاط $m = 1, 2, ..., N$ به‌عنوان نامزدهای انتخاب برای زیرمجموعه آموزش تعریف شوند، آنگاه انتخاب نقاط طراحی به‌صورت ترتیبی (سکانسی) انجام می‌گیرد. اگر فاصله مربعی بین نقطه i و j به‌صورت $D^2_{i,j}$ تعریف شود و تاکنون k نقطه انتخاب شده باشند (که $k<p$ است)، آنگاه کمترین فاصله از نقطه نامزد N به نقاط انتخاب‌شده k تایی به‌صورت معادله ۳ تعریف می‌شود:

$$D^2_{i,j} = \| x_i - x_j \| = \sum_{k=1}^{p} (x_{ki} - x_{kj})^2 \qquad (۳)$$

$$\Delta^2_i(k) = \min(D^2_{1i}, D^2_{2i}, ..., D^2_{ki}) \quad i \neq m$$

با استفاده از روش SSMD، ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد داده‌ها برای آزمون مدل‌های استخراج‌شده انتخاب شدند. شکل ۵ و جدول ۲ توزیع زیرمجموعه‌های انتخاب‌شده را نشان می‌دهد و مشخص می‌کند که زیرمجموعه آموزشی، نواحی مرزی مجموعه داده را پوشش داده و زیرمجموعه آزمون در درون دامنه آموزشی قرار دارد.

به‌منظور کنترل قابلیت تعمیم‌پذیری مدل‌های توسعه‌یافته مبتنی بر هوش مصنوعی در برآورد عمق آبشستگی اطراف گروه‌های شمع در شرایط جریان زلال، از روش اعتبارسنجی متقابل K-بخش (K-fold cross-validation) استفاده شده است. در این روش، مجموعه‌دادهٔ اولیه به‌صورت تصادفی به K زیرمجموعهٔ مساوی تقسیم می‌شود. از میان این K زیرمجموعه، یک زیرمجموعه به‌عنوان دادهٔ اعتبارسنجی (آزمون) در نظر گرفته شده و

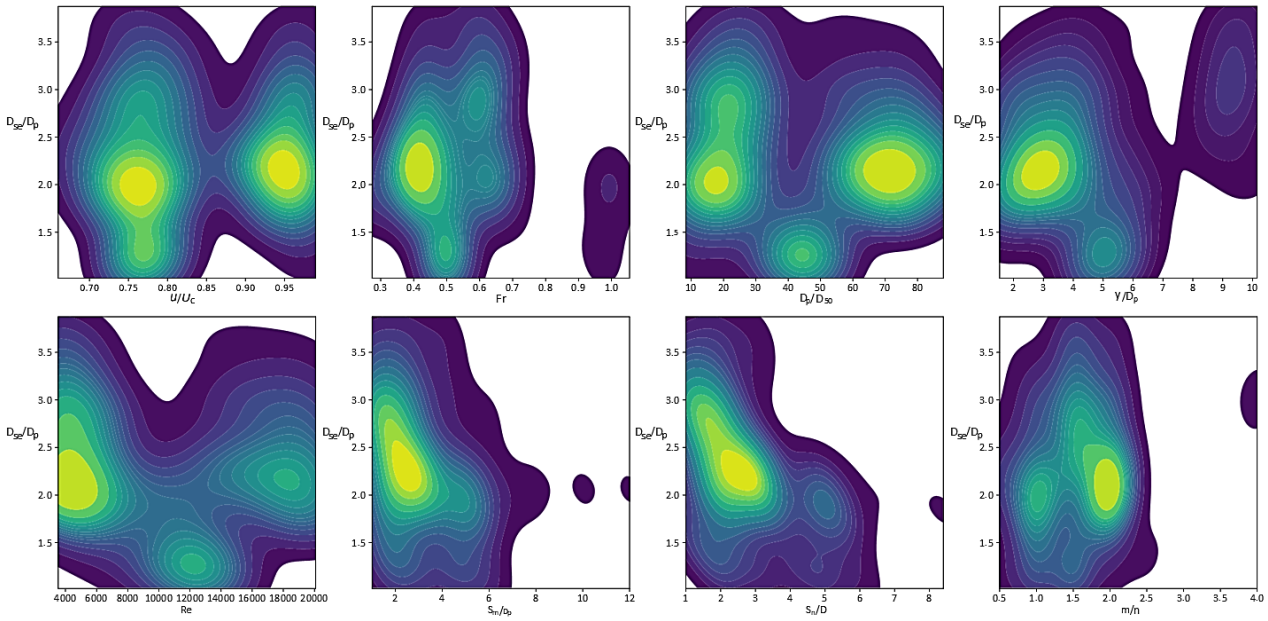

شکل ۴. تغییرات کانتوری عمق آبشستگی نسبی نسبت به پارامترهای ورودی

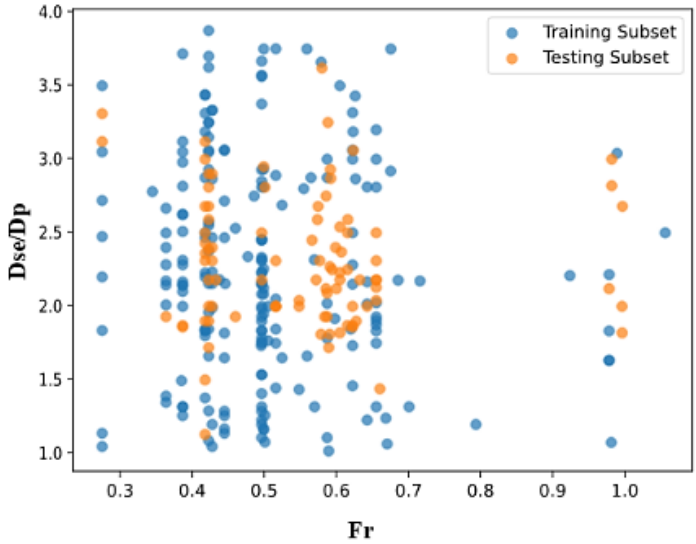

شکل ۵. توزیع زیر مجموعه‌های آموزش و آزمایش انتخاب شده با روش SSMD

باقی‌مانده K−1 زیرمجموعه به‌عنوان دادهٔ آموزش به‌کار گرفته می‌شود. این فرایند K بار تکرار شده و در هر بار، یکی از زیرمجموعه‌ها دقیقاً یک‌بار در نقش دادهٔ اعتبارسنجی قرار می‌گیرد.

مدل‌های یادگیری ماشین

- تقویت گرادیان شدید (XGB)

الگوریتم تقویت گرادیان شدید XGB، همچنین با نام XGBoost شناخته می‌شود که توسط چن و گوسترین (۱۴) ارائه شده و به‌عنوان نسل جدیدی از ماشین‌های تقویت گرادیانی محسوب می‌شود. مشابه سایر الگوریتم‌های تقویت گرادیان، XGB نیز از راهبرد آموزش تجمعی (additive training strategy) پیروی می‌کند؛ بدین‌صورت که پیش‌بینی‌ها بر پایهٔ یادگیرنده‌های

جدول ۲. ویژگی‌های آماری داده‌ها در دو بخش آموزش (train) و آزمایش (test)

DataSet	Parameter	Mean	Std Dev	Min	Max	Skewness	Kurtosis
train	Sn/D	2.911	1.598	1.000	8.400	1.046	0.804
	Sm/Dp	3.376	2.133	1.000	12.000	1.500	3.225
	m/n	1.566	0.647	0.500	4.000	1.254	3.815
	u/Uc	0.841	0.098	0.660	0.990	0.193	-1.569
	Fr	0.503	0.137	0.274	1.054	1.569	3.703
	y/Dp	3.876	1.676	1.540	10.150	1.290	2.444
	Dp/D50	47.710	24.822	8.333	88.000	-0.008	-1.300
	Re	10667.623	5757.895	3536.000	20079.528	0.134	-1.434
	Dse/Dp	2.135	0.635	1.018	3.717	0.888	-0.179
test	Sn/D	2.237	0.864	1.000	5.000	1.464	2.716
	Sm/Dp	2.403	0.957	1.000	5.000	0.965	0.812
	m/n	1.511	0.395	0.667	2.000	-0.309	-0.932
	u/Uc	0.836	0.096	0.680	0.980	0.459	-1.574
	Fr	0.555	0.149	0.274	0.995	1.280	2.525
	y/Dp	5.083	2.948	1.540	10.000	0.574	-1.318
	Dp/D50	38.998	25.481	8.333	88.000	0.616	-1.340
	Re	9120.014	6632.703	3578.994	19851.438	0.720	-1.309
	Dse/Dp	2.577	0.617	1.318	3.875	0.105	-0.759

ضعیف انجام می‌شود که به‌صورت پیاپی سعی در جبران خطاهای یادگیرنده‌های قبلی دارند. تفاوت اصلی در این است که الگوریتم‌های تقویت گرادیان معمول، از گرادیان منفی برای آموزش یادگیرنده ضعیف استفاده می‌کنند تا تابع خطا را تقریب بزنند؛ درحالی‌که XGB ابتدا تقریب درجه دوم تیلور از تابع خطا را در نقطه مورد نظر محاسبه کرده و سپس با کمینه‌سازی آن، یادگیرنده ضعیف را آموزش می‌دهد.

- رگرسیون بردار پشتیبان (SVR)

رگرسیون بردار پشتیبان (SVR) نوعی از ماشین بردار پشتیبان (SVM) است که برای انجام وظایف رگرسیونی به‌کار گرفته می‌شود (۳۳). مفهوم کلی SVR بر این اصل استوار است که داده‌های ویژگی (Feature Data) به‌صورت غیرخطی به فضای ویژگی با بُعد بیشتر نگاشت می‌شوند. هدف اصلی SVR یافتن یک اَبَرصفحه است که حاشیه بین نمونه‌ها را بیشینه کند و به‌گونه‌ای داده‌ها را از یکدیگر جدا سازد. نقاط داده‌ای که در نزدیکی این ابرصفحه قرار دارند و از حاشیه حمایت می‌کنند، بردارهای پشتیبان (Support Vectors) نامیده می‌شوند. در SVR، فرایند نگاشت داده‌ها به فضای ویژگی با بُعد بیشتر توسط تابع هسته‌ای انجام می‌شود (۱۹). مطالعات پیشین در حوزه‌ی هیدرولوژی که از SVR بهره گرفته‌اند، نشان داده‌اند که تابع هسته‌ای پایه شعاعی در بسیاری از موارد عملکرد مؤثری داشته است (۳۲).

- پرسپترون چندلایه (MLP)

شبکه عصبی مصنوعی (ANN) با الهام از ساختار عصبی مغز انسان توسعه یافته است (۱). یکی از معماری‌های رایج ANN که در این مطالعه مورد استفاده قرار گرفته، پرسپترون چندلایه (MLP) است (۴). به‌طور خلاصه، MLP یک شبکه پیش‌خور است که از سه بخش اصلی تشکیل شده است: لایه ورودی، لایه(های) پنهان و لایه خروجی. لایه ورودی، داده‌های بیرونی را دریافت می‌کند و لایه خروجی، نتیجه نهایی را تولید

می‌نماید. لایه‌های پنهان شامل گره‌های عصبی (نورون‌ها) بین لایه ورودی و خروجی هستند که مسئول ایجاد رفتار غیرخطی در شبکه هستند. در مسائل پیچیده‌تر، با افزایش تعداد نورون‌های پنهان یا تعداد لایه‌های پنهان، قابلیت حل مسئله افزایش می‌یابد. هر نورون به‌عنوان یک واحد محاسباتی در نظر گرفته می‌شود که ورودی‌هایی را از سایر نورون‌ها دریافت می‌کند. این ورودی‌ها با وزن‌هایی با نورون مقصد مرتبط شده‌اند. نورون‌ها از یک تابع فعال‌سازی استفاده می‌کنند که ترکیب خطی ورودی‌ها را گرفته و خروجی نهایی را پس از اعمال یک تبدیل غیرخطی تولید می‌کند.

- یادگیری گروهی Stacking (Stacking Ensemble Learning)

یادگیری گروهی Stacking نخستین‌بار توسط وولپرت (۳۴) پیشنهاد شد. این روش با بهره‌گیری از تکمیل‌کنندگی متقابل مدل‌های پایه به‌منظور افزایش قابلیت تعمیم‌پذیری مدل نهایی عمل می‌کند. فرایند به این صورت است که ابتدا مجموعه‌ای از مدل‌های پایه با ساختارها و عملکردهای متفاوت، خروجی‌های پیش‌بینی‌شده را تولید می‌کنند و سپس این خروجی‌ها به‌صورت بهینه با استفاده از یک فرا-یادگیرنده ترکیب می‌شوند تا پیش‌بینی نهایی حاصل شود. برای جلوگیری از بیش‌برازش، خروجی‌های مدل‌های پایه به طور مستقیم به مدل فراگیر آموزش داده نمی‌شوند. در عوض، از روش اعتبارسنجی متقابل یک‌به‌جامانده (Leave-One-Out Cross Validation) استفاده می‌شود. در این روش، خروجی‌های تولیدی در مرحله اعتبارسنجی، به‌عنوان مجموعه داده جدید برای آموزش فرا-مدل انباشته می‌شوند؛ از همین‌رو به این رویکرد، Stacking گفته می‌شود.

یکی از نکات کلیدی در این روش، نحوه ترکیب مدل‌های پایه است. در این راستا می‌توان از مدل‌های رگرسیونی خطی چندگانه و یا جنگل تصادفی (RF) به‌عنوان متا استفاده کرد. در این پژوهش، برای تشکیل مدل نهایی، ضرایبی به مدل‌های پایه اختصاص داده شده که پیش‌بینی نهایی مدل انباشته را شکل می‌دهند که رابطه ریاضی مدل متا آن به صورت معادله ۴ است:

$$y_{p,i} = \sum_{m=1}^{M} \omega_m f_{m,i} \quad (۴)$$

که در آن، $\omega_m \left(m = 1,2,...,M\right)$ وزن اختصاص‌داده‌شده به هر یک از مدل‌های پایه و $f_{m,i}$ پیش‌بینی مدل m برای مشاهدهٔ i ام است.

برای به‌دست‌آوردن پیش‌بینی نهایی بهینه، مجموعه ضرایب (وزن‌ها) از طریق کمینه‌سازی میانگین مربعات خطای رگرسیون خطی تعیین می‌شود. تابع هدف و قیود به‌صورت زیر تعریف می‌شوند:

$$\Omega = \text{argmin} \sum_{i=1}^{N} \left[y_{O,i} - \sum_{m=1}^{M} \omega_m f_{m,i} \right]^2 \quad (۵)$$

$$\omega_m \geq 0 \quad m = 1,2,...,M \quad (۶)$$

$$\sum_{m=1}^{M} \omega_m = 1 \quad m = 1,2,...,M \quad (۷)$$

که در آن، $\Omega = \{\omega_1, \omega_2, ..., \omega_M\}$ مجموعه‌ای از وزن‌های اختصاص داده‌شده به مدل‌های پایه است. با محاسبه وزن‌های مدل‌های پایه، مدل انباشته نهایی ساخته شده و پیش‌بینی نهایی حاصل می‌شود که در این پژوهش برای حل آن از بسته پایتون (qpsolvers) استفاده شده است.

بهینه‌سازی اَبَرپارامترها (Hyper-Parameter Optimization)

تنظیم اَبَرپارامترها (Hyper-parameter tuning) یکی از روش‌های رایج برای ساخت مدلی مناسب برای انجام یک پیش‌بینی خاص است. عملکرد مدل یادگیری ماشین با توجه به انتخاب مقادیر مختلف اَبَرپارامترها متفاوت خواهد بود. در مدل‌های یادگیری ماشین، چندین اَبَرپارامتر مهم می‌توانند به‌طور هم‌زمان عملکرد مدل را تحت تأثیر قرار دهند. در این مطالعه، از روش جستجوی شبکه‌ای (Grid Search) برای بهینه‌سازی ترکیب اَبَرپارامترها در محدوده مشخص استفاده شده است. سپس، مدل‌های آموزش‌دیده با اَبَرپارامترهای بهینه‌شده روی مجموعه تست اعمال شده‌اند.

فرایند تنظیم اَبَرپارامتر برای مدل‌های رگرسیون بردار پشتیبان (SVR)، تقویت گرادیان شدید (XGB) و پرسپترون

چندلایه (MLP) در شکل ۶ نمایش داده شده است. اَبَرپارامترها با استفاده از داده‌های آموزشی و به کمک روش اعتبارسنجی متقابل K-بخشی (K-fold cross-validation) تنظیم و ارزیابی شده‌اند. این روش با بهره‌گیری بهتر از اطلاعات موجود در داده‌های محدود، از بیش‌برازش جلوگیری می‌کند و منجر به ساخت مدلی می‌شود که عملکرد مناسبی روی داده‌های جدید دارد (۲۳).

در شکل ۶-الف و۶-ب دیده می‌شود که عملکرد مدل SVR با مقادیر مختلف اَبَرپارامترهای هزینه (C) و گاما (γ) تغییر می‌کند. این دو پارامتر در مدل SVR با تابع هسته‌ای پایه شعاعی (RBF) نقش کلیدی دارند. نتایج نشان می‌دهند که بازهٔ مناسب برای C بین حدود ۱۰ تا ۱۰۰ و برای γ بین $۱۰^{-۲}$ تا $۱۰^{-۱}$ بوده است. در ادامه، فرایند تنظیم اَبَرپارامترها برای مدل تقویت گرادیان شدید (XGBoost) روی پارامترهای کلیدی شامل تعداد درخت‌ها (n_estimators) و عمق بیشینه درخت (max_depth) انجام شده است که نتایج آن در شکل ۶-ج و ۶-د ارائه شده‌اند. همان‌گونه که در شکل ۶-ج دیده می‌شود، با افزایش تعداد درخت‌ها، مقدار ضریب تعیین R برای داده‌های آموزشی افزایش یافته؛ درحالی‌که عملکرد مدل روی داده‌های اعتبارسنجی پس از یک مقدار مشخص روندی تقریباً ثابت یا کاهشی از خود نشان می‌دهد. نتایج نشان می‌دهند که بازه‌ی مناسب برای پارامتر n_estimators در حدود ۲۵ تا ۱۰۰ قرار دارد که در این محدوده، تعادل مناسبی بین دقت مدل و جلوگیری از بیش‌برازش حاصل شده است.

در مورد مدل MLP نیز اندازه لایه پنهان یکی از اَبَرپارامترهای اصلی محسوب می‌شود؛ چراکه پیچیدگی مدل یادگیری را تعیین می‌کند. در شکل ۶-هـ عملکرد دو پیکربندی مختلف از شبکه عصبی با لایه پنهان (۸,۱۲) و (۱۰۰,۱۰۰) مقایسه شده است. نتایج نشان می‌دهند که شبکه با لایه پنهان (۸,۱۲) دارای همگرایی و عملکرد نزدیک با تعداد نرون‌های زیاد (۱۰۰) روی مجموعه اعتبارسنجی بوده است. این موضوع نشان می‌دهد که مدل MLP با لایه پنهان کوچک‌تر از توانایی یادگیری کافی برخوردار است و در مقابل، افزایش بیش‌ازحد اندازه لایه پنهان ممکن است منجر به بیش‌برازش شود. جدول ۳ خلاصه‌ای از نتایج نهایی اَبَرپارامترهای چهار مدل یادگیری ماشین به‌کاررفته در این مطالعه را ارائه می‌دهد.

شاخص‌های آماری ارزیابی عملکرد مدل‌ها

عملکرد مدل‌های یادگیری ماشین با استفاده از شاخص‌های آماری ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و میانگین قدرمطلق خطا (MAE) ارزیابی شد. ضریب تعیین (R^2) مطابق معادله ۸ بیانگر میزان واریانس توضیح‌داده‌شده توسط مدل است. RMSE مطابق معادله ۹ باقیمانده بین مقادیر مشاهده‌شده و پیش‌بینی‌شده را ارزیابی می‌کند و نسبت به خطاهای بزرگ حساس‌تر است. در مقابل، MAE مطابق معادله ۱۰ میانگین خطای مطلق را محاسبه کرده و نسبت به مقادیر پرت (extreme values) حساسیت کمتری دارد (۱۷).

$$R^2 = 1 - \frac{\sum_{i=1}^{N}\left(O_i - P_i\right)^2}{\sum_{i=1}^{N}\left(O_i - \bar{O}\right)^2} \quad (۸)$$

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(O_i - P_i\right)^2} \quad (۹)$$

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|Oi - Pi| \quad (۱۰)$$

در رابطه‌های بالا، O_i مقدار مشاهده‌شده (واقعی) عمق آبشستگی در مشاهده i، P_i مقدار پیش‌بینی‌شده عمق آبشستگی توسط مدل در مشاهده i، $\bar{O}$ میانگین مقادیر مشاهده‌شده عمق آبشستگی و N تعداد کل مشاهدات هستند. گفتنی است مقادیر R^2 نزدیک یک و مقادیر RMSE وMAE نزدیک به صفر، نشان‌دهندهٔ دقت بیشتر و عملکرد بهتر مدل هستند.

نتایج و بحث

نتایج آنالیز حساسیت SHAP

مطابق شکل ۷ نتایج تحلیل SHAP نشان داد که بیشترین تأثیر بر عمق نرمال‌شده آبشستگی (D_{se}/D_p) مربوط به فاصله عرضی

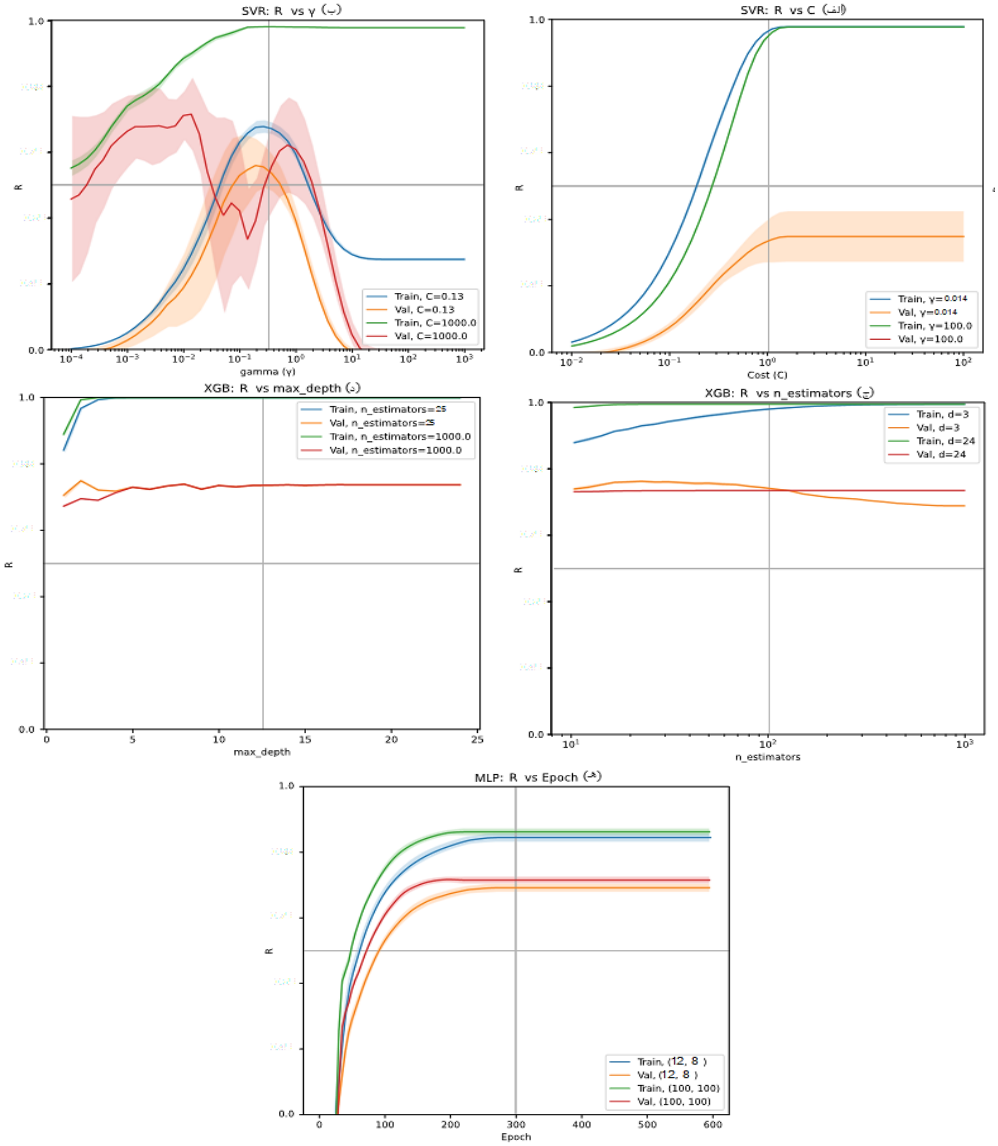

شکل۶. تغییرات شاخص آماری ضریب پیرسون R به منظور محاسبه اَبَرپارامترهای یادگیری ماشین، (الف) مدل SVR در دو مقدار ثابت هزینه (C) به ازای تغییرات گاما (γ)؛ (ب) مدل SVR در دو مقدار ثابت گاما (γ) به ازای تغییرات هزینه (C)؛ (ج) مدل XGBoost در دو مقدار ثابت پیش بینی کننده (n-estimator) به ازای تغییرات بیشینه عمق (max-depth)؛ (د) مدل XGBoost در دو مقدار ثابت بیشینه عمق (max-depth) به ازای پیش‌بینی‌کننده (n-estimator)؛ (هـ) مدل MLP در دو ساختار متفاوت لایه‌های پنهان برحسب تغییرات تعداد دوره‌های آموزشEpoch.

شمع‌ها (S_n/D_p) است، با دامنه تأثیر حدود (۰/۲۵)؛ به‌طوری‌که کاهش فاصله عرضی موجب افزایش ۲۰ تا ۵۰ درصدی عمق آبشستگی می‌شود. در رتبه دوم، عمق جریان نرمال‌شده (y/D_p) با محدوده (۰/۴-) تا (۰/۳+) قرار دارد و کاهش آن از ۵ به ۱ می‌تواند عمق آبشستگی را تا ۳۰ درصد افزایش دهد. نسبت سرعت جریان به سرعت بحرانی (U/U_c) با میانگین (۰/۲۰) نیز عامل کلیدی در تشدید فرسایش بوده و افزایش آن از ۰/۸ به ۱/۲ عمق آبشستگی را تقریباً دو برابر کرده است. پارامترهای عدد رینولدز (Re)، (m/n)، (S_m/D_p) و (Fr) تأثیر متوسطی داشته و نسبت (D_p/D_{50}) با میانگین (۰/۰۵) کمترین اهمیت را

جدول ۳. مقادیر نهایی آبَرپارامترهای سه مدل یادگیری ماشین

مدل یادگیری ماشین	آبَرپارامترها	مقدار بهینه
تقویت گرادیان شدید (XGB)	تعداد تخمین‌زننده‌ها	۲۵
	نرخ یادگیری	۰/۱
	بیشینه عمق	۳
رگرسیون بردار پشتیبان (SVR)	هزینه (C)	۰/۱۳
	گاما (γ)	۰/۰۱۴
پرسپترون چندلایه (MLP)	اندازه‌ی لایه‌ی پنهان	(۸,۱۲)
	تابع فعال‌سازی	Tanh
	نرخ یادگیری	۰/۰۱

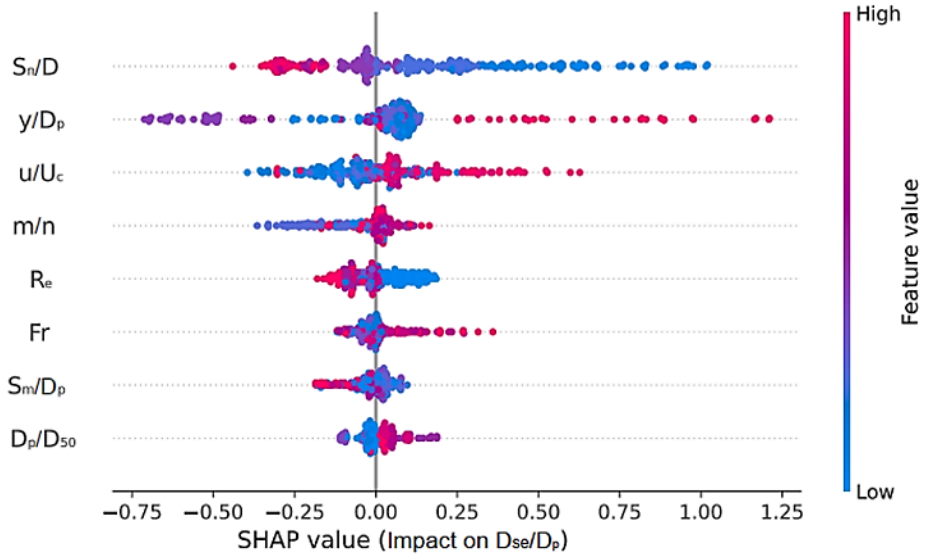

شکل ۷. میزان نتایج آنالیز SHAP

نشان داد که بر غلبه عوامل هیدرولیکی نسبت به رسوبی تأکید دارد.

پیاده‌سازی و ارزیابی مدل‌های هوش مصنوعی

- پیاده‌سازی و ارزیابی مدل MLP

عملکرد مدل MLP در پیش‌بینی عمق نسبی آبشستگی (D_{se}/D_p) با استفاده از نمودارهای پراکندگی، توزیع جهت‌دار و تحلیل خطا که در شکل ۸ نشان داده شده است. همان‌گونه که در شکل ۸-الف دیده می‌شود، مدل MLP در مرحله آموزش با ضریب تعیین (R^2 =۰/۹۳۷) همبستگی خطی قوی بین مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده (D_{se}/D_p) نشان داد. مقدار خطای میانگین مربعات (RMSE =۰/۱۵) بوده است.

در شکل ۸-ب، مقایسه توزیع مقادیر اندازه‌گیری‌شده و پیش‌بینی‌شده (D_{se}/D_p) در مرحله آزمایش نشان می‌دهد که مدل MLPتوانایی زیادی با تعمیم تغییرات در آرایش شمع‌ها دارد. ضریب تعیین در مرحله آزمایش (R^2 =۰/۸۷) به‌دست آمد که بیانگر دقت و تطابق مناسب پیش‌بینی‌ها با داده‌های واقعی است.

در شکل‌های ۸-ج و ۸-د، تحلیل خطا نشان می‌دهد مدل

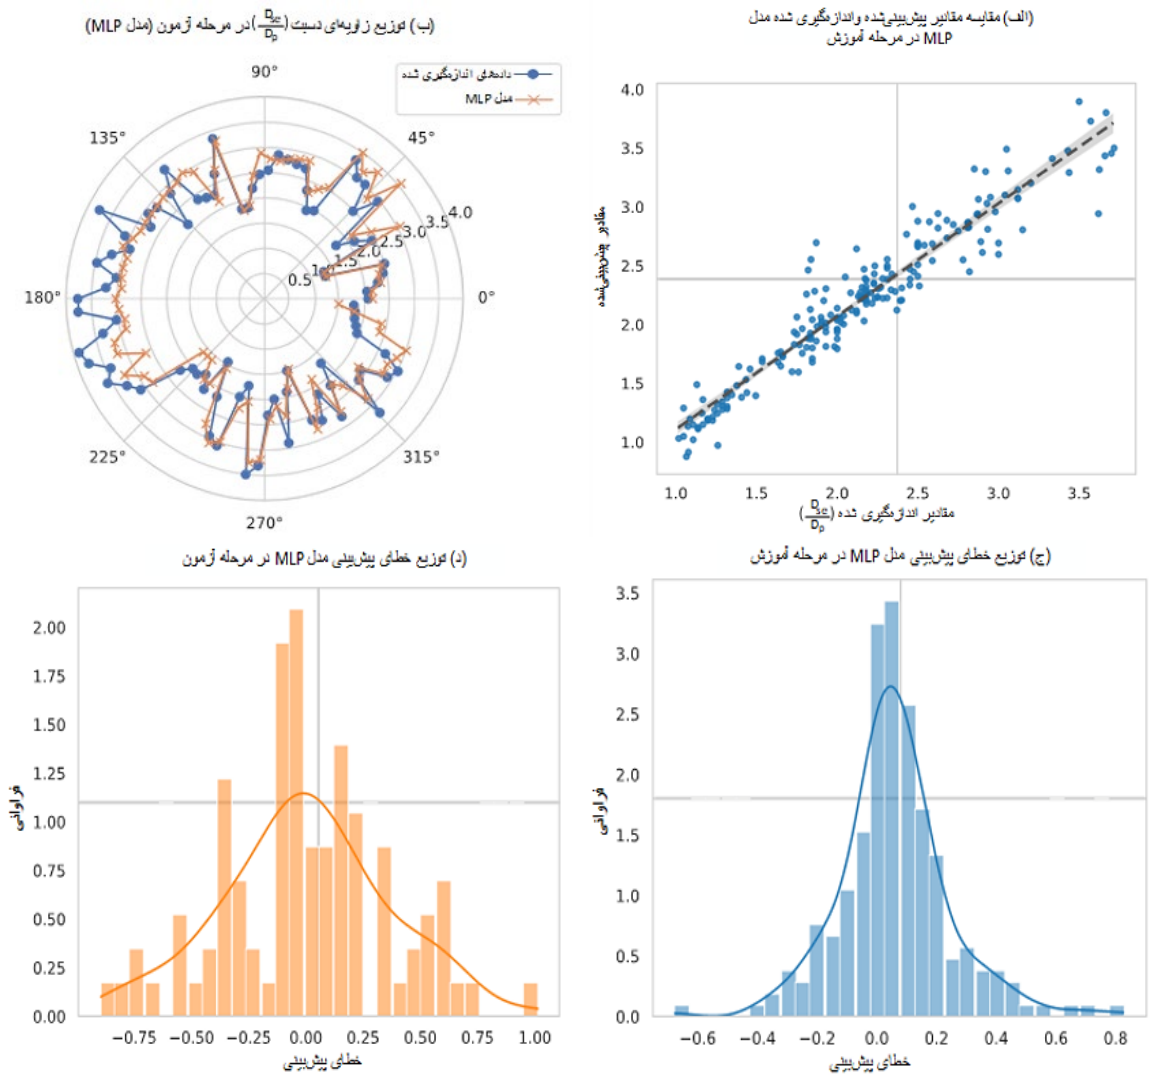

شکل۸. مقایسه مقادیر پیش‌بینی‌شده و واقعی در مراحل آموزش و آزمون با استفاده از مدل MLP: (الف) مقایسه مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده در مرحله آموزش، (ب) نمودار توزیع مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده در مرحله آزمون، (ج) توزیع خطای پیش‌بینی در مرحله آموزش و (د) توزیع خطای پیش بینی در مرحله آزمون

MLP در مرحله آموزش و آزمایش خطاهای کوچک و توزیع نزدیک به نرمال نشان می‌دهد. تمرکز خطاها حول صفر در مرحله آزمایش، نشان می‌دهد مدل با دقت، پایداری و تعمیم‌پذیری مناسب پیش‌بینی کرده است. با این وجود در مرحله آزمایش با میانگین خطاها ۰/۰۴۲-، مدل MLP در مقادیر زیاد آبشستگی نسبی مقادیر کمتری را پیش‌بینی کرده است.

- پیاده‌سازی و ارزیابی مدل XGBoost

در شکل ۹ عملکرد مدل XGBoost در پیش‌بینی عمق نسبی آبشستگی (D_{se}/D_p) با استفاده از نمودارهای پراکندگی، توزیع جهت‌دار و تحلیل خطا ارزیابی شده است. همان‌گونه که در شکل ۹-الف نمودار پراکندگی مرحله آموزش مدل XGBoost همبستگی بسیار قوی بین مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده عمق نسبی آبشستگی (R^2 =۰/۹۷۱) را نشان می‌دهد. مقدار RMSE برابر ۰/۱۲ به‌دست آمد.

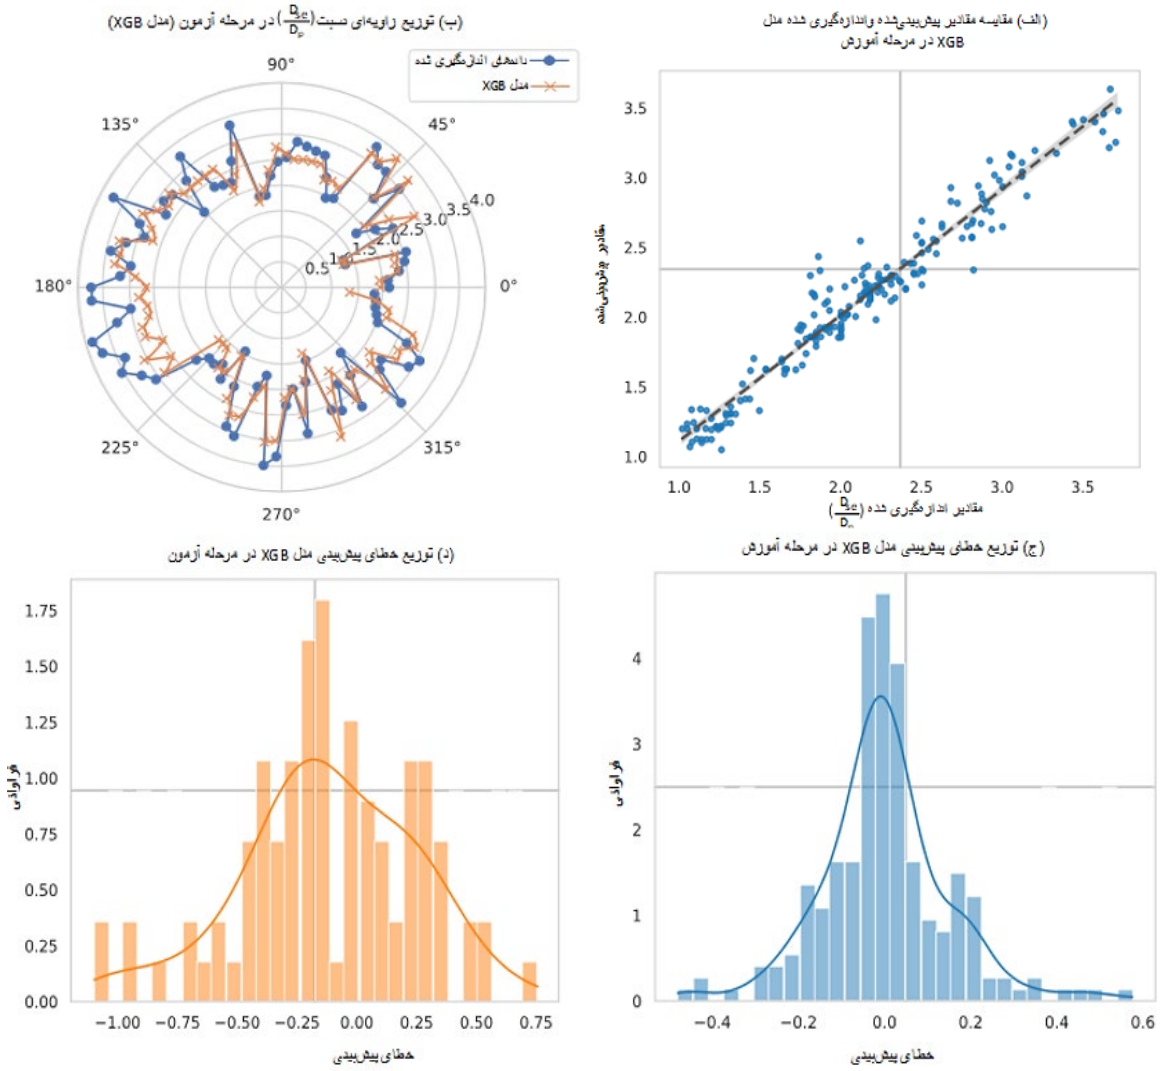

شکل ۹. مقایسه مقادیر پیش‌بینی‌شده و واقعی در مراحل آموزش و آزمون با استفاده از مدل XGBoost: (الف) مقایسه مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده در مرحله آموزش، (ب) نمودار توزیع مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده در مرحله آزمون، (ج) توزیع خطای پیش‌بینی در مرحله آموزش و (د) توزیع خطای پیش بینی در مرحله آزمون

در مرحله داده‌های آزمایش در شکل ۹-ب، نمودار قطبی توزیع داده‌ها برای مقادیر اندازه‌گیری‌شده (آبی) و پیش‌بینی‌شده (نارنجی) (D_{se}/D_p) توانایی مدل در تعمیم به داده‌های تست را برجسته می‌کند. به طور کلی، R^2 این مرحله ۰/۹۴ است. تحلیل خطا برای بخش آموزش در شکل ۹-ج، خطاها به طور نرمال و با میانگین نزدیک به صفر توزیع شده‌اند. در مقابل، توزیع خطای در بخش آزمایش شکل ۹-د شامل پراکندگی بیشتری در توزیع خطا با میانگین ۰/۰۲- نشان‌دهنده پیش‌بینی کمتر از حد در سناریوهای آبشستگی با مقادیر زیاد است.

- پیاده‌سازی و ارزیابی مدل SVR

عملکرد مدل SVR در شکل ۱۰، با استفاده از کرنل RBF و حاشیه خطای بهینه (epsilon) می‌تواند الگوهای غیرخطی در برآورد آبشستگی نسبی را بازسازی کند. نتایج شکل ۱۰-الف نشان می‌دهد مدل SVR در مرحله آموزش با ضریب تعیین

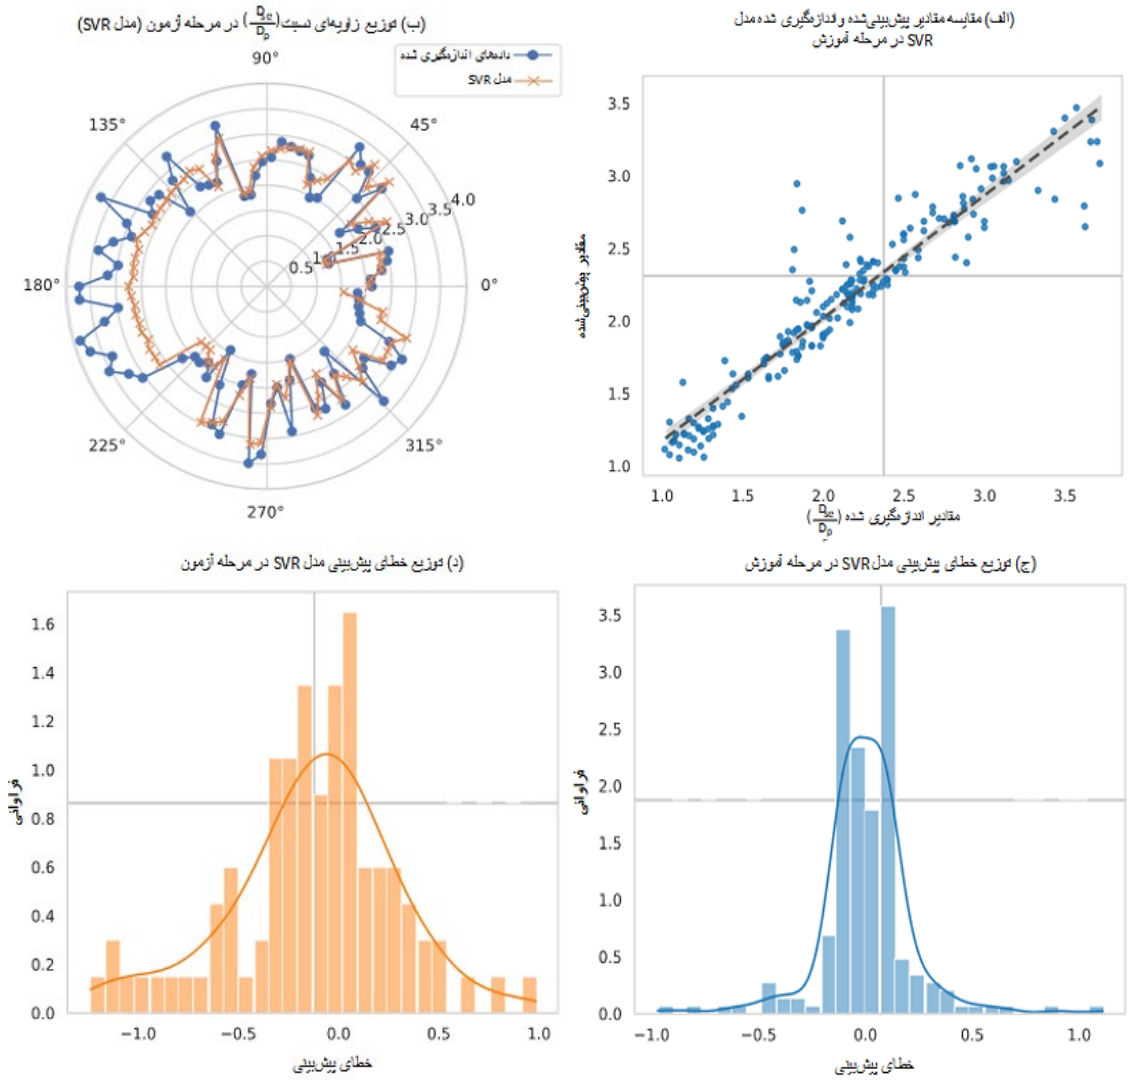

شکل ۱۰. مقایسه مقادیر پیش‌بینی‌شده و واقعی در مراحل آموزش و آزمون با استفاده از مدل SVR: (الف) مقایسه مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده در مرحله آموزش، (ب) نمودار توزیع مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده در مرحله آزمون، (ج) توزیع خطای پیش‌بینی در مرحله آموزش و (د) توزیع خطای پیش‌بینی در مرحله آزمون

(R^2=۰/۹۵) و خطای (RMSE =۰/۱۳) عملکرد مناسبی نسبت به مدل MLP داشته است. در مرحله آزمایش در شکل ۱۰-ب، نیز ضریب تعیین (R^2 =۰/۹۱) نشان‌دهنده تعمیم‌پذیری مناسب مدل است. در تحلیل خطاهای مدل SVR در شکل ۱۰-ج و ۱۰-د، خطاهای آموزش با میانگین منفی ۰/۰۲- و در مرحله آزمایش، با پراکندگی بیشتر با میانگین ۰/۰۴ به دست می‌آید.

- پیاده‌سازی و ارزیابی مدل Stacking

در این بخش، عملکرد مدل یادگیری ماشین ترکیبی (Stacking Ensemble-based) برای پیش‌بینی عمق نسبی آبشستگی (D_{se}/D_p) در اطراف گروه‌های شمع با فاصله غیریکنواخت، بررسی شد. این روش با ترکیب سه مدل پایه بیان شده MLP، XGBoost و SVR استفاده شد و سپس با استفاده از رگرسیون خطی به عنوان مدل متا توسعه یافته شد تا از نقاط قوت هر مدل بهره گیرد.

نمودار پراکندگی بخش آموزش مدل ترکیب انباشتی شکل ۱۱-الف نشان‌دهنده همبستگی بسیار قوی بین مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده است. ضریب تعیین مدل (R^2 =۰/۹۸) و خطای میانگین مربعات (RMSE =۰/۱۰) به‌دست آمده است. در بخش آزمایش در شکل ۱۱-ب، نمودار توزیع مقادیر اندازه‌گیری‌شده (آبی) و پیش‌بینی‌شده (نارنجی) (D_{se}/D_p) توانایی مدل در تعمیم به داده‌های نادیده را برجسته می‌کند. ضریب تعیین (R^2) برای بخش آزمایش ۰/۹۶ تخمین زده شده است. تحلیل خطا در شکل ۱۱-ج و ۱۱-د از طریق تخمین چگالی آن، خطاهای پیش‌بینی قرار گرفته، قابلیت اطمینان مدل را بیشتر روشن می‌کند. برای بخش آموزش و آزمایش خطاها به طور نرمال حول صفر توزیع شده‌اند. به طور کلی، نتایج این بخش برتری مدل متا نسبت به روش‌های تک‌مدلی پیشین را برجسته می‌کند.

ارزیابی عملکرد مدل‌های توسعه داده شده

نمودار ارائه‌شده در شکل ۱۲، عملکرد مدل‌های مختلف شامل XGBoost، SVR، MLP و Stacking را در مرحله آزمایش با استفاده از منحنی نسبت خطای تجمعی Relative Error Cumulative Curve یا REC ارزیابی می‌کند. این نمودار، کسر خطاهای پیش‌بینی‌شده (Fraction of error) را برحسب آستانه خطا (Error threshold ε) نمایش می‌دهد و معیاری جامع برای مقایسه دقت و توزیع خطاها در پیش‌بینی عمق نسبی آبشستگی (D_{se}/D_p) فراهم می‌سازد. همان‌گونه که دیده می‌شود، مدل Stacking (بنفش) بهترین عملکرد را در این نمودار نشان می‌دهد. افزایش تدریجی مقدار خطا در منحنی مدل‌های پایه پس از ۰/۲ = ε بیانگر تمرکز خطاهای باقی‌مانده در بازه‌های بیشتر، تا حدود ۰/۷۵، است.

عملکرد مدل XGBoost پس از Stacking قرار دارد؛ با این حال، شیب ملایم‌تر منحنی آن نسبت به Stacking نشان‌دهنده پراکندگی بیشتر خطاهاست. به‌طور کلی، نمودار REC تأیید می‌کند مدل Stacking با ترکیب نقاط قوت مدل‌های پایه (MLP، XGBoost، SVR)، بهترین عملکرد را در مرحله آزمایش داشته و کمترین خطای تجمعی را در آستانه‌های خطای کم نشان می‌دهد. این نتایج با معیارهای R^2 و RMSE به‌دست‌آمده در تحلیل‌های پیشین هم‌خوانی دارد و مدل Stacking را به‌عنوان مدل برتر برای پیش‌بینی دقیق و پایدار عمق آبشستگی در این مطالعه برجسته می‌سازد.

مقایسه با روابط تجربی

در این بخش از مقاله، روابط تجربی مندرج در جدول ۱ با سناریوی برتر مدل متا به‌منظور برآورد عمق آبشستگی پیرامون گروه شمع مقایسه شده‌اند. عملکرد پیش‌بینیِ مدل‌های توسعه‌یافته و روابط موجود با استفاده از شاخص R^2، RMSE ارزیابی شده و نتایج آنها در شکل ۱۳ آمده است. همان‌گونه که نتایج نشان می‌دهد که تمامی مدل‌های تجربی در تخمین عمق آبشستگی پیرامون گروه شمع دقت کمتری نسبت به مدل متا دارند؛ به نحوی که به ترتیب شاخص عملکرد روابط قائمی و همکاران (۱۸) با (RMSE =۰/۰۴۲ و R^2=۰/۶۰۴)، هوارد و اعتمادشهیدی (۲۱) با (RMSE =۰/۰۳۷ و R^2=۰/۵۶۶)، امینی و همکاران (۵) با (RMSE =۰/۰۳۵ و R^2=۰/۵۶۱) و بهشتی و همکاران (۱۲) با (RMSE =۰/۰۳۱ و R^2=۰/۵۳۶) به دست آمده است. با این حال، گفتنی است که این مقایسه به‌معنای ناکارآمدی مطالعات پیشین نیست؛ زیرا هر یک از روابط قبلی برای شرایط خاصی ارائه شده‌اند که شامل آرایش‌ها و فواصل متفاوت شمع‌ها و نیز پیکربندی‌های گوناگون است.

نتیجه‌گیری

در این پژوهش به‌منظور پیش‌بینی عمق نسبی آبشستگی پیرامون گروه‌های شمع با آرایش غیریکنواخت، چهار مدل MLP، XGBoost، SVR و مدل ترکیبی Stacking توسعه و مقایسه شدند. پیش از ساخت مدل‌ها، تحلیل حساسیت با روش SHAP نشان داد که پارامترهای هندسی و هیدرولیکی بیشترین سهم را در تغییرات آبشستگی دارند؛ به‌گونه‌ای که فاصله جانبی شمع‌ها (S_n/D_p) و عمق جریان نرمال‌شده (y/D_p) به ترتیب دارای

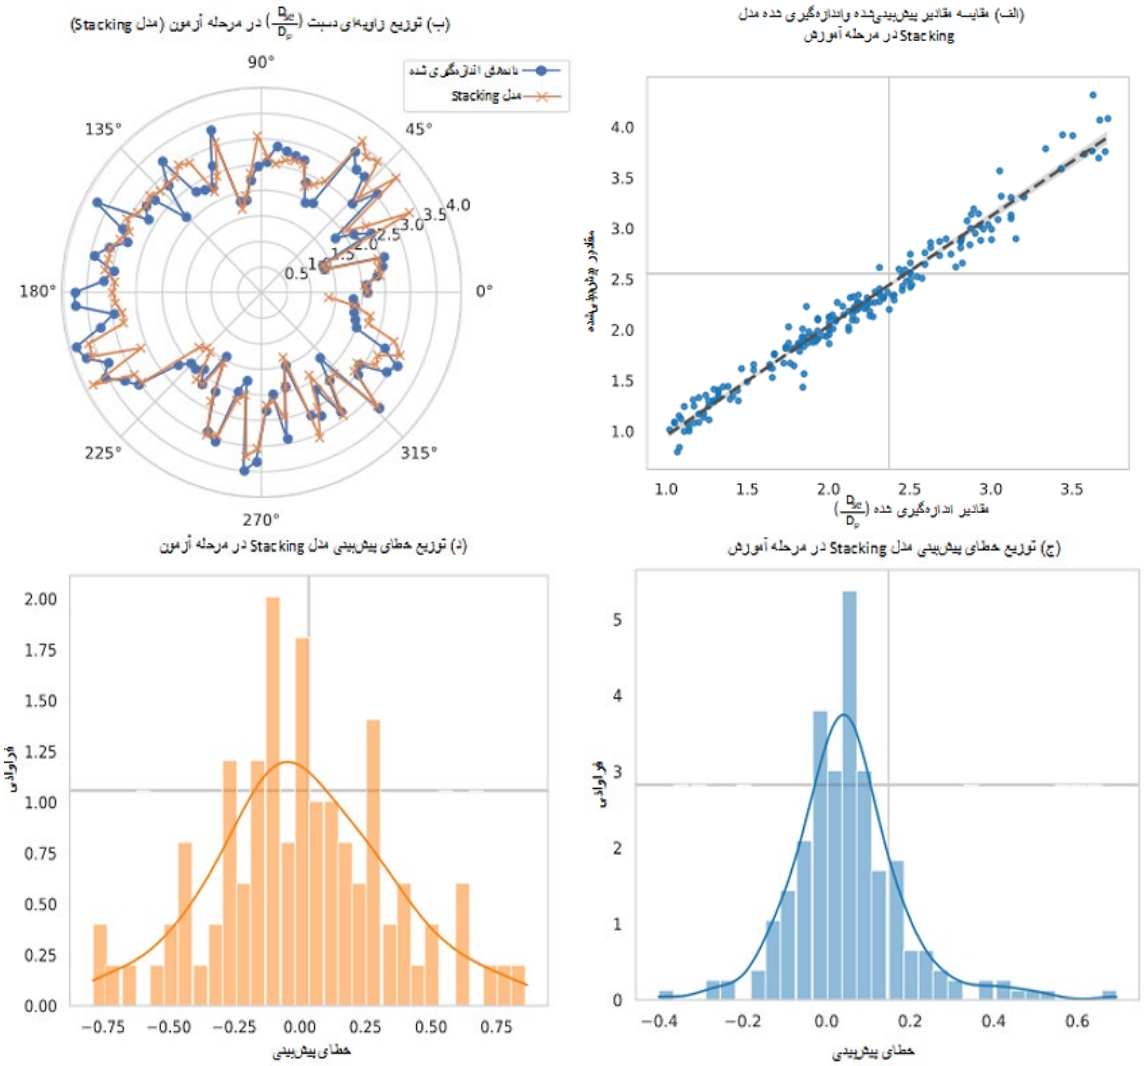

شکل ۱۱. مقایسه مقادیر پیش‌بینی‌شده و واقعی در مراحل آموزش و آزمون با استفاده از مدل Stacking: (الف) مقایسه مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده در مرحله آموزش، (ب) نمودار توزیع مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده در مرحله آزمون، (ج) توزیع خطای پیش‌بینی در مرحله آموزش، (د) توزیع خطای پیش‌بینی در مرحله آزمون

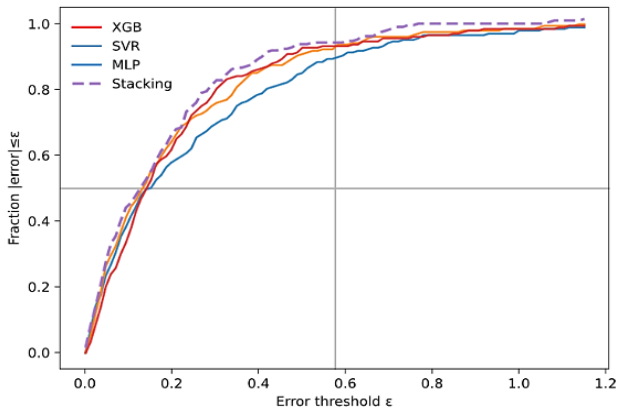

شکل ۱۲. منحنی نسبت خطای تجمعی (Relative Error Cumulative Curve یا REC)

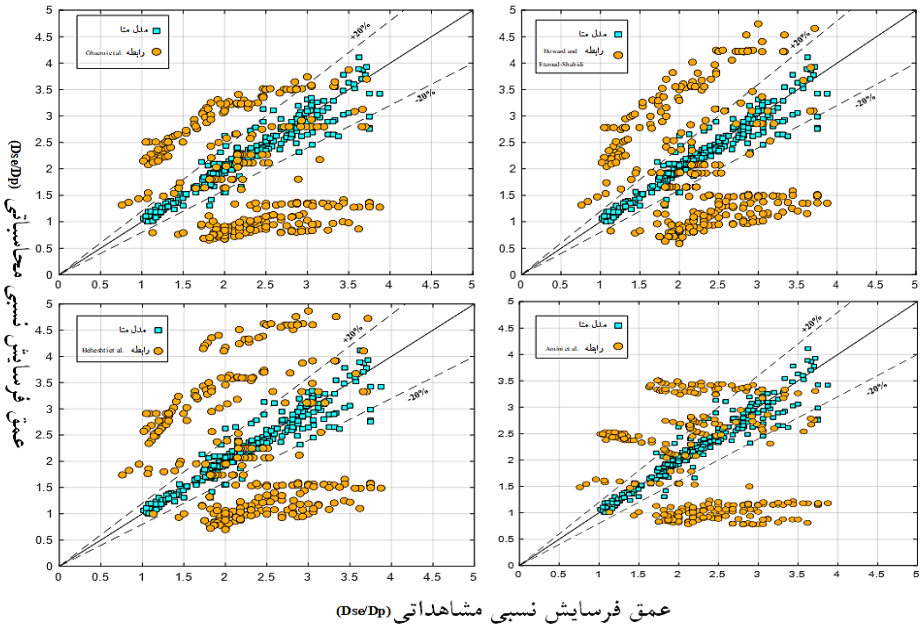

شکل ۱۳. ارزیابی عملکرد مدل متا در برابر چهار رابطه‌ی آزمایشگاهی برتر موجود— شامل قائمی و همکاران (۲۰)، هوارد و اعتمادشهیدی (۲۴)، بهشتی و همکاران (۱۳) و امینی و همکاران (۵) — برای پیش‌بینی عمق آبشستگی

بیشترین میانگین اثر مطلق SHAP بوده و مؤثرترین متغیرهای مدل شناسایی شدند.

در ادامه، مدل‌ها پس از تنظیم اَبَرپارامترها ارزیابی شدند. مدل MLP در مرحله آزمایش توانست دقت قابل قبولی ارائه دهد و مقدار R^2 =۰/۸۷ را به دست آورد.

مدل SVR با R^2 =۰/۹۱ عملکرد بهتری داشت، اما پراکندگی خطای آن در داده‌های آزمون نسبتاً بیشتر بود. مدل XGBoost با دستیابی به R^2 = ۰/۹۴ و کاهش RMSE ، نسبت به مدل‌های تکی عملکرد پایدارتر و دقیق‌تری ارائه داد.

به‌منظور بهبود بیشتر، مدل Stacking با ترکیب این سه مدل پایه ساخته شد. این مدل با افزایش حدود ۱۵ درصدی دقت نسبت به MLP و حدود ۷ درصد نسبت به XGBoost توانست بیشترین عملکرد را ثبت کند و مقدار R^2 =۰/۹۶ و RMSE =۰/۱۱ را ارائه دهد. همچنین نمودار REC نشان داد که بیش از ۸۵ درصد پیش‌بینی‌های مدل Stacking در محدوده خطای کمتر از ۱۰ درصد قرار می‌گیرند. نتایج نهایی بیانگر آن است که روش‌های ترکیبی، به‌ویژه مدل Stacking، با دقت زیادتر و پایداری بیشتر، می‌توانند به‌عنوان ابزاری مؤثر برای تحلیل و مدیریت ریسک آبشستگی در طراحی و بهره‌برداری از سازه‌های هیدرولیکی مورد استفاده قرار گیرند.

سپاسگزاری

این پروژه پژوهشی با استفاده از گرنت‌های ویژه پژوهشی نویسنده دوم از دانشگاه شهید چمران اهواز، تحت شماره گرنت SCU.WH1404.43525 انجام شده است

منابع مورد استفاده

References

1. Agatonovic-Kustrin, S and R. Beresford. 2000. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis* 22 (5): 717–727.
2. Ahmadianfar, Iman., M. Jamei and X. Chu. 2021. Prediction of local scour around circular piles under waves using a novel artificial intelligence approach. *Marine Georesources and Geotechnology* 39 (1): 44–55.

3. Ahmadianfar, Iman., M. Jamei, M. Karbasi and et al. 2022. A novel boosting ensemble committee-based model for local scour depth around non-uniformly spaced pile groups. *Engineering with Computers* 38 (4): 3439–3461.
4. Ahmed, K., S. Shahid, S.B. Haroon and et al. 2015. Multilayer perceptron neural network for downscaling rainfall in arid region: A case study of Baluchistan, Pakistan. *Journal of Earth System Science* 124 (6): 1325–1341.
5. Amini, A., B.W. Melville, T.M. Ali and et al., 2012. Clear-Water Local Scour around Pile Groups in Shallow-Water Flow. *Journal of Hydraulic Engineering* 138 (2): 177–185.
6. Amini, A. and N. Solaimani. 2018. The effects of uniform and nonuniform pile spacing variations on local scour at pile groups. *Marine Georesources and Geotechnology* 36 (7): 861–866.
7. Amini Baghbadorani, D., A.A. Beheshti and B. Ataie-Ashtiani. 2017. Scour hole depth prediction around pile groups: review, comparison of existing methods, and proposition of a new approach. *Natural Hazards* 88 (2): 977–1001.
8. Arneson, L. A., L.W. Zevenbergen, P.F. Lagasse and et al., 2012. Evaluating Scour at Bridges: Fifth Edition. Federal Highway Administration (FHWA), Washington.
9. Ataie-Ashtiani, B. and A.A. Beheshti. 2006. Experimental Investigation of Clear-Water Local Scour at Pile Groups. *Journal of Hydraulic Engineering* 132 (10): 1100–1104.
10. Barbhuiya, A.K. and S. Dey. 2004. Local scour at abutments: A review. *Sadhana* 29 (5): 449–476.
11. Bateni, S. M., H. R. Vosoughifar, B. Truce and et al., 2019. Estimation of Clear-Water Local Scour at Pile Groups Using Genetic Expression Programming and Multivariate Adaptive Regression Splines. *Journal of Waterway, Port, Coastal, and Ocean Engineering* 145 (1): 04018029.
12. Beheshti, A. A., B. Ataie-Ashtiani and M. J. Khanjani. 2013. Discussion of "Clear-Water Local Scour around Pile Groups in Shallow-Water Flow" by Ata Amini, Bruce W. Melville, Thamer M. Ali, and Abdul H. Ghazali. *Journal of Hydraulic Engineering* 139 (6): 679–680.
13. Bolboaca, S-D. and L. Jäntschi. 2006. Pearson versus Spearman, Kendall's tau correlation analysis on structure-activity relationships of biologic active compounds. *Leonardo Journal of Sciences* 5 (9): 179–200.
14. Chen, T. and C. Guestrin. 2016. XGBoost: A Scalable Tree Boosting System. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2016), ACM SIGKDD, San Francisco, CA, USA.
15. Dang, N. M., A. Tran, D. Duong and D. Thanh. 2021. ANN optimized by PSO and Firefly algorithms for predicting scour depths around bridge piers. *Engineering with Computers* 37 (1): 293–303.
16. Ebtehaj, I., H. Bonakdari, F. Moradi and et al., 2018. An integrated framework of Extreme Learning Machines for predicting scour at pile groups in clear water condition. *Coastal Engineering* 135: 1–15.
17. Fox, D. G. 1981. Judging air quality model performance: A summary of the AMS workshop on dispersion model performance, woods hole, Mass., 8–11 September 1980. *Bulletin of the American Meteorological Society* 62 (5): 599–609.
18. Ghaemi, N., A. Etemad-Shahidi and B. Ataie-Ashtiani. 2012. Estimation of current-induced pile groups scour using a rule-based method. *Journal of Hydroinformatics* 15 (2): 516–528.
19. Hofmann, T., B. Schölkopf, A.J. Smola. 2008. Kernel methods in machine learning. *The Annals of Statistics* 36 (3): 1171–1220.
20. Hosseini, R., R. Fazloula, M. Saneie and et al., 2018. Bagged neural network for estimating the scour depth around pile groups. *International Journal of River Basin Management* 16 (4): 401–412.
21. Howard, S. and A. Etemad-Shahidi. 2014. Predicting scour depth around non-uniformly spaced pile groups. *In*: Proceedings of the 5th IAHR International Symposium on Hydraulic Structures, (ISHS 2014), The University of Queensland, Brisbane, Australia.
22. Jalali, S., K. Nosrati and Z. Fathi. 2023. Investigating the Relationship between Suspended Sediment Concentration and Watershed Characteristic of the Kan River in Tehran Using Principal Component Regression. *Journal of Water and Soil Science* 27 (2): 195–208.
23. Lever, J., M. Krzywinski and N. Altman. 2016. Points of Significance: Model selection and overfitting. *Nature Methods* 13 (9): 703–705.
24. Mohammadpour, R. 2017. Prediction of local scour around complex piers using GEP and M5-Tree. *Arabian Journal of Geosciences* 10 (18): 416.
25. Riahi-Madvar, Hossien, Gholami, Mahsa, Gharabaghi, Bahram, et al., 2021. A predictive equation for residual strength using a hybrid of subset selection of maximum dissimilarity method with Pareto optimal multi-gene genetic programming. *Geoscience Frontiers* 12 (5): 101222.
26. Samadi, M., M.H. Afshar, E. Jabbari and et al., 2021. Prediction of current-induced scour depth around pile groups using MARS, CART, and ANN approaches. *Marine Georesources & Geotechnology* 39 (5): 577–588.
27. Shahinejad, B., A. Parsaei, A. Haghizadeh and et al., 2022. Modeling and Estimating the Dimensions of Stable Alluvial Channels using Soft Calculations. *Journal of Water and Soil Science* 26 (3): 91–107.

28. Sharafati, A., S.B.H.S. Asadollah and M. Hosseinzadeh. 2020. The potential of new ensemble machine learning models for effluent quality parameters prediction and related uncertainty. *Process Safety and Environmental Protection* 140: 68–78.
29. Sharafati, A., M. Haghbin, D. Motta and et al., 2021. The Application of Soft Computing Models and Empirical Formulations for Hydraulic Structure Scouring Depth Simulation: A Comprehensive Review, Assessment and Possible Future Research Direction. *Archives of Computational Methods in Engineering* 28 (2): 423–447.
30. Sharafati, A., A.Tafarojnoruz, Z.M. Yaseen. 2020. New stochastic modeling strategy on the prediction enhancement of pier scour depth in cohesive bed materials. *Journal of Hydroinformatics* 22 (3): 457–472
31. Sheppard, D, Renna, R, 2005. Bridge scour manual.
32. Tian, Di., X. He, P. Srivastava and et al., 2022. A hybrid framework for forecasting monthly reservoir inflow based on machine learning techniques with dynamic climate forecasts, satellite-based data, and climate phenomenon information. *Stochastic Environmental Research and Risk Assessment* 36 (8): 2353–2375.
33. Vapnik, V. 1995. Support-vector networks. *Machine Learning* 20: 273–297.
34. Wolpert, D. H. 1992. Stacked generalization. *Neural Networks* 5 (2): 241–259.
35. Yang, Y., M. Qi, X. Wang and et al., 2020. Experimental study of scour around pile groups in steady flows. *Ocean Engineering* 195: 106651.