

**Web site:**

<https://wsrcj.srbiau.ac.ir>

Email:

iauwsrcj@srbiau.ac.ir
iauwsrcj@gmail.com

Vol. 15
No. 2 (58)

Received:
2025-07-27

Accepted:
2025-09-21

Pages: 1-12

Comparison of Channel Geometry Effects on Discharge Coefficient of Rectangular Side Weirs in Rectangular and Trapezoidal Channels Using Optimized Machine Learning Models

Kiyoumars Roushangar^{1*} and Aydin Panahi²

1) Professor, Department of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran.

2) Ph.D. student, Department of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran.

*Corresponding author emails: roshangari@tabrizu.ac.ir

Abstract:

Introduction: Side weirs play a key role in flow measurement and control in hydraulic systems, especially in flood mitigation and runoff management projects. Accurate estimation of the discharge coefficient (C_d) has become a critical technical challenge due to the complex interactions between flow dynamics and channel geometry. This study introduces, for the first time, two novel hybrid models—SVM-HOA and SVM-RSA—based on SVM optimized by the Horse Optimization Algorithm and Reptile Search Algorithm, respectively. These models are applied to predict the geometry-specific discharge coefficient of sharp-crested rectangular side weirs in both rectangular and trapezoidal channel configurations.

Method: The proposed methodology involves two experimental scenarios. Scenario 1 includes 407 laboratory observations of sharp-crested rectangular side weirs located in rectangular channels, whereas Scenario 2 consists of 78 observations in trapezoidal channels. Dimensional analysis was first conducted to identify the most influential nondimensional parameters, including Fr_1 , P/y_1 , L/B , L/y_1 , y_1/B , and m . These parameters served as inputs for training the SVM models. Each hybrid model was implemented by optimizing the SVM hyperparameters using the HOA and RSA metaheuristic algorithms, aiming to avoid local minima and enhance prediction accuracy. The dataset was split into training and testing subsets in a ratio: 80:20. To mitigate overfitting, 10-fold cross-validation was applied. Model performance was evaluated using standard statistical metrics: Root Mean Square Error (RMSE), Nash–Sutcliffe Efficiency (NSE), and correlation coefficient (R). Additionally, sensitivity analysis was conducted to assess the influence of each input variable on the final prediction.

Results: Results of the comparative evaluation showed that both SVM-HOA and SVM-RSA yielded high accuracy in predicting C_d for both channel configurations. In Scenario 1 (rectangular channel), With inputs such as the ratio of the spillway height to the initial flow depth (P/y_1), the ratio of the spillway crest length to the channel bottom width (L/B), the ratio of the crest length to the flow depth (L/y_1), and the upstream Froude number, the best-performing model was SVM-HOA with $R = 0.953$, $RMSE = 0.063$, and $NSE = 0.904$ during the testing phase. In Scenario 2 (trapezoidal channel), the optimal model also used SVM-HOA With inputs L/B , Fr_1 , y_1/B and channel wall slope (m) and achieved $R = 0.986$, $RMSE = 0.020$, and $NSE = 0.964$. Taylor diagrams confirmed the robustness and higher predictive power of the SVM-HOA model compared to SVM-RSA. Sensitivity analysis revealed that in the rectangular channel setup, the P/y_1 ratio was the most influential input, while in the trapezoidal channel, the upstream Froude number (Fr_1) played the dominant role in determining C_d . The findings underscore the importance of accounting for geometry-specific variables and selecting appropriate optimization algorithms to fine-tune ML models for hydraulic applications.

Conclusions: This study presents a novel and geometry-aware approach to accurately predicting the discharge coefficient of sharp-crested rectangular side weirs using two advanced hybrid SVM-based models. The proposed SVM-HOA and SVM-RSA frameworks demonstrated consistently high accuracy, excellent adaptability to different channel geometries, and strong robustness against overfitting and local minima. Results indicate that SVM-HOA significantly outperforms SVM-RSA in most cases, particularly when paired with well-chosen nondimensional parameters and a properly tuned training-testing data split. The models developed in this work can effectively assist hydraulic engineers in the design, simulation, and performance analysis of side weirs under diverse flow conditions and channel types.

Keywords: Discharge coefficient, Machine learning, Meta-heuristic algorithms, Sensitivity analysis, Side weir



مقایسه تأثیر هندسه کانال‌های مستطیلی و دوزنقه‌ای بر ضریب دبی سرریزهای جانبی مستطیلی با استفاده از مدل‌های یادگیری ماشین بهینه‌شده

کیومرث روشنگر^{۱*} و آیدین پناهی^۲

(۱) استاد، گروه مهندسی منابع آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران.

(۲) دانشجو دکتری، گروه مهندسی منابع آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران.

* ایمیل نویسنده مسئول: roshangari@tabrizu.ac.ir

چکیده:

زمینه و هدف: سرریزهای جانبی نقشی کلیدی در اندازه‌گیری و کنترل جریان در سامانه‌های هیدرولیکی ایفا می‌کنند، به‌ویژه در پروژه‌های کاهش خسارات سیلاب و مدیریت رواناب. برآورد دقیق ضریب دبی (C_d) این سازه‌ها، به دلیل تعامل پیچیده بین دینامیک جریان و هندسه کانال، به یک چالش فنی مهم تبدیل شده است. در این پژوهش، برای نخستین بار، دو مدل ترکیبی نوین تحت عنوان SVM-HOA و SVM-RSA معرفی شده‌اند که در آن‌ها، ماشین بردار پشتیبان (SVM) به ترتیب با الگوریتم‌های بهینه‌سازی اسب (HOA) و جست‌وجوی خزنده (RSA) تنظیم شده است. این مدل‌ها به منظور پیش‌بینی ضریب دبی متناسب با هندسه برای سرریزهای جانبی مستطیلی لبه‌تیز در دو نوع کانال مستطیلی و دوزنقه‌ای به کار گرفته شده‌اند.

روش پژوهش: این مطالعه، دو سناریوی آزمایشگاهی بررسی شده است. سناریوی نخست شامل ۴۰۷ داده آزمایشگاهی از سرریزهای جانبی مستطیلی لبه‌تیز در کانال‌های مستطیلی و سناریوی دوم شامل ۷۸ داده آزمایشگاهی در کانال‌های دوزنقه‌ای است. در ابتدا، مهم‌ترین پارامترهای بی‌بعد مؤثر از جمله Fr_1 ، P/y_1 ، L/B ، L/y_1 ، m و y_1/B شناسایی شدند. این پارامترها به عنوان ورودی مدل‌های SVM استفاده شدند. هر مدل ترکیبی با بهینه‌سازی ابر پارامترهای SVM به وسیله الگوریتم‌های HOA و RSA پیاده‌سازی شد تا از افتادن در کمینه‌های موضعی جلوگیری شود و دقت پیش‌بینی افزایش یابد. داده‌ها به نسبت ۸۰ به ۲۰ برای آموزش و آزمون تقسیم شدند و برای جلوگیری از بیش‌برازش، از اعتبارسنجی متقابل ۱۰ بخشی استفاده شد. عملکرد مدل‌ها با شاخص‌های آماری استاندارد از جمله خطای ریشه میانگین مربعات (RMSE)، کارایی نش-سانتکیف (NSE) و ضریب همبستگی (R) ارزیابی گردید. همچنین، تحلیل حساسیت برای بررسی میزان تأثیر هر پارامتر ورودی بر خروجی انجام شد.

نتایج و بحث: نتایج ارزیابی تطبیقی نشان داد که هر دو مدل SVM-HOA و SVM-RSA در پیش‌بینی دقیق ضریب دبی در هر دو نوع کانال عملکرد مناسبی داشتند. در سناریوی اول (کانال مستطیلی)، مدل SVM-HOA با ورودی‌های نظیر نسبت ارتفاع سرریز به عمق جریان ابتدایی (P/y_1)، نسبت طول تاج سرریز به عرض کف کانال (L/B)، نسبت طول تاج به عمق جریان (L/y_1) و عدد فرود بالادست (Fr_1) مقادیر NSE، RMSE و R به ترتیب برابر با ۰.۹۰۴، ۰.۰۶۳ و ۰.۹۵۳ بهترین عملکرد را نشان داد. در سناریوی دوم (کانال دوزنقه‌ای) نیز مدل SVM-HOA با ورودی‌های L/B ، Fr_1 و y_1/B و شیب دیواره کانال (m) به مقادیر NSE، RMSE و R به ترتیب برابر با ۰.۹۶۴، ۰.۰۲۰ و ۰.۹۸۶ دست‌یافت. نمودارهای تیلور، برتری مدل SVM-HOA نسبت به SVM-RSA را در قدرت پیش‌بینی و پایداری نتایج تأیید کردند. تحلیل حساسیت نشان داد که نسبت P/y_1 در کانال مستطیلی و عدد فرود بالادست (Fr_1) در کانال دوزنقه‌ای بیشترین تأثیر را بر مقدار C_d دارند. این یافته‌ها بر اهمیت توجه به متغیرهای هندسه محور و انتخاب الگوریتم بهینه‌سازی مناسب در کاربردهای هیدرولیکی تأکید می‌کنند.

نتیجه‌گیری: این پژوهش رویکردی نوآورانه و متکی بر هندسه را برای پیش‌بینی دقیق ضریب دبی در سرریزهای جانبی مستطیلی لبه‌تیز ارائه می‌دهد. دو مدل ترکیبی پیشنهادی، یعنی SVM-HOA و SVM-RSA، دقت بالا، تطبیق‌پذیری مناسب با هندسه‌های مختلف کانال و مقاومت بالا در برابر بیش‌برازش و کمینه‌های محلی را از خود نشان دادند. نتایج بیانگر برتری قابل‌توجه مدل SVM-HOA در بیشتر موارد است، به‌ویژه زمانی که با پارامترهای بی‌بعد مناسب و نسبت بهینه‌ی داده‌های آموزش و تست همراه باشد. این مدل‌ها می‌توانند به عنوان ابزاری کارآمد برای مهندسان هیدرولیک در طراحی، شبیه‌سازی و تحلیل عملکرد سرریزهای جانبی در شرایط مختلف جریان و انواع کانال‌ها مورد استفاده قرار گیرند.

کلید واژه‌ها: الگوریتم‌های فرا ابتکاری، آنالیز حساسیت، سرریز جانبی، ضریب دبی، یادگیری ماشین

مقدمه

سرریزهای جانبی به‌عنوان سازه‌های هیدرولیکی کلیدی برای انحراف و کنترل جریان در کانال‌ها طراحی می‌شوند و در کاربردهایی نظیر شبکه‌های آبیاری، مدیریت رواناب و تأسیسات تصفیه‌خانه‌ای نقش مهمی ایفا می‌کنند (Abdollahi et al., 2017). ضریب دبی (C_d) این سازه‌ها، که معیاری اصلی برای برآورد دبی جریان و رفتار سطح آزاد است، به عوامل متعددی از جمله هندسه سرریز، شکل مقطع کانال، و ویژگی‌های جریان بالادست و پایین‌دست وابسته است. مطالعات آزمایشگاهی نشان داده‌اند که C_d در طول سرریز ثابت نیست و تحت تأثیر شرایط هیدرولیکی و هندسی تغییر می‌کند (Granata et al., 2016). تحلیل دقیق این ضریب نیازمند روش‌های متنوعی از جمله مدل‌های تعادل انرژی (Hager, 1994)، اندازه حرکت (El-Khashab & Smith, 1976)، روابط تجربی (Biggiero et al., 1994) و شبیه‌سازی دینامیک سیالات محاسباتی (Azimi et al., 2014) است.

مطالعات پیشین تأثیر عوامل هیدرولیکی و هندسی بر C_d را بررسی کرده‌اند. جدول ۱ برخی معادله تجربی معتبر برای پیش‌بینی ضریب دبی سرریزهای جانبی مستطیلی لبه‌تیز را ارائه می‌دهد که بر اساس پارامترهای بی‌بعد مانند عدد فرود (Fr_1)، نسبت ارتفاع تاج به عمق جریان (P/y_1) و نسبت طول تاج به عرض کانال (L/B) تدوین شده‌اند. سابرامانیا و آواستی^۱ (۱۹۷۲) با آزمایش روی سرریزهای جانبی مستطیلی لبه‌تیز در کانال مستطیلی، نشان دادند که عدد فرود (Fr_1) مهم‌ترین عامل اثرگذار بر C_d است. راجو^۲ و همکاران (۱۹۷۹) با مقایسه سرریزهای لبه‌تیز و لبه‌پهن، کاهش دبی عبوری در سرریزهای لبه‌پهن را گزارش کردند. جلیلی و برقی (۱۹۹۶) با فرض کاهش ۳۰٪ درصدی انرژی مخصوص، رابطه‌ای برای C_d بر اساس Fr_1 و نسبت ارتفاع تاج به عمق جریان (P/y_1) پیشنهاد کردند. برقی و همکاران (۱۹۹۹) اثر شیب طولی کانال را ناچیز دانستند.

در ادامه، روش‌های عددی و مدل‌های فیزیکی برای شبیه‌سازی جریان به کار گرفته شده‌اند، اما به دلیل پیچیدگی محاسباتی، خطاهای عددی و هزینه و زمان بالا، با محدودیت‌هایی همراهند (Ghaderi et al., 2020). در سال‌های اخیر، روش‌های یادگیری ماشین به دلیل دقت بالا، زمان محاسباتی کمتر و قابلیت تعمیم مبتنی بر داده‌های موجود، به‌عنوان جایگزینی کارآمد برای روش‌های سنتی معرفی شده‌اند (Hien et al., 2024). بیلهان^۳ و

همکاران (۲۰۱۰) شبکه عصبی پیشرو (FFNN) را دقیق‌تر از شبکه عصبی پایه شعاعی (RBNN) یافتند. ابتهاج و همکاران (۲۰۱۵) با استفاده از روش گروهی مدل‌سازی داده‌ها (GMDH) دقت بالاتری نسبت به FFNN گزارش کردند. خوش‌بین و همکاران (۲۰۱۶) یک مدل ترکیبی بهینه برای تخمین ضریب دبی سرریزهای جانبی از طریق ترکیب ANFIS با الگوریتم ژنتیک (GA) و تجزیه مقادیر تکین (SVD) ارائه کردند و نشان دادند که در پیش‌بینی ضریب دبی، مدل بهینه ارائه‌شده در مقایسه با شبکه عصبی چندلایه پرسپترون (MLP-ANN) عملکرد بهتری دارد. عظمت‌الله^۴ و همکاران (۲۰۱۶) برتری روش ماشین بردار پشتیبان (SVM) نسبت به ANN و ANFIS را نشان دادند. روشنگر و همکاران (۲۰۱۶) ۱ بهینه‌سازی SVM توسط الگوریتم ژنتیک (SVM-GA)، دقت بالاتری نسبت به GEP گزارش کردند. عظیمی و همکاران (۲۰۱۷) از یادگیری افراطی (ELM) برای کانال‌های دوزنقه‌ای استفاده کردند. صفار و همکاران (۲۰۲۱) با استفاده از ANFIS در کانال‌های همگرا، دبی سرریز جانبی را با دقت قابل قبولی پیش‌بینی نمودند. سیدیان و کیشی (۲۰۲۴) با مدل GPR، دقت و اطمینان بالایی در پیش‌بینی ضریب دبی در کانال‌های مستطیلی نشان دادند. هم‌چنین، بالا‌هنگ و قدسیان (۲۰۲۴) با استفاده از تکنیک stacking و مدل‌های XGBoost، LightGBM و SVR، دقت بالایی در پیش‌بینی C_d گزارش کردند. دهر^۵ و همکاران (۲۰۲۵) با مقایسه شش مدل یادگیری ماشین، برتری مدل CatBoost را تأیید کردند.

با توجه به‌مرور مطالعات گذشته، اگرچه روش‌های یادگیری ماشین در پیش‌بینی ضریب دبی سرریزهای جانبی نتایج قابل‌قبولی ارائه داده‌اند، اما بیشتر پژوهش‌های موجود بر توسعه یا ترکیب مدل‌های محاسبات نرم متمرکز بوده‌اند و کمتر به بررسی نقش هندسه کانال اصلی پرداخته‌اند. نوآوری اصلی این پژوهش در مقایسه دو سناریوی هندسی متفاوت (کانال مستطیلی و دوزنقه‌ای) و شناسایی پارامترهای بی‌بعد غالب از طریق تحلیل حساسیت است. در این راستا، مدل‌های ترکیبی مبتنی بر SVM بهینه‌شده با HOA و RSA برای اطمینان از دقت پیش‌بینی به کار گرفته شده‌اند. این رویکرد ضمن ارائه تصویری دقیق از تأثیر هندسه کانال بر رفتار هیدرولیکی، مبنایی برای طراحی کارآتر سرریزهای جانبی فراهم می‌کند.

جدول ۱. معادلات تجربی پیش‌بینی ضریب دبی سرریزهای جانبی مستطیلی لبه‌تیز

شماره معادله	نام محقق	کانال واقع شده	معادله
(۱)	سابرامانیا و آواستی (۱۹۷۲)	مستطیلی	$C_d = 0.864 \left(\frac{1 - Fr_1^2}{2 + Fr_1^2} \right)^2$
(۲)	راجو و همکاران (۱۹۷۹)	مستطیلی	$C_d = 0.81 - 0.6Fr_1$
(۳)	برقی و همکاران (۱۹۹۹)	مستطیلی	$C_d = 0.7 - 0.48Fr_1 - 0.3 \left(\frac{P}{y_1} \right) + 0.06 \left(\frac{L}{b} \right)$
(۴)	جلیلی و برقی (۱۹۹۶)	دوزنقه‌ای	$C_d = 0.71 - 0.41Fr_1 - 0.22 \left(\frac{P}{y_1} \right)$

مواد و روش‌ها

ضریب دبی سرریزهای جانبی

متغیرهای مؤثر بر ضریب دبی سرریزهای جانبی مستطیلی لبه تیز به صورت رابطه (۵) بیان می‌شوند (Ghaderi et al., 2020):

$$C_d = f(y_1, B, L, P, Fr_1, m, Re, We, S_0) \quad (5)$$

که در آن، y_1 عمق جریان در ابتدای سرریز جانبی، B عرض کف کانال اصلی، L طول تاج سرریز جانبی، P ارتفاع تاج سرریز جانبی، Fr_1 عدد فرود بالادست سرریز جانبی، m شیب دیواره کانال اصلی دوزنقه‌ای، Re عدد رینولدز، We عدد وبر و S_0 شیب بستر کانال اصلی است.

برقی و همکاران (۱۹۹۹) در آزمایش‌های خود نشان دادند که تأثیر شیب کانال اصلی بر ضریب دبی ناچیز است. همچنین با توجه به اینکه عمق جریان بر روی تاج سرریزهای جانبی بیش از سه سانتی‌متر بوده و جریان از نوع آشفته ($Re > 2000$) می‌باشد، می‌توان از اثرات عدد وبر و عدد رینولدز که به ترتیب معرف کشش سطحی و اثر لزجت هستند، صرف‌نظر نمود (Ghaderi et al., 2020). علاوه بر این، برای بی‌بعد نمودن پارامترهای معرفی شده و در نظر گرفتن سایر پارامترهای بی‌بعد مؤثر بر ضریب دبی، معادله بالا به صورت رابطه (۶) نوشته شد:


$$C_d = f\left(\frac{P}{y_1}, \frac{L}{B}, \frac{L}{y_1}, \frac{y_1}{B}, m, Fr_1\right) \quad (6)$$

گردآوری داده‌های مورد استفاده

برای پیش‌بینی ضریب دبی سرریزهای جانبی مستطیلی از دو سناریوی مختلف استفاده شد. در سناریو اول که مربوط به سرریزهای جانبی مستطیلی لبه تیز واقع در کانال مستطیلی است از ۴۰۷ داده‌ی آزمایشگاهی ارائه‌شده توسط آگراوال^۶ (۱۹۸۹)، برقی و همکاران (۲۰۱۴) و امیر اوغلو^۷ و همکاران (۲۰۱۱) استفاده‌شده است که رژیم جریان در آن‌ها زیر بحرانی می‌باشد. آزمایش آگراوال در آزمایشگاه هیدرولیک دانشگاه روئورکی هند انجام شد که کانال اصلی با شیب بستر افقی دارای ۹ متر طول و ۰٫۵ متر عرض بود و سرریز جانبی

ساخته‌شده از صفحات فولادی لبه تیز در فاصله ۴ متری از ابتدای کانال اصلی قرار داشت. مدل برقی و همکاران یک کانال مستطیلی با شیب بستر افقی به طول ۸ متر، عرض ۰٫۴ متر و عمق ۰٫۶ متر بود که سرریز جانبی در فاصله ۴٫۵ متری از ورودی کانال تعبیه‌شده بود. آزمایش امیر اوغلو و همکاران نیز در دانشگاه فیرات ترکیه شامل یک کانال مستطیلی مستقیم با شیب بستر ۰٫۰۰۱ به طول ۱۲ متر، عرض ۰٫۵ متر و عمق ۰٫۵ متری بود.

در سناریو دوم که مربوط به سرریزهای جانبی مستطیلی لبه تیز واقع در کانال دوزنقه‌ای است از ۷۸ داده‌ی آزمایشگاهی ارائه‌شده توسط چئونگ^۸ (۱۹۹۱) استفاده‌شده است که رژیم جریان در آن‌ها به هر دو صورت زیر بحرانی و فوق بحرانی می‌باشد. آزمایش چئونگ شامل یک کانال دوزنقه‌ای به طول ۱۰ متر و عرض کف ۰٫۶۷ متر است که شیب دیواره‌های جانبی کانال متغیر بوده و سرریز جانبی مستطیلی در فاصله‌ی دو سوم طول کانال از ورودی نصب گردیده است. طرح شماتیک آزمایشگاهی این آزمایش‌ها در شکل (۱) ارائه‌شده است.



شکل ۱. شماتیک سرریزهای جانبی مستطیلی لبه تیز واقع در کانال:

(الف) مستطیلی (ب) دوزنقه‌ای

جدول ۲. دامنه مقادیر آزمایشگاهی در سناریوهای تحقیق

سرریزهای جانبی مستطیلی لبه تیز واقع در کانال مستطیلی						
y_1 (m)	B (m)	L (m)	P (m)	Fr_1	C_d	
حداقل	۰٫۰۳۰	۰٫۴۰۰	۰٫۱۵۰	۰٫۰۰۰	۰٫۰۸۸	۰٫۲۸۱
حداکثر	۰٫۴۳۲	۰٫۵۰۰	۱٫۵۰۰	۰٫۲۸۰	۰٫۸۶۵	۱٫۷۴۶
میانگین	۰٫۲۰۱	۰٫۴۸۰	۰٫۵۳۳	۰٫۱۱۷	۰٫۴۰۰	۰٫۵۸۹
سرریزهای جانبی مستطیلی لبه تیز واقع در کانال دوزنقه‌ای						
y_1 (m)	B (m)	L (m)	P (m)	Fr_1	m	C_d
حداقل	۰٫۰۲۸	۰٫۳۴۰	۰٫۲۷۷	۰٫۰۰۰	۰٫۲۴۰	۰٫۱۷۷
حداکثر	۰٫۲۲۱	۰٫۶۷۰	۰٫۹۷۰	۰٫۰۰۰	۱٫۲۷۵	۰٫۴۸۵
میانگین	۰٫۰۹۶	۰٫۴۹۲	۰٫۵۲۲	۰٫۰۰۰	۰٫۷۰۳	۰٫۳۸۶

بهینه‌سازی از تکنیک لاگرانژ استفاده می‌شود و در نهایت تابع رگرسیون به صورت زیر قابل محاسبه است:

$$f(x) = \sum_{i=1}^n a_i K(x_i, x_j) - b \quad (10)$$

در رابطه فوق $K(x_i, x_j)$ تابع تبدیل کرنل می‌باشد که انواع مختلفی دارد که در این تحقیق از یکی از رایج‌ترین و قدرتمندترین توابع به نام تابع کرنل پایه شعاعی (RBF) یا گاوسی که به صورت رابطه (۱۱) است، استفاده شده است.

$$K(x_i, x_j) = \varphi^T(x_i) \varphi(x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (11)$$

که در این روابط σ ابر پارامتر تنظیم‌کننده با مقدار مثبت در کرنل RBF است. مهم‌ترین و مشکل‌ترین مسئله در استفاده از ماشین‌های بردار پشتیبان انتخاب سه ابر پارامتر تنظیم‌کننده C و σ و ε می‌باشد که در این پژوهش برای دستیابی به مقادیر بهینه این ابر پارامترها از دو الگوریتم فرا ابتکاری جدید استفاده شده است که در ادامه به معرفی آن‌ها پرداخته خواهد شد. شایان ذکر است که ε معرف دقت پیش‌بینی یعنی اختلاف بین مقادیر واقعی و مقادیر پیش‌بینی شده است.

الگوریتم بهینه‌سازی اسب

الگوریتم بهینه‌سازی اسب (HOA) یک بهینه‌سازی مبتنی بر هوش تجمعی است که بر اساس الگوهای رفتاری اسب‌ها در محیط زندگی آن‌ها ساخته شده است. این الگوریتم از شش الگوی رفتاری اسب‌ها شامل چرا (G)، سلسله‌مراتب (H)، جامعه‌پذیری (S)، تقلید (I)، مکانیزم دفاعی (D) و پرسه زدن (R) الهام گرفته شده است (MiarNaeimi et al., 2021).

معادله موقعیت اسب‌ها در هر تکرار به صورت رابطه (۱۲) است:

$$X_m^{Iter, Age} = \bar{V}_m^{Iter, Age} X_m^{(Iter-1), Age}, \quad Age = \alpha, \beta, \gamma, \delta \quad (12)$$

که در آن $X_m^{(Iter-1), Age}$ موقعیت اسب m ام، $Iter$ تکرار فعلی، $\bar{V}_m^{Iter, Age}$ بردار سرعت این اسب و Age محدوده سنی اسب در نظر گرفته شده را نشان می‌دهد که با توجه به اینکه اسب‌ها در سنین مختلف رفتارهای متفاوتی از خود نشان می‌دهند، این محدوده سنی به ۴ قسمت تقسیم شده است. اسب‌های مسن‌تر α و β روی جستجوی محلی و بهبود راه‌حل‌ها تمرکز دارند، در حالی که اسب‌های جوان‌تر γ و δ تمایل بیشتری به کاوش مناطق جدید دارند. هم‌چنین در طول هر چرخه الگوریتم، بردار سرعت حرکت اسب‌ها به‌روز می‌شوند. این الگوریتم ترکیبی از جستجوی محلی و سراسری را ارائه می‌دهد و با بهره‌گیری از مکانیزم‌های جمعی، از گیر افتادن در بهینه‌های محلی جلوگیری می‌کند. با این حال، HOA محدودیت‌هایی دارد، از جمله نیاز به تنظیم دقیق پارامترهای سنی (مانند ضرایب رفتاری گروه‌های α ، β ، γ و δ) که در مسائل با ابعاد بالا یا داده‌های پیچیده می‌تواند زمان‌بر باشد، محدودیت به مسائل

هم‌چنین، به‌منظور ایجاد درک دقیق‌تری از دامنه تغییرات داده‌های مورد استفاده و شرایط حاکم بر هر سناریو، محدوده‌ی مشخصات هیدرولیکی و هندسی آزمایش‌ها برای سرریزهای جانبی مستطیلی لبه‌تیز در دو پیکربندی کانال مستطیلی و دوزنقه‌ای، در جدول (۲) ارائه گردیده است.

ماشین بردار پشتیبان

ماشین بردار پشتیبان (SVM) در مقایسه با سایر روش‌های یادگیری ماشین شامل شبکه عصبی، با مجموعه داده‌های کوچک عملکرد بهتری دارند و قابلیت‌های تعمیم بالاتری را نشان می‌دهند. علاوه بر این، SVM ها کمتر مستعد بیش برازش هستند که به آن‌ها امکان می‌دهد نتایج قابل اطمینان‌تری ارائه دهند. نوعی از یادگیری ماشین نظارت‌شده می‌باشد که در سال ۱۹۹۵ توسط کورتس و وپنیک ابداع شد (Cortes & Vapnik, 1995). این روش، ریسک ساختاری را به‌عنوان تابع هدف قرار داده و با جلوگیری از بیش برازش در برابر داده‌های تست نیز بهتر عمل می‌کند. درواقع ایده اصلی ماشین‌های بردار پشتیبان، ترسیم ابر صفحه‌ای در فضا است که عمل تمایز نمونه‌های مختلف داده را به‌طور بهینه انجام دهند. شایان ذکر است که بهترین ابر صفحه، صفحه‌ای می‌باشد که دارای بیشترین حاشیه از دو کلاس است و بردارهای پشتیبان نیز نقاطی هستند که کمترین فاصله را با این ابر صفحه دارند. در SVM با استفاده از توابع تبدیل کرنل، داده‌هایی که به‌صورت خطی در ابعاد اصلی خود قابل جداسازی خطی نیستند به فضای ویژگی بالاتری (بعد بالاتر) انتقال داده می‌شوند که بتوان آن‌ها را به‌صورت خطی جدا کرد.

داده‌های آموزش SVM به صورت $XY = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ می‌باشند به گونه‌ای که n تعداد داده‌های آموزش است. هدف نهایی در SVM یافتن رابطه (۷) میان بردارهای ورودی $x \in R_n$ و متغیرهای خروجی $y \in R$ است.

$$f(x) = w^T \varphi(x) + b \quad (7)$$


که b ، w و $\varphi(x)$ به ترتیب بایاس، بردار وزن و تابع کرنل هستند که برای یافتن مقدار بهینه آن‌ها نیاز به کمینه‌سازی رابطه (۸) با قیود (۹) است.

$$\min(w, b, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (8)$$

$$\text{s.t.} \begin{cases} 1 - \xi_i - y_i (w^T \varphi(x_i) + b) \leq 0 \\ -\xi_i \leq 0 \end{cases} \quad (9)$$

که در این روابط C ابر پارامتر تنظیم‌کننده حاشیه به‌عنوان ضریب جریمه خطا عمل می‌کند و مقداری مثبت است، ξ_i متغیر مجازی است که حد بالا و پایین خطای آموزش مرتبط با مقدار خطای مجاز ε را تعیین می‌کند. برای حل این مسئله

و جمعیت به ۵ محدود شد. همچنین ضرایب سنی HOA و کران‌های RSA از طریق سعی و خطا تنظیم شدند تا تعادل کاوش و بهره‌برداری حفظ شود و همگرایی تسریع و خطر گیر افتادن در بهینه محلی کاهش یابد. شایان‌ذکر است که برای توسعه مدل‌های مختلف SVM-HOA و SVM-RSA ترکیب‌های متغیرهای بی‌بعد مؤثر بر ضریب دبی استفاده می‌شود که مدل‌های ورودی برای پیش‌بینی ضریب دبی سرریزهای جانبی در شکل (۲) نشان داده شده است.



شکل ۲. مدل‌های ورودی برای پیش‌بینی ضریب دبی سرریزهای جانبی مستطیلی لبه تیز واقع در کانال: الف) مستطیلی ب) دوزنقه‌ای

معیارهای ارزیابی

به منظور ارزیابی دقت مدل‌های تعریف شده در پیش‌بینی ضریب دبی سرریزهای جانبی از سه شاخص آماری همچون ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و ضریب راندمان نش-ساتکلیف (NSE) استفاده گردید. شایان‌ذکر است که مدلی مطلوب است که مقدار R و NSE آن به یک و مقدار RMSE آن به صفر نزدیک باشد (Roushangar et al., 2024b, 2024a). معادلات (۱۵)، (۱۶) و (۱۷) به ترتیب R، RMSE و NSE را توصیف می‌کنند:

$$R^2 = \frac{\sum_{i=1}^N (Y_i - \bar{Y}) \times (\hat{Y}_i - \bar{\hat{Y}})}{\sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2 \times (\hat{Y}_i - \bar{\hat{Y}})^2}} \quad (15)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2} \quad (16)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (17)$$

تک‌هدفه و حساسیت به تعداد تکرارها که ممکن است تعادل بین کاوش و بهره‌برداری را مختل کند (MiarNaeimi et al., 2021).

الگوریتم جستجوی خزندگان

الگوریتم جستجوی خزندگان (RSA) یک بهینه‌سازی مبتنی بر هوش تجمعی است که از رفتار اجتماعی کروکدیل‌ها در طبیعت الهام گرفته شده است و از دو الگوی رفتاری کروکدیل‌ها شامل محاصره کردن (اکتشاف) و شکار کردن (استخراج) استفاده می‌نماید. فرآیند بهینه‌سازی مطابق معادله (۱۳) با مجموعه‌ای از راه‌حل‌های کاندید (X) یا جمعیت شروع می‌شود و در طول مسیر تکرار، مکانیزم‌های جستجوی RSA موقعیت‌های احتمالی پاسخ تقریباً بهینه را بررسی می‌کنند (Abualigah et al., 2022).

$$X = \begin{bmatrix} x_{1,1} & \cdots & x_{1,n} \\ \vdots & \ddots & \vdots \\ x_{N,1} & \cdots & x_{N,n} \end{bmatrix} \quad (13)$$

که در آن X مجموعه‌ای از راه‌حل‌های کاندید است که به‌طور تصادفی با استفاده از معادله (۱۴) ایجاد می‌شود. x_{ij} موقعیت j ام راه‌حل i ام، N تعداد راه‌حل‌های کاندید و n اندازه بعد مسئله را نشان می‌دهد.

$$x_{ij} = rand \times (UB - LB) + LB, \quad j = 1, 2, \dots, n \quad (14)$$

همچنین rand مقدار تصادفی بین صفر و یک، UB و LB کران پایین و بالای مسئله داده شده است. با این حال، RSA محدودیت‌هایی دارد، از جمله خطر گیر افتادن در بهینه‌های محلی در مسائل با فضای جستجوی پیچیده، سرعت همگرایی کند در فضاهای جستجوی بزرگ و محدودیت به مسائل تک‌هدفه با متغیرهای پیوسته (Abualigah et al., 2022).

تقسیم‌بندی داده‌ها و تعیین ورودی مدل‌ها

در این مطالعه، مجموعه داده‌ها به دو قسمت داده‌های آموزش و تست با نسبت ۸۰ درصد برای آموزش و ۲۰ درصد برای تست تفکیک شدند. برای جلوگیری از بیش‌برازش و بهبود تعمیم‌پذیری، از روش اعتبارسنجی متقابل ۱۰ بخشی استفاده شد. در روش اعتبارسنجی متقابل 10-fold، داده‌های آموزش به‌طور تصادفی به ۱۰ لایه با تعداد یکسان تقسیم شده و در هر مرحله، تعداد (k-1) تا از این لایه‌ها به‌عنوان مجموعه داده‌های آموزشی و یک لایه به‌عنوان مجموعه داده اعتبارسنجی در نظر گرفته می‌شود. با توجه به حجم کوچک داده‌ها (۴۰۷ داده برای کانال مستطیلی و ۷۸ داده برای دوزنقه‌ای)، این روش پایداری مدل‌های SVM-HOA و SVM-RSA را بهبود داد. برای رفع محدودیت‌های این دو الگوریتم بهینه‌سازی، تعداد تکرارها به ۱۰

جدول ۳. پارامترهای تنظیم‌شده برای اجرای مدل‌ها

مقدار	پارامترهای تنظیم SVR-HOA	مقدار	پارامترهای تنظیم SVR-RSA
۱۰	Maximum number of iterations	۱۰	Maximum number of iterations
۵	Population size (N)	۵	Population size (N)
۱۰	k-fold	۱۰	k-fold
۱.۵	g (Grazibg coefficient for all Ages)	۰.۱	α
۰.۹	h_β (Hierarchy factor for β)	۰.۱	β
۰.۵	h_γ (Hierarchy factor for γ)	RMSE	Cost function
۰.۲	s_β (Sociability factor for β)		
۰.۱	s_γ (Sociability factor for γ)		
۰.۳	i_γ (Imitation factor for γ)		
۰.۳	i_δ (Imitation factor for δ)		
۰.۵	d_α (Defense factor for α)		
۰.۲	d_β (Defense factor for β)		
۰.۱	d_γ (Defense factor for γ)		
۰.۰۵	r_γ (Roam factor for γ)		
۰.۱	r_δ (Roam factor for δ)		
۰.۹۹۹	ω (Reduction factor)		
RMSE	Cost function		

انتخاب شدند. نتایج مدل‌سازی نشان داد که مدل‌های SVM-HOA و SVM-RSA با این نسبت عملکرد بهتری داشتند. در جدول (۴) به ارزیابی شاخص‌های آماری و مقادیر بهینه سه ابر پارامتر تنظیم‌کننده C، σ و ε برای مدل‌های اجراشده، اشاره گردیده است. با توجه به نتایج مربوط به شاخص‌های آماری داده‌های تست، مدل RR2 به‌عنوان مدل برتر برگزیده می‌شود که مقادیر NSE، RMSE و R در الگوریتم SVR-HOA به ترتیب برابر ۰.۹۰۴، ۰.۰۶۳ و ۰.۹۵۳ و در الگوریتم SVR-RSA به ترتیب برابر ۰.۸۹۸، ۰.۰۶۵ و ۰.۹۵۰ می‌باشد. علاوه بر این در شکل‌های (۳) و (۴) برای بهترین مدل، ضرایب دبی پیش‌بینی‌شده با الگوریتم‌های SVM-HOA و SVM-RSA در مقابل ضرایب دبی آزمایشگاهی در هر دو مرحله آموزش و تست نشان داده‌شده است.

در روابط شماره ۱۵-۱۷ ضرایب دبی مشاهداتی، $\bar{Y}$ میانگین ضرایب دبی مشاهداتی، $\hat{Y}_i$ ضرایب دبی پیش‌بینی‌شده، $\bar{\hat{Y}}$ میانگین ضرایب دبی پیش‌بینی‌شده و N تعداد کل داده‌ها می‌باشد.

نتایج و بحث


در این مطالعه، مدل SVR بهینه برای پیش‌بینی ضریب دبی سرریزهای جانبی پیشنهاد شد که پارامترهای تنظیم‌شده برای اجرای مدل‌های بهینه‌سازی SVR-HOA و SVR-RSA در جدول (۳) ارائه شده است.

نتایج تحت سناریو ۱


در سناریو اول که مربوط به سرریزهای جانبی مستطیلی لبه تیز واقع در کانال اصلی مستطیلی است، ۴۰۷ داده آزمایشگاهی با نسبت ۸۰ درصد برای آموزش در مقابل ۲۰ درصد برای تست

جدول ۴. نتایج حاصل از روش‌های SVM-HOA و SVM-RSA برای پیش‌بینی ضریب دبی تحت سناریو ۱


مدل‌ها	الگوریتم	مقادیر بهینه			مرحله آموزش			مرحله تست		
		σ	ε	C	NSE	RMSE	R	NSE	RMSE	R
RR1	SVR-HOA	۲.۵۰۰	۰.۰۱۴	۲۹.۱۴۸	۰.۹۷۰	۰.۰۳۴	۰.۹۴۱	۰.۹۳۳	۰.۰۷۵	۰.۸۶۱
	SVR-RSA	۲.۵۰۰	۰.۰۱۰	۳۱.۰۰۰	۰.۹۷۰	۰.۰۳۴	۰.۹۴۱	۰.۹۳۸	۰.۰۷۳	۰.۸۷۰
RR2	SVR-HOA	۲.۵۰۳	۰.۰۱۲	۳۰.۷۷۴	۰.۹۶۴	۰.۰۳۸	۰.۹۲۹	۰.۹۵۳	۰.۰۶۳	۰.۹۰۴
	SVR-RSA	۲.۵۰۰	۰.۰۱۰	۳۱.۰۰۰	۰.۹۲۹	۰.۰۳۸	۰.۹۲۹	۰.۹۵۰	۰.۰۶۵	۰.۸۹۸
RR3	SVR-HOA	۲.۵۰۰	۰.۰۱۴	۲۹.۱۶۸	۰.۸۲۳	۰.۰۸۲	۰.۶۶۶	۰.۸۲۲	۰.۱۲۳	۰.۶۳۷
	SVR-RSA	۲.۵۰۰	۰.۰۱۰	۲۹.۰۰۰	۰.۸۲۳	۰.۰۸۲	۰.۶۶۷	۰.۸۳۹	۰.۱۱۹	۰.۶۵۵
RR4	SVR-HOA	۲.۵۰۵	۰.۰۱۲	۳۰.۷۷۴	۰.۹۶۹	۰.۰۳۵	۰.۹۳۸	۰.۹۳۷	۰.۰۷۴	۰.۸۶۴
	SVR-RSA	۲.۵۰۰	۰.۰۱۰	۳۱.۰۰۰	۰.۹۶۸	۰.۰۳۵	۰.۹۳۹	۰.۹۴۰	۰.۰۷۳	۰.۸۶۹
RR5	SVR-HOA	۲.۵۰۴	۰.۰۱۲	۳۰.۷۷۴	۰.۹۶۳	۰.۰۳۸	۰.۹۲۷	۰.۹۳۹	۰.۰۷۳	۰.۸۷۰
	SVR-RSA	۲.۵۰۰	۰.۰۱۰	۳۱.۰۰۰	۰.۹۶۳	۰.۰۳۸	۰.۹۲۷	۰.۹۴۱	۰.۰۷۱	۰.۸۷۶
RR6	SVR-HOA	۲.۸۰۷	۰.۰۱۳	۳۱.۰۰۰	۰.۹۲۶	۰.۰۵۴	۰.۸۵۴	۰.۸۵۰	۰.۱۱۰	۰.۷۰۱
	SVR-RSA	۲.۵۰۰	۰.۰۱۰	۲۹.۰۰۰	۰.۸۶۴	۰.۰۵۳	۰.۸۵۸	۰.۸۵۱	۰.۱۱۰	۰.۷۰۰
RR7	SVR-HOA	۲.۵۱۳	۰.۰۱۴	۲۹.۱۰۸	۰.۹۲۳	۰.۰۵۵	۰.۸۴۸	۰.۸۴۵	۰.۱۱۳	۰.۶۸۵
	SVR-RSA	۲.۵۰۰	۰.۰۱۰	۲۹.۰۰۰	۰.۹۲۴	۰.۰۵۵	۰.۸۵۱	۰.۸۴۶	۰.۱۱۳	۰.۶۸۸
RR8	SVR-HOA	۲.۵۱۳	۰.۰۱۴	۲۹.۱۰۸	۰.۷۲۶	۰.۰۹۹	۰.۵۱۶	۰.۷۷۷	۰.۱۴۲	۰.۵۰۶
	SVR-RSA	۲.۵۰۰	۰.۰۱۰	۳۱.۰۰۰	۰.۷۲۷	۰.۰۹۹	۰.۵۱۵	۰.۷۷۴	۰.۱۴۳	۰.۵۰۱



شکل ۳. ضرایب دبی پیش‌بینی‌شده با الگوریتم SVM-HOA در مقابل ضرایب دبی آزمایشگاهی در مراحل آموزش و تست برای RR2 تحت سناریو ۱



شکل ۴. ضرایب دبی پیش‌بینی‌شده با الگوریتم SVM-RSA در مقابل ضرایب دبی آزمایشگاهی در مراحل آموزش و تست برای RR2 تحت سناریو ۱



شکل ۵. نمودار تیلتور برای RR2 تحت سناریو ۱

مقدار پیش‌بینی‌شده از نظر R ، $RMSE$ و SD به مقدار مشاهده نزدیک‌تر باشد، پیش‌بینی بهتری صورت می‌گیرد. مطابق نمودار، الگوریتم SVM-HOA دارای راندمان بالاتری است و پیش‌بینی دقیق‌تری انجام می‌دهد.

علاوه بر این، در شکل (۵) از نمودار تیلتور برای تجزیه و تحلیل الگوریتم‌های SVR-HOA و SVR-RSA بر روی مدل برتر استفاده شد که از سه شاخص آماری ضریب همبستگی (R)، ریشه میانگین مربعات خطا ($RMSE$) و انحراف معیار (SD) استفاده می‌کند. در نمودار تیلتور هرچه


نتایج تحت سناریو ۲

برگزیده می‌شود که مقادیر NSE، RMSE و R در الگوریتم SVR-HOA به ترتیب برابر ۰،۹۶۴، ۰،۰۲۰ و ۰،۹۸۶ و در الگوریتم SVR-RSA به ترتیب برابر ۰،۹۶۴، ۰،۰۲۰ و ۰،۹۸۵ می‌باشد. همچنین در شکل‌های (۶) و (۷) برای بهترین مدل، ضرایب دبی پیش‌بینی‌شده با الگوریتم‌های SVM-HOA و SVM-RSA در مقابل ضرایب دبی آزمایشگاهی در هر دو مرحله آموزش و تست نشان داده شده است.


در سناریو دوم که مربوط به سرریزهای جانبی مستطیلی لبه تیز واقع در کانال اصلی دوزنقه‌ای با ۷۸ داده آزمایشگاهی است، نتایج مدل‌سازی نشان داد که مدل‌های SVM-HOA و SVM-RSA عملکرد بهتری داشتند. در جدول (۵) به ارزیابی شاخص‌های آماری و مقادیر بهینه سه ابر پارامتر تنظیم‌کننده C ، σ و ε برای مدل‌های اجرا شده، اشاره گردیده است. با توجه به نتایج مربوط به شاخص‌های آماری داده‌های تست، مدل RT5 به عنوان مدل برتر

جدول ۵. نتایج حاصل از روش‌های SVM-HOA و SVM-RSA برای پیش‌بینی ضریب دبی تحت سناریو ۲

مدل‌ها	الگوریتم	مقادیر بهینه			مرحله آموزش			مرحله تست		
		C	ε	σ	R	RMSE	NSE	R	RMSE	NSE
RT1	SVR-HOA	۹،۷۳۵	۰،۰۱۹	۴،۸۹۹	۰،۹۷۶	۰،۰۱۹	۰،۹۵۲	۰،۹۸۳	۰،۰۲۱	۰،۹۶۲
	SVR-RSA	۹،۶۷۵	۰،۰۱۹	۴،۸۶۹	۰،۹۷۶	۰،۰۱۹	۰،۹۵۲	۰،۹۸۳	۰،۰۲۰	۰،۹۶۳
RT2	SVR-HOA	۹،۲۴۲	۰،۰۱۸	۴،۸۹۰	۰،۹۷۱	۰،۰۲۱	۰،۹۴۳	۰،۹۷۶	۰،۰۲۷	۰،۹۳۴
	SVR-RSA	۹،۲۲۲	۰،۰۱۸	۴،۸۹۰	۰،۹۷۰	۰،۰۲۱	۰،۹۴۱	۰،۹۷۰	۰،۰۲۹	۰،۹۲۵
RT3	SVR-HOA	۹،۶۷۵	۰،۰۱۹	۴،۸۶۹	۰،۹۷۶	۰،۰۲۰	۰،۹۵۲	۰،۹۸۲	۰،۰۲۱	۰،۹۶۲
	SVR-RSA	۹،۰۰۰	۰،۰۲۰	۴،۵۰۰	۰،۹۷۶	۰،۰۲۰	۰،۹۵۱	۰،۹۸۵	۰،۰۱۹	۰،۹۶۸
RT4	SVR-HOA	۹،۵۰۳	۰،۰۱۴	۴،۶۰۷	۰،۸۷۸	۰،۰۴۳	۰،۷۶۶	۰،۸۳۷	۰،۰۶۸	۰،۵۹۸
	SVR-RSA	۹،۰۰۰	۰،۰۲۰	۴،۵۰۰	۰،۸۷۴	۰،۰۴۴	۰،۷۵۸	۰،۸۴۸	۰،۰۶۸	۰،۵۹۶
RT5	SVR-HOA	۹،۶۴۳	۰،۰۱۳	۴،۶۷۷	۰،۹۷۶	۰،۰۱۹	۰،۹۵۲	۰،۹۸۶	۰،۰۲۰	۰،۹۶۴
	SVR-RSA	۹،۰۰۰	۰،۰۱۰	۴،۵۰۰	۰،۹۷۷	۰،۰۱۹	۰،۹۵۵	۰،۹۸۵	۰،۰۲۰	۰،۹۶۴
RT6	SVR-HOA	۹،۲۲۲	۰،۰۱۸	۴،۸۹۰	۰،۹۷۳	۰،۰۲۱	۰،۹۴۶	۰،۹۹۰	۰،۰۲۱	۰،۹۶۰
	SVR-RSA	۹،۲۲۲	۰،۰۱۸	۴،۸۹۰	۰،۹۷۳	۰،۰۲۱	۰،۹۴۶	۰،۹۹۰	۰،۰۲۱	۰،۹۶۰
RT7	SVR-HOA	۹،۴۸۳	۰،۰۱۴	۴،۵۹۷	۰،۹۲۹	۰،۰۳۳	۰،۸۶۳	۰،۹۲۷	۰،۰۴۰	۰،۸۶۰
	SVR-RSA	۹،۰۰۰	۰،۰۲۰	۴،۵۰۰	۰،۹۳۲	۰،۰۳۲	۰،۸۶۶	۰،۹۲۲	۰،۰۴۱	۰،۸۵۳
RT8	SVR-HOA	۹،۵۶۳	۰،۰۱۴	۴،۶۳۷	۰،۹۵۵	۰،۰۲۶	۰،۹۱۲	۰،۹۷۷	۰،۰۳۰	۰،۹۲۲
	SVR-RSA	۹،۴۸۳	۰،۰۱۴	۴،۵۹۷	۰،۹۵۵	۰،۰۲۶	۰،۹۱۲	۰،۹۷۵	۰،۰۳۰	۰،۹۱۹



شکل ۶. ضرایب دبی پیش‌بینی‌شده با الگوریتم SVM-HOA در مقابل ضرایب دبی آزمایشگاهی در مراحل آموزش و تست برای RT5 تحت سناریو ۲




شکل ۷. ضرایب دبی پیش‌بینی‌شده با الگوریتم SVM-RSA در مقابل ضرایب دبی آزمایشگاهی در مراحل آموزش و تست برای RT5 تحت سناریو ۲

نتایج حاصل از آنالیز حساسیت در شکل (۹) ارائه شده است که مطابق آن، در مدل RR2، پارامتر P/y_1 در پیش‌بینی ضریب دبی سرریزهای جانبی مستطیلی لبه تیز واقع در کانال اصلی مستطیلی دارای اهمیت بسیاری می‌باشد که حذف آن منجر به کاهش مقدار شاخص NSE در مرحله تست به ۰٫۶۹۸ می‌شود. در مدل RT5، پارامتر Fr_1 در پیش‌بینی ضریب دبی سرریزهای جانبی مستطیلی لبه تیز واقع در کانال اصلی دوزنقه‌ای دارای اهمیت بسیاری می‌باشد که حذف آن منجر به کاهش مقدار شاخص NSE در مرحله تست به ۰٫۵۴۵ می‌شود.

نتیجه‌گیری

در این پژوهش، ضریب دبی سرریزهای جانبی مستطیلی لبه‌تیز در دو نوع کانال اصلی مستطیلی و دوزنقه‌ای مدل‌سازی شد. متغیرهای بی‌بعد مؤثر شناسایی و با استفاده از مدل‌های مبتنی بر SVM بهینه‌شده، پیش‌بینی C_d در هر یک از شرایط هندسی انجام گردید. نتایج نشان داد که هندسه کانال نقش تعیین‌کننده‌ای در پیش‌بینی ضریب دبی دارد. در کانال مستطیلی، مدل SVM-HOA با ورودی‌های نظیر نسبت ارتفاع سرریز به عمق جریان ابتدایی (P/y_1)، نسبت طول تاج سرریز به عرض کف کانال (L/B)، سبب طول تاج به عمق جریان (L/y_1) و عدد فرود بالادست (Fr_1)، دقت مناسبی ارائه کرد ($R=0.953$ ، $RMSE=0.063$ ، $NSE=0.904$) و تحلیل حساسیت نشان داد که نسبت P/y_1 بیشترین اثر را دارد. در مقابل، در کانال دوزنقه‌ای، مدل SVM-HOA با ورودی‌های L/B ، Fr_1 ، y_1/B و شیب دیواره کانال (m) دقت بالاتری نشان داد ($R=0.986$ ، $RMSE=0.020$ ، $NSE=0.964$) و پارامتر غالب بود که وابستگی بیشتر به ویژگی‌های جریان را تأیید می‌کند. تحلیل حساسیت انجام‌شده نقش کلیدی این پارامترهای هندسه محور را تأیید کرد که راهنمایی برای طراحی بهینه سرریزها ارائه می‌دهد. این مطالعه با موفقیت تفاوت‌های ناشی از هندسه کانال را بازتولید کرد و بر ضرورت در نظر گرفتن پارامترهای خاص هر هندسه در طراحی سرریزها تأکید می‌کند. پیشنهاد می‌شود بررسی جریان مستغرق و استفاده از الگوریتم‌های بهینه‌سازی دیگر در تحقیقات آینده مدنظر قرار گیرد.




شکل ۸. نمودار تیلور برای TB8 تحت سناریو ۲

علاوه بر این، در شکل (۸) از نمودار تیلور برای تجزیه و تحلیل الگوریتم‌های SVR-HOA و SVR-RSA بر روی مدل برتر استفاده شد که مطابق نمودار، الگوریتم SVM-HOA با اختلاف جزئی پیش‌بینی دقیق‌تری انجام می‌دهد.

آنالیز حساسیت مدل برتر

جهت بررسی تأثیر پارامترهای ورودی به‌کاررفته در پیش‌بینی ضریب دبی، از آنالیز حساسیت در مدل‌های برتر سرریزهای جانبی استفاده گردید. بدین منظور با حذف تک‌تک پارامترهای ورودی مدل برتر و اجرای دوباره مدل با الگوریتم SVM-HOA و تعیین معیار ارزیابی NSE، میزان تأثیر پارامتر حذف‌شده در کاهش دقت مدل موردبررسی قرار گرفت.



شکل ۹. نتایج آنالیز حساسیت مدل برتر برای سرریزهای جانبی در مراحل آموزش و تست تحت الف) سناریو ۱ ب) سناریو ۲

Reference:

- Abdollahi, A., Kabiri-Samani, A., Asghari, K., Atoof, H., & Bagheri, S. (2017). Numerical modeling of flow field around the labyrinth side-weirs in the presence of guide vanes. *ISH Journal of Hydraulic Engineering*, 23(1), 71–79. <https://doi.org/10.1080/09715010.2016.1239555>
- Abualigah, L., Abd Elaziz, M., Sumari, P., Geem, Z. W., & Gandomi, A. H. (2022). Reptile Search Algorithm (RSA): A nature-inspired meta-heuristic optimizer. *Expert Systems with Applications*, 191, 116158. <https://doi.org/10.1016/j.eswa.2021.116158>
- Agrawal, S. K. (1989). *Elementary Discharge Coefficient of Rectangular Side Weirs*. Roorkee Univ Roorkee, India.
- Azamathulla, H. M., Haghiabi, A. H., & Parsaie, A. (2016). Prediction of side weir discharge coefficient by support vector machine technique. *Water Science and Technology: Water Supply*, 16(4), 1002–1016. <https://doi.org/10.2166/ws.2016.014>
- Azimi, H., Bonakdari, H., & Ebtehaj, I. (2017). Sensitivity analysis of the factors affecting the discharge capacity of side weirs in trapezoidal channels using extreme learning machines. *Flow Measurement and Instrumentation*, 54, 216–223. <https://doi.org/10.1016/j.flowmeasinst.2017.02.005>
- Azimi, H., Shabanlou, S., & Salimi, M. S. (2014). Free surface and velocity field in a circular channel along the side weir in supercritical flow conditions. *Flow Measurement and Instrumentation*, 38, 108–115. <https://doi.org/10.1016/j.flowmeasinst.2014.05.013>
- Bagheri, S., Kabiri-Samani, A. R., & Heidarpour, M. (2014). Discharge coefficient of rectangular sharp-crested side weirs Part II: Domínguez's method. *Flow Measurement and Instrumentation*, 35, 116–121. <https://doi.org/10.1016/j.flowmeasinst.2013.10.006>
- Balahang, S., & Ghodsian, M. (2024). Enhancing rectangular side weir discharge prediction using stacking technique. *Flow Measurement and Instrumentation*, 97, 102622. <https://doi.org/10.1016/j.flowmeasinst.2024.102622>
- Biggiero, V., Longobardi, D., & Pianese, D. (1994). Indagine sperimentale su sfioratori laterali a soglia bassa. *Giornale Del Genio Civile*, 132(7–8–9), 183–199.
- Bilhan, O., Emiroglu, M. E., & Kisi, O. (2010). Application of two different neural network techniques to lateral outflow over rectangular side weirs located on a straight channel. *Advances in Engineering Software*, 41(6), 831–837. <https://doi.org/10.1016/j.advengsoft.2010.03.001>
- Borghai, S. M., Jalili, M. R., & Ghodsian, M. (1999). Discharge coefficient for sharp-crested side weir in subcritical flow. *Journal of Hydraulic Engineering*, 125(10), 1051–1056. [https://doi.org/10.1061/\(ASCE\)0733-9429\(1999\)125:10\(1051\)](https://doi.org/10.1061/(ASCE)0733-9429(1999)125:10(1051))
- Cheong, H.-F. (1991). Discharge coefficient of lateral diversion from trapezoidal channel. *Journal of Irrigation and Drainage Engineering*, 117(4), 461–475. [https://doi.org/10.1061/\(ASCE\)0733-9437\(1991\)117:4\(461\)](https://doi.org/10.1061/(ASCE)0733-9437(1991)117:4(461))
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273–297. <https://doi.org/10.1007/Bf00994018>
- Dhar, M., Sapkota, S. C., Saha, P., & Arora, S. (2025). Evaluating Discharge Coefficient of Rectangular Sharp Crested Weirs Using Machine Learning Models. *Water Resources Management*, 39(8), 4151–4171. <https://doi.org/10.1007/s11269-025-04152-3>
- Ebtehaj, I., Bonakdari, H., Zaji, A. H., Azimi, H., & Khoshbin, F. (2015). GMDH-type neural network approach for modeling the discharge coefficient of rectangular sharp-crested side weirs. *Engineering Science and Technology, an International Journal*, 18(4), 746–757. <https://doi.org/10.1016/j.jestch.2015.04.012>
- El-Khashab, A., & Smith, K. V. H. (1976). Experimental investigation of flow over side weirs. *Journal of the Hydraulics Division*, 102(9), 1255–1268. <https://doi.org/10.1061/JYCEAJ.0004610>
- Emiroglu, M. E., Agaccioglu, H., & Kaya, N. (2011). Discharging capacity of rectangular side weirs in straight open channels. *Flow Measurement and Instrumentation*, 22(4), 319–330. <https://doi.org/10.1016/j.flowmeasinst.2011.04.003>
- Ghaderi, A., Dasineh, M., Abbasi, S., & Abraham, J. (2020). Investigation of trapezoidal sharp-crested side weir discharge coefficients under subcritical flow regimes using CFD. *Applied Water Science*, 10(1), 1–12. <https://doi.org/10.1007/s13201-019-1112-8>
- Granata, F., Gargano, R., & Santopietro, S. (2016). A flow field characterization in a circular channel along a side weir. *Flow Measurement and Instrumentation*, 52, 92–100. <https://doi.org/10.1016/j.flowmeasinst.2016.09.011>
- Hager, W. H. (1994). Supercritical Flow in Circular-Shaped Side Weir. *Journal of Irrigation and Drainage Engineering*, 120(1), 1–12. [https://doi.org/10.1061/\(ASCE\)0733-9437\(1994\)120:1\(1\)](https://doi.org/10.1061/(ASCE)0733-9437(1994)120:1(1))
- Hien, L. T. T., Van Chien, N., & Xuan-Hien, L. (2024). Advanced hybrid techniques for predicting discharge coefficients in ogee-crested spillways: integrating physical, numerical, and machine learning models. *Environmental Research Communications*, 6(11), 115002. <https://doi.org/10.1088/2515-7620/ad8a24>
- Jalili, M. R., & Borghai, S. M. (1996). Discussion: discharge coefficient of rectangular side weirs. *Journal of*

- Irrigation and Drainage Engineering*, 122(2), 132. [https://doi.org/10.1061/\(ASCE\)0733-9437\(1996\)122:2\(132\)](https://doi.org/10.1061/(ASCE)0733-9437(1996)122:2(132))
- Khoshbin, F., Bonakdari, H., Ashraf Talesh, S. H., Ebtehaj, I., Zaji, A. H., & Azimi, H. (2016). Adaptive neuro-fuzzy inference system multi-objective optimization using the genetic algorithm/singular value decomposition method for modelling the discharge coefficient in rectangular sharp-crested side weirs. *Engineering Optimization*, 48(6), 933–948. <https://doi.org/10.1080/0305215X.2015.1071807>
- MiarNaeimi, F., Azizyan, G., & Rashki, M. (2021). Horse herd optimization algorithm: A nature-inspired algorithm for high-dimensional optimization problems. *Knowledge-Based Systems*, 213, 106711. <https://doi.org/10.1016/j.knosys.2020.106711>
- Raju, K. G. R., Gupta, S. K., & Prasad, B. (1979). Side Weir in Rectangular Channel. *Journal of the Hydraulics Division*, 105(5), 547–554. <https://doi.org/10.1061/JYCEAJ.0005207>
- Roushangar, K., Khoshkanar, R., & Shiri, J. (2016). Predicting trapezoidal and rectangular side weirs discharge coefficient using machine learning methods. *ISH Journal of Hydraulic Engineering*, 22(3), 254–261. <https://doi.org/10.1080/09715010.2016.1177740>
- Roushangar, K., Saadatjoo, R., Abbaszadeh, H., & Panahi, A. (2024a). Estimation of air concentration in chute spillway using metamodel methods. *Iranian Journal of Soil and Water Research*, 55(4), 601–613. DOI: <https://doi.org/10.22059/ijswr.2024.370643.669640> [in Persian].
- Roushangar, K., Abbaszadeh, H., Saadatjoo, R. and Panahi, A. (2024b). Prediction of Air Concentration in Stepped Spillways Using Data-Oriented Methods. *Environment and Water Engineering*, 11(3), 316-325. DOI: <https://doi.org/10.22034/ewe.2024.433409.1905>
- Saffar, S., Babarsad, M. S., Shooshtari, M. M., & Riazi, R. (2021). Prediction of the discharge of side weir in the converge channels using artificial neural networks. *Flow Measurement and Instrumentation*, 78, 101889. <https://doi.org/10.1016/j.flowmeasinst.2021.101889>
- Seyedian, S. M., & Kisi, O. (2024). Uncertainty analysis of discharge coefficient predicted for rectangular side weir using machine learning methods. *Journal of Hydrology and Hydromechanics*, 72(1), 113-130. <https://doi.org/10.2478/johh-2023-0043>
- Subramanya, K., & Awasthy, S. C. (1972). Spatially varied flow over side-weirs. *Journal of the Hydraulics Division*, 98(1), 1–10. <https://doi.org/10.1061/JYCEAJ.0003188>

یادداشت‌ها

¹ Subramanya and Awasthy² Raju³ Bilhan⁴ Azamathulla⁵ Dhar⁶ Agrawal⁷ Emiroglu⁸ Cheong