

مقاله علمی-پژوهشی

برآورد ضریب دبی در سرریزهای جانبی مثلثی و دوزنقه‌ای با استفاده از مدل یادگیری ترکیبی

SVM بهینه‌شده با الگوریتم‌های HOA و RSA

کیومرث روشنگر^{۱*} و آیدین پناهی^۲

تاریخ دریافت: ۱۴۰۴/۰۲/۲۶ تاریخ پذیرش: ۱۴۰۴/۰۵/۲۵

چکیده

سرریزهای جانبی به‌عنوان اجزای کلیدی در تنظیم جریان و اندازه‌گیری آب، نقشی محوری در سامانه‌های مدیریت سیلاب، جمع‌آوری رواناب‌های شهری و شبکه‌های آبیاری و زهکشی ایفا می‌کنند. پیش‌بینی دقیق ضریب دبی این سرریزها برای طراحی بهینه، ضرورتی انکارناپذیر است. در این مطالعه، به‌منظور مدل‌سازی دقیق‌تر ضریب دبی در سرریزهای جانبی دوزنقه‌ای لبه تیز، دوزنقه‌ای با لبه پهن و مثلثی لبه تیز، از ترکیب روش ماشین بردار پشتیبان (SVM) با دو الگوریتم متاهیوریستیک یعنی الگوریتم بهینه‌سازی اسب (HOA) و جستجوی خزندگان (RSA) بهره گرفته شده است. پس از شناسایی متغیرهای بی‌بعد مؤثر، مدل‌های متعددی برای هر هندسه توسعه داده شد. یافته‌ها نشان می‌دهد که هر دو مدل ترکیبی توانایی مناسبی در تخمین ضریب دبی دارند، اما SVM-HOA در مرحله تست، دقت بالاتری از خود نشان داد. به‌طور خاص، در سرریز دوزنقه‌ای لبه تیز، دوزنقه‌ای لبه پهن و مثلثی لبه تیز به ترتیب ضرایب NSE، RMSE و R معادل (۰.۹۱۳، ۰.۰۱۹، ۰.۹۵۹)، (۰.۹۳۳، ۰.۰۱۴، ۰.۹۶۶) و (۰.۹۳۲، ۰.۰۱۵، ۰.۹۶۷) به دست آمد که نشان‌دهنده برتری این مدل نسبت به SVM-RSA در تمام هندسه‌ها است.

واژه‌های کلیدی: الگوریتم‌های فرا ابتکاری، آنالیز حساسیت، سرریز جانبی، ضریب دبی، یادگیری ماشین

مقدمه

آن برای پیش‌بینی میزان جریان و شکل‌گیری سطح آزاد آب در طول سرریز اهمیت فراوانی دارد. این ضریب تحت تأثیر پارامترهای متعددی از جمله ویژگی‌های هندسی سرریز و کانال، شرایط جریان بالادست و پایین‌دست، و نیز شکل مقطع و شیب بستر کانال می‌باشد. یافته‌های آزمایشگاهی نشان می‌دهد که مقدار C_d در طول مسیر سرریز، ثابت نبوده و دستخوش تغییراتی می‌شود (Granata et al., 2016).

کومار و پاتک سرریز جانبی لبه تیز مثلثی را در شرایط زیربحرانی مطالعه نمودند و روابط ضریب دبی برای زوایای رأس ۶۰، ۹۰ و ۱۲۰ درجه ارائه دادند (Kumar & Pathak, 1987). کوشار و آقاجیوگلو سرریزهای جانبی مثلثی در کانال‌های مستقیم و خمیده را بررسی کردند و نشان دادند که ضرایب دبی در کانال‌های خمیده بیشتر از کانال‌های مستقیم است (Coşar & Agaccioglu, 2004). قدسیان با مطالعه آزمایشگاهی مشخصه‌های هیدرولیکی سرریزهای جانبی لبه تیز مثلثی، نشان داد که ضریب دبی به عدد فرود کانال اصلی، زاویه رأس سرریز و نسبت ارتفاع سرریز به عمق بالادست جریان بستگی دارد (Ghodsian, 2004). رحیم‌پور و همکاران با بررسی جریان بر روی سرریزهای جانبی دوزنقه‌ای لبه تیز، رابطه‌ای را برای ضریب دبی

سرریزهای جانبی به‌عنوان اجزای کلیدی در سامانه‌های هیدرولیکی، وظیفه هدایت و تنظیم جریان را در امتداد دیواره‌های جانبی کانال‌های اصلی بر عهده‌دارند. این نوع سازه‌ها در پروژه‌های متنوعی نظیر شبکه‌های آبیاری و زهکشی، سامانه‌های مدیریت رواناب شهری و همچنین تأسیسات تصفیه آب، نقش مهمی ایفا می‌کنند (Abdollahi et al., 2017). تحلیل عملکرد این سرریزها از دیدگاه هیدرولیکی، با استفاده از رویکردهای مختلفی همچون مدل تعادل انرژی، قانون اندازه حرکت، روابط تجربی و شبیه‌سازی‌های عددی CFD انجام می‌پذیرد (Azimi et al., 2014; Biggiero et al., 1994; El-Khashab & Smith, 1976; Hager, 1994). شاخص اصلی در این تحلیل‌ها، ضریب دبی (C_d) است. برآورد دقیق

۱- استاد، گروه مهندسی منابع آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

۲- دانشجوی دکتری، گروه مهندسی منابع آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

(* نویسنده مسئول: (Email: roshangari@tabrizu.ac.ir)

ارائه دادند (Rahimpour et al., 2011). حدادی و رحیم‌پور به بررسی آزمایشگاهی سرریز جانبی لبه پهن دوزنقه‌ای با شیب‌های ۱، ۱.۵ و ۲ واقع در کانال مستطیلی پرداختند. آن‌ها نشان دادند که ضریب دبی تابعی از عدد فرود بالادست سرریز، نسبت ارتفاع تاج سرریز به عمق جریان در بالادست سرریز، عرض کانال اصلی به عمق جریان در بالادست سرریز، طول تاج سرریز به عرض کانال اصلی و پهنا سرریز به عرض کانال اصلی می‌باشد (Haddadi & Rahimpour, 2012). ولایتی و وطن‌خواه (۱۳۹۸) با مطالعه‌ی آزمایشگاهی سرریزهای جانبی دوزنقه‌ای لبه پهن و با استفاده از روش عددی، نشان دادند که ضریب دبی به عدد فرود بالادست، نسبت عمق جریان به پهنا تاج سرریز و شیب جداره جانبی سرریز بستگی دارد. چن و همکاران با استفاده از CFD جریان سرریز جانبی کنگره‌ای مثلثی را تحلیل کردند و مدل BELM را برای پیش‌بینی ضریب دبی ارائه دادند. نتایج آن‌ها نشان داد که تغییرات جریان اصلی و جریان ثانویه در نزدیکی سرریز قابل‌توجه است (Shen et al., 2024). نامدار و همکاران (۱۴۰۳) با شبیه‌سازی عددی در Fluent، تأثیر زاویه رأس، ارتفاع و بار آبی بر ضریب دبی سرریز جانبی دوزنقه‌ای را بررسی کردند. نتایج آن‌ها نشان داد که ضریب دبی به ترکیبی از پارامترهای هندسی و هیدرولیکی وابسته است و شبیه‌سازی‌ها با داده‌های آزمایشگاهی مطابقت خوبی دارند.

در سال‌های اخیر، روش‌های محاسبات نرم و هوش مصنوعی برای حل مسائل پیچیده در علوم مختلف استفاده شده است. این روش‌ها نسبت به روابط تجربی و روش‌های سنتی دارای برتری‌هایی نظیر دقت بالاتر، قابلیت تعمیم بهتر، توانایی در تحلیل داده‌های بزرگ و پیچیده و کاهش زمان و هزینه‌های محاسباتی می‌باشند. بیلهان و همکاران قابلیت شبکه عصبی پیشرو (FFNN) و شبکه عصبی پایه شعاعی (RBNN) را برای تخمین ضریب دبی سرریز جانبی در یک کانال مستطیل شکل ارزیابی کردند. آن‌ها نشان دادند که روش FFNN دقیق‌تر از روش RBNN است (Bilhan et al., 2010). کیشی و همکاران با استفاده از شبکه عصبی پایه شعاعی (RBNN)، شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) و برنامه‌ریزی بیان ژن (GEP)، ضریب دبی سرریز جانبی کنگره‌ای مثلثی را پیش‌بینی نمودند. هم‌چنین نتیجه‌گیری نمودند که این روش‌ها در مقایسه با مدل‌های رگرسیون خطی چندگانه (MLR) و رگرسیون غیرخطی (NLR) می‌توانند با موفقیت در مدل‌سازی ضریب دبی مورد استفاده قرار گیرند (Kisi et al., 2012). امیراوغلو و کیشی نیز نشان دادند که روش ANFIS در پیش‌بینی ضریب دبی سرریز جانبی کنگره‌ای دوزنقه‌ای، دقیق‌تر از شبکه عصبی مصنوعی (ANN)، روش‌های NLR و MLR عمل می‌کند (Emiroglu & Kisi, 2013). روشنگر و همکاران برای پیش‌بینی ضریب دبی سرریزهای جانبی لبه تیز دوزنقه‌ای و مستطیلی شکل، روش ماشین بردار پشتیبان را توسط

مواد و روش‌ها

ضریب دبی سرریزهای جانبی

متغیرهای مؤثر بر ضریب دبی سرریزهای جانبی دوزنقه‌ای لبه تیز، دوزنقه‌ای لبه پهن و مثلثی لبه تیز به ترتیب به صورت روابط (۱)، (۲) و (۳) بیان می‌شوند (Ghaderi et al., 2020):

$$C_d = f(y_1, B, L, P, T, z, Fr_1, Re, We, S_0) \quad (1)$$

$$C_d = f(y_1, B, L, P, T, t, z, Fr_1, Re, We, S_0) \quad (2)$$

$$C_d = f(y_1, B, P, T, Fr_1, Re, We, S_0) \quad (3)$$

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، z شیب جداره سرریز جانبی دوزنقه‌ای و مثلثی، T طول سطح آبگذری روی سرریز جانبی دوزنقه‌ای و مثلثی، t پهنا تاج سرریز لبه پهن، Re عدد رینولدز، We عدد وبر و S_0 شیب بستر کانال اصلی است.

برقعی و همکاران در آزمایش‌های خود نشان دادند که تأثیر شیب

و عسکری و وطن‌خواه استفاده شده است که رژیم جریان در آن‌ها زیربحرانی می‌باشد (عسکری و وطن‌خواه، ۱۳۹۸؛ ولایتی و وطن‌خواه، ۱۳۹۸). آزمایش‌های آن‌ها شامل یک کانال اصلی با طول ۱۲ متر، عرض ۰.۲۵ متر و ارتفاع ۰.۵ متر است که شیب کانال متغیر بوده و سرریز جانبی دوزنقه‌ای لبه پهن در فاصله‌ی شش متری از ابتدای کانال نصب گردیده است. شایان‌ذکر است که سرریزهای جانبی مورد استفاده در تحقیق عسکری و وطن‌خواه از نوع دوزنقه‌ای لبه پهن با تاج و کناره‌های نیم‌دایره است.

سناریو سوم نیز مربوط به سرریزهای جانبی مثلثی لبه تیز است که از ۱۳۸ داده‌ی آزمایشگاهی ارائه شده توسط کومار و موهان با رژیم جریان زیربحرانی استفاده شده است (Kumar, 1985; Mohan, 1987). آزمایش آن‌ها بر روی سرریزهای جانبی مثلثی لبه تیز در آزمایشگاه هیدرولیک دانشگاه روئورکی هند انجام شد که کانال اصلی با شیب ۰.۳ درصد دارای ۹ متر طول، ۰.۵ متر عرض و ۰.۸ ارتفاع بود. طرح شماتیک آزمایشگاهی این آزمایش‌ها در شکل (۱) ارائه شده است.

هم‌چنین محدوده مشخصات هیدرولیکی و هندسی مقادیر هر یک از این سناریوها در جدول (۱) 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، SVM‌ها کمتر مستعد بیش برآزش هستند که به آن‌ها امکان می‌دهد نتایج قابل اطمینان‌تری ارائه دهند. نوعی از یادگیری ماشین نظارت شده 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 برآزش در برابر داده‌های تست نیز بهتر عمل می‌کند.

کانال اصلی بر ضریب دبی ناچیز است (Borgheti et al., 1999). 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 (Ghadery et al., 2020). علاوه بر این، برای بی‌بعد نمودن پارامترهای معرفی شده و در نظر گرفتن سایر پارامترهای بی‌بعد مؤثر بر ضریب دبی، معادلات بالا به صورت روابط (۴)، (۵) و (۶) نوشته شدند:

$$C_d = f\left(\frac{P}{y_1}, \frac{y_1}{B}, \frac{T}{B}, \frac{T}{L}, \frac{h_1}{T}, z, Fr_1, Fr_2\right) \quad (4)$$

$$C_d = f\left(\frac{P}{y_1}, \frac{B}{T}, \frac{T}{L}, \frac{t}{y_1}, z, Fr_1, Fr_2\right) \quad (5)$$


$$C_d = f\left(\frac{P}{y_1}, \frac{T}{B}, \frac{h_1}{T}, \frac{y_1}{y_2}, z, Fr_1, Fr_2\right) \quad (6)$$

که در آن، h_1 عمق جریان روی تاج سرریز جانبی، y_2 عمق جریان در انتهای سرریز جانبی و Fr_2 عدد فرود پایین دست سرریز جانبی است.

گردآوری داده‌های مورد استفاده

برای پیش‌بینی ضریب دبی سرریزهای جانبی مثلثی و دوزنقه‌ای از سه سناریوی مختلف استفاده شد. در سناریو اول که مربوط به سرریزهای جانبی دوزنقه‌ای لبه تیز است از ۲۹۹ داده‌ی آزمایشگاهی ارائه شده توسط پاندی با رژیم جریان زیربحرانی و تاینس با رژیم جریان به دو صورت زیربحرانی و فوق بحرانی استفاده شده است (Pandey, 1985; Tynes, 1989). آزمایش پاندی شامل یک کانال اصلی با عرض ۰.۵ متر، طول ۹ متر، عمق ۰.۸ متر و شیب بستر ۰.۳ درصد و یک کانال جانبی با زاویه ۹۰ درجه نسبت به کانال اصلی و تقریباً در وسط طول آن بود. مدل آزمایشی تاینس شامل یک کانال مستطیلی با شیب بستر ۰.۰۰۰۳ به طول ۱۹.۸۱ متر، عرض‌های ۰.۵۴ و ۱.۰۳ متری بود.

در سناریو دوم که مربوط به سرریزهای جانبی دوزنقه‌ای لبه پهن است از ۳۹۰ داده‌ی آزمایشگاهی ارائه شده توسط ولایتی و وطن‌خواه



شکل ۱- شماتیک سرریزهای جانبی مورد مطالعه: الف) دوزنقه‌ای لبه تیز ب) دوزنقه‌ای لبه پهن ج) مثلثی لبه تیز

جدول ۱- دامنه مقادیر آزمایشگاهی در سناریوهای تحقیق

trapezoidal sharp-crested side weirs										
	y_1 (m)	B (m)	L (m)	P (m)	h_1 (m)	T (m)	z	Fr ₁	Fr ₂	C _d
Min	۰.۱۰۳	۰.۵۰۰	۰.۱۰۰	۰.۰۴۹	۰.۰۰۶	۰.۱۴۲	۰.۲۶۸	۰.۱۰۷	۰.۰۱۸	۰.۳۴۴
Max	۰.۴۴۸	۱.۰۳۶	۷.۲۸۸	۰.۲۱۳	۰.۴۰۰	۷.۵۳۲	۲.۵۰۰	۱.۴۱۳	۱.۲۱۳	۰.۹۴۷
Ave	۰.۲۲۹	۰.۷۴۴	۲.۵۵۵	۰.۱۵۹	۰.۰۷۰	۲.۷۹۴	۲.۱۱۶	۰.۵۸۶	۰.۳۹۷	۰.۵۹۵
trapezoidal broad-crested side weirs										
	y_1 (m)	B (m)	L (m)	P (m)	T (m)	t (m)	z	Fr ₁	Fr ₂	C _d
Min	۰.۰۸۳	۰.۲۵۰	۰.۲۰۰	۰.۰۵۰	۰.۲۲۶	۰.۰۰۰	۰.۵۰۰	۰.۱۹۲	۰.۰۸۹	۰.۲۰۸
Max	۰.۲۸۲	۰.۲۵۰	۰.۲۵۰	۰.۱۵۰	۰.۴۴۳	۰.۰۸۰	۱.۰۰۰	۰.۹۶۸	۰.۵۷۲	۰.۷۲۰
Ave	۰.۱۷۲	۰.۲۵۰	۰.۲۲۶	۰.۱۰۵	۰.۳۲۵	۰.۰۶۰	۰.۷۱۰	۰.۴۵۳	۰.۲۶۱	۰.۶۱۱
triangular sharp-crested side weirs										
	y_1 (m)	y_2 (m)	B (m)	P (m)	h_1 (m)	T (m)	z	Fr ₁	Fr ₂	C _d
Min	۰.۱۵۵	۰.۱۵۶	۰.۵۰۰	۰.۰۶۰	۰.۰۹۵	۰.۱۴۸	۰.۵۷۷	۰.۰۸۶	۰.۰۰۶	۰.۴۳۷
Max	۰.۴۶۷	۰.۴۷۲	۰.۵۰۰	۰.۲۴۲	۰.۴۰۶	۰.۵۳۲	۱.۷۳۲	۰.۶۸۸	۰.۵۴۱	۰.۷۸۶
Ave	۰.۲۶۷	۰.۲۷۲	۰.۵۰۰	۰.۰۷۶	۰.۱۸۹	۰.۳۵۰	۱.۰۳۱	۰.۳۱۴	۰.۲۰۳	۰.۵۸۵

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

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. در این پژوهش، برای دستیابی به مقادیر بهینه ابر پارامترهای SVM، از دو الگوریتم فرا ابتکاری نوین HOA و RSA استفاده شد. الگوریتم‌های فرا ابتکاری بر مبنای رفتارهای طبیعی و جمعی موجودات زنده یا فرآیندهای فیزیکی/ریاضیاتی الهام گرفته شده و با ترکیب جستجوی محلی و سراسری، قادر به یافتن بهینه‌های سراسری مسائل پیچیده هستند. الگوریتم HOA با شبیه‌سازی رفتار جمعی اسب‌ها، تعادل مناسبی بین اکتشاف و بهره‌برداری ایجاد می‌کند و می‌تواند از بهینه‌های محلی عبور کند. الگوریتم RSA نیز از رفتار شکار خزندگان الهام گرفته و در مسائل غیرخطی، همگرایی سریع و پایدار به نقاط بهینه را فراهم می‌کند. انتخاب این دو الگوریتم نه تنها به دلیل نو بودن و عدم کاربرد پیشین در پیش‌بینی ضریب دبی سرریزهای جانبی است، بلکه توانایی آن‌ها در مدیریت پیچیدگی‌های غیرخطی، کاهش احتمال بیش برآزش و دستیابی به نتایج پایدار و قابل اعتماد، آن‌ها را نسبت به الگوریتم‌های کلاسیک مانند PSO (MiarNaeimi et al., 2021; Abualigah et al.) متمایز می‌سازد.

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 (Roushangar et al., 2024). 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 به‌صورت $XY = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ می‌باشند به‌گونه‌ای که n تعداد داده‌های آموزش است. هدف نهایی در SVM یافتن رابطه (Y) میان بردارهای ورودی $x \in R_n$ و متغیرهای خروجی $y \in R$ است.

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

که w و b 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 بهینه‌سازی از تکنیک لاگرانژ استفاده می‌شود و در نهایت تابع رگرسیون به‌صورت زیر قابل محاسبه است:

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).

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

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

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

هم‌چنین rand مقدار تصادفی بین صفر و یک، LB و UB کران پایین و بالای مسئله داده شده است. (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٪ برای آموزش در مقابل ۲۰٪ برای تست تفکیک می‌شوند. در مرحله پیش‌پردازش، مقادیر پرت از مجموعه داده حذف شدند و با توجه به یکنواختی توزیع داده‌ها، نرمال‌سازی انجام نگرفت. برای جلوگیری از بیش‌برازش از روش اعتبار سنجی متقابل 10-fold استفاده می‌شود. در روش اعتبار سنجی 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. شایان‌ذکر است که برای توسعه مدل‌های مختلف SVM-HOA و SVM-RSA از 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.

(al., 2022). شایان‌ذکر 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 به‌صورت 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، درحالی‌که 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 (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



شکل ۲- مدل‌های ورودی برای پیش‌بینی ضریب دبی سرریزهای جانبی با استفاده از پارامترهای بی‌بعد مؤثر: الف) دوزنقه‌ای لبه تیز ب) دوزنقه‌ای لانه پهن ج) مثلثی لانه تیز

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. شایان ذکر است که مدلی مطلوب است که مقدار R و NSE آن به یک و مقدار RMSE آن به صفر نزدیک باشد (روشنگر و همکاران، ۱۴۰۳). معادلات (۱۵)، (۱۶) و (۱۷) به ترتیب R، RMSE و NSE را توصیف می‌کنند:

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

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

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

در روابط بالا Y_i ضرایب دبی مشاهداتی، \bar{Y} میانگین ضرایب دبی مشاهداتی، \hat{Y}_i ضرایب دبی پیش‌بینی شده، $\bar{\hat{Y}}$ میانگین ضرایب دبی پیش‌بینی شده و N تعداد کل داده‌ها می‌باشد.

یافته‌ها و بحث

در این مطالعه، مدل SVM بهینه برای پیش‌بینی ضریب دبی سرریزهای جانبی پیشنهاد شد که پارامترهای تنظیم شده برای اجرای مدل‌های بهینه‌سازی SVM-HOA و SVM-RSA در جدول (۲) ارائه شده است. در فرآیند بهینه‌سازی، حداکثر تعداد تکرار برابر با ۱۰ و اندازه جمعیت برابر با ۵ در نظر گرفته شد. این مقادیر بر اساس آزمون‌های مقدماتی انتخاب شدند تا با حداقل هزینه محاسباتی، همگرایی سریع و مطلوب در مقدار تابع برازش (RMSE) حاصل شود.

جدول ۲- مقادیر پارامترهای تنظیم شده برای اجرای مدل‌های SVM-HOA و SVM-RSA در هر سناریو

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


نتایج تحت سناریو ۱

در سناریو اول که مربوط به سرریزهای جانبی دوزنقه‌ای لبه تیز است، ۲۹۹ داده آزمایشگاهی با نسبت ۸۰٪ برای آموزش در مقابل ۲۰٪ برای تست انتخاب شدند. در جدول (۳) 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 TS7 به‌عنوان مدل برتر برگزیده می‌شود که مقادیر NSE، RMSE و R در الگوریتم SVM-HOA به ترتیب برابر ۰.۹۱۳، ۰.۰۱۹ و ۰.۹۵۹ و در الگوریتم SVM-RSA به ترتیب برابر ۰.۸۹۲، ۰.۰۲۲ و ۰.۹۴۷ می‌باشد.

جدول ۳- نتایج حاصل از روش‌های SVM-HOA و SVM-RSA برای پیش‌بینی ضریب دبی تحت سناریو ۱

Model	Method	Optimal value			Training stage			Testing stage		
		C	ϵ	σ	NSE	RMSE	R	NSE	RMSE	R
TS1	SVM-HOA	۲۷۱.۹۳۰	۰.۰۰۷	۲.۶۰۴	۰.۹۹۰	۰.۰۰۹	۰.۹۹۵	۰.۷۶۱	۰.۰۳۲	۰.۸۹۰
	SVM-RSA	۴۵۰.۰۰۰	۰.۰۱۰	۲.۵۰۰	۰.۹۸۵	۰.۰۱۱	۰.۹۹۳	۰.۷۰۰	۰.۰۳۶	۰.۴۶۶
TS2	SVM-HOA	۲۷۱.۹۳۰	۰.۰۰۷	۲.۶۰۴	۰.۹۷۶	۰.۰۱۴	۰.۹۸۸	۰.۸۷۷	۰.۰۲۳	۰.۹۴۲
	SVM-RSA	۴۵۰.۰۰۰	۰.۰۱۰	۲.۵۰۰	۰.۹۷۸	۰.۰۱۴	۰.۹۸۹	۰.۸۱۱	۰.۰۲۸	۰.۹۱۵
TS3	SVM-HOA	۲۷۱.۹۳۱	۰.۰۰۷	۲.۶۰۴	۰.۹۸۶	۰.۰۱۱	۰.۹۹۳	۰.۷۶۳	۰.۰۳۲	۰.۸۸۹
	SVM-RSA	۴۵۰.۰۰۰	۰.۰۱۰	۲.۹۶۷	۰.۹۸۳	۰.۰۱۲	۰.۹۹۲	۰.۷۳۶	۰.۰۳۴	۰.۸۷۵
TS4	SVM-HOA	۲۷۱.۹۳۱	۰.۰۰۷	۲.۶۰۴	۰.۹۸۹	۰.۰۰۹	۰.۹۹۵	۰.۷۶۶	۰.۰۳۲	۰.۸۹۵
	SVM-RSA	۴۵۰.۰۰۰	۰.۰۱۰	۲.۵۰۰	۰.۹۸۶	۰.۰۱۱	۰.۹۹۳	۰.۷۰۹	۰.۰۳۵	۰.۸۷۵
TS5	SVM-HOA	۲۷۱.۹۳۱	۰.۰۰۷	۲.۶۰۴	۰.۹۸۲	۰.۰۱۲	۰.۹۹۱	۰.۷۷۲	۰.۰۳۱	۰.۸۹۶
	SVM-RSA	۱۰۰.۰۰۰	۰.۰۱۰	۲.۵۰۰	۰.۹۷۶	۰.۰۱۴	۰.۹۸۸	۰.۷۶۲	۰.۰۳۲	۰.۵۱۸
TS6	SVM-HOA	۲۷۱.۹۳۱	۰.۰۰۷	۲.۶۰۴	۰.۹۷۱	۰.۰۱۶	۰.۹۸۶	۰.۸۶۳	۰.۰۲۴	۰.۹۳۵
	SVM-RSA	۴۵۰.۰۰۰	۰.۰۱۰	۲.۵۰۰	۰.۹۷۸	۰.۰۱۴	۰.۹۸۹	۰.۸۲۴	۰.۰۲۸	۰.۹۲۰
TS7	SVM-HOA	۲۷۱.۹۳۱	۰.۰۰۷	۲.۶۰۴	۰.۹۷۳	۰.۰۱۵	۰.۹۸۷	۰.۹۱۳	۰.۰۱۹	۰.۹۵۹
	SVM-RSA	۴۵۰.۰۰۰	۰.۰۰۱	۲.۵۰۰	۰.۹۸۲	۰.۰۱۲	۰.۹۹۱	۰.۸۹۲	۰.۰۲۲	۰.۹۴۷
TS8	SVM-HOA	۲۷۱.۹۳۱	۰.۰۰۷	۲.۶۰۴	۰.۹۷۳	۰.۰۱۵	۰.۹۸۷	۰.۸۵۴	۰.۰۲۵	۰.۹۲۸
	SVM-RSA	۴۵۰.۰۰۰	۰.۰۱۰	۲.۵۰۰	۰.۹۷۷	۰.۰۱۸	۰.۹۸۹	۰.۸۱۶	۰.۰۲۸	۰.۹۲۱
TS9	SVM-HOA	۲۶۵.۹۴۱	۰.۰۱۳	۲.۶۰۴	۰.۹۵۷	۰.۰۱۹	۰.۹۷۸	۰.۷۹۸	۰.۰۲۹	۰.۹۱۴
	SVM-RSA	۴۵۰.۰۰۰	۰.۰۱۰	۲.۵۰۰	۰.۹۶۸	۰.۰۱۶	۰.۹۸۴	۰.۸۴۰	۰.۰۲۶	۰.۹۳۴



شکل ۳- ضرایب دبی پیش‌بینی شده با الگوریتم SVM-HOA در مقابل ضرایب دبی آزمایشگاهی برای TS7 تحت سناریو ۱



شکل ۴- ضرایب دبی پیش‌بینی شده با الگوریتم SVM-RSA در مقابل ضرایب دبی آزمایشگاهی برای TS7 تحت سناریو ۱

آماري و مقادير بهينه سه ابر پارامتر تنظيم کننده C، σ و ϵ برای مدل‌های اجرا شده، اشاره گردیده است. با توجه به نتایج مربوط به شاخص‌های آماری داده‌های تست، مدل TB8 به عنوان مدل برتر برگزیده می‌شود که مقادیر NSE، RMSE و R در الگوریتم SVM-HOA به ترتیب برابر ۰.۹۳۳، ۰.۰۱۴ و ۰.۹۶۶ و در الگوریتم SVM-RSA به ترتیب برابر ۰.۹۱۹، ۰.۰۱۵ و ۰.۹۵۹ می‌باشد.



علاوه بر این در شکل‌های (۳) و (۴) برای بهترین مدل، ضرایب دبی پیش‌بینی شده با الگوریتم‌های SVM-RSA و SVM-HOA در مقابل ضرایب دبی آزمایشگاهی در مرحله تست نشان داده شده است.

نتایج تحت سناریو ۲



در سناریو دوم که مربوط به سرریزهای جانبی دوزنقه‌ای لبه پهن با ۳۹۰ داده آزمایشگاهی است، در جدول (۴) به ارزیابی شاخص‌های

جدول ۴- نتایج حاصل از روش‌های SVM-HOA و SVM-RSA برای پیش‌بینی ضریب دبی تحت سناریو ۲

Model	Method	Optimal value			Training stage			Testing stage		
		C	ϵ	σ	NSE	RMSE	R	NSE	RMSE	R
TB1	SVM-HOA	۴۸.۹۸۷	۰.۰۰۶	۳.۷۰۸	۰.۹۸۸	۰.۰۰۶	۰.۹۹۴	۰.۹۱۷	۰.۰۱۵	۰.۹۵۸
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۸۷	۰.۰۰۶	۰.۹۹۴	۰.۸۹۴	۰.۰۱۷	۰.۹۴۶
TB2	SVM-HOA	۲۸.۷۸۱	۰.۰۰۹	۴.۰۶۲	۰.۹۰۶	۰.۰۱۷	۰.۹۵۲	۰.۸۴۳	۰.۰۲۱	۰.۹۲۳
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۰۱	۰.۰۱۷	۰.۹۵۰	۰.۷۷۳	۰.۰۲۵	۰.۸۸۲
TB3	SVM-HOA	۳۷.۷۴۱	۰.۰۱۸	۴.۰۴۲	۰.۸۸۹	۰.۰۱۸	۰.۹۴۴	۰.۷۲۰	۰.۰۲۸	۰.۸۵۸
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۰۷	۰.۰۱۷	۰.۹۵۲	۰.۷۴۸	۰.۰۲۶	۰.۸۶۸
TB4	SVM-HOA	۲۹.۳۰۱	۰.۰۰۴	۴.۰۷۲	۰.۹۶۹	۰.۰۱۰	۰.۹۸۵	۰.۸۸۴	۰.۰۱۸	۰.۹۴۰
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۶۱	۰.۰۱۱	۰.۹۸۱	۰.۸۵۷	۰.۰۲۰	۰.۹۲۶
TB5	SVM-HOA	۴۹.۵۰۷	۰.۰۱۰	۳.۶۹۸	۰.۹۶۴	۰.۰۱۱	۰.۹۸۲	۰.۸۵۹	۰.۰۲۰	۰.۹۲۹
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۵۵	۰.۰۱۲	۰.۹۷۷	۰.۸۴۶	۰.۰۲۰	۰.۹۲۳
TB6	SVM-HOA	۵۰.۰۲۷	۰.۰۰۶	۳.۷۰۸	۰.۹۴۶	۰.۰۱۳	۰.۹۷۳	۰.۷۴۷	۰.۰۲۶	۰.۸۷۱
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۳۱	۰.۰۱۴	۰.۹۶۵	۰.۸۳۲	۰.۰۲۱	۰.۹۱۴
TB7	SVM-HOA	۲۹.۳۰۱	۰.۰۰۴	۴.۰۷۲	۰.۹۸۵	۰.۰۰۷	۰.۹۹۲	۰.۹۱۸	۰.۰۱۵	۰.۹۵۸
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۸۳	۰.۰۰۷	۰.۹۹۲	۰.۸۸۴	۰.۰۱۸	۰.۹۴۰
TB8	SVM-HOA	۳۱.۹۰۱	۰.۰۰۱	۴.۱۲۲	۰.۹۹۰	۰.۰۰۶	۰.۹۹۵	۰.۹۳۳	۰.۰۱۴	۰.۹۶۶
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۸۴	۰.۰۰۷	۰.۹۹۲	۰.۹۱۹	۰.۰۱۵	۰.۹۵۹
TB9	SVM-HOA	۵۰.۰۲۷	۰.۰۰۶	۳.۷۲۸	۰.۹۶۴	۰.۰۱۱	۰.۹۸۲	۰.۸۰۱	۰.۰۲۳	۰.۹۰۰
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۵۲	۰.۰۱۲	۰.۹۷۶	۰.۸۵۳	۰.۰۲۰	۰.۹۲۴
TB10	SVM-HOA	۲۹.۳۰۱	۰.۰۰۴	۴.۰۷۲	۰.۹۲۰	۰.۰۱۶	۰.۹۶۰	۰.۸۶۱	۰.۰۱۹	۰.۹۲۸
	SVM-RSA	۸.۰۰۰	۰.۰۰۱	۳.۵۰۰	۰.۹۱۲	۰.۰۱۶	۰.۹۵۶	۰.۸۳۰	۰.۰۲۲	۰.۹۱۱



شکل ۵- ضرایب دبی پیش‌بینی شده با الگوریتم SVM-HOA در مقابل ضرایب دبی آزمایشگاهی برای TB8 تحت سناریو ۲



شکل ۶- ضرایب دبی پیش‌بینی شده با الگوریتم SVM-RSA در مقابل ضرایب دبی آزمایشگاهی برای TB8 تحت سناریو ۲

نتایج تحت سناریو ۳

در سناریو سوم که مربوط به سرریزهای جانبی مثلثی لبه تیز است، ۱۳۸ داده آزمایشگاهی با نسبت ۸۰٪ برای آموزش در مقابل ۲۰٪ برای تست انتخاب شدند. در جدول (۵) به ارزیابی شاخص‌های



همچنین در شکل‌های (۵) و (۶) برای بهترین مدل، ضرایب دبی پیش‌بینی شده با الگوریتم‌های SVM-HOA و SVM-RSA در مقابل ضرایب دبی آزمایشگاهی در مرحله تست نشان داده شده است.

برگزیده می‌شود که مقادیر NSE، RMSE و R در الگوریتم SVM-HOA به ترتیب برابر ۰.۹۳۲، ۰.۰۱۵ و ۰.۹۶۷ و در الگوریتم SVM-RSA به ترتیب برابر ۰.۹۳۴، ۰.۰۱۵ و ۰.۹۶۸ می‌باشد.



آماري و مقادير بهينه سه ابر پارامتر تنظيم‌کننده C، σ و ϵ برای مدل‌های اجرا شده، اشاره گردیده است. با توجه به نتایج مربوط به شاخص‌های آماری داده‌های تست، مدل Tr10 به‌عنوان مدل برتر

جدول ۵- نتایج حاصل از روش‌های SVM-HOA و SVM-RSA برای پیش‌بینی ضریب دبی تحت سناریو ۳

Model	Method	Optimal value			Training stage			Testing stage		
		C	ϵ	σ	NSE	RMSE	R	NSE	RMSE	R
Tr1	SVM-HOA	۰.۵۵۰	۰.۰۰۲	۱.۰۵۸	۰.۹۷۱	۰.۰۱۰	۰.۹۸۷	۰.۸۹۲	۰.۰۱۹	۰.۹۴۷
	SVM-RSA	۰.۵۰۸	۰.۰۰۴	۱.۰۴۴	۰.۹۶۸	۰.۰۱۰	۰.۹۸۵	۰.۸۹۱	۰.۰۱۹	۰.۹۴۶
Tr2	SVM-HOA	۰.۵۴۴	۰.۰۰۳	۱.۰۵۶	۰.۹۳۵	۰.۰۱۵	۰.۹۶۷	۰.۹۱۲	۰.۰۱۷	۰.۹۵۵
	SVM-RSA	۰.۲۵۸	۰.۰۰۱	۰.۹۰۰	۰.۹۳۴	۰.۰۱۵	۰.۹۶۷	۰.۸۹۶	۰.۰۱۸	۰.۹۴۷
Tr3	SVM-HOA	۰.۵۶۲	۰.۰۰۲	۱.۰۶۲	۰.۹۵۰	۰.۰۱۳	۰.۹۷۵	۰.۸۶۵	۰.۰۲۱	۰.۹۳۳
	SVM-RSA	۰.۲۲۹	۰.۰۰۱	۰.۹۰۰	۰.۹۴۱	۰.۰۱۴	۰.۹۷۰	۰.۸۶۴	۰.۰۲۱	۰.۹۳۱
Tr4	SVM-HOA	۰.۵۵۰	۰.۰۰۲	۱.۰۵۸	۰.۹۱۹	۰.۰۱۶	۰.۹۵۹	۰.۹۲۰	۰.۰۱۶	۰.۹۶۲
	SVM-RSA	۰.۵۰۸	۰.۰۰۴	۱.۰۴۴	۰.۹۱۴	۰.۰۱۷	۰.۹۵۷	۰.۹۲۳	۰.۰۱۶	۰.۹۶۳
Tr5	SVM-HOA	۰.۵۵۰	۰.۰۰۲	۱.۰۵۸	۰.۹۷۲	۰.۰۱۰	۰.۹۸۷	۰.۸۹۲	۰.۰۱۹	۰.۹۴۷
	SVM-RSA	۰.۵۰۸	۰.۰۰۴	۱.۰۴۴	۰.۹۶۸	۰.۰۱۰	۰.۹۸۵	۰.۸۹۲	۰.۰۱۹	۰.۹۴۷
Tr6	SVM-HOA	۰.۵۰۸	۰.۰۰۴	۱.۰۴۴	۰.۹۴۵	۰.۰۱۴	۰.۹۷۲	۰.۹۰۹	۰.۰۱۷	۰.۹۵۶
	SVM-RSA	۰.۵۰۸	۰.۰۰۴	۱.۰۴۴	۰.۹۴۵	۰.۰۱۴	۰.۹۷۲	۰.۹۰۹	۰.۰۱۷	۰.۹۵۶
Tr7	SVM-HOA	۰.۳۶۹	۰.۰۱۸	۰.۹۲۴	۰.۸۷۴	۰.۰۲۰	۰.۹۴۶	۰.۷۱۱	۰.۰۳۰	۰.۸۴۸
	SVM-RSA	۰.۳۳۵	۰.۰۰۱	۰.۹۰۰	۰.۸۹۶	۰.۰۱۹	۰.۹۵۱	۰.۸۰۶	۰.۰۲۵	۰.۹۰۱
Tr8	SVM-HOA	۰.۵۵۶	۰.۰۰۲	۱.۰۶۰	۰.۹۷۲	۰.۰۱۰	۰.۹۸۷	۰.۹۰۰	۰.۰۱۸	۰.۹۵۱
	SVM-RSA	۰.۵۰۸	۰.۰۰۴	۱.۰۴۴	۰.۹۶۸	۰.۰۱۰	۰.۹۸۵	۰.۸۹۸	۰.۰۱۸	۰.۹۵۰
Tr9	SVM-HOA	۰.۵۴۴	۰.۰۰۳	۱.۰۵۶	۰.۹۳۶	۰.۰۱۴	۰.۹۶۸	۰.۹۱۶	۰.۰۱۶	۰.۹۵۷
	SVM-RSA	۰.۲۵۸	۰.۰۰۱	۰.۹۰۰	۰.۹۳۵	۰.۰۱۵	۰.۹۶۷	۰.۹۰۱	۰.۰۱۸	۰.۹۵۰
Tr10	SVM-HOA	۰.۵۳۸	۰.۰۰۳	۱.۰۵۴	۰.۹۱۲	۰.۰۱۷	۰.۹۵۶	۰.۹۳۲	۰.۰۱۵	۰.۹۶۷
	SVM-RSA	۰.۵۰۸	۰.۰۰۴	۱.۰۴۴	۰.۹۰۹	۰.۰۱۷	۰.۹۵۴	۰.۹۳۴	۰.۰۱۵	۰.۹۶۸
Tr11	SVM-HOA	۰.۵۲۶	۰.۰۰۳	۱.۰۵۰	۰.۸۵۶	۰.۰۲۲	۰.۹۲۵	۰.۸۳۲	۰.۰۲۳	۰.۹۱۳
	SVM-RSA	۰.۵۰۸	۰.۰۰۴	۱.۰۴۴	۰.۸۵۵	۰.۰۲۲	۰.۹۲۵	۰.۸۲۹	۰.۰۲۳	۰.۹۱۲



شکل ۷- ضرایب دبی پیش‌بینی شده با الگوریتم SVM-HOA در مقابل ضرایب دبی آزمایشگاهی برای Tr10 تحت سناریو ۳



شکل ۸- ضرایب دبی پیش‌بینی شده با الگوریتم SVM-RSA در مقابل ضرایب دبی آزمایشگاهی برای Tr10 تحت سناریو ۳

پیش‌بینی بالایی ارائه می‌کنند و خطای پیش‌بینی آن‌ها به‌طور قابل‌توجهی کمتر از مدل‌های تجربی سنتی است. این مقایسه برتری روش‌های هوشمند پیشنهادی را نشان می‌دهد و اهمیت استفاده از یادگیری ماشین برای پیش‌بینی جامع‌تر و دقیق‌تر ضرایب دبی سرریزهای جانبی را برجسته می‌کند. این ویژگی می‌تواند راهنمای ارزشمندی برای طراحی و تحلیل هیدرولیکی در شرایط واقعی باشد.

آنالیز حساسیت مدل بهینه

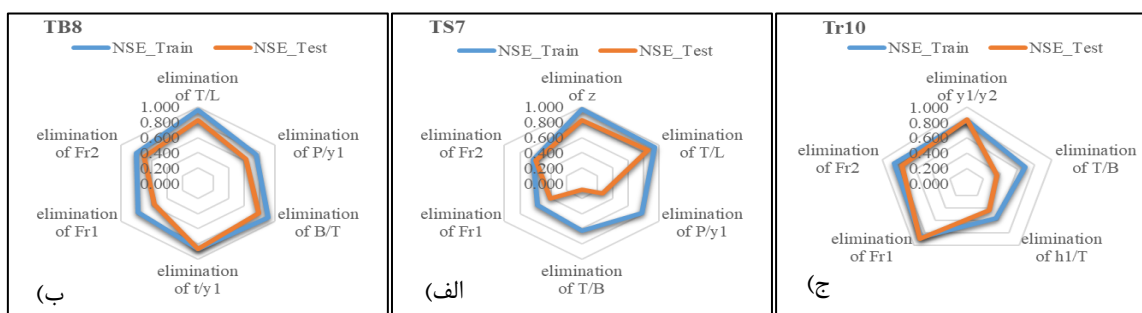
جهت بررسی تأثیر پارامترهای ورودی به‌کاررفته در پیش‌بینی ضریب دبی، از آنالیز حساسیت در مدل‌های برتر سرریزهای جانبی استفاده گردید. بدین منظور با حذف تک‌تک پارامترهای ورودی مدل برتر و اجرای دوباره مدل با الگوریتم SVM-HOA و تعیین معیار ارزیابی NSE، میزان تأثیر پارامتر حذف‌شده در کاهش دقت مدل موردبررسی قرار گرفت. نتایج حاصل از آنالیز حساسیت در شکل (۹) ارائه‌شده است که مطابق آن، در مدل TS7، پارامترهای P/y_1 و T/B در پیش‌بینی ضریب دبی سرریزهای جانبی دوزنقه‌ای لبه تیز واقع در کانال اصلی مستطیلی دارای اهمیت بسیاری می‌باشند که حذف آن‌ها به ترتیب منجر به کاهش مقدار شاخص NSE در مرحله تست به 0.089 و 0.270 می‌شوند. در مدل TB8، پارامترهای Fr_1 و P/y_1 در پیش‌بینی ضریب دبی سرریزهای جانبی دوزنقه‌ای لبه پهن واقع در کانال اصلی مستطیلی دارای اهمیت بسیاری می‌باشند که حذف آن‌ها به ترتیب منجر به کاهش مقدار شاخص NSE در مرحله تست به 0.565 و 0.627 می‌شوند. در مدل Tr10، پارامترهای T/B و h_1/T در پیش‌بینی ضریب دبی سرریزهای جانبی مثلثی لبه تیز واقع در کانال اصلی مستطیلی دارای اهمیت بسیاری می‌باشند که حذف آن‌ها به ترتیب منجر به کاهش مقدار شاخص NSE در مرحله تست به 0.361 و 0.431 می‌شوند.

همچنین در شکل‌های (۷) و (۸) برای بهترین مدل، ضرایب دبی پیش‌بینی‌شده با الگوریتم‌های SVM-HOA و SVM-RSA در مقابل ضریب دبی آزمایشگاهی در مرحله تست نشان داده‌شده است.

مقایسه عملکرد روش پیشنهادی با روابط تجربی و یافته‌های پیشین

برای ارزیابی دقت مدل‌های پیشنهادی SVM-HOA و SVM-RSA، پیش‌بینی ضرایب دبی سرریزهای جانبی با روابط تجربی ارائه‌شده در مطالعات قبلی مقایسه شد. در سرریز مثلثی لبه تیز، روابط تجربی کوشار و آقاچوغلو و قدسیان با داده‌های آزمایشگاهی این پژوهش سنجیده شدند (Coşar & Agaccioglu, 2004; Ghodsian, 2004). ضریب همبستگی (R) برای این روابط به ترتیب 0.411 و 0.295 و مقادیر RMSE به ترتیب 0.147 و 0.082 به دست آمد که نشان‌دهنده عملکرد متوسط تا ضعیف مدل‌های تجربی در پیش‌بینی دقیق ضرایب دبی است. در سرریز دوزنقه‌ای لبه پهن، رابطه تجربی ولایتی و وطن‌خواه (۱۳۹۸) بررسی شد که R و RMSE را به ترتیب 0.42 و 0.154 نشان داد. با این حال، در سرریز دوزنقه‌ای لبه تیز، به دلیل گستردگی مقادیر پارامتر Z ($0.268, 0.57, 1, 2.5$)، روابط تجربی پیشین توانایی پیش‌بینی دقیق برای کل دامنه داده‌ها را نداشتند و اعمال مستقیم آن‌ها بر روی داده‌های این مطالعه امکان‌پذیر نبود. این محدودیت نشان می‌دهد که مدل‌های تجربی سنتی اغلب تنها برای محدوده‌های خاص داده‌ای معتبر هستند و قابلیت تعمیم محدودی دارند.

در مقابل، مدل‌های پیشنهادی SVM-HOA و SVM-RSA با استفاده از الگوریتم‌های یادگیری ماشین و فرا‌ابتکاری، قادر به پوشش کامل دامنه داده‌های آزمایشگاهی و متغیرهای مؤثر بر ضریب دبی هستند. نتایج نشان داد که این مدل‌ها علاوه بر انعطاف‌پذیری، دقت



شکل ۹- نتایج آنالیز حساسیت مدل برتر برای سرریزهای جانبی در مراحل آموزش و تست تحت: (الف) سناریو ۱ (ب) سناریو ۲ (ج) سناریو ۳

برای RSA، پیش‌بینی ضریب دبی سرریزهای جانبی با مقاطع دوزنقه‌ای لبه تیز، دوزنقه‌ای لبه پهن و مثلثی لبه تیز در کانال‌های

نتیجه‌گیری

در این مطالعه، از مدل‌های تلفیقی SVM-HOA و SVM-RSA

منابع

- روشنگر، ک.، سعادت‌جو، ر.، عباس‌زاده، ح. و پناهی، آ. ۱۴۰۳. تخمین غلظت هوا در سرریز شوت با استفاده از روش‌های فرا مدل. تحقیقات آب و خاک ایران. ۵۵ (۴): ۶۱۳-۶۰۱.
- عسکری، ر. و وطن‌خواه، ع. ۱۳۹۸. مطالعه نظری و آزمایشگاهی سرریز جانبی دوزنقه‌ای لبه‌گرد در شرایط رژیم زیربحرانی. تحقیقات آب و خاک ایران. ۵۰ (۵): ۱۱۸۱-۱۱۶۹.
- نامدار، س.، عباسپور، ا.، حسین‌زاده، ع. و سلماسی، ف. ۱۴۰۳. بررسی عددی تأثیر پارامترهای هندسی سرریز جانبی با پلان دوزنقه‌ای بر ضریب دبی جریان. دانش آب و هیدرولیک. ۳۴ (۴): ۸۸-۷۵.
- ولایتی، ف. و وطن‌خواه، ع. ۱۳۹۸. محاسبه بده سرریز جانبی لبه‌پهن دوزنقه‌ای در رژیم زیر بحرانی بر اساس تئوری جریان متغیر مکانی. تحقیقات مهندسی سازه‌های آبیاری و زهکشی. ۲۰ (۷۴): ۱-۱۲.
- Abdollahi, A., Kabiri-Samani, A., Asghari, K., Atoof, H. and 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.
- Abualigah, L., Abd Elaziz, M., Sumari, P., Geem, Z. W. and Gandomi, A. H. 2022. Reptile Search Algorithm (RSA): A nature-inspired meta-heuristic optimizer. *Expert Systems with Applications*. 191: 116158.
- Azimi, H., Shabanlou, S. and 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.
- Balahang, S. and Ghodsian, M. 2023. Estimation of rectangular and triangular side weir discharge. *ISH Journal of Hydraulic Engineering*. 29(1): 12-23.
- Biggiero, V., Longobardi, D. and Pianese, D. 1994. Indagine sperimentale su sfioratori laterali a soglia bassa. *Giornale Del Genio Civile*. 132(7-9): 183-199.
- Bilhan, O., Emiroglu, M. E. and 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.
- Borghei, S. M., Jalili, M. R. and Ghodsian, M. 1999. Discharge coefficient for sharp-crested side weir in subcritical flow. *Journal of Hydraulic Engineering*. 125(10): 1051-1056.
- Cortes, C. and Vapnik, V. 1995. Support-vector networks. *Machine Learning*. 20: 273-297.
- Coşar, A. and Agaccioglu, H. 2004. Discharge مستطیلی استفاده شد. ابتدا، پارامترهای بی‌بعد مؤثر بر ضریب دبی استخراج گردید و سپس مدل‌های متعددی برای هر شکل هندسی طراحی شد. داده‌های موجود با نسبت ۸۰ به ۲۰ به داده‌های آموزش و آزمون تقسیم شده‌اند. تحلیل نتایج نشان داد که هر دو رویکرد مبتنی بر هوش مصنوعی عملکرد قابل قبولی در تخمین ضریب دبی ارائه می‌دهند. مدل SVM-HOA به‌ویژه در پیش‌بینی با دقت بالا موفق عمل کرد. برای سرریزهای دوزنقه‌ای لبه‌تیز، مدل TS7 که بر پایه پارامترهایی مانند شیب دیواره (Z)، نسبت طول مؤثر آبگذری به طول تاج (T/L)، نسبت ارتفاع سرریز به عمق جریان اولیه (P/y_1)، نسبت طول مؤثر به عرض کانال (T/B) و اعداد فرود بالا و پایین دست تعریف شده بود، توانست نتایج دقیقی ارائه دهد ($NSE=0.913$ ، $RMSE=0.019$ و $R=0.959$). تحلیل حساسیت نشان داد که پارامترهای T/B و P/y_1 نقش کلیدی در عملکرد مدل دارند. در سرریزهای دوزنقه‌ای لبه‌پهن، مدل TB8 با در نظر گرفتن نسبت‌هایی مانند T/L، P/y_1 ، B/T، نسبت پهنا تاج سرریز به طول تاج سرریز جانبی (t/L) و همچنین Fr_1 و Fr_2 توانست به دقت قابل‌توجهی دست یابد ($NSE=0.933$ ، $RMSE=0.014$ و $R=0.966$). از میان این متغیرها، پارامترهای Fr_1 و P/y_1 بیشترین تأثیر را داشتند. برای سرریزهای جانبی مثلثی لبه‌تیز، مدل Tr10 با اتکا به متغیرهایی چون نسبت عمق جریان در ابتدای سرریز جانبی به عمق جریان در انتهای سرریز جانبی (y_1/y_2)، T/B، نسبت عمق جریان روی تاج سرریز جانبی به طول سطح آبگذری روی سرریز جانبی مثلثی (h_1/T)، Fr_1 و Fr_2 توسعه یافت و دقت مناسبی ارائه کرد ($NSE=0.932$ ، $RMSE=0.015$ و $R=0.967$). در این حالت، T/B و h_1/T از مهم‌ترین عوامل تأثیرگذار بر عملکرد مدل شناسایی شدند.
- از دیدگاه کاربردی نیز، استفاده از مدل‌های تلفیقی SVM-HOA و SVM-RSA امکان تحلیل سریع و دقیق اثر پارامترهای بی‌بعد بر ضریب دبی سرریزها را فراهم می‌آورد و به مهندسان هیدرولیک ابزار ارزشمندی برای طراحی بهینه و تصمیم‌گیری در شرایط واقعی ارائه می‌کند. تحقیقات آینده می‌تواند با گسترش داده‌های میدانی و آزمایشگاهی، بررسی هندسه‌ها و شرایط هیدرولیکی متنوع‌تر و ترکیب شبیه‌سازی‌های CFD با الگوریتم‌های پیشرفته یادگیری ماشین، قابلیت تعمیم، دقت و پایداری مدل‌های پیش‌بینی ضریب دبی سرریزهای جانبی را ارتقا دهد همچنین باید تأکید کرد که برخلاف روابط تجربی که معمولاً تنها در دامنه محدودی از داده‌ها معتبر هستند، روش‌های هوش مصنوعی از انعطاف‌پذیری و قابلیت تعمیم بالاتری برخوردارند و با تغذیه از داده‌های متنوع‌تر می‌توانند عملکرد خود را در شرایط واقعی و پیچیده ارتقا دهند. این ویژگی، نقطه تمایز اصلی رویکردهای هوشمند نسبت به روابط سنتی محسوب می‌شود.

- side weirs. M.E. Thesis. University of Roorkee, Roorkee, India.
- Kumar, C. P. and Pathak, S. K. 1987. Triangular side weirs. *Journal of Irrigation and Drainage Engineering*. 113(1): 98–105.
- MiarNaeimi, F., Azizyan, G. and Rashki, M. 2021. Horse herd optimization algorithm: A nature-inspired algorithm for high-dimensional optimization problems. *Knowledge-Based Systems*. 213: 106711.
- Mohan, M. 1987. Side weir discharge coefficient. M.E. Thesis. University of Roorkee, Roorkee, India.
- Pandey, N. P. 1985. Flow characteristics of non-rectangular side weirs. M.E. Thesis. University of Roorkee, Roorkee, India.
- Rahimpour, M., Keshavarz, Z. and Ahmadi, M. 2011. Flow over trapezoidal side weir. *Flow Measurement and Instrumentation*. 22(6): 507–510.
- Roushangar, K., Khoshkanar, R. and Shiri, J. 2016. Predicting trapezoidal and rectangular side weirs discharge coefficient using machine learning methods. *ISH Journal of Hydraulic Engineering*. 22(3): 254–261.
- Roushangar, K., Abbaszadeh, H., Saadatjoo, R. and Panahi, A. 2024. Prediction of air concentration in stepped spillways using data-oriented methods. *Environment and Water Engineering*. 11(3): 316–325.
- Shen, G., Cao, D., Li, S. and Li, G. 2024. Numerical and sensitivity analysis of hydraulic characteristics of triangular labyrinth side weir. *Flow Measurement and Instrumentation*. 100: 102686.
- Tynes, K. A. 1989. Hydraulics of side-channel weirs for regional detention basins. M.E. Thesis.
- coefficient of a triangular side-weir located on a curved channel. *Journal of Irrigation and Drainage Engineering*. 130(5): 410–423.
- El-Khashab, A. and Smith, K. V. H. 1976. Experimental investigation of flow over side weirs. *Journal of the Hydraulics Division*. 102(9): 1255–1268.
- Emiroglu, M. E. and Kisi, O. 2013. Prediction of discharge coefficient for trapezoidal labyrinth side weir using a neuro-fuzzy approach. *Water Resources Management*. 27: 1473–1488.
- Ghaderi, A., Dasineh, M., Abbasi, S. and 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.
- Ghodsian, M. 2004. Flow over triangular side weir. *Scientia Iranica*. 11(1).
- Granata, F., Gargano, R. and Santopietro, S. 2016. A flow field characterization in a circular channel along a side weir. *Flow Measurement and Instrumentation*. 52: 92–100.
- Haddadi, H. and Rahimpour, M. 2012. A discharge coefficient for a trapezoidal broad-crested side weir in subcritical flow. *Flow Measurement and Instrumentation*. 26: 63–67.
- Hager, W. H. 1994. Supercritical Flow in Circular-Shaped Side Weir. *Journal of Irrigation and Drainage Engineering*. 120(1): 1–12.
- Kisi, O., Emiroglu, M. E., Bilhan, O. and Guven, A. 2012. Prediction of lateral outflow over triangular labyrinth side weirs under subcritical conditions using soft computing approaches. *Expert Systems with Applications*. 39(3): 3454–3460.
- Kumar, C. P. 1985. Flow characteristics of triangular

Hybrid learning-based estimation of discharge coefficient in triangular and trapezoidal side weirs using SVM optimized by HOA and RSA

K. Roushangar^{1*} and A. Panahi²

Received: May.18, 2025

Accepted: Aug.16, 2025

Abstract

Side weirs play a pivotal role in flow regulation and water measurement, serving as essential components in flood management systems, urban runoff collection, and irrigation and drainage networks. Accurate prediction of the discharge coefficient is critical for the optimal design of these structures. In this study, to enhance the modeling accuracy of the discharge coefficient in sharp-crested trapezoidal, broad-crested trapezoidal, and sharp-crested triangular side weirs, Support Vector Machine (SVM) models were hybridized with two metaheuristic algorithms: Horse Optimization Algorithm (HOA) and Reptile Search Algorithm (RSA). After identifying the key dimensionless variables, multiple models were developed for each weir geometry. The results indicate that both hybrid models exhibit strong predictive capabilities; however, SVM-HOA consistently outperformed SVM-RSA in the testing phase. Specifically, for sharp-crested trapezoidal, broad-crested trapezoidal, and sharp-crested triangular weirs, the SVM-HOA model achieved NSE, RMSE, and R values of (0.913, 0.019, 0.959), (0.933, 0.014, 0.966), and (0.932, 0.015, 0.967), respectively, demonstrating its superior performance across all geometries.

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

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

2- PhD Student, Department of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

(* - Corresponding Author Email: roshangari@tabrizu.ac.ir)