

برآورد ضریب آبدهی سرریزهای کلید پیمانویی انحنادار با استفاده از ترکیب رگرسیون بردار پشتیبان و الگوریتم های ملخ و کرم شب تاب

حجت کرمی^{۱*}، علیرضا رضائی^۲

تاریخ ارسال: ۱۳۹۸/۱۰/۲۳

تاریخ پذیرش: ۱۳۹۹/۰۱/۱۷

مقاله پژوهشی

چکیده

سرریزهای کلیدپیانویی نوع جدیدی از سرریزها هستند که در جهت افزایش ظرفیت تخلیه سدها و کانالها طراحی می شوند. در صورتی که کلیدهای تشکیل دهنده این مدل سرریز بر روی کمانی از یک دایره قرار بگیرند، آن را سرریز کلیدپیانویی انحنادار می نامند. در این پژوهش عملکرد سه مدل هوشمند رگرسیون بردار پشتیبان (SVR)، رگرسیون بردار پشتیبان-کرم شب تاب (SVR-FA) و رگرسیون بردار پشتیبان-ملخ (SVR-GOA) برای پیش بینی میزان آبدهی سرریزهای کلیدپیانویی انحنادار مورد ارزیابی قرار گرفته است. ضریب تعیین (R2)، میانگین مربعات خطا (MAE)، جذر میانگین مربعات خطا (RMSE) و شاخص پراکندگی (SI) چهار شاخص آماری می باشند که برای تعیین دقت مدل های هوشمند به کار گرفته شده است. نتیجه این معیارهای ارزیابی در دوره آزمون نشان می دهد که مدل SVR-GOA با مقادیر ۰/۹۹۲۷۵، ۰/۰۱۲۰۲، ۰/۰۰۰۲۶ و ۰/۰۰۰۴۶ نسبت به مدل SVR-FA با مقادیر ۰/۹۵۶۶۶، ۰/۰۳۸۴۴، ۰/۰۰۲۰۰ و ۰/۰۰۳۴۲ و SVR با مقادیر ۰/۹۴۲۴۹، ۰/۰۴۰۱۳، ۰/۰۶۰۲۷ و ۰/۰۰۴۱۰ به ترتیب برای شاخص های R2، MAE، RMSE و SI از دقت بیشتری در پیش بینی آبدهی سرریز کلیدپیانویی انحنادار برخوردار است.

واژه های کلیدی: رگرسیون بردار پشتیبان، الگوریتم ملخ، الگوریتم کرم شب تاب، سرریز کلیدپیانویی انحنادار، ضریب آبدهی

^۱ * دانشیار گروه مهندسی آب و سازه های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان. پست الکترونیکی: hkarami@semnan.ac.ir.

^۲ دانشجوی دکتری مهندسی آب و سازه های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان. پست الکترونیکی: a.rezaei@semnan.ac.ir.

مقدمه

انحنادار پرداختند و مشاهده نمودند که با افزایش زاویه سیکل قوسی، ظرفیت آگذری افزایش پیدا می‌کند. امروزه استفاده از مدل‌های هوشمند نیز می‌تواند به عنوان ابزاری جایگزین برای مدل‌ها و معادله‌های تجربی به شمار آید. در سالیان اخیر، پژوهش‌هایی در زمینه مطالعات هوشمند درباره سرریزها انجام گرفته که در ادامه به برخی از آنها اشاره شده است. خوشبین و همکاران از الگوریتم هیبرید الگوریتم نروفازی و ژنتیک برای تعیین آبدهی سرریز مستطیلی لبه تیز استفاده کردند. نتایج، حاکی از دقت بیشتر الگوریتم مذکور نسبت به فرمول‌های تجربی و شبکه‌ی عصبی پرسپترون چند لایه بوده است (Khoshbin et al., 2015). کرمی و همکاران با به کارگیری مدل‌های ماشین بردار پشتیبان، ماشین بردار پشتیبان کرم شب‌تاب، روش سطح پاسخ و تجزیه و تحلیل مولفه‌های اصلی در پیش‌بینی ضریب آگذری سرریزهای کنگره‌ای، عملکرد برتر مدل ماشین بردار پشتیبان کرم شب‌تاب را مشاهده نمودند (Karami et al., 2016). همکاران در پژوهشی دیگر با استفاده از الگوریتم برنامه‌ریزی بیان ژن، آبدهی سرریز جانبی را در کانال ذوزنقه‌ای محاسبه و عملکرد دقیق این الگوریتم را مشاهده نمودند (Azimi et al., 2017). روشنگر و همکاران الگوریتم ماشین بردار پشتیبان را جهت محاسبه آبدهی سرریزهای کنگره‌ای خطی و غیرخطی استفاده و اعلام کردند که روش مذکور دقت بیشتری در تعیین آبدهی سرریزهای غیرخطی داشته است (Roushangar et al., 2017). اولیایی و همکاران با به کارگیری چهار روش شبکه‌ی عصبی پیشخور پس‌انتشار خطا، برنامه‌ریزی بیان ژن، ماشین بردار پشتیبان حداقل مربعات و ماشین یادگیری مضاعف آبدهی سرریز کلیدپیانویی را تخمین زدند. در این پژوهش گزارش شد که عملکرد هر چهار روش مطلوب است اما، الگوریتم‌های ماشین بردار پشتیبان حداقل مربعات و ماشین یادگیری مضاعف دقیق‌تر از سایر روش‌ها بررسی شده است (Olyaie et al., 2018a). اولیایی و همکاران در تعیین آبدهی سرریز کلیدپیانویی، چهار روش یادگیری مختلف، شامل ماشین بردار پشتیبان حداقل مربعات، ماشین یادگیری مضاعف، ماشین یادگیری بی‌زین و رگرسیون شرطی را به کار


سرریزها از قدیمی‌ترین و ساده‌ترین سازه‌های هیدرولیکی هستند که برای اندازه‌گیری جریان، تنظیم تراز سطح آب، هدایت سیلاب و منظوره‌های دیگر استفاده می‌شوند. ایمنی سد با کفایت ظرفیت سرریز رابطه مستقیم دارد و این موضوع نشان‌دهنده درجه اهمیت این سازه می‌باشد. در بعضی موارد که به دلیل شرایط توپوگرافی منطقه، احداث سرریز با محدودیت عرضی مواجه می‌شود، استفاده از سرریزهای غیرخطی نظیر سرریزهای کلیدپیانویی می‌تواند یک راهکار مناسب در جهت رساندن ظرفیت آگذری سرریز به مقدار مورد نظر باشد. سرریزهای کلیدپیانویی به مخازن سدها این امکان را می‌دهند تا با تراز بالاتری عمل کنند و این موضوع باعث افزایش حجم ذخیره در مخزن می‌شود (Ribeiro et al., 2012). همچنین هندسه خاص این مدل سرریز باعث افزایش حدوداً ۴ برابری ظرفیت تخلیه آن نسبت به سرریزهای اوجی معمولی می‌شود (Anderson and Tulis, 2012). کلیدپیانویی در سال ۲۰۰۶ بر روی سد گلورس در کشور فرانسه ایجاد شد (Laugier., 2007). اشلایس تاریخچه مطالعات در زمینه سرریز کلیدپیانویی را مرور کرده است (Schleis., 2011). بیری و همکاران با استفاده از نتایج مدل‌های فیزیکی موجود یک معادله عمومی برای رابطه دبی-اشل سرریزهای کلیدپیانویی ارائه نمودند (Bieri et al., 2012). کبیری سامانی و جواهری با بررسی تأثیر پارامترهای هندسی مختلف، رابطه‌ای جهت محاسبه آبدهی در حالت جریان آزاد و مستغرق در سرریز کلیدپیانویی ارائه نمودند (Kabiri-Samani and Javaheri., 2012). در صورتی که کلیدهای تشکیل‌دهنده سرریز کلیدپیانویی بر روی کماتی از یک دایره قرار بگیرند، این مدل سرریز را سرریز کلیدپیانویی انحنادار می‌نامند. صفرزاده و نوروزی (۱۳۹۳) به بررسی هیدرودینامیک سه‌بعدی سرریزهای کلیدپیانویی انحنادار پرداختند و مشاهده نمودند که اگر سرریز کلیدپیانویی به صورت غیرخطی (انحنادار) در پلان اجرا شود می‌تواند تا حدود ۳۰ درصد آبدهی بیشتری نسبت به سرریز کلیدپیانویی خطی با تعداد کلید یکسان داشته باشد. روشنگر و همکاران (۱۳۹۷) به ارزیابی تأثیر تغییرات زاویه سیکل قوسی بر آبدهی سرریزهای کلیدپیانویی



در این پژوهش برای نخستین بار، با استفاده از مدل رگرسیون بردار پشتیبان ملخ (SVR-GOA) آبدهی سرریزهای کلیدپیانویی انحنادار پیش‌بینی می‌شود. همچنین، برای مقایسه میزان دقت عملکرد الگوریتم مذکور با سایر الگوریتم‌ها، از الگوریتم‌های قدرتمند رگرسیون بردار پشتیبان (SVR) و رگرسیون بردار پشتیبان کرم شبتاب (SVR_FA) استفاده شده است.

مواد و روش‌ها

در پژوهش حاضر به منظور تعیین آبدهی سرریز کلیدپیانویی با استفاده از مدل‌های SVR، SVR-GOA و SVR-FA، از روند شماتیک زیر استفاده شده است (شکل ۱). در این فلوچارت، ابتدا الگوریتم‌های مذکور بر اساس ورودی‌ها در دو دوره آموزش و آزمون شامل مشخصات هندسی و شرایط مرزی مقدار آبدهی را محاسبه می‌کنند. سپس با توجه به مقادیر مشاهداتی آبدهی و مقادیر پیش‌بینی شده آن برای هر مدل، مقدار معیارهای ارزیابی محاسبه شده و در نهایت بهترین الگوریتم انتخاب می‌شود.



شکل (۱): روند شماتیک مراحل پیش‌بینی آبدهی سرریز کلیدپیانویی

مقدار خروجی‌ها را تخمین می‌زند. فرض می‌شود که x (داده‌های دوره مشاهداتی می‌باشند که x بردار ورودی و y خروجی مشاهداتی است. این الگوریتم با استفاده از معادله ۱، رابطه‌ای خطی بین ورودی‌ها و خروجی برقرار می‌کند.

$$y' = f(x) = \omega^T \phi(x) + b \quad (1)$$

برندند. در این پژوهش، روش یادگیری مضاعف دقت بیشتری نسبت به سایر روش‌ها داشت (Olyae et al., 2018b). حیدری و همکاران با بهینه‌سازی الگوریتم پرسپترون چند لایه (MLP) با الگوریتم ملخ (GOA)، عملکرد دقیق‌تر الگوریتم GOA-MLP را نسبت به MLP مشاهده نمودند (Heidari et al, 2019). ذونعمت کرمانی و مهدوی میمند از هیبرید الگوریتم‌های شبکه‌ی عصبی پرسپترون چندلایه و نروفازی با الگوریتم‌های بهینه‌سازی ازدحام ذرات، ژنتیک، کرم شبتاب و شمع-پروانه برای پیش‌بینی آبدهی سرریز کلیدپیانویی استفاده کردند و نشان دادند که الگوریتم‌های ازدحام ذرات و کرم شبتاب سبب بهبود نتایج الگوریتم‌های شبکه‌ی عصبی پرسپترون چندلایه و نروفازی می‌شوند (Zounemat-Kermani and Mahdavi-meymand., 2019). بررسی مطالعات قبلی نشان می‌دهد که در زمینه سرریزهای کلیدپیانویی پژوهش‌های گسترده‌ای انجام شده است. اما در زمینه سرریزهای کلیدپیانویی انحنادار و همچنین به کارگیری روش‌های هوشمند برای تخمین آبدهی این مدل سرریز مطالعات اندکی صورت گرفته است.

رگرسیون بردار پشتیبان

ماشین بردار پشتیبان نخستین بار توسط وپنیک به جامعه علمی معرفی شد. از مزیت‌های این الگوریتم این است که دلیل استفاده از روش‌های بهینه‌سازی سراسری در ساختار خود، مانند الگوریتم شبکه‌های عصبی مصنوعی در دام بهینه‌های محلی نمی‌افتد (Vapnik., 1995). همچنین الگوریتم ماشین بردار پشتیبان با استفاده از یک تابع غیر خطی، بردار ورودی‌ها را به فضایی با ابعاد بالاتر نگاشت می‌کند. سپس با استفاده از یک رگرسیون خطی،

الگوریتم هیچ روشی برای تعیین دقیق این سه پارامتر وجود ندارد. از طرفی این پارامترها دارای تأثیر قابل توجهی در نتایج نهایی الگوریتم می‌باشند. لذا، تعیین بهینه آن‌ها با استفاده از الگوریتم‌های تکاملی به‌جای استفاده از روش سعی و خطا، افزایش دقت مدل‌سازی را به همراه دارد. تاکنون الگوریتم‌های تکاملی مختلفی به این منظور معرفی شده است. در این زمینه می‌توان به الگوریتم‌های ژنتیک (Zhao & Zarat, 2005)، ازدحام ذرات (Zhang et al., 2010) ، جستجوی فاخته (Wang, 2010) و کرم شب‌تاب (Mehr et al., 2018) که در تعیین بهینه پارامترهای ماشین بردار پشتیبان استفاده شده‌اند، اشاره کرد. در پژوهش حاضر از الگوریتم‌های کرم شب‌تاب و ملخ برای تعیین دقیق این سه پارامتر استفاده شده است

سایر الگوریتم‌های بهینه‌سازی دارای مزایایی چون، مشارکت همه‌ی عوامل جستجو در به‌روز رسانی موقعیت هر عامل جستجو، توجه ویژه برای جلوگیری از افتادن در دام بهینه‌های محلی و سپس همگرایی، ایجاد تعادل بین قابلیت جستجوی سراسری و محلی، عدم نیاز به اطلاعات گرادینان فضای جستجو می‌باشد (Saremi et al., 2017). در این الگوریتم موقعیت ملخ‌ها در گروه بصورت رابطه ۵ تعریف می‌شود:

$$X_i = S_i + G_i + A_i \quad (5)$$

در این رابطه S_i تأثیر برهم کنش اجتماعی، G_i تأثیر گرانش و A_i تأثیر باد در حرکت ملخ‌ها می‌باشد. به منظور شبیه‌سازی برهم کنش اجتماعی ملخ‌ها از رابطه ۶ استفاده می‌شود:

$$S_i = \sum_{j=1}^n s(d_{ij}) d'_{ij} \quad (6)$$

در این رابطه d_{ij} معرف فاصله اقلیدسی بین ملخ i ام و ملخ j ام، s تنش حاصل از نیروی اجتماع و d'_{ij} بردار واحد که نشان‌دهنده جهت حرکت ملخ i ام به سمت ملخ j ام می‌باشد. تابع S به‌صورت رابطه ۷ تعریف می‌شود:

$$S(r) = fe^{-r/l} - e^{-r} \quad (7)$$

در این رابطه f شدت جذب و l مقیاس طول جذب می‌باشد. در این معادله، دو نیروی جذب و دفع در نظر گرفته می‌شود.

که در این معادله y' خروجی مدل، $f(x)$ بیانگر رابطه خطی بین ورودی‌ها و خروجی‌ها و $\phi(x)$ تابع نگاشت غیرخطی می‌باشند. ω و b نیز معرف وزن و بایس مدل می‌باشند. هدف کاهش اختلاف بین خروجی‌های مدل و خروجی‌های واقعی است. بدین منظور تابع هدف رابطه ۲ با استفاده از روش بهینه‌سازی مرتبه دوم حداقل می‌شود:

$$\min : \psi = \frac{1}{2} \|\omega\|^2 + \gamma \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (2)$$

$$\text{subject to : } \begin{cases} \omega\phi(x_i) + b - y \leq \varepsilon + \xi_i \\ y - \omega\phi(x_i) + b \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^*, i = 1, 2, 3, \dots, n \end{cases}$$

که σ معرف عرض تابع کرنل و K تابع غیرخطی کرنل می‌باشد. بنابراین الگوریتم رگرسیون بردار پشتیبان دارای سه پارامتر اثرگذار σ ، γ و ε می‌باشد. لیکن در این

الگوریتم بهینه‌سازی کرم شب‌تاب

الگوریتم کرم شب‌تاب، یک الگوریتم بهینه‌سازی جمعیت محور و تصادفی می‌باشد که اولین بار توسط یانگ به جامعه علمی معرفی شد (Yang., 2009). این الگوریتم بر مبنای رفتار کرم‌های شب‌تاب در جذب جفت عمل می‌کند. سه فرضیه اساسی این الگوریتم در ادامه شرح داده شده‌است:

۱- برای کرم‌های شب‌تاب جنسیت خاصی در نظر گرفته نمی‌شود.

۲- هر کرم شب‌تاب به کرم‌های شب‌تاب دیگر با توجه به شدت نور آن‌ها جذب می‌شود.

۳- در مسائل ماکزیمم سازی میزان شدت نور با تابع هدف رابطه مستقیم دارد و در مسائل مینیمم سازی شدت نور با تابع هدف رابطه عکس دارد.

جابجایی بک کرم شب‌تاب به سمت کرم شب‌تاب دیگر به‌صورت رابطه ۴ تعریف می‌شود:

$$x_i^{t+1} = x_i^t + \beta_0 e^{-\gamma r_{ij}^2} (x_j^t - x_i^t) + \alpha(\text{rand} - 0.5) \quad (4)$$

الگوریتم بهینه‌سازی ملخ

الگوریتم ملخ یک الگوریتم بهینه‌سازی جدید است که اولین بار توسط صارمی و همکاران برای حل مسائل مهندسی پیچیده به جامعه علمی معرفی شده است (Saremi et al., 2017). این الگوریتم در مقایسه با



در پژوهش حاضر، از هیبرید رگرسیون بردار پشتیبان و الگوریتم بهینه‌سازی ملخ (SVR-GOA) جهت پیش-بینی آبدهی سرریز کلیدپیانویی استفاده شده است. طرح شماتیک این الگوریتم در شکل ۲ آورده شده است.

- ۱- تعیین پارامترهای اولیه الگوریتم ملخ شامل تعداد جمعیت، cmax، cmin و حداکثر تعداد تکرار
- ۲- تقسیم بندی داده‌های آزمایشگاهی به دو دوره آموزش و آزمون
- ۳- تولید جمعیت اولیه
- ۴- آموزش ماشین بردار پشتیبان با توجه به متغیر تصمیم

ملخ‌ها

- ۵- آزمون ماشین بردار پشتیبان و تعیین تابع هدف (MSE) برای هر ملخ
- ۶- کنترل شرط خاتمه، در صورت رعایت آن برگرداندن مقادیر بهینه پارامترهای ماشین بردار پشتیبان و در غیر این صورت به‌روز رسانی موقعیت هر ملخ و تکرار گام‌های ۴ تا ۵

لازم به ذکر است که متغیرهای تصمیم پارامترهای ماشین بردار پشتیبان شامل C (ضریب پنالتی) σ (عرض تابع کرنل) و ϵ (پارامتر خطا) می‌باشند

زمانی که فاصله ملخ‌ها از یکدیگر بین ۰ تا ۲/۰۷۹ باشد، نیروی ملخ‌ها به‌صورت دافعه و زمانی که این فاصله بین ۲/۰۷۹ تا ۴ باشد این نیرو به‌صورت جاذبه می‌باشد. همچنین اگر فاصله برابر ۲/۰۷۹ باشد، هیچ‌گونه نیرویی ایجاد نمی‌شود. (Saremi et al., 2017) رابطه ۸ بیان‌گر فرمول به‌روز رسانی موقعیت ملخ‌ها می‌باشد:

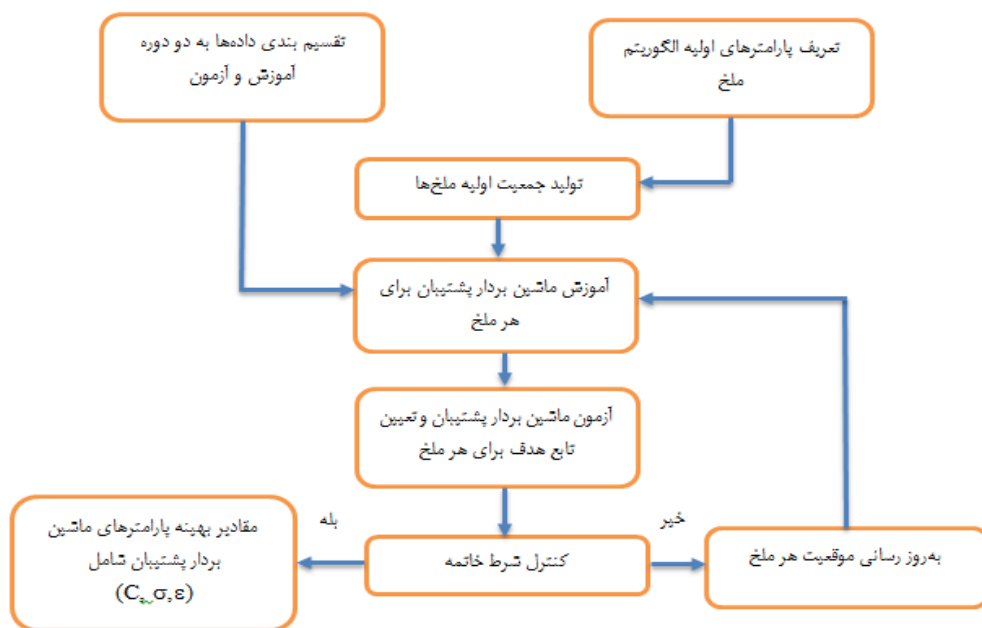
$$X_i^d = c \left[\sum_{j=1}^n c \left(\frac{ub_d - lb_d}{2} \right) s \left(|x_j^d - x_i^d| \right) \frac{x_j - x_i}{d_{ij}} \right] + T_d \quad (8)$$

که در این رابطه ub و lb به‌ترتیب بیانگر حد بالا و حد پایین متغیرهای تصمیم می‌باشند. T بیانگر هدف یا بهترین موقعیت به‌دست آمده تاکنون می‌باشد. پارامتر c نیز معرف یک ضریب کاهشی برای محدود کردن منطقه خنثی، منطقه دافعه و منطقه جاذبه می‌باشد. پارامتر C باعث همگرایی گروه ملخ‌ها به سمت هدف می‌شود. این موقعیت که توسط گروه ملخ‌ها دنبال می‌شود، در صورت یافتن موقعیت جدید به‌روز می‌شود. رابطه ۹ بیانگر فرمول به‌روز رسانی پارامتر c در هر تکرار می‌باشد:

$$c = c_{\max} - l(c_{\max} - c_{\min})/L \quad (9)$$

که در این رابطه L بیانگر حداکثر تعداد تکرارها، l شماره تکرار کنونی، $c_{\max}=1$ و $c_{\min}=0.00001$ می‌باشد.

رگرسیون بردار پشتیبان ملخ (SVR-GOA)



شکل (۲): طرح شماتیک هیبرید رگرسیون بردار پشتیبان و الگوریتم بهینه‌سازی ملخ (SVR-GOA)



داده‌های آزمایشگاهی مورد استفاده

در پژوهش حاضر برای پیش‌بینی آبدهی سرریزهای کلیدپیانویی انحنادار از نتایج مطالعات روشنگر و همکاران (۱۳۹۷) استفاده شده است. این محققین در کانالی به طول ۱۰ متر، عرض ۱ متر و عمق ۰/۸ متر به بررسی تأثیر تغییرات زاویه سیکل قوسی بر آبدهی سرریزهای کلیدپیانویی انحنادار پرداختند. در شکل ۳ نمای فلوم آزمایشگاهی و همچنین پارامترهای هندسی سرریز کلیدپیانویی انحنادار نمایش داده شده است. مدل‌هایی از آزمایش روشنگر و همکاران (۱۳۹۷) که در این پژوهش مورد بررسی قرار گرفتند عبارت‌اند از APK20 (سرریز کلیدپیانویی انحنادار با زاویه سیکل قوسی ۲۰ درجه)، APK30 (سرریز کلیدپیانویی انحنادار با زاویه سیکل قوسی ۳۰ درجه) و APK40 (سرریز کلیدپیانویی انحنادار با زاویه سیکل قوسی ۴۰ درجه). در این پژوهش با به کارگیری داده‌های ورودی نسبت هد بالادست به ارتفاع

سرریز (H_t/P)، نسبت طول سرریزی به عرض یک چرخه (L/W)، نسبت عرض چرخه به ارتفاع سرریز (W/P) و زاویه سیکل قوسی (θ)، ضریب آبدهی (C_d) که خروجی مدل می‌باشد تخمین زده می‌شود. ضریب آبدهی سرریزهای کلیدپیانویی با استفاده از معادله عمومی سرریزهای لبه پهن به کمک رابطه ۱۰ محاسبه می‌شود:

$$C_d = \frac{Q}{\frac{2}{3} L \sqrt{2gH}^{1.5}} \quad (10)$$

که در این رابطه، Q دبی عبوری از سرریز، L طول تاج، H هد روی سرریز و C_d ضریب آبدهی می‌باشد. تعداد داده‌هایی که از آزمایش مذکور برای پیش‌بینی ضریب آبدهی سرریزهای کلیدپیانویی انحنادار اخذ شده ۷۴ عدد می‌باشد. محدوده پارامترهای مورد استفاده در مدل‌های هوشمند در جدول ۱ مشخص شده است.



شکل (۳): نمای شماتیک فلوم آزمایشگاهی به همراه پلان سرریز کلیدپیانویی انحنادار

مربعات خطا (MAE)، جذر میانگین مربعات خطا (RMSE) و شاخص پراکندگی (SI) به ترتیب مطابق با روابط ۱۰، ۱۱، ۱۲ و ۱۳ استفاده می‌شود. شاخص R^2 بیانگر میزان همبستگی میان مقادیر آزمایشگاهی و خروجی‌های مدل هوشمند می‌باشد و هرچه مقدار آن به عدد یک نزدیک‌تر باشد نشان دهنده این است که تطابق خوبی بین داده‌های آزمایشگاهی و نتایج مدل هوشمند برقرار می‌باشد. شاخص‌های MAE، RMSE و SI نیز نشان‌دهنده میزان خطای آزمایش می‌باشند و هرچه مقدار این شاخص‌ها به عدد صفر نزدیک‌تر باشند، جواب پیش‌بینی شده توسط مدل هوشمند دقیق‌تر است.

جدول (۱): محدوده پارامترهای مورد استفاده برای مدل‌سازی سرریز کلیدپیانویی انحنادار با روش هوشمند

پارامتر	محدوده
θ	۲۰-۴۰
W/P	۱/۱-۳۶/۷۷
L/W	۳/۴-۲۱/۲
H_t/P	۰/۱-۱/۰۳
C_d	۰/۰-۳۲/۸۳

شاخص‌های آماری

برای تعیین دقت آبدهی پیش‌بینی شده توسط مدل‌های هوشمند SVR-FA، SVR-GOA و SVR از شاخص‌های ارزیابی شامل ضریب تعیین (R^2)، میانگین



نتایج و بحث

در جدول‌های ۲ و ۳ نتایج مربوط به پیش‌بینی آبدهی دبی عبوری از سرریز کلیدپیانویی انحنادار در دو دوره آموزش و آزمون برای مدل‌های SVR-GOA، SVR-FA و SVR ارائه شده است. در پژوهش حاضر، ۷۰ درصد داده‌ها در دوره آموزش و ۳۰ درصد داده‌ها در دوره آزمون مورد استفاده قرار گرفت. نتایج نشان می‌دهد که در دوره آموزش، مدل SVR-GOA با مقدار شاخص R^2 برابر با ۰/۹۹۶۶۵ برتر از مدل SVR با مقدار ۰/۹۷۳۳۷ و مدل SVR-FA با مقدار ۰/۹۶۰۰۸ برای معیار مذکور می‌باشد. در مورد شاخص‌های MAE، RMSE و SI در این دوره، مدل SVR-GOA با مقادیر به ترتیب ۰/۰۰۰۸۷، ۰/۰۰۰۰۹ و ۰/۰۰۰۱۶ نسبت به مدل SVR با مقادیر ۰/۰۲۲۲۶، ۰/۰۲۷۸۶ و ۰/۰۴۶۲۲ و مدل SVR-FA با مقادیر ۰/۰۳۳۲۷، ۰/۰۱۴۵ و ۰/۰۲۳۹ عملکرد بهتری را از خود نشان داده است. در دوره آزمون نیز مقدار بیشتر شاخص R^2 در مدل SVR-GOA (۰/۹۹۲۷۵) نسبت به مدل‌های هوشمند SVR-FA (۰/۹۵۶۶۶) و SVR (۰/۹۴۲۴۹)، نشان‌دهنده دقت بالای این مدل می‌باشد. در این دوره همچنین مدل SVR-GOA نشان داده که با مقادیر ۰/۰۱۲۰۲، ۰/۰۰۰۲۶ و ۰/۰۰۰۴۶ نسبت به مدل SVR-FA با مقادیر ۰/۰۳۸۴۴، ۰/۰۰۲۰۰ و ۰/۰۰۳۴۲ و مدل SVR با مقادیر ۰/۰۴۰۱۳، ۰/۰۶۰۲۷ و ۰/۰۰۴۱۰ به ترتیب برای شاخص‌های MAE، RMSE و SI، از قدرت پیش‌بینی بالاتری برخوردار می‌باشد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (E_i - G_i)^2}{\sum_{i=1}^n E_i^2 - \left(\frac{\sum_{i=1}^n G_i}{N}\right)^2} \quad (10)$$

$$MAE = \frac{1}{N} \sum_{i=1}^n |E_i - G_i| \quad (11)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - G_i)^2}{N}} \quad (12)$$

$$SI = \frac{RMSE}{\bar{G}} \quad (13)$$

که در روابط فوق، E_i مقدار حاصل از مدل آزمایشگاهی، G_i مقدار پیش‌بینی شده توسط مدل هوشمند، \bar{G} میانگین مقادیر پیش‌بینی شده توسط مدل هوشمند و N تعداد متغیرهاست.

جدول (۲): نتایج شاخص‌های ارزیابی برای مدل‌های مورد استفاده در دوره آموزش


SI	RMSE	MAE	R^2	Model
۰/۰۰۰۱۶	۰/۰۰۰۰۹	۰/۰۰۰۸۷	۰/۹۹۶۶۵	SVR-GOA
۰/۰۰۲۳۹	۰/۰۰۱۴۵	۰/۰۳۳۲۷	۰/۹۶۰۰۸	SVR-FA
۰/۰۴۶۲۲	۰/۰۲۷۸۶	۰/۰۲۲۲۶	۰/۹۷۳۳۷	SVR

جدول (۳): نتایج شاخص‌های ارزیابی برای مدل‌های مورد استفاده در دوره آزمون

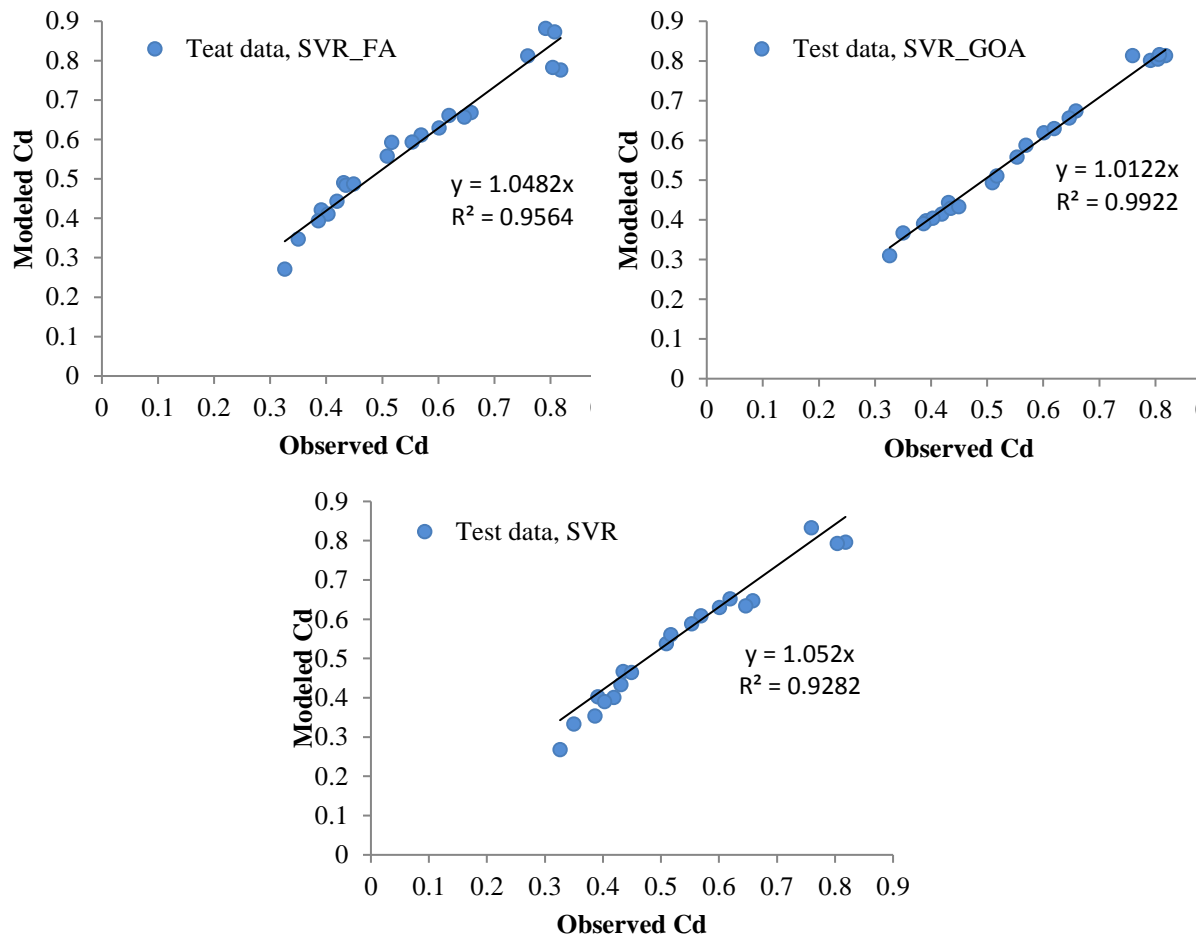
SI	RMSE	MAE	R^2	Model
۰/۰۰۰۴۶	۰/۰۰۰۲۶	۰/۰۱۲۰۲	۰/۹۹۲۷۵	SVR-GOA
۰/۰۰۳۴۲	۰/۰۰۲۰۰	۰/۰۳۸۴۴	۰/۹۵۶۶۶	SVR-FA
۰/۰۰۴۱۰	۰/۰۶۰۲۷	۰/۰۴۰۱۳	۰/۹۴۲۴۹	SVR

مدل حاصل شده است. در شکل ۵ نیز، میزان همبستگی داده‌های آزمایشگاهی و مدل‌های هوشمند SVR-GOA و SVR-FA در دوره آزمون بررسی شده است. در این دوره نیز مدل SVR-GOA با ضریب همبستگی ۰/۹۹۲۲ عملکرد بهتری را نسبت به مدل SVR-FA با ضریب همبستگی ۰/۹۵۶۴ و مدل SVR با ضریب همبستگی ۰/۹۲۸۲ نشان داده است.

در شکل ۴ به مقایسه میزان آبدهی سرریز کلیدپیانویی انحنادار در دو حالت آزمایشگاهی و پیش‌بینی شده با مدل‌های SVR-GOA، SVR-FA و SVR در دوره آموزش پرداخته شده است. در این همچنین میزان همبستگی داده‌های آزمایشگاهی و مدل هوشمند برای مدل‌های مذکور نمایش داده شده است. نتایج نشان می‌دهد که داده‌های مربوط به مدل SVR-GOA، همبستگی و تراکم بالایی دارند و ضریب همبستگی ۰/۹۹۶۵ در این دوره برای این




شکل (۴): مقایسه بین مقادیر آزمایشگاهی و مدل‌های هوشمند در مرحله آموزش




شکل (۵): مقایسه بین مقادیر آزمایشگاهی و مدل‌های هوشمند در مرحله آزمون

زده شده‌اند. در شکل ۷ توزیع خطای پیش‌بینی در آستانه خطاهای مختلف در دوره آزمون برای مدل‌های SVR-GOA، SVR-FA و SVR نمایش داده شده است. در دوره مذکور نیز بیش از ۳۱، ۹۵ و ۵۴ درصد داده‌های پیش‌بینی شده به ترتیب در مدل‌های SVR-FA، SVR-GOA و SVR خطای نسبی کمتر از ۲ درصد دارند. در این دوره تقریباً ۱۰۰ درصد داده‌ها در مدل SVR-FA با خطایی کمتر از ۱۰ درصد، در مدل SVR-GOA با خطایی کمتر از ۵ درصد و در مدل SVR با خطایی کمتر از ۲۰ درصد تخمین زده شده‌اند.

در شکل ۶ توزیع خطای پیش‌بینی در آستانه خطاهای مختلف در دوره آموزش برای مدل‌های SVR-GOA، SVR-FA و SVR نشان داده شده است. همان‌طور که مشاهده می‌شود، در این دوره در مدل SVR-FA بیش از ۳۳ درصد، در مدل SVR-GOA بیش از ۹۸ درصد و در مدل SVR بیش از ۷۴ درصد داده‌های پیش‌بینی شده خطای نسبی کمتر از ۲ درصد دارند. همچنین تقریباً ۱۰۰ درصد داده‌ها در مدل SVR-FA با خطایی کمتر از ۷/۵ درصد، در مدل SVR-GOA با خطایی کمتر از ۲/۵ درصد و در مدل SVR با خطایی کمتر از ۹/۷۵ درصد تخمین



شکل (۶): توزیع خطای پیش‌بینی در آستانه‌های خطاهای مختلف در دوره آموزش



شکل (۷): توزیع خطای پیش‌بینی در آستانه‌های خطاهای مختلف در دوره آزمون

عملکرد را در میان الگوریتم‌های بررسی شده دارد (Aljarah et al, 2018). نتایج پژوهش حاضر نیز، به نوعی دقت بالای این الگوریتم بهینه‌سازی را تصدیق می‌کند.

در جدول ۴ تعدادی از داده‌های ورودی و خروجی در فاز آزمون برای داده‌های آزمایشگاهی و همچنین مقادیر پیش‌بینی شده توسط مدل SVR-GOA نمایش داده شده است. با توجه به این جدول، آبدهی مشاهداتی و آبدهی پیش‌بینی شده توسط مدل SVR-GOA از تطابق بالایی برخوردارند.

پیش از این در پژوهش الجراح و همکاران که الگوریتم ماشین بردار پشتیبان (SVM) را با الگوریتم‌هایی نظیر CS و BA, FF, PSO, GWO, MVO, GA, GOA بهینه‌سازی نمودند، مشاهده شد که الگوریتم GOA بهترین



جدول (۴): مقادیر ورودی و خروجی مدل هوشمند SVR-GOA

θ	L/W	W/P	H_t/P	$C_d(\text{EXP})$	$C_d(\text{SVR-GOA})$
۲۰	۴/۲	۱/۳۶	۰/۴۳۴	۰/۵۶۹	۰/۵۸۷
۲۰	۴/۲	۱/۳۶	۰/۴۶۵	۰/۵۵۳	۰/۵۵۸
۲۰	۴/۲	۱/۳۶	۰/۷۷۰	۰/۳۹۱	۰/۳۹۷
۳۰	۳/۷۷	۱/۵۱	۰/۳۷۲	۰/۶۵۸	۰/۶۷۳
۳۰	۳/۷۷	۱/۵۱	۰/۸۳۶	۰/۳۸۶	۰/۳۹۰
۳۰	۳/۷۷	۱/۵۱	۰/۷۵۱	۰/۴۱۹	۰/۴۱۴
۴۰	۳/۲۱	۱/۷۷	۰/۲۳۵	۰/۸۱۸	۰/۸۱۳
۴۰	۳/۲۱	۱/۷۷	۰/۶۰۴	۰/۵۰۹	۰/۴۹۳
۴۰	۳/۲۱	۱/۷۷	۰/۷۲۳	۰/۴۴۹	۰/۴۳۲

نتیجه گیری

ارزیابی در هر دو دوره آموزش و آزمون عملکرد بهتری دارد. همچنین مقادیر میزان همبستگی که برای مدل SVR-GOA در دوره آموزش ۰/۹۹۶۵ و آزمون ۰/۹۹۲۲، برای مدل SVR-FA در دوره آموزش ۰/۹۳۴۶ و آزمون ۰/۹۵۶۴ و برای مدل SVR در دوره آموزش ۰/۹۲۸۲ به دست آمد، برتری مدل SVR-GOA را تأیید کرد. از نتایج کاربردی این پژوهش که قابل ذکر می‌باشد این است که می‌توان ضریب آبگذری سرریزهای کلیدپیانویی با ابعاد و پارامترهای هندسی مختلف را بدون انجام پژوهش زمان‌بر و هزینه‌بر آزمایشگاهی و تنها با استفاده از الگوریتم‌هایی نظیر SVR-GOA، در مدت زمان کوتاه و با دقت بالا پیش‌بینی نمود. در این صورت هم در بحث هزینه و هم در بحث زمان، صرفه جویی بسیاری صورت می‌گیرد.

سرریزها یکی از روش‌های کنترل سیلاب در سدها و انحراف و اندازه‌گیری جریان در کانال‌ها هستند. در ارتباط با مبحث سرریزها، یکی از پارامترهای هیدرولیکی مهم ظرفیت آبگذری می‌باشد. در این پژوهش، آبدهی جریان عبوری از سرریزهای کلیدپیانویی انحنادار با استفاده از مدل‌های هوشمند SVR-GOA و SVR-FA پیش‌بینی شده‌است. جهت دستیابی به این هدف، در مجموع از ۷۴ داده آزمایشگاهی برای سه مدل سرریز کلیدپیانویی قوسی با زوایای قوس متفاوت ۲۰، ۳۰ و ۴۰ درجه استفاده شد. بدین منظور با به کارگیری پارامترهای θ ، L/W ، W/P و H_t/P ، آبدهی (Cd) که خروجی مدل می‌باشد تخمین زده شد. در گام بعدی با استفاده از معیارهای ارزیابی R_2 ، MAE، RMSE و SI عملکرد مدل‌های هوشمند مذکور در دو دوره آموزش و آزمون مورد بررسی قرار گرفت. نتایج نشان داد که مدل SVR-GOA در تمامی شاخص‌های

منابع

- روشنگر، ک.، ماجدی اصل، م.، اعلمی، م. و شیری، ج. ارزیابی تاثیر تغییرات زاویه سیکل قوسی بر ضریب دبی سرریزهای کنگره‌ای قوسی و کلید پیانویی قوسی. تحقیقات آب و خاک ایران. ۲. ۴۹: ۳۴۱-۳۵۱.
- صفرزاده، ا. و نوروزی، ب. ۱۳۹۳. هیدرودینامیک سه بعدی سرریزهای کلیدپیانویی انحنادار در پلان. مجله هیدرولیک. ۹: ۳. ۶۱-۷۹.



- Anderson, R.M and Tullis, B. 2011. Influence of Piano Key weir geometry on discharge. Proc. Intl. Conf. Labyrinth and Piano Key Weirs, Liège B, 75-80. CRC Press, Boca Raton FL.
- Anderson, R.M., and Tullis, B. 2012. Comparison of Piano Key and rectangular Labyrinth weir hydraulics. J. Hydr. Engin. 138.4:358-361.
- Azimi, H., Bonakdari, H and Ebtehaj, I. 2017. A highly efficient gene expression programming model for predicting the discharge coefficient in a side weir along a trapezoidal canal. Irrigation and drainage. 66.4:655-666.
- Aljarah, I., Ala'M, A. Z., Faris, H., Hassonah, M. A., Mirjalili, S and Saadeh, H. 2018. Simultaneous feature selection and support vector machine optimization using the grasshopper optimization algorithm. Cognitive Computation, 10.3: 478-495.
- Goel, A. 2013. Modeling aeration of sharp crested weirs by using support vector machines. World Academy of Science, Engineering and Technology. 7.12: 2620-2625.
- Heidari, A. A., Faris, H., Aljarah, I and Mirjalili, S. 2019. An efficient hybrid multilayer perceptron neural network with grasshopper optimization. Soft Computing, 23.17: 7941-7958.
- Juma, I. A., Hussein, H and AL-Sarraj, M. 2014. Analysis of hydraulic characteristics for hollow semi-circular weirs using artificial neural networks. Flow Measurement and Instrumentation. 38: 49-53.
- Kabiri-Samani, A and Javaheri, A. 2012. "Discharge coefficient for free and submerged flow over piano key weirs". Journal of Hydraulic Research. 50.1: 114-120.
- Karami, H., Karimi, S., Rahmimanesh, M and Farzin, S. 2017. Predicting discharge coefficient of triangular labyrinth weir using support vector regression, support vector regression-firefly, response surface methodology and principal component analysis. Flow Measurement and Instrumentation, 55: 75-81.
- Khosshbin, F., Bonakdari, H., Ashraf Talesh, S.H., Ebtehaj, I., Zaji, A.H and 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.
- Laugier, F. 2007. Design and construction of the first Piano Key Weir (PKW) spillway at the Goulours dam. Hydropower & Dams. 14.5: 94-101.
- Laugier, F., Lochu, A., Gille, C., Leite Ribeiro, M and Boillat, J.L. 2009. Design and construction of a labyrinth PKW spillway at St-Marc Dam. J. Hydropower Dams. 15.5: 100-107.
- Leite Ribeiro, M., Bieri, M., Boillat, J.L., Schleiss, A.J., Singhal, G and Sharma, N. 2012. Discharge capacity of Piano Key Weirs. J. Hydraulic Eng. 138: 199-203.
- Leite Ribeiro, M., Pfister, M., Boillat, J.L., Schleiss, A.J and Laugier, F. 2012. Piano key weirs as efficient spillway structure. Proc. 24nd ICOLD congress on Large Dams, Kyoto, Japan, Q.94, R.13.
- Leite Ribeiro, M., Pfister, M., Schleiss, A.J and Boillat, J.L. 2012. Hydraulic design of A-type Piano Key weirs. J. Hydr. Res. 50.4: 400-408.
- Mehr, A. D., Nourani, V., Khosrowshahi, V.K and Ghorbani, M.A. 2019. A hybrid support vector regression-firefly model for monthly rainfall forecasting. International Journal of Environmental Science and Technology. 16.1: 335-346.
- Olyaie, E., Heydari, M and Banejad, H. 2018b. Estimating Discharge Coefficient of PK-Weir Under Subcritical Conditions Based on High-Accuracy Machine Learning Approach. Iran J Sci Technol Trans Civ Eng. 1-13.
- Olyaie, E., Heydari, M., Banejad, H and Chau, K.W. 2018a. A laboratory investigation on the potential of computational intelligence approaches to estimate the discharge coefficient of piano key weir. Journal of Rehabilitation in Civil Engineering. 6: 1-20.
- Pai, P.F., Hong, W.C. 2005. Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms. Electric Power Systems Research. 74.3: 417-425.
- Parsaie, A and Haghiabi, A.H. 2014. Assessment of some famous empirical equation and artificial intelligent model (MLP, ANFIS) to predicting the side weir discharge coefficient. Applied Research in Water and Wastewater. 2: 75-79.



- Roushangar, K., Alami, M.T., Shiri, J and Asl, M.M. 2018. Determining discharge coefficient of labyrinth and arced labyrinth weirs using support vector machine. *Hydrology Research*. 49.3: 924-938.
- Saremi, S., Mirjalili, S and Lewis, A. 2017. Grasshopper optimisation algorithm: theory and application. *Adv Eng Softw*. 105: 30-47
- Schleis, A. 2011. Labyrinth and piano key weirs-PKW. CRC Press, Leiden. 17-24.
- Vapnik, V.N. 1995. *The Nature of Statistical Learning Theory*. Springer, New York.
- Yang, X.S. 2009. Firefly Algorithms for Multimodal Optimization. *Stochastic Algorithms: Foundations and Applications* 5792. 169-178.
- Zhang, X., Wang, J. and Zhang, K. 2017. Short-term electric load forecasting based on singular spectrum analysis and support vector machine optimized by Cuckoo search algorithm. *Electric Power Systems Research*. 146: 270-285.
- Zhao, S and Wang, L. 2010. Support vector regression based on particle swarm optimization for rainfall forecasting. In *Computational Science and Optimization (CSO), Third International Joint Conference*. 28.2: 484-487.
- Zounemat-Kermani, M and Mahdavi-Meymand, A. 2019. Hybrid meta-heuristics artificial intelligence models in simulating discharge passing the piano key weirs. *Journal of Hydrology*. 569: 12-21.



Estimating Discharge Coefficient of Curved Piano Key Overflows Using Combination of Support Vector Regression and Grasshopper and Firefly Algorithms

Hojat Karami^{1*}, Alireza Rezaei²

Abstract

Piano-Key weirs are a new type of overflow that are designed to increase the drainage capacity of dams and canals. If the keys forming this overflow model are placed on an arc of a circle, it is called curved piano-key weir. In this research, the performance of three models of Intelligent Support Vector Regression (SVR), Support Vector Regression- Firefly (SVR-FA) and Support Vector Regression-Grasshopper (SVR-GOA) to predict curved piano-key weir flow rate were evaluated. Determination Coefficient (R²), Mean Squared Error (MAE), Root Mean Squared Error (RMSE), and Scattering Index (SI) are four statistical indicators that are used to determine the accuracy of intelligent models. The result of these evaluation criteria during the test period is that the SVR-GOA model with values of 0.99275, 0.01220, 0.00026 and 0.00046 compared to the SVR-FA model with values of 0.95666, 0.03844, 0.00200 and 0.00342 and SVR with values of 0.94249, 0.04013, 0.06027 and 0.00410 for R², MAE, RMSE and SI indicators, are more accurate in predicting curved piano-key weir flow rate.

Keywords: Support Vector Regression, Grasshopper Algorithm, Firefly Algorithm, Curved Piano-Key Weir, Discharge Coefficient

¹ Associate Professor, Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University. Email: (hkarami@semnan.ac.ir).

² Phd Student, Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University. Email: (a.rezaei@semnan.ac.ir).

Extended Abstract

Research Paper

Estimating Discharge Coefficient of Curved Piano Key Overflows Using Combination of Support Vector Regression, Grasshopper and Firefly Algorithms

Hojat Karami^{1*}, Alireza Rezaei²

^{1*} Associate Professor, Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University. Email: (hkarami@semnan.ac.ir).

² PhD Student, Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University. Email: (a.rezaei@semnan.ac.ir).



10.22125/IWE.2020.215710.1277

Received:

13. January.2020

Accepted:

05. April.2020

Available online:

10. January.2022

Keywords: Support Vector Regression, Grasshopper Algorithm, Firefly Algorithm, Curved Piano-Key Weir, Discharge Coefficient

Abstract

Piano-Key weirs are a new type of overflow that are designed to increase the drainage capacity of dams and canals. If the keys forming this overflow model are placed on an arc of a circle, it is called curved piano-key weir. In this research, the performance of three models of Intelligent Support Vector Regression (SVR), Support Vector Regression-Firefly (SVR-FA) and Support Vector Regression-Grasshopper (SVR-GOA) to predict curved piano-key weir flow rate were evaluated. Determination Coefficient (R²), Mean Squared Error (MAE), Root Mean Squared Error (RMSE), and Scattering Index (SI) are four statistical indicators that are used to determine the accuracy of intelligent models. The result of these evaluation criteria during the test period is that the SVR-GOA model with values of 0.99275, 0.01220, 0.00026 and 0.00046 compared to the SVR-FA model with values of 0.95666, 0.03844, 0.00200 and 0.00342 and SVR with values of 0.94249, 0.04013, 0.06027 and 0.00410 for R², MAE, RMSE and SI indicators, are more accurate in predicting curved piano-key weir flow rate.

1. Introduction

Overflows are one of the oldest and simplest hydraulic structures used for flow measurement, water level regulation, flood conduction and other purposes. Dam safety is directly related to the adequacy of overflow capacity and this shows the importance of this structure. In some cases, due to the topographic conditions of the area, the construction of the overflow is limited, the use of nonlinear overflows such as piano key overflows can be a good way to increase the overflow capacity to the desired value. Piano key overflows allow dam reservoirs to operate at higher altitudes, which increases the volume of storage in the reservoir (Ribeiro et al., 2012). In recent years, research has been conducted in the field of intelligent studies on piano key overflows. For example, Karami et al. by applying methods Support Vector Regression (SVR), Support Vector Regression–Firefly (SVR- Firefly), Response Surface Methodology (RSM) and Principal Component Analysis (PCA), Observed the superior performance of SVR- Firefly Model in predicting the discharge coefficient of labyrinth overflows (Karami et al., 2016).

Azimi et al. using the gene expression programming algorithm, predicted the discharge coefficient of side weir in the trapezoidal canal and observed the exact performance of this algorithm (Azimi et al., 2017).

Roshangar et al. used the support vector machine algorithm to calculate the discharge coefficient of linear and nonlinear labyrinth overflows and stated that this method was more accurate in determining the discharge coefficient of nonlinear overflows (Roushangar et al., 2017).

Olyaie et al. estimated the discharge coefficient of piano key overflow using four methods: feed forward back-propagation neural network (FFBPN), namely gene-expression programming (GEP), least square support vector machine (LSSVM) and extreme learning machine (ELM). In this study, it was reported that the performance of all four methods is optimal, but the algorithms of the LSSVM and the ELM were more accurately than other methods (Olyaie et al., 2018).

Zounemat-Kermani and Mahdavi-meymand used multi-layer perceptron neural network (MLPNN) and adaptive neuro-fuzzy inference system (ANFIS) with four meta-heuristic optimization algorithms (particle swarm optimization, genetic algorithm, firefly algorithm & moth-flame optimization) to predict discharge of piano key overflows and Showed that the particle swarm optimization and firefly algorithm meta-heuristic algorithms improve the performance of ANFIS and MLPNN, respectively (Zounemat-Kermani and Mahdavi-meymand., 2019).

A review of previous studies shows that extensive research has been done on piano key overflows. However, few studies have been conducted on curved piano key overflows as well as the use of intelligent methods to estimate the discharge coefficient of this overflow model. In this study, for the first time, the discharge coefficient of curved piano key overflows is predicted using the Support Vector Regression- Grasshopper (SVR-GOA). Also, to compare the performance accuracy of the mentioned algorithm with other algorithms, Support Vector Regression (SVR) and Support Vector Regression-Firefly (SVR-FA) models have been used.

2. Materials and Methods

In the present study, the following schematic process has been used to determine the discharge coefficient of piano key overflow using SVR, SVR-GOA and SVR-FA models (Figure 1).




Figure (1): Schematic process of forecasting of discharge coefficient piano key overflow

3. Results

In this study, the discharge coefficient of curved piano key overflows is predicted using SVR-FA and SVR-GOA models. To achieve this goal, a total of 74 laboratory data were used for three models of arched piano key weirs with different arc angles of 20, 30 and 40 degrees. The results showed that the SVR-GOA model with the correlation rate of 0.9965 in the training period and 0.9922 in the test period, has the best performance among the studied models.

4. Discussion and Conclusion

In the present study, out of 74 laboratory data, 70% of the data were used in the training period and 30% of the data in the test period. The results show that in the training phase, the SVR-GOA model with a value of R2 index equal to 0.99665 is superior to the SVR model with a value of 0.97337 and the SVR-FA model with a value of 0.96008 for the mentioned criterion. Regarding MAE, RMSE and SI indices in this period, SVR-GOA model has shown better performance with values of 0.00870, 0.00009 and 0.00016, respectively, compared to SVR model with values of 0.02226, 0.02786 and 0.04622 and The SVR-FA model with values of 0.03327, 0.0045 and 0.00239. During the test phase, the higher value of R2 index in SVR-GOA model (0.99275) than intelligent models SVR-FA (0.95666) and SVR (0.94249), indicates the high accuracy of this model. In this period, the SVR-GOA model has shown higher predictive power with values of 0.01202, 0.00026 and 0.00046 compared to the SVR-FA model with values of 0.03844, 0.200200 and 0.00342 and SVR model with values of 0.04013, 0.06027 and 0.00410 respectively for MAE, RMSE and SI indices..

5. Six important references

1. Azimi, H., Bonakdari, H and Ebtahaj, I. 2017. A highly efficient gene expression programming model for predicting the discharge coefficient in a side weir along a trapezoidal canal. *Irrigation and drainage*. 66.4:655-666.
2. Karami, H., Karimi, S., Rahmanimanesh, M and Farzin, S. 2017. Predicting discharge coefficient of triangular labyrinth weir using support vector regression, support vector regression-firefly, response surface methodology and principal component analysis. *Flow Measurement and Instrumentation*, 55: 75-81.
3. Leite Ribeiro, M., Pfister, M., Schleiss, A.J and Boillat, J.L. 2012. Hydraulic design of A-type Piano Key weirs. *J. Hydr. Res.* 50.4: 400-408.
4. Olyae, E., Heydari, M., Banejad, H and Chau, K.W. 2018. A laboratory investigation on the potential of computational intelligence approaches to estimate the discharge coefficient of piano key weir. *Journal of Rehabilitation in Civil Engineering*. 6: 1-20.
5. Roushangar, K., Alami, M.T., Shiri, J and Asl, M.M. 2018. Determining discharge coefficient of labyrinth and arced labyrinth weirs using support vector machine. *Hydrology Research*. 49.3: 924-938.
6. Zounemat-Kermani, M and Mahdavi-Meymand, A. 2019. Hybrid meta-heuristics artificial intelligence models in simulating discharge passing the piano key weirs. *Journal of Hydrology*. 569: 12-21.

Conflict of Interest

Authors declared no conflict of interest.