

ارزیابی تأثیر شکل هندسی پایه پل روی عمق آبستگي با استفاده از الگوریتم پشتیبان بردار ماشین

مهدی فولادی پناه^{۱*} و مهدی ماجدی اصل^۲

(تاریخ دریافت: ۱۳۹۹/۱/۲۵؛ تاریخ پذیرش: ۱۳۹۹/۵/۴)

چکیده

پیش‌بینی عمق آبستگي موضعی به‌عنوان پدیده‌ای پویا و غیرخطی با استفاده از روش‌هایی با توانایی پیش‌بینی مناسب همواره مورد توجه پژوهشگران بوده‌اند. از عوامل مؤثر در اندازه حفرة آبستگي، شکل هندسی پایه‌های پل است. در این پژوهش با استفاده از الگوریتم پشتیبان بردار ماشین و بر مبنای ۳۹۵ داده صحرائی سازمان زمین‌شناسی آمریکا و فروهلیچ (۱۹۸۸) در قالب دو سناریو، مقدار عمق آبستگي سه پایه پل استوانه‌ای، نوک تیز و مستطیلی بر اساس ترکیب‌های مختلف پارامترهای بی‌بعد: زاویه حمله آب (α)، عدد فرود (Fr)، نسبت طول به عرض پایه (L/b) و نسبت قطر متوسط ذرات رسوبی به عرض پایه (D_{50}/b) پیش‌بینی شدند. نتایج پژوهش ضمن تأیید عملکرد قابل قبول الگوریتم SVM برای همه پایه‌ها در هر دو سناریو نشان داد در سناریوی اول و دوم بهینه‌ترین عملکرد مربوط به پایه مستطیلی به ترتیب با ضریب همبستگی 0.87 و 0.88 و مقدار بیشینه $D_s(DDR)$ با مقادیر 0.854 و $1/229$ در فرایند تست الگوریتم بودند. همچنین تأثیر مثبت افزایش تعداد داده‌ها روی عملکرد الگوریتم SVM با افزایش شاخص‌های ارزیابی تأیید شد. مقایسه نتایج نشان داد الگوریتم SVM مقادیر آبستگي را بیشتر از مقدار مشاهداتی با خطای مطلق بین ۱۱ تا ۳۵ درصد برآورد کرده است.

واژه‌های کلیدی: ارزیابی عملکرد، آبستگي، بهینه‌سازی، روش داده-مبنا، هوش مصنوعی

۱ گروه عمران، واحد رامهرمز، دانشگاه آزاد اسلامی، رامهرمز، ایران

۲. گروه عمران، دانشگاه مراغه، مراغه، ایران

*: مسئول مکاتبات: پست الکترونیکی: fuladipناه@gmail.com


مقدمه

تغییرات شتاب و جهت جریان در مجاورت پایه‌های پل باعث ایجاد جریان نعل اسبی و در نتیجه وقوع پدیده دینامیکی و غیرخطی آبشستگی موضعی در پایه پل می‌شود. مکانیزم آبشستگی پایه پل در شکل (۱) نشان داده شده است (۱۷).

مطالعات نشان می‌دهد سالانه به‌طور متوسط ۱۵۰ پل در ایالات متحده آمریکا در اثر وقوع پدیده آبشستگی و انتقال رسوب تخریب می‌شود به طوری که ۶۰ درصد تخریب پل‌ها در ایالات متحده به دلیل آبشستگی پای پل و فقط ۲ درصد به دلیل زمین‌لرزه بوده است. روش‌های مختلفی برای تعیین میزان دقیق عمق آبشستگی توسط پژوهشگران مورد استفاده قرار گرفته است که از جمله آنها می‌توان به روش‌های تجربی، آزمایشگاهی، عددی و هوش مصنوعی اشاره کرد. استفاده از معادلات تجربی تا اواخر دهه نود میلادی بین پژوهشگران کاربرد زیادی داشت. با وجود شباهت این معادلات به یکدیگر، در بسیاری موارد فاقد پارامترهای مؤثر بر آبشستگی موضعی بودند. به همین دلیل نتایج حاصل از آنها چندان مورد اطمینان نبود و حتی مقدار برآوردی آنها ممکن بود تا ۱۰۰ درصد متفاوت باشد. از طرفی اغلب روابط تجربی در محدوده معینی از داده‌ها قابل استفاده بودند که همین امر کاربرد آنها را برای تمام شرایط محدود می‌کرد (۲۳).

در این دسته از معادلات پارامترهایی مانند $\frac{b}{D_{50}}$ ، $\frac{y}{b}$ و Fr_1 برای پیش‌بینی عمق آبشستگی مورد استفاده قرار گرفته بودند (۷). با ارائه روابط مبتنی بر مدل‌های آزمایشگاهی، دقت پیش‌بینی‌ها افزایش پیدا کرد که علت آن شناخت و کاربرد پارامترهای مؤثر در آبشستگی تحت شرایط کنترل شده و مختلف بود. از جمله محدودیت‌های این روش می‌توان به ظرفیت محدود تجهیزات هیدرولیکی و فیزیکی، زمانبر بودن آزمایش‌ها، هزینه انجام آزمایش‌ها و از همه مهم‌تر عدم اطمینان از برقراری تشابه سینماتیکی و دینامیکی بین مدل و نمونه اصلی و شبیه‌سازی دقیق جریان‌های گردابی و ثانویه اشاره کرد (۱). روش‌های آزمایشگاهی نیز در پژوهش‌های مختلف برای ارزیابی و نیز استخراج معادلات پیش‌بینی عمق آبشستگی مورد استفاده قرار

گرفته است (۲، ۳، ۴، ۹ و ۱۶). استفاده از روش‌های عددی مانند Fluent، Flow3d، SSIIM، LES و ... به دلیل امکان به‌کارگیری پارامترها و شرایط مختلف و نیز کنترل مقادیر آنها رشد چشمگیری پیدا کرد. این نرم‌افزارها با امکان شبیه‌سازی دقیق و بدون محدودیت‌های فیزیکی، اقتصادی و زمانی، جایگاه ویژه‌ای بین پژوهشگران پیدا کردند (۶، ۱۰، ۱۲ و ۲۶). یکی از متداول‌ترین روش‌های جایگزین برای روابط سنتی و تجربی موجود در مدل‌سازی پدیده‌های فیزیکی پیچیده، روش‌های موسوم به داده‌کاوی مبتنی بر هوش مصنوعی است که به‌طور وسیعی در مطالعات هیدرولیکی استفاده شده است. هوش مصنوعی به‌عنوان روشی جدید، راه حلی نوین برای استخراج روابط مخفی و پیچیده بین پارامترهای مؤثر بر پدیده غیرخطی و دینامیکی آبشستگی توسط پژوهشگران معرفی شده است از جمله روش‌های داده‌مبنا می‌توان به روش ANFIS، ANN، SVM، GE، GEP، درخت تصمیم‌گیری و ... اشاره کرد (۱۳ و ۱۴). استفاده از روش داده‌کاوی پشتیبان بردار ماشین (Support vector machine (SVM) در سال‌های اخیر مورد توجه پژوهشگران قرار گرفته است. مبانی SVM اولین بار توسط ریاضیدان روس به نام وپنیک ارائه شد. دقت کارکرد این الگوریتم تابعی از پارامترهای ورودی به مدل است. بنابراین ممکن است وجود یک پارامتر ورودی مانع حل بهینه مدل شود (۲۳). برخی غضنفری هاشمی و اعتماد شهیدی (۸) نشان دادند استفاده از پارامترهای بی‌بعد دقت پیش‌بینی مدل SVM را افزایش می‌دهد در حالی که مهندس و همکاران (۱۹) و ماجدی اصل و ولیزاده (۱۵) استفاده از داده‌های بی‌بعد در مدل SVM را نیز برای پیش‌بینی و شبیه‌سازی توصیه کرده‌اند. سیدیان و فتح‌آبادی (۲۴) با مقایسه نتایج حاصل از پیش‌بینی این روش با دیگر روش‌های داده‌کاوی نشان دادند الگوریتم SVM برتر و دقیق‌تر از دیگر روش‌ها است. پژوهش‌های مختلفی با استفاده از SVM برای شبیه‌سازی عمق آبشستگی تحت شرایط مختلف توسط پژوهشگران به‌کار گرفته شده است که نتایج آنها مؤید دقت و کارکرد بسیار مناسب SVM در پیش‌بینی و شبیه‌سازی عمق



شکل ۱. الگوی جریان و آبستگي در پایه پل

بررسی شده است. داده‌های این پژوهش از ۴۴ پل در ایالات متحده آمریکا جمع‌آوری شده‌اند. محدوده داده‌های هندسی و هیدرولیکی هر یک از شکل پایه پل‌ها در جدول ۱ ارائه شده است. داده‌های مورد استفاده در این پژوهش در قالب دو سناریو (مشمول بر: الف) شبیه‌سازی ۳۱۲ داده صحرایی جمع‌آوری شده توسط سازمان زمین‌شناسی آمریکا (USGS) (The United States Geological Survey)؛ (ب) شبیه‌سازی ۳۹۵ داده صحرایی شامل مجموع داده‌های سناریوی اول باضافه ۸۳ داده جمع‌آوری شده توسط فروهلیچ (۱۹۸۸) مورد بررسی قرار گرفته‌اند. لازم به ذکر است خصوصیات و ویژگی‌های داده‌های جمع‌آوری شده توسط USGS و فروهلیچ از نظر هیدرولیکی و رسوبي با یکدیگر متفاوت هستند و هدف از تقسیم‌بندی پژوهش در قالب دو سناریو، بررسی تأثیر شرایط مختلف جمع‌آوری داده‌ها و همچنین تعداد داده‌ها بر میزان توانایی پیش‌بینی میزان عمق آبستگي توسط الگوریتم SVM است.

تئوری پی باکینگهام

پارامترهای مؤثر بر عمق آبستگي (D_s) شامل ضریب شکل پایه (K_s)، ضریب زاویه بین جهت جریان و پایه (α)، عرض پایه (b)، طول پایه (L)، سرعت نزدیک شدن جریان به پایه (U)، عمق جریان در بالادست پایه (y)، شتاب ثقل (g)، چگالی سیال (ρ)، چگالی رسوب (ρ_s)، ویسکوزیته سیال (μ)، قطر


آبستگي است. نتایج حاصل از شبیه‌سازی عمق آبستگي تک پایه قائم با استفاده از SVM نشان از توانایی بسیار مطلوب این مدل در پیش‌بینی عمق آبستگي داشت (۵). در پژوهش انجام شده توسط نوری و همکاران (۲۰)، مقایسه بین شبیه‌سازی پدیده آبستگي با استفاده از SVM با روش‌های آماری کلاسیک حاکی از برتری مطلق الگوریتم SVM بود (۲۰). پژوهش‌های مختلفی نیز از کاربرد SVM برای شبیه‌سازی و پیش‌بینی رفتار متقابل آب و رسوب در تقابل با سازه‌های هیدرولیکی انجام شده‌اند که نتایج آنها مؤید دقت بسیار مطلوب الگوریتم SVM است (۱۱، ۱۸، ۲۱، ۲۴ و ۲۸).

همان‌طور که مرور تحقیقات گذشته نشان می‌دهد استفاده از روش‌های هوشمند داده‌مبنا در سال‌های اخیر مورد استفاده و کاربرد پژوهشگران مختلف قرار گرفته است که نتایج حاصل از آن انطباق بسیار مناسبی با مقادیر اندازه‌گیری شده نشان داده است. در این پژوهش از الگوریتم هوشمند SVM به‌منظور بررسی تأثیر شکل پایه پل (استوانه‌ای، مستطیلی و نوک تیز) روی عمق آبستگي موضعی بر مبنای داده‌های صحرایی استفاده شده است.

مواد و روش‌ها

مشخصات داده‌ها

در این پژوهش تأثیر سه شکل پایه پل شامل استوانه‌ای، نوک تیز و مستطیلی (شکل ۲) بر میزان عمق آبستگي پایه پل



شکل ۲. شکل پایه‌های پل

جدول ۱. دامنه متغیرهای اندازه‌گیری شده در این پژوهش

D _s (m)	D _{۵۰} (mm)		U (m/s)	y (m)	α (rad)	L (m)		b (m)		تعداد داده‌ها	شکل پایه											
	پیشینه	متوسط				پیشینه	متوسط	پیشینه	متوسط			پیشینه	متوسط									
۶/۴۳	۱/۰۳	۰/۰۹	۹/۱۶	۰/۰۵	۴/۰۸	۱/۲۲	۰/۰۵	۱۲/۰۴	۳/۶۸	۰/۱۵	۸۵/۰	۳/۹۰	۰/۰	۲۲/۹	۸/۵۱	۰/۳۰	۵/۹۴	۱/۴۲	۰/۳	۲۲۱	استوانه‌ای	
۷/۶۵	۱/۱۹	۰/۰۵	۱۰/۸۰	۲۷/۱۱	۰/۰۱	۳/۶۶	۱/۴۶	۰/۱۹	۲۰/۰۳	۳/۳۴	۰/۱۲	۴۲/۰	۸/۴۱	۰/۰	۲۷/۴۳	۹/۶۴	۱/۸۶	۵/۴۶	۱/۶۲	۰/۱۶	۶۳	نوک تیز
۴/۵۷	۰/۹۸	۰/۰۹	۳۶/۰	۱/۵۳	۰/۳۸	۲/۲۶	۰/۹۵	۰/۰۹	۱۵/۳۶	۴/۵۷	۰/۱۳	۲۶/۰	۷/۳۲	۰/۰	۱۰/۸۰	۷/۹۸	۱/۱۲	۵/۵۲	۱/۲۸	۰/۰۹	۱۱۱	مستطیلی

روش‌های هوش مصنوعی که خطای محاسباتی را کاهش می‌دهند، با هدف قرار دادن ریسک عملیاتی، مقدار جواب بهینه را به دست می‌آورد (۲۶). این الگوریتم در واقع حداقل خطا را با استفاده از قیدها جستجو می‌کند. الگوریتم SVM بر اساس اطلاعات محدود نمونه‌ها، بهترین گزینه را بین مدل‌ها با پیچیدگی‌های مختلف و توانایی آموزش این مدل‌ها دنبال می‌کند (۲۶). رابطه رگرسیونی این الگوریتم به قرار زیر است:

$$f(x) = \sum_{i=1}^D W_i \varphi_i(x) + b \quad (2)$$

در این معادله $\varphi_i(x)$ ویژگی‌ها (Features)، b مقدار خطا و W_i بردارهای وزنی است که با استفاده از داده‌ها تخمین زده می‌شود. در حقیقت با استفاده از تکنیک SVM، داده‌های ورودی به یک فضا با ابعاد بسیار نگاهت می‌شوند. در این

متوسط ذرات بستر (D_{50}) و انحراف معیار هندسی ذرات بستر (σ_g) است. با استفاده از تئوری پی‌باکینگهام و با صرف نظر کردن از پارامترهای غیر مؤثر در آبشستگی، فرم نهایی معادله بین پارامترهای مستقل و وابسته به صورت زیر به دست آمد:

$$\frac{D_s}{b} = F\left(\frac{L}{b}, \frac{D_{50}}{b}, Fr, \alpha\right) \quad (1)$$

الگوریتم پشتیبان بردار ماشین

پشتیبان بردار ماشین یکی از روش‌های یادگیری با نظارت است. یادگیری تحت نظارت، نیازمند تعدادی داده ورودی به‌منظور آموزش سیستم است. الگوریتم SVM، روشی نوین بر مبنای تئوری آموزش آماری است که در پیش‌بینی پارامترهای مختلف مورد استفاده قرار می‌گیرد. پشتیبان بردار ماشین برعکس دیگر

جدول ۲. انواع توابع کرنل

نام کرنل	رابطه کرنل
خطی	$K(x_i, x_j) = (x_i, x_j)$
چند جمله‌ای	$K(x_i, x_j) = [(x_i, x_j) + 1]^d$
تابع پایه شعاعی	$K(x_i, x_j) = \exp\left[-\frac{x_i - x_j^2}{2\sigma^2}\right]$
سیگموئید	$K(x_i, x_j) = \tanh[-\alpha(x_i, x_j) + c]$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N [x_{O_i} - x_{P_i}]^2}{N}} \quad (6)$$

$$MNE = \frac{\sum_{i=1}^N \frac{x_{O_i} - x_{P_i}}{x_{O_i}}}{N} \quad (7)$$

که در این روابط R ضریب همبستگی، RMSE مجذور میانگین مربعات خطا، شاخص MNE نشان‌دهنده میانگین خطای نرمال، x_o و x_p به ترتیب بیانگر متغیر اندازه‌گیری و پیش‌بینی شده هستند. شاخص‌های آماری ارزیابی عملکرد که در بالا گفته شد، توصیف-گر خطای متوسط هستند و قضاوت صحیحی در خصوص عملکرد مدل‌ها و همچنین توزیع خطاها نمی‌توانند ارائه کنند. برای رفع این محدودیت، نوری و همکاران (۲۰) استفاده از آماره نسبت تفاوت توسعه داده شده (Developed Discrepancy Ratio) (DDR) به قرار زیر پیشنهاد شده است (۳۰):

$$DDR = \frac{\text{مقدار پیش‌بینی شده}}{\text{مقدار مشاهده شده}} - 1 \quad (8)$$

مقدار $DDR=0$ بیانگر معادل بودن مقادیر پیش‌بینی شده و مشاهده شده، $DDR>0$ بیانگر بیشتر بودن مقدار پیش‌بینی شده از مقدار مشاهده شده و $DDR<0$ بیانگر کم بودن مقدار پیش‌بینی شده از مقدار مشاهده شده است. برای قضاوت بهتر استفاده و محاسبه تابع گوسی مقادیر DDR توصیه شده است که به صورت توزیع نرمال استاندارد رسم می‌شود. تمایل بیشتر به سمت محور عمودی همراه با مقادیر بزرگ‌تر روی آن محور بیانگر دقت زیاد عملکرد مدل مورد نظر خواهد بود. برای رسم منحنی، باید مقادیر استاندارد شده DDR با استفاده از تابع گوسی مقادیر نرمال شده DDR محاسبه شوند (۲۰).

روش یک رگرسیون غیرخطی با ابعاد فضایی بسیار کم به یک رگرسیون خطی با ابعاد فضایی بسیار زیاد تبدیل می‌شود. بر اساس حداقل‌سازی مقدار خطا پارامتر $w_i(x)$ با استفاده از داده‌ها براساس بهینه‌سازی ارائه شده در معادله (۳) تعیین می‌شود:

$$\min \frac{1}{2} W^2 + c \sum_{i=1}^N (\xi_i + \xi_i^0) \quad (3)$$

تابع خطای مذکور لازم است که با توجه به محدودیت‌های ارائه شده در معادله (۴) کمینه شود:

$$\begin{cases} -y_i < W^T \varphi(X_i) < -b \leq \varepsilon + \xi_i \\ \xi_i \geq 0, \xi_i^0 \geq 0 \quad i=1,2,\dots,N \end{cases} \quad (4)$$

در این معادلات C ثابت گنجایش (Capacity constant)، W بردار ضرایب، W^T ترانهاده بردار ضرایب، ξ_i^0 و ξ_i ضرایب کمبود، N الگوی آموزش مدل و φ تابع کرنل است. معادلات مختلفی برای تابع کرنل وجود دارد که در جدول ۲ ارائه شده اند. از بین توابع مذکور، تابع پایه شعاعی (Radial Base Function) (RBF) به عنوان بهترین انتخاب توسط پژوهشگران مختلف مورد اشاره قرار گرفته است (۲۷). بنابراین برای تخمین دقیق میزان عمق آبخستگی، لازم است مقادیر پارامترهای تنظیمی ε ، γ و C بهینه‌سازی شوند.

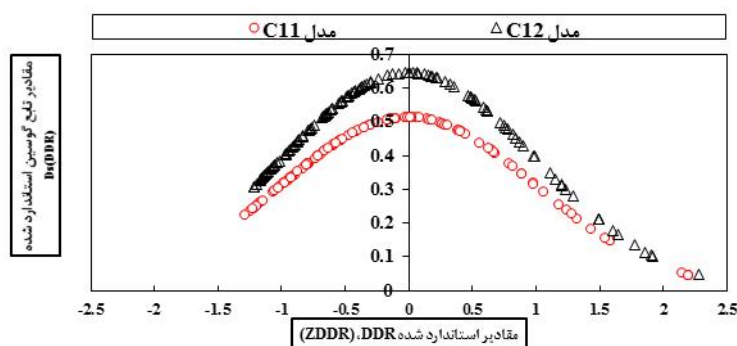
معیارهای ارزیابی

برای ارزیابی دقت الگوریتم SVM در پیش‌بینی عمق آبخستگی از معیارهای زیر استفاده شده است:

$$R = \frac{\sum_{i=1}^N [x_{O_i} - \bar{x}_O][x_{P_i} - \bar{x}_P]}{\sqrt{\sum_{i=1}^N [x_{O_i} - \bar{x}_O]^2 \sum_{i=1}^N [x_{P_i} - \bar{x}_P]^2}} \quad (5)$$

جدول ۳. نتایج ارزیابی شبیه‌سازی عمق آبشستگی در سناریوی اول با استفاده از داده‌های USGS پایه استوانه‌ای

فاز تست			فاز آموزش			نام مدل	پارامترهای ورودی به SVM
MNE	RMSE	R	MNE	RMSE	R		
۰/۸۶۷۹	۰/۳۴۱۲	۰/۸۴۵۵	۰/۷۳۲۹	۰/۳۳۲۴	۰/۸۵۵۱	C11	$\frac{L}{b}, \frac{D_{50}}{b}, Fr, \alpha$
۰/۴۴۴۸	۰/۳۰۸۲	۰/۸۰۷۸	۰/۵۰۷۷	۰/۳۰۷۱	۰/۷۶۷۲	C12	$\frac{L}{b}, \frac{D_{50}}{b}, Fr$
۰/۹۶۶۱	۰/۲۹۳۹	۰/۶۵۳۷	۰/۸۹۴۸	۰/۳۴۴۱	۰/۶۶۹۷	C13	$\frac{L}{b}, \frac{D_{50}}{b}, \alpha$
۰/۶۹۳۴	۰/۳۲۷۰	۰/۶۳۱۰	۰/۶۸۲۰	۰/۳۱۲۹	۰/۶۵۱۲	C14	$\frac{L}{b}, Fr$
۰/۹۰۰۱	۰/۳۲۸۹	۰/۶۰۱۹	۰/۸۹۳۲	۰/۳۳۹۰	۰/۶۳۳۳	C15	$\frac{L}{b}, \frac{D_{50}}{b}$
۰/۸۴۱۰	۰/۳۱۸۵	۰/۶۲۸۱	۰/۷۵۹۰	۰/۳۱۴۶	۰/۶۶۰۵	C16	$\frac{D_{50}}{b}, Fr$



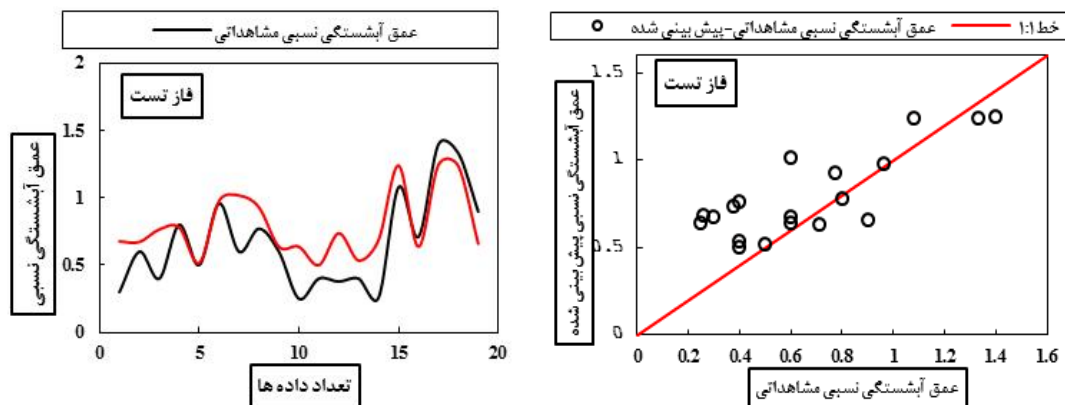
شکل ۳. توزیع نرمال استاندارد شده مقادیر DDR برای مدل‌های C11 و C12 پژوهش حاضر برای عمق آبشستگی

نتایج

سناریوی اول

شکل استوانه‌ای، مدل C12 با سه پارامتر $Fr, \frac{D_{50}}{b}$ و $\frac{L}{b}$ منجر به دقیق‌ترین نتیجه برای شبیه‌سازی عمق آبشستگی توسط SVM شده است (جدول ۳). مطابق شکل ۳، بیشینه مقدار $D_s(DDR)$ برای مدل‌های C11 و C12 به ترتیب ۰/۵۱۳ و ۰/۶۴۶ حاصل شده‌اند که مؤید برتری مدل سه‌پارامتری C12 برای شبیه‌سازی عمق آبشستگی توسط الگوریتم SVM است. در شکل ۴ مقایسه بین داده‌های مشاهداتی و پیش‌بینی شده برای مدل C12 در فاز تست ارائه شده است. می‌توان گفت دقت مدل در مقادیر حدی عمق آبشستگی کمتر از مقادیر حد وسط است. طی فرایندهای آموزش و تست، مدل SVM به ترتیب ۶۳ و ۷۴ درصد از موارد، عمق آبشستگی را بیشتر از مقدار واقعی به ترتیب با خطای مطلق ۲۸ و ۲۵ درصد پیش‌بینی کرده است. از طرفی، با افزایش تعداد داده‌ها، دقت پیش‌بینی مدل نیز افزایش نشان داده است.

در این سناریو، مقدار عمق آبشستگی برای داده‌های صحرایی جمع‌آوری شده توسط USGS براساس ترکیبی از چهار پارامتری بعد ارائه شده در معادله ۱ با استفاده از مدل SVM شبیه‌سازی شدند. با اجرای مدل SVM بر مبنای ترکیب‌های مختلف از پارامترهای $Fr, \frac{D_{50}}{b}$ و $\frac{L}{b}$ ، مقدار عمق آبشستگی برای هر یک از سه شکل پایه پل شبیه‌سازی شدند. برای سهولت، پایه‌های استوانه‌ای، نوک تیز و مستطیلی به ترتیب با حروف C, S و R نمایش داده شده‌اند. بعد از نماد هر پایه، عدد اول نشان‌دهنده شماره سناریو و عدد دوم نشان‌دهنده شماره مدل است. نتایج فرایند شبیه‌سازی در گام‌های آموزش و تست برای هر یک از پایه‌ها در جدول‌هایی بر مبنای شاخص‌های ارزیابی ارائه شده‌اند. برای



شکل ۴. فاز آموزش و تست الگوریتم SVM برای مدل C۱۲ (رنگی در نسخه الکترونیکی)

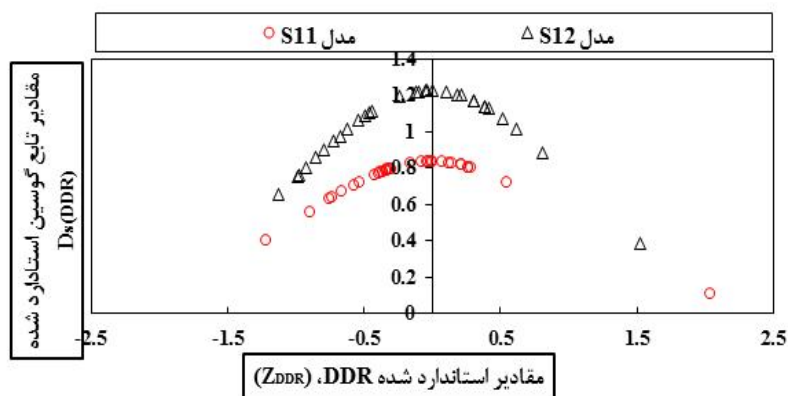
جدول ۴. نتایج ارزیابی شبیه‌سازی عمق آبستنگی در سناریوی اول با استفاده از داده‌های USGS پایه نوک تیز

فاز تست			فاز آموزش			نام مدل	پارامترهای ورودی به SVM
MNE	RMSE	R	MNE	RMSE	R		
۰/۲۸۰۵	۰/۱۸۲۰	۰/۸۵۷۴	۰/۲۵۰۰	۰/۱۷۴۲	۰/۹۲۱۶	S۱۱	$\frac{L}{b}, \frac{D_{50}}{b}, Fr, \alpha$
۰/۲۸۷۸	۰/۱۷۶۱	۰/۸۶۸۱	۰/۲۱۳۱	۰/۱۷۵۷	۰/۹۴۵۴	S۱۲	$\frac{L}{b}, \frac{D_{50}}{b}, Fr$
۰/۲۸۹۵	۰/۲۰۱۳	۰/۸۴۲۲	۰/۲۳۳۰	۰/۱۸۲۰	۰/۹۱۴۶	S۱۳	$\frac{L}{b}, \frac{D_{50}}{b}, \alpha$
۰/۳۴۸۹	۰/۲۴۶۷	۰/۸۵۱۴	۰/۲۱۴۹	۰/۱۸۵۰	۰/۸۹۴۲	S۱۴	$\frac{L}{b}, Fr$
۰/۳۸۱۰	۰/۲۸۶۰	۰/۸۱۰۷	۰/۲۲۸۱	۰/۱۸۲۳	۰/۸۷۷۲	S۱۵	$\frac{L}{b}, \frac{D_{50}}{b}$
۰/۳۵۰۱	۰/۲۴۶۶	۰/۸۲۹۱	۰/۲۳۶۷	۰/۱۸۳۷	۰/۸۹۶۱	S۱۶	$\frac{D_{50}}{b}, Fr$

حاصل شده‌اند که تأیید کننده برتری مدل R۱۲ است. مقدار عمق آبستنگی نسبی در ۶۴ و ۵۴ درصد موارد به ترتیب طی فرایندهای آموزش و تست توسط الگوریتم SVM پیش‌بینی شده است. مقدار خطای مطلق برای این شبیه‌سازی به ترتیب ۲۸ و ۳۵ درصد در دوره‌های آموزش و تست حاصل شدند برای نمونه تغییرات پارامتر تنظیمی γ برای مدل R۱۲ در برابر شاخص‌های R و RMSE در شکل ۷ رسم شده است. همان‌طور که مشخص است بهترین‌ترین مقدار $\gamma=۴۳$ به ترتیب متناظر با مقادیر R و RMSE برابر با ۰/۸۶۸۱ و ۰/۱۷۶۲ حاصل شده است. همچنین مقایسه‌ای بین عملکرد مدل SVM بین مدل‌های برتر سه پایه در شکل ۸ انجام شده است که نشان‌دهنده شبیه‌سازی دقیق‌تر عمق آبستنگی برای پایه نوک تیز توسط الگوریتم SVM نسبت به دیگر شکل‌ها است.

مدل S۱۲ نسبت به مدل S۱۱ مطابق جدول ۴ مقادیر شبیه‌سازی شده دقیق‌تری با استفاده از الگوریتم SVM تولید کرده است. براساس شکل ۵، حداکثر مقدار $D_s(DDR)$ برای مدل‌های S۱۱ و S۱۲ به ترتیب ۰/۸۳۴ و ۱/۲۲۸ هستند که تأیید کننده برتری مدل سه‌پارامتری S۱۲ است. مقدار عمق آبستنگی پیش‌بینی شده توسط مدل SVM طی فرایندهای آموزش و تست به ترتیب ۶۰ و ۷۵ درصد از موارد بیشتر از عمق مشاهداتی با خطای مطلق ۱۶ و ۱۸ درصد بوده است.


بر اساس مقادیر به دست آمده برای شاخص‌های ارزیابی در جدول ۵، مدل سه پارامتری R۱۲ نسبت به دیگر مدل‌ها دقت زیادی دارد. مقادیر بیشینه $D_s(DDR)$ برای مدل‌های چهار و سه پارامتری R۱۱ و R۱۲ بر اساس شکل ۶ به ترتیب ۰/۲۴۶ و ۰/۸۵۴



شکل ۵. توزیع نرمال استاندارد شده مقادیر DDR برای مدل‌های S11 و S12 پژوهش حاضر برای عمق آبشستگی


جدول ۵. نتایج ارزیابی شبیه‌سازی عمق آبشستگی در سناریوی اول با استفاده از داده‌های USGS پایه مستطیلی

فاز تست			فاز آموزش			نام مدل	پارامترهای ورودی به SVM
MNE	RMSE	R	MNE	RMSE	R		
۱/۳۷۹۸	۰/۵۶۰۱	۰/۸۳۷۶	۱/۰۳۳۵	۰/۵۳۷۲	۰/۸۴۱۰	R11	$\frac{L}{b}, \frac{D_{50}}{b}, Fr, \alpha$
۰/۴۵۶۶	۰/۴۲۳۶	۰/۸۷۰۲	۰/۳۹۵۰	۰/۴۲۲۵	۰/۸۷۰۶	R12	$\frac{L}{b}, \frac{D_{50}}{b}, Fr$
۰/۶۷۲۴	۰/۵۵۶۳	۰/۸۲۷۰	۰/۳۸۰۰	۰/۵۸۱۰	۰/۸۳۴۵	R13	$\frac{L}{b}, \frac{D_{50}}{b}, \alpha$
۰/۶۳۲۸	۰/۵۷۱۹	۰/۷۹۸۱	۰/۳۹۱۲	۰/۶۲۱۹	۰/۸۰۱۷	R14	$\frac{L}{b}, Fr$
۰/۷۰۳۶	۰/۵۹۹۳	۰/۷۸۳۲	۰/۷۶۴۰	۰/۶۰۱۲	۰/۷۹۰۰	R15	$\frac{L}{b}, \frac{D_{50}}{b}$
۰/۶۴۹۰	۰/۵۶۹۸	۰/۸۱۷۹	۰/۳۹۳۳	۰/۵۹۲۱	۰/۸۲۶۶	R16	$\frac{D_{50}}{b}, Fr$

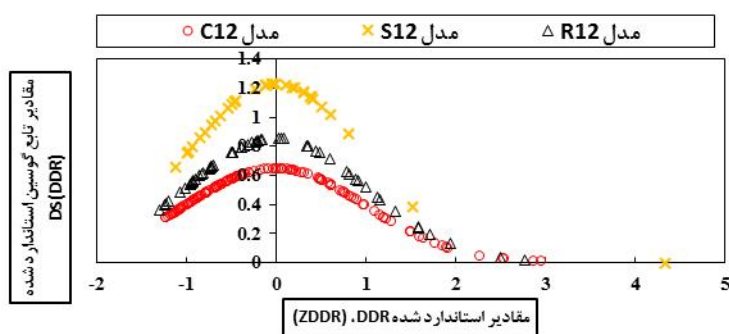


شکل ۶. توزیع نرمال استاندارد شده مقادیر DDR برای مدل‌های R11 و R12 پژوهش حاضر برای عمق آبشستگی

(رنگی در نسخه الکترونیکی)



شکل ۷. نمودار تغییرات γ در برابر R و RMSE برای مدل R12 در سناریوی اول (رنگی در نسخه الکترونیکی)



شکل ۸. مقایسه ارزیابی عملکرد مدل SVM در سناریوی اول براساس شکل پایه (رنگی در نسخه الکترونیکی)

سناریوی دوم

با ترکیب داده‌های USGS و فروهلیچ، سناریوی دوم پژوهش حاصل شده است. بر اساس جدول ۶، مدل سه پارامتری C22 منجر به کارکرد بهینه مدل SVM شده است. همان‌طور که شکل ۹ نیز نشان می‌دهد مقدار بیشینه $D_s(DDR)$ برای مدل‌های C21 و C22 به ترتیب ۰/۵۲۲ و ۰/۷۳۳ است که مؤید برتری مدل سه پارامتری C22 است. در ۵۶ و ۵۲ درصد موارد از داده‌ها طی فرایند آموزش و تست مدل SVM عمق آبخستگی را بیشتر از مقدار مشاهداتی به ترتیب با خطای مطلق ۲۰/۳ و ۱۹/۸ درصد برآورد کرده است. در مقایسه با مدل پایه استوانه‌ای در سناریوی اول، افزایش تعداد داده‌ها منجر به کاهش مقدار مطلق داده‌ها شده است. همچنین مقدار $D_s(DDR)$ پایه استوانه‌ای در سناریوی دوم نسبت به سناریوی اول افزایش نشان می‌دهد که این امر بیانگر بهبود کارکرد الگوریتم SVM همراه با افزایش تعداد داده‌ها است.


مقادیر شاخص‌های ارزیابی در جدول ۷ نشان‌دهنده برتری

مدل چهار پارامتری S21 نسبت به دیگر مدل‌ها است. مقدار بیشینه $D_s(DDR)$ با مقدار ۱/۱۹۶ نسبت به دیگر مدل‌ها در شکل ۱۰ نیز برتری مدل چهار پارامتری را نسبت به مابقی مدل‌ها و به‌خصوص مدل S11 تأیید می‌کند. عمق آبخستگی نسبی پیش‌بینی شده توسط الگوریتم SVM در ۵۸ و ۵۷ درصد موارد فازهای آموزش و تست از مقادیر مشاهداتی با خطای مطلق ۱۴ و ۱۱ درصد بیشتر است.

طبق مقادیر شاخص‌های ارزیابی در جدول ۸، مدل R21 نسبت به دیگر مدل‌ها برتری محسوسی در برآورد عمق آبخستگی نسبی پیش‌بینی شده به الگوریتم SVM داشته است. با استفاده از شکل ۱۱، مقدار بیشینه $D_s(DDR)$ با مقدار ۱/۲۲۹ برای مدل R21 نسبت به مدل R12 علاوه بر برتری مدل، مؤید تأثیر تعداد داده روی دقت پیش‌بینی مدل نیز است در این مدل نیز، عمق آبخستگی پیش‌بینی شده طی فرایندهای آموزش و تست به ترتیب در ۴۸ و ۴۷ درصد موارد بیشتر از مقدار مشاهداتی با خطای مطلق ۱۷ و ۲۱ درصد است. در این سناریو نیز، طبق شکل ۱۲ عملکرد

جدول ۶. نتایج ارزیابی شبیه‌سازی عمق آبستگي در سناریوی دوم با استفاده از داده‌های USGS پایه استوانه‌ای

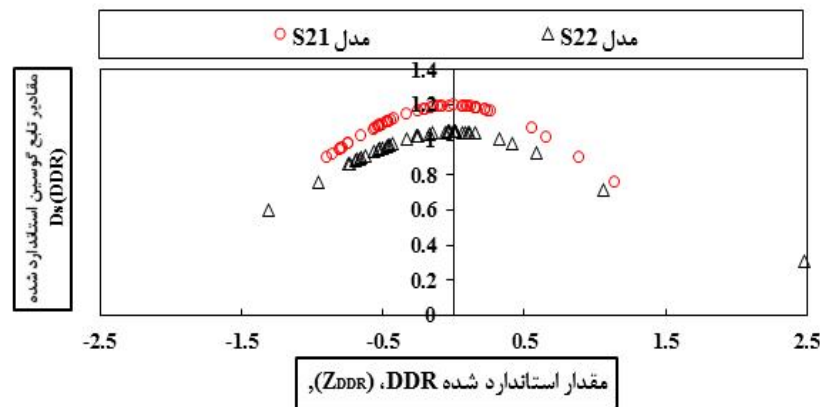
فاز تست			فاز آموزش			نام مدل	پارامترهای ورودی به SVM
MNE	RMSE	R	MNE	RMSE	R		
۰/۵۳۰۱	۰/۲۹۸۲	۰/۷۵۴۹	۰/۶۹۴۳	۰/۲۸۸۸	۰/۷۶۵۷	C۲۱	$\frac{L}{b}, \frac{D_{50}}{b}, Fr, \alpha$
۰/۴۰۰۱	۰/۲۷۲۱	۰/۷۶۰۱	۰/۳۸۵۰	۰/۲۶۴۱	۰/۸۵۵۶	C۲۲	$\frac{L}{b}, \frac{D_{50}}{b}, Fr$
۰/۹۴۱۱	۰/۲۹۴۱	۰/۵۳۷۴	۱/۰۹۶	۰/۳۶۱۲	۰/۵۶۷۹	C۲۳	$\frac{L}{b}, \frac{D_{50}}{b}, \alpha$
۰/۸۵۲۰	۰/۲۸۳۱	۰/۵۴۱۰	۰/۸۶۱۱	۰/۳۲۱۶	۰/۵۵۳۱	C۲۴	$\frac{L}{b}, Fr$
۰/۶۷۵۴	۰/۲۹۶۹	۰/۵۲۰۰	۰/۵۱۰۷	۰/۳۸۵۶	۰/۵۵۶۵	C۲۵	$\frac{L}{b}, \frac{D_{50}}{b}$
۰/۸۳۱۵	۰/۲۸۴۰	۰/۴۶۸۱	۰/۷۶۴۲	۰/۳۳۱۹	۰/۵۳۲۹	C۲۶	$\frac{D_{50}}{b}, Fr$



شکل ۹. توزیع نرمال استاندارد شده مقادیر DDR برای مدل‌های C۲۱ و C۲۲ پژوهش حاضر برای عمق آبستگي

جدول ۷. نتایج ارزیابی شبیه‌سازی عمق آبستگي در سناریوی دوم با استفاده از داده‌های USGS پایه نوک تیز


فاز تست			فاز آموزش			نام مدل	پارامترهای ورودی به SVM
MNE	RMSE	R	MNE	RMSE	R		
۰/۳۱۴۸	۰/۲۸۱۳	۰/۸۷۸۰	۰/۲۳۹۹	۰/۲۰۴۹	۰/۹۵۱۴	S۲۱	$\frac{L}{b}, \frac{D_{50}}{b}, Fr, \alpha$
۰/۳۴۱۹	۰/۲۶۱۸	۰/۸۳۴۱	۰/۲۹۹۲	۰/۲۱۴۹	۰/۸۴۰۱	S۲۲	$\frac{L}{b}, \frac{D_{50}}{b}, Fr$
۰/۳۵۱۷	۰/۲۹۱۰	۰/۸۱۵۰	۰/۳۰۲۳	۰/۲۱۹۳	۰/۸۴۰۱	S۲۳	$\frac{L}{b}, \frac{D_{50}}{b}, \alpha$
۰/۳۳۷۵	۰/۲۹۹۲	۰/۸۲۷۸	۰/۲۹۰۰	۰/۲۲۳۸	۰/۸۵۱۷	S۲۴	$\frac{L}{b}, Fr$
۰/۳۴۲۲	۰/۳۰۰۱	۰/۸۰۹۳	۰/۳۲۶۱	۰/۲۱۷۰	۰/۸۲۴۸	S۲۵	$\frac{L}{b}, \frac{D_{50}}{b}$
۰/۳۳۰۰	۰/۲۸۵۹	۰/۸۲۸۶	۰/۲۸۰۳	۰/۲۲۷۹	۰/۸۵۲۴	S۲۶	$\frac{D_{50}}{b}, Fr$




شکل ۱۰. توزیع نرمال استاندارد شده مقادیر DDR برای مدل‌های S21 و S22 پژوهش حاضر برای عمق آبخستگی

جدول ۸. نتایج ارزیابی شبیه‌سازی عمق آبخستگی در سناریوی دوم با استفاده از داده‌های USGS پایه مستطیلی

فاز تست			فاز آموزش			نام مدل	پارامترهای ورودی به SVM
MNE	RMSE	R	MNE	RMSE	R		
۰/۵۴۴۴	۰/۵۰۸۸	۰/۸۸۳۸	۰/۲۱۷۲	۰/۱۷۳۷	۰/۹۶۷۲	R21	$\frac{L}{b}, \frac{D_{50}}{b}, Fr, \alpha$
۰/۶۵۴۸	۰/۵۱۳۴	۰/۷۸۱۶	۰/۴۲۲۴	۰/۳۱۵۲	۰/۸۹۵۴	R22	$\frac{L}{b}, \frac{D_{50}}{b}, Fr$
۰/۶۸۳۳	۰/۵۴۰۰	۰/۷۸۰۲	۰/۳۷۵۱	۰/۳۱۸۳	۰/۸۶۷۰	R23	$\frac{L}{b}, \frac{D_{50}}{b}, \alpha$
۰/۶۶۱۵	۰/۵۲۶۱	۰/۷۷۹۵	۰/۴۰۷۶	۰/۳۱۷۷	۰/۸۷۵۲	R24	$\frac{L}{b}, Fr$
۰/۶۹۳۷	۰/۵۵۸۶	۰/۷۷۶۲	۰/۳۵۰۱	۰/۳۲۶۱	۰/۸۵۱۸	R25	$\frac{L}{b}, \frac{D_{50}}{b}$
۰/۶۶۸۳	۰/۵۲۸۸	۰/۷۷۸۰	۰/۳۴۱۵	۰/۳۱۸۰	۰/۸۸۳۲	R26	$\frac{D_{50}}{b}, Fr$



شکل ۱۱. توزیع نرمال استاندارد شده مقادیر DDR برای مدل‌های R21 و R22 پژوهش حاضر برای عمق آبخستگی



شکل ۱۲. مقایسه ارزیابی عملکرد مدل SVM در سناریوی دوم براساس شکل پایه

گرفتند. نتایج این پژوهش نشان داد بر مبنای شاخص‌های ارزیابی آماری، الگوریتم SVM توانایی قابل قبولی در برآورد عمق آبشستگی پایه‌های پل دارد. در هر دو سناریو، الگوریتم SVM عمق آبشستگی پایه مستطیلی شکل را با دقت بالاتری نسبت به دیگر پایه‌ها برآورد می‌کند. افزایش تعداد داده منجر به بهبود عملکرد الگوریتم داده مبنای SVM می‌شود. الگوریتم SVM عمق آبشستگی را در بیشتر موارد زیادتز عمق اندازه‌گیری شده و با خطای مطلق بین ۱۱ تا ۳۵ درصد پیش‌بینی می‌کند.

الگوریتم SVM برای پایه نوک‌تیز نسبت به دیگر پایه‌ها برتری دارد.

نتیجه‌گیری

در این پژوهش، قابلیت پیش‌بینی الگوریتم پشتیبان بردار ماشین (SVM) در تخمین عمق آبشستگی پایه پل براساس نوع پایه پل و با استفاده از داده‌های صحرایی بررسی شده است. بدین منظور از دو سری داده صحرایی مختلف به تعداد ۳۹۵ داده استفاده شد که این داده‌ها در دو سناریو و هر سناریو شامل سه پایه پل استوانه‌ای، نوک تیز و مستطیلی مورد مطالعه قرار

منابع مورد استفاده

1. Bateni, S. M., S. M. Borghei and D. S. Jeng. 2007. Neural network and neuro-fuzzy assessments for scour depth around bridge piers. *Engineering Applications of Artificial Intelligence* 20: 401-414.
2. Bayram, A. and M. Larson. 2000. Analysis of scour around a group of vertical piles in the field. *Journal of the Waterway, Port, Coastal, and Ocean Engineering* 126(4): 215-220.
3. Dargahi, B. 1990. Controlling mechanism of local scouring. *Journal of Hydrologic Engineering* 116: 1197-1214.
4. Dey, S. and R. V. Raikar. 2007. Characteristics of horseshoe vortex in developing scour holes at piers. *Journal of Hydraulic Engineering* 133(4): 399-413.
5. Dibike, Y. B., S. Velickov, D. P. Solomatine and M. B. Abbott. 2001. Model induction with support vector machines: introduction and applications. *Journal of Computing in Civil Engineering* 15: 208-216.
6. Esmaili T., A. A. Dehghani, A. R. Zahiri and K. Suzuki. 2009. 3D numerical simulation of scouring around bridge piers (case study: bridge 524 crosses the Tanana river). In: proceeding of 2009 World Academy of Science conference, Engineering and Technology, Venice, Italy.
7. Ghanbari Adivi, E. and M. Kashefipour Dezfuli. 2017. Estimation of scour depth at bridge piers by using FASTER model and experimental formulas. *Water Resources Management* 9: 1-10. (In Farsi).
8. Ghazanfari Hashemi, S. and A. Etemad-Shahidi. 2012. Prediction of scour depth around bridge pier by support vector machines. *Modares Civil Engineering Journal* 12(2): 23-35. (In Farsi).

9. Ghodsi, H. and M. J. Khanjani. 2018. Experimental investigation of local scour around complex bridge pier. *Journal of Irrigation and Water Engineering* 31: 35-47. (In Farsi).
10. Jafari, M., S. A. Ayyoubzadeh, M. Esmaceli Varaki and M. Rostami. 2017. Simulation of Flow Pattern around Inclined Bridge Group Pier using FLOW-3D Software. *Journal of Water and Soil* 30(6): 1860-1873. (In Farsi).
11. Kakaei Lafdani, E., A. Moghaddam Nia and A. Ahmadi. 2012. Daily suspended sediment load prediction using artificial neural networks and support vector machines machine. *Journal of Hydrology* 50-62.
12. Kardan, N., N. Hassanpour and A. H. Hoseinzade-Dalir. 2018. Experimental and numerical investigation of bed erosion around bridge piers with different cross-sections. *Irrigation and Drainage Structures Engineering Research* 19(71):19-36. (In Farsi).
13. Lu, J. Y., Zh. H. Shi, J. H. Hong, J. J. Lee and R. V. Raikar. 2011. Temporal variation of scour depth at no uniform cylindrical piers. *Journal of Hydraulic Engineering* 137(1): 45-56.
14. Mahesh P., N. K. Singh and N. K. Tiwari. 2011. Support vector regression based modeling of pier scour using field data. *Engineering Applications of Artificial Intelligence* 24: 911-916.
15. Majedi Asl, M. and S. Valizadeh. 2018. Application of SVM algorithm in predicting vertical pier scour depth. *Journal of Water and Soil Science (Science and Technology of Agriculture and Natural Resources)* 23: 165-181. (In Farsi).
16. Majediasl, M., K. Daneshfaraz and S. Valizadeh. 2019. Experimental investigation of the river materials mining effect on the scouring around armed pier groups. *Iranian Journal of Soil and Water Research* 50(6): 1363-1380. (In Farsi).
17. Meshkavati Toroujeni, S. J., S. M. Saneie, M. Masoudian and M. Kh. Ziatabar Ahmadi. 2014. Investigation of the effect of discharge and pier diameter size in depth and volume of local scour around bridge pier. *Watershed Engineering and Management* 6(3): 269-280. (In Farsi).
18. Mohammadpour, R., S. Shaharuddin., C. K. Chang, N. A. Zakaria, A. Ab Ghani and N. W. Chan. 2015. Prediction of water quality index in constructed wetlands using support vector machine. *Environmental Science and Pollution Research* 22(8): 6208-6219.
19. Mohandes, M. A., T. O. Halawani, S. A. Rehman and A. A. Hssain. 2004. Support vector machines for wind speed prediction. *Renewable Energy* 29(6): 939-947.
20. Noori, R., A. Khakouir, B. Omidvar and A. Farokhnia. 2010. Comparison of ANN and principal component analysis-multivariate linear regression models for predicting the river flow based on developed discrepancy ratio statistic. *Expert Systems with Applications* 37: 5856-5862.
21. Pai, P. and C. Lin. 2005. A hybrid ARIMA and support vector machines model in stock price forecasting. *Omega* 33: 197-505.
22. Seyedian, S. M. 2015. Determinations of affecting parameters on bridge pier scour using new methods. *Journal of Irrigation and Water Engineering* 5(19): 1-16. (In Farsi).
23. Seyedian, S. M. and A. Fathabadi. 2016. Estimation of bridge pier scour using statistical methods and intelligent algorithms. *Journal of Civil and Environmental Engineering* 46(2): 1-16. (In Farsi).
24. Sharafi, H., I. Ebtehaj, H. Bonakdari and A. H. Zaji. 2016. Design of a support vector machine with different kernel functions to predict scour depth around bridge piers. *Natural Hazards* 84(3): 2145-2162.
25. Tseng M., C. L. Yen and C. C. S. Song. 2000. Computation of three-dimensional flow around square and circular piers. *International Journal for Numerical Methods in Fluids* 34: 207-227.
26. Vapnik. V. 1995. *The Nature of Statistical Learning Theory*. Springer-Verlag, New York.
27. Wang, W. J., Z. B. Xu, W. Z. Lu and X. Y. Zhang. 2003. Determination of the spread parameter in the gaussian kernel for classification and regression. *Neuro Computing* 55(3-4): 643-663.
28. Zhou, J., J. Shi and G. Li. 2011. Fine tuning support vector machines for short-term wind speed forecasting. *Energy Conversion and Management* 52: 1990-1998.

Assessment of the Geometric Shape of Bridge Pier on the Scour Depth Using the Support Vector Machine

M. Fuladipanah^{1*} and M. Majediasl²

(Received: April 13-2020 ; Accepted: July 25-2020)

Abstract

The prediction of local scouring as a dynamic and nonlinear phenomenon using methods of acceptable predictive capability has always been of interest to researchers. The shape of the bridge pier is one of the important factors in the formation and magnitude of the scour hole. In this paper, the scour depth of three bridge piers with cylindrical, sharp nose and rectangular shapes was predicted in two scenarios using the support vector machine algorithm with 395 field data obtained from the US Geological Survey and Froehlich (1988), based on different combinations of dimensionless parameters as the water attack angle (α), Froud number (Fr), the ration of pier length to width (l/b), and the ratio of mean sediment size to pier width (D_{50}/b). The results of the study, while confirming the acceptable performance of the SVM algorithm for all piers in both scenarios, showed that in the first and second scenarios, the most optimal performance was related to the rectangular pier shape with correlation coefficient of 0.8702 and 0.8838, with and maximum D_s (D_{DDR}) values of 0.854 and 1.229 respectively, during the testing phase. The positive effect of increasing the number of data on the performance of the SVM algorithm was also confirmed by further probing the evaluation indicators. The results of the comparison pointed out the overestimation of the predicted scour depth values of absolute error between 11% to 35%.

Keywords: Performance assessment, Scouring, Optimization, Scouring, Data-based method, Artificial intelligence.

1. Department on Civil Engineering, Ramhormoz Branch, Islamic Azad University, Ramhormoz, Iran.

2. Department of Civil Engineering, Maragheh University, Maragheh, Iran.

*: Corresponding author, Email: fuladipanah@gmail.com