

کاربرد الگوریتم SVM در پیش‌بینی عمق آبشستگی تک پایه قائم

مهدی ماجدی اصل* و سعیده ولیزاده^۱

(تاریخ دریافت: ۱۳۹۶/۱۲/۲۸؛ تاریخ پذیرش: ۱۳۹۷/۶/۲۶)

چکیده

آبشستگی موضعی حول فوندانسیون سازه‌های دریایی و هیدرولیکی یکی از مهم‌ترین عوامل در ناپایداری و خرابی این سازه‌ها است. همواره پیش‌بینی نادرست عمق آبشستگی حول پایه پل‌ها باعث تحمل ضررهای مالی در پل‌سازی و به‌خطر افتادن جان انسان‌های بسیاری شده است از این‌رو برآورد دقیق این پدیده پیچیده، اطراف پایه پل‌ها لازم و ضروری است. از آنجایی که فرمول‌های ارائه شده توسط محققین مختلف، مربوط به شرایط خاص آزمایشگاهی است، در شرایط دیگر کمتر صادق بوده و از دقت چندانی برخوردار نیستند. به‌تازگی محققان زیادی تلاش کردند تا روش‌ها و مدل‌های جدیدی را با عنوان محاسبات نرم، در پیش‌بینی این پدیده مهم مورد بررسی قرار دهند. در این پژوهش، برای پیش‌بینی عمق آبشستگی اطراف پایه پل ۱۴۶ سری داده آزمایشگاهی مختلف (در سه نوع شرایط آزمایشگاهی متفاوت) با استفاده از ماشین بردار پشتیبان مورد تحلیل قرار گرفت. این داده‌ها در قالب ترکیبات مختلف متشکل از پارامترهای ورودی، $d_s, d_{d_0}, v, u^*, \tau^*, v_c, Re, \delta$ هستند که به ترتیب، ضخامت زیر لایه لزج، عدد رینولدز، سرعت بحرانی، پارامتر شیلدز، سرعت برشی، سرعت متوسط، قطر متوسط ذرات، عمق اولیه جریان و قطر پایه پل معرفی می‌شوند. پارامترهای گفته شده در دو سناریو متفاوت (حالت با بعد و حالت بی‌بعد) وارد شبکه SVM شدند. برای ارزیابی کارایی ترکیبات از معیارهای آماری RMSE (جذر میانگین مربعات خطاها)، R^2 (مجذور ضریب همبستگی بین مقادیر آزمایشگاهی و پیش‌بینی) و DC (ضریب تعیین خطی بین مقادیر پیش‌بینی شده و آزمایشگاهی) استفاده شده است. نتایج حاصل از این ماشین با نتایج به‌دست آمده از فرمول‌های تجربی و روابط ارائه شده در همین تحقیق مقایسه شد. نتایج حاصل از این پیش‌بینی است. نتایج نشان می‌دهد، در سناریو اول ترکیب شماره ۵ با پارامترهای ورودی بی‌بعد $d_s, d_{d_0}, v, u^*, \tau^*, v_c, Re, \delta$ و در سناریو دوم نیز ترکیب شماره ۵ با پارامترهای ورودی با بعد $d_s, d_{d_0}, v, u^*, \tau^*, v_c, Re, \delta$ و $R^2 = 0.9931$ و $RMSE = 0.3715$ و برای مرحله آزمون، به‌عنوان برترین مدل انتخاب شده‌اند. در نتیجه از نتایج چنین استنباط شد که سناریو دو (حالت با بعد) در پیش‌بینی عمق آبشستگی حول تک پایه قائم برآورد دقیق‌تری نسبت به سناریو اول (حالت بی‌بعد) ارائه داده است. در پایان آنالیز حساسیت روی پارامترها انجام شد و پارامترهای v, u^*, D به ترتیب و به‌عنوان مؤثرترین پارامترها انتخاب شدند.

واژه‌های کلیدی: آبشستگی موضعی، پارامترهای ورودی، ماشین بردار پشتیبان، محاسبات نرم

۱. گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه مراغه، ایران

*: مسئول مکاتبات: پست الکترونیکی: Mehdi.majedi@gmail.com

مقدمه

بررسی‌های آماری تخریب پل‌ها نشان می‌دهد که عوامل هیدرولیکی و در رأس آن آبستنگی موضعی مهم‌ترین عامل تخریب پایه پل‌ها به‌شمار می‌رود (۲۶). جریان مداوم در اطراف پایه‌های پل‌ها منجر به تضعیف و شسته شدن بستر و ایجاد گودال حول پایه شده و به سقوط پایه و عرشه پل منجر می‌شود. از این‌رو شناخت این پدیده، الگوی آبستنگی پیرامون پایه و شبیه‌سازی جریان از اهمیت بالایی برخوردار است.

آبستنگی رودخانه‌ها به دو دسته آبستنگی آب زلال و آبستنگی بستر زنده تقسیم می‌شود که بیشترین آبستنگی و عمق گودال حاصل مربوط به آب زلال است (۲). در زمینه بررسی عمق آبستنگی مطالعات زیادی انجام گرفته است که از جمله آن می‌توان به مطالعات لارسن و تاج (۱۷)، کادر (۲۱)، ملویل و چپو (۱۹)، رودکیوی و اتما (۲۴)، چپو (۷)، کوتیاری و همکاران (۱۳)، احمد و راجاراتنا (۵) اشاره کرد. بزگوش و یئلدز (۶) آبستنگی حول پایه‌های مایل در کانال مستقیم را بررسی کردند و نشان دادند با افزایش زاویه تعادل پایه پل آبستنگی حول پایه کاهش می‌یابد حال آنکه جهت تمایل پایه نیز در مقدار آبستنگی مؤثر است. در نتیجه بررسی الگوی جریان در گودال آبستنگی حول پایه استوانه‌ای توسط گراف و استیارت نشان داد که یک سیستم گردابی به نام گردابه نعل اسبی در جلو پایه و یک سیستم گردابی دنباله‌دار با قدرت بیشتر در پشت پایه ایجاد می‌شود (۱۱).

لی و استورم (۱۶) تأثیر سه سائز دانه‌بندی مختلف را روی آبستنگی حول گروه پایه‌ها با آرایش متفاوت بررسی و مشاهده کردند که عمق آبستنگی فقط به نسبت قطر پایه و اندازه متوسط دانه‌ها بستگی دارد. ولی‌زاده و همکاران عمق آبستنگی اطراف گروه پایه‌های قائم در حضور امواج نوسانی را با استفاده از ماشین بردار پشتیبان پیش‌بینی و مشاهده کردند که پارامتر شیلدز تأثیر به‌سزایی در افزایش دقت شاخص‌های آماری دارد (۲۸). به دلیل تعامل ساختار جریان (گرداب نعل اسبی) و ساختار سازه‌ای پایه پل‌ها، از آنجایی که محاسبه عمق آبستنگی

به دلیل شرایط خاص و محدود آزمایشگاهی مشکلات مخصوص خود را داشته و تخمین آن با روابط تجربی از دقت پایینی برخوردار است. امروزه پژوهشگران از روش‌های جدید برای پیش‌بینی این پدیده پیچیده با عنوان روش‌های داده‌کاوی که برای مدل‌سازی سیستم‌های غیرخطی هستند بهره گرفتند، که از جمله این روش‌ها، می‌توان به روش ANN (شبکه عصبی مصنوعی)، GEP (برنامه‌ریزی بیان ژن)، GA، ANFIS و SVM (ماشین بردار پشتیبان) اشاره کرد.

شبیه‌سازی فرایند بارش و رواناب توسط قربانی و همکاران (۱۲) و در مسائل مرتبط با هیدرولیک نیز تخمین ضریب دبی سرریزهای کنگره‌ای و قوسی کنگره‌ای توسط روش‌نگر و همکاران (۲۳) از جمله تحقیقات در زمینه روش‌های هوش مصنوعی هستند. از دیگر موارد استفاده این روش‌ها می‌توان به تحقیقات زیر اشاره کرد: محمدپور و همکاران با استفاده از ماشین بردار پشتیبان SVM به پیش‌بینی شاخص کیفیت آب در تالاب‌ها پرداختند و متغیرهای تأثیرگذار در این پیش‌بینی را بررسی و این روش را با روش‌های دیگر هوش مصنوعی همچون روش ANN مقایسه کردند و نشان دادند که روش SVM با ضریب همبستگی ۰/۹۹۸۴ عملکرد بهتری در پیش‌بینی عمق آبستنگی داشته است (۲۰). آلپ و سگیز اگلو (۳) از دو نوع شبکه عصبی مصنوعی FFBP و RBF استفاده و نتایج حاصل را با یک رگرسیون خطی چندگانه مقایسه کردند و به این نتیجه رسیدند که شبکه عصبی شبیه‌سازی بسیار واقعی‌تری نسبت به رگرسیون خطی چندگانه انجام می‌دهند. کیسی (۱۴) روش‌های ANN، GEP و منحنی سنجه را در تخمین بار معلق به‌کار برده و نتیجه گرفت که روش‌های هوش مصنوعی نسبت به روش منحنی سنجه عملکرد بهتری دارند. تحقیقات اردشیر و همکاران (۱) به پیش‌بینی آبستنگی اطراف آبشکن‌های نفوذناپذیر در نهر مستقیم توسط شبکه عصبی مصنوعی و بررسی توسعه زمانی آن پرداخته‌اند. آرفین و همکاران (۴) از مدل ANN و مدل رگرسیونی خطی برای پیش‌بینی میزان

جدول ۱. محدوده برخی پارامترهای مؤثر در آبشستگی

تعداد داده‌ها	d_s / D	Fr	Re	d_{50} (mm)	D (mm)	d_s (mm)	پژوهشگر
۸۴	۰/۲-۰/۱۹۴/۵۶	۰/۰-۱۲۲/۸۷۸	۶۸۲۳۱۰-۲۰۰۰۵۵	۰/۷-۸/۸	۲۰۰-۱۶	۶۰۰-۵۰	ملویل (۱۹۹۹)
۳۸	۱/۳-۰/۴/۲۶	۰/۰-۱۳۹/۶۰۲۳	۳۰۹۹۶۳-۶۸۸۵۸	۰/۳-۵۳/۳	۲۰/۵۵-۳/۴	۲۴۱-۱۰۷	لی و همکاران (۲۰۰۹)
۲۴	۰/۱-۸۶/۹۷	۰/۱-۰/۸۳/۲۵۹۰	۱۶۲۴۰۶-۱۶۰۵۹۳	۰/۰-۲۷/۸۴	۱۵۲	۴۳۰-۲۰۰	شیپارد و همکاران (۲۰۰۶)


مشاهده شد که پارامترهای ورودی در پیش‌بینی این پدیده مهم بسیار حائز اهمیت هستند. بنابراین در تحقیق حاضر به پیش‌بینی عمق آبشستگی توسط الگوریتم SVM پرداخته شده، با این تفاوت که تمرکز اصلی تحقیق روی پارامترهای ورودی مؤثر در آبشستگی بوده است. لذا این پیش‌بینی یک‌بار با استفاده از پارامترهای بی‌بعد و بار دیگر توسط پارامترهای با بعد انجام گرفته و نتایج حاصل از این دو حالت مورد مقایسه قرار گرفته است.

مواد و روش‌ها

به منظور بررسی عملکرد روش‌های داده‌کاوی در پیش‌بینی عمق آبشستگی (d_s)، از سه نوع داده آزمایشگاهی متفاوت، در مجموع ۱۴۶ سری داده، استفاده شده است. که محدوده برخی پارامترها از جمله، عمق اولیه جریان d_s ، عدد فرود Fr، عدد رینولدز Re، قطر پایه پل D و قطر متوسط ذرات بستر d_{50} ، در جدول (۱) آورده شده است.


۸۴ داده اول مربوط به آزمایش‌های ملویل و همکاران (۱۸) هستند که در بررسی آبشستگی انواع تک‌پایه قائم با قطر بین ۱۶-۲۰۰ میلی‌متر از چهار فلوم آزمایشگاهی که سه فلوم در آزمایشگاه هیدرولیک دانشگاه آکلند نیوزلند و یک فلوم در دانشگاه نانیانگ بوده است به دست آمده‌اند (شکل ۱). ۳۸ سری داده آزمایشگاهی دوم نیز مربوط به آزمایشات لی و همکاران (۱۶) برای بررسی آبشستگی اطراف تک‌پایه قائم با قطرهای بین ۳/۴-۲۰/۵۵ در دانشگاه آتلاتا در کانالی با طول ۲۴/۵ و عرض ۴/۳ متر بوده و ۲۴ سری داده نیز در این تحقیق مورد استفاده

رسوبات استفاده کردند، آنها توانستند بین چهار پارامتر تأثیرگذار بر میزان رسوب و غلظت رسوبات با استفاده از دو روش گفته شده روابطی برقرار کنند. گول و پال (۹) با استفاده از داده‌های صحرایی و آزمایشگاهی به بررسی پتانسیل ماشین بردار پشتیبان (SVM) در پیش‌بینی عمق آبشستگی پرداختند و نشان دادند که تغییرات شرایط جریان، هندسه و مصالح بستر در پیش‌بینی عمق آبشستگی تأثیرگذار است. روشنگر و کوشه (۲۲) با استفاده از روش رگرسیون بردار پشتیبان بار انتقالی بستر را در رودخانه یا بستر شنی پیش‌بینی کردند. شرفی و همکاران (۲۷) نیز به طراحی ماشین بردار پشتیبان با توابع کرنل مختلف پرداختند و با پیش‌بینی عمق آبشستگی حول پایه‌های پل مشاهده کردند که بهترین تابع کرنل برای این پیش‌بینی تابع چند جمله‌ای است. کاکایی و همکاران (۱۵) بار رسوبات معلق را با استفاده از روش رگرسیون بردار پشتیبان پیش‌بینی کردند و نشان دادند تابع کرنل مورد استفاده در این تحقیق نتایج بهتری نسبت به توابع دیگر می‌دهد. گویال و اوجا (۸) آبشستگی در پایین‌دست جت ریزشی را با استفاده از ماشین بردار پشتیبان و مدل M5 درختی پیش‌بینی کرده و با مقایسه این دو روش با روش ANN مشاهده کردند روش‌های SVM و M5 نتایج بهتری را در پی دارد. غضنفر هاشمی و همکاران (۱۰) با استفاده از روش‌های SVM و ANN عمق آبشستگی پایه پل را در یک مدل آزمایشگاهی پیش‌بینی کرده و نشان دادند که روش‌های فوق پیش‌بینی‌های دقیق‌تری نسبت به روش‌های تجربی ارائه می‌دهند. با توجه به مطالعات پیشین مرتبط با پیش‌بینی عمق آبشستگی توسط الگوریتم SVM



Test Piles with Scour Depth Instrumentation

شکل ۲. نمادین پایه قائم برای داده‌های شپارد و همکاران



شکل ۱. نمادین پایه قائم برای داده‌های ملویل و همکاران

دارد این است که جواب منحصر به فردی به همراه دارد. لازم به ذکر است که الگوریتم SVM دارای پارامترهای مختلفی (γ, \dots, c) است که اصلی‌ترین پارامتر γ (پارامتر کرنل) است که تنظیم آنها در به دست آوردن جواب هرچه بهتر مسئله بسیار مؤثر است.

تئوری SVM

مبنای کار SVM دسته‌بندی و تفکیک خطی داده‌ها است که در صورت خطی بودن داده‌ها برای جداسازی داده‌ها سعی بر این است که صفحه‌ای با حداکثر حاشیه انتخاب شود (شکل ۳). در واقع با حل یک نوع مسئله بهینه‌سازی روبه‌رو هستیم که توسط روش برنامه نویسی درجه دو قابل حل است.

اندازه حاشیه صفحه تفکیک‌کننده از رابطه (۱) به دست می‌آید که در شکل (۳) این حاشیه را می‌توان مشاهده کرد:

$$\text{Margin} = \frac{2}{\|W\|} = \frac{2}{w^T w} \quad (1)$$


از آنجایی که بهترین صفحه تفکیک‌کننده صفحه‌ای است که دارای بیشینه فاصله بین دو کلاس باشد، بنابراین $\|W\|$ باید کمترین مقدار را به خود اختصاص دهد. در دسته‌بندی‌های غیرخطی که داده‌ها به صورت خطی قابل تفکیک نیستند نداشت‌های مختلفی (توابع کرنل) در این ماشین تعریف شده است که مسئله را به فضای جدید منتقل کرده تا داده‌ها در آن به صورت خطی تفکیک شوند. بنابراین تابع کرنلی به نام ϕ

قرار گرفته است که از آزمایشات شپارد و همکاران (۲۵)، با عنوان آبشستگی تک پایه قائم با قطر ۱۵۲ میلی‌متر در کانالی به طول ۴۵ متر، عرض ۱/۵ متر، عمق ۱/۲ و قطر متوسط ذرات بین ۰/۸۴-۰/۲۷ میلی‌متر استخراج شده است (شکل ۲).

در این پژوهش برای سنجش بهتر مدل SVM، داده‌های آزمایشگاهی عنوان شده در بالا با هم ادغام شده و در مجموع ۱۴۶ سری داده برای پیش‌بینی عمق آبشستگی استفاده شده است. برای این منظور پارامترهای مؤثر در عمق آبشستگی در ماشین بردار پشتیبان تحلیل شده و عمق آبشستگی برآورد شده است.

ماشین بردار پشتیبان

ماشین بردار پشتیبان یا الگوریتم SVM اولیه در سال ۱۹۶۳ میلادی توسط واپنیک (۲۹) ابداع شده است. این ماشین یک نوع الگوریتم داده‌کاوی است که تا به امروز کاربردهای مختلفی از جمله دسته‌بندی و پیش‌بینی داده‌ها داشته است. این الگوریتم به دو مرحله آموزش (train) و مرحله آزمون یا صحت‌سنجی (test) تقسیم می‌شود. روال کار ماشین بردار پشتیبان به این صورت است که ابتدا یک سری داده آزمایشگاهی مستقل و وابسته وارد محیط نرم‌افزار شده و سیستم توسط درصدی از داده‌ها آموزش داده می‌شود، سپس راه حل مسئله توسط داده‌های آزمون مورد ارزیابی قرار گرفته و نرم‌افزار پارامتر وابسته را بر اساس پارامترهای مستقل پیش‌بینی می‌کند. مزیتی که این الگوریتم نسبت به سایر الگوریتم‌ها



شکل ۳. ماشین بردار پشتیبان

جدول ۲. روابط مربوط به معیارهای ارزیابی

معادلات	معیارهای ارزیابی
$RMSE = \sqrt{\frac{\sum_{i=1}^N \left(\left(\frac{ds}{D} \right)_m - \left(\frac{ds}{D} \right)_p \right)^2}{N}}$	جذر میانگین مربعات خطاها
$R^2 = \frac{\sum_{i=1}^N \left(\left(\frac{ds}{D} \right)_m - \left(\frac{\overline{ds}}{\overline{D}} \right)_m \right) \times \left(\left(\frac{ds}{D} \right)_p - \left(\frac{\overline{ds}}{\overline{D}} \right)_p \right)}{\sqrt{\sum_{i=1}^N \left(\left(\frac{ds}{D} \right)_m - \left(\frac{\overline{ds}}{\overline{D}} \right)_m \right)^2} \times \sqrt{\sum_{i=1}^N \left(\left(\frac{ds}{D} \right)_p - \left(\frac{\overline{ds}}{\overline{D}} \right)_p \right)^2}}$	ضریب همبستگی
$DC = 1 - \frac{\sum_{i=1}^N \left(\left(\frac{ds}{D} \right)_m - \left(\frac{\overline{ds}}{\overline{D}} \right)_m \right)^2}{\sum_{i=1}^N \left(\left(\frac{ds}{D} \right)_m - \left(\frac{\overline{ds}}{\overline{D}} \right)_m \right)^2}$	ضریب تعیین

پیچیده‌تر راه یافت. فرایند گفته شده ترفند کرنل نامیده می‌شود، در نتیجه رابطه فوق به صورت یک معادله قابل حل و بهینه به صورت روابط (۴) و (۵) درمی‌آید:

$$y = \text{sign} \left(\sum_{i=1}^n \alpha_i y_i k(x_i, x) + b \right) \quad (4)$$

$$b = \frac{1}{|s|} \sum_{i=1}^n [y_i - \sum_{j=1}^n \alpha_j y_j k(x_j, x)] \quad (5)$$

معیارهای ارزیابی

در این تحقیق از سه پارامتر آماری برای پیش‌بینی عمق آب‌سنگی تک پایه قائم با استفاده از روش SVM به شرح جدول (۲)، استفاده شده است. RMSE جذر میانگین مربعات خطاها، R^2 مجذور ضریب همبستگی بین مقادیر آزمایشگاهی و پیش‌بینی و DC ضریب تعیین خطی (نش- ساتکیلِف) بین

تعریف می‌شود که داده‌های فضای x را به z ببرد:

$$\phi: x \rightarrow z \quad z = \phi(x)$$

در نتیجه معادله تفکیک‌کننده به صورت رابطه (۲) نوشته می‌شود:

$$W^T z + b = f(x) = 0 \rightarrow W^T \phi(x) + b = 0 \quad (2)$$

در رابطه (۲) که رابطه بین متغیر وابسته هدف و متغیرهای مستقل ورودی است، $\phi(x)$ کرنل، $f(x)$ تابع هدف، W ضریب بردار و b مقدار ثابت است. تابع هدف یا همان $f(x)$ که تابع محدب است که یک جواب بهینه و منحصر به فرد دارد. برای یافتن صفحه بهینه به صورت رابطه (۳) عمل می‌کنیم:

$$\min \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \phi(x_i)^T \phi(x_j) - \sum_{i=1}^n \alpha_i \quad 0 \leq \alpha_i \leq c \quad (3)$$

به جای عبارت $\phi(x_j) \phi(x_i)^T$ یک حالت کلی‌تر به صورت $k(x_i, x_j)$ می‌توان تعریف کرد که به وسیله آن بتوان به فضاهای

جدول ۳. معیارهای ارزیابی درصدهای مختلف آموزش و آزمون در مدل برتر ماشین بردار پشتیبان در حالت کلی

معیارهای ارزیابی	۶۰-۴۰٪	۶۵-۳۵٪	۷۰-۳۰٪	۷۵-۲۵٪	۸۰-۲۰٪
سناریو اول					
RMSE	۰/۲۰۱۵	۰/۳۱۵۹	۰/۳۰۱۷	۰/۴۶۵۱	۰/۲۷۹۵
R^2	۰/۸۵۲۹	۰/۷۷۲۱	۰/۷۹۸۵	۰/۴۴۳۶	۰/۸۳۶۲
سناریو دوم					
RMSE	۰/۰۳۳۱	۰/۰۵۸۴	۰/۰۲۹۵	۰/۰۵۲۳	۰/۰۵۵۴
R^2	۰/۸۹۳۴	۰/۸۱۴۷	۰/۹۱۲۰	۰/۸۱۴۰	۰/۸۱۹۸

مقادیر پیش‌بینی شده و آزمایشگاهی هستند. لازم به ذکر است برترین مدل، مدلی است که مقادیر R^2 و DC آن به یک نزدیک‌تر و مقدار RMSE آن به صفر میل کند.

در جدول (۲)، اندیس p مربوط به مقادیر پیش‌بینی و اندیس m مربوط به مقادیر مشاهداتی، $(ds/D)_p$ نسبت عمق آبستگي به قطر پایه پیش‌بینی شده و $(ds/D)_m$ نسبت عمق آبستگي به قطر پایه در داده‌های مشاهداتی است و N نیز تعداد داده‌ها را نشان می‌دهد.

نتایج و بحث

در تحقیق حاضر به منظور پیش‌بینی عمق آبستگي حول پایه پل و بررسی تأثیر بی‌بعد و بابعاد بودن پارامترهای مؤثر بر این پدیده از روش ماشین بردار پشتیبان استفاده شده است. در ماشین بردار پشتیبان کرنل‌های متفاوتی قابل استفاده بوده است که در این تحقیق از تابع کرنل RBF کمک گرفته شده است. لذا برای برآورد عمق آبستگي اطراف تک‌پایه قائم با استفاده از ماشین بردار پشتیبان در حالت بابعاد و بی‌بعد درصدهای مختلفی برای مراحل آموزش و آزمون اعمال شد (جدول ۳). در نهایت برای حالت بی‌بعد ۶۰ درصد داده‌ها برای آموزش و ۴۰ درصد به مرحله آزمون اختصاص داده شد و در حالت بابعاد بهترین نتیجه برای پیش‌بینی عمق آبستگي در صورتی حاصل شد که ۷۰ درصد داده‌ها برای آموزش شبکه و ۳۰ درصد بقیه برای صحت‌سنجی آنها استفاده شد. در آخر نتایج مدل‌های معرفی شده در شبکه SVM با یکدیگر مورد مقایسه قرار گرفتند. روش کار به این صورت است که ابتدا پارامترهای مرتبط با عمق آبستگي شناسایی شده و ۱۰ ترکیب بر

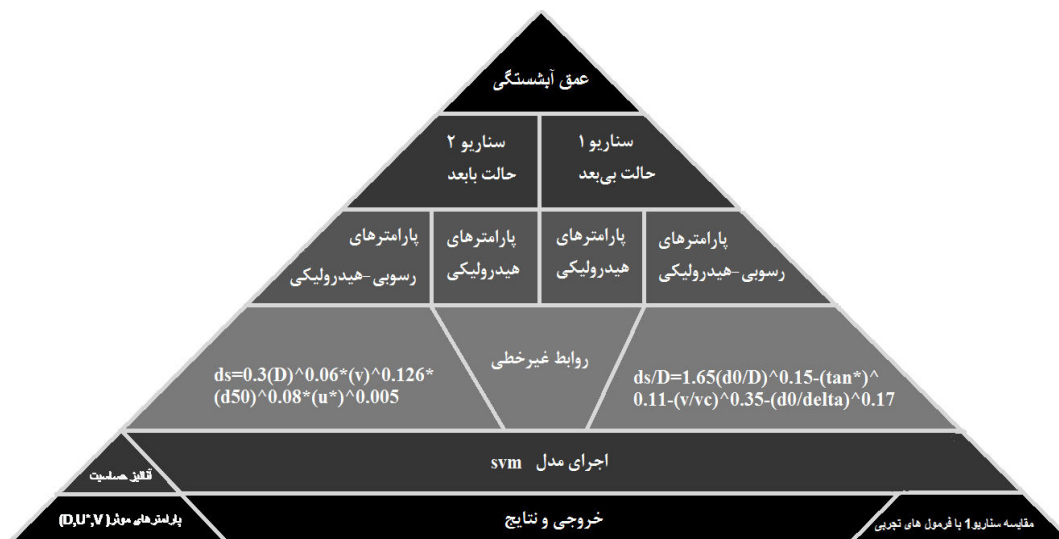
اساس پارامتر وابسته (عمق آبستگي) و پارامترهای مستقل برای هر دو حالت بابعاد و بی‌بعد به شرح جدول‌های (۴) و (۶) معرفی شده و با تغییر مقادیر پارامتر γ یعنی پارامتر کرنل جدول‌های (۴) و (۶) بهترین جواب را برای عمق آبستگي به دست می‌آوریم. ابتدا ترکیبات ورودی حاصل از پارامترهای بی‌بعد، سپس همان ترکیب‌ها با استفاده از پارامترهای بابعاد وارد شبکه SVM شده و نتایج حاصل برای پیش‌بینی عمق آبستگي با هم مقایسه شده و نتایج به صورت جدول‌ها و نمودارها ارائه شده است. برای برآورد عمق آبستگي اطراف پایه پل، ۱۰ ترکیب مختلف با ورودی‌های متفاوت به شرح جدول (۴) برای سناریو اول (پارامترهای بی‌بعد) و ۱۰ ترکیب دیگر برای سناریو دوم (پارامترهای بابعاد) به شرح جدول (۶) تعریف شده است. شکل (۴) روند نمای کلی این تحقیق را نشان می‌دهد.

سناریو اول (پارامترهای بی‌بعد)

در سناریو اول از دو گروه پارامتر مختلف در مجموع ۱۰ ترکیب استفاده شده است که چهار ترکیب، متشکل از پارامترهای هیدرولیکی $(V/V_c, d/D, Re)$ و شش ترکیب دیگر متشکل از پارامترهای هیدرولیکی و رسوبی $(d/\delta, \tau^* V/V_c, d/D, Re)$ هستند. این پارامترها در قالب ترکیبات ارائه شده در جدول (۴) وارد ماشین بردار پشتیبان شده آنالیز شده‌اند، نتایج حاصل در جدول (۵) به تفصیل آورده شده است و بهترین ترکیب که دارای کمترین خطا و بیشترین ضریب همبستگی است، به ترتیب ترکیبات ۵ و ۱ برای حالت پارامترهای هیدرولیکی - رسوبی و حالت پارامترهای هیدرولیکی

جدول ۴. ترکیبات مختلف پارامترهای بی‌بعد

حالت بی‌بعد (سناریو ۱)			
شماره ترکیب	مشخصات هیدرولیکی و رسوبی	شماره ترکیب	مشخصات هیدرولیکی و رسوبی
۱	$Re, \frac{v}{v_c}, \frac{d_s}{D}, \frac{d_{s0}}{\delta}$	۶	$\frac{v}{v_c}, Re, \frac{d_s}{D}, \frac{d_{s0}}{\delta}$
۲	$Re, \frac{d_s}{D}$	۷	$\frac{v}{v_c}, \frac{d_{s0}}{\delta}, Re, \tau^*$
۳	$Re \frac{v}{v_c}$	۸	$\tau^*, \frac{v}{v_c}, \frac{d_s}{D}$
۴	$\frac{v}{v_c}, \frac{d_s}{D}$	۹	$\frac{d_s}{D}, \frac{d_{s0}}{\delta}, \tau^*$
۵	$\frac{d_s}{D}, \frac{v}{v_c}, \frac{d_{s0}}{\delta}, Re, \tau^*$	۱۰	$\frac{d_{s0}}{\delta}, Re, \tau^*$



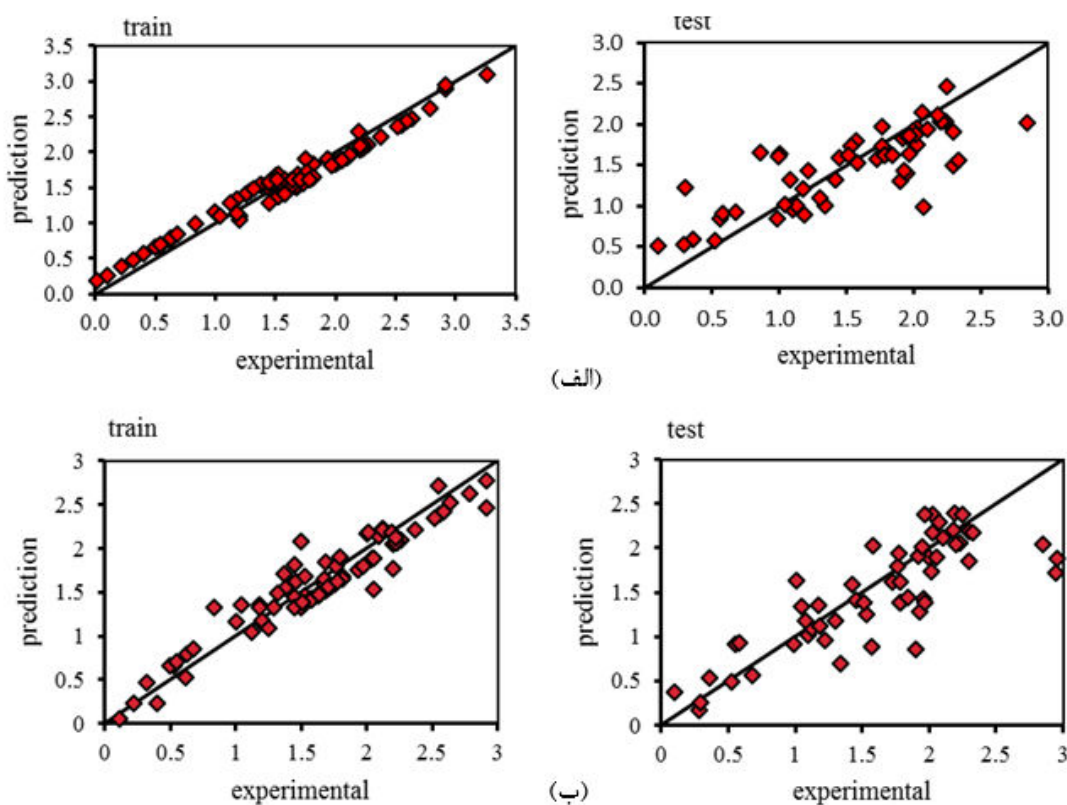
شکل ۴. روند نمای پژوهش حاضر

به عنوان ترکیبات برتر به دست آمده‌اند. نتایج حاصل از روش SVM نشان می‌دهد که در سناریو اول، ترکیب شماره ۵ با ورودی‌های، $Re, \tau^*, \frac{d_s}{D}, \frac{v}{v_c}, \frac{d_{s0}}{\delta}$ که مربوط به حالت هیدرولیکی-رسوبی است دارای کمترین خطا (RMSE=۰/۳۷۱۵) و بیشترین ضریب همبستگی ($R^2=۰/۶۹۳۱$) بوده و به عنوان برترین مدل برای پیش‌بینی عمق آبشستگی انتخاب می‌شود. مدل‌های ۶ و ۸ از همین سناریو نیز نتایج قابل قبولی را ارائه داده‌اند که مقادیر شاخص‌های آماری نزدیک‌تری


به عنوان ترکیبات برتر به دست آمده‌اند. نتایج حاصل از روش SVM نشان می‌دهد که در سناریو اول، ترکیب شماره ۵ با ورودی‌های، $Re, \tau^*, \frac{d_s}{D}, \frac{v}{v_c}, \frac{d_{s0}}{\delta}$ که مربوط به حالت هیدرولیکی-رسوبی است دارای کمترین خطا (RMSE=۰/۳۷۱۵) و بیشترین ضریب همبستگی ($R^2=۰/۶۹۳۱$) بوده و به عنوان برترین مدل برای پیش‌بینی عمق آبشستگی انتخاب می‌شود. مدل‌های ۶ و ۸ از همین سناریو نیز نتایج قابل قبولی را ارائه داده‌اند که مقادیر شاخص‌های آماری نزدیک‌تری

جدول ۵. معیارهای ارزیابی ترکیبات مختلف مدل SVM، برای تعیین عمق آبستگي در سناریو اول


معیارهای ارزیابی						پارامترهای کرنل			
Test			Train						
R ²	DC	RMSE	R ²	DC	RMSE	C	ϵ	γ	ترکیب
پارامترهای هیدرولیکی									
۰/۵۶۰۶	۰/۴۴۷۷	۰/۴۷۱۸	۰/۸۵۶۳	۰/۷۸۷۵	۰/۲۵۴۴	۸	۰/۱	۱۰۰	۱
۰/۳۲۱۸	۰/۴۶۰۰	۰/۵۲۶۰	۰/۴۲۹۲	۰/۴۴۵۰	۰/۵۱۲۷	۱۰	۰/۳	۱۰۰	۲
۰/۳۳۲۳	۰/۲۲۹۶	۰/۵۸۱۱	۰/۶۴۴۷	۰/۴۱۵۳	۰/۴۹۶۹	۱۰	۰/۵	۱۰۰۰۰	۳
۰/۵۵۴۷	۰/۵۳۳۲	۰/۴۵۲۳	۰/۸۳۱۹	۰/۸۱۵۵	۰/۲۷۹۱	۱۰	۰/۱	۱۰۰۰	۴
پارامترهای رسوبي و هیدرولیکی									
۰/۶۹۳۱	۰/۵۱۶۶	۰/۳۷۱۵	۰/۹۶۹۲	۰/۹۴۳۲	۰/۱۳۸۲	۶	۰/۱	۱۱۰	۵
۰/۵۷۸۸	۰/۱۹۹۲	۰/۴۳۵۴	۰/۹۶۹۱	۰/۹۳۸۳	۰/۱۳۸۸	۳	۰/۱	۱۰۰۰	۶
۰/۶۳۷۷	۰/۴۴۳۴	۰/۳۹۹۵	۰/۸۹۲۴	۰/۸۳۶۳	۰/۲۲۲۵	۵	۰/۱	۱۰۰۰	۷
۰/۵۲۵۷	۰/۱۰۸۹	۰/۴۵۶۳	۰/۹۶۵۴	۰/۹۳۰۲	۰/۱۴۶۷	۵	۰/۱	۱۰۰۰	۸
۰/۲۱۷۷	۰/۰۲۵۶	۰/۶۵۳۵	۰/۷۰۶۸	۰/۶۹۶۳	۰/۳۵۸۵	۱۰	۰/۱	۱۰۰	۹
۰/۳۵۸۰	۰/۵۸۷۴	۰/۴۲۵۲	۰/۸۷۷۰	۰/۸۷۱۸	۰/۲۳۲۶	۱۰	۰/۱	۱۰۰	۱۰




شکل ۵. الف) منحنی پراکنش داده‌های آزمایشگاهی و مشاهداتی در مرحله آزمون و آموزش برای مدل برتر با پارامترهای هیدرولیکی و ب) منحنی پراکنش داده‌های آزمایشگاهی و مشاهداتی در مرحله آزمون و آموزش برای مدل برتر با پارامترهای هیدرولیکی - رسوبي



شکل ۶. مقایسه داده‌های آزمایشگاهی و مشاهداتی در مرحله آزمون و آموزش مدل برتر (رنگی در نسخه الکترونیکی)



شکل ۸. تأثیر پارامترهای d/D , τ^* در عمق آبشستگی پیش‌بینی شده



شکل ۷. مقادیر معیارهای ارزیابی مدل‌های برتر در سناریو ۱

در شکل (۸) مشاهده می‌شود که با افزایش پارامتر d/D از صفر تا ۱۰ عمق آبشستگی افزایش و با افزایش d/D از ۱۰ تا ۲۲ عمق آبشستگی کاهش می‌یابد. در نتیجه با افزایش τ^* از صفر تا ۰/۰۸ عمق آبشستگی کاهش و با افزایش آن از ۰/۰۸ تا ۰/۲۲ عمق آبشستگی افزایش می‌یابد. در این تحقیق با استفاده از روش سولور (solver) رابطه غیرخطی شماره (۶) با استفاده از پارامترهای مؤثر ارائه شده که دارای $R^2 = ۰/۳۷$ و $RMSE = ۰/۵۳$ است و واضح است که نتایج ماشین بردار پشتیبان در پیش‌بینی عمق آبشستگی نتیجه بهتری نسبت به روابط غیرخطی حاصل از روش رگرسیونی دارد. لازم به ذکر

می‌دارد داده‌های مربوط به پارامترهای رسوبی و هیدرولیکی پراکندگی کمتری نسبت به حالت پارامترهای هیدرولیکی داشته و روی نیمساز قرار گرفته‌اند. شکل (۶) به مقایسه داده‌های آزمایشگاهی و مشاهداتی مدل برتر پرداخته و نشان می‌دهد همبستگی نسبتاً خوبی در این سناریو بین داده‌های آزمایشگاهی و پیش‌بینی شده عمق آبشستگی موجود است. شکل (۷) مقادیر معیارهای ارزیابی ترکیب برتر هر دو بخش (هیدرولیکی و هیدرولیکی-رسوبی) را نشان می‌دهد، همان‌طور که در جدول هم مشاهده می‌شود گویای برتری حالت هیدرولیکی-رسوبی نسبت به حالت هیدرولیکی است.

جدول ۶. ترکیبات مختلف ورودی برای حالت بعددار

حالت بعددار (سناریو ۲)			
شماره ترکیب	مشخصات هیدرولیکی پارامترهای ورودی	شماره ترکیب	مشخصات هیدرولیکی و رسوبی پارامترهای ورودی
۱	$D, d_s, v,$	۵	D, d_s, d_{s0}, v, u^*
۲	D, d_s	۶	d_s, d_{s0}, u^*
۳	D, v	۷	D, d_s, d_{s0}, v
۴	d_s, v	۸	D, d_{s0}, v, u^*
		۹	d_s, v, u^*
		۱۰	d_{s0}, v, u^*

است که τ^* پارامتر شیلدز مربوط به ذرات رسوبی، v_c سرعت بحرانی و δ طول زیرلایه لزج به فرمول $\delta = 11.6 \frac{v_*}{U_*}$ بوده که در آن v بیانگر لزجت سینماتیکی آب و U^* سرعت برشی است:

$$\frac{d_s}{D} = 1/65 \left(\frac{d_s}{D} \right)^{0.15} \left(\frac{v}{v_c} \right)^{0.35} \left(\frac{d_{s0}}{\delta} \right)^{0.17} (\tau^*)^{0.11} \quad (6)$$


سناریو دوم (پارامترهای بایعد)

در سناریو دوم نیز ۱۰ ترکیب مختلف برای ماشین بردار پشتیبان تعریف شده است (جدول ۶) با این تفاوت که این‌بار برای تعریف ترکیبات ورودی به ماشین از پارامترهای بایعد استفاده شده است که این پارامترها عبارت‌اند از D, d_s, d_{s0}, v, u^* . طبق آنچه در سناریو اول اجرا شد در این سناریو نیز ترکیبات ورودی در روش ماشین بردار پشتیبان آنالیز شده و نتایج تحلیل‌ها در جدول (۷) ارائه شده است که بیانگر بهبود عملکرد روش‌های داده‌کاوی با استفاده از پارامترهای بایعد نسبت به پارامترهای بی‌بعد است. همان‌طور که در جدول (۷) مشاهده می‌شود، ترکیب شماره ۱، (D, d_s, v) با $RMSE=0.0204$ و $R^2=0.9574$ برای حالت پارامترهای هیدرولیکی و ترکیب شماره ۵، (D, D, d_{s0}, v, u^*) با $RMSE=0.0161$ و $R^2=0.9748$ برای حالت هیدرولیکی - رسوبی به‌عنوان ترکیبات برتر انتخاب شده‌اند. در نتیجه در


شکل‌های (۹ و ۱۰) مشاهده می‌شود که همبستگی بین داده‌های آزمایشگاهی و پیش‌بینی‌شده در این سناریو بهتر از سناریو اول بوده و طبق نتایج حاصل از جدول (۷) و تحلیل این شکل‌ها می‌توان دریافت که عملکرد ماشین بردار پشتیبان در پیش‌بینی عمق آبشستگی حول تک‌پایه قائم در حالت پارامترهای بایعد بهتر از حالت بی‌بعد است. شکل (۱۱) مقادیر معیارهای ارزیابی ترکیب برتر هر دو بخش (هیدرولیکی و هیدرولیکی - رسوبی) را نشان می‌دهد که گویای برتری حالت هیدرولیکی - رسوبی نسبت به حالت هیدرولیکی است. از شکل (۱۲) چنین نتیجه می‌شود که با افزایش پارامتر u^* از صفر تا ۰/۰۲ عمق آبشستگی تقریباً ثابت مانده و با افزایش آن از ۰/۰۲ تا ۰/۰۱۵ عمق آبشستگی افزایش می‌یابد و از ۰/۰۱۵ به بعد کاهش می‌یابد. در نتیجه با افزایش d_{s0} تا ۰/۰۰۲۵ عمق آبشستگی افزایش و از ۰/۰۰۲۵ تا ۰/۰۰۳۵ عمق آبشستگی رو به کاهش است. در این سناریو نیز با استفاده از روش سولور رابطه غیرخطی شماره (۷) با استفاده از پارامترهای مؤثر ارائه شده که دارای $R^2=0.95$ و $RMSE=0.086$ است و واضح است که نتایج ماشین بردار پشتیبان در پیش‌بینی عمق آبشستگی نتیجه بهتری نسبت به روابط غیرخطی حاصل از روش رگرسیونی دارد. لازم به‌ذکر است که رابطه غیرخطی حاصل برای سناریو دوم (بایعد) دارای خطای کمتر و ضریب همبستگی بیشتری در مقایسه با سناریو

جدول ۷. معیارهای ارزیابی ترکیبات مختلف مدل SVM، برای تعیین عمق آب‌سنگی در سناریو ۲


معیارهای ارزیابی						پارامترهای کرنل			
Test			Train						
R^2	DC	RMSE	R^2	DC	RMSE	C	ε	γ	ترکیب
پارامترهای هیدرولیکی									
۰/۸۲۸۳	۰/۷۵۳۹	۰/۰۴۷۳	۰/۹۵۷۴	۰/۹۵۵۴	۰/۰۲۰۴	۱۰	۰/۱	۵	۱
۰/۷۳۳۱	۰/۶۷۳۰	۰/۰۴۹۲	۰/۸۷۹۵	۰/۸۷۷۹	۰/۰۳۴۵	۷	۰/۲	۲۰	۲
۰/۷۸۷۱	۰/۷۲۰۸	۰/۰۴۵۵	۰/۸۷۴۵	۰/۸۷۴۳	۰/۰۳۵۰	۱۰	۰/۱	۱	۳
۰/۵۶۵۵	۰/۴۲۸۶	۰/۰۶۵۱	۰/۶۸۲۳	۰/۵۶۳۷	۰/۰۶۶۵	۱۰	۰/۵	۲۰	۴
پارامترهای رسوبی و هیدرولیکی									
۰/۸۱۸۵	۰/۷۹۷۴	۰/۰۴۵۹	۰/۹۷۴۸	۰/۹۷۱۲	۰/۰۱۶۱	۶	۰/۱	۱۰	۵
۰/۵۲۹۶	۰/۵۱۸۳	۰/۰۵۹۷۹	۰/۵۳۸۹	۰/۵۱۷۵	۰/۰۶۸۶	۱۰	۰/۱	۰/۰۱	۶
۰/۷۱۷۴	۰/۶۸۹۷	۰/۰۵۳۷	۰/۸۹۸۸	۰/۸۸۳۸	۰/۰۳۱۴	۱۰	۰/۲	۱۰	۷
۰/۸۱۰۵	۰/۷۳۸۱	۰/۰۴۸۹	۰/۹۷۱۷	۰/۹۶۸۳	۰/۰۱۶۸	۴	۰/۱	۲۰	۸
۰/۸۰۴۷	۰/۷۴۰۰	۰/۰۴۸۵	۰/۹۶۹۵	۰/۹۶۱۷	۰/۰۱۷۳	۴	۰/۱	۲۰	۹
۰/۶۲۸۲	۰/۴۹۵۵	۰/۰۶۱۱	۰/۷۸۶۹	۰/۷۸۵۰	۰/۰۴۵۶	۱۰	۰/۱	۱۰	۱۰




شکل ۹. الف) منحنی پراکنش داده‌های آزمایشگاهی و مشاهداتی در مرحله آزمون و آموزش برای مدل برتر بخش پارامترهای هیدرولیکی، ب) منحنی پراکنش داده‌های آزمایشگاهی و مشاهداتی در مرحله آزمون و آموزش برای مدل برتر بخش پارامترهای هیدرولیکی - رسوبی



شکل ۱۰. مقایسه داده‌های آزمایشگاهی و مشاهداتی در مرحله آزمون و آموزش



شکل ۱۲. تأثیر پارامترهای τ^* , $\frac{d_b}{D}$ در عمق آبستگي پيش‌بینی شده



شکل ۱۱. مقادير معيارهای ارزیابی مدل‌های برتر در سناریو ۱

در این بخش نتایج سه سری آزمایش با شرایط متفاوت در چهار رابطه تجربی به شرح جدول (۹) ارائه شده است. مشاهده می‌شود که رابطه ریچاردسون و داویس (CSU) (۳۱) کمترین خطا ($RMSE=0.6780$) و بیشترین ضریب تعیین ($DC=0.9711$) را داشته و لازم به ذکر است که رابطه غیرخطی حاصل در این تحقیق حتی در حالت با بعد نیز دارای خطای کمتری بوده و نیز رابطه بروزرس (۳۰) یکی از کم‌دقت‌ترین روابط برای تخمین عمق آبستگي است. در نتیجه شکل (۱۳) منحنی مقایسه روابط تجربی با نتایج حاصل از ماشین بردار پشتیبان را نشان می‌دهد و بیان می‌دارد که نتایج ماشین بردار پشتیبان تقریباً روی نیمساز قرار گرفته ولی داده‌های محاسباتی روابط محققین مختلف بسیار پراکنده هستند

اول (بی‌بعد) است:

$$d_s = 0.3(D)^{0.06}(V)^{0.126}(d_{b0})^{0.08}(U^*)^{0.005} \quad (7)$$

مقایسه با فرمول‌های تجربی

تاکنون روش‌های مختلفی توسط محققین برای تخمین عمق آبستگي ارائه شده است که در استخراج این روابط از مفاهیم تئوری و تجربی و روش‌های مختلفی استفاده شده است. از آنجایی که انتخاب فرمول مناسب برای محاسبه عمق آبستگي در شرایط مختلف مشکل است از این‌رو مقایسه‌ای بین روش‌های پیشنهادی این تحقیق و برخی روابط تجربی که خلاصه‌ای از این روابط در جدول (۸) آورده شده است در ادامه انجام گرفته است.

جدول ۸. روابط تجربی محاسبه عمق آبستنگی ارائه شده توسط محققین مختلف

محقق	رابطه آبستنگی
بروزرس و همکاران (۱۹۷۷)	$\frac{d_s}{D} = K_v \times \tanh\left(\frac{d_o}{D}\right)$ $K_v = 0 \rightarrow \frac{v}{v_c} \leq 0.5$, $K_v = 1 \rightarrow \frac{v}{v_c} > 1$ $K_v = 2\left(\frac{v}{v_c}\right) - 1 \rightarrow 0.5 \leq \frac{v}{v_c} \leq 1$
ملویل و همکاران (۱۹۹۷)	$\frac{d_s}{D} = \frac{v}{v_c} \times 0.5 \log\left(2.24 \frac{D}{d_{o*}}\right) \times k_{yd}$ $k_{yd} = 2/4 \rightarrow \frac{D}{d_o} \leq 0.7$, $k_{yd} = 2\sqrt{\frac{d_o}{D}} \rightarrow 0.7 \leq \frac{D}{d_o} \leq 5$, $k_{yd} = 4/5 \rightarrow \frac{D}{d_o} > 5$
شپارد و همکاران (۲۰۰۶)	$\frac{d_s}{D} = 2/5 f_1\left(\frac{d_o}{D}\right) f_2\left(\frac{D}{d_{o*}}\right) \left[1 - 1/75 \left(\ln\left(\frac{v}{v_c}\right)\right)^2\right] f_3\left(\frac{d_o}{D}\right)$ $= \tanh\left(\frac{d_o}{D}\right)^{0.4}, f_2\left(\frac{D}{d_{o*}}\right) = \frac{\frac{D}{d_{o*}}}{0.4\left(\frac{D}{d_{o*}}\right)^{1/2} + 1.0/6\left(\frac{D}{d_{o*}}\right)^{-0.13}}$
ریچاردسون و داویس (۲۰۰۱)	$\frac{d_s}{D} = 2k_r \left(\frac{d_o^{0.35}}{D}\right) Fr^{0.43}$, $k_r = 1/1 \rightarrow \text{plane bed}$

جدول ۹. مقایسه مقادیر خطای RMSE و DC بین روابط تجربی و نتایج این تحقیق


نام محقق	Train
سناریو ۱ (پارامترهای بی‌بعد)	DC RMSE
بروزرس و همکاران (۱۹۷۷)	-۲/۰۰۷ ۱/۱۳۶۲
ملویل و همکاران (۱۹۹۷)	-۹/۹۴۵ ۲/۱۶۰۱
شپارد و همکاران (۲۰۰۶)	-۹/۳۶۸ ۲/۱۰۹۶
ریچاردسون و داویس (۲۰۰۱)	-۰/۰۷۱۱ ۰/۶۷۸۰
پژوهش حاضر (SVM)	۰/۹۷۱۲ ۰/۰۱۶۱
رابطه غیرخطی (رابطه شماره [۶])	۰/۵۲ ۰/۳۷

که حاکی از دقت بالای مدل SVM است.

تحلیل حساسیت

در این بخش برای بررسی تأثیر پارامترهای هیدرولیکی و رسوبی و انتخاب پارامترهای مؤثر، ترکیبات مورد نظر بدون پارامتر گفته شده آنالیز شده تا درصد تأثیر و حساسیت مدل SVM نسبت به آن پارامتر مشخص شود. در تحقیق حاضر ترکیب شماره ۵ به عنوان مدل برتر (سناریو ۲) با خطای کمتر و

ضریب همبستگی بیشتر نسبت به مدل‌های دیگر با پارامترهای ورودی d_o, d_{o*}, v, u^* انتخاب شد، به طوری که پارامترها یک به یک حذف شده و مدل مجدد مورد تحلیل قرار گرفت که نتایج در جدول (۱۰) آورده شده است و مشخص است که پارامتر D تأثیر بسزایی در افزایش جذر میانگین مربعات خطاها (RMSE=۰/۶۲۸) و کاهش مجذور ضریب همبستگی (R^۲=۰/۷۰۳۲) دارد. لذا مدل SVM در پیش‌بینی عمق آبستنگی از حساسیت بالایی نسبت به پارامتر D برخوردار



شکل ۱۳. مقایسه روابط تجربی با نتایج حاصل از ماشین بردار پشتیبان

جدول ۱۰. آنالیز حساسیت برای ترکیب برتر سناریو ۲ (ترکیب شماره ۵).


Test			Train			ترکیب
DC	R ^۲	RMSE	DC	R ^۲	RMSE	
-۰/۵۷	۰/۵۷۷۶	۰/۰۶۶۸	-۰/۳۳	۰/۷۰۴۲	۰/۰۶۲۸	d_o, d_{do}, v, u^*
۰/۷۳۸۱	۰/۸۱۰۵	۰/۰۴۸۹	۰/۹۶۸۳	۰/۹۷۱۷	۰/۰۱۶۸	D, d_{do}, v, u^*
۰/۷۳۱۸	۰/۸۰۰۴	۰/۰۴۶۷	۰/۹۵۶۹	۰/۹۶۳۱	۰/۰۱۹۱	D, d_o, v, u^*
۰/۶۸۲۷	۰/۷۱۶۲	۰/۰۵۳۱	۰/۸۷۹۸	۰/۹۰۲۷	۰/۰۳۱۲	D, d_o, d_{do}, u^*
۰/۶۸۹۷	۰/۷۱۷۴	۰/۰۵۳۷	۰/۸۸۳۸	۰/۸۹۸۸	۰/۰۳۱۴	D, d_o, d_{do}, v

ماشین بردار پشتیبان پیش‌بینی شده است که برای این منظور در مجموع از ۱۴۶ سری داده با شرایط آزمایشگاهی متفاوت استفاده شد و نشان داده شد که پیش‌بینی عمق آبشستگی حول تک‌پایه پل‌ها در حالت ۱ یعنی با استفاده از پارامترهای بابتد توسط ماشین بردار پشتیبان دارای خطای نسبی کمتر و ضریب همبستگی بیشتری در مقایسه با حالت ۲ (پارامترهای بی‌بعد) است. در نتیجه لازم به توضیح است که به منظور ارزیابی کارایی روش SVM برای پیش‌بینی عمق آبشستگی، از سه پارامتر آماری R^2 ، DC و RMSE استفاده شد و نتایج حاصل از SVM با روابط تجربی و نیمه تجربی و روابط غیرخطی حاصل از روش رگرسیونی تحقیق حاضر مورد مقایسه قرار گرفت. مشاهده شد که در هر دو حالت با بعد و بی‌بعد ترکیباتی که به‌طور همزمان دارای هر دو گروه پارامترهای رسوبی و هیدرولیکی هستند نتایج بهتری از معیارهای ارزیابی را به‌دست


است. در نتیجه بعد از پارامتر D ، پارامترهای v و u^* از جمله پارامترهای مؤثر هستند. شکل‌های (۱۴ و ۱۵) تأثیر مؤثرترین پارامتر (D) و بی‌تأثیرترین پارامتر (d_o) در عمق آبشستگی داده‌های آزمایشگاهی و داده‌های پیش‌بینی شده را در این تحقیق نشان می‌دهد. همان‌طور که از جدول (۱۰) و از شکل‌های مذکور نیز مشخص است، پارامتر D در پیش‌بینی عمق آبشستگی بیشترین تأثیر را داشته که دلیل بر دقت بالای پیش‌بینی ماشین بردار پشتیبان در حضور این پارامتر است از طرفی پارامتر d_o باعث پراکنده شدن داده‌های آزمایشگاهی و پیش‌بینی شده است.

نتیجه‌گیری

در تحقیق حاضر، عمق آبشستگی حول تک‌پایه قائم در دو حالت: (۱) پارامترهای بابتد و (۲) پارامترهای بی‌بعد با استفاده از



شکل ۱۵. تأثیر پارامتر D در عمق آب‌سستگی



شکل ۱۴. تأثیر پارامتر d در عمق آب‌سستگی

حساسیت در حالت ۲ (پارامترهای با بعد) نیز پرداخته شد و نتایج نشان داد که پارامترهای D, u^*, v, d_0 به ترتیب مؤثرترین پارامترها برای پیش‌بینی عمق آب‌سستگی اطراف تک‌پایه قائم هستند. لازم به ذکر است که در راستای صحت‌سنجی تحقیق حاضر، نتایج گفته شده با نتایج روابط تجربی محققین مختلف و رابطه غیرخطی به دست آمده در همین تحقیق مورد مقایسه قرار گرفت و مشاهده شد که مدل SVM استفاده شده در این تحقیق با خطای $0/0161$ بهترین تخمین از عمق آب‌سستگی را ارائه می‌دهد.

می‌دهد. در سناریو ۱ (حالت بی‌بعد) ترکیب شماره ۵ با پارامترهای ورودی $d_0/\delta, Re, \tau^*, v/v_c, d_0/D$ به عنوان ترکیب برتر شناخته شد که دارای نتایجی به شرح $(R^2 = 0/6931, DC = 0/5166, RMSE = 0/3715)$ در مرحله آزمون بوده و در سناریو ۲ (با بعد) نتایج ترکیب برتر یعنی ترکیب شماره ۵ با پارامترهای D, d_0, v, u^* به شرح $(R^2 = 0/8185, DC = 0/7974, RMSE = 0/0459)$ به دست آمده است. همان‌طور که اشاره شد ضرایب همبستگی و خطاها بیانگر عملکرد بهتر ماشین بردار پشتیبان در حالت با بعد نسبت به حالت بی‌بعد است. در تحقیق حاضر به بررسی آنالیز

منابع مورد استفاده

1. Ardeshtir, A., H. Karami., M. Saneyi and S. Salamatian. 2010. Investigation of temporal development of scour around impermeable gullies in direct stream and its prediction by artificial neural network. *Iranian Journal of Watershed Management Science and Engineering* 13(4) :49-50. (In Farsi).
2. Arvanaghi, H., A. Hoseinzadeh Delir, D. Farsadizadeh and A. Fakherizadeh Fard. 2008. Temporal variations of the scour depth around the bridge base and its empirical relationships. *Journal of Agricultural Science and Sustainable Production* 180(2) :1-10. (In Farsi).
3. Alp, M. and H. K. Cigizoglu. 2005. Suspended sediment load simulation by two artificial neural network methods using hydro meteorological data. *Journal of Environmental Modeling Modeling and Software* 22: 2-13.
4. Ariffin, J., A. Abdul Ghani, N. Zakaria and A. Shukri Yahya. 2003. Sediment prediction using ANN and regression approach. In: *Proceeding of the 1st International Conference on Managing River in 21st Century Issues and challenges*, Unuversiti Sains Malaysia, Penang. Malaysia. pp 930-945.
5. Ahmhad, F. and N. Rajaratna. 1998. Flow around bridge pier. *Journal of Hydraulic Engineering* 124(3) : 288-299.

6. Bozkus, Z. and O. Yildiz. 2001. Experimental investigation of scour-ing around inclined bridge piers. In: Proceeding of the Wetlands Engineering and River Restoration Conference 2001, CD-ROM, ASCE, Reston, Va., Sec. 47, Chap. 1.
7. Chiew, Y. M. 1995. Mechanics of riprap failure at bridge piers. *Journal of Hydraulic Engineering* 121(9) : 635-643.
8. Goyal, M. K. and C. S. P. Ojha. 2011. Estimation of scour downstream of a ski-jump bucket using support vector and M5 model tree. *Water Resources Management* 25 : 2177-2195.
9. Goel, A. and M. Pal. 2009. Application of support vector machines in scour prediction on grade-control structures. *Engineering Applications of Artificial Intelligence* 22(2): 216-223.
10. Ghazanfari-Hashemi, S., A. Etemad-Shahidi., M. H. Kazeminezhad and A. R. Mansoori. 2011. Prediction of pile groups scour in waves using support vector machines and ANN. *Journal of Hydroinformatics* 13: 609-620.
11. Graf, W. and I. Istiarto. 2002. Flow pattern in the scour hole around a cylinder. *Journal of Hydraulic Research* 40(1): 13-20.
12. Ghorbani, M. A., A. Azani, L. Naghipour and S. Nemati. 2016. Comparison of the performance of support vector machine with other intelligent techniques to simulate rainfall-runoff process. *Journal of Watershed Management Research* 7(13): 92-103. (In Farsi).
13. Kothiyari, U. C., R. J. Garde and K. G. Ranga Raju. 1992. Temporal variation of scour around circular bridge piers. *Journal of Hydraulic Engineering* 118(8): 1091-1106.
14. Kisi, O. 2012. Modelling discharge-suspended sediment relationship using least square support vector machine, *Journal of Hydrology* 456: 110-120.
15. 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.
16. Lee, S. O. and T. W. Sturm. 2009. Effect of sediment size scaling on phys-ical modeling of bridge pier scour. *Journal of Hydraulic Engineering* 135(10): 793-802.
17. Laursen, E. M. and A. Toch. 1956. Scour around Bridge Piers and Abutments, Bull. No. 4, Iow a Highway Research Board, U.S.A.
18. Milville, B. W. 1975. Local scour at bridge sites. Report No. 17, Univ. of Auckland, School of Eng., Auckland, NewZea land.
19. Melville, B. W. and Y. M. Chiew. 1999. Time scale for local scour at bridge piers. *Journal of Hydraulic Engineering* 125(1): 59-65.
20. 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.
21. Qadar, A. 1981. The Vortex Scour Mechanism at Bridge Piers. Proceeding Sof Institution of Civil Engineers ,Vol. 71, Pt. 2.
22. Roushangar, K. and A. Kooshe. 2015. Evaluation of GA-SVR method for modeling bed load transport in gravel-bed Rivers. *Journal of Hydrology* 527: 1142-1152.
23. Roshangar, K., M. T. Alami and M. Majedi Asl. 2017. Determination of Labyrinth and Arced Labyrinth Weirs Discharge Coefficients Using Support Vector Regression. *Water and Soil Sience* 173(27): 1-186. (In Farsi).
24. Raudkivi, A. J. and R. Ettema. 1983. Clear-water scour at cylindrical piers. *Journal of Hydraulic Engineering* 109(3): 338-350.
25. Sheppard, D. M. and W. Miller Jr. 2006. Live-bed local pier scour experiments. *Journal of Hydraulic Engineering* 132(7): 635-642.
26. Shirole, A. M. and R. C. Holt. 1991. Planning for a comprehensive bridge safety assurance. *Transport Research Record* 1290 : 39-50.
27. 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.
28. Vlizadeh, S., M. Majedi Asl, R. Daneshfaraz and G. Chabokpour. 2018. Prediction of Scour Depth around Vertical Base Group in the Presence of Oscillating Waves Using Backing Machines (SVM), In: Proceeding of the Seventh National Hydraulic Conference of Iran, University of Shahrkord.
29. Vapnik, V. 1995. The Nature of Statistical Learning Theory, Springer-Verlag, New York.
30. Breusers, H. N. C., G. Nicollet and H. W. Shen. 1977. Local scour around cylindrical piers. *Journal of Hydraulic Resources* 15(3): 211-252.
31. Richardson, E. V. and S. R. Davis. 2001. Evaluating Scour at Bridges, Fourth Edition, Hydraulic Engineering Circular No. 18, FHWA-NHI-01-001, Washington, D.C.

Application of SVM Algorithm in Predicting Vertical Pier Scour Depth

M. Majedi Asl^{*} and S. Valizadeh¹

(Received: March 19-2018; Accepted: September 17-2018)

Abstract

Local scour around the foundation of marine and hydraulic structures is one of the most important factors in the instability and destruction of these structures. False prediction of scour depth around bridges has caused financial losses in plasticization and endangered many people's lives. Therefore, an accurate estimation of this complex phenomenon around the bridges is necessary. Also, since the formulas presented by different researchers relate to laboratory conditions, they are less true and less accurate in other situations. Recently, many researchers have tried to introduce new methods and models called soft calculations in predicting this phenomenon. In this research, 146 different laboratory data series (three different laboratory conditions) were analyzed using a backup vector machine to predict scour depth around the bridge head. These data are presented in the form of various combinations of input parameters $D, d_0, d_{50}, v, u^*, \tau^*, v_c, Re, \delta$ which, respectively, represent thickness under the slippery layer, Reynolds number, critical velocity, Shields parameter, velocity Shear, average speed, flow depth, the average diameter of the particles and diameter of the bridge. The parameters in two different scenarios (the mode with dimension and mode) were introduced into the SVM network and the results of this machine were compared with those obtained from the experimental formulas and relations presented in this study. The results showed that in the first scenario, the combination of No. 5 with input parameters ($R^2 = 0.6931, RMSE = 0.3715(d_0/D, v/v_c, d_{50}/\delta, Re, \tau^*)$) and in the second scenario, the combination No. 5 with input parameters D, d_0, d_{50}, v, u^* ($R^2 = 0.8185, RMSE = 0.0459$) for the test stage were selected as the best model. It was also concluded from the results that the scenario two (the state with dimension) in predicting the scour depth around the vertical single-pillar provided a more accurate estimate than the first scenario (barrier state). At the end, the sensitivity analysis was carried out on the parameters and the parameters D, U^*, V were selected, respectively, as the most effective parameters

Keywords: Local scour, Input parameters, Support Vector Machine, Soft computing

1. Department of Civil Engineering, Hydraulic Structures, University of Maragheh, Iran.

*: Corresponding Author, Email: Mehdi.majedi@gmail.com