

## تخمین عمق آبشستگی پایه‌های پل با استفاده از روش‌های آماری و الگوریتم‌های هوشمند

سیدمرتضی سیدیان<sup>۱\*</sup> و ابوالحسن فتح‌آبادی<sup>۱</sup>  
<sup>۱</sup> استادیار دانشکده کشاورزی، دانشگاه گنبد کاووس

\* نویسنده مسئول

دریافت ۹۴/۷/۶ پذیرش ۹۵/۲/۱۲

### چکیده

تخمین دقیق عمق آبشستگی اطراف پایه‌های پل در کارهای مهندسی حائز اهمیت می‌باشد. به دلیل پیچیدگی این پدیده بسیاری از روابط موجود قادر نمی‌باشند عمق آبشستگی را با دقت قابل قبولی پیش‌بینی نمایند. در این تحقیق ابتدا ۱۷ رابطه تخمین عمق آبشستگی با داده‌های میدانی مقایسه شدند و رابطه فروهلیچ ۱۹۹۱ به عنوان بهترین رابطه انتخاب گردید. سپس با استفاده از روش‌های ترکیبی میانگین (C-SAM)، رگرسیون خطی (C-REG) و ماشین بردار پشتیبان (C-SVM) ۵ رابطه تخمین عمق آبشستگی (شن، فروهلیچ، فروهلیچ اصلاح شده، بلنج I و اینگلیس II) که دارای کمترین خطا بودند با یکدیگر ترکیب شدند. مقایسه در مرحله صحت‌سنجی نشان داد نتایج C-SAM به دلیل این‌که از میانگین روابط استفاده می‌نماید، تفاوتی با رابطه فروهلیچ ندارد؛ اما C-REG و به ویژه C-SVM توانستند نتایج را بهبود بخشند. C-SVM توانسته ضریب همبستگی و خطای RMSE رابطه فروهلیچ را به ترتیب از ۰/۵۹ به ۰/۸۵ و از ۰/۶۳ به ۰/۴۲ تغییر دهد. با استفاده از SVM عمق آبشستگی با استفاده از پارامترهای مؤثر بر آبشستگی (P-SVM) بررسی گردید. نتایج نشان دادند دقت P-SVM قابل قبول است. دقت P-SVM با ضریب همبستگی ۰/۷۷ و خطای RMSE ۰/۵۱ بین دو روش C-SVM و C-REG قرار دارد. در این تحقیق نشان داده شد ترکیب روابط تجربی با استفاده از تکنیک SVM دارای بیشترین دقت و ترکیب پارامترهای مؤثر بر آبشستگی در رتبه دوم قرار دارد. همچنین نتایج این تحقیق نشان دادند SVM با استفاده از هوش مصنوعی می‌تواند پدیده آبشستگی را با دقت بیشتری نسبت به روابط تجربی شبیه‌سازی نماید.

واژگان کلیدی: پایه پل، روش ترکیبی، عمق آبشستگی، SVM.

### ۱- مقدمه

مصنوعی، سیستم استنتاج عصبی- فازی و اخیراً روش ماشین بردار پشتیبان (SVM)<sup>۱</sup> ابزارهایی می‌باشند که در زمینه هیدرولیک و رسوب مورد استفاده قرار گرفته‌اند. Bateni و همکاران [۵، ۶] در دو تحقیق مختلف نشان دادند شبکه عصبی و سیستم استنتاج عصبی- فازی می‌توانند عمق آبشستگی را با دقت زیادی پیش‌بینی نمایند. بررسی‌ها نشان داده است هوش مصنوعی قادر است با ترکیب پارامترهای مؤثر بر آبشستگی، عمق آبشستگی را به خوبی پیش‌بینی نماید [۷-۹].

اصول ریاضی SVM بر مبنای تحقیقات ریاضیدان روسی، Vapnik [۱۰] می‌باشد. SVM مدل جدیدی بر مبنای تئوری آموزش آماری<sup>۲</sup> می‌باشد که در پیش‌بینی پارامترهای مختلف مورد استفاده قرار می‌گیرد. Noori و همکاران [۱۱] با استفاده از مدل SVM تولید هفتگی زباله در شهر مشهد را پیش‌بینی کردند. SVM در زمینه هیدرولوژی در کارهای مختلف مورد

هنگامی که جریان به پایه‌های پل برخورد می‌نماید الگوی جریان در اطراف پایه‌ها کاملاً تغییر می‌نماید. تغییرات الگوی جریان به گونه‌ای است که باعث آبشستگی در اطراف پایه‌ها می‌گردد. تخمین عمق آبشستگی پایه‌های پل، پارامتر مهمی در طراحی پل‌ها می‌باشد زیرا عدم توجه به آن ممکن است باعث تخریب و یا کاهش عمر پل گردد [۱-۴].

طراحی ایمن و اقتصادی پل نیازمند آگاهی از حداکثر عمق آبشستگی می‌باشد. روابط زیادی برای تخمین عمق آبشستگی پایه‌های پل ارائه شده است. برخی از این روابط در محیط آزمایشگاهی توسعه داده شده‌اند و دقت آن‌ها در پیش‌بینی‌های واقعی کم می‌باشد [۵]. استفاده از روش‌هایی که بتواند عمق آبشستگی را با دقت بیشتری تخمین بزند همیشه مورد توجه بوده است. در سال‌های اخیر استفاده از هوش مصنوعی به عنوان یک ابزار توانمند برای مدل‌سازی سیستم‌های غیر خطی پیچیده پذیرفته شده است و به طور گسترده‌ای برای پیش‌بینی پارامترهای مختلفی مورد استفاده قرار گرفته‌اند. شبکه عصبی

1- Support vector machine  
 2- Statistical learning theory

مرور منابع نشان می‌دهد تاکنون هیچ رابطه‌ای که بتواند در تمام شرایط، عمق آبستگي را با دقت قابل قبولی پیش‌بینی نماید ارائه نشده است. هدف این تحقیق ترکیب روابط مختلف پیش‌بینی عمق آبستگي در اطراف پایه‌های پل با استفاده از روش‌های معمول و هوشمند (SVM) و ترکیب پارامترهای مؤثر بر این پدیده با استفاده از SVM به منظور پیش‌بینی عمق آبستگي می‌باشد.

## ۲- مواد و روش‌ها

### ۲-۱- اطلاعات مورد استفاده

اطلاعات مورد استفاده به وسیله سازمان FHWA<sup>۱</sup> ارائه شده است که مربوط به پل‌های موجود در ایالت متحده می‌باشد. تمامی اطلاعات مورد استفاده میدانی می‌باشد. خصوصیات آماری مربوط به متغیرهای اندازه‌گیری شده ۴۷۸ سری داده در جدول (۱) آورده شده است. همان‌گونه که مشخص می‌باشد پارامترهای مربوط به هیدرولیک جریان، رسوب و هندسه پل دارای دامنه وسیعی می‌باشند و همچنین میدانی بودن این اطلاعات، ضریب اطمینان نتایج حاصل از این تحقیق را افزایش می‌دهد.

### ۲-۲- روابط تخمین عمق آبستگي

روش‌های مختلفی به منظور پیش‌بینی عمق آبستگي ارائه شده است. تعدادی از این روابط در جدول (۲) آورده شده است.

### ۲-۳- انتخاب پارامترهای مؤثر بر آبستگي

عمق آبستگي در اطراف پایه پل ( $S$ ) به هیدرولیک جریان و رسوب، مشخصات رسوب و هندسه پایه پل بستگی دارد. رابطه بین عمق آبستگي و پارامترهای مؤثر به صورت رابطه (۲) قابل ارائه می‌باشد [۴۲].

$$S = f(\rho, \rho_s, v, u, u_c, \gamma, g, D_{50}, \sigma, b, \alpha, \varphi) \quad (2)$$

در این رابطه  $\rho$  و  $\rho_s$  به ترتیب چگالی آب و رسوب،  $\sigma$  انحراف هندسی ذرات رسوب،  $\alpha$  زاویه برخورد جریان با پایه پل و  $\varphi$  به شکل پایه بستگی دارد.

استفاده قرار گرفته است [۱۲-۱۴]. غضنفری هاشمی و اعتماد شهیدی [۱۵] با استفاده از روش SVM عمق آبستگي پایه پل را در یک مدل آزمایشگاهی پیش‌بینی نمودند. آن‌ها نشان دادند این روش نسبت به روابط تجربی دارای دقت بیشتری می‌باشد. اگرچه مطالعات گسترده‌ای در زمینه آبستگي پایه پل انجام شده است اما یک رابطه معتبر که بتواند در شرایط مختلف نتایج قابل قبولی ارائه دهد وجود ندارد. همچنین هر رابطه برای یک شرایط خاص جواب مناسبی می‌دهد [۵].

با توجه به اهمیت عمق آبستگي، ارائه روشی که بتواند در شرایط مختلف نتایج قابل قبولی داشته باشد دارای اهمیت است. با فرض این که هر رابطه منفرد تنها می‌تواند در یک یا چند شرایط هیدرولیکی نتایج قابل قبولی ارائه دهد، انتظار می‌رود نتیجه‌ای که از ترکیب روش‌های منفرد به دست می‌آید جامع‌تر و دقیق‌تر از هر یک از روش‌ها باشد. توضیحات بیشتر در مقاله Shamseldin و همکاران [۱۶] قابل دسترسی می‌باشد. به شکل ریاضی، اگر  $N$  رابطه تخمین عمق آبستگي وجود داشته باشد، به طور کلی فرایند ترکیب به صورت زیر بیان می‌شود:

$$S_{c,i} = F(S_{1,i}, S_{2,i}, \dots, S_{n-1,i}, S_{n,i}) \quad (1)$$

که  $S_{j,i}$  نتیجه حاصل از رابطه  $j$ ام در دوره زمانی  $i$ ام و  $S_{c,i}$  نتیجه حاصل از ترکیب  $N$  رابطه تخمین عمق آبستگي در دوره زمانی  $i$  می‌باشد.

یکی از اولین تحقیقات در زمینه روش ترکیبی کار Bates و Granger [۱۷] می‌باشد. تاکنون تحقیقات زیادی انجام شده و این نتیجه حاصل گردید که اغلب، ترکیب پیش‌بینی‌ها دارای دقت بیشتری از یک رابطه پیش‌بینی منفرد می‌باشد [۱۹، ۲۳]. Shamseldin و همکاران [۱۶] از روش‌های ترکیبی میانگین ساده، میانگین وزنی و شبکه عصبی به منظور پیش‌بینی سیلاب استفاده نمودند. See و Openshaw [۲۴] برای پیش‌بینی تراز آب از ۴ روش ترکیبی استفاده نمودند. Nasserی و همکاران [۲۵] با استفاده از روش‌های ترکیبی دبی ماهانه در دو منطقه کوهستانی را پیش‌بینی نمودند. Zhao و همکاران [۲۶] با استفاده از روش‌های ترکیبی برق مصرفی کشور چین را پیش‌بینی نمودند. آن‌ها نشان دادند کارایی این روش بهتر از روش‌های دیگر است.

جدول ۱- مشخصات هندسی و هیدرولیکی پایه پل

پارامتر	حداقل	میانگین	حداکثر	انحراف معیار	ضریب تغییرات	چولگی
عرض پل (m)	۰/۳	۱/۴	۵/۵	۱/۱	۰/۸	۲/۱
طول پل (m)	۰	۱۰/۸	۲۷/۴	۴/۱	۰/۴	۱/۲
زاویه برخورد* (°)	۰	۷/۲	۸۵/۰	۱۴/۶	۲/۰	۲/۷
سرعت (m/s)	۰	۱/۳	۴/۵	۰/۸	۰/۶	۱/۰
عمق (m)	۰/۱	۴/۴	۲۲/۵	۳/۵	۰/۸	۱/۵
قطر متوسط رسوب (D <sub>50</sub> ) (mm)	۰/۱	۱۳/۱	۱۰۸/۰	۲۲/۹	۱/۸	۲/۲
انحراف هندسی ذرات رسوب	۱/۲	۳/۴	۲۱/۸	۲/۶	۰/۸	۳/۷
پارامتر شیلدز	۰/۰۳	۰/۰۴	۰/۰۶	۰/۰۱	۰/۲۰	۰/۱۷
سرعت بحرانی (m/s)	۰/۳	۱/۳	۳/۹	۱/۰	۰/۸	۱/۱
عمق آبستگی (m)	۰/۰	۱/۰	۷/۷	۱/۱	۱/۲	۳/۰

جدول ۲- روابط پیش‌بینی عمق آبستگی پایه‌های پل

رابطه	محقق
$S = 1.35b^{0.7}y^{0.3}$	Toch و Laursen, ۱۹۵۶ [۲۷]
$S = 0.00073 \left(\frac{ub}{v}\right)^{0.619}$	Shen و همکاران, ۱۹۶۹ [۲۸]
$S = 0.00022 \left(\frac{ub}{v}\right)^{0.619}$	Shen, ۱۹۷۱ [۲۹]
$\frac{S}{b} = 2.42 \left(2 \frac{u}{u_c} - 1\right) \left(\frac{u_c^2}{gb}\right)^{1/3}$	Hancu, ۱۹۷۱ [۳۰]
$\frac{S}{b} = f\left(\frac{u}{u_c}\right) \left[2 \tanh\left(\frac{y}{b}\right)\right]$	Breusers و همکاران, ۱۹۷۷ [۳۱]
$S = 0.32b\phi F_r^{0.2} \left(\frac{b_e}{b}\right)^{0.62} \left(\frac{y}{b}\right)^{0.46} \left(\frac{b}{D_{50}}\right)^{0.08}, b_e = \frac{b}{y}$	Froehlich, ۱۹۸۸ [۳۲]
$\frac{S}{y} = 2 \left(\frac{\theta}{90}\right)^{0.13} \left(\frac{b}{y}\right)^{0.43} F_r^{0.61}$	Landers و Fischenich, ۱۹۹۹ [۳۳]
$S = 0.32\theta b^{0.62} y^{0.47} F_r^{0.22} D_{50}^{-0.09}$	Froehlich, ۱۹۹۱ [۳۴]
$S = 1.8 b^{0.25} y^{0.75} - y$	Blench I, ۱۹۶۲ [۳۵]
$S = 1.53 b^{0.25} u^{0.5} D_{50}^{-0.125} y^{0.5} - y$	Blench II, ۱۹۶۲ [۳۵]
$S = 1.4b$	Breusers, ۱۹۶۵ [۳۶]
$S = y(-5.49F_r^2 + 6.65F_r - 0.51)$	Chitale, ۱۹۶۲ [۳۷]
$S = 1.7 b^{0.22} u^{0.52} y^{0.52} - y$	Inglis I, ۱۹۴۹ [۳۸]
$S = 1.73 b^{0.22} y^{0.78} - y$	Inglis II, ۱۹۴۹ [۳۸]
$S = 1.5 b^{0.70} y^{0.30}$	Neill, ۱۹۶۴ [۳۹]
$S = 1.11 b^{0.50} y^{0.50}$	Melville, ۱۹۷۵ [۴۰]
$\frac{S}{b} = 5.0 \log\left(\frac{b}{D_{50}}\right) - 4.0, \quad 6 \leq \frac{b}{D_{50}} \leq 25$ $\frac{S}{b} = \frac{1.8}{(0.02 b/D_{50} - 0.2)^2 + 1} + 1.3,$ $25 \leq \frac{b}{D_{50}} \leq 10000$	Sturm و Lee, ۲۰۰۹ [۴۱]

$$S_c = \frac{1}{n} \sum_{i=1}^n S_i \quad (4)$$

این معادله نشان می‌دهد که نتیجه ترکیبی حاصل از این روش، بسیار ساده بوده و نیازی به تلاش زیاد یا هرگونه برازش منحنی ندارد.

#### ۲-۴-۲- رگرسیون خطی چندگانه (MLR) <sup>۳</sup>

تحلیل رگرسیون خطی چندگانه به منظور پیش‌بینی متغیر وابسته (Y) با استفاده از n متغیر مستقل  $(x_1, x_2, \dots, x_n)$  انجام می‌شود. در رگرسیون خطی چندگانه تعداد n متغیر مستقل وجود دارد و رابطه بین متغیرهای مستقل و وابسته به صورت رابطه (۵) بیان می‌گردد.

$$Y = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n \quad (5)$$

که  $\beta_0$  عدد ثابت و  $\beta_1$  تا  $\beta_n$  ضرایب مربوط به n متغیر مستقل می‌باشد. با استفاده از نرم‌افزار SPSS از روش ترکیبی رگرسیونی (C-REG) به منظور ترکیب نتایج استفاده شد.

#### ۲-۵- ماشین بردار پشتیبان (SVM)

در مدل رگرسیونی SVM متغیر وابسته y با توجه به متغیرهای مستقل x باید تخمین زده شوند. این مدل مانند دیگر روش‌های رگرسیونی فرض می‌کند رابطه‌ای بین متغیرهای مستقل و وابسته به صورت  $f(x) = w^T \cdot \phi(x) + b$  به علاوه مقداری نویز <sup>۴</sup> به صورت  $(y = f(x) + noise)$  وجود دارد. مقدار نویز بر اساس مقدار مجاز خطا (ε) تعیین می‌شود. w (ضرایب بردار) و b (مقدار ثابت) پارامترهای تابع رگرسیون می‌باشند و  $\phi$  تابع هسته <sup>۵</sup> است و هدف، پیدا کردن تابع  $f(x)$  می‌باشد. این کار با آموزش مدل SVM با استفاده از یک سری داده (به عنوان مثال داده‌های آموزش) با بهینه کردن تابع خطا انجام می‌شود. w و b با حداقل سازی تابع خطای معادله (۶) با شرایط معادله (۷) به دست می‌آید.

$$\frac{1}{2} w^T \cdot w + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^2 \quad (6)$$

با توجه به این که پارامترهای  $g, v, p_s$  و q ثابت می‌باشند از این پارامترها صرف‌نظر می‌گردد. دو پارامتر  $D_{50}$  و  $\sigma$  مربوط به خصوصیات ذرات رسوبی می‌باشد. بررسی روابط مختلف پیش-بینی عمق آبستگي نشان می‌دهد پارامتر  $D_{50}$  بیشتر از  $\sigma$  در روابط مختلف مورد استفاده قرار گرفته است. با توجه به تأثیر پارامتر  $\sigma$  بر مسلح‌سازی<sup>۱</sup> بستر، برخی از محققین مانند Melville [۴۳] و Sutherland و Melville [۴۴] از نسبت  $\frac{u}{u_c}$  برای شبیه‌سازی تأثیر فرآیند مسلح‌سازی بستر بر آبستگي استفاده کرده‌اند. در نتیجه در این تحقیق با توجه به وجود پارامترهای  $u_c$  و u به منظور ساده‌سازی از پارامتر  $\sigma$  صرف‌نظر گردید. در نهایت رابطه (۲) به رابطه (۳) خلاصه شد. در رابطه (۳) تعداد پارامترهای مؤثر بر عمق آبستگي به ۷ پارامتر کاهش داده شد.

$$S = f(u, u_c, y, D_{50}, b, \alpha, \varphi) \quad (3)$$

رابطه (۳) قابل تبدیل شدن به یک سری پارامترهای بی‌بعد می‌باشد اما ظهیری و همکاران [۷]، غضنفری هاشمی و اعتماد شهیدی [۱۵]، Bateni و همکاران [۶] و Firat و Gungor [۱۸] نشان دادند دقت پارامترهای بعد دار در پیش‌بینی عمق آبستگي بیشتر از پارامترهای بی‌بعد می‌باشد. در نتیجه در این تحقیق از پارامترهای رابطه (۳) به منظور پیش‌بینی عمق آبستگي با استفاده از SVM استفاده گردید.

#### ۲-۴-۲- مبانی نظری روش‌های ترکیبی

فرض کنید n پیش‌بینی به صورت  $f_1, f_2, f_3, \dots, f_n$  وجود دارد. برای ترکیب این پیش‌بینی‌ها و تبدیل آن به یک پیش‌بینی روش‌های مختلفی وجود دارد.

#### ۲-۴-۱- روش متوسط‌گیری ساده (SAM) <sup>۲</sup>

روش متوسط‌گیری ساده (SAM) ساده‌ترین روش ترکیب نتایج حاصل از روابط مختلف می‌باشد [۴۵]. با استفاده از n نتیجه تخمین عمق آبستگي، نتیجه ترکیبی برای زمان i با استفاده از این روش به صورت رابطه (۴) بیان می‌شود.

3- Multiple linear regression

4- Noise

5- Kernel

1- Armoring

2- Simple average method

به منظور اجرای SVM، به صورت تصادفی ۸۰٪ داده‌های عمق آبهستگی (۳۸۲ سری) به آموزش مدل و ۲۰٪ مابقی (۹۶ سری) به صحت سنجی مدل اختصاص داده شد. در این تحقیق از SVM به منظور ترکیب بهترین روابط پیش‌بینی عمق آبهستگی (C-SVM) و پیش‌بینی عمق آبهستگی با استفاده از پارامترهای رابطه (۳) (P-SVM) استفاده شد.

### ۲-۶- معیارهای ارزیابی

هدف از کاربرد آزمون‌های آماری در این تحقیق، تعیین میزان خطای هر یک از روابط منفرد تخمین عمق آبهستگی و روش‌های ترکیبی می‌باشد.

$$MBE = \frac{1}{n} \sum_{i=1}^n (A_i - B_i) \quad (11)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - B_i)^2}{n}} \quad (12)$$

مقادیر مثبت و منفی MBE<sup>۳</sup> (میانگین خطای اریب) نشان می‌دهد مدل به طور کلی مقادیر را به ترتیب بیشتر و کمتر از مقدار واقعی پیش‌بینی کرده است. همچنین خطای RMSE<sup>۴</sup> میانگین ریشه مربعات خطا است که هر چه این مقدار به صفر نزدیک‌تر باشد پیش‌بینی دقیق‌تری توسط مدل صورت گرفته است. در این روابط A<sub>i</sub> مقادیر محاسباتی عمق آبهستگی و B<sub>i</sub> مقادیر اندازه‌گیری شده و n تعداد داده‌ها می‌باشد.

### ۳- نتایج و بحث

#### ۳-۱- توسعه مدل SVM

در این تحقیق تابع هسته شعاعی مورد استفاده قرار گرفت. به منظور توسعه مدل SVM با هسته شعاعی، نیاز است پارامترهای C، ε و γ تعیین شوند. تعیین مقادیر مناسب برای این پارامترها توانایی مدل در شبیه‌سازی پدیده را بهبود می‌بخشد. مقدار γ در هسته شعاعی دارای اهمیت می‌باشد زیرا ممکن باعث تخمین بیشتر یا کمتر از مقدار واقعی شود. تخمین کمتر از مقدار واقعی هنگامی رخ می‌دهد که مدل نتواند داده-

$$w^T \cdot \phi(x_i) + b - y_i \leq \epsilon + \xi_i^+ \quad (7-الف)$$

$$y_i - w^T \cdot \phi(x_i) - b \leq \epsilon + \xi_i^- \quad (7-ب)$$

$$\xi_i^+, \xi_i^- \geq 0, i = 1, 2, \dots, N \quad (7-ج)$$

C مقدار جریمه را هنگامی که خطا رخ می‌دهد نشان می‌دهد، φ تابع هسته، N تعداد نمونه‌ها و ξ<sub>i</sub><sup>±</sup> و ξ<sub>i</sub> ضرایب کمبود<sup>۱</sup> می‌باشند. اگر داده‌ای خارج از محدوده ε قرار گیرد یک خطا به مقدار ξ<sub>i</sub><sup>±</sup> و ξ<sub>i</sub> به وجود خواهد آمد. SVM با حداقل کردن دو عبارت  $\frac{1}{2} w^T \cdot w$  و  $C \sum_{i=1}^N (\xi_i^+ + \xi_i^-)$  به طور هم‌زمان، تابع را برآزش می‌دهد. معادله با استفاده از رابطه (۸) با شروط رابطه (۹) حل می‌شود.

$$\sum_{i=1}^N y_i (x_i - x_i^*) - \epsilon \sum_{i=1}^N (x_i + x_i^*) - \quad (8)$$

$$0.5 \sum_{i,j=1}^N (x_i - x_i^*) (x_j - x_j^*) \phi(x_i)^T \cdot \phi(x_j)$$

$$\sum_{i=1}^N (x_i - x_i^*) = 0 \quad (9-الف)$$

$$0 \leq x_i \leq C \quad (9-ب)$$

$$i=1, 2, \dots, N \quad 0 \leq x_i^* \leq C \quad (9-ج)$$

تابع هدف در رابطه (۸) یک تابع محدب می‌باشد که دارای یک جواب بهینه و منحصر به فرد است. در SVM هسته به صورت تابع  $K(x_i, x) = \phi(x_i)^T \cdot \phi(x)$  در نظر گرفته می‌شود. توابع هسته مختلفی شامل خطی، شعاعی، چند جمله‌ای و سیگموئید قابل استفاده می‌باشند. هسته شعاعی<sup>۲</sup> به صورت رابطه (۱۰) نسبت به دیگر هسته‌ها دارای جواب‌های بهتری است [۱۱، ۴۵، ۴۶]. با توجه به تئوری توضیح داده شده دقت در تعیین پارامترهای C، ε و γ در کاهش خطای مسئله تأثیر بسیار زیادی دارد.

$$K(x_i, x) = \exp(-\gamma |x_i - x|^2) \quad (10)$$

3- Mean bias error

4- Root mean square error

1-Slack variable

2- Radial base function (RBF) kernal

خطا در تخمین عمق آبستگي را نشان می‌دهد. علامت مثبت یا منفی آن به ترتیب نشان می‌دهد رابطه، عمق آبستگي را بیش از مقدار واقعی و یا کمتر از مقدار واقعی تخمین زده است. با مقایسه مقادیر خطا می‌توان بیان کرد رابطه شن [۲۸] یکی از کم دقت‌ترین روابط می‌باشد. همچنین رابطه فروهلیچ [۳۲] دارای کمترین خطا بین ۱۷ رابطه مورد بررسی می‌باشد. ضریب همبستگی رابطه فروهلیچ [۳۲] مقداری از روابط لارسن و تاج، لارسن و لارسن- کالاردو کمتر است اما مقادیر خطای این روابط بسیار بیشتر از فروهلیچ [۳۲] می‌باشد. با توجه به داده‌های مورد استفاده که از مطالعات میدانی به دست آمده است می‌توان نتیجه گرفت رابطه فروهلیچ [۳۲] در بین روابط مورد مطالعه دارای بهترین پیش‌بینی برای عمق آبستگي پایه پل است.

شکل (۱) مقادیر عمق آبستگي و تخمین زده شده توسط رابطه فروهلیچ [۳۲] را برای کل داده‌ها (۴۷۸ سری) نشان می‌دهد. با توجه به شکل (۱) مشخص می‌باشد برای مقادیر آبستگي کمتر از ۲ متر، فروهلیچ [۳۲] آبستگي را با دقت قابل قبولی تخمین زده اما برای مقادیر بیش از ۲ متر، مقادیر تخمین زده شده کمتر از مقادیر واقعی می‌باشد. همان‌گونه که ذکر گردید مقدار خطای MBE در این رابطه ۰/۱- می‌باشد که علامت منفی بیانگر تخمین کمتر از مقدار واقعی در این رابطه است.

بر روی محور افقی دو مقدار برابر با ۳/۷ و ۴/۰ وجود دارد که مدل مقدار بسیار کمی را برای آن‌ها تخمین زده است. بررسی داده‌ها نشان داد سرعت جریان آب هنگام اندازه‌گیری، برای این دو مقدار بسیار کم و نزدیک به صفر است در نتیجه عدد فرود در رابطه فروهلیچ [۳۲] بسیار کوچک و عمق آبستگي نیز بسیار کم تخمین زده شده است.

هایی را که با آن آموزش دیده است پیش‌بینی نماید. همچنین تخمین بیشتر از مقدار واقعی هنگامی رخ می‌دهد که مدل داده‌های آموزش را حفظ کند و برای داده‌های دیگر قادر به تخمین نباشد. مقادیر زیاد و کم  $\gamma$  به ترتیب باعث تخمین بیشتر و کمتر از مقدار واقعی می‌شوند [۴۷]. همچنین مقادیر زیاد  $C$  هم منجر به تخمین بیشتر از مقدار واقعی می‌شود [۴۸]. مقدار  $\epsilon$  به نوع نويز داده‌ها ارتباط دارد که معمولاً مقدار آن از قبل مشخص نمی‌باشد. با توجه به موارد ذکر شده مقادیر بهینه این پارامترها با توجه به حداقل کردن مقدار خطای RMSE با آزمون و خطا برای P-SVM و C-SVM تعیین شد که در جدول ۳ آورده شده است.

جدول ۳- مقادیر بهینه پارامترهای SVM

$\gamma$	$\epsilon$	$C$	
۰/۰۲	۰/۶۵	۲۰۰۰	P-SVM
۳۳	۵/۱	۷۰۰۰۰	C-SVM

### ۳-۲- ارزیابی کارایی مدل‌های منفرد

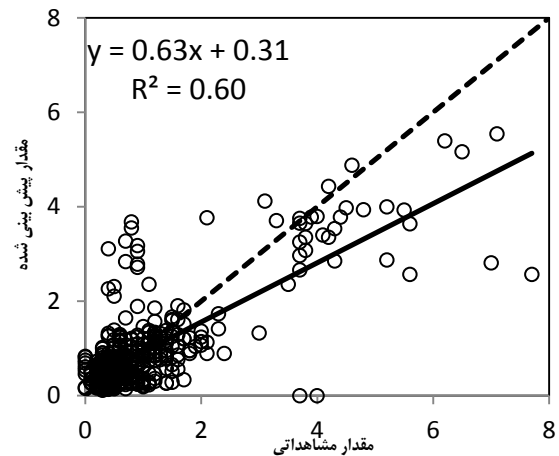
در این بخش دقت ۱۷ رابطه‌ای که در جدول (۲) آورده شده است مورد ارزیابی قرار گرفت. مقادیر ضریب همبستگی و خطاهای RMSE و MBE در جدول (۴) آورده شده است. همان‌گونه که مشخص می‌باشد مقدار ضریب همبستگی برای روابط مختلف از ۰/۱۵ برای رابطه اینگلیس I تا ۰/۶۴ برای رابطه لارسن- کالاردو متغیر می‌باشد. کمترین مقدار خطای RMSE برابر ۰/۷۳ مربوط به رابطه فروهلیچ [۳۲] و بیشترین مقدار برابر ۵/۳۸ مربوط به رابطه شن [۲۸] می‌باشد. همچنین کمترین و بیشترین خطای MBE مربوط به روابط فروهلیچ [۳۲] و شن [۲۸] به ترتیب با مقادیر ۰/۱- و ۴/۳ می‌باشد. MBE متوسط

جدول ۴- مقادیر ضریب همبستگی و خطای روابط منفرد تخمین عمق آبستگي

لارسن و تاج [۲۷]	شن ۱۹۷۱ [۲۹]	شن ۱۹۶۹ [۲۸]	هانکو و همکاران [۳۰] [۳۱]	بروسر [۳۱]	فروهلیچ ۱۹۸۸ [۳۲]	فروهلیچ ۱۹۹۱ [۳۴]	فروهلیچ اصلاح شده ۱۹۹۹ [۳۳]	I بلنج [۳۵]	II بلنج [۳۵]	بروسر [۳۶]	چیتال [۳۷]	I انگلیس [۳۸]	II انگلیس [۳۸]	لارسن [۳۹]	لارسن- کالاردو [۴۰]	لی- استورم [۴۱]	
۰/۶۲	۰/۴۸	۰/۴۸	۰/۵۲	۰/۵۳	۰/۳۰	۰/۶۰	۰/۳۹	۰/۵۲	۰/۵۲	۰/۵۲	۰/۲۸	۰/۱۵	۰/۵۶	۰/۶۲	۰/۶۴	۰/۳۶	R <sup>2</sup>
۱/۹۱	۱/۱۰	۵/۳۸	۲/۷۴	۱/۸۷	۱/۳۷	۰/۷۳	۱/۰۸	۰/۹۰	۴/۸۸	۱/۳۷	۲/۷۱	۲/۵۴	۰/۸۴	۲/۲۳	۱/۹۸	۱/۶۸	RMSE
۱/۵۰	۰/۵۹	۴/۲۵	۰/۱۸	۰/۹۷	-۰/۸۲	-۰/۰۶	-۰/۵۲	۰/۲۹	۲/۷۴	۰/۹۱	۱/۳۲	-۱/۱۲	۰/۲۹	۱/۷۸	۱/۵۸	۱/۱۰	MBE

شکل (۲) مقدار خطای هر یک از روابط مختلف را نشان می‌دهد. در روش‌های ترکیبی از یک سو هرچه خطای روابط منفرد کمتر باشد خطای حاصل از ترکیب آن‌ها هم کاهش می‌یابد و از سوی دیگر تعداد روابط منفرد باید به حدی باشد تا بتواند در شرایط مختلف نتایج قابل قبولی ارائه دهند. با توجه به این ویژگی‌ها روابط دارای خطای کمتر از ۱/۱۰ متر (خط افقی) به عنوان روابط منفرد مورد استفاده در روش‌های ترکیبی انتخاب گردیدند. با توجه به شکل (۲) روابط شن [۲۸]، فروهلیچ [۳۴]، فروهلیچ اصلاح شده [۳۳]، بلنچ I [۳۵] و اینگلیس II [۳۸] که بیشترین تطابق را با مقادیر مشاهداتی داشتند به عنوان متغیر مستقل و ورودی روش‌های ترکیبی و مقادیر اندازه‌گیری شده عمق آبستگی به عنوان خروجی روش‌های ترکیبی در نظر گرفته می‌شود.

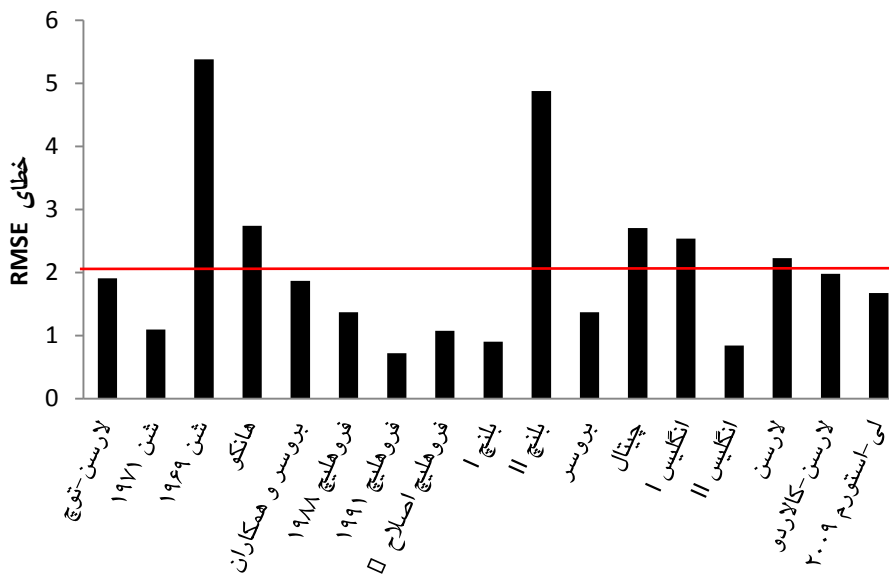
همان‌گونه که ذکر گردید به منظور آموزش مدل SVM داده‌ها به صورت تصادفی به دو بخش آموزش و صحت‌سنجی تقسیم می‌شوند. به منظور سهولت در مقایسه روش‌های ترکیبی و روابط منفرد تخمین عمق آبستگی، همانند مدل SVM، در روابط منفرد نیز ۸۰٪ داده‌ها برای آموزش و ۲۰٪ مابقی برای صحت‌سنجی مورد استفاده قرار گرفت. مقدار ضریب همبستگی و توابع خطای RMSE و MBE برای روش‌های ترکیبی و بهترین رابطه منفرد [۳۲] برای مرحله آموزش و صحت‌سنجی در جدول (۵) آورده شده است.



شکل ۱- مقایسه مقادیر مشاهداتی عمق آبستگی و مقادیر حاصل از رابطه فروهلیچ ۱۹۹۱

### ۳-۳- روش‌های ترکیبی و P-SVM

همان‌گونه که ذکر گردید روش‌های ترکیبی مورد استفاده در این تحقیق شامل روش متوسط‌گیری ساده (C-SAM)، روش رگرسیون چندگانه (C-REG) و روش ماشین بردار پشتیبان (C-SVM) می‌باشند. به منظور جلوگیری از پیچیده شدن روش‌های ترکیبی ابتدا روابطی که دارای دقت بیشتری در تخمین عمق آبستگی می‌باشند انتخاب می‌گردد. به منظور انتخاب بهترین روابط از مقدار خطای RMSE استفاده گردید.



شکل ۲- مقادیر خطای RMSE روابط منفرد

جدول ۵- مقادير ضريب همبستگي و خطاي رابطه فروهليچ، روش هاي تركيبی و P-SVM

صحت سنجي			آموزش			
R <sup>2</sup>	RMSE	MBE	R <sup>2</sup>	RMSE	MBE	
۰/۵۹	۰/۶۳	-۰/۵۵	۰/۶۰	۰/۷۵	-۰/۵۲	فروهليچ ۱۹۹۱
۰/۵۸	۰/۶۴	۰/۱۸	۰/۵۹	۰/۷۷	۰/۱۱	C-SAM
۰/۷۰	۰/۵۶	-۰/۱۷	۰/۷۱	۰/۶۳	-۰/۰۱	C-REG
۰/۸۵	۰/۴۲	-۰/۱۵	۰/۸۶	۰/۴۵	-۰/۰۲	C-SVM
۰/۷۷	۰/۵۱	-۰/۲۲	۰/۷۹	۰/۵۴	-۰/۰۶	P-SVM

مقایسه ۰/۵۶ به ۰/۴۲ (بیش از ۲۰٪) تغییر یافته است. مقایسه C-SVM با C-REG نشان می‌دهد که هوش مصنوعی برتری قابل توجهی نسبت به رابطه رگرسیونی در شبیه‌سازی آبستگي دارد.

مقایسه سه روش ترکیبی نشان می‌دهد C-SVM بهترین روش برای ترکیب روابط منفرد است و دارای بیشترین ضریب همبستگي و کمترین مقادير خطا می‌باشد. از بین ۵ رابطه منفرد انتخاب شده بر اساس علامت خطای MBE مشخص می‌باشد دو رابطه فروهليچ [۳۲] و فروهليچ اصلاح شده [۳۴] (جدول ۳) مقادير عمق آبستگي را کمتر و سه رابطه ديگر بیشتر از مقدار واقعی نشان می‌دهند. با توجه به مقادير عددی خطای MBE انتظار می‌رود میانگين ۵ رابطه منفرد، مثبت باشد که C-SAM نشان می‌دهد در مرحله صحت‌سنجی به‌طور میانگين عمق آبستگي ۰/۱۸ بیش از مقدار واقعی تخمین زده می‌شود. اگرچه مقدار خطای C-REG و C-SVM کمتر از C-SAM می‌باشد اما به‌طور میانگين عمق آبستگي را کمتر پیش‌بینی می‌نمایند که در مباحث طراحی باید مورد توجه قرار گیرد.

جهت شبیه‌سازی عمق آبستگي توسط SVM از پارامترهای تعیین شده در رابطه (۳) استفاده گردید. این مدل P-SVM نامگذاری می‌گردد. ضریب همبستگي و مقادير خطا در جدول ۵ آورده شده است. مقدار ضریب همبستگي این روش از C-REG بیشتر و از C-SVM که بهترین روش ترکیبی می‌باشد کمتر است. مقدار خطای RMSE این روش نیز بین C-REG و C-SVM می‌باشد. این مدل نیز مانند C-REG و C-SVM عمق آبستگي را کمتر از مقدار واقعی پیش‌بینی می‌نماید اما مقدار خطای MBE آن مقداری بیشتر است. مقایسه اجزای تشکیل دهنده رابطه فروهليچ ۱۹۹۱ نسبت به رابطه (۳) نشان می‌دهد فقط پارامتر  $\alpha$  (زاویه برخورد جریان به پایه پل) در رابطه فروهليچ وجود ندارد. با این وجود قدرت شبیه‌سازی بالای SVM باعث شده است مقدار ضریب همبستگي P-SVM نسبت

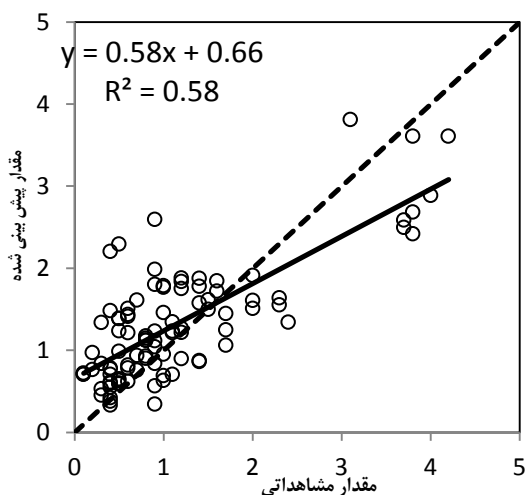
مقایسه ساده‌ترین روش ترکیبی (C-SAM) با رابطه فروهليچ نشان داد که در مرحله آموزش و صحت سنجی مقدار ضریب همبستگي و خطای RMSE تقریباً مشابه یکدیگر می‌باشد اما مقدار خطای MBE در C-SAM کاهش یافته است. رابطه فروهليچ در مرحله آموزش و صحت‌سنجی عمق آبستگي را حدود ۰/۵ متر کمتر از مقدار اندازه‌گیری شده نشان می‌دهد اما C-SAM در مرحله صحت‌سنجی عمق آبستگي را ۰/۲ بیش از مقدار واقعی نشان می‌دهد که بهتر از رابطه فروهليچ می‌باشد. در مجموع با توجه به مقادير خطا و ضریب همبستگي، C-SAM نتوانسته است نتایج بهتری از رابطه فروهليچ ارائه دهد.

رابطه‌ای که C-REG برای ترکیب روابط منفرد استفاده می‌نماید پیچیده‌تر از C-SAM می‌باشد. ضریب همبستگي و مقادير خطا در هر دو مرحله نسبت به رابطه فروهليچ بهبود نشان می‌دهد. در هر دو مرحله مقدار ضریب همبستگي حدود ۰/۱ افزایش و خطای RMSE حدود ۱۰٪ کاهش نشان می‌دهد. علامت منفی در خطای MBE نشان می‌دهد C-REG به‌طور متوسط، مقدار عمق آبستگي را کمتر از مقدار واقعی تخمین زده است.

مقدار ضریب همبستگي در C-SVM نسبت به فروهليچ در هر دو مرحله به مقدار قابل توجهی افزایش نشان می‌دهد. مقدار ضریب همبستگي در مرحله صحت‌سنجی ۰/۸۵ می‌باشد که بیانگر یک شبیه‌سازی با دقت مناسب است. مقدار ضریب همبستگي نسبت به رابطه فروهليچ حدود ۰/۲۵ افزایش و خطای RMSE بیش از ۳۰٪ کاهش نشان می‌دهد. مقدار خطای MBE در مرحله صحت‌سنجی ۰/۱۵- می‌باشد که نشان دهنده تخمین کمتر از مقدار واقعی توسط C-SVM می‌باشد. مقادير ضریب همبستگي و خطا در C-SVM نسبت به C-REG به مقدار قابل توجهی بهبود یافته است به طوری که در مرحله صحت‌سنجی مقدار ضریب همبستگي از ۰/۷۰ به ۰/۸۵ و خطای RMSE از



شکل (۴) مقادير پيش‌بيني شده توسط روش C-SAM را در مقابل مقادير واقعي نشان مي‌دهد. همان‌گونه که ذکر گرديد مقادير اين روش، ميانگين مقادير ۵ رابطه منفرد مي‌باشد. به طور کلي اين روش براي مقادير کمتر از ۲ بيش از مقدار واقعي و براي مقادير زياد (حدود ۴ متر آبستگي) کمتر از مقدار واقعي پيش‌بيني مي‌کند. مقايسه شکل‌هاي (۳) و (۴) نشان مي‌دهد اگرچه ضرايب همبستگي آن‌ها مشابه يکديگر است اما به طور کلي پراکندگي نقاط حول خط ۱:۱ در رابطه فروهليچ يکنواخت-تر است. C-SAM نتوانسته است تخمين بهتري نسبت به رابطه فروهليچ ارائه دهد زيرا مقادير خطاي ۴ رابطه منفرد ديگر بيش از رابطه فروهليچ مي‌باشد و چون C-SAM از ميانگين استفاده مي‌کند، خطاي اين روابط در C-SAM نمايانگر مي‌شود.



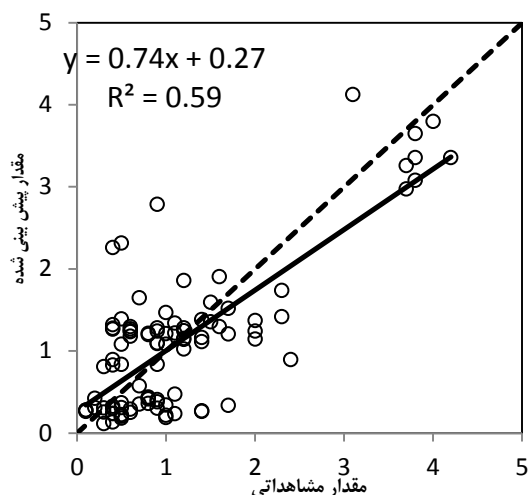
شکل ۴- مقايسه مقادير مشاهداتي عمق آبستگي و مقادير حاصل از روش ترکيبی C-SAM (مرحله صحت‌سنجی)

شکل (۵) مقادير عمق آبستگي توسط C-REG در مقابل مقادير واقعي را در مرحله‌ی صحت‌سنجی نشان مي‌دهد. در مقايسه با شکل‌هاي (۳) و (۴) پراکندگي نقاط حول خط برآزش شده کمتر مي‌باشد. براي مقادير کمتر از ۱ پراکندگي حول خط ۱:۱ يکنواخت مي‌باشد. با افزايش عمق آبستگي، C-REG عمق آبستگي را کمتر از مقدار واقعي پيش‌بيني مي‌نمايد. اگرچه C-REG براي مقادير زياد آبستگي (حدود ۴ متر) حول خط برآزش شده پراکندگي يکنواختي دارد اما نسبت به C-SAM و به‌ويژه فروهليچ ۱۹۹۱ اين مقادير را با دقت کمتری تخمين مي‌زند.

به فروهليچ حدود ۰/۱۸ افزايش و مقدار خطاي RMSE حدود ۲۰٪ کاهش يابد. همچنين مقدار خطاي MBE به مقدار قابل توجهی کاهش نشان مي‌دهد. غضنفری هاشمی و اعتماد شهیدی [۱۵] نیز با تركيب پارامترهاي مؤثر بر آبستگي توسط SVM نشان دادند SVM مي‌تواند عمق آبستگي را با دقت بالایی تخمين بزند. همچنين دقت اين روش از روابط منفرد بيشتر می‌باشد که مطابق با نتايج اين تحقيق است.

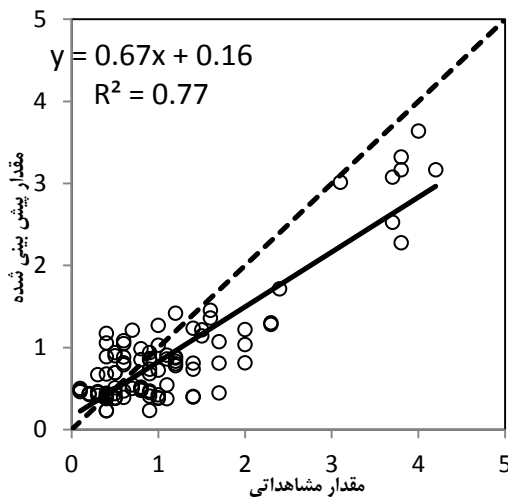
مقايسه پنج روش ذکر شده (جدول (۵)) نشان مي‌دهد مقدار خطاي MBE فقط در C-SVM مثبت است و ديگر روش‌ها به طور متوسط عمق آبستگي را کمتر از مقدار واقعي تخمين مي‌زنند. بهترين نتايج مربوط به C-SVM و P-SVM می‌باشد. SVM نشان داد با استفاده هوش مصنوعي می‌تواند با استفاده از پارامترهاي مؤثر بر آبستگي و همچنين با تركيب روابط منفرد، عمق آبستگي را با دقت قابل قبولی تخمين بزند.

شکل (۳) عمق آبستگي تخمين زده‌شده توسط رابطه فروهليچ [۳۲] را در مقابل مقادير مشاهداتي در مرحله صحت-سنجی نشان مي‌دهد. با توجه به شکل مشخص می‌باشد براي مقادير کمتر از ۲ متر عمق آبستگي پراکندگي نقاط حول خط ۱:۱ تقريباً يکنواخت است اما براي مقادير بيشتر، رابطه فروهليچ کمتر از مقدار واقعي تخمين زده است. شیب خط برآزش شده نیز نشانگر تخمين کمتر از مقدار واقعي عمق آبستگي توسط رابطه فروهليچ می‌باشد.



شکل ۳- مقايسه مقادير مشاهداتي عمق آبستگي و مقادير حاصل از رابطه فروهليچ ۱۹۹۱ (مرحله صحت‌سنجی)

روش‌های C-SVM و P-SVM مقادیر ضرایب  $C$ ،  $\epsilon$  و  $\gamma$  بر اساس داده‌های مرحله آموزش تعیین می‌گردد. با توجه با این که تعداد داده‌های مربوط به عمق آبشستگی زیاد، کم می‌باشد مدل‌ها در این محدوده خوب آموزش نمی‌بینند و در نتیجه در مرحله صحت‌سنجی نمی‌توانند نتایج مناسبی ارائه دهند. در صورتی که سری داده‌های مورد استفاده، در رابطه فروهلیچ [۳۲] تأثیری بر روی نتیجه آن ندارد.

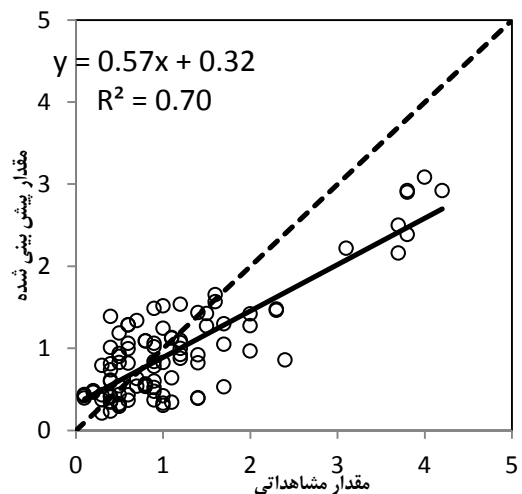


شکل ۷- مقایسه مقادیر مشاهداتی عمق آبشستگی و مقادیر حاصل از روش P-SVM (مرحله صحت‌سنجی)

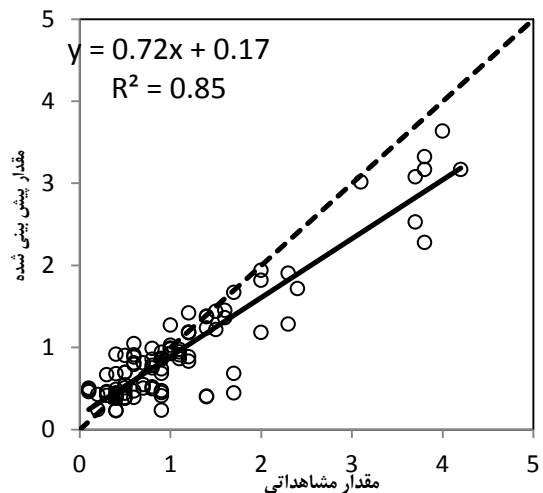
#### ۴- نتیجه‌گیری

در این تحقیق کارایی هوش مصنوعی و روش‌های ترکیبی با استفاده از داده‌های میدانی جهت تخمین عمق آبشستگی مورد بررسی قرار گرفت. با استفاده از سه روش:

- ۱- روابط تخمین عمق آبشستگی،
  - ۲- ترکیب روابط تخمین عمق آبشستگی و
  - ۳- ترکیب پارامترهای مؤثر بر آبشستگی (رابطه ۳)،
- دقت تخمین آن‌ها مورد بررسی قرار گرفت. در بین ۱۷ رابطه مورد بررسی رابطه فروهلیچ ۱۹۹۱ عمق آبشستگی را با دقت بیشتری تخمین می‌زند؛ اما ضریب همبستگی ۰/۵۹ نشان می‌دهد نتایج این روش قابل اعتماد نیست. روش‌های ترکیبی C-SAM، C-REG و C-SVM نشان دادند هرچه روش ترکیب پیچیده‌تر باشد قدرت شبیه‌سازی و دقت نتایج افزایش می‌یابد. C-SAM که از میانگین‌گیری ساده استفاده می‌نماید، نمی‌تواند نتایج قابل قبولی ارائه دهد اما دو روش ترکیبی دیگر نتایج بهتری نسبت به C-SAM ارائه می‌دهند. ترکیب پارامترهای رابطه (۳) با استفاده از SVM نتایج قابل قبولی می‌دهد و P-



شکل ۵- مقایسه مقادیر مشاهداتی عمق آبشستگی و مقادیر حاصل از روش ترکیبی C-REG (مرحله صحت‌سنجی)



شکل ۶- مقایسه مقادیر مشاهداتی عمق آبشستگی و مقادیر حاصل از روش ترکیبی C-SVM (مرحله صحت‌سنجی)

عمق آبشستگی تخمین زده شده توسط SVM با استفاده از پارامترهای مشخص شده در رابطه (۳) در شکل (۷) نشان داده شده است. برای مقادیر کمتر از ۱ متر آبشستگی، پراکندگی نقاط حول خط برازش داده شده تقریباً یکنواخت می‌باشد اما با افزایش عمق آبشستگی، P-SVM آبشستگی را کمتر از مقدار واقعی تخمین می‌زند. تمامی روش‌های ترکیبی و P-SVM در مقایسه با رابطه فروهلیچ [۳۲]، مقادیر آبشستگی زیاد را با دقت کمتری تخمین می‌زنند. حتی هوش مصنوعی (SVM) نیز نتوانسته با قابلیت شبیه‌سازی فرایندهای پیچیده، در این محدوده نتایجی مشابه رابطه فروهلیچ [۳۲] ارائه دهد. همان‌گونه که ذکر گردید در روش C-REG مقادیر ضرایب  $\beta_0$  تا  $\beta_n$  و در

- [۷] ظهیری، ج.، ظهیری، م.، سالاری جزی، م.، "برآورد بیشترین ژرفای آبشستگی در پیرامون پایه‌های پل با بهره‌وری از شبکه‌های وایزی کلی و پرسپترون چند لایه‌ای"، فصل‌نامه مهندسی منابع آب، ۱۳۹۱، ۱۴ (۳)، ۶۰-۵۱.
- [۸] روشنگر، ک.، روح‌پرور، ب.، "عملکرد سیستم‌های فرامدل در تخمین عمق آبشستگی پایه‌های پل در خاک‌های غیر چسبنده"، نشریه مهندسی عمران و محیط زیست، ۱۳۹۱، ۴۲ (۳)، ۱۳-۲۶.
- [۹] روشنگر، ک.، روح‌پرور، ب.، "ارزیابی عملکرد سیستم‌های هوش مصنوعی برای شبیه‌سازی آبشستگی پایه‌های پل در خاک‌های چسبنده"، نشریه دانش آب و خاک، ۱۳۹۲، ۲۳ (۳)، ۱۶۹-۱۸۲.
- [10] Vapnik, V., "The Nature of Statistical Learning Theory", Springer-Verlag, New York, 1995, pp 113-141.
- [11] Noori, R., Abdoli, M. A., Ameri, A., Jalili-Ghazizade, M., "Prediction of Municipal Solid Waste Generation with Combination of Support Vector Machine and Principal Component Analysis: A Case Study of Mashhad", *Environmental Progress & Sustainable Energy*, 2009, 28 (2), 249-258.
- [12] Liong, S. Y., Sivapragasam, C., "Flood Stage Forecasting With SVM", *Journal of the American Water Resources Association*, 2002, 38 (1), 173-186.
- [13] Babovic, V., Keijzer, M., Bundzel, M., "From Global To Local Modelling: A Case Study in Error Correction of Deterministic Models", *The Fourth International Conference on Hydroinformatics*, Iowa City, US, 2000, pp 45-54.
- [14] Asefa, T., Kembrowski, M. W., "Support Vector Machines Approximation of Flow and Transport Models in Initial Groundwater Contamination Network Design", *Transactions of American Geophysical Union*, 2002, 83 (2), 47-59.
- [۱۵] غضنفری هاشمی، س.، اعتماد شهیدی، ا.، "پیش‌بینی عمق آبشستگی اطراف پایه پل با استفاده از ماشین‌های بردار پشتیبان"، عمران مدرس، ۱۳۹۱، ۱۲ (۲)، ۲۳-۳۶.
- [16] Shamseldin, A. Y., O'Connor, K. M., Liang, G. C., "Methods for Combining the Outputs of Different Rainfall-Runoff Models", SVM را بعد از C-SVM در رتبه دوم قرار می‌دهد. به طور کلی نتایج نشان می‌دهند روش‌های ترکیبی می‌توانند باعث بهبود نتایج شوند. مقایسه تمام روش‌ها نشان می‌دهد SVM با استفاده از هوش مصنوعی توانسته است چه در ترکیب روابط منفرد و چه در ترکیب پارامترهای مؤثر موفق عمل نماید. ترکیب هوشمند روابط منفرد با استفاده از SVM این امکان را به وجود می‌آورد که C-SVM بتواند در کل دامنه عمق آبشستگی نتایج قابل قبولی را ارائه دهد. هوش مصنوعی با قدرت شبیه‌سازی بالا می‌تواند روابط منفرد را به صورتی که بهترین نتایج حاصل شود ترکیب نماید. در استفاده از SVM باید به این نکته توجه نمود که فرایند آزمون و خطا در مرحله آموزش زمان‌بر و حساس می‌باشد و نیاز به تعداد قابل قبولی داده می‌باشد که دقت و دامنه این داده‌ها بر نتایج بسیار مؤثر است. همچنین SVM قادر نیست مانند روابط منفرد یک رابطه صریح ارائه نماید در نتیجه استفاده از آن مانند روابط منفرد ساده نمی‌باشد.
- ### ۵- مراجع
- [1] Parola, A. C., Hagerty, D. J., Kamojjala, S., "Highway Infrastructure Damage Caused by the 1993 Upper Mississippi River Basin Flooding", Rep. No. 417, Transportation Research Board, Washington, 1998.
- [2] Richardson, E. V., Davis, S. R., "Evaluating Scour at Bridges", *Hydraulic Engineering Circular 18 (HEC-18)*, U.S. Federal Highway Administration, Washington, 2001.
- [3] Morris, J. L., Pagan-Ortiz, J. E., "Bridge Scour Evaluation Program in the United States", *Stream Stability and Scour at Highway Bridges*, E.V. Richardson and P.F. Lagasse, eds., ASCE, Reston, 1999, pp 61-70.
- [4] Wardhana, K., Hadipriono, F. C., "Analysis of Recent Bridge Failures in the United States", *Journal of Performance of Constructed Facilities*, 2003, 17 (3), 144-150.
- [5] Bateni, S. M., Borgheib, S. M., Jeng, D. S., "Neural Network and Neuro-Fuzzy Assessments for Scour Depth Around Bridge Piers", *Engineering Applications of Artificial Intelligence*, 2007, 20 (3), 401-414.
- [6] Bateni, S. M., Jeng, D. S., Melville, B. W., "Bayesian Neural Networks for Prediction of Equilibrium and Time-Dependent Scour Depth Around Bridge Piers", *Advances in Engineering Software*, 2007, 38 (2), 102-111.

- of the Hydraulics Division, ASCE, 1969, 95, 1919-1940.
- [29] Shen, H. W., "River Mechanics", Colorado State University, Fort Collins", CO, 1971.
- [30] Hancu, S., "Sur Le Calcul Des Affouillements Locaux Dams La Zone Des Piles Des Ponts", Proceedings of 14th IAHR Congress, Paris, France, vol. 3, International Association for Hydraulic Research, Delft, The Netherlands, 1971, pp 299-313.
- [31] Breusers, H. N. C., Nicollet, G., Shen, H. W., "Local Scour around Cylindrical Piers", Journal of Hydraulic Research, 1977, 15 (3), 211-52.
- [32] Froehlich, D. C., "Analysis of Onsite Measurements of Scour at Piers", National Conference on Hydraulic Engineering, Colorado Springs, CO, US, 1988.
- [33] Fischenich, C., Landers, M., "Computing Scour. EMRRP Technical Notes Collection (ERDC TN-EMRRP-SR-05)", US Army Engineer Research and Development Center, Vicksburg, US, 1999.
- [34] Froehlich, D. C., "Upper Confidence Limit of Local Pier-Scour Predictions", Proceedings of Third Bridge Engineering Conference, Denver, Colorado, US, 1991.
- [35] Blench, T., "Discussion of Scour at Bridge Crossings, by E. M. Laursen", Transactions of American Society of Civil Engineers, 1962, 127, 180-183.
- [36] Breusers, H. N. C., "Scour around Drilling Platforms", Bulletin of Hydraulic Research, 1965, 19, 276-283.
- [37] Chitale, S. V., "Scour at Bridge Crossings", Transactions of the American Society of Civil Engineers, 1962, 127, 191-196.
- [38] Inglis, S. C., "Maximum Depth of Scour at Heads of Guide Banks and Groynes, Pier Noses, and Downstream of Bridges", The Behavior and Control Of Rivers and Canals: Poona, India, 1949.
- [39] Neill, C. R., "Riverbed Scour-A Review for Engineers: Ottawa, Canada", Canadian Good Roads Association Technical Publication No. 23, 1964.
- [40] Melville, M. W., "Local Scour at Bridge Sites: New Zealand, University of Auckland", School of Engineering, Project Report No. 117, 1975.
- [41] Lee, S. O., Sturm, T. W., "Effect of Sediment Size Scaling on Physical Modeling of Bridge Pier Scour", Journal of Hydraulic Engineering, 2009, 135 (10), 793-802.
- Journal of Hydrology, 1997, 197 (1-4), 203-229.
- [17] Bates, J. M., Granger, C. W. J., "The Combination of Forecasts", Operations Research Quarterly, 1969, 20 (4), 451-468.
- [18] Firat, M., Gungor, M., "Generalized Regression Neural Networks and Feed Forward Neural Networks for Prediction of Scour Depth Around Bridge Piers", Advances in Engineering Software, 2009, 40 (8), 731-737.
- [19] Granger, C. W. J., Terasvirta, T., "Experiments in Modeling Nonlinear Relationships Between Time Series", In Casdagli M and Eubank S (Eds.), "Nonlinear Modeling and Forecasting", Redwood City, CA: Addison-Wesley, 1992.
- [20] Lebaron, B., "Nonlinear Forecasts for the S and P Stock Index", In Casdagli M and Eubank S (Eds.), Nonlinear Modeling and Forecasting. Redwood City, CA: Addison-Wesley, 1992.
- [21] Batchelor, R., Dua, P., "Forecaster Diversity and the Benefits of Combining Forecasts", Management Science, 1995, 41 (1), 68-75.
- [22] Yip, D. H. F., Hines, E. L., Yu, W. H., "Application of Artificial Neural Networks in Sales Forecasting", International Conference on Neural Networks (ICNN '97), Houston, 1997, pp 2121-2124.
- [23] Thiesing, F. M., Vornberger, O., "Sales Forecasting Using Neural Networks", International Conference on Neural Networks (ICNN '97), Houston, 1997, pp 2125-2128.
- [24] See, L., Openshaw, S. A., "Hybrid Multi-Model Approach to River Level Forecasting", Hydrological Sciences Journal, 2000, 45 (4), 523-536.
- [25] Nasser, M., Zahraie, B., Ajami, N. K., Solomatine, D. P., "Monthly Water Balance Modeling: Probabilistic, Possibilistic and Hybrid Methods for Model Combination and Ensemble Simulation", Journal of Hydrology, 2014, 511, 675-691.
- [26] Zhao, W., Wang, J., Lu, H., "Combining Forecasts of Electricity Consumption in China Withtime-Varying Weights Updated by a High-Order Markov Chain Model", Omega, 2014, 45, 80-91.
- [27] Laursen, E. M., Toch, A., "Scour Around Bridge Piers and Abutments", Bulletin No. 4, Iowa Highway Research Board, Ames, Iowa, US, 1956.
- [28] Shen, H. W., Schneider, V. R., Karaki, S., "Local Scour around Bridge Piers", Journal

- [42] Melville, B. W., Coleman, S. E., "Bridge Scour", Water Resources Publications, Littleton, Co, 2000.
- [43] Melville, B., "Pier and Abutment Scour: Integrated Approach", Journal of Hydraulic Engineering, 1997, 123 (2), 125-136.
- [44] Melville, B., Sutherland, A., "Design Method for Local Scour at Bridge Piers", Journal of Hydraulic Engineering, 1988, 114 (10), 1210-1226.
- [45] Noori, R., Karbassi, A. R., Moghaddamnia, A., Han, D., Zokaei-Ashtiani, M. H., Farokhnia, A., Ghafari Gousheh, M., "Assessment of Input Variables Determination on the SVM Model Performance Using PCA, Gamma Test and Forward Selection Techniques for Monthly Stream Flow Prediction", Journal of Hydrology, 2001, 401 (3-4), 177-189.
- [46] Dibike, Y. B., Velickov, S., Solomatine, D., Abbott, M. B., "Model Induction with Support Vector Machines: Introduction and Applications", Journal of Computing in Civil Engineering, 2001, 15 (3), 208-216.
- [47] Han, D., Chan, L., Zhu, N., "Flood Forecasting Using Support Vector Machines", Journal of Hydroinformatics, 2007, 9 (3), 267-276.
- [48] Wang, W. J., Xu, Z. B., Lu, W. Z., Zhang, X. Y., "Determination of the Spread Parameter in the Gaussian Kernel for Classification and Regression", Neurocomputing, 2003, 55 (3-4), 643-663.

**EXTENDED ABSTRACT**

## Estimation of Bridge Pier Scour Using Statistical Methods and Intelligent Algorithms

Seyed Morteza Seyedian \*, Abolhasan Fathabadi

*Faculty of Agriculture, Gonbad Kavoods University, 9915149717, Iran*

**Received:** 28 September 2015; **Accepted:** 01 May 2016

---

**Keywords:**

Bridge pier, Combination method, Scour depth, SVM

---

### 1. Introduction

When a stream is partially obstructed by a bridge pier, the flow pattern around the pier is significantly changed. Changes in flow pattern are the cause scour around piers. Bridge pier scouring estimates, is an important parameter in the design of bridges because inattention to it may cause damage or reduce the life of the bridge [1-4]. The safe and economical design of bridge piers requires accurate prediction of the maximum scour depth around their foundations [5].

Mathematical Principles of SVM is based Russian mathematician researches [6]. Ghazanfari Hashemi and Etemad Shahidi had predicted bridge pier scour using SVM method in a laboratory model. They showed that this method is more accurate than empirical relationship. Although extensive studies have been conducted on the pier scour, but a valid relationship does not exist that gives satisfactory results in different conditions [5].

Bates and Granger is one of the first research works in the field of hybrid approach [7]. Shamseldin et al. was used combination methods such as simple average, weighted average and neural network to predict floods [8].

Studying literature reveals that there is a lack of reliable formulas for prediction of the scour depth to cover different condition. The aim of this study is combination of the various pier scour relationships to predict the scour depth using conventional and intelligent (SVM) methods and combination of effective parameters of this phenomenon.

### 2. Methodology

#### 2.1. Data

The data used in this study was provided by the FHWA that is relevant to existing bridges in the United States. All used data is the result of fieldwork.

#### 2.2. Selection of scour parameters

Scour around bridge piers ( $S$ ) depends on hydraulic flow and sediment, sediment characteristics and pier geometry. Following formula can describe relationship between scour and parameters:

$$S = f(\rho, \rho_s, v, u, u_c, y, g, D_{50}, \sigma, b, \alpha, \varphi) \quad (1)$$

Seven parameters in relation to scour depth (Eq. (1)) were reduced to three parameters (Eq. (2)).

$$S = f(u, u_c, y, D_{50}, b, \alpha, \varphi) \quad (2)$$

---

\* Corresponding Author

E-mail addresses: s.m.seyedian@gmail.com (Seyed Morteza Seyedian), ahfathabadi@yahoo.com (Abolhasan Fathabadi).

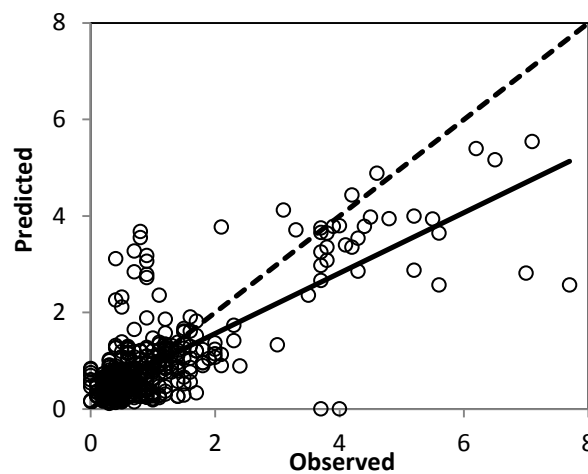
### 2.3. SVM

In SVM regression the dependent variable  $y$  with respect to the independent variable  $x$  must be estimated. This model such as other regression models assume there is a relationship between independent and dependent variables  $f(x) = w^T \cdot \phi(x) + b$  plus the amount of noise ( $y = f(x) + noise$ ). The amount of noise based on the amount of allowable error ( $\epsilon$ ) determined. In SVM kernel function is considered as  $K(x_i, x) = \phi(x_i)^T$ .

The SVM are trained with a randomly training set of scour data (382 series) and the remaining 20% (96 series) was dedicated to the validation of the model.

### 3. Results and discussion

Fig. 1 show observed and estimated scour depth by the Froehlich [9] for the whole data (478 series). According to Fig. 1 Froehlich [9] estimated scour for with reasonable accuracy amounts less than 2 meters but for amounts in excess of 2 meters, estimated scour is less than observed values. As mentioned earlier, the MBA error is -0.1 that minus sign indicates an underestimation in scour depth prediction.



**Fig. 1.** Comparison of observed scour depth and results of Froehlich [9]

The correlation coefficient, RMSE and MBA error hybrid techniques and Froehlich [9] are presented at train and test data set in Table 1. Comparison of simplest combination method (C-SAM) and Froehlich showed that the train and test correlation coefficient and RMSE error approximately similar, but the MBE error has decreased in C-SAM. Froehlich [9] predicts scour depth 0.5 m less than observed depth in train and test data set But C-SAM predict 0.2 m more than observed depth that better than Froehlich.

The correlation coefficient and error of C-REG better than Froehlich in both phases. Correlation coefficient increased about 0.1 and RMSE error decreased about 10% in both phases.

C-SVM correlation coefficient show significant increases into Froehlich. The correlation coefficient is 0.85 in test phase which represents a simulation is accurate.

Comparison of three combination methods shows C-SVM is the best method to combine individual relations and has highest correlation coefficient and minimum errors.

**Table 1.** Result of Froehlich [9], combination methods and P-SVM

	Test			Train		
	R <sup>2</sup>	RMSE	MBE	R <sup>2</sup>	RMSE	MBE
Froehlich [9]	0.59	0.63	-0.55	0.60	0.75	-0.52
C-SAM	0.58	0.64	0.18	0.59	0.77	0.11
C-REG	0.70	0.56	-0.17	0.71	0.63	-0.01
C-SVM	0.85	0.42	-0.15	0.86	0.45	-0.02
P-SVM	0.77	0.51	-0.22	0.79	0.54	-0.06

In this study, the efficiency of artificial intelligence and combinatorial techniques were analyzed to estimate the depth of pier scour using field data. Pier scour prediction were studied using three methods 1- pier scour relationship, 2- combination of pier scour relationship, 3- combination of effective parameters on pier scour. Froehlich estimate pier scour more accurately than 17 relationship but correlation coefficients 0.59 shows the results of this method is not reliable. C-SAM, which uses simple average unable to provide satisfactory results, but two other hybrid methods, provides better results than the C-SAM. Compare all methods show that SVM using artificial intelligence has been succeed to combine both individual relationships and in combining parameters.

## 5. References

- [1] Parola, A. C., Hagerty, D. J., Kamojjala, S., "Highway Infrastructure Damage Caused by the 1993 Upper Mississippi River Basin Flooding", Report No. 417, Transportation Research Board, Washington, 1998.
- [2] Richardson, E. V., Davis, S. R., "Evaluating Scour at Bridges", Hydraulic Engineering Circular 18 (HEC-18), US Federal Highway Administration, Washington DC, US, 2001.
- [3] Morris, J. L., Pagan-Ortiz, J. E., "Bridge Scour Evaluation Program in the United States", Stream Stability and Scour at Highway Bridges, EV. Richardson and PF. Lagasse, eds., ASCE, Reston, 61-70, 1999.
- [4] Wardhana, K., Hadipriono, F. C., "Analysis of Recent Bridge Failures in the United States", Journal of Performance of Constructed Facilities, 2003, 17 (3), 144-150.
- [5] Bateni, S. M., Borgheib, S. M., Jeng, D. S., "Neural Network and Neuro-Fuzzy Assessments for Scour Depth around Bridge Piers", Engineering Applications of Artificial Intelligence, 2007, 20 (3), 401-414.
- [6] Vapnik, V., "The Nature of Statistical Learning Theory", Springer-Verlag, New York, 1995.
- [7] Bates, J. M., Granger, C. W. J., "The Combination of Forecasts", Operations Research Quarterly, 1969, 20 (4), 451-468.
- [8] Shamseldin, A. Y., O'connor, K. M., Liang, G. C., "Methods for Combining the Outputs of Different Rainfall-Runoff Models", Journal of Hydrology, 1997, 197 (1-4), 203-229.
- [9] Froehlich, D. C., "Analysis of Onsite Measurements of Scour at Piers", The National Conference on Hydraulic Engineering: Colorado Springs, CO, US, 1988.