

پیش‌بینی عمق آب‌شستگی اطراف پایه پل با استفاده از ماشین‌های بردار پشتیبان

سمانه غضنفری‌هاشمی^۱، امیراعتمادشهیدی^{۲*}

۱- کارشناس ارشد مهندسی عمران-آب، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران

۲- دانشیار دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران

etemad@iust.ac.ir

تاریخ پذیرش: ۱۳۹۰/۳/۰۴

تاریخ دریافت: ۱۳۸۹/۰۷/۱۸

چکیده- آب‌شستگی یکی از مهم‌ترین عوامل خرابی پل‌ها است. بنابراین، تخمین عمق آب‌شستگی پای پل‌ها اهمیت زیادی برخوردار دارد. تاکنون فرمول‌ها و روابط تجربی زیادی برای تخمین عمق چاله آب‌شستگی ارائه شده است؛ اما این روابط از دقت مناسبی برخوردار نیستند. علاوه بر این، پیچیدگی مدل‌سازی فرایند آب‌شستگی سبب شده است تا از روش‌های جایگزین روابط تجربی، مانند روش‌های داده‌کاوی برای تخمین عمق آب‌شستگی پای پل‌ها استفاده شود. پیش از این، از شبکه‌های عصبی مصنوعی به عنوان شناخته شده‌ترین روش داده‌کاوی، برای تخمین عمق آب‌شستگی پایه پل‌ها استفاده شده اما تاکنون عملکرد روش داده‌کاوی ماشین‌های بردار پشتیبان در این زمینه مورد بررسی قرار نگرفته است. در تحقیق حاضر، عملکرد روش ماشین‌های بردار پشتیبان در تخمین عمق چاله آب‌شستگی اطراف پایه پل بررسی شده و نتایج حاصل با نتایج حاصل از روش شبکه‌های عصبی مصنوعی و روابط تجربی مقایسه شده است. بررسی‌ها نشان داده است که نتایج حاصل از روش ماشین‌های بردار پشتیبان دقت بالاتری نسبت به روش شبکه‌های عصبی مصنوعی برخوردار است. همچنین دقت روش شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان به مراتب بهتر از روابط تجربی است که این خود نشان‌دهنده عملکرد مناسب‌تر روش‌های داده‌کاوی به‌کاررفته نسبت به روابط تجربی است.

واژگان کلیدی: عمق آب‌شستگی، پایه پل، شمع، روش‌های داده‌کاوی، ANN، SVM

۱- مقدمه

درصد این خرابی‌ها پدیده آب‌شستگی پیرامون پایه پل بوده است [۱].

زمانی که پایه پل (شمع) در مسیر جریان قرار می‌گیرد الگوی جریان تغییرات عمده‌ای می‌کند. مهم‌ترین تغییر، شکل‌گیری یک ناحیه جداشدگی سه‌بعدی در نواحی اطراف پایه پل است که به خاطر آن خطوط جریان در کناره‌ها و مقابل بدنه شمع دچار تغییر می‌شوند. تغییر در خطوط جریان در جلو و پشت پایه پل اختلاف فشار به

موضوع آب‌شستگی پای پل‌ها در مهندسی رودخانه و همچنین آب‌شستگی پیرامون شمع‌ها در دریا همواره اهمیت بسیار زیادی داشته است. گزارش‌های بسیار از نقش مؤثر پدیده آب‌شستگی به عنوان یکی از عوامل خرابی پل‌ها حکایت می‌کند. برای مثال، آمار ۳۰ سال گذشته از وضعیت پل‌ها در آمریکا نشان می‌دهد که از ششصد هزار پل، حدود هزار عدد از آن‌ها خراب شده که علت ۶۰

وجود می‌آید؛ همچنین به دلیل شکل‌گیری گردابه‌های نعل اسبی، توزیع تنش برشی اطراف پایه پل نیز تغییرات عمده-ای می‌کند. وجود این پدیده‌ها به تدریج و طی زمان سبب شکل‌گیری چاله آب‌شستگی اطراف پایه پل خواهد شد.

یکی از مهم‌ترین نکات هنگام طراحی پایه پل‌ها (شمع‌ها)، تعیین عمق چاله آب‌شستگی اطراف آن است و به همین دلیل است که تاکنون روابط تجربی متعددی برای تخمین عمق آب‌شستگی پای پل‌ها (شمع‌ها) به‌وسیله‌ی محققین مختلف ارائه شده است. از آن‌جا که پدیده آب‌شستگی تابع عوامل و پدیده‌های مختلفی مانند لایه مرزی آشفته، الگوی جریان وابسته به زمان، مکانیسم انتقال رسوب، مشخصات رسوب و جریان و همچنین هندسه پایه پل است، تخمین دقیق مشخصات هندسی چاله ایجاد شده کار دشواری است.

از میان شکل‌های مختلف پایه پل، بیشتر هندسه استوانه‌ای دارند و بر همین اساس تاکنون مطالعات تجربی بسیاری برای تعیین عمق آب‌شستگی اطراف پایه پل‌های با هندسه استوانه‌ای انجام شده است [۱۱، ۲]؛ اما مقایسه مقادیر حاصل از این روابط تجربی گاهی اختلافی تا چندین برابر را با یک‌دیگر نشان می‌دهد [۴]. علت آن است که در مطالعات تجربی انجام شده، تأثیر همه‌ی پارامترهای مؤثر بر مسئله، به خوبی در نظر گرفته نشده است [۱۲]. بر همین اساس و به دنبال مطالعات تجربی، در سال‌های اخیر تلاش‌های تحقیقاتی بسیاری برای اصلاح و بهبود روش‌های تجربی موجود انجام شده است.

یکی از متداول‌ترین روش‌های جایگزین برای روابط سنتی و تجربی موجود برای مدل‌سازی پدیده‌های فیزیکی پیچیده، روش‌های موسوم به داده‌کاوی است. از میان این روش‌ها، روش شبکه‌های عصبی مصنوعی تاکنون به طور وسیعی در مطالعات هیدرولیکی استفاده شده است. از

موارد استفاده از این روش در تخمین عمق آب‌شستگی پای پل‌ها می‌توان به مطالعات باتنی و همکاران [۱۳] اشاره کرد که برای تعیین عمق آب‌شستگی پایه پل‌ها از شبکه‌های عصبی مصنوعی استفاده کرده و نتیجه حاصل را با سیستم استنباط فازی^۱ مقایسه کردند. ایشان در مطالعات خود به این نتیجه رسیدند که روش شبکه‌های عصبی مصنوعی عملکرد مناسب‌تری نسبت به سیستم استنباط فازی دارد.

کامبکار و دئو [۱۴] برای تعیین عمق آب‌شستگی ناشی از موج در پای گروه شمع از شبکه‌های عصبی مصنوعی برای یک سری داده‌های میدانی استفاده کردند. نتایج تحقیقات ایشان نشان داد شبکه‌های عصبی مصنوعی، عمق آب‌شستگی پای شمع را با دقت مناسب‌تری نسبت به روابط تجربی و همچنین روش برازش خطی پیش‌بینی می‌کند.

به تازگی روش ماشین‌های بردار پشتیبان نیز به عنوان یکی دیگر از روش‌های داده‌کاوی مورد توجه مهندسين قرار گرفته است که از موارد استفاده از آن می‌توان به مطالعات مهندس و همکاران [۱۵] اشاره کرد که برای پیش‌بینی سرعت باد، عملکرد این روش را در مقایسه با شبکه‌های عصبی مصنوعی بررسی کردند و نشان دادند که ماشین‌های بردار پشتیبان نتایج بهتری نسبت به شبکه‌های عصبی مصنوعی به دست می‌دهد. ساخاره و دئو [۱۶] نیز از ماشین‌های بردار پشتیبان و درخت تصمیم‌گیری برای پیش‌بینی طیف موج استفاده کردند. محجوبی و مسبب [۱۷] ارتفاع موج مشخصه را با استفاده از ماشین‌های بردار پشتیبان پیش‌بینی کردند.

با این حال تاکنون عملکرد روش ماشین‌های بردار پشتیبان در تخمین عمق آب‌شستگی پای پل‌ها بررسی و ارزیابی نشده است. بنابراین در این پژوهش، روش

1- Adoptive neuro-fuzzy inference system (ANFIS)

جدول (۱) روابط تجربی مختلف ارائه شده برای تخمین عمق آبشستگی اطراف پایه پل

مرجع	رابطه ارائه شده
[۸]	$S = 1.35D^{0.7}Y^{0.3}$
[۱۱]	$S = 0.00022(\frac{UD}{v})^{0.619}$
[۶]	$\frac{S}{D} = 2.42(2\frac{U}{U_c} - 1)(\frac{U_c^2}{gD})^{1/3}$
[۳]	$\frac{S}{D} = f(\frac{U}{U_c})[2\tanh(\frac{Y}{D})],$ $if \frac{U}{U_c} < 0.5, f(\frac{U}{U_c}) = 0;$ $if 0 < \frac{U}{U_c} < 0.5, f(\frac{U}{U_c}) = (2\frac{U}{U_c} - 1)$
[۵]	$\frac{S}{D} = K_3 \left(\frac{Y}{D}\right)^{-0.65} \left(\frac{U}{\sqrt{gY}}\right)^{0.43}$ که در آن $1.1 \leq K_3 \leq 1.3$ ضریب حرکت و فرسایش بستر است

۳- روش کار

۳-۱- ماشین‌های بردار پشتیبان

ماشین‌های بردار پشتیبان همانند شبکه‌های عصبی مصنوعی، یک نوع الگوریتم داده کاوی است. از ماشین‌های بردار پشتیبان تاکنون در زمینه‌های مختلفی مانند تشخیص چهره، طبقه‌بندی متون، بیوانفورماتیک و ... استفاده شده است. مهم‌ترین کاربرد ماشین‌های بردار پشتیبان در طبقه‌بندی و خطی‌سازی داده‌ها است. مراحل حل مسئله در الگوریتم ماشین‌های بردار پشتیبان همانند الگوریتم شبکه‌های عصبی مصنوعی به دو مرحله آموزش و مرحله آزمایش یا صحت‌سنجی تقسیم می‌شود.

در ادامه، نحوه عملکرد الگوریتم ماشین‌های بردار پشتیبان در حل یک مسئله‌ی طبقه‌بندی داده‌ها شرح داده

داده‌کاوی ماشین‌های بردار پشتیبان برای تخمین عمق آبشستگی پای پل‌ها در اثر جریان استفاده خواهد شد. نتایج حاصل به کمک شاخص‌های آماری مختلف، ارزیابی و با نتایج فرمول‌های تجربی نیز مقایسه خواهند شد.

۲- آبشستگی پیرامون پایه پل‌ها تحت تأثیر جریان

با احداث یک پایه پل در مسیر جریان، به تدریج یک چاله آبشستگی در اطراف آن در اثر مشخصه‌های جریان، بستر و مشخصات هندسی پایه پل شکل می‌گیرد. ارتباط میان پارامترهای مؤثر بر این فرآیند را می‌توان با رابطه (۱) بیان کرد.

$$S = f(\rho, \mu, U, Y, g, d_{50}, U_c, D) \quad (۱)$$

S عمق آبشستگی برحسب m ، ρ چگالی سیال برحسب $\frac{Kg}{m^3}$ ، μ لزجت سیال برحسب $\frac{Ns}{m^2}$ ، U سرعت متوسط جریان برحسب $\frac{m}{s}$ ، Y عمق جریان برحسب m ، U_c سرعت بحرانی برحسب $\frac{m}{s}$ ، D قطر پایه پل برحسب m و d_{50} معرف قطر متوسط ذرات رسوب برحسب m است.

اگر ارتباط میان ۸ پارامتر مستقل موجود در رابطه ۱ ($\rho, \mu, U, Y, g, d_{50}, U_c, D$) به صورت پارامترهای بدون بعد بیان شود، رابطه (۲) به دست می‌آید [۱۳]:


$$\frac{S}{D} = f\left(\frac{U}{U_c}, \frac{U}{\sqrt{gY}}, \frac{Y}{D}, \frac{D}{d_{50}}, \frac{\rho UD}{\mu}\right) \quad (۲)$$

تاکنون روابط تجربی متعددی برای تخمین عمق آبشستگی در حالت بستر تمیز و بستر زنده ارائه شده که از میان آن‌ها، روابطی برای این مطالعه انتخاب شدند که با داده‌های موجود سازگارتر باشد. در جدول ۱ فهرستی از روابط استفاده شده برای تخمین عمق آبشستگی در حالت آب تمیز که در این مطالعه نیز استفاده شد، ارائه شده است.

زیر به دست می‌آید که در آن α_i متغیر لاگرانژین است:

$$f(x_i) = \frac{1}{2}(w \cdot w) - \sum_{i=1}^m \alpha_i (y_i (w \cdot x_i + b) - 1) \quad (6)$$

همان‌طور که پیش‌تر نیز توضیح داده شد، از الگوریتم ماشین‌های بردار پشتیبان، علاوه بر طبقه‌بندی می‌توان برای خطی‌سازی داده‌ها نیز استفاده کرد که این کار با اندکی تغییر در الگوریتم طبقه‌بندی امکان‌پذیر است. برای اولین بار واپنیک [۱۸]، با ارائه الگوریتم خطی‌سازی ϵ -SVR و با معرفی تابع ϵ -sensitive، الگوریتم خطی‌سازی ماشین‌های بردار پشتیبان را ارائه کرد. در یک الگوریتم خطی‌سازی - ϵ SVR، با فرض مقادیر ورودی x_i و مقادیر خروجی y_i ، هدف یافتن تابعی است که کمترین انحراف ϵ را از y_i ‌ها داشته باشد. این مسئله در شکل ۱ به خوبی نشان داده شده است.



شکل (۱) شمایی از روش خطی‌سازی با کمک الگوریتم ماشین‌های بردار پشتیبان با در نظر گرفتن انحراف ϵ

اگر داده‌های آموزش به تعداد k سری به صورت $(x_1, y_1), \dots, (x_k, y_k)$ در نظر گرفته شوند، تابع خطی‌سازی به صورت رابطه (۷) بیان می‌شود:

$$f(x) = (w, x) + b \quad \text{with} \quad (w, x) \in R^N, b \in R \quad (7)$$

خواهد شد. برای ساده‌سازی مسئله، فرض شده است داده‌ها به دو کلاس مختلف تعلق دارند؛ بنابراین نحوه تفکیک داده‌های متعلق به این دو کلاس، بررسی می‌شود. ابتدا تابع طبقه‌بندی دودویی $f(x)$ به گونه‌ای تعریف می‌شود که مقدار آن به دو عدد $+1$ و -1 محدود شود:

$$f(x_i) = y_i = \pm 1 \quad (3)$$

در رابطه (۳)، x_i بردار داده‌های ورودی و y_i بردار داده‌های خروجی است.

با در نظر گرفتن داده‌های ورودی x_i ، اگر مقدار تابع $f(x_i)$ ، -1 باشد، بردار x_i به یک کلاس و اگر مقدار آن $+1$ باشد، به کلاس دیگر تعلق دارد. به این ترتیب به کمک تابع $f(x_i)$ ، طبقه‌بندی داده‌ها انجام خواهد شد.

حال برای بیان ریاضی مسئله طبقه‌بندی، تابع علامت، که دارای شرایط تابع ذکرشده در رابطه (۴) است، به عنوان تابع $f(x)$ انتخاب می‌شود. با در نظر گرفتن وزن w به ازای x_i و مقدار b به عنوان مقدار اختلال^۱، معادله تابع $f(x)$ به شکل رابطه زیر نوشته خواهد شد:

$$f(x_i) = \text{Sign}(wx_i + b) = y_i \quad (4)$$

در این رابطه، w ، وزن بردار x_i و b مقدار اختلالی است که قابل اعمال به تابع است.

حال با توجه به شرایط تخصیص داده‌ها به هر کلاس که شرح داده شد، معادله بهینه‌سازی مسئله طبقه‌بندی را می‌توان به صورت معادله (۵) نوشت:

$$\text{Minimise } \frac{1}{2} \|w\|^2 \quad (5)$$

$$\text{subject to } y_i (w \cdot x_i + b) \geq 1$$

اگر معادله (۴) به شکل لاگرانژین بازنویسی شود، معادله

شده و سرانجام معادله (۱۱) به دست خواهد آمد:

$$f(x, b) = \sum_{i=1}^k (\lambda'_i - \lambda_i)(x_i, x) + b \quad (10)$$

معادله بالا رابطه خطی سازی یا رگرسیون به کمک روش ماشین های بردار پشتیبان است. رابطه (۱۰) با به کارگیری توابع کرنل، برای حل مسائل رگرسیون غیرخطی نیز استفاده می شود [۱۸]، بنابراین سرانجام با استفاده از توابع کرنل، معادله تابع رگرسیون، به شکل رابطه زیر بازنویسی خواهد شد:

$$f(x, b) = \sum_{i=1}^k (\lambda'_i - \lambda_i)k(x_i, x) + b \quad (11)$$

در این رابطه $k(x_i, x)$ ، نمایانگر تابع کرنل است. در مدل سازی به کمک ماشین های بردار پشتیبان و محاسبه تابع $f(x, b)$ انتخاب مقادیر مناسب دو پارامتر ε و C در تخمین تابع رگرسیون $f(x)$ اهمیت بسیار دارد. بر این اساس، در ادامه، تاثیر انتخاب مقادیر ε و C در مدل سازی به کمک ماشین های بردار پشتیبان به تفصیل بررسی شده است.

۴- داده ها، ساخت مدل

۴-۱- مشخصات داده ها

برای بررسی عملکرد روش داده کاوی ماشین های بردار پشتیبان در تخمین عمق چاله آب شستگی اطراف یک پایه پل، از ۱۱ مجموعه داده آزمایشگاهی، حاوی ۲۶۹ داده استفاده شده است [۱۳]. جدول ۲ محدوده تغییرات پارامترهای موجود در مجموعه داده های مورد نظر را نشان می دهد.

در تعیین تابع $f(x)$ باید همواره مقادیر خروجی به گونه ای تعیین شود که به طور هم زمان، میزان کمترین انحراف از ε تعیین شده و تابع مقدار مناسب w را اختیار کند. با حل معادله بهینه سازی زیر دستیابی به چنین شرایطی محقق می شود:

$$\begin{aligned} & \text{Minimise } \frac{1}{2} \|w\|^2 \\ & \text{Subject to } \begin{cases} y_i - (w, x_i) - b \leq \varepsilon \\ (w, x_i) + b - y_i \leq \varepsilon \end{cases} \end{aligned} \quad (8)$$

در این رابطه w ، b ، x_i و y_i همان پارامترهای معادله (۸) و ε نیز میزان انحراف اعمال شده است.

گاهی ممکن است نتوان تنها میزان انحراف ε را لحاظ کرد و باید مقداری انحراف از همان مقدار ε را نیز قابل قبول فرض کرد. این میزان انحراف اضافه با لحاظ کردن متغیرهای سرباره ξ_i و ξ'_i در معادله بهینه سازی (۹) اعمال می شود [۱۸] که سرانجام معادله بهینه سازی زیر را به دست خواهد داد:

$$\begin{aligned} & \text{Minimise } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^k (\xi_i + \xi'_i) \\ & \text{Subject to } \begin{cases} y_i - (w, x_i) - b \leq \varepsilon + \xi_i \\ (w, x_i) + b - y_i \leq \varepsilon + \xi'_i \\ \xi_i, \xi'_i \geq 0 \text{ for all } i=1, 2, \dots, k \end{cases} \end{aligned} \quad (9)$$

ξ_i و ξ'_i ، متغیرهای سرباره و C ، خطای تولید^۱ است. به بیان دیگر، پارامتر C بیانگر موازنه^۲ میان ε لحاظ شده و w است. همان طور که در رابطه (۱۰) دیده می شود، این معادله بهینه سازی، با یک مجموعه قیود نامعادلات و نامساوی ها بیان شده است، بنابراین برای تبدیل آن به یک معادله صریح، پارامترهای لاگرانژین^۴ λ_i و λ'_i در آن لحاظ

1- Slack Variables
2- Generalization error
3- Trade-off
4- Lagrangian multipliers

جدول (۲) محدوده پارامترهای موجود در مجموعه داده‌های آزمایشگاهی

پارامتر	محدوده
Y	0.02-0.7(m)
U	0.165-1.503(m/s)
d_{50}	0.2-7.8(m)
U_c	0.222-1.652(m/s)
D	0.01-1(m)
S	0.004-0.440(m)

بررسی این مجموعه داده نشان می‌دهد که شرایط آزمایش آب تمیز در مورد تمام داده‌ها برقرار است.

۲-۴- روند ارزیابی عملکرد مدل SVM

برای بررسی نتایج به‌دست‌آمده از مرحله آزمایش مدل SVM، می‌توان از شاخص‌های آماری زیادی استفاده کرد. با این وجود در پژوهش حاضر، از میان شاخص‌های آماری متعدد در دسترس، شاخص‌هایی برای ارزیابی درستی عملکرد دو مدل انتخاب شده است که با استفاده از آن‌ها میزان خطای موجود در نتایج به‌دست‌آمده، میزان همبستگی داده‌ها، پراکندگی آن‌ها و همچنین بالادست یا پایین دست بودن نتایج حاصل نسبت به مقادیر واقعی نشان داده شده و ارزیابی شود. بر این اساس عملکرد مدل SVM با کمک پارامترهای آماری ضریب همبستگی، جذر مربع میانگین خطاها، شاخص پراکندگی و انحراف، ارزیابی شده است.

ضریب همبستگی، نوع و میزان همبستگی موجود بین داده‌های ورودی و خروجی مدل را تعیین می‌کند و مقدار آن از رابطه (۱۲) محاسبه می‌شود.

$$CC = \frac{\sum (T_i - \bar{T}_i)(O_i - \bar{O}_i)}{\sqrt{\sum (T_i - \bar{T}_i)^2 \sum (O_i - \bar{O}_i)^2}} \quad (12)$$

در این رابطه O_i معرف مقدار خروجی شبکه برای هر داده، T_i مقدار واقعی برای i امین خروجی، $\bar{O}_i$ میانگین

خروجی‌ها و $\bar{T}_i$ میانگین مقادیر واقعی است.

جذر مربع میانگین خطاها بیانگر میزان خطای با بعد موجود در نتایج به‌دست آمده است. میزان جذر مربع میانگین خطاهای موجود در نتایج خروجی هر یک از مدل‌ها با رابطه (۱۳) محاسبه می‌شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - T_i)^2}{N}} \quad (13)$$

N ، بیانگر تعداد کل نمونه‌ها است.

ضریب پراکندگی نشان‌دهنده میزان خطا در نتایج به‌دست‌آمده به صورت بدون بعد است و مقدار آن از رابطه (۱۴) محاسبه می‌شود:

$$SI = \frac{RMSE}{T_i} \quad (14)$$

پارامتر انحراف نیز میزان اختلاف میانگین داده‌های خروجی و ورودی است و مقدار آن از رابطه (۱۵) محاسبه می‌شود.

$$Bias = \bar{O}_i - \bar{T}_i \quad (15)$$

با این شاخص می‌توان بالادست یا پایین دست بودن مقادیر نتایج خروجی مدل را ارزیابی کرد، به این ترتیب که مقادیر مثبت این پارامتر بیانگر بالادست بودن نتایج به‌دست‌آمده و مقدار منفی آن بیانگر پایین دست بودن نتایج بدست آمده نسبت به مقادیر واقعی است.

در این مقاله، مدلی که دارای CC بیشتر و پارامترهای خطای کمتر بوده، به عنوان مدل بهینه انتخاب شده است.

۳-۴- پارامترها و نحوه انتخاب داده‌های آموزش و

آزمایش

در این مقاله برای مدل‌سازی، پارامترها به دو صورت با بعد و

برگیرد. برای انجام این کار، داده‌ها بر اساس میزان عمق آب‌شستگی به صورت نزولی مرتب و مقادیر ۲۱۸ نمونه آموزشی به گونه‌ای انتخاب شده‌اند که محدوده مقادیر بیشینه، کمینه و متوسط را شامل شوند.

۴-۴- SVM مدل

همان‌گونه که پیش‌تر در بخش ۳-۱ اشاره شد، مقادیر C و ε از مهم‌ترین پارامترهای تعیین‌کننده ساختار یک مدل SVM است، بنابراین در ادامه، مقدار این دو پارامتر برای هر دو حالت با بعد و بدون بعد از طریق آزمون و خطا تعیین شده که نتایج حاصل از آن در جدول‌های ۳ و ۴ مشاهده می‌شود. مقدار بهینه C و ε به گونه‌ای تعیین شده که نتایج به‌دست‌آمده دارای بیشترین مقادیر پارامتر ضریب همبستگی و کمترین مقادیر $RMSE$ باشد. جداول ۳ و ۴ به خوبی نشان می‌دهد که میزان C بهینه برای هر دو حالت با بعد و بدون بعد برابر ۱۰۰۰ و میزان ε بهینه برای حالت با بعد برابر ۰/۰۰۱ و برای حالت بدون بعد برابر ۰/۰۱ است.

بدون بعد به عنوان ورودی داده شده است و سرانجام مقادیر عمق آب‌شستگی (S) در حالت با بعد و عمق آب‌شستگی نرمال ($\frac{S}{D}$) در حالت بدون بعد، به عنوان خروجی پیش‌بینی شده است. پارامترهای ورودی با بعد در هر دو مدل، پارامترهای سرعت متوسط جریان (U) برحسب $\frac{m}{s}$ ، عمق جریان (Y) برحسب m ، سرعت بحرانی (U_c) برحسب $\frac{m}{s}$ ، قطر شمع (D) برحسب m و قطر میانگین دانه‌ها (d_{50}) برحسب m است. پارامترهای ورودی بدون بعد نیز مقادیر $\frac{\rho U D}{\mu}$ ، $\frac{D}{d_{50}}$ ، $\frac{Y}{D}$ ، $\frac{U}{\sqrt{gY}}$ ، $\frac{U}{U_c}$ است.

مجموعه داده‌های مرحله آموزش و آزمایش به گونه‌ای انتخاب شده که از میان ۲۶۹ داده موجود، ۸۰ درصد آن‌ها (۲۱۸ عدد) برای آموزش شبکه و ۲۰ درصد آن‌ها (۵۱ عدد) برای آزمایش شبکه استفاده شده است. از مجموعه داده‌های آموزش برای ساخت مدل‌ها و از مجموعه داده‌های آزمایش برای صحت‌سنجی هریک از مدل‌ها استفاده شده است. نحوه انتخاب داده‌های آموزش نیز به گونه‌ای بوده که محدوده تمامی مجموعه داده‌ها را در

جدول (۳) تعیین پارامترهای مدل SVM با آزمون و خطا (در حالت مدل با پارامترهای با بعد)

C	CC	$RMSE$	ε	CC	$RMSE$
1	0.8587	0.0264	1	0	0.1301
10	0.9113	0.0223	0.1	0.9087	0.0214
50	0.9294	0.0159	0.01	0.9652	0.0152
100	0.9266	0.0214	0.001	0.9622	0.0151
500	0.9596	0.017	0.0001	0.9616	0.0151
1000	0.9622	0.0151	-	-	-
1100	0.9601	0.0152	-	-	-

جدول (۴) تعیین پارامترهای مدل SVM با آزمون و خطا (در حالت مدل با پارامترهای بدون بعد)

C	CC	$RMSE$	ε	CC	$RMSE$
1	0.7602	0.3452	1	0	0.5283
10	0.8184	0.3123	0.1	0.8645	0.2782
50	0.8373	0.308	0.01	0.8664	0.2822
100	0.8448	0.3044	0.011	0.8664	0.2825
500	0.8633	0.2846	-	-	-
1000	0.8664	0.2822	-	-	-
1100	0.8677	0.2013	-	-	-

۵-۴- مدل ANN

در این پژوهش از مدل «شبکه عصبی مصنوعی» (ANN) با الگوریتم پس انتشار خطا (BP) استفاده شده است. تعداد نرون‌های لایه ورودی برابر تعداد پارامترهای ورودی یعنی ۵ نرون و تعداد نرون‌های لایه خروجی برابر با تعداد پارامترهای خروجی یعنی ۱ نرون است. تعداد نرون‌های لایه پنهان به کمک آزمون و خطا تعیین شده است؛ بدین صورت که تعداد بهینه نرون‌های این لایه به گونه‌ای انتخاب شده که نتایج به‌دست‌آمده بیشترین مقدار پارامتر ضریب همبستگی و کمترین مقدار $RMSE$ را داشته باشد. تعداد نرون‌های لایه پنهان با آزمون و خطا ۱۶ نرون به‌دست آمده است. سرانجام شبکه به‌دست‌آمده ساختار ۱۶-۵ دارد.

برای کنترل پدیده وراآموزی در مدل ANN، 10-fold cross validation انجام شده و برای جلوگیری از این پدیده حین فرایند آموزش شبکه، زمانی که مشاهده شده از دقت نتایج مرحله آزمایش کاسته می‌شود، فرایند آموزش شبکه متوقف شده است.


۵- تحلیل و بررسی نتایج

پس از انتخاب ساختار بهینه برای مدل SVM و با توجه به توضیحات مندرج در بخش قبل، در این بخش نتایج حاصل از این مدل داده‌کاوی تحلیل و بررسی می‌شود.


۵-۱- مقایسه نتایج مدل SVM با ANN و روابط تجربی

شکل‌های ۲ تا ۵، مقادیر اندازه‌گیری‌شده و مقادیر پیش‌بینی شده عمق آب‌شستگی به‌وسیله‌ی مدل‌های SVM و ANN در مرحله آموزش و صحت‌سنجی، برای داده‌های با بعد و بدون بعد را نشان می‌دهد. همان‌طور که در شکل‌های ۲ و ۳ به خوبی دیده می‌شود، عملکرد هر دو مدل ANN و

SVM در حالت با بعد با توجه به پارامترهای آماری به‌دست‌آمده از نتایج آن‌ها، نسبتاً به یک‌دیگر نزدیک است و هر دو میزان عمق آب‌شستگی را با دقت بالایی تخمین می‌زنند. همچنین نتایج آموزش شبکه‌ها نشان‌دهنده وضعیت آموزش مناسب‌تر شبکه در مدل ANN است.



(الف)



(ب)


شکل (۲) مقایسه عمق آب‌شستگی مشاهده و پیش‌بینی‌شده با SVM بر اساس پارامترهای با بعد برای مراحل الف) آموزش مدل ب) آزمایش مدل

دقت در شکل‌های ۲ و ۳ نشان می‌دهد که نتایج مراحل آموزش و آزمایش شبکه در مدل ANN تقریباً با هم برابر است. می‌توان چنین برداشت کرد که این مدل در مرحله صحت‌سنجی، عمق چاله آب‌شستگی را با همان دقت


در بررسی نتایجی که از پارامترهای با بعد موثر بر فرایند آب‌شستگی به دست می‌آید، همواره باید به این نکته توجه شود که نتایج به دست آمده تنها برای شرایط ابعادی داده‌هایی با محدوده همین داده‌های آزمایشگاهی قابل استفاده است؛ بنابراین برای تعمیم نتایج به دست آمده به مقیاس واقعی، هر دو مدل را باید با استفاده از پارامترهای بدون بعد مورد بررسی و ارزیابی کرد.

شکل‌های ۴ و ۵ میزان عمق آب‌شستگی مشاهده شده و پیش‌بینی شده با مدل‌های SVM و ANN با استفاده از پارامترهای بدون بعد را نشان می‌دهد. همان‌گونه که در مدل‌های با بعد نیز دیده شد، پارامترهای آماری نتایج دو مدل SVM و ANN بسیار به یکدیگر نزدیک است ولی SVM عمق آب‌شستگی را با دقت بیشتری نسبت به ANN پیش‌بینی می‌کند. همانند نتایج مربوط به حالت اجرای مدل‌ها با پارامترهای با بعد، مدل ANN از نتایج بهتری در مرحله آموزش نسبت به SVM برخوردار است. بر این اساس می‌توان به یک نتیجه‌گیری کلی رسید که هم در مدل داده‌کاوی با پارامترهای با بعد و هم در مدل با پارامترهای بی‌بعد، نتایج مرحله آموزش مدل ANN نسبت به SVM بهتر خواهد بود. دقت در نتایج مدل‌های SVM و ANN نشان دهنده آن است که در مرحله آزمایش مدل‌ها، شاخص آماری CC مدل SVM در حالت با بعد ۲/۲۷ درصد و در حالت بدون بعد، ۲/۹۸ درصد نسبت به ANN افزایش داشته و از پارامتر خطای $RMSE$ در حالت با بعد به میزان ۸/۴۳ درصد و در حالت بدون بعد به میزان ۱۷/۸۸ درصد کاسته شده است. بنابراین می‌توان گفت در مرحله آزمایش در هر دو وضعیت با بعد و بدون بعد، نتایج آماری مدل SVM از دقت بالاتری برخوردار است که این خود می‌تواند بیانگر مزیت SVM نسبت به ANN باشد و با توجه به توانایی تعمیم (generalization ability) بالاتر مدل SVM،

مرحله آموزش تخمین می‌زند. در حالی که در مدل SVM بین پارامترهای آماری مراحل آموزش و آزمایش اختلاف بیشتری وجود دارد و سرانجام این مدل عمق آب‌شستگی را با دقت بالاتری نسبت به مدل داده‌کاوی ANN تخمین می‌زند. این بدین معنا است که پارامترهای آماری نتایج مرحله آموزش SVM در مرحله آزمایش بسیار بهبود می‌یابد، در حالی که چنین تغییری در پارامترهای آماری نتایج مرحله آموزش ANN دیده نمی‌شود.





(الف)




(ب)

شکل (۳) مقایسه عمق آب‌شستگی مشاهده و پیش‌بینی شده با ANN بر اساس پارامترهای با بعد برای مراحل (الف) آموزش مدل (ب) آزمایش مدل



شکل (۵) مقایسه عمق آب‌شستگی مشاهده و پیش‌بینی شده با ANN بر اساس پارامترهای بی بعد برای مراحل الف) آموزش مدل ب) آزمایش مدل





شکل (۶) مقایسه عمق آب‌شستگی مشاهده و پیش‌بینی شده با روش SVM و رابطه تجربی [۵]

تضمین یکتایی وزن‌ها و رسیدن به مقادیر بهینه کلی (و نه محلی)، همچنین آموزش SVM در زمان کوتاه تر نسبت به ANN [۲۱-۱۹، ۱۷] چنین نتیجه‌ای دور از انتظار نیست.

جدول ۵ پارامترهای آماری حاصل از روش‌های تجربی معرفی شده در جدول شماره ۱ را نشان می‌دهد. همان‌طور که دیده می‌شود، با توجه به پارامترهای آماری به دست آمده برای رابطه تجربی [۵]، این رابطه عمق چاله آب‌شستگی را با دقت بالاتری نسبت به سایر روابط تجربی تخمین زده است.

در شکل ۶ نتایج مدل SVM به عنوان مدل داده‌کاوی با عملکرد مناسب‌تر نسبت به ANN و نتایج رابطه تجربی [۵] به عنوان بهترین رابطه تجربی در مقایسه با سایر روابط تجربی ترسیم شده است.



شکل (۴) مقایسه عمق آب‌شستگی مشاهده و پیش‌بینی شده با SVM بر اساس پارامترهای بی بعد برای مراحل الف) آموزش مدل ب) آزمایش مدل

جدول (۵) پارامترهای آماری به دست آمده از نتایج حاصل از روابط تجربی برای داده‌های آزمایش

مشخصه آماری				رابطه تجربی
<i>CC</i>	<i>RMSE</i>	<i>SI</i>	<i>Bias</i>	
0.7976	0.0428	0.4185	0.0279	[8]
0.8412	0.0335	0.3274	0.0167	[11]
0.3739	1.2878	0.9229	-0.3305	[6]
0.3239	1.6686	1.1959	-0.1686	[3]
0.8804	0.0334	0.3262	0.02201	[5]

در جداول ۵ و ۶ نشان‌دهنده آن است که هر دو مدل داده‌کاوی ANN و SVM نسبت به روابط تجربی دقت بالاتری دارند.

توجه به این نکته ضروری است که تعیین پارامترهای مناسب در ساختار هر دو مدل داده‌کاوی و تعیین مدل بهینه همواره بر روش آزمون و خطا استوار است. این مسئله ممکن است سبب زمان‌بری بیشتر استفاده از این مدل‌ها نسبت به روابط تجربی موجود شود. پس از بهینه‌سازی مدل‌ها، زمان اجرای مراحل آموزش و آزمایش در هر دو مدل SVM و ANN در یک رایانه شخصی (RAM=1GB, CPU=2.8GHz) چیزی حدود ۳۰ دقیقه است؛ علاوه بر این، کمیت و کیفیت داده‌های موجود در مسئله مورد نظر بر عملکرد مدل‌های داده‌کاوی ANN و SVM بسیار مؤثر است و نبود داده‌های مناسب، وجود اختلال و یا تعداد کم داده‌ها ممکن است موجب عملکرد نامناسب این مدل‌ها شود. در ضمن این مدل‌ها بر خلاف روابط تجربی موجود که عموماً تنها بر خطی‌سازی یک سری داده استوار است، به صورت جعبه سیاه عمل کرده و قادر به ارائه رابطه صریحی برای تعیین پارامتر خروجی مدل مربوطه نیست. علاوه بر این کاربر ناگزیر به بهینه‌سازی مدل است. نکته قابل ذکر دیگر در استفاده از روش‌های داده‌کاوی این است که استفاده از این مدل‌ها خارج از محدوده داده‌های آموزشی مدل باید با احتیاط انجام شود.

همان‌طور که در شکل ۶ دیده می‌شود، مدل SVM عمق چاله آب‌شستگی را با دقت بالاتری نسبت به رابطه تجربی [۵] (که با توجه به نتایج جدول ۵ نسبت به سایر روابط تجربی از دقت بالاتری برخوردار است)، پیش‌بینی می‌کند. جدول شماره ۶، مشخصات هر یک از مدل‌های ANN و SVM برای داده‌های با بعد و بدون بعد همراه با مشخصه‌های آماری حاصل از نتایج را نشان می‌دهد.

همان‌گونه که در این جدول نیز به خوبی مشاهده می‌شود، از مقایسه نتایج به دست آمده با استفاده از پارامترهای با بعد و بدون بعد می‌توان این گونه نتیجه گرفت که روش‌های داده‌کاوی به کار گرفته شده، عمق آب‌شستگی مورد نظر را در حالت بدون بعد با دقت کمتری تخمین می‌زنند. همچنین در هر دو روش، کاهش پارامتر ضریب همبستگی در تغییر پارامترها از با بعد به بدون بعد، حدود ۱۰ درصد است و این خود بدان معناست که حساسیت این مدل‌ها نسبت به تغییر پارامترها از حالت با بعد به بدون بعد یکسان است. مقایسه نتایج به دست آمده

جدول (۶) پارامترهای آماری به دست آمده از روش‌های مختلف داده‌کاوی

مشخصه آماری				روش داده‌کاوی		نوع پارامترها
<i>CC</i>	<i>RMSE</i>	<i>SI</i>	<i>Bias</i>	مشخصات	مدل	
0.9622	0.0151	0.1475	-0.0060	C=1000 $\epsilon=0.001$	SVM	با بعد
0.9406	0.0178	0.1739	0.0042	Number of iterations=22000 Learning Rate=0.0088 Momentum=0.7 (5-16-1)	ANN/BP	
0.8664	0.2822	0.2022	-0.0975	C=1000 $\epsilon=0.01$	SVM	بدون بعد
0.8413	0.306	0.2193	-0.0834	Number of iterations=23000 Learning Rate=0.008 Momentum=0.7(5-16-1)	ANN/BP	

همه‌ی پارامترهای بی بعد تقریباً با یکدیگر برابر بوده و نسبتاً زیاد است. این مسئله نشان‌دهنده آن است که پارامترهای بدون بعد مؤثر، برای مدل‌سازی مسئله به خوبی انتخاب شده است.

جدول (۷) تحلیل حساسیت پارامترهای معادله (۱) با مدل SVM

مشخصه آماری بدون پارامتر	<i>Bias</i>	<i>SI</i>	<i>RMSE</i>	<i>CC</i>
U	-0.0009	0.2560	0.0262	0.8611
U_c	-0.0079	0.1788	0.0183	0.9472
D	0.0167	0.4935	0.0505	0.4502
d_{50}	-0.0087	0.1857	0.0190	0.9449
Y	-0.0113	0.2541	0.026	0.8888

جدول (۸) تحلیل حساسیت پارامترهای معادله (۲) با استفاده از مدل SVM

مشخصه آماری بدون پارامتر	<i>Bias</i>	<i>SI</i>	<i>RMSE</i>	<i>CC</i>
$\frac{U}{U_c}$	-0.0459	0.192	0.2679	0.864
$\frac{U}{\sqrt{gY}}$	-0.099	0.2471	0.3448	0.8014
$\frac{Y}{D}$	-0.1001	0.2052	0.2863	0.8629
$\frac{D}{d_{50}}$	-0.0727	0.2234	0.3117	0.8379
$\frac{\rho UD}{\mu}$	-0.0591	0.2265	0.3161	0.8222

حساسیت مدل SVM، نسبت به پارامتر $\frac{U}{\sqrt{gY}}$ (عدد فرود) در مقایسه با سایر پارامترهای بدون بعد (از جمله عدد رینولدز) بیشتر است و با توجه به فرایند مدل‌سازی شده، چنین نتیجه‌ای دور از انتظار نیست. تأثیر این پارامتر در رابطه تجربی [۵] نیز به‌خوبی مشخص است.

۷- جمع‌بندی نتایج

در این پژوهش، عملکرد روش SVM برای تخمین عمق

با وجود محدودیت‌هایی که شرح داده شد، دقت بالاتر نتایج به‌دست آمده از روش‌های داده‌کاوی نسبت به روش‌های تجربی و همچنین ثبات بیشتر نتایج آماری به‌دست آمده از تبدیل داده‌های آزمایشگاهی با بعد به داده‌های بدون بعد، امکان استفاده از این روش‌ها را در مطالعات میدانی فراهم می‌کند. بنابراین استفاده از این روش‌ها به عنوان روش مناسبی در کنار روابط تجربی در تعیین عمق آب‌شستگی پایه پل‌ها (شمع‌ها) توصیه می‌شود.

۶- تحلیل حساسیت

در هر یک از مدل‌های SVM ارائه‌شده در بخش قبل، تأثیر پارامترهای با بعد U ، U_c ، D ، d_{50} ، Y و پارامترهای بدون بعد $\frac{U}{U_c}$ ، $\frac{U}{\sqrt{gY}}$ ، $\frac{Y}{D}$ و $\frac{D}{d_{50}}$ و $\frac{\rho UD}{\mu}$ در تعیین عمق چاله آب‌شستگی پایه پل به طور یک‌جا در نظر گرفته شده است. بنابراین برای بررسی تأثیر تک تک پارامترها در پیش‌بینی عمق آب‌شستگی، با حذف آن‌ها از سری پارامترهای ورودی مدل در همان سری داده‌های آموزش و آزمایش قبلی، مدل دوباره اجرا شده است. به این ترتیب که مثلاً برای بررسی تأثیر پارامتر U ، شاخص‌های آماری نتایج مدل SVM، با پارامترهای ورودی U_c ، D ، d_{50} و Y بررسی می‌شود. بر این اساس نتایج تحلیل حساسیت مدل SVM برای پارامترهای مختلف موجود در روابط (۱ و ۲) در جدول‌های ۷ و ۸ ارائه شده است. جدول ۷ و نتایج به‌دست آمده از تحلیل حساسیت پارامترهای موجود در معادله (۱) به خوبی نشان می‌دهد که حساسیت مدل SVM نسبت به پارامتر D در مقایسه با سایر پارامترهای با بعد دیگر بیشتر است. همچنین نتایج به‌دست آمده از تحلیل حساسیت پارامترهای موجود در معادله (۲)، مندرج در جدول ۸، نشان می‌دهد حساسیت مدل SVM، نسبت به

توجه به دقت بالاتر آن‌ها و ثبات بیشتر نتایج آماری به دست آمده از تبدیل داده‌های آزمایشگاهی به داده‌های بدون بعد، استفاده از این روش‌ها به عنوان روش مناسبی در کنار روابط تجربی در تعیین عمق آب‌شستگی پایه پل‌ها توصیه می‌شود.

۸- مراجع

- [1] Briaud, J.-L., Ting, F. C. K., Chen, H. C., Gudavalli, R., Perugu, S. and G., W., "Prediction of scour rates in cohesive soils and bridge piers", J. Geotechnical and Geoenvironmental Engineering, Vol. 125, 1999, 237-246.
- [2] Anderson, A. G., Scour at bridge water ways- A review, U.S. Dept. of Transportation, Office of research and Development, Environmental Design and Control Division, 1974.
- [3] Breusers, H. N. C., Nicollet, G. and Shen, H. W., "Local scour around cylindrical piers", Journal of Hydraulic Research, Vol. 15, 1977; 211-252.
- [4] Breusers, H. N. C. and Raudkivi, A. J., Scouring, A. A. Balakema, Rotterdam, Brookfield, 1991.
- [5] US-DOT, Evaluating scour at bridges, Hydraulic Engineering Circular, Federation of Hwy, Administration, US Department of Transportation, McLean, VA, 1993.
- [6] Hancu, S., "Sur le calcul des affouillements locaux dans la zone des piles des ponts", Proceedings of the 14th IAHR Congress, Paris, France, 1971, 299-313.
- [7] Hopkins, G. R., Vance, R. W. and Kasraie, B., Scour around bridge piers, Federal Highway Administration, Washington D.C., 1975.
- [8] Laursen, E. M., and Toch, A., "Scour around bridge piers and abutments", Bulletin Iowa Road Research Board, No. 4, 1956.
- [9] Melville, B. W. and Chiew, Y. M., "Time scale for local scour depth at bridge piers", Journal of Hydraulic Engineering, Vol. 125, 1999, 59-65.
- [10] Melville, B. W. and Sutherland, A. J., "Design method for local scour at bridge piers", Journal

آب‌شستگی پای شمع‌ها بررسی شد. در این مطالعه از مجموعه‌ای از داده‌های آزمایشگاهی متشکل از ۲۶۹ داده برای بررسی نتایج استفاده شد. در صحت‌سنجی نتایج، مقایسه مقادیر پیش‌بینی شده با SVM با ANN و روابط تجربی با استفاده از شاخص‌های آماری SI ، $Bias$ ، $RMSE$ و CC انجام شد و نتایج زیر به دست آمد:

- نتایج به دست آمده از SVM در هر دو حالت با بعد و بدون بعد از ضریب همبستگی (CC) بیشتر و مقادیر پارامترهای خطای کمتر نسبت به ANN دارد. بنابراین روش داده‌کاوی SVM عمق چاله آب‌شستگی را با دقت مناسب‌تری نسبت به ANN پیش‌بینی می‌کند.
- دقت هر دو مدل SVM و ANN در حالت با بعد بیشتر از حالت بدون بعد است.
- بررسی‌ها نشان داد که رابطه تجربی [۵] نسبت به سایر روابط تجربی استفاده شده در این پژوهش، از دقت بیشتری در تخمین مقدار چاله آب‌شستگی پایه پل دارد.
- روش SVM عمق چاله آب‌شستگی را با دقت بالاتری نسبت به رابطه تجربی [۵] پیش‌بینی می‌کند.
- حساسیت مدل SVM در حالت پارامترهای با بعد، نسبت به پارامتر D در مقایسه با سایر پارامترها بیشتر است.
- مدل SVM در حالت پارامترهای با بعد، حساسیت بیشتری نسبت به پارامتر $\frac{U}{\sqrt{gY}}$ در مقایسه با سایر پارامترها از خود نشان می‌دهد.
- میزان تغییر پارامترهای آماری نتایج دو مدل SVM و ANN در تغییر پارامترها از حالت با بعد به بدون بعد حدود ۱۰ درصد است که این خود بیانگر ثبات نتایج این مدل‌ها است.
- تعیین مدل بهینه در روش‌های داده‌کاوی بر آزمون و خطا استوار است؛ بنابراین استفاده از این روش‌ها نسبت به روش‌های تجربی زمان‌برتر است.
- با وجود برخی محدودیت‌های روش‌های داده‌کاوی با

- [17]Mahjoobi, J. and A. Mosabbebe, E., "Prediction of significant wave height using regressive support vector machines", Ocean Engineering, Vol. 36; 2009.
- [18]Vapnik, V. N., The nature of statistical learning theory, Springer, New York, 1995.
- [19]Singh, K. K., Pal, M., Ojha, P. & Singh, V. P., "Estimation of removal efficiency for settling basins using neural networks and support vector machines". J. of Hydr. Eng., Vol 13(3), 2008; 146-155.
- [20]Lin, G.F., Chen, G.R., Huang, P.Y., Chou, Y.C., "Support vector machine-based models for hourly reservoir inflow forecasting during typhoon-warning periods". Journal of Hydrology, Vol 372 (1-4), 2009; 17-29.
- [21]Lin, G.F., Chen, G.R., Wu, M.C., Chou, Y.C., "Effective forecasting of hourly typhoon rainfall using support vector machines" Journal of Water Resources, 2009.
- of Hydraulic Engineering, Vol. 114, 1988, 1210–1226.
- [11]Shen, H. W., "Scour near piers", River Mechanics, Ft. Collins, Colorado, 1971.
- [12]Ettema, R., Melville, B. W. and Barkdoll, B., "Scale effect of pier-scour experiments", Journal of Hydraulic Engineering, Vol. 124, 1998; 639–642.
- [13]Bateni, S. M., Borghei, S. M. and S., J. D., "Neural Network and neuro-fuzzy assessments for scour depth around bridge piers", Engineering Application of Artificial Intelligence, Vol. 20, 2007, 401-414.
- [14]Kambekar, A. R. and Deo, M. C., "Estimation of pile group using neural networks", Applied Ocean Research, Vol. 25, 2003, 225-234.
- [15]Mohandes, M. A., Halawani, T. O., Rehman, S. A. and Hssain, A. A., "Support vector machines for wind speed prediction", Renewable Energy, Vol. 29, 2004.
- [16]Sakhare, S. and Deo, M. C., "Derivation of wave spectrum using data driven methods", Marine Structures, Vol. 30, 2009; 1-16.

Prediction of Scour Depth Around Bridge Pier by Support Vector Machines

S. Ghazanfari Hashemi¹, A. Etemad-Shahidi^{2*}

1- M.Sc. in Hydraulic Engineering, Iran University of Science and Technology, Tehran, Iran

2- Associate Professor of Civil Engineering, Iran University of Science and Technology, Tehran, Iran

etemad@iust.ac.ir

Abstract:

Scouring is one of the main causes of failures of bridges and piles in rivers and marine environment. So the estimation of scour depth around bridge piers and piles is of great importance. On the other hand, since the scour depth properties should be considered in designs by the designers, the importance of acceptable accuracy to estimate the scour depth properties will be quite highlighted. Regarding the importance of scouring investigation, there are several empirical formulas that have been presented by researchers but acceptable results have not been provided yet. Considering the fact that the prediction of scour depth around a pile is complicated and is affected by sediment characteristics and sediment transport mechanism, current properties and pile geometries, new approaches other than empirical ones are being sought by researches. Recently alternative methods like data mining approaches have been widely applied to simulate complicated problems. Artificial Neural Networks (ANN) as a famous data mining approach has been successfully used to estimate the scour properties around a pile. However, performances of Support Vector Machines (SVM) as another type of data mining approach are not explored yet. SVM has been recently applied in fields of particle identification, face identification, text categorization and bioinformatics. In this study SVM is applied to estimate the scour depth around a pile and the results are compared with those of the ANN by MLP network with one hidden layer and back propagation training algorithm. Performances of all methods are tested by experimental data sets and the results are compared using statistical measures. Results of statistical measures of verification stage indicate that SVM provides a better estimation of scour depth than ANN and empirical formulae. They also indicate that data mining approaches provide better prediction than empirical approaches.

Keywords: Scour depth, Bridge pier, Pile, Data mining