

کاربرد و ارزیابی الگوریتم SVM برای شبیه‌سازی هندسه‌ی گودال آبستگ‌ی پایین‌دست سرریز

سیفونی

مهدی فولادی‌پناه^{۱*}، مهدی ماجدی‌اصل^۲، رضا جعفری‌نیا^۳

تاریخ دریافت: ۱۳۹۸/۹/۲۲ تاریخ پذیرش: ۱۳۹۸/۱۲/۱۹

چکیده

شبیه‌سازی دقیق مشخصات هندسی گودال آبستگ‌ی ناشی از برخورد جت آب به کف حوضچه‌ی استغراق نقش مهمی در طراحی، ساخت و عملکرد سرریزها و مستهلک‌کننده‌های انرژی دارد. در این پژوهش، ارزیابی تطبیقی بین مطالعه‌ی آزمایشگاهی و عددی آبستگ‌ی در پایین‌دست سرریز سیفونی با استفاده از الگوریتم پشتیبان بردار ماشین (SVM) با سه دانه‌بندی از مواد رسوبی و سه زاویه‌ی پرتابه‌ی باکت به ازای مقادیر مختلف دبی و عمق پایاب در یک فلوم آزمایشگاهی مستطیلی از جنس پلاکسی گلاس انجام شد. سه متغیر بی‌بعد که دارای استقلال خطی نسبت به هم بودند، تشکیل شدند. علاوه بر الگوریتم SVM، معادلات رگرسیون کلاسیک خطی و غیرخطی و همچنین شبکه‌ی عصبی FFBP و CPBF برای شبیه‌سازی هندسه‌ی گودال مورد استفاده قرار گرفتند و به کمک پنج شاخص آماری R، RMSE، MAE، N.S و DDR مقایسه شدند. مقایسه‌ی شاخص‌های تدقیق پنج‌گانه نشان داد از بین مدل‌های عددی، الگوریتم SVM کارکرد بهتری نسبت به بقیه‌ی مدل‌ها مخصوصاً مدل‌های رگرسیونی کلاسیک داشت. در بین تمام پارامترهای هندسی گودال آبستگ‌ی، بالاترین و پایین‌ترین سطح عملکرد الگوریتم SVM مربوط به $\frac{L_s}{h_t}$ و $\frac{L_s}{h_t}$ به ترتیب با مقادیر شاخص‌های آماری پنج‌گانه‌ی فوق‌الذکر (۰/۹۹۵۴، ۰/۲۰۵۶، ۰/۹۸۷، ۰/۹۸۵۱، ۷/۸۵۵) و (۰/۸۹۲۴، ۰/۸۶۰، ۲/۲۳۰، ۰/۷۵۸۷، ۱/۴۰۵) بودند. در نهایت مقایسه‌ی بین خروجی الگوریتم SVM و معادله‌های تجربی برای شبیه‌سازی عمق گودال فرسایشی انجام شد. نتایج نشان داد الگوریتم SVM برتری محسوس و مطلق نسبت به معادلات تجربی ارائه شده توسط محققان دیگر دارد.

واژه‌های کلیدی: ارزیابی عملکرد، حوضچه‌ی استغراق، تحلیل ابعادی، الگوریتم SVM

مقدمه

جام پرتابی به عنوان یکی از روش‌های مطمئن برای استهلاک انرژی، تحت شرایط خاصی در پایین‌دست سدها به کار گرفته می‌شود. وقوع پدیده‌ی آبستگ‌ی ناشی از جت‌های ریزشی موجب بروز پدیده‌ی گودال آبستگ‌ی می‌شود. تشکیل گودال آبستگ‌ی به عنوان پدیده‌ای پویا و غیرخطی، تابعی از عوامل هیدرولیکی، مورفولوژیکی و ژئوتکنیکی است که در اثر انتقال رسوب ناشی از انرژی جت سیال برخورد کننده به کف بستر شکل می‌گیرد. دو پارامتر طول و عمق گودال در زمره‌ی پارامترهایی هستند که در بیشتر تحقیقات برای پیش‌بینی مورد بررسی قرار می‌گیرند. این تحقیقات در قالب روابط

تجربی (مانند Schocklitch, 1928; Veronese, 1937)، روابط آزمایشگاهی (مانند Hager and Minor, 2004; Vesalian et al., 2004; Rajsratnam and Mazurek, 2003)، معادلات تحلیلی (مانند Wiltner et al., 1998) و نیز مدل‌های هوش مصنوعی (مانند Azamatollah et al., 2005؛ هوشیاری‌پور و نوری (۱۳۹۲)) تقسیم‌بندی می‌شوند. به عنوان مثال، روابط تجربی برای محاسبه‌ی عمق آبستگ‌ی در قالب کلی معادله‌ی زیر قابل بیان است:

$$D_s = K \frac{q^{0.5} H^y}{d_s^z} \quad (1)$$

که در این معادله D_s عمق آبستگ‌ی، K ضریب ثابت در محدوده‌ی ۰/۲ تا ۲/۳، q دبی، H ارتفاع آبشار، d_s اندازه‌ی شاخص ذرات رسوبی، x ضریب ثابت با دامنه‌ی ۰/۵ تا ۰/۶۷، y ضریب ثابت در محدوده‌ی ۰ تا ۰/۵ و z ضریب ثابت در محدوده‌ی ۰ تا ۰/۵ هستند. برای نمونه، رابطه‌ی Schocklitch (1928) به عنوان اولین رابطه برای پیش‌بینی عمق آبستگ‌ی با استفاده از ماسه‌ی یکنواخت و غیریکنواخت به قرار زیر ارائه شده است:

۱- استادیار گروه عمران، واحد رامهرمز، دانشگاه آزاد اسلامی، رامهرمز، ایران
۲- استادیار گروه عمران، دانشگاه مراغه، مراغه، ایران
۳- استادیار گروه مهندسی آب، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران
* نویسنده مسئول: (Email: Fuladipanah@gmail.com)

فولادی‌پناه (۱۳۹۷) استفاده از الگوریتم SVM را برای استفاده در شبیه‌سازی‌هایی که متغیر وابسته آزمایشگاهی تابع چندین متغیر مستقل است توصیه کرده‌اند. رضازاده و همکاران (۱۳۹۸) ضمن کاربرد هوش مصنوعی در تعیین عمق آبخستگی پایه‌ی پل، بیان کردند که شبکه‌ی عصبی مصنوعی و بهینه کردن آن با الگوریتم ژنتیک در تخمین عمق آبخستگی پایه‌های پل در بسترهای با رسوبات چسبنده در مقایسه با معادلات تجربی عملکرد بسیار بهتری دارد. فتاحی و همکاران (۱۳۹۸) ضمن به کارگیری روش‌های هوش مصنوعی برای تعیین آبخستگی در پایین‌دست سیفون معکوس، بیان داشتند استفاده از هوش مصنوعی قادر به پیش‌بینی خصوصیات گودال آبخستگی با دقت بسیار مناسب و قابل قبول است. استفاده از روش‌های شبیه‌سازی داده مینا برای گودال آبخستگی توسط ییپ و همکاران، دیبیک و همکاران، وانگ و همکاران، باطنی و همکاران، فیرات و گنگور پیشنهاد شده است (Dibik et al., 1997; Yip et al., 2007a,b; Wang et al., 2003; al., 2001; Firat and Gungor, 2009). استفاده از سیستم تطبیقی استنتاج فازی-عصبی و رگرسیون خطی برای پیش‌بینی عمق آبخستگی پل‌ها توسط آکب و همکاران پیشنهاد شده است (Akib et al., 2014). نتایج تحقیقات پندی و همکاران حاکی از توصیه آن‌ها برای به‌کارگیری روش الگوریتم ژنتیک و رگرسیون خطی چندگانه برای پیش‌بینی عمق آبخستگی زمانی، نزدیک پایه‌های دایره‌ای شکل بود (Pandy et al., 2018). هوانگ و همکاران استفاده از الگوریتم SVM را برای تخمین خصوصیات گودال آبخستگی اطراف پایه‌های پل پیشنهاد دادند (Hoang et al., 2018).

مطالعه‌ی تحقیقات پیشین حاکی از توصیه‌ی محققین برای کاربرد روش‌های داده-مینا در تعیین عمق آبخستگی است. تعیین موقعیت دقیق گودال آبخستگی تشکیل شده در حوضچه‌ی استغراق می‌تواند نقش بسیار مهمی در پایداری و عملکرد مناسب سازه‌های هیدرولیکی در بالادست خود داشته باشد. از طرفی دیگر به دلیل عدم مطالعه‌ی عددی گودال آبخستگی در پایین‌دست سرریز سیفونی، پژوهش حاضر به بررسی و شبیه‌سازی خصوصیات هندسی گودال فرسایشی در پایین‌دست سرریز سیفونی با استفاده از الگوریتم پشتیبان بردار ماشین پرداخته است. ضمن اینکه خروجی الگوریتم SVM با معادلات تجربی و شبکه‌ی عصبی نیز مقایسه شده است.

مواد و روش‌ها

برایی چیدمان آزمایشگاهی

همان‌طور که ذکر شد هدف از این پژوهش، شبیه‌سازی ابعاد گودال فرسایشی پایین‌دست سرریز سیفونی با استفاده از الگوریتم SVM، مدل‌های رگرسیون کلاسیک خطی و غیرخطی و نیز شبکه‌ی

$$D_s = 0.521 H^{0.7} q^{0.15} d_{90}^{-0.32} \quad (2)$$

که در این فرمول D_s برحسب m ، H برحسب m ، q برحسب $\frac{m^3}{m.s}$ و d_{90} برحسب m هستند. همان‌طور که مشاهده می‌شود در معادلات تجربی و همچنین آزمایشگاهی آسان بودن کاربرد معادله و نیز کم بودن تعداد پارامترهای مورد نیاز از مزایای این دسته از معادلات محسوب می‌شود. اما به دلیل محدودیت‌ها و شرایط آزمایشگاهی، این گروه از معادلات در محدوده و دامنه‌ی مشخصی از متغیرها قابلیت استفاده دارند. از طرف دیگر به دلیل پیچیدگی و غیرخطی بودن پدیده‌ی آبخستگی ارائه‌ی رابطه‌ی دقیق تجربی که قادر به پیش‌بینی صحیح خصوصیات آن باشد مشکل است. طبق مطالعات و تحقیقات انجام شده توسط عظمت‌الله و همکاران و گوپال، مدل‌های هوش مصنوعی معمولاً منجر به نتایج رضایت‌بخش‌تری نسبت به معادلات رگرسیونی کلاسیک می‌شوند که دلیل آن خطاهای کم و ضریب همبستگی بالای روش‌های هوش مصنوعی است (Azamatollah et al., 2008; Goyal, 2011). استفاده از روش‌های داده-مینا و الگوریتم‌های هوشمند جایگاه و نقش ویژه‌ای در سال‌های اخیر پیدا کرده‌اند. روش‌های داده-مینا این قابلیت را دارند تا روابط پیچیده و مخفی بین متغیرهای مستقل و وابسته‌ی پدیده‌ی آبخستگی را بدون دانش پایه‌ای از فیزیک مسئله و تنها از طریق آموزش استخراج کنند و برای تولید داده‌های جدید استفاده نمایند. طبق تحقیقات انجام شده توسط غضنفری هاشمی و اعتماد شهیدی (۱۳۹۱)، استفاده از الگوریتم پشتیبان بردار ماشین (SVM) نسبت به روش‌های آزمایشگاهی منجر به نتایج دقیق‌تری در پیش‌بینی مشخصات گودال آبخستگی پایه‌های پل می‌شود. روشنگر و روح‌پرور (۱۳۹۱، ۱۳۹۲) استفاده از الگوریتم SVM را برای شبیه‌سازی عمق آبخستگی پیشنهاد دادند. سیدیان (۱۳۹۴) استفاده از روش‌های داده-مینای شبکه‌ی عصبی و پشتیبان بردار ماشین را برای پیش‌بینی عمق آبخستگی در پایه‌های پل توصیه کرده است. طبق نتایج تحقیقات او، استفاده از الگوریتم SVM منجر به نتایج قابل قبول می‌شود. سیدیان و فتح‌آبادی (۱۳۹۵) ضمن مطالعه‌ی پدیده‌ی آبخستگی، به مقایسه‌ی روابط تجربی موجود در پیش‌بینی گودال آبخستگی با روش‌های عددی پرداختند. نتایج تحقیقات آن‌ها ضمن اثبات برتری روش‌های هوش مصنوعی نسبت به روابط تجربی، نشان داد در میان روش‌های عددی هوشمند، الگوریتم SVM جواب دقیق‌تری نسبت به دیگر روش‌های عددی دارد. نتیجه‌ی به‌کارگیری روش داده‌کاوی برای پیش‌بینی عمق آبخستگی گروه پایه‌ی پل توسط سلطانی-گردفرامرزی و تقی‌زاده‌مهرجردی (۱۳۹۵) حاکی از دقت بسیار مناسب و دقیق این روش نسبت به روش‌های تجربی بود. ماجدی‌اصل و

$$\psi = f(Q, \rho, \mu, g, H, h_t, v, d_{50}, G_s, C_u, \theta, S.F., \alpha, D, S, n) \quad (3)$$

با توجه به اینکه وضعیت نهایی گودال آبشستگی در این پژوهش مورد بررسی و ارزیابی قرار گرفته است پارامتر زمان لحاظ نشده است. به دلیل ثابت بودن شکل مجرای سیفون، شیب و جنس مجرا و نیز فاکتور شکل، انحراف معیار ذرات رسوبی و زاویه ایستایی ثابت به دلیل یکنواخت بودن ذرات رسوبی، تعداد متغیرهای پژوهش در معادله (۳) به صورت زیر کاهش می‌یابد:

$$\Phi = f(Q, \rho, g, h_t, d_{50}, G_s, \alpha) \quad (4)$$

نه متغیر بی‌بعد برای شبیه‌سازی مشخصات گودال آبشستگی با استفاده از تئوری باکینگهام به دست آمدند که پس از بررسی استقلال خطی بین آن‌ها، در نهایت سه متغیر به قرار $\Pi_1 = \alpha$ ، $\Pi_2 = \frac{Q}{\sqrt{g d_{50}^3 (G_s - 1)}}$ و $\Pi_3 = \frac{U}{\sqrt{g h_t}}$ انتخاب شدند. شکل ۴ استقلال خطی سه متغیر بی‌بعد را نشان می‌دهد.

الگوریتم SVM

در الگوریتم SVM متغیر وابسته‌ی y با استفاده از چندین متغیر مستقل x تخمین زده می‌شود. در این الگوریتم مانند دیگر روش‌های رگرسیونی، رابطه‌ای همانند

$$f(x) = w^T \cdot \Phi(x) + b \quad (5)$$

به‌اضافه‌ی مقداری نویز به صورت


$$y = f(x) + \text{noise} \quad (6)$$

شکل می‌گیرد. مقدار نویز بر اساس مقدار مجاز خطای ϵ تعیین می‌شود. در معادله‌ی (۵)، w (بردار ضرایب) و b (مقدار ثابت) پارامترهای تابع رگرسیونی و Φ تابع هسته هستند.


عصبی و در نهایت مقایسه‌ی آن‌ها با مقادیر آزمایشگاهی است در شکل ۱ کانال آزمایشگاهی همراه با سرریز نصب شده در آن نشان داده شده است. در شکل ۲ نمای شماتیک از مدل آزمایشگاهی همراه با پارامترهای گودال فرسایشی نشان داده شده است. این مدل در آزمایشگاه موسسه تحقیقات آب ساخته شده است. طول، عرض و ارتفاع فلوم آزمایشگاهی به ترتیب ۱۹ متر، ۱۰۰ سانتی‌متر و ۷۰ سانتی‌متر است. طول، عرض و ارتفاع سرریز سیفونی ساخته شده از پلاکسی گلاس به ترتیب ۷۷، ۹۵ و ۳۰ سانتی‌متر است که در قسمت میانی فلوم نصب گردید. جت آب تحت سه زاویه پرتابه‌ی ۳۰، ۴۵ و ۶۰ درجه در انتهای سرریز نصب شده بود. منحنی دانه‌بندی رسوبات مورد استفاده در این تحقیق در شکل ۳ نشان داده شده است. وزن مخصوص نسبی ذرات رسوبی ۲/۶۴ و d_{50} منحنی‌های دانه‌بندی ۱/۴، ۳/۷ و ۸/۱ میلی‌متر و ضریب یکنواختی آن‌ها به ترتیب ۱/۵، ۱/۳۸ و ۱/۵۴ است. در مجموع ۱۲۵ آزمایش روی مدل انجام شده. محدوده‌ی متغیرهای آزمایشگاهی نیز در جدول ۱ ارائه شده است. با توجه به تقسیم‌بندی پارامترهای مؤثر در ایجاد گودال آبشستگی در چهار گروه: (۱) متغیرهای گروه جریان شامل دبی جریان (Q)، جرم مخصوص سیال (ρ)، لزجت سیال (μ)، شتاب ثقل (g)، ارتفاع ریزش جت (H) و عمق پایاب (h_t)، لزجت سینماتیکی (ν)؛ (۲) متغیرهای گروه ذرات رسوبی شامل قطر مشخصه‌ی ذرات رسوبی (d_{50})، وزن مخصوص نسبی ذرات رسوبی (G_s)، ضریب یکنواختی منحنی دانه‌بندی رسوب (C_u)، زاویه ایستایی ذرات رسوبی (ϕ)، فاکتور شکل ($S.F.$)؛ (۳) متغیرهای گروه هندسه‌ی مجرا شامل زاویه‌ی پرتابه باکت (α)، قطر مجرا (D)، شیب مجرا (S)، ضریب زبری مانینگ (n)؛ (۴) زمان. هر یک از مشخصات گودال فرسایشی، Φ را به صورت توابعی از متغیرهای فوق‌الذکر در قالب معادله‌ی زیر می‌توان نوشت:



شکل ۱- نمایی از کانال، گودال فرسایشی و سرریز در آزمایشگاه




(الف)



(ب)

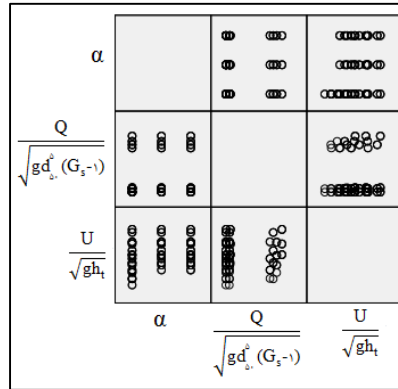
شکل ۲- (الف) نمای شماتیک مدل آزمایشگاهی (ب) نمای شماتیک از گودال فرسایشی



شکل ۳- منحنی دانه‌بندی مواد رسوبی

جدول ۱- محدوده‌ی متغیرهای آزمایشگاهی

α (Degree)	h_i (cm)	d_{50} (mm)	Q (l/s)
۳۰-۶۰	۱۵-۳۵	۱/۴-۸/۱	۳۹/۲-۴۹/۷۶



شکل ۴- استقلال خطی متغیرهای سه گانه بی بعد

از توابع رایج و پرکاربرد در مسائل هستند. تابع کرنل چندجمله‌ای در مسائل پیچیده می‌تواند بسیار مفیدتر باشد. توابع گوسین (RBF) و سیگموئید (ERBF) معروف‌ترین و پرکاربردترین توابع کرنل در مسائل پشتیبان بردار ماشین هستند و در مسائلی مورد استفاده قرار می‌گیرند که هیچ‌گونه اطلاعاتی از نوع داده‌ها و طبیعت آن‌ها در دست نباشد. مشخصه‌های الگوریتم SVM، یعنی مقادیر ϵ و C بهینه‌سازی می‌شوند و مقدار γ برای تابع کرنل RBF باید بهینه گردد. برای دستیابی به نتایج پیش‌بینی بهتر و دقیق‌تر مدل‌ها، فرآیند آموزش مدل چند بار مورد آزمون و خطا قرار خواهد گرفت تا در نهایت الگوی عددی برتر از بین ترکیب‌ها مختلف انتخاب شود.

معیارهای ارزیابی عملکرد

هدف از کاربرد این معیارها تعیین میزان دقت و نیز خطای هر یک از مدل‌های به رفته در این پژوهش است. در این پژوهش از شاخص‌های (۱) مجذور میانگین مربع خطا (RMSE)، (۲) میانگین مطلق خطا (MAE)، (۳) ضریب همبستگی (R) و (۴) ضریب ناش-ساتکلیف (N.S) با معادلات زیر استفاده شده است:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_0 - x_p)^2}{N}} \quad (10)$$

$$MAE = \frac{\sum_{i=1}^N |x_0 - x_p|}{N} \quad (11)$$

$$R = \frac{\sum_{i=1}^N (x_0^i - \bar{x}_0)(x_p^i - \bar{x}_p)}{\sqrt{[\sum_{i=1}^N (x_0^i - \bar{x}_0)^2][\sum_{i=1}^N (x_p^i - \bar{x}_p)^2]}} \quad (12)$$

$$N.S = 1 - \frac{\sum_{i=1}^N (x_0 - x_p)^2}{\sum_{i=1}^N (x_0 - \bar{x}_0)^2} \quad (13)$$

در این معادلات x_0 و x_p به ترتیب داده‌های مشاهداتی و برآورد شده، \bar{x}_0 و \bar{x}_p به ترتیب مقادیر متوسط داده‌های مشاهداتی و پیش-بینی شده هستند. در خصوص ضریب N.S لازم به ذکر است مقدار

در این الگوریتم، هدف پیدا کردن تابع $f(x)$ است که با استفاده از آموزش به کمک یک سری داده تحت عنوان داده‌های آموزشی، به بهینه کردن تابع خطا پرداخته می‌شود. بهینه‌سازی با استفاده از به حداقل رساندن معادله‌ی (۷) تحت شرایط ذکر شده در معادله‌ی (۸) انجام می‌شود:

$$\frac{1}{2} w^T \cdot w + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^* \quad (7)$$

$$\begin{cases} w^T \cdot \Phi(x_i) + b - y_i \leq \epsilon + \xi_i^* \\ y_i - w^T \cdot \Phi(x_i) - b \leq \epsilon + \xi_i \\ x_i, \xi_i \geq 0 \end{cases} \quad (8)$$

در این معادلات، C مقدار جریمه را هنگامی که خطایی رخ می‌دهد نشان می‌دهد. همچنین N نشان دهنده‌ی تعداد نمونه‌ها، و ξ_i و ξ_i^* ضرایب کمبود هستند. اگر داده‌ای در خارج از محدوده‌ی ϵ قرار گیرد خطایی در مقادیر ξ_i و ξ_i^* شکل می‌گیرد. الگوریتم SVM با به حداقل رساندن سه عبارت ذکر شده در معادله‌ی (۷) به صورت هم‌زمان، تابع موردنظر را برازش می‌دهد. در الگوریتم SVM، تابع هسته به صورت معادله‌ی (۹) در نظر گرفته می‌شود:

$$\Phi(x_i)^T = K(x_i, x) \quad (9)$$

توابع هسته‌ی مختلفی در این الگوریتم قابل استفاده هستند که در جدول ۲ ارائه شده‌اند.

جدول ۲- انواع توابع کرنل

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

تابع کرنل خطی حالت خاصی از تابع کرنل چندجمله‌ای است که

به کمک شاخص‌های تدقیق آماری، کارکرد هر یک از مدل‌های داده‌منا در جدول ۵ ارزیابی شد. همان‌طور که از مقادیر این جدول برمی‌آید الگوریتم SVM و مدل شبکه‌ی عصبی که بر مبنای آموزش و تست استوار هستند نسبت به دو مدل رگرسیونی خطی و غیرخطی در شبیه‌سازی مشخصه‌های گودال آبخستگی از دقت بیشتری برخوردار هستند. از بین الگوریتم SVM و مدل شبکه‌ی عصبی، الگوریتم پشتیبان بردار ماشین دارای شاخص‌های عملکرد بهتری نسبت به هر دو مدل شبکه‌ی عصبی است. از بین تمام مشخصه‌های هندسی گودال آبخستگی بیشترین و مطلوب‌ترین ضرایب عملکرد مربوط به پارامتر $\frac{L_s}{h_t}$ و در خصوص $\frac{L_f}{h_t}$ پایین‌ترین و کمترین ضرایب عملکرد مطلوب به دست آمده است.

شکل‌های ۵ و ۶ مقادیر شاخص‌های تدقیق را برای این دو پارامتر نشان می‌دهند. همان‌طور که مشاهده می‌شود مقدار شاخص‌های متوسط خطا در الگوریتم SVM نسبت به دیگر مدل‌ها کمتر است در عین حال سطح عملکرد بهتر و مطلوب‌تری بر مبنای شاخص N.S دارد. در شکل‌های (۷-الف) و (۸-الف) به ترتیب پراکندگی مقادیر مشاهداتی و شبیه‌سازی شده‌ی پارامترهای $\frac{L_s}{h_t}$ و $\frac{L_f}{h_t}$ در فرآیند آموزش و تست الگوریتم SVM نشان داده شده‌اند. رابطه‌ی خطی همراه با مربع ضریب همبستگی بین داده‌های مشاهداتی و شبیه‌سازی شده در فرآیندهای آموزش و تست الگوریتم SVM در شکل‌های (۷-ب) و (۸-ب) ارائه شده‌اند. در شکل (۸-ب) ضریب تبیین برای پارامتر $\frac{L_s}{h_t}$ در دوره‌ی آموزش و تست به ترتیب ۰/۹۸۸۵ و ۰/۹۹۰۹ و مقدار این ضریب برای پارامتر $\frac{L_f}{h_t}$ در دوره‌های آموزش و تست به ترتیب ۰/۷۱۳۶ و ۰/۷۳۶۷ حاصل شده‌اند. همان‌طور که مشخص است رابطه‌ی خطی با ضریب همبستگی قابل قبولی بین مقادیر مشاهداتی و شبیه‌سازی شده هم در دوره‌ی آموزش و هم در دوره‌ی تست در الگوریتم SVM وجود دارد. پراکندگی داده‌های شبیه‌سازی شده و مشاهده شده حول خط با شیب ۱:۱ در پارامتر $\frac{L_s}{h_t}$ نسبت به پارامتر $\frac{L_f}{h_t}$ بیشتر است که حاکی از عملکرد مطلوب‌تر الگوریتم SVM در برآورد و شبیه‌سازی طول گودال آبخستگی دارد.

توزیع نرمال استاندارد مدل‌های این تحقیق برای پارامترهای $\frac{L_s}{h_t}$ و $\frac{L_f}{h_t}$ به ترتیب در شکل‌های (۹-الف) و (۹-ب) نشان داده شده‌اند. مقادیر حداکثر برای DDR برای پارامترهای $\frac{L_s}{h_t}$ و $\frac{L_f}{h_t}$ به ترتیب ۷/۸۵۵ و ۱/۴۰۵ هستند. با توجه به این دو مقدار، مشخص است الگوریتم SVM از دیدگاه شاخص DDR نسبت به مدل‌های دیگر عملکرد بهتری داشته است.

آن بین $-\infty$ تا یک متغیر است. بهترین مقدار برای این ضریب یک است. مقدار ضریب N.S بیشتر از ۰/۷۵ نشان‌دهنده‌ی نتایج خوب، مقادیر ۰/۳۶ تا ۰/۷۵ بیانگر نتایج قابل قبول و مقادیر کمتر از ۰/۳۶ نشان از نتایج غیرقابل قبول دارد. لازم به ذکر است شاخص‌های آماری تدقیق به کار رفته فقط بیان‌کننده‌ی متوسط خطا هستند و از روی آن‌ها نمی‌توان قضاوت صحیحی روی عملکرد مدل‌ها و توزیع خطا در مدل‌ها انجام داد. برای دستیابی به این هدف، از آماره‌ی نسبت تفاوت توسعه داده شده^۱ (DDR) به قرار زیر استفاده می‌شود:

$$(14) \quad DDR = \frac{\text{مقدار پیش بینی شده}}{\text{مقدار مشاهده شده}} - 1$$

طبق این معادله، اگر $DDR=0$ باشد آنگاه مقادیر پیش‌بینی شده و مشاهده شده معادل هستند، اگر $DDR>0$ باشد مقدار پیش‌بینی شده از مقدار مشاهده شده بیشتر خواهد بود و در حالتی که $DDR<0$ باشد مقدار پیش‌بینی شده کمتر از مقدار مشاهده شده است. برای قضاوت بهتر و دید بهتر می‌توان تابع گوسی مقادیر DDR را محاسبه نمود و به صورت توزیع نرمال استاندارد رسم نمود. هر چه تمایل منحنی توزیع به سمت محور مرکزی بیشتر باشد و مقادیر بزرگ‌تری رو محور مرکزی داشته باشد نشان از دقت بالای آن مدل دارد. برای رسم منحنی باید مقادیر DDR استاندارد شوند و سپس با استفاده از تابع گوسی مقادیر نرمال شده DDR محاسبه شوند (Noori et al., 2011).

نتایج و بحث

همان‌طور که گفته شد هدف از این تحقیق شبیه‌سازی ابعاد هندسی گودال آبخستگی در پایین‌دست سرریز سیفونی با استفاده از روش‌های مختلف داده‌کاوی و مقایسه‌ی آن‌ها با مقادیر آزمایشگاهی و تعیین مدل بهینه است. در جدول ۳ معادلات مربوط به پیش‌بینی مشخصات گودال آبخستگی به کمک معادلات رگرسیونی کلاسیک خطی و غیرخطی ارائه شده است. در این جدول $\Pi_1 = \alpha$ ، $\Pi_2 = \frac{U}{\sqrt{gh_t}}$ و $\Pi_3 = \frac{Q}{\sqrt{gd_s^{0.5}(G_s-1)}}$ جدول، بیشترین ضریب همبستگی را در بین انواع معادلات داشته‌اند. در جدول ۴ بهینه‌ترین تابع کرنل همراه با ضرایب توابع برای الگوریتم SVM به منظور ارزیابی مشخصات گودال آبخستگی نشان داده شده است. برای مقایسه‌ی کارایی الگوریتم داده‌کاوی SVM، شبیه‌سازی مشخصات گودال آبخستگی با شبکه‌ی عصبی نیز انجام شد. در جدول ۵ مقایسه‌ی نهایی مدل‌ها همراه با شاخص‌های تدقیق آماری انجام شده است.

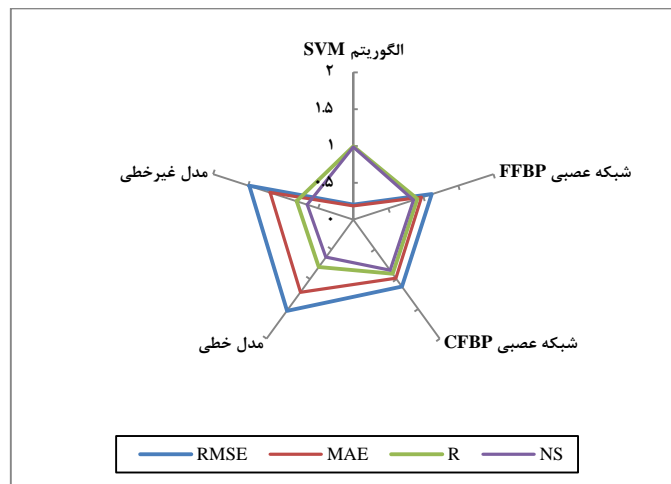
جدول ۳- نتایج ارزیابی مدل‌های رگرسیونی خطی و غیرخطی

ردیف	مشخصه‌ی گودال آبستتگی	معادلات رگرسیونی	
		خطی	غیرخطی
۱	$\frac{L_1}{h_t}$	$-.0252 + 1.389\Pi_1 - 4.37 \times 10^{-7}\Pi_2 - .0481\Pi_3$	$.0727(\Pi_1^{.373}) (\Pi_2^{-.18}) (\Pi_3^{-.161})$
۲	$\frac{L_2}{h_t}$	$-1/446 + 3/0.1\Pi_1 - 1/582 \times 10^{-7}\Pi_2 - .05\Pi_3$	$1/993(\Pi_1^{.769}) (\Pi_2^{-.24}) (\Pi_3^{-.139})$
۳	$\frac{L_3}{h_t}$	$-2/635 + 4/154\Pi_1 + 9/258 \times 10^{-7}\Pi_2 + .0692\Pi_3$	$1/994(\Pi_1^{.289}) (\Pi_2^{.107}) (\Pi_3^{.570})$
۴	$\frac{L_4}{h_t}$	$-6/194 + 1/339\Pi_1 + 1/0.28 \times 10^{-6}\Pi_2 + 8/383\Pi_3$	$2/976(\Pi_1^{.265}) (\Pi_2^{.114}) (\Pi_3^{.290})$
۵	$\frac{L_5}{h_t}$	$-11/0.79 + 0/302\Pi_1 + 1/779 \times 10^{-6}\Pi_2 + 16/526\Pi_3$	$4/801(\Pi_1^{.154}) (\Pi_2^{.116}) (\Pi_3^{.294})$
۶	$\frac{L_6}{h_t}$	$-14/690 - .096\Pi_1 + 5/651 \times 10^{-6}\Pi_2 + 22/717\Pi_3$	$6/163(\Pi_1^{.102}) (\Pi_2^{.126}) (\Pi_3^{.270})$
۷	$\frac{L_7}{h_t}$	$-21/506 - 3/937\Pi_1 - 2/251 \times 10^{-6}\Pi_2 + 32/374\Pi_3$	$5/71(\Pi_1^{.101}) (\Pi_2^{.117}) (\Pi_3^{.413})$
۸	$\frac{D_s}{h_t}$	$-1/220 + 0/117\Pi_1 - 1/193 \times 10^{-7}\Pi_2 + 1/547\Pi_3$	$.0380(\Pi_1^{.378}) (\Pi_2^{.108}) (\Pi_3^{.443})$
۹	$\frac{h_u}{h_t}$	$-.0243 + 0/328\Pi_1 + 1/495 \times 10^{-7}\Pi_2 + 0/079\Pi_3$	$.086(\Pi_1^{.291}) (\Pi_2^{.165}) (\Pi_3^{.176})$
۱۰	$\frac{h_d}{h_t}$	$-.0138 - 0/119\Pi_1 - 1/298 \times 10^{-8}\Pi_2 + 0/662\Pi_3$	$.039(\Pi_1^{.107}) (\Pi_2^{.107}) (\Pi_3^{.1513})$
۱۱	$\frac{L_s}{h_t}$	$-8/444 - 2/852\Pi_1 + 8/532 \times 10^{-7}\Pi_2 + 15/834\Pi_3$	$3/117(\Pi_1^{.153}) (\Pi_2^{.114}) (\Pi_3^{.244})$

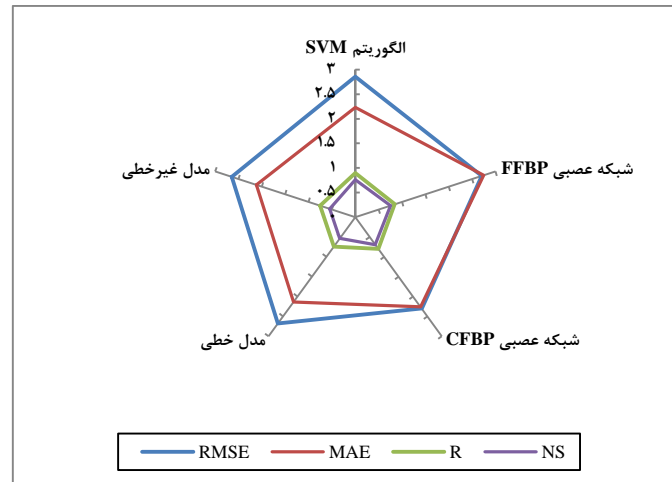
جدول ۴- مشخصات مدل بهینه‌ی SVM برای هر مشخصه‌ی گودال

ردیف	مشخصه گودال آبستتگی	مشخصات تابع SVM				نوع تابع کرنل	مشخصه گودال آبستتگی	
		درصد داده‌های مورد استفاده		C	ε			
توضیحات	تست	آموزش	γ			ε		
۱	$\frac{L_1}{h_t}$	۲۵	۷۵	۲/۱۵	۰/۱	۲	RBF	
۲	$\frac{L_2}{h_t}$	۲۵	۷۵	۰/۰۱	۰/۱	۱۰	RBF	
۳	$\frac{L_3}{h_t}$	۲۵	۷۵	۰/۹۵	۰/۱	۸	RBF	
۴	$\frac{L_4}{h_t}$	توان چندجمله‌ای: ۲ ضریب: ۰/۰	۱۵	۸۵	۰/۰۱۹	۰/۱	۱۰	چندجمله‌ای
۵	$\frac{L_5}{h_t}$	توان چندجمله‌ای: ۲ ضریب: ۰/۰	۱۵	۸۵	۰/۲۸۵	۰/۱	۰/۶	چندجمله‌ای
۶	$\frac{L_6}{h_t}$	-	۱۵	۸۵	۰/۵۵۳	۰/۱۹۲	۱۰	RBF
۷	$\frac{L_7}{h_t}$	-	۱۰	۹۰	۰/۷۳	۰/۲	۱۰	RBF
۸	$\frac{D_s}{h_t}$	-	۱۲	۸۸	۵/۵۱	۰/۵	۱۰	RBF
۹	$\frac{h_u}{h_t}$	ضریب: ۲/۵	۲۵	۷۵	۰/۰۰۱	۰/۳	۸	سیگموئید
۱۰	$\frac{h_d}{h_t}$	-	۲۷	۷۳	۰/۵	۰/۳	۳۰	RBF

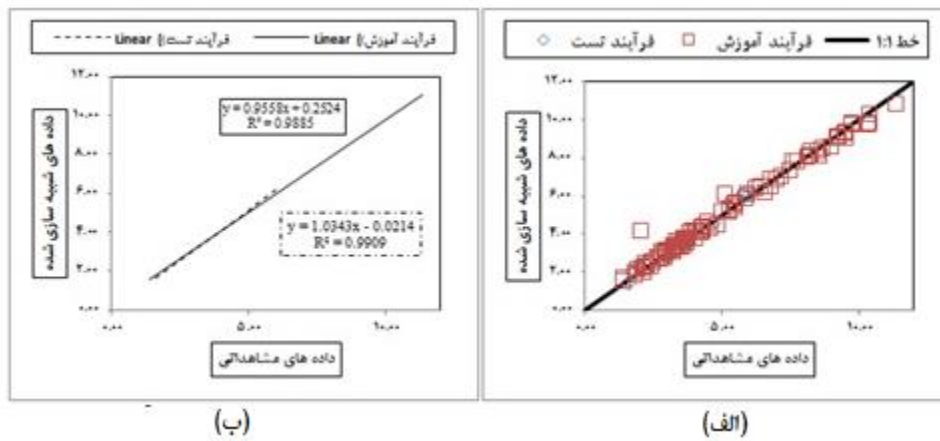
جدول ۵- مقایسه معیارهای ارزیابی مدل‌های عددی در مدل‌های رگرسیونی (خطی، غیرخطی)، شبکه‌ی عصبی و SVM											
پارامتر	شاخص	الگوریتم SVM				شبکه‌ی عصبی				مدل رگرسیونی	
		آموزش	تست	FFBP	CFBP	خطی	غیرخطی	خطی	غیرخطی	خطی	غیرخطی
L _۱ h _t	RMSE	-۰/۴۴۲	-۰/۵۹۴	-۰/۸۷۲	-۰/۱۱۳۳	-۰/۲۶۵۰	-۰/۲۶۷۹	RMSE	۱/۸۱۷۶	-۰/۶۴۳۹	۱/۸۱۷۶
	MAE	-۰/۲۲۹	-۰/۰۱۶	-۰/۱۳۴۹	-۰/۰۳۸۹۳	-۰/۱۹۰۲	-۰/۱۹۰۳	MAE	۱/۰۰	-۰/۳۸۴	۱/۰۰
	R	-۰/۹۴۰۷	-۰/۹۸۷۷	-۰/۹۳۲۳	-۰/۹۲۱۳	-۰/۷۴۷۷	-۰/۷۴۳۸	R	-۰/۹۵۲۶	-۰/۹۲۳۴	-۰/۹۲۳۴
	N.S	-۰/۸۹۸۸	-۰/۹۶۶۹	-۰/۸۸۶۶	-۰/۸۷۰۳	-۰/۵۵۹۰	-۰/۵۴۹۳	N.S	-۰/۷۶۳۶	-۰/۹۸۶۴	-۰/۹۸۶۴
L _۲ h _t	RMSE	-۰/۱۲۱۶	-۰/۱۵۳۷	-۰/۱۵۴۳	-۰/۱۶۸۹	-۰/۳۲۳۴	-۰/۳۷۵۶	RMSE	-۰/۰۶۸۲	-۰/۰۷۲۵	-۰/۰۸۷۴
	MAE	-۰/۰۷۸۹	-۰/۰۲۷	-۰/۰۸۱۵	-۰/۰۹۶۳	-۰/۲۲۴۸	-۰/۳۰۷۴	MAE	-۰/۰۱۶۲	-۰/۰۳۵	-۰/۰۱۳۷۰
	R	-۰/۹۸۵۷	-۰/۹۹۷۷	-۰/۹۶۵۴	-۰/۹۴۸۹	-۰/۸۹۸	-۰/۸۵۹	R	-۰/۹۵۷۵	-۰/۹۳۵۳	-۰/۹۳۱۸
	N.S	-۰/۹۵۵۲	-۰/۹۳۲۷	-۰/۹۳۵۸	-۰/۹۱۱۳	-۰/۸۰۶۱	-۰/۷۲۸۵	N.S	-۰/۹۵۳۴	-۰/۸۷۴۴	-۰/۸۸۵۹
L _۲ h _t	RMSE	-۰/۳۳۵	-۰/۳۴۷۵	-۰/۳۰۰۳	-۰/۳۱۸۹	-۰/۵۰۲۶	-۰/۵۹۹۲	RMSE	-۰/۰۱۸۹	-۰/۰۳۵۴	-۰/۰۴۲
	MAE	-۰/۱۵۲۵	-۰/۲۱۱۵	-۰/۲۲۹	-۰/۲۴۸	-۰/۳۹۱۹	-۰/۵۰۹۸	MAE	-۰/۰۸۶	-۰/۰۲۱۳	-۰/۰۱۴۶
	R	-۰/۹۷۳۸	-۰/۹۴۹۰	-۰/۹۲۰۶	-۰/۹۱۵۴	-۰/۸۸۳	-۰/۸۲۸	R	-۰/۹۷۹۴	-۰/۹۳۵۸	-۰/۹۳۱۸
	N.S	-۰/۹۴۷۴	-۰/۸۹۶۰	-۰/۸۶۹	-۰/۸۶۱۵	-۰/۷۷۹۳	-۰/۶۸۶۳	N.S	-۰/۹۵۹۵	-۰/۸۷۳۷	-۰/۸۷۲۳
L _۲ h _t	RMSE	-۰/۴۴۵۶	-۰/۵۸۱	-۰/۵۱۰۵	-۰/۵۹۸۱	-۰/۵۵۹۸	۲/۴۱	RMSE	-۰/۰۳۷۸	-۰/۰۶۴۹	-۰/۰۵۴۸
	MAE	۵/۹۲۴	-۰/۰۰۳	-۰/۴۴۲۵	-۰/۵۳۱۳	۲/۱۹۸	۲/۰۳۵	MAE	-۰/۰۴۶	۲/۵۲۶۵	-۰/۰۴۸۱
	R	-۰/۹۹۲۴	-۰/۹۳۵۶	-۰/۹۴۵۶	-۰/۹۳۷۶	-۰/۷۰۴	-۰/۷۲۲	R	-۰/۹۷۸۲	-۰/۹۶۴۵	-۰/۹۶۴۵
	N.S	-۰/۹۸۷۵	-۰/۷۵۷۰	-۰/۹۰۶۴	-۰/۸۹۴۵	-۲/۲۰۸	-۱/۸۴۴	N.S	-۰/۹۵۵۴	-۰/۹۳۳۴	-۰/۹۳۳۴
L _۵ h _t	RMSE	-۰/۶۹۹۵	-۰/۵۶۴۳	-۰/۷۲۳۵	-۰/۶۷۳۳	۱/۴۳۱۴	۱/۳۹۱	RMSE	-۰/۱۱۳۰	-۰/۲۰۵۶	۱/۱۲۳
	MAE	۵۷/۳۵۸	-۰/۵۲۶۴	-۰/۶۵۸۵	-۰/۶۰۸۶	۱/۱۵۸	۱/۱۰۹	MAE	-۰/۹۸۷	-۰/۱۸۶۸	-۰/۹۷۶
	R	-۰/۹۷۶۸	-۰/۹۷۳۹	-۰/۹۴۵۶	-۰/۹۵۷۸	-۰/۸۳	-۰/۸۴۱	R	-۰/۹۳۶۱	-۰/۹۹۵۴	-۰/۹۱۳۴
	N.S	-۰/۹۴۰۰	-۰/۹۲۷۰	-۰/۹۰۶۴	-۰/۹۲۴۵	-۰/۶۸۹۴	-۰/۷۰۶۹	N.S	-۰/۸۷۳۳	-۰/۹۸۵۱	-۰/۸۵۸۵
L _۲ h _t	RMSE	۲/۱۰۸	۲/۸۶	۲/۷۰۹	۲/۳۰۴	۲/۶۷۸	۲/۶۴۸	RMSE	-	-	-
	MAE	۱/۹۱۲	۲/۳۳	۲/۷۵۳	۲/۲۶	۲/۱۴	۲/۱۲	MAE	-	-	-
	R	-۰/۸۵۲۷	-۰/۸۹۳۴	-۰/۸۴۵۳	-۰/۸۰۲۱	-۰/۷۴۶	-۰/۷۵۳	R	-	-	-
	N.S	-۰/۷۰۹۴	-۰/۷۵۸۷	-۰/۷۵۷۰	-۰/۶۹۳۱	-۰/۵۳۶۸	-۰/۵۴۷۱	N.S	-	-	-



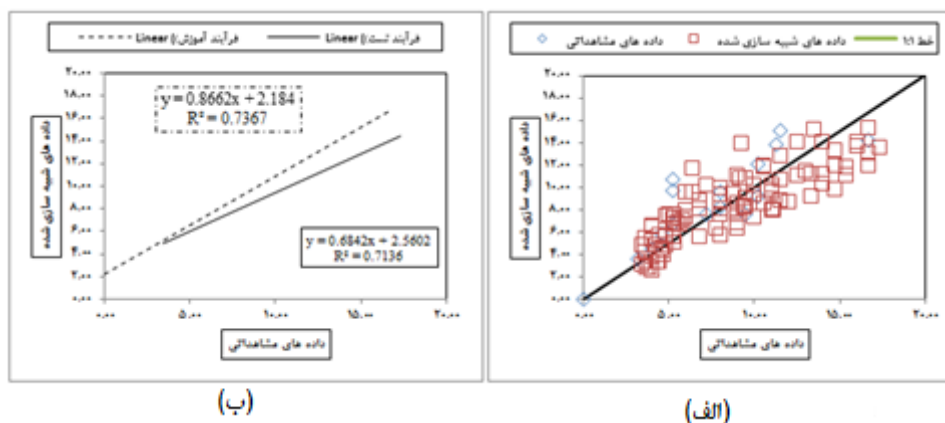
شکل ۵- نمودار راداری شاخص‌های آماری تدقیق مدل‌های تحقیق در مورد $\frac{L_S}{h_t}$




شکل ۶- نمودار راداری شاخص‌های آماری تدقیق مدل‌های تحقیق در مورد $\frac{L_p}{h_t}$



شکل ۷- (الف) پراکندگی داده‌های مشاهداتی و شبیه‌سازی شده در فرآیندهای آموزش و تست الگوریتم SVM برای پارامتر $\frac{L_s}{h_t}$ (ب) خطوط برازش همراه با ضریب تبیین



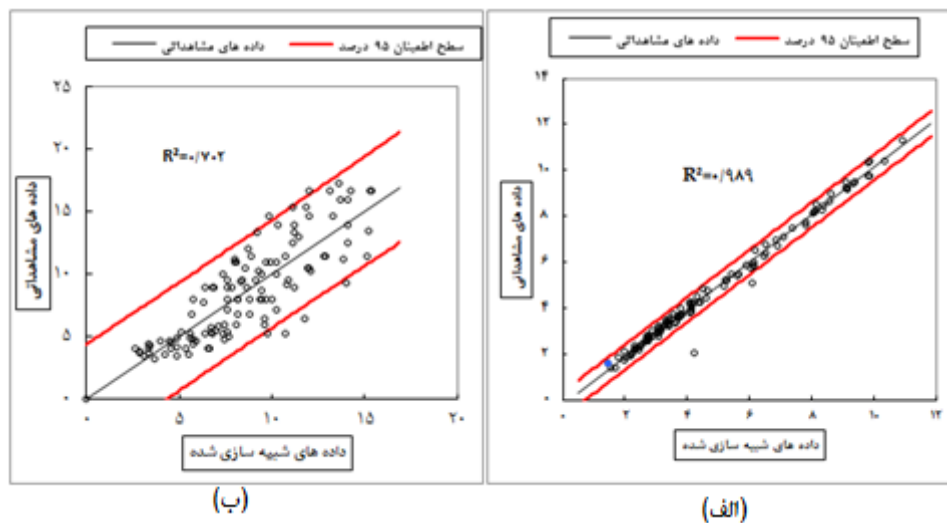
شکل ۸- (الف) پراکندگی داده‌های مشاهداتی و شبیه‌سازی شده در فرآیندهای آموزش و تست الگوریتم SVM برای پارامتر $\frac{L_p}{h_t}$ (ب) خطوط برازش همراه با ضریب تبیین



شکل ۹- نمودار توزیع نرمال استاندارد شده مقادیر DDR برای مدل‌های تحقیق حاضر در خصوص پارامتر (الف) $\frac{L_s}{h_t}$ (ب) $\frac{L_1}{h_t}$

مشاهده شده وجود دارد. ضریب تبیین این دو نمودار نیز به ترتیب ۰/۹۸۹ و ۰/۷۰۲ می‌باشد. مقادیر ضریب تبیین برای این دو پارامتر نشان از رابطه‌ی خطی با دقت بسیار مطلوب بین دو مقدار مشاهداتی و اندازه‌گیری شده است.

در شکل ۱۰ منحنی تغییرات مقادیر مشاهداتی و شبیه‌سازی شده همراه با منحنی پوش در سطح اطمینان ۹۵ درصد برای پارامترهای $\frac{L_s}{h_t}$ (شکل ۱۰-الف) و $\frac{L_1}{h_t}$ (شکل ۱۰-ب) رسم شده‌اند. همانطور که مشاهده می‌شود انطباق بسیار مناسبی بین داده‌های شبیه‌سازی شده و



شکل ۱۰- برازش داده‌های پیش‌بینی شده و مشاهده شده همراه با منحنی پوش با اطمینان ۹۵ درصد برای پارامتر (الف) $\frac{L_s}{h_t}$ (ب) $\frac{L_1}{h_t}$

(۱۹۴۴) به قرار زیر هستند:

$$T = 0.16q^{0.15} H^{0.25} \left(\frac{H_t}{d_0}\right)^{-0.233} \quad (17)$$

$$T = 1/44q^{0.16} H^{0.15} d_0^{-0.4} \quad (18)$$

که در این معادلات H_t بیانگر عمق پایاب است. نتایج مقایسه در


علاوه بر مدل‌های مقایسه شده در این پژوهش، معادلات تجربی ارائه شده توسط محققان مختلف برای پیش‌بینی عمق گودال آبخستگی (۷۰ داده آزمایشگاهی) نیز مورد ارزیابی قرار گرفت. بدین منظور از سه معادله‌ی شوکلیچ (۱۹۲۸)، ورونسی (۱۹۳۷) و آگنبرگر (۱۹۴۴) استفاده شده است. معادلات ورونسی (۱۹۳۷) و آگنبرگر

استاندارد برای مدل‌های به کار رفته در جدول ۶ ارائه شده است. مقایسه‌ی بین نمودارها نشان می‌دهد الگوریتم SVM کارآیی و عملکرد بهتری نسبت به دیگر مدل‌های تجربی دارد. مقدار حداکثر DDR برای الگوریتم SVM، شوکلیچ، ورونسی و اگنبرگر به ترتیب ۱/۵۲۱، ۰/۳۳۳۹، ۰/۳۹۰۸ و ۰/۲۸۰۳ به دست آمده است. این مقادیر نیز حاکی از برتری مطلق الگوریتم SVM نسبت به مدل‌های تجربی است.

جدول ۶ ارائه شده است. طبق نتایج این جدول، مقدار ضریب همبستگی R در الگوریتم SVM نسبت به روش‌های تجربی بسیار مناسب‌تر است به طوری که در برخی موارد تا چهار برابر مدل‌های تجربی رسیده است. مقدار خطای الگوریتم SVM نیز از سه معادله‌ی تجربی مذکور کمتر است و ضریب N.S الگوریتم پشتیبان بردار ماشین برتری بسیار زیادی نسبت به مدل‌های تجربی دارد که حاکی از عملکرد مناسب الگوریتم SVM می‌باشد. در شکل ۱۱ توزیع نرمال

جدول ۶- مقایسه‌ی کارکرد الگوریتم SVM با مدل‌های تجربی

مدل	RMSE	MAE	R	N.S
SVM	۰/۰۷۲۵	۰/۰۶۳۵	۰/۹۳۵۳	۰/۸۷۴۴
شوکلیچ	۵/۶۳۳	۱۲/۳۴	۰/۲۴۶۵	۰/۲۸۷
ورونسی	۳/۲۹۸	۳/۲۴۳	۰/۴۳۸۵	۰/۴۲
اگنبرگر	۵/۰۶۷۱	۹/۶۷۱	۰/۳۷۸۴	۰/۳۰۱



شکل ۱۱- نمودار توزیع نرمال استاندارد شده مقادیر DDR برای الگوریتم SVM و مدل‌های تجربی در خصوص پارامتر $\frac{D_s}{h_t}$

از این الگوریتم برای شبیه‌سازی و پیش‌بینی پدیده‌هایی که تابعی از چندین متغیر مستقل هستند و یافتن ارتباط بین متغیرهای مستقل پیچیده است پیشنهاد می‌شود.

منابع

- رضازاده، ر.، بارانی، غ.ع. و ناصری، ا. ۱۳۹۸. کاربرد شبکه عصبی مصنوعی در تخمین عمق آبشستگی اطراف پایه پل در بستر با رسوبات چسبنده. مجله هیدرولیک، ۱۴: ۱۴۱-۱۴۹.
- روشنگر، ک. و روح‌پرور، ب. ۱۳۹۱. عملکرد سیستم‌های فرامدل در تخمین عمق آبشستگی پایه‌های پل در خاک‌های غیرچسبنده. نشریه مهندسی عمران و محیط‌زیست، ۳۰: ۴۲-۲۶.
- روشنگر، ک. و روح‌پرور، ب. ۱۳۹۲. ارزیابی عملکرد سیستم‌های

نتایج

در این پژوهش، ارزیابی عملکرد الگوریتم SVM در شبیه‌سازی و پیش‌بینی ابعاد گودال آبشستگی، که پدیده‌ای پویا و غیرخطی است، در پایین‌دست سرریز سیفونی دارای پرتابه جامی شکل مورد بررسی و مطالعه قرار گرفته است. علاوه بر این الگوریتم، از مدل رگرسیون کلاسیک (خطی و غیرخطی)، شبکه عصبی (FFBP و CFBP) و نیز معادلات تجربی به منظور مطالعه‌ی تطبیقی در مقام مقایسه با SVM استفاده شد. مقایسه‌ی بین مدل‌های به کار رفته در این پژوهش بر مبنای پنج شاخص R، RMSE، MAE، N.S. و DDR انجام گرفت. نتایج این پژوهش نشان می‌دهد که الگوریتم SVM دارای قابلیت بسیار بالایی در شبیه‌سازی و پیش‌بینی ابعاد گودال آبشستگی است. همچنین میزان دقت عملکرد الگوریتم SVM نسبت به دیگر مدل‌ها و معادلات ارائه شده در پژوهش، بیشتر است. به همین دلیل، استفاده

- 484.
- Batani, S.M., Borgheib, S.M., and Jeng, D.S. 2007. Neural Network and Neuro-Fuzzy Assessments for Scour Depth around Bridge Piers. *Engineering Applications of Artificial Intelligence*. 20.3: 401-414.
- Batani, S.M., Jeng, D.S. and Melville, B.W. 2007. Bayesian Neural Networks for Prediction of Equilibrium and Time-Dependent Scour Depth Around Bridge Piers, *Advances in Engineering Software*, 38.2: 102-111.
- Dibike, Y.B., Velickov, S., Solomatine, D. and Abbott, M.B. 2001. Model Induction with Support Vector Machines: Introduction and Applications. *Journal of Computing in Civil Engineering*. 15.3: 208-216.
- Firat, M., and Gungor, M. 2009. Generalized Regression Neural Networks and Feed Forward Neural Networks for Prediction of Scour Depth Around Bridge Piers. *Advances in Engineering Software*. 40.8: 731-737.
- Goyal, M.K. 2011. Estimation of scour downstream of a ski jump bucket using support vector and M5 model tree. *Journal of Water Resources Management*. 25: 2177-2195.
- Hager, W.H. and Minor, H.E. 2004. Plunge pool scour in prototype and laboratory, proceeding of 2004 International Conference on hydraulics of dam and river structures, April 29-28, Tehran, Iran.
- Hoang, N.D., Liao, K.W. and Tran, X.L. 2018. Estimation of scour depth at bridges with complex pier foundations using support vector regression integrated with feature selection. *Journal of Civil Structural Health Monitoring*, 8.3: 431-442
- Noori, R., Karbassi, A.R., Moghaddamnia, A., Han, D., Zokaei-Ashtiani, M. H., Forokhnial, A., and Ghafari-Goushesh, M. 2011. 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*, 401: 177- 189.
- Pai, P. and Lin, C. 2005. A hybrid ARIMA and support vector machines model in stock price forecasting. *Omega*. 33:197-505.
- Pandey, M., Zakwan, M., Sharma, P.K., and Ahmad, Z. 2018. Multiple linear regression and genetic algorithm approaches to predict temporal scour depth near circular pier in non-cohesive sediment. *ISH Journal of Hydraulic Engineering*: 1-8.
- Rajaratnam, N. and Mazurek, K. 2003. Erosion of sand by circular impinging water jets with small tail water, *Journal of Hydraulic Engineering, ASCE*. 129.3: 225-229.
- Veronese, A. 1937. Erosion of a bed downstream from an outlet, Colorado A & M College, Fort Collins, هوش مصنوعی برای شبیه‌سازی آبستگي پایه‌های پل در خاک‌های غیرچسبنده. نشریه دانش آب و خاک، ۳۰:۳۳-۱۶۹-۱۸۲.
- سلطان‌نیک‌دفرامری، س. و تقی‌زاده مهرجردی، ر. ۱۳۹۵. کاربرد روش‌های داده‌کاوی در تخمین عمق آبستگي گروه پایه‌ها. *مجله هیدرولیک*، ۱۰:۱۱: ۶۷-۷۵.
- سیدیان، س.م. ۱۳۹۴. استفاده از روش‌های نوین در تعیین پارامترهای موثر بر آبستگي پایه پل. *مجله مهندسی آبیاری و آب*، ۱۹:۵-۱-۱۶.
- سیدیان، م. و فتح‌آبادی ا. ۱۳۹۵. تخمین عمق آبستگي پایه‌های پل با استفاده از روش‌های آماری و الگوریتم‌های هوشمند. *نشریه مهندسی عمران و محیط‌زیست*، ۱-۱۲: ۲۰۴۶-۱۲-۱.
- غضنفری‌هاشمی، س. و اعتمادشهییدی، ا. ۱۳۹۱. پیش‌بینی عمق آبستگي اطراف پایه‌ی پل با استفاده از ماشین‌های بردار پشتیبان. *نشریه عمران مدرس*، ۱۲: ۲۳-۳۶.
- فتاحی، م.، لشکرآراء، ب. و نجفی ل. ۱۳۹۸. تخمین آبستگي پایین‌دست سازه سیفون معکوس بالارود با استفاده از روش‌های فراالبتکاری. *مجله علوم و مهندسی آبیاری*، ۱۰:۴۲: ۱۲۹-۱۴۳.
- ماجدی‌اصل، م.، فولادی‌پناه، م. ۱۳۹۷. کاربرد سیستم‌های تکاملی در تعیین ضریب دبی سرریزهای کنگره‌ای مثلثی. *نشریه علوم آب و خاک*. *نشریه علوم و فنون کشاورزی و منابع طبیعی*، ۱۰:۱۴: ۲۷۹-۲۹۰.
- مومنی و صالحیان ر.، موسوی‌چهرمی ح.، شفاعی‌بجستان م. ۱۳۸۷. آبستگي ناشی از جت‌های مستطیلی در پایین‌دست پرتابه‌های جامی شکل با مصالح غیریک‌نواخت. *نشریه علوم و فنون کشاورزی و منابع طبیعی*، ۲: ۲۰۳-۲۱۶.
- هوشیاری‌پور ف.، نوری ر. ۱۳۹۲. استفاده از تکنیک ماشین بردار پشتیبان در پیش‌بینی ابعاد چاله آبستگي پایین‌دست یک پرتابه جامی شکل. *مهندسی آب و محیط‌زیست ایران*، ۱۰: ۳۵-۴۵.
- Akib, S., Mohammadhassani, M. and Jahangirzadeh, A. 2014. Application of ANFIS and LR in prediction of scour depth in bridges. *Computers & Fluids*. 91.2: 77-86.
- Azmathullah, H.M., Deo, M.C., and Deolalikar, P.B. 2005. Neural networks for estimation of scour downstream of ski-jump bucket, *Journal of Hydraulic Engineering, ASCE*. 131.10: 898- 908.
- Azmathullah, H.M., Ghani A.A.B., Zakaria, N., Hin, L.S, Kiat, C.C., Siang, L.C. and Hasan, Z.A. 2008. Genetic programming to predict ski-jump bucket spillway scour. *Journal of Hydrodynamic*. 20.4: 477-

spillway scour, proceeding of 1998 Annual Conference of The Association of State Safety Officials, October 11-14, Las Vegas.

Yip, D.H.F., Hines, E.L., and Yu, W.H. 1997. Application of Artificial Neural Networks in Sales Forecasting. International Conference on Neural Networks (ICNN '97), Houston: 2121-2124.

United States.

Wang, W.J., Xu, Z. B., Lu, W. Z. and Zhang, X.Y. 2003. Determination of the Spread Parameter in the Gaussian Kernel for Classification and Regression. Neuro computing, 55.3-4: 643-663.

Wittler, R.J., Annandale, G.W. Abt, S.R. and Ruff, J.F. 1998. New technology for estimating plunge pool

Application and Assessment of SVM Algorithm to Simulate the Geometry of Scour Hole Downstream of a Siphon Spillway

M. Fuladipanah^{۱*}, M. Majedi Asl^۲, R. Jafarinia^۳

Received: Dec.13, 2020

Accepted: Mar.9, 2020

Abstract

Accurate simulation of scour hole's geometric specifications, created due to flow jet collision to plunge pool bed, has a significant role in the design, construction and performance of weirs and energy dissipater structures. In this research, a comparative evaluation was done between experimental and numerical study of scour phenomena downstream of a siphon spillway using SVM algorithm with three sediment particles and three buckets angles for different magnitudes of flow discharge and tail water depths in a rectangular flume made from plexiglas. Three linear-independent dimensionless parameters were formed. Classic linear and non-linear regression model and FFBP and CFBP neural networks were applied more over the SVM algorithm to simulate the scour hole dimensions and were compared using five statistical indices as R, RMSE, MAE, N.S and DDR. A comparison of the quintuple accuracy indices showed that SVM algorithm had better performance than to the other models, especially classic regression ones. Among all parameters, SVM algorithm had acceptable prediction with higher and lower level of accuracy for $\frac{L_5}{h_t}$ and $\frac{L_6}{h_t}$ by quintuple above mentioned indices as (0.9954, 0.2056, 0.987, 0.9851, 7.855) and (0.8924, 2.860, 2.23, 0.7587, 1.405), respectively. Finally, a comparison was done among SVM algorithm and empirical predictors of scour hole depth. Comparison of accuracy indices showed that the SVM had a tangible and absolute advantage over empirical equations presented by other researchers.

Keywords: Performance Assessment, Plunge Pool, Dimensional Analysis, SVM Algorithm

۱- Department of Civil Engineering, Ramhormoz Branch, Islamic Azad University, Ramhormoz, Iran

۲- Department of Civil Engineering, Maragheh University, Maragheh, Iran

۳- Department of Water Engineering, Arak Branch, Islamic Azad University, Arak, Iran

(*- Corresponding Author Email: Fuladipanah@gmail.com)