

پیش‌بینی ظرفیت باربری جانبی شمع‌ها در خاک‌های رسی با استفاده از ماشین بردار پشتیبان

علیرضا اردکانی^{۱*} و وحیدرضا کوهستانی^۲

^۱ استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)

^۲ دانش آموخته کارشناسی مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)

(دریافت: ۹۵/۲/۱۳، پذیرش: ۹۵/۲/۲۲، نشر آنلاین: ۹۵/۲/۲۳)

چکیده

پیش‌بینی ظرفیت باربری شمع‌های تحت بار جانبی یکی از مسائل اساسی در مهندسی ژئوتکنیک است و تاکنون روش‌های متغیرهایی برای ارزیابی آن ارائه شده است. ماشین بردار پشتیبان (SVM) یک روش نسبتاً جدید هوش مصنوعی است که در بسیاری از مسائل ژئوتکنیکی به طور موفقیت‌آمیزی مورد استفاده قرار گرفته است. این مقاله کاربرد مدل SVM برای پیش‌بینی ظرفیت باربری جانبی شمع‌ها در خاک‌های رسی را شرح می‌دهد. از نتایج مدل‌های کوچک مقیاس آزمایشگاهی شمع‌های رسی با پلارامترهای ورودی قطر شمع (L), طول مدفون شمع (D)، خروج از مرکز بار (e) و مقاومت برشی زهکشی نشده خاک (Su) برای توسعه و ارزیابی مدل استفاده شده است. ظرفیت باربری جانبی پیش‌بینی شده توسط مدل پیشنهادی با نتایج حاصل از مدل شبکه عصبی مصنوعی (ANN) و همچنین روش‌های تحلیلی Broms و Hansen مقایسه شده است. نتایج نشان از کارایی بهتر مدل SVM نسبت به روش‌های مذکور دارد. این مطالعه نشان می‌دهد که روش SVM یک ابزار جایگزین برای مهندسین ژئوتکنیک به منظور پیش‌بینی ظرفیت باربری جانبی شمع‌ها ارائه می‌دهد.

کلیدواژه‌ها: ماشین بردار پشتیبان (SVM)، ظرفیت باربری جانبی، شمع، مقاومت برشی زهکشی نشده (Su).

۱- مقدمه
دخالت دارند مشکل و در برخی موارد نامعین می‌باشند لذا پیش‌بینی ظرفیت باربری شمع‌ها دشوار است. از میان این عوامل می‌توان خواص فیزیکی و مکانیکی منحصر به فرد خاک مانند ناهمگونی، ناهمسانی، وجود آب و تنوع ترکیبات مختلف خاک در طبیعت و همچنین تنوع شمع‌ها از لحاظ جنس صالح، شکل مقاطع، روش‌های اجرا و نصب را نام برد. در این ارتباط روش‌های تئوری و تجربی زیادی ارائه شده است که اکثر روش‌های موجود با در نظر گرفتن فرضیاتی راجع به عوامل مؤثر در ظرفیت باربری شمع، مسئله را ساده کرده‌اند بنابر این در روش‌های متغیرهای ظرفیت باربری، سازگاری وجود در ندارد (Shahin et al., ۲۰۱۰). با توجه به عدم قطعیت‌های موجود در پیش‌بینی ظرفیت باربری شمع‌ها، بهتر است ظرفیت باربری آن‌ها به صورت درجا تعیین شود. آزمایش بارگذاری شمع در مقیاس واقعی کامل ترین و بهترین روش تعیین ظرفیت باربری یک شمع است. با این حال این روش‌ها مشکلات عملی و

در صورت مناسب نبودن ظرفیت باربری زمین برای استفاده از شالوده‌های سطحی از شمع‌ها برای ساخت شالوده‌های عمیق استفاده می‌شود. غالباً شمع‌ها علاوه بر بار قائم، تحت اثر نیروهای جانبی قرار دارند. در سازه‌هایی همچون پل‌ها، اسکله‌های دریایی و توربین‌های بادی و غیره شمع‌ها تحت اثر بار جانبی زیادی قرار دارند و می‌باشد طراحی در مقابله این بارها با دقت بیشتری صورت گیرد. طراحی شمع‌ها تحت اثر بار جانبی بر اساس دو معیار صورت می‌گیرد:

- ۱- ظرفیت باربری نهایی شمع
 - ۲- تغییر مکان مجاز سر شمع که عموماً معیار دوم نقش تعیین‌کننده‌تری را دارد (Davis and Poulos, ۱۹۸۰).
- تعیین ظرفیت باربری شمع‌های تحت اثر بار جانبی یکی از چالش‌هایی است که اکثر مهندسان ژئوتکنیک با آن مواجه‌اند. از آنجا که تعیین عواملی که در میزان ظرفیت باربری شمع‌ها

* نویسنده مسئول؛ شماره تماس: ۰۲۸-۳۳۹۰۱۱۶۴

آدرس ایمیل: a.ardakani@eng.ikiu.ac.ir (ع. اردکانی)، vrkohestani@gmail.com (و. کوهستانی).

در این تحقیق، از مدل SVM برای تخمین ظرفیت باربری شمع‌های تحت بار جانبی در خاک‌های رسی استفاده شده است. نتایج مدل‌های کوچک مقیاس آزمایشگاهی برای توسعه مدل بکار رفته است و نهایتاً نتایج به دست آمده با مقادیر واقعی داده‌ها و نتایج حاصل از مدل ANN و DAS، Basudhar Hansen (۱۹۶۴) و روشن‌های تحلیلی Broms (۱۹۶۱) و (۲۰۰۶) مقایسه خواهد گردید.

۲- روشن‌های تعیین ظرفیت باربری جانبی شمع‌های واقع بر خاک‌های رسی

رایج‌ترین روشن برای تعیین ظرفیت باربری جانبی شمع‌های واقع بر خاک‌های دانه‌ای و رسی روشن Broms است که امروزه نیز توسط مهندسین مورد استفاده قرار می‌گیرد. شکل (۱) نتایج حاصل از روشن Broms برای شمع‌های واقع بر خاک‌های رسی را به صورت نمودارهای بدون بعد نشان می‌دهد. با استفاده از این نمودارها می‌توان به سادگی و به طور مستقیم ظرفیت باربری جانبی شمع‌های واقع بر خاک‌های رسی را به دست آورد. در این روشن شمع‌ها به دو دسته: ۱- شمع کوتاه و صلب و ۲- شمع‌های بلند و قابل انعطاف تقسیم شده‌اند. همان طور که در شکل (۱) دیده می‌شود مقاومت جانبی شمع به شرایط سر شمع نیز بستگی دارد به طوری که ظرفیت باربری جانبی شمع‌های با سر ثابت شده بیشتر از شمع‌هایی با سر آزاد است.

علاوه بر Broms، محققین بسیاری Hansen و Christensen (۱۹۶۱)، Georgiadis (۱۹۷۰)، Welch (۱۹۷۵)، Matlock (۱۹۷۰)، Reese (۱۹۷۹)، Stewart (۱۹۹۹)، Meyerhof (۱۹۸۱) و همکاران (۱۹۷۹) با در نظر گرفتن فرضیاتی سعی در ارائه روابطی برای تخمین ظرفیت باربری جانبی شمع‌ها نموده‌اند. در شکل (۲) مقایسه‌ای بین نمودار بدون بعد $Q_u/c_u b^2$ در برابر L/D به دست آمده از روشن Broms و سایر روشن‌های موجود برای تخمین ظرفیت باربری شمع‌های صلب در خاک‌های رسی صورت گرفته است. در شکل (۲)، α فاکتور چسبندگی بین شمع و خاک است که Georgiadis و همکاران (۱۹۱۳) مقدار آن را برای شمع‌های صاف صفر و برای شمع‌های زبر ۱ در نظر گرفت و z_r عمق بحرانی است که توسط رابطه زیر به دست می‌آید:

$$z_r = \frac{6D}{(\gamma D/c_u) + J} \quad (1)$$

که در آن، J یک فاکتور تجربی است که Matlock (۱۹۷۰) مقدار آن را بین ۰/۰۵ تا ۰/۰۵ و Welch (۱۹۷۵) و Reese (۱۹۷۵) آن را ۰/۰۵ و Bhushan (۱۹۷۵) و همکاران (۱۹۷۵) مقدار آن را پیشنهاد داده‌اند.

اقتصادی خود را دارند. این مشکلات، استفاده از این روشن‌ها محدود و کم می‌کند. برای رفع این مشکلات مدل‌های با مقایسه کوچک به عنوان جایگزین به کار گرفته می‌شود.

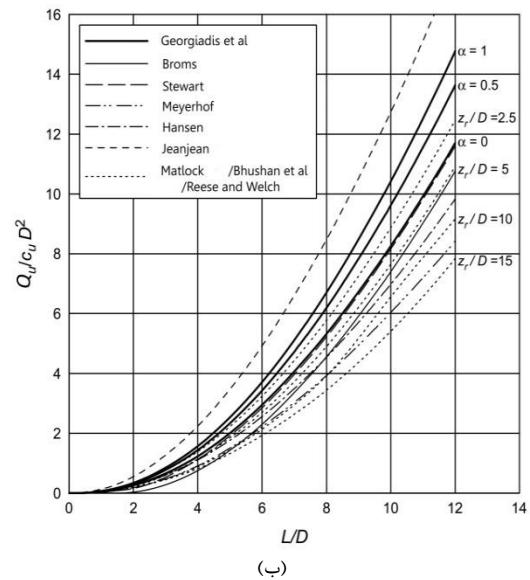
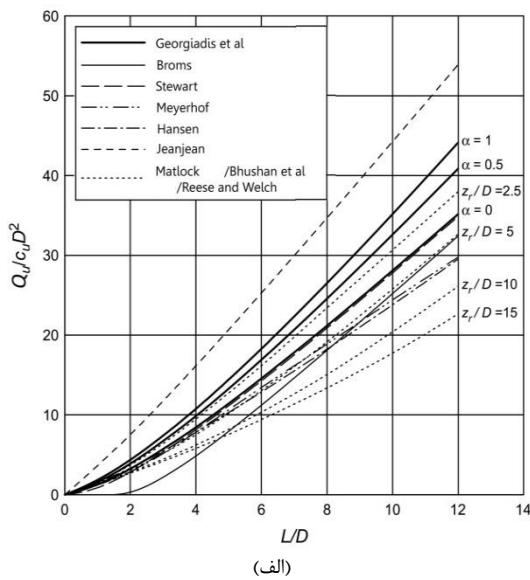
در سال‌های اخیر روشن‌های محاسبات نرم^۱ به عنوان روشن‌های جدید برای مدل‌سازی روابط پیچیده مورد استفاده قرار گرفته‌اند. مزیت عمدی این روشن‌ها این است که تنها با داشتن مجموعه‌ای از داده‌های مؤثر بر متغیر هدف، قادر به تخمین آن می‌باشند Kohestani و همکاران (۲۰۱۵) از جمله این روشن‌ها هستند که برای تخمین ظرفیت باربری شمع‌ها مورد استفاده قرار گرفته‌اند.

Kordjazi و همکاران (۲۰۱۴) با استفاده از ماشین‌های بردار پشتیبان ظرفیت باربری شمع‌ها تحت اثر بار محوری را پیش‌بینی کردند. آن‌ها از داده‌های مربوط به آزمایش بارگذاری استاتیکی در مقایس واقعی و همچنین نتایج آزمایش نفوذ مخروط (CPT) برای مدل‌سازی استفاده کردند و نهایتاً نتایج مدل SVM با نتایج مدل شبکه عصبی مصنوعی^۲ (ANN) و یک CPT روش مستقیم اندازه‌گیری ظرفیت باربری بر اساس نتایج مقایسه و نشان داده شد که روشن پیشنهادی، ظرفیت باربری شمع را با دقت بهتری نسبت به سایر روشن‌ها محاسبه می‌کند. Deswal و Pal (۲۰۰۸) از SVM برای مدل‌سازی ظرفیت باربری استاتیکی شمع‌ها با استفاده از ۱۰۵ داده‌های دینامیکی موج-تنش استفاده کردند و نتایج را با یک روشن شبکه عصبی رگرسیونی تعیین یافته مقایسه کردند. شمع‌های مورد مطالعه از نوع بتنی پیش‌ساخته پیش‌تینیده با مقطع لوله‌ای شکل بودند. آنها نشان دادند که هر مدل پیشنهادی با دقت مناسبی قادر به تخمین ظرفیت باربری استاتیکی شمع‌ها می‌باشد.

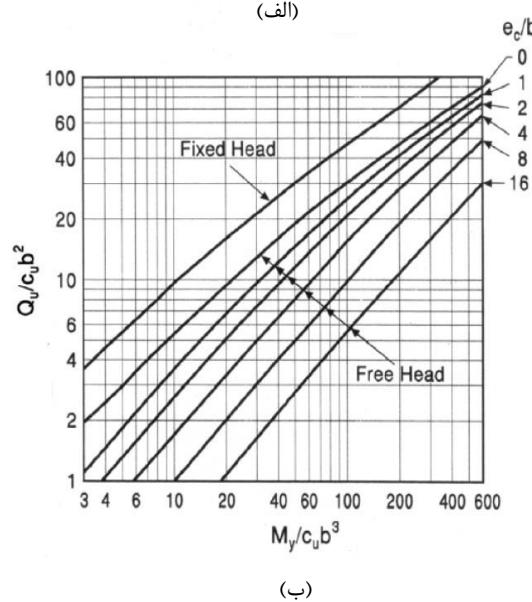
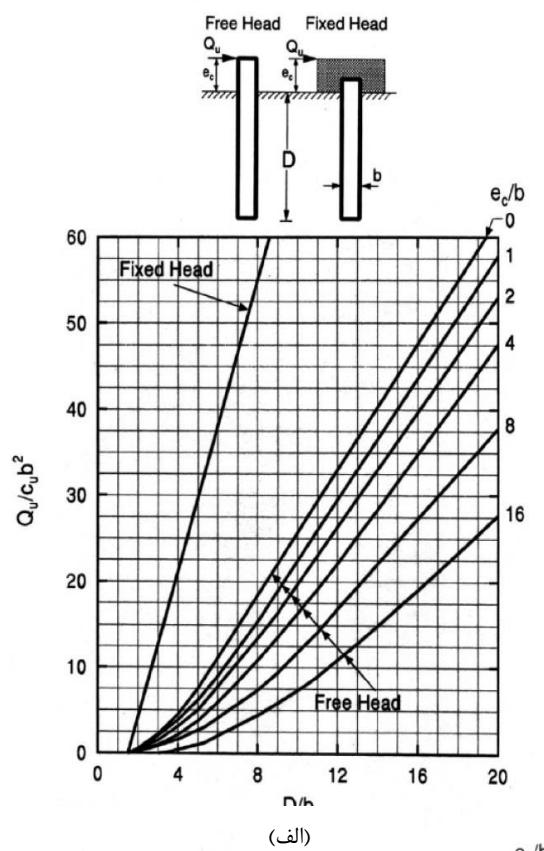
Liu و همکاران (۲۰۱۱) از روشن SVM برای پیش‌بینی ظرفیت باربری نهایی شمع‌ها استفاده کردند. آنها از ۲۸ داده تست بارگذاری شمع برای ساخت مدل استفاده کردند. نسبت عمق نفوذ (l/d)، تنش نرمال میانگین (σ_m) و تعداد ضربات (n) به عنوان پارامترهای ورودی مدل در نظر گرفته شد. استفاده از آنالیز حساسیت نشان داده شد که l/d در بین پارامترهای ورودی، مهمترین فاکتور تأثیرگذار روی ظرفیت باربری شمع‌ها است.

Zhang و همکاران (۲۰۱۲) نیز از مدل SVM برای پیش‌بینی مقاومت اصطکاکی جانبی شمع‌هایی با قطر زیاد و طول بسیار بلند استفاده کردند. مطالعات انجام شده توسط Samui (۲۰۱۱) و Samui (۲۰۰۸a) نمونه‌هایی دیگر از کاربرد مدل SVM برای محاسبه ظرفیت باربری شمع‌ها است.

1. Soft Computing Approaches
2. Support Vector Machines
3. Artificial Neural Network



شکل ۲- ظرفیت باربری جانبی شمع‌های صلب با سر آزاد:
الف) $e/D = 0$ ، ب) $e/D = 16$ و همکاران، ۲۰۱۳ Georgiadis



شکل ۱- ظرفیت باربری جانبی شمع‌های واقع بر خاک‌های رسی، الف) شمع‌های کوتاه، ب) شمع‌های بلند (Broms، ۱۹۶۴)

۳- ماشین بردار پشتیبان
 ماشین بردار پشتیبان یکی از روش‌های نسبتاً جدید در مسائل دسته‌بندی و رگرسیون است که امروزه از آن به عنوان یکی از معتبرترین ابزارهای یادگیری ماشین استفاده می‌شود که در سال ۱۹۹۲ توسط Vapnik بر پایه تئوری آماری معروفی شد (Schölkopf و Smola، ۱۹۹۵؛ Cortes و Vapnik، ۱۹۹۵؛ Cortes و Vapnik، ۲۰۰۴). تئوری آماری Vapnik سابقه نسبتاً طولانی دارد، او و همکارانش در سال ۱۹۶۳، تئوری ابر صفحه را به عنوان طبقه‌بندی‌کننده خطی ارائه دادند. آن‌ها همچنین در سال ۱۹۹۲، طبقه‌بندی‌کننده غیرخطی را به کمک توابع کرنل^۴

$$\begin{aligned} ((w \cdot x_i) + b) - y_i &\leq \varepsilon + \xi_i^* \quad i = 1, 2, \dots, l \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \quad (4)$$

در این رابطه، ε خطای مورد قبول درتابع تلفات، $\|w\|^2$ نرم بردار وزن؛ C پارامتر جریمه یا پارامتر تنظیم، ξ, ξ^* متغیرهای Slack که به همراهتابع تلفات در شکل (۳) نشان داده شده‌اند.

بر اساس تئوری لاگرانژ، مسئله بهینه‌سازی رابطه (۴) قابل تبدیل بهتابع لاگرانژ است:

$$\begin{aligned} L(\alpha^*, \alpha) = & -\varepsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i) + \sum_{i=1}^l y_i (\alpha_i^* - \alpha_i) \\ & - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* + \alpha_j)(x_i \cdot x_j) \end{aligned} \quad (5)$$

که در این رابطه، $L(\alpha^*, \alpha)$ تابع لاگرانژ و α^* و α ضرایب لاگرانژ می‌باشند.تابع فوق باید تحت قیدهای زیر بیشینه شود:

$$\begin{aligned} \sum \alpha_i^* &= \sum \alpha_i \\ 0 \leq \alpha_i^* &\leq C \\ 0 \leq \alpha_i &\leq C \end{aligned} \quad (6)$$

با تعیین ضرایب α^* و α ، بدین ترتیب پاسخنهایی به صورت زیر خواهد بود (Dibike و همکاران، ۲۰۰۱):

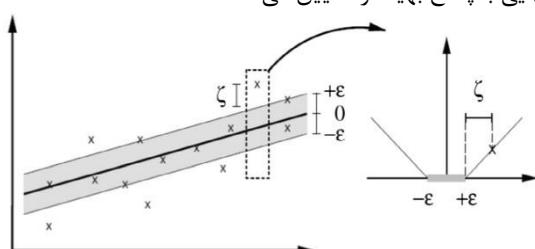
$$w_0 = \sum_{\text{Support vectors}} (\alpha_i^* - \alpha_i)x_i \quad (7)$$

$$b_0 = -\frac{1}{2} w_0 \cdot [x_r + x_s] \quad (8)$$

$$f(x) = \sum_{\text{Support vector}} (\alpha_i^* - \alpha_i)(x_i \cdot x) + b_0 \quad (9)$$

در این روابط، w_0 و b_0 مقادیر بهینه بردار وزن و بایاس؛ x_r و x_s دو بردار پشتیبان هستند.

داده‌هایی که ضرایب لاگرانژ متناظر با آن‌ها غیر صفر باشد، به عنوان بردار پشتیبان شناخته می‌شوند. از نظر هندسی این داده‌ها دارای خطای پیش‌بینی بزرگ‌تر از $\pm \varepsilon$ هستند؛ بنابر این، مقدار ε تعداد بردار پشتیبان را کنترل می‌کند (Samui، ۲۰۰۸b). با توجه به رابطه (۷) مشاهده می‌شود که داده‌هایی که ضریب لاگرانژ آن‌ها صفر است، نقشی در پاسخنهایی ندارند. به سخن دیگر، بردارهای پشتیبان هستند که تابع رگرسیون نهایی با پاسخ بهینه را تعیین می‌کنند.



شکل ۳- تابع تلفات Vapnik و متغیرهای Slack و همکاران، ۲۰۰۱

معرفی کردند. اصول اساسی آنچه که امروز به عنوان بردار پشتیبان شناخته می‌شود نتیجه کارهای او و همکارانش است که در سال ۱۹۹۵ منتشر گردید و در نهایت گسترش ماشین بردار پشتیبان بر اساس رگرسیون در سال ۱۹۹۶ توسط وی و همکارانش به نتیجه رسید (Shawe and Cristianini، ۲۰۰۰).

در این روش برای کمینه کردن خطای مدل از اصولی که با عنوان کمینه‌سازی ریسک ساختاری^۵ (SRM) شناخته می‌شوند، استفاده می‌شود. در حالی که سایر روش‌ها مانند شبکه‌های عصبی مصنوعی از اصول کمینه‌سازی ریسک تجربی^۶ (ERM) بهره می‌برند (Dibike و همکاران، ۲۰۰۱). هدف اصلی SRM این است که به طور همزمان علاوه بر کمینه کردن ریسک تجربی (کاهش خطای داده‌های آموختش) تعمیم‌یابی مدل را بیشینه کند (Dibike و همکاران، ۲۰۰۱).

در SVM حل مسئله رگرسیون با معرفی یک تابع تلفات^۷ که در آن حداقل خطایی به میزان ε قابل صرف‌نظر کردن است، بررسی می‌گردد. به طور خلاصه، ماشین بردار پشتیبان تابع رگرسیون را با به کارگیری یک دسته تابع خطی تخمین می‌زند، اگرچه قابلیت گسترش با استفاده از رگرسیون غیرخطی را دارد. حل مسئله رگرسیون در SVM بر روی یک مجموعه از داده‌ها به صورت:

$$\{(x_1, y_1), \dots, (x_l, y_l) \in R^m, y \in R\} \quad (2)$$

$$f(x) = \langle w \cdot x \rangle + b \quad (2)$$

در این رابطه، l تعداد نمونه‌ها، x بردار ورودی، y مقدار خروجی، w بردار وزن، b بایاس، $\langle w \cdot x \rangle$ حاصل‌ضرب داخلی دو بردار x و w است.

یک تابع تلفات با ناحیه ε نیز به صورت زیر تعریف می‌شود:

$$L_\varepsilon(y) = |y - f(x)|_\varepsilon \quad |y - f(x)| \leq \varepsilon \\ = |y - f(x)| - \varepsilon \quad \text{otherwise} \quad (3)$$

که در آن، $(y - f(x))_\varepsilon$ تابع تلفات و ε یک مقدار ثابت مثبت است.

با استفاده از تابع تلفات Vapnik، پارامترهای کنترل کننده تابع پاسخ بهینه در SVM یعنی تابع وزن (w_0) و بایاس (b_0) با حل مسئله بهینه‌سازی زیر حاصل می‌شوند:

Minimize

$$\Phi(w, \xi^*, \xi) = \frac{\|w\|^2}{2} + C(\sum \xi^* + \sum \xi)$$

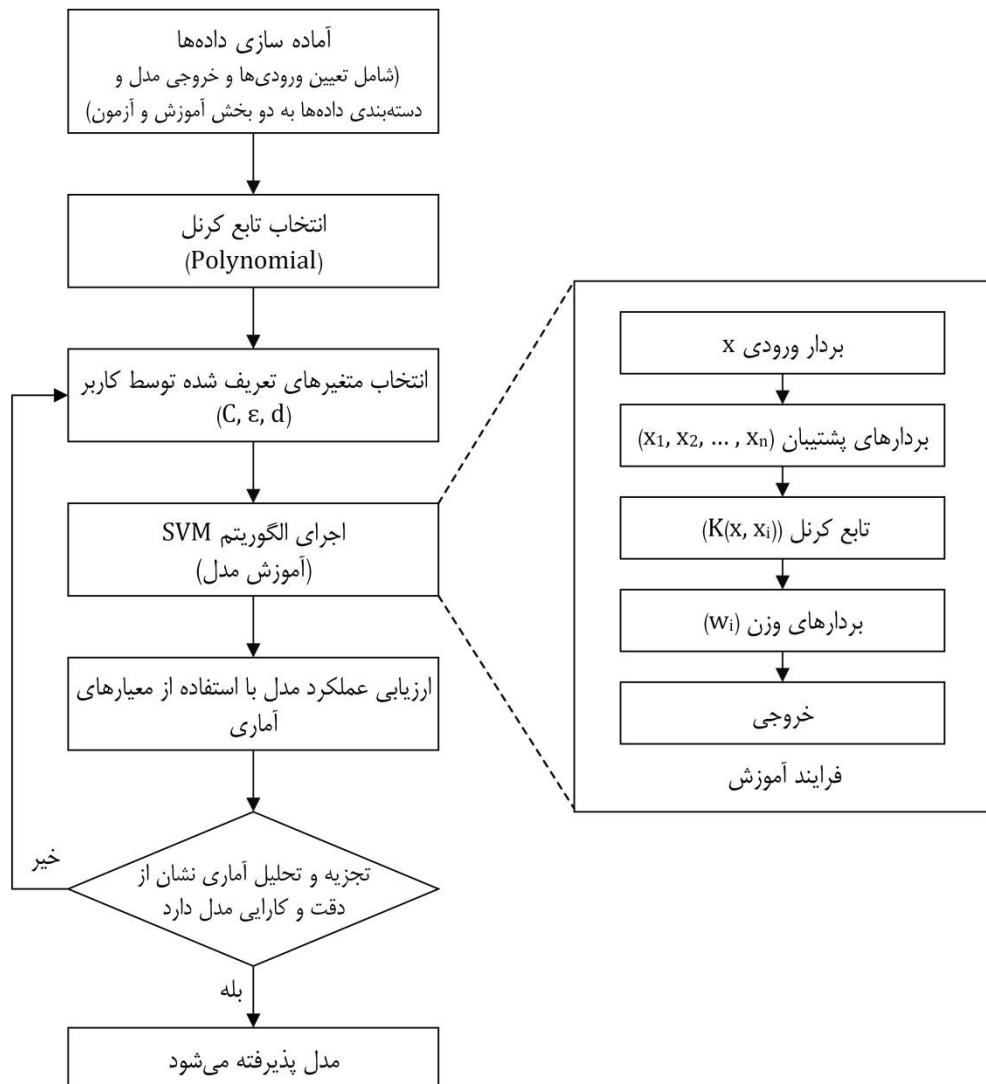
Subject to:

$$y_i - ((w \cdot x_i) + b) \leq \varepsilon + \xi_i$$

5. Structural Risk Minimization

6. Empirical Risk Minimization

7. Loss Function



شکل ۴- خلاصه‌ای از مراحل توسعه مدل با استفاده از SVM و همکاران Kordjazi (۲۰۱۴) و

چندجمله‌ای (Polynomial)، تابع کرنل پایه شعاعی (RBF) و تابع کرنل پیرسون (PUK) به طور موفقیت‌آمیز در مسائل رئوتکنیک به کار رفته است (Hassanlourad و Kohestani؛ ۲۰۱۵؛ GOH، ۲۰۰۷). در نتیجه معادله (۷) و (۸) را می‌توان به صورت زیر بازنویسی کرد (Dibike و همکاران، ۲۰۰۱):

$$w_0 \cdot x = \sum_{\text{Support vectors}} (\alpha_i^* - \alpha_i) K(x_i, x) \quad (10)$$

$$b_0 = -\frac{1}{2} \sum_{\text{Support vectors}} (\alpha_i^* - \alpha_i) [K(x_r, x_i) + K(x_s, x_i)] \quad (11)$$

که در آن‌ها، $K(x_i, x)$ یک تابع کرنل است.

پارامتر ϵ نیز می‌تواند مقادیر صفر تا بی‌نهایت را بپذیرد. مقدار این پارامتر در وضعیت بردار پشتیبان و در نتیجه کارایی مدل بسیار مؤثر است. با انتخاب مقادیر خیلی بزرگ برای ϵ بردارهای پشتیبان کاهش داده می‌شود، ولی باند ϵ عرضی تر می‌شود و دامنه خطای مجاز بالا می‌رود. مقادیر خیلی کوچک ϵ نیز باعث می‌شود بردارهای پشتیبان زیاد شده و احتمال خطر بیش آموزش افزایش یابد (Samui، ۲۰۰۸b).

مسئله رگرسیون خطی در SVM به آسانی قابل گسترش به رگرسیون غیرخطی است. بدین منظور از توابع کرنل استفاده می‌شود. توابع کرنل، داده‌ها را به یک فضای ویژگی \mathcal{H} نگاشت می‌کنند که در آن فضا امکان استفاده از رگرسیون خطی وجود داشته باشد. تاکنون کرنل‌های گوناگونی معرفی شده‌اند (Shawe و Cristianini، ۲۰۰۰) که در میان آن‌ها تابع کرنل

۶- ارزیابی نتایج حاصله

در این تحقیق چند مدل ماشین بردار پشتیبان برای پیش‌بینی ظرفیت باربری جانی شمع‌ها بر اساس مقاومت برشی زهکشی نشده خاک انجام شده است که نتایج مدل با تابع کرنل چندجمله‌ای رائمه شده است. برای رسیدن به مدل بهینه، با ترکیب‌های مختلفی از پارامترهای C ، ϵ و پارامتر تابع کرنل (d)، مدل SVM بر روی داده‌های آموزش گسترش داده شده و به کمک مجموعه داده‌های آزمون، عملکرد مدل بررسی می‌شود. جدول (۳) فرایند بهینه‌سازی پارامترهای فوق را نشان می‌دهد. بدین صورت که نتایج مدل به ازای تغییرات یک پارامتر از پارامترهای سه‌گانه (C ، ϵ ، d) درحالی که دو پارامتر دیگر ثابت هستند، نشان داده شده است.

جهت ارزیابی دقت مدل تولیدشده از شاخص‌های آماری از قبیل ضریب همبستگی (CC)، ریشه میانگین مربعات خطای ($RMSE$) و ضریب بهره‌وری (E) استفاده شد. مقادیر این پارامترها از روابط زیر به دست می‌آید:

$$CC = \frac{\sum_{i=1}^n [(s_i - \bar{s}_i)(c_i - \bar{c}_i)]}{\sqrt{\sum_{i=1}^n (s_i - \bar{s}_i)^2 (c_i - \bar{c}_i)^2}} \quad (13)$$

$$RMSE = \left(\frac{\sum_{i=1}^n (s_i - c_i)^2}{n} \right)^{0.5} \quad (14)$$

$$E = (E_1 - E_2)/E_1 \quad (15)$$

$$E_1 = \sum_{t=1}^r (c_i - \bar{c}_i)^2 \quad (15\text{-الف})$$

$$E_2 = \sum_{t=1}^r (s_i - c_i)^2 \quad (15\text{-ب})$$

که در این روابط، \bar{c}_i میانگین مقدار مشاهداتی متغیر، s_i میانگین مقدار محاسبه شده توسط مدل، c_i مقدار محاسبه شده متغیر توسط مدل، r مقدار مشاهداتی (واقعی) متغیر و n تعداد داده‌های مشاهداتی است.

با بررسی مدل‌های گسترش‌یافته با تابع کرنل چندجمله‌ای، مشاهده می‌شود که مدلی که در آن توان تابع کرنل (d) و پارامتر C و ϵ به ترتیب $4/7$ ، $1/5$ و 0.025 است بهترین عملکرد را نشان می‌دهد. نتایج عملکرد مدل بهینه بر مجموعه داده‌های آموزش و آزمون در جدول (۴) نشان داده شده است. در شکل (۵) نیز مقادیر پیش‌بینی و اندازه‌گیری شده توسط مدل SVM مقایسه شده است.

۴- آموزش و ارزیابی مدل

همان طور که ذکر شد به منظور گسترش یک مدل غیرخطی SVM از توابع کرنل استفاده می‌شود. در این تحقیق از تابع کرنل چندجمله‌ای استفاده شده است؛ که در رابطه (۱۲) نشان داده شده‌اند (Üstün و همکاران، ۲۰۰۶).

$$K(x, x_i) = (\langle x, x_i \rangle + 1)^d \quad (12)$$

در این رابطه، d ، توان چندجمله‌ای است که توسط کاربر تعیین می‌شوند.

در این تحقیق برای آموزش مدل و ارزیابی آن بر داده‌های آزمون از نرم‌افزار WEKA (Frank و Witten، ۲۰۰۵) برای ساخت مدل SVM استفاده شده است.

۵- داده‌های استفاده شده برای ساخت مدل

به منظور دستیابی به یک مدل کارآمد برای پیش‌بینی ظرفیت باربری شمع نیاز به شناسایی پارامترهای مؤثر بر ظرفیت باربری شمع‌ها است. این پارامترها شامل اطلاعاتی درباره شمع و خاک است.

در این تحقیق برای آموزش و ارزیابی مدل SVM از داده‌های منتشرشده توسط Rao و Suresh Kumar (۱۹۹۶) استفاده شده است (جدول (۱)). داده‌ها شامل قطر شمع (D)، طول مدفون شمع (L)، خروج از مرکز بار (e) و مقاومت برشی زهکشی نشده خاک (S_{ll}) به عنوان ورودی مدل و مقاومت جانی شمع (Q_m) به عنوان خروجی مدل می‌باشند. داده‌ها شامل ۳۸ آزمایش بارگذاری شمع تحت بار جانی واقع بر خاک‌های رسی در مقیاس کوچک است که همگی از نوع شمع‌های کوتاه و صلب می‌باشند.

این داده‌ها توسط Das و Basudhar (۲۰۰۶) نیز برای تخمین ظرفیت باربری شمع‌های تحت بار جانی با استفاده از مدل ANN مورد استفاده قرار گرفت که نتایج حاکی از برتری مدل ANN نسبت به روش‌های تحلیلی Broms و Hansen داشت. در این تحقیق به منظور مقایسه نتایج مدل SVM با نتایج Das و Basudhar، از مجموعه داده‌های یکسانی برای آموزش و ارزیابی استفاده شده است. بدین ترتیب ۲۹ داده برای آموزش و ۹ داده برای ارزیابی مدل استفاده شده است (جدول (۱)). در جدول (۲) مشخصات آماری داده‌ها شامل کمینه، بیشینه، میانگین و انحراف از معیار مجموعه داده‌های آموزش و آزمون به صورت جداگانه رائمه شده است.

پس از اتمام فرآیند آموزش مدل، عملکرد آن توسط داده‌هایی که در فرآیند آموزش استفاده نشده‌اند (داده‌های آزمون) ارزیابی می‌شود. شکل (۴) فرایند ساخت مدل SVM را به طور خلاصه نشان می‌دهد.

جدول ۱- داده‌های مورد استفاده برای توسعه SVM و Rao (Suresh Kumar و Rao ۱۹۹۶)

داده‌های آزمون					داده‌های آموزش				
D (mm)	L (mm)	e (mm)	S _u (kN/m ²)	Q _m (N)	D (mm)	L (mm)	e (mm)	S _u (kN/m ²)	Q _m (N)
۱۳/۵۰	۱۹۰/۰۰	۰/۰۰	۲۴/۰۰	۱۲۸/۰۰	۶/۳۵	۱۴۶/۱۰	۱۹/۱۰	۳۸/۸۰	۶۹/۵۰
۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۳/۴۰	۳۸/۰۰	۱۲/۰۰	۲۶۰/۰۰	۰/۰۰	۲۴/۰۰	۲۲۵/۰۰
۱۸/۴۰	۳۰۰/۰۰	۵۰/۰۰	۳/۴۰	۴۲/۵۰	۱۲/۵۰	۱۳۰/۰۰	۰/۰۰	۲۴/۰۰	۱۰۶/۰۰
۲۵/۴۰	۳۰۰/۰۰	۵۰/۰۰	۴/۰۰	۵۸/۰۰	۱۲/۵۰	۳۰۰/۰۰	۵۰/۰۰	۳/۴۰	۳۰/۰۰
۱۳/۰۰	۱۳۲/۱۰	۲۳/۸۰	۳۳/۸۰	۵۳/۰۰	۱۲/۵۰	۳۰۰/۰۰	۵۰/۰۰	۴/۰۰	۳۶/۰۰
۱۸/۰۰	۳۰۰/۰۰	۵۰/۰۰	۴/۰۰	۴۹/۰۰	۱۲/۵۰	۳۰۰/۰۰	۵۰/۰۰	۵/۵۰	۵۰/۰۰
۱۸/۰۰	۳۰۰/۰۰	۵۰/۰۰	۵/۵۰	۶۵/۰۰	۱۲/۵۰	۳۰۰/۰۰	۵۰/۰۰	۷/۲۰	۶۴/۰۰
۱۸/۰۰	۳۰۰/۰۰	۵۰/۰۰	۷/۲۰	۸۷/۰۰	۱۸/۰۰	۳۰۰/۰۰	۵۰/۰۰	۱۰/۰۰	۸۹/۰۰
۱۲/۳۰	۳۰۰/۰۰	۵۰/۰۰	۴/۰۰	۳۵/۰۰	۱۸/۰۰	۳۰۰/۰۰	۵۰/۰۰	۳/۴۰	۳۹/۰۰
					۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۴/۰۰	۴۶/۰۰
					۱۲/۳۰	۳۰۰/۰۰	۵۰/۰۰	۵/۵۰	۴۴/۰۰
					۱۸/۴۰	۳۰۰/۰۰	۵۰/۰۰	۴/۰۰	۵۱/۰۰
					۱۸/۰۰	۳۰۰/۰۰	۵۰/۰۰	۱۰/۰۰	۱۱۶/۰۰
					۳۳/۳۰	۳۰۰/۰۰	۵۰/۰۰	۳/۴۰	۷۸/۰۰
					۳۳/۳۰	۳۰۰/۰۰	۵۰/۰۰	۵/۵۰	۱۱۰/۰۰
					۱۲/۳۰	۳۰۰/۰۰	۵۰/۰۰	۳/۴۰	۲۹/۰۰
					۶/۳۵	۱۳۹/۷۰	۲۵/۴۰	۳۸/۸۰	۶۵/۵۰
					۱۲/۳۰	۳۰۰/۰۰	۵۰/۰۰	۷/۲۰	۵۸/۰۰
					۱۲/۳۰	۳۰۰/۰۰	۵۰/۰۰	۸/۱۰	۸۱/۰۰
					۱۸/۴۰	۳۰۰/۰۰	۵۰/۰۰	۵/۵۰	۶۵/۵۰
					۱۸/۰۰	۳۰۰/۰۰	۵۰/۰۰	۷/۲۰	۸۶/۰۰
					۱۸/۴۰	۳۰۰/۰۰	۵۰/۰۰	۱۰/۰۰	۱۱۴/۰۰
					۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۵/۵۰	۵۹/۵۰
					۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۷/۲۰	۷۶/۵۰
					۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۱۰/۰۰	۸۷/۰۰
					۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۷/۲۰	۹۰/۰۰
					۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۱۰/۰۰	۱۵۱/۶۱
					۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۳/۴۰	۵۰/۰۰
					۲۰/۴۰	۳۰۰/۰۰	۵۰/۰۰	۵/۵۰	۷۵/۰۰

جدول ۲- مشخصات آماری مجموعه داده‌های ورودی و خروجی مدل

پارامتر	مجموعه داده‌های آموزش				مجموعه داده‌های آزمون			
	کمینه	بیشینه	میانگین	انحراف از معیار	کمینه	بیشینه	میانگین	انحراف از معیار
D (mm)	۶/۳۵	۳۳/۳	۱۷/۸۹	۱۷/۴۴	۱۲/۳	۲۵/۴	۱۷/۴۴	۴/۱۲
L (mm)	۱۳۰	۳۰۰	۲۸۱/۹۲	۲۶۹/۱۲۲	۱۳۲/۱	۳۰۰	۲۸۱/۹۲	۶۲/۹۶
e (mm)	۰	۵۰	۴۴/۶۴	۴۲/۶۴	۱۴/۳	۵۰/۱۴	۵۰/۱۴	۱۶/۸۶
S _u (kN/m ²)	۳/۴	۳/۴	۹/۷۸	۹/۴۸	۹/۵۲	۹/۵۲	۹/۷۸	۱۲/۴۸
Q _m (N)	۲۹/۵	۲۲۵	۷۷/۴	۶۱/۷۲	۴۰/۴۵	۴۰/۴۵	۴۰/۴۵	۲۹/۴۵

جدول ۳- تعیین پارامترهای بهینه مدل SVM باتابع کرنل چندجمله‌ای

تعیین d (C = 1.5, ε = 0.025)			تعیین ε (C = 1.5, d = 4.7)			تعیین C (ε = 0.025, d = 4.7)		
RMSE (N)	CC	d	RMSE (N)	CC	ε	RMSE (N)	CC	C
۲۷/۸۹۵۴	۰/۹۹۲۸	۰/۱	۹/۴۷۷۹	۰/۹۴۰۲	۰/۰۰۱	۲۷/۸۴۴۷	۰/۳۹۳۵	۰/۰۰۱
۱۵/۹۷۶۸	۰/۹۰۳۴	۱	۸/۰۱۹۴	۰/۹۵۷۶	۰/۰۰۵	۲۰/۴۳۷۹	۰/۷۶۱۷	۰/۰۱
۱۶/۹۱۰۲	۰/۸۹۹۶	۲	۶/۶۹۸۷	۰/۹۷۱۳	۰/۰۱	۱۱/۳۰۷۷	۰/۹۵۶۵	۰/۰۵
۹/۴۱۵	۰/۹۵۶۲	۳	۶/۱۹۱۵	۰/۹۷۷۵	۰/۰۱۵	۱۰/۴۵۷۱	۰/۹۶۲۴	۰/۱
۶/۵۲۰۴	۰/۹۷۲۹	۴	۴/۹۱۶۶	۰/۹۸۶۳	۰/۰۲	۴/۷۴۷۷	۰/۹۸۸۸	۰/۵
۴/۶۶۱۷	۰/۹۸۶۹	۴/۵	۴/۷۶۵۹	۰/۹۸۶۷	۰/۰۲۲	۴/۵۳۵۸	۰/۹۸۸۴	۱
۴/۵۹۹	۰/۹۸۷۳	۴/۶	۴/۵۷۷۶	۰/۹۸۸۱	۰/۰۲۴	۴/۵۵۲	۰/۹۸۸۶	۱/۴
۴/۴۷۷۹	۰/۹۸۸۷	۴/۷	۴/۴۷۷۹	۰/۹۸۸۷	۰/۰۲۵	۴/۴۷۷۹	۰/۹۸۷۷	۱/۵
۴/۶۱۴	۰/۹۸۸۹	۴/۸	۴/۵۸۸۶	۰/۹۸۸۱	۰/۰۲۶	۴/۵۰۳۳	۰/۹۸۸۸	۱/۶
۴/۵۸۱۸	۰/۹۸۹۴	۴/۹	۴/۸۶۳۶	۰/۹۸۶۶	۰/۰۲۸	۴/۵۹۲۶	۰/۹۸۸۱	۲
۴/۶۷۴۵	۰/۹۸۹۸	۵	۵/۱۲۶۴	۰/۹۸۵	۰/۰۳	۵/۱۴۹۳	۰/۹۸۴۶	۳
۵/۷۶۴۹	۰/۹۸۸۳	۶	۵/۷۸۱۳	۰/۹۷۸۵	۰/۰۵	۶/۵۱۶۲	۰/۹۷۲۷	۵
۷/۱۱۱۸	۰/۹۸۲۶	۸	۹/۳۲۶۲	۰/۹۵۱۱	۰/۰۷	۱۱/۵۳۳۳	۰/۹۱۷	۱۰
۷/۶۵۵۳	۰/۹۷۴۷	۱۰	۱۲/۵۴۲۸	۰/۹۵۳۳	۰/۱	۲۱/۶۰۷۵	۰/۷۸۱۴	۵۰
۱۴/۸۰۱۳	۰/۸۷۲۹	۲۰	۲۸/۰۳۱	۰/۹۰۲۵	۰/۲	۲۵/۷۶۵۷	۰/۷۲۶۸	۱۰۰
۳۹۷۹/۹۶	۰/۱۱۱۱	۵۰	۷۱/۱۶۹۳	۰	۰/۵	۳۰/۷۷۷۱	۰/۶۷۶۵	۵۰۰

نتایج حاصل از مدل SVM و روش‌های تحلیلی Hansen و Broms برای کل داده‌ها در قالب شاخص‌های آماری SVM در جدول (۵) ارائه شده است که نشان از برتری مدل SVM نسبت به روش‌های مذکور دارد.

روش دیگری که جهت مقایسه ارائه شده است، نمودار نسبت مقادیر ظرفیت باربری جانی تخمین زده شده به اندازه‌گیری شده در مقابل احتمال تجمعی (p) آن‌ها است. استفاده از تحلیل آماری فوق، اطلاعات ارزشمند و باکیفیتی را از توانایی پیش‌بینی و همبستگی تجربی به ما ارائه می‌دهد؛ بنابراین برای مجموعه‌های از اطلاعات، نسبت ظرفیت باربری جانی تخمین زده شده به اندازه‌گیری شده را به صورت صعودی و شماره‌گذاری شده ($i, 1, 2, 3, \dots, n$) مرتب می‌کنیم. همچنین مقدار احتمال تجمعی را برای هر ظرفیت باربری شمع طبق معادله زیر به دست می‌آوریم (Abu-Farsakh, Titi, ۲۰۰۴):

$$p = \frac{i}{r+1} \quad (16)$$

که در آن r ، شماره موردی که فاکتور احتمال تجمعی برای آن محاسبه می‌شود و r تعداد کل موارد بررسی است.

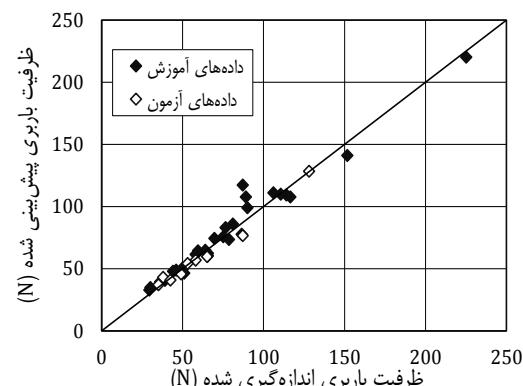
این روش در ارزیابی پراکندگی روش پیش‌بینی کننده حاوی اطلاعات ارزشمندی است:

۱- نسبت تخمین زده شده به اندازه‌گیری شده در احتمال $p = 50\%$ ، تمایل روش را به تخمین کم یا زیاد ظرفیت باربری جانی شمع نشان می‌دهد. هر چه این مقدار به ۱ نزدیک‌تر باشد، پیش‌بینی بهتری را انجام داده است.

۲- شبی خط بیانگر پراکندگی و انحراف استاندارد است. هر چه خط با شبی کمتری باشد نتیجه بهتری را نشان می‌دهد.

جدول ۴- نتایج عملکرد مدل بهینه بر مجموعه داده‌های آموزش و آزمون

E	RMSE (N)	CC	SVM
۰/۹۵۷	۸/۲۲۶	۰/۹۷۹۴	داده‌های آموزش
۰/۹۷۸	۴/۴۷۷۹	۰/۹۸۸۷	داده‌های آزمون



شکل ۵- مقایسه بین مقادیر پیش‌بینی و اندازه‌گیری شده توسط مدل SVM باتابع کرنل چندجمله‌ای

جدول ۵- نتایج عملکرد مدل ANN و روش‌های Broms و Hansen برای کل داده‌ها

E	CC	مدل
۰/۹۶۱	۰/۹۸۱	SVM
۰/۸۹۴	۰/۹۳۷	ANN
۰/۷۸۱	۰/۹۶۷	Broms
۰/۲۲۰	۰/۹۴۱	Hansen

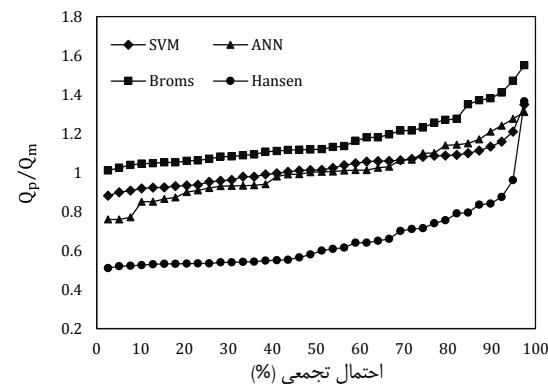
درنتیجه نتایج حاصل از این مدل تنها در محدوده داده‌های آموزش قابل کاربرد است. با این حال، هنگامی که داده‌های جدید در دسترس قرار گیرد، مدل SVM همواره قابل توسعه است و بدین وسیله می‌توان به نتایج جامعتری رسید (Kohestani و همکاران، ۲۰۱۶).

-۸- مراجع

- Abu-Farsakh MY, Titi HH, "Assessment of direct cone penetration test methods for predicting the ultimate capacity of friction driven piles", Journal of Geotechnical and Geoenvironmental Engineering, 2004, 130(9), 935-944.
- Ardakani A, Kohestani VR, "Evaluation of liquefaction potential based on CPT results using C4.5 decision tree", Journal of AI and Data Mining, 2015, 3(1), 85-89.
- Bhushan K, Fong PT, Haley SC, "Lateral load tests on drilled piers in stiff clays", Journal of the Geotechnical Engineering Division, 1979, 105(8), 969-985.
- Broms BB, "Lateral Resistance of Piles in Cohesive Soils", Journal of the Soil Mechanics and Foundations Division, 1964, 90(2), 27-64.
- Cortes C, Vapnik V, "Support-vector networks", Machine learning, 1995, 20(3), 273-297.
- Cristianini N, Shawe-Taylor J, "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods", 2000, Cambridge University Press.
- Das SK, Basudhar PK, "Undrained lateral load capacity of piles in clay using artificial neural network", Computers and Geotechnics, 2006, 33(8), 454-459.
- Dibike YB, Velickov S, Solomatine D, Abbott B, "Model induction with support vector machines: introduction and applications", Journal of Computing in Civil Engineering, 2001, 15(3), 208-216.
- Georgiadis K, Georgiadis M, Anagnostopoulos C, "Lateral bearing capacity of rigid piles near clay slopes", Soils and Foundations, 2013, 53(1), 144-154.
- Goh AT, Goh S, "Support vector machines: their use in geotechnical engineering as illustrated using seismic liquefaction data", Computers and Geotechnics, 2007, 34(5), 410-421.
- Hansen JB, Christensen N, "The Ultimate Resistance of Rigid Piles against Transversal Forces; Model Tests with Transversally Loaded Rigid Piles in Sand", 1961, Geoteknisk Institut.
- Jeanjean P, "Re-assessment of py curves for soft clays from centrifuge testing and finite element modeling", in Offshore Technology Conference, 2009, Offshore Technology Conference.
- Kohestani VR, Bazargan-Lari MR, Asgari marnani J, "Prediction of maximum surface settlement caused by earth pressure balance shield tunneling using random forest", Journal of AI and Data Mining, 2016, 5(1), 127-135.
- Kohestani VR, Hassanlourad M, "Modeling the Mechanical Behavior of Carbonate Sands Using

در شکل (۶)، نمودار ظرفیت باربری پیش‌بینی شده به اندازه‌گیری شده مقابله احتمال تجمعی برای روش‌های مختلف ترسیم شده است. برای احتمال Q_p/Q_m برای مدل SVM و ANN بسیار به ۱ نزدیک است. همان طور که از این شکل مشخص است، روش Broms تمایل به تخمین بالاتر از مقدار واقعی دارد و روش Hansen در تخمین ظرفیت باربری جانبی شمع‌ها محافظه‌کارانه عمل می‌کند.

ارائه خط با شبکه کمتر و همچنین پراکندگی کمتر توسط مدل SVM گویای نتیجه بهتر و پیش‌بینی دقیق‌تر از سایر روش‌ها است.



شکل ۶- نمودار احتمال تجمعی Q_p/Q_m برای مدل‌های مختلف (بخش Hansen و Broms برگرفته شده از DAS و Basudhar (۲۰۰۶).

-۷- نتیجه‌گیری

در این مقاله قابلیت روش ماشین بردار پشتیبان برای پیش‌بینی ظرفیت باربری جانبی شمع‌ها بر اساس مقاومت برشی زهکشی نشده خاک ارزیابی شده است. در این پژوهش ازتابع کرنل چندجمله‌ای برای گسترش مدل غیرخطی بر یک مجموعه داده شامل ۳۸ آزمون بارگذاری جانبی کوچک مقیاس شمع استفاده شده است. نتایج ارزیابی مدل بهینه گسترش داده شده بر روی داده‌های آزمون، مقادیر ضریب همبستگی ۰/۹۸۸۷ و ریشه میانگین مربعات خطای ۴/۴۷۷۹ نیوتن به دست آمدند. علاوه بر همبستگی بسیار خوب نتایج مدل SVM با مقادیر واقعی، با استفاده از تحلیل‌های آماری و احتمال تجمعی عملکرد این مدل با نتایج مدل ANN و روش Hansen و Broms مقایسه شد. نتایج حاصله برتری مدل ارائه شده در این پژوهش را تأیید می‌کند.

شایان ذکر است که این روش، مشابه سایر روش‌های مبتنی بر هوش مصنوعی، دامنه کاربرد محدودی دارد. این دامنه وابسته به داده‌هایی است که برای ساخت مدل استفاده شده است.

- 633-649.
- Samui P, "Prediction of friction capacity of driven piles in clay using the support vector machine", Canadian Geotechnical Journal, 2008, 45(2), 288-295.
- Samui P, "Prediction of pile bearing capacity using support vector machine", International Journal of Geotechnical Engineering, 2011a, 5(1), 95-102.
- Samui P, "Support vector machine applied to settlement of shallow foundations on cohesionless soils", Computers and Geotechnics, 2008b, 35(3), 419-427.
- Samui P, Sitharam T, Kurup PU, "OCR prediction using support vector machine based on piezocone data", Journal of Geotechnical and GeoEnvironmental engineering, 2008, 134(6), 894-898.
- Shahin MA, "Intelligent computing for modeling axial capacity of pile foundations", Canadian Geotechnical Journal, 2010, 47 (2), 230-243.
- Smola AJ, Schölkopf B, "A tutorial on support vector regression. Statistics and computing", 2004, 14(3), 199-222.
- Stewart D, "Reduction of undrained lateral pile capacity in clay due to an adjacent slope", Aust Geomech, 1999, 34(4), 17-23.
- Üstün B, Melssen WJ, Buydens LM, "Facilitating the application of support vector regression by using a universal Pearson VII function based kernel", Chemometrics and Intelligent Laboratory Systems, 2006, 81(1), 29-40.
- Witten IH, Frank E, "Data Mining: Practical machine learning tools and techniques", 2005, Morgan Kaufmann.
- Zhang MY, Liang L, Song HZ, Li Y, Peng WT, "Intelligent prediction for side friction of large-diameter and super-long steel pipe pile based on support vector machine", Applied Mechanics and Materials, 2012, 170, 747-750.
- Artificial Neural Networks and Support Vector Machines", International Journal of Geomechanics, 2015, 16(1), 04015038.
- Kohestani VR, Hassanlourad M, Ardakani A, "Evaluation of liquefaction potential based on CPT data using random forest", Natural Hazards, 2015, 79(2), 1078-1089.
- Kohestani V, Hassanlourad M, Bazargan-Lari MR, "Prediction the Ultimate Bearing Capacity of Shallow Foundations on the Cohesionless Soils Using M5P Model Tree", Journal of Civil Engineering, 2016, 27(2), 99-110. (in Persian)
- Kordjazi A, Pooya Nejad F, Jaksa M, "Prediction of ultimate axial load-carrying capacity of piles using a support vector machine based on CPT data", Computers and Geotechnics, 2014, 55, 91-102.
- Liu YJ, Liang SH, Wu JW, Fu N, "Prediction method of vertical ultimate bearing capacity of single pile based on support vector machine", Advanced Materials Research, 2011, 168, 2278-2282.
- Matlock H, "Correlations for design of laterally loaded piles in soft clay", Offshore Technology in Civil Engineering's Hall of Fame Papers from the Early Years, 1970, 77-94.
- Meyerhof G, Mathur S, Valsangkar A, "Lateral resistance and deflection of rigid walls and piles in layered soils", Canadian Geotechnical Journal, 1981, 18(2), 159-170.
- Pal M, Deswal S, "Modeling pile capacity using support vector machines and generalized regression neural network", Journal of geotechnical and geoenvironmental engineering, 2008, 134(7), 1021-1024.
- Poulos HG, Davis EH, "Pile foundation analysis and design", 1980, New York: Wiley.
- Rao KM, Suresh Kumar V, "Measured and predicted response of laterally loaded piles", in sixth international conference and exhibition on piling and deep foundations, 1996, India.
- Reese LC, Welch RC, "Lateral loading of deep foundations in stiff clay", Journal of the Geotechnical Engineering Division, 1975, 101(7),

EXTENDED ABSTRACT

Prediction of Lateral Bearing Capacity of Pile in Clay Using Support Vector Machine

Alireza Ardakani*, Vahid Reza Kohestani

Faculty of Engineering and Technology, Imam Khomeini International University, Qazvin, Iran

Received: 02 May 2016; Accepted: 12 March 2017

Keywords:

Support vector machine (SVM), Lateral bearing capacity, Pile, Undrained shear strength (S_u)

1. Introduction

A number of empirical formulas were proposed so as to reduce the time and cost involved in static approach to determine the pile capacity. Although these formulas have been widely used to predict pile capacity, it is agreed that these formulas are inaccurate due to their oversimplification of the modeling of the hammer, driving system, pile, and soil (Fragaszy et al. 1985). The support vector machine (SVM) is a relatively new artificial intelligence technique which is increasingly being applied to geotechnical problems. An important feature of the SVM is that it endeavors to discover the rules (or functions) that govern a phenomenon using only a set of data (a set of measured inputs and their corresponding outputs). Hence, there is no need to incorporate any assumptions to simplify the problem as, is often the case with many traditional methods. The previous studies indicated that these methods are more accurate compared to analytical formulas. In this paper, SVM technique is presented to predict the undrained lateral load capacity of piles in clay using the diameter of pile (D), depth of pile embedment (L), eccentricity of load (e), undrained shear strength of soil (S_u) as the inputs of model. The model was developed and tested using an experimental dataset. The performance of the proposed model (SVM) was compared with ANN and those of theoretical methods of Broms, and Hansen.

2. Support vector machines algorithm

The present study focuses on adapting the SVM algorithm to predicting the lateral bearing capacity of pile. SVM performs a supervised learning, where the model is adjusted to a dataset of examples that map inputs (independent variables) into a given target (the dependent variable). The SVM are a very specific class of algorithms, which is characterized by use of kernels, absence of local minima during the learning phase, sparseness of the solution and capacity control obtained by acting on the margin or on number of support vectors. When compared with other types of base learners, such as the widely used multilayer perceptron (also known as back-propagation ANN), SVM represents a significant enhancement in functionality, since it always achieves the optimal learning convergence, while ANNs might get stuck in local minima. By using a non-linear kernel, the SVM implicitly maps the input space into high-dimensional feature space. In this feature space, the algorithm finds the best linear separating hyperplane set of support vector points (most representative points). Hence, SVMs are capable of learning both simple (linear) and complex (non-linear) mapping functions. The present work adopted the popular Polynomial kernel, since it presents better result than other kernels. The stages involved in the process of developing an SVM model are briefly summarized in a flow chart in Fig. 1.

* Corresponding Author

E-mail addresses: a.ardakani@eng.ikiu.ac.ir (Alireza Ardakani), vrkohestani@gmail.com (Vahid Reza Kohestani).

3. Development of model

3.1. The data used for model development

In this paper, the input variables used in the development of the models are diameter of pile (D), depth of pile embedment (L), eccentricity of load (e), and undrained shear strength of soil (S_u). The lateral load capacity of pile (Q_m) is the single output variable. In the present study, the data are taken from previous literature (Rao and Suresh Kumar, 1996). The whole dataset consists of total 38 data points, 29 data points were considered for training and 9 for testing. The piles considered here are short and rigid piles.

For building the model, based on training data set, the SVM model implemented in WEKA software was used. To achieve the optimum SVM models, their design parameters, namely, the constants C , ε , and the kernel parameters have been identified using a trial-and-error process. Table 1 contains the design parameters of model.

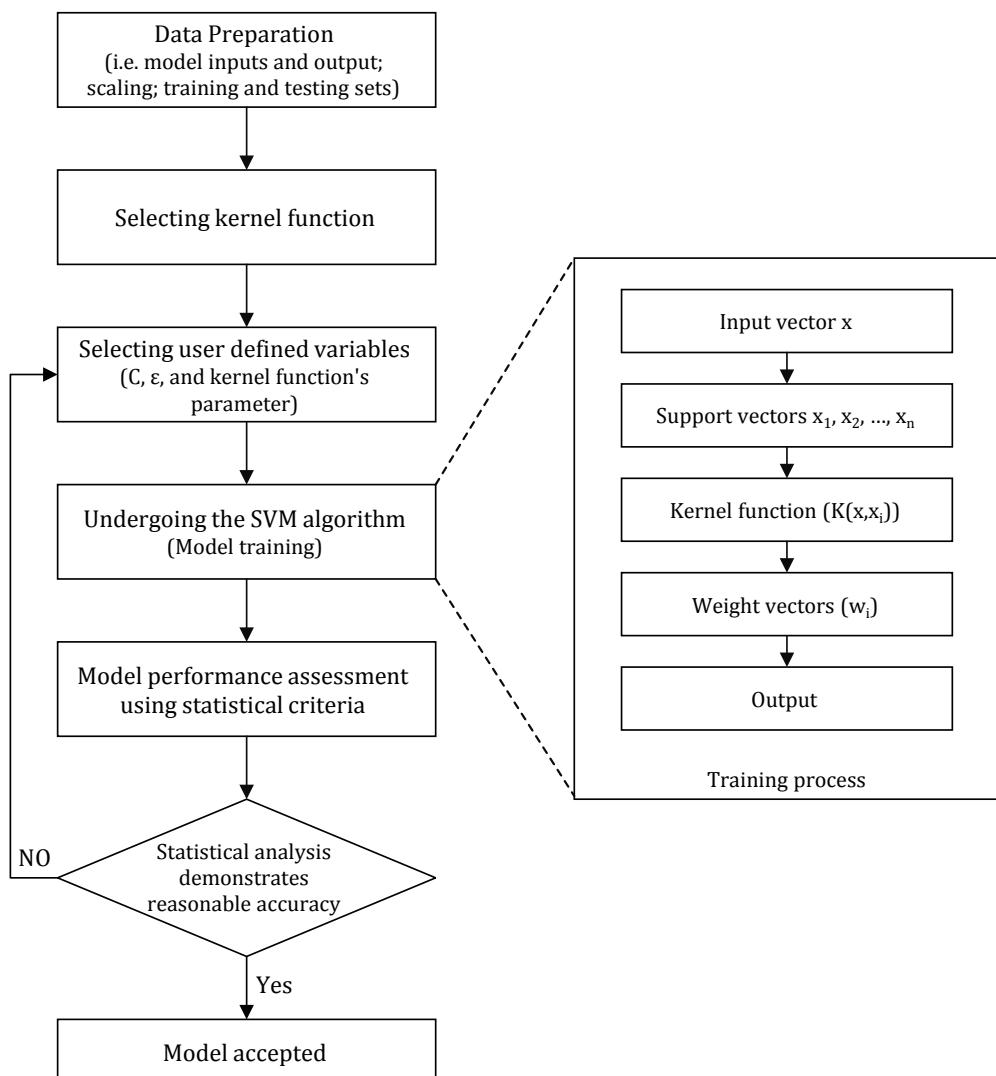


Fig. 1. The summary of steps involved in the process of model development using the SVM (Kordjazi et al. 2014)

Table 1. Design parameters of optimum models

Model	Kernel parameter	Optimum value of C	Optimum value of ε
SVM-POLY	$d = 4.7$	1.5	0.025

3.2. Criteria of evaluation

The performances of the model developed in this study have been assessed using various standard statistical performance evaluation criteria. The statistical measures considered have been correlation coefficient (R), root mean square error (RMSE), and efficiency factor (E).

4. Result

A comparative study has been carried out between the developed model (SVM) and traditional methods of Broms, and Hansen for the prediction lateral bearing capacity of pile (Q_m) in clay. Table 2 shows the values of performance indexes for the traditional methods, ANN (DAS and Basudhar, 2006) and developed model in this paper. The error indicators reveal that the result of the SVM model has much higher values of CC and E in comparison with the theoretical equations and ANN.

Table 2. Comparison between SVM model with theoretical methods for all dataset

Model	CC	E
SVM	0.981	0.961
ANN	0.937	0.894
Broms	0.967	0.781
Hansen	0.941	0.220

5. References

- Fragaszy RJ, Higgins JD, Lawton EC, "Development of guidelines for construction control of pile driving and estimation of pile capacity (Phase I)", 1985, Rep. No. WA-RD-68.1, Washington State Dept. of Transportation, Olympia, Wash.
- Rao KM, Suresh Kumar V, "Measured and predicted response of laterally loaded piles", in sixth international conference and exhibition on piling and deep foundations, 1996, India.
- Kordjazi A, Pooya Nejad F, Jaksa M, "Prediction of ultimate axial load-carrying capacity of piles using a support vector machine based on CPT data", Computers and Geotechnics, 2014, 55, 91–102.
- Das SK, Basudhar PK, "Undrained lateral load capacity of piles in clay using artificial neural network", Computers and Geotechnics, 2006, 33(1), 454–459.