



پیش بینی ظرفیت باربری نهایی شمع های تحت اثر بار محوری به کمک ماشین بردار پشتیبان

علیرضا کردجزی^۱، فریدون پویانزاد^۲

۱- دانشجوی کارشناسی ارشد مکانیک خاک و پی، دانشگاه فردوسی مشهد

۲- استادیار گروه عمران دانشکده مهندسی دانشگاه فردوسی مشهد

pooyaf@ferdowsi.um.ac.ir

خلاصه

پیش بینی ظرفیت باربری شمع های تحت اثر بار محوری یکی از مسائل اساسی در مهندسی ژئوتکنیک بوده و تاکنون روش های گوناگونی برای ارزیابی آن معرفی شده است. در این مقاله از یک روش یادگیری ماشینی با عنوان ماشین بردار پشتیبان (SVM) برای پیش بینی ظرفیت باربری نهایی شمع های تحت اثر بار محوری استفاده شده است. مدل ارائه شده بر مبنای نتایج آزمایش نفوذ مخروط گسترش داده شده است. یک مجموعه داده شامل ۱۰۸ نمونه از نتایج آزمون بارگذاری استاتیکی شمع در مقیاس واقعی، نتایج آزمایش نفوذ مخروط (CPT) در مجاورت آن ها و خواص هندسی شمع برای آموزش و ارزیابی عمل کرد مدل مورد استفاده قرار گرفته است. در این مدل علاوه بر ارزیابی ظرفیت باربری نهایی شمع های تحت اثر بار محوری، به بررسی حساسیت ظرفیت باربری نهایی نسبت به متغیرهای ورودی مدل، پرداخته شده است. با مقایسه نتایج به دست آمده با مقادیر واقعی، کارایی مناسب مدل تأیید می شود.

کلمات کلیدی: آزمایش بارگذاری استاتیکی شمع، آزمایش نفوذ مخروط، ظرفیت باربری نهایی شمع، ماشین بردار پشتیبان.

۱. مقدمه

اثر مستقیم عمل کرد پی ها بر ایمنی و کارایی سازه های بنا شده بر آن ها، ضرورت پیش بینی صحیح رفتار این اجزا را ایجاب می کند. به همین دلیل پیش بینی صحیح ظرفیت باربری پی ها، به عنوان یک فاکتور موثر در رفتار پی ها، یکی از مسائل مهم در مهندسی ژئوتکنیک به شمار می رود. شمع ها یکی از انواع متداول پی ها هستند که تاکنون روش های گوناگون تجربی و تئوری برای ارزیابی ظرفیت باربری آن ها ارائه شده است. به علت پیچیدگی رفتار شمع ها در خاک و مشکلات موجود در برآورد عوامل موثر بر این کمیت، روش های موجود قادر به پیش بینی صحیح ظرفیت باربری نیستند و بنابراین نیاز به روش های جدید برای پیش بینی ظرفیت باربری شمع ها هم چنان وجود دارد.

دشواری های تهیه نمونه های دست نخورده برای تعیین پارامترهای مکانیکی خاک سبب گرایش به استفاده از آزمایش های برجا در بسیاری از روش های پیش بینی ظرفیت باربری شمع ها شده است. آزمایش هایی مانند آزمایش نفوذ مخروط (CPT)، نفوذ استاندارد (SPT)، پرسو متری و دیلاتو متری از جمله آزمایش های بر جای پر کاربرد در این زمینه می باشند [1]. به علت شباهت میان مخروط در آزمون نفوذ مخروط و شمع، تعیین ظرفیت باربری به کمک نتایج CPT از مهم ترین کاربردهای این آزمایش به شمار می آید [2].

در دهه های اخیر به کارگیری روش های یادگیری ماشینی در مسائل مهندسی ژئوتکنیک در پژوهش های گوناگونی ذکر شده است [3,4]. روش ماشین بردار پشتیبان یکی از روش های نسبتاً جدید یادگیری ماشینی است که نتایج خوبی در مدل سازی پدیده های ژئوتکنیکی داشته است [5,6,7].

در این پژوهش جهت پیش بینی ظرفیت باربری نهایی شمع های تحت اثر بار محوری به کمک ماشین بردار پشتیبان مدلی بر مبنای نتایج حاصل از آزمایش نفوذ مخروط (CPT) گسترش داده شده است. در انتها نیز حساسیت مدل ارائه شده برای محاسبه ظرفیت باربری نهایی نسبت به متغیرهای ورودی بررسی خواهد شد.

۲. ماشین بردار پشتیبان (SVM)

روش ماشین بردار پشتیبان یکی از روش‌های یادگیری ماشینی است که بر مبنای تئوری یادگیری آماری Vapnik در دهه ۹۰ میلادی توسط Vapnik و همکارانش ارائه گردید. در SVM از اصول کمینه‌سازی ریسک ساختاری (SRM) استفاده شده است، در حالی که سایر روش‌ها از اصول کمینه سازی ریسک تجربی (ERM) بهره می‌برند. ثابت شده است که اصول SRM در مقایسه با ERM عمل کرد بهتری از خود نشان می‌دهند [4]. از ماشین بردار پشتیبان به‌طور کلی در مسائل طبقه‌بندی دو یا چند گروه و رگرسیون استفاده می‌شود. مانند بسیاری از روش‌های یادگیری ماشینی، در روش ماشین بردار پشتیبان نیز فرآیند ساخت مدل شامل دو مرحله آموزش و آزمایش می‌باشد. در انتهای فاز آموزش قابلیت تعمیم یابی مدل آموزش داده شده با استفاده از داده‌های آزمایش ارزیابی می‌شود. به‌صورت خلاصه سازو کار اصلی SVM در حل مساله رگرسیون را به صورت زیر بیان می‌شود:

(۱) ماشین بردار پشتیبان، تابع رگرسیون را با به کارگیری یک دسته تابع خطی تخمین می‌زند. (۲) ماشین بردار پشتیبان عملیات رگرسیون را با تابعی که انحراف از مقدار واقعی در آن به میزان کمتر از ε مجاز است انجام می‌دهد (تابع تلفات). (۳) ماشین بردار پشتیبان، با کمینه کردن ریسک ساختاری، بهترین جواب را ارائه می‌دهد. [8].

در روش‌هایی مانند شبکه‌های عصبی مصنوعی برای رسیدن به بهترین جواب از اصول کمینه‌سازی ریسک تجربی استفاده می‌شود، با کمینه کردن ریسک تجربی کارآیی مناسب مدل بر روی داده‌های آموزش تضمین می‌شود، اما تضمینی برای قابلیت تعمیم‌یابی مناسب وجود ندارد، به همین دلیل در این روش طراحی مناسب شبکه برای بهبود عمل کرد تعمیم‌یابی مدل ضروری است. هدف از کمینه‌سازی ریسک ساختاری، بهینه کردن قابلیت تعمیم‌یابی مدل، هم‌زمان با کمینه کردن ریسک تجربی است [8].

حل مساله رگرسیون در SVM یک تابع خطی به شکل $f(x) = \langle w, x \rangle + b$ است که بر روی یک مجموعه شامل l نمونه مانند $\{(x_1, y_1), \dots, (x_l, y_l) \in R^N, y \in R\}$ بتواند مقادیر خروجی را بر مبنای ورودی‌ها تخمین بزند. در رابطه فوق x بردار مقادیر ورودی و $(w, b) \in R^N \times R$ پارامترهای کنترل کننده تابع f هستند. $\langle w, x \rangle$ نشان‌گر ضرب داخلی می‌باشد. برای حل مساله رگرسیون تابع تلفات Vapnik^۱ که در آن حداقل خطایی به میزان ε قابل صرف نظر کردن است، مورد استفاده قرار می‌گیرد. این تابع تلفات به شکل زیر تعریف می‌شود [8]:

$$L_\varepsilon(y) = |y - f(x)|_\varepsilon = \begin{cases} 0 & |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & \text{otherwise} \end{cases} \quad (1)$$

$L_\varepsilon(y)$ معرف تابع تلفات و ε میزان خطای مجاز در تابع تلفات می‌باشد. پارامترهای کنترل کننده تابع رگرسیون بهینه با حل مساله بهینه سازی زیر حاصل می‌شوند [9]:


$$\text{Minimise } \Phi(w, \zeta^*, \zeta) = \frac{\|w\|^2}{2} + C \left(\sum \zeta_i^* + \sum \zeta_i \right) \quad (2)$$

$$\text{Subject to } \begin{aligned} y_i - ((w \cdot x_i) + b) &\leq \varepsilon + \zeta_i \\ ((w \cdot x_i) + b) - y_i &\leq \varepsilon + \zeta_i^* \\ \zeta_i, \zeta_i^* &\geq 0 \end{aligned} \quad (2\text{-الف})$$

در رابطه فوق ζ_i^* متغیرهای slack هستند. این متغیرها به همراه تابع تلفات در شکل ۱ نشان داده شده‌اند. برای حل مساله بهینه‌سازی فوق، به کمک تئوری لاگرانژ، تابع لاگرانژ مطابق رابطه ۳ نوشته می‌شود.

^۱ Support Vector Machine

^۲ loss function



شکل ۱- تابع تلفات Vapnik و متغیرهای slack [10]

$$L(\alpha^*, \alpha) = -\varepsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i) + \sum_{i=1}^l y_i (\alpha_i^* - \alpha_i) - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) (x_i, x_j) \quad (3)$$

با پیشینه شدن تابع فوق تحت قیدهای زیر، مقادیر ضرایب α, α^* بدست می آیند. این ضرایب، ضرایب لاگرائز نامیده می شوند.

$$\begin{cases} \sum \alpha_i^* = \sum \alpha_i \\ 0 \leq \alpha_i^* \leq C \quad \text{for } i = 1, 2, \dots, l \\ 0 \leq \alpha_i \leq C \end{cases} \quad (4)$$

مساله بهینه سازی فوق به کمک روش های QP¹ قابل حل می باشد، در نتیجه رسیدن به اکسترمم کلی نیز قطعی خواهد بود و خطر به دام افتادن در اکسترمم محلی وجود ندارد. داده هایی که ضرایب لاگرائز متناظر با آنها غیر صفر باشد، به عنوان بردار پشتیبان شناخته می شوند [9]. از نظر هندسی این داده ها دارای خطای پیش بینی بزرگتر از $\pm \varepsilon$ هستند، بنابراین بردارهای پشتیبان درون باند $\pm \varepsilon$ قرار نمی گیرند. بنابراین مقدار ε تعداد بردارهای پشتیبان را کنترل می کند [8].

به کمک ضرایب لاگرائز و بردارهای پشتیبان، پارامترهای کنترل کننده پاسخ بهینه نیز به صورت زیر محاسبه می شوند [4]:

$$w_0 = \sum_{\text{sup portvectors}} (\alpha_i^* - \alpha_i) x_i \quad (5)$$

$$b_0 = -\left(\frac{1}{2}\right) w_0 \cdot [x_r + x_s] \quad (6)$$

$$f(x) = \sum_{\text{sup portvectors}} (\alpha_i^* - \alpha_i) (x_i - x) + b_0 \quad (7)$$

در رابطه ۶، x_r, x_s دو بردار پشتیبان هستند.

برای ساخت مدل ماشین بردار پشتیبان، پارامترهای C و ε توسط کاربر تعریف می شوند. پارامتر C یک پارامتر تنظیمی است و می تواند مقادیر صفر تا بی نهایت را بپذیرد. نقش این پارامتر ایجاد تعادل میان کمینه کردن ریسک تجربی و پیشینه کردن قابلیت تعمیم یابی است. پارامتر ε نیز می تواند مقادیر صفر تا بی نهایت را بپذیرد. مقدار این پارامتر در وضعیت بردارهای پشتیبان و در نتیجه کارایی مدل بسیار موثر است.

مساله رگرسیون خطی در SVM به آسانی قابل گسترش به رگرسیون غیر خطی است. بدین منظور از توابع کرنل استفاده می شود. تا کنون کرنل های گوناگونی شناخته شده اند [10]، اما کاربرد همراه با موفقیت کرنل های چند جمله ای و پایه شعاعی (rbf) در مسائل مهندسی ژئوتکنیک گزارش شده اند [6, 8, 11]. بدین ترتیب در حالت رگرسیون غیر خطی در SVM پارامترهای کنترل کننده تابع بهینه با روابط زیر محاسبه می شوند [4]:

$$w_0 \cdot x = \sum_{\text{sup portvectors}} (\alpha_i^* - \alpha_i) K(x_i, x) \quad (8)$$

$$b_0 = -\frac{1}{2} \sum_{\text{sup portvectors}} (\alpha_i^* - \alpha_i) [K(x_r, x_i) + K(x_s, x_i)] \quad (9)$$

¹. Quadratic Programming Method

در این روابط (K, ρ) نشان گر تابع کرنل می باشد.

۳. داده های مورد استفاده

برای گسترش مدل ماشین بردار پشتیبان برای پیش بینی ظرفیت باربری نهایی شمع ها از یک مجموعه داده شامل ۱۰۸ نمونه استفاده شده است. هر نمونه در برگیرنده مشخصات هندسی شمع، نتایج آزمون بارگذاری استاتیکی شمع در مقیاس واقعی و همچنین نتایج آزمون نفوذ مخروطی می باشد. داده های مورد استفاده در این مقاله از پویانژاد [۱۲] و Eslami [13] اقتباس شده است.

ظرفیت باربری نهایی اندازه گیری شده از نتایج آزمایش بارگذاری استاتیکی شمع در مقیاس واقعی استخراج شده است، برای شمع هایی که در طول انجام آزمایش به گسیختگی رسیدند، بار گسیختگی به عنوان ظرفیت باربری نهایی شمع در نظر گرفته شده است، برای سایر شمع ها نیز معیار $0.8/P_u$ که توسط Hansen [14] ارائه شده، مورد استفاده قرار گرفته است.

۴. ورودی ها و خروجی های مدل

دستیابی به یک مدل کارآمد جهت پیش بینی ظرفیت باربری شمع ها نیازمند شناسایی پارامترهای موثر در ظرفیت باربری شمع ها می باشد. بسیاری از روش های موجود مصالحی که شمع از آن ها ساخته شده است، هندسه شمع، خصوصیات مکانیکی خاک و بار اعمال شده را مهمترین فاکتورها در ظرفیت باربری می دانند. در این مقاله از نتایج آزمون نفوذ مخروط برای در نظر گرفتن خصوصیات خاک استفاده شده است. نتایج آزمون نفوذ مخروط شامل مقاومت نوک مخروط (q_c) در امتداد طول شمع و همچنین اصطکاک جدار مخروط (f_s) می باشد. برای دقت بیشتر طول مدفون شمع به سه قسمت مساوی تقسیم شد و مقادیر متوسط q_c و f_s در هر بخش محاسبه شده است. مقدار q_c متوسط در زیر نوک شمع نیز محاسبه گردید.

به این ترتیب پارامترهای ورودی مدل SVM عبارتند از (۱) نوع آزمایش بارگذاری استاتیکی شمع (CRP یا ML)، (۲) نوع مصالح شمع (فولادی، بتنی یا کامپوزیت)، (۳) طریقه نصب شمع (کوبیده شده یا حفاری شده)، (۴) انتهای شمع (باز یا بسته بودن)، (۵) طول مدفون شمع (L_{embed})، (۶) محیط خارجی شمع (O)، (۷) مساحت نوک شمع (A_{tip})، (۸) مقادیر متوسط نوک مخروط در طول شمع (q_{c1}, q_{c2}, q_{c3})، (۹) مقادیر متوسط مقاومت جدار مخروط در طول شمع (f_{s1}, f_{s2}, f_{s3})، (۱۰) مقدار متوسط مقاومت نوک مخروط زیر نوک شمع (q_{ctip}). تنها خروجی این مدل نیز مقدار ظرفیت باربری نهایی شمع (P_u) است.

۵. آماده سازی داده ها و آموزش مدل

برای گسترش یک مدل ماشین بردار پشتیبان داده ها به دو دسته آموزش و آزمایش تقسیم بندی می شوند [8,4]. مدل مورد نظر توسط داده های مجموعه آموزش، آموزش داده می شود و کارایی مدل در پیش بینی کمیت مورد نظر به کمک داده هایی که در طول آموزش مدل توسط مدل تجربه نشده اند (مجموعه داده های آزمایش)، بررسی می گردد.

یک روش آماده سازی مجموعه داده ها، تقسیم کل نمونه ها به دو دسته آموزش و آزمایش به صورت تصادفی است. در مقالاتی که از شبکه های عصبی مصنوعی استفاده شده است، توصیه شده که در صورتی که شاخص های آماری (شامل میانگین و انحراف استاندارد) هر یک از متغیرها در مجموعه آموزش و آزمایش نزدیک به یکدیگر باشد، نتایج با دقت بالاتری قابل انتظار خواهد بود [15,3]. توجه به این نکته می تواند راهنمای مناسبی برای آماده کردن داده ها به روش تقسیم بندی تصادفی باشد. راه کار دیگری که برای آماده سازی داده ها وجود دارد استفاده از روش اعتبار سنجی K باره^۱ (یا K تایی) می باشد. در این روش کل داده ها به K دسته تقریباً هم اندازه تقسیم می شوند. (K-1) دسته برای آموزش مدل و دسته باقیمانده برای آزمایش مدل به کار می رود. به این ترتیب، به تعداد K مرتبه مدل آموزش و آزمایش می شود. مزیت این روش این است که سر انجام همه نمونه های

¹ K-fold Cross Validation

موجود در هر دو فرآیند آموزش و آزمایش شرکت می کنند [7]. در این مقاله تقسیم بندی کل داده‌ها به مجموعه داده‌های آموزش و آزمایش به روش اعتبارسنجی متقابل ۵ باره (K=5) انجام شده است.

پیش از شروع آموزش مدل، داده‌ها به بزرگترین مقدار متناظرشان تقسیم شده تا به مقدارهای بین صفر و یک مقیاس (نرمالیزه) شوند. این کار موجب می‌شود اثر مقیاس واقعی^۱ کمینه شده [5] و همه ورودی‌ها تقریباً در یک دامنه قرار گیرند.

برای آموزش مدل SVM نظر از تابع تلفات Vapnik یا به عبارت دیگر تابع غیر حساس به ϵ استفاده شده است و مقادیر ϵ و C (پارامتر تنظیم یا جریمه) برای گسترش مدل در فرآیند سعی و خطا، تعیین شده‌اند. همچنین به منظور ایجاد یک مدل غیرخطی از تابع کرنل با پایه شعاعی (rbf) استفاده می‌شود.

$$K(x, x_i) = \exp\left(-|x - x_i|^2 / 2\sigma^2\right) \quad (10)$$

در رابطه بالا σ عرض کرنل با پایه شعاعی می‌باشد و مقدار آن توسط کاربر تعیین می‌شود.

در این مقاله برای آموزش مدل و ارزیابی آن بر روی داده‌های آزمایش، از جعبه ابزار SVM استفاده شده است [16]. شاخص‌های مورد استفاده برای ارزیابی مدل نیز شامل ضریب همبستگی و ریشه میانگین مربعات خطاها (RMSE) می‌باشد.

۴. نتایج

در این مقاله یک مدل ماشین بردار پشتیبان برای پیش‌بینی ظرفیت باربری نهایی شمع‌های تحت اثر بار محوری گسترش داده شده است. آماده‌سازی داده‌ها به دو دسته داده‌های آموزش و آزمایش به روش اعتبارسنجی ۵ باره انجام شده و به منظور گسترش یک مدل غیرخطی از تابع کرنل پایه شعاعی (rbf) استفاده شده است. برای دستیابی به مدل بهینه، مدل ماشین بردار پشتیبان با ترکیب‌های گوناگونی از پارامترهای تعریف‌کننده مدل (C، ϵ ، σ و پارامتر تابع کرنل σ) بر روی داده‌های آموزش، آموزش داده شده و عمل کرد مدل بر روی داده‌های آزمایش بررسی می‌شود. پارامترهای تعریف‌کننده مدل در یک فرآیند سعی و خطا به گونه‌ای تعیین شده‌اند که مدل قابلیت پیش‌بینی ظرفیت باربری نهایی نمونه‌های مجموعه آزمایش را با کمترین میزان RMSE و بزرگترین مقدار ضریب همبستگی نسبت به مقادیر اندازه‌گیری شده داشته باشد.

نتایج بهترین مدل به ازای $C=2/2$ ، $\epsilon=0/02$ و $\sigma=0/9$ بر روی هر یک از ۵ دسته حاصل از روش اعتبارسنجی متقابل در جدول ۱ خلاصه شده است. در این جدول تعداد بردارهای پشتیبان و ضریب همبستگی مدل بر روی هر یک از داده‌های آموزش و آزمایش به ازای هر یک از مدل‌های حاصل از روش اعتبارسنجی متقابل ارائه شده است. با توجه به این جدول مشاهده می‌شود، مدلی که از دسته دوم داده‌های به دست آمده از روش اعتبارسنجی متقابل به عنوان داده‌های آزمایش و از سایر داده‌ها به عنوان داده‌های آموزش استفاده شده است، بهترین عملکرد را ارائه می‌دهد. همان‌طور که مشاهده می‌شود این مدل با $RMSE=290/84kN$ و ضریب همبستگی $0/967$ ، دقت مناسبی در پیش‌بینی ظرفیت باربری نشان می‌دهد. مقادیر شاخص‌های آماری داده‌های هر یک از متغیرهای این مدل در مجموعه‌های آموزش و آزمایش در جدول ۲ خلاصه شده است. شکل ۲ نیز نمودار مقادیر اندازه‌گیری شده در برابر مقادیر پیش‌بینی شده ظرفیت باربری نهایی را برای این مدل بهینه نشان می‌دهد.

جدول ۱- نتایج عمل کرد مدل بهینه بر مجموعه داده‌های آموزش و آزمایش

شماره مدل	تعداد بردارهای پشتیبان	نتایج بر روی مجموعه داده‌های آموزش		نتایج بر روی مجموعه داده‌های آزمایش	
		R	RMSE(kN)	R	RMSE(kN)
دسته اول	63	0.987	288.888	0.865	959.704
دسته دوم	59	0.986	320.97	0.967	290.84
دسته سوم	59	0.993	208.157	0.791	1098.180
دسته چهارم	59	0.982	306.203	0.276	2248.119
دسته پنجم	54	0.992	224.338	0.846	891.058

¹. Absolute Scale

برای بررسی حساسیت ظرفیت باربری نهایی نسبت به متغیرهای ورودی از روشی که توسط Liong و همکاران [17] ارائه شده است، استفاده شد. در این روش هر بار یکی از متغیرهای ورودی به اندازه مقداری ثابت تغییر می کند و مقدار خروجی به ازای این ورودی های جدید محاسبه می شود. در این مقاله نرخ تغییر ۱۰٪ به کار گرفته شده است. مقدار حساسیت نیز از رابطه زیر محاسبه می شود:

$$X_i = \frac{1}{n} \sum_{j=1}^n \left(\frac{\text{درصد تغییر خروجی}}{\text{درصد تغییر ورودی}} \right)_j \times 100 \quad (12)$$

در رابطه فوق n ، تعداد نمونه ها در آنالیز حساسیت می باشد.

در تحلیل حساسیت، از متغیرهای مساحت نوک شمع، پیرامون شمع در تماس با خاک و مشخصات خاک در قالب q_c و f_s و q_{ctip} استفاده

جدول ۲ - مشخصات آماری مجموعه داده های ورودی و خروجی در مدل بهینه

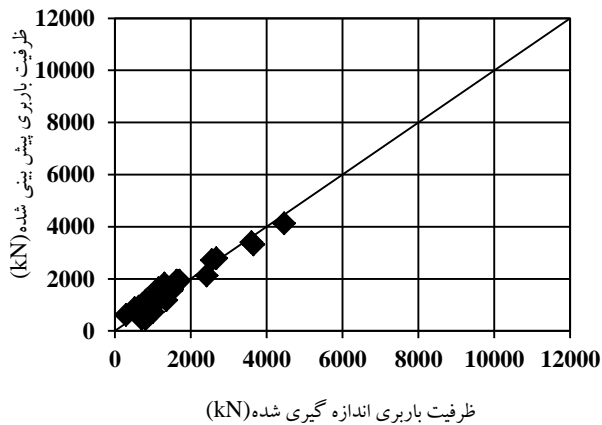
	میانگین	انحراف استاندارد	مینیمم	ماکزیمم	دامنه
$A_{tip}(m^2)$					
مجموعه داده های آموزش	0.1836	0.1805	0.0080	0.7854	0.7774
مجموعه داده های ارزیابی	0.1475	0.0994	0.0080	0.3420	0.3340
$O(mm)$					
مجموعه داده های آموزش	1633.60	862.84	585.00	7341.30	6756.30
مجموعه داده های ارزیابی	1387.71	397.66	785.00	2070.00	1285.00
$L_{embed}(m)$					
مجموعه داده های آموزش	16.20	10.76	5.50	67.00	61.50
مجموعه داده های ارزیابی	14.44	6.15	6.50	34.25	27.75
$q_{c1}(MPa)$					
مجموعه داده های آموزش	3.95	3.16	0.02	15.07	15.05
مجموعه داده های ارزیابی	4.39	2.90	0.99	10.04	9.05
$f_{s1}(kPa)$					
مجموعه داده های آموزش	76.05	60.79	0.73	283.93	283.20
مجموعه داده های ارزیابی	62.72	30.87	12.87	141.44	128.57
$q_{c2}(MPa)$					
مجموعه داده های آموزش	6.24	5.91	0.44	30.71	30.27
مجموعه داده های ارزیابی	5.61	3.66	0.32	18.42	18.10
$f_{s2}(kPa)$					
مجموعه داده های آموزش	109.72	99.02	2.12	618.67	616.54
مجموعه داده های ارزیابی	78.81	39.62	5.00	155.75	150.75
$q_{c3}(MPa)$					
مجموعه داده های آموزش	7.10	6.07	0.27	32.59	32.32
مجموعه داده های ارزیابی	7.51	4.72	0.65	23.06	22.41
$f_{s3}(kPa)$					
مجموعه داده های آموزش	130.87	98.29	10.00	396.57	386.57
مجموعه داده های ارزیابی	124.67	91.78	7.99	380.00	372.01
$q_{ctip}(MPa)$					
مجموعه داده های آموزش	8.74	6.16	0.25	27.11	26.86
مجموعه داده های ارزیابی	9.10	6.43	0.85	22.30	21.45
$P_u(kN)$					
مجموعه داده های آموزش	2080.50	1837.27	63.90	10910.00	10846.10
مجموعه داده های ارزیابی	1599.13	1086.05	290.00	4460.00	4170.00

و در نهایت درصد تاثیر هر یک از پارامترهای فوق نسبت به سایر پارامترها در جدول ۳ ارائه شده است. این جدول نشان می‌دهد که مشخصات خاک در قالب نتایج آزمایش CPT با دارا بودن بیشترین نسبت تأثیر، بیشترین تأثیر را بر ظرفیت باربری نهایی شمع دارد.


جدول ۳- نتایج تحلیل حساسیت در مدل بهینه ماشین بردار پشتیبان

متغیر ورودی	نسبت تأثیر متغیر ورودی (%)
A_{tip}	15.31
O	11.92
L_{embed}	17.75
q_{cav}	22.90
f_{sav}	22.06
q_{ctip}	10.06

نتایج به دست آمده نشان می‌دهد که ماشین بردار پشتیبان عمل کرد قابل قبولی در پیش‌بینی ظرفیت باربری نهایی شمع‌های تحت اثر بار محوری در محدوده اطلاعات نمونه‌های مورد استفاده دارا می‌باشد و علاوه بر آن استفاده از تکنیک اعتبار سنجی متقابل، یک ابزار مناسب برای آماده‌سازی مجموعه داده‌های آموزش و آزمایش می‌باشد.



(ب)



(الف)

شکل ۲: ظرفیت باربری اندازه گیری شده در برابر ظرفیت باربری پیش‌بینی شده توسط مدل بهینه SVM؛ (الف) بر روی داده‌های مجموعه آموزش، (ب) بر روی مجموعه داده‌های آزمایش

۸. نتیجه گیری

در این مقاله از یک مدل غیر خطی ماشین بردار پشتیبان به همراه تابع کرنل پایه شعاعی برای پیش‌بینی ظرفیت باربری نهایی شمع‌های تحت اثر بار محوری استفاده شده است. یک مجموعه داده شامل ۱۰۸ نمونه از اندازه گیری‌های میدانی از شمع‌ها در مقیاس واقعی و نتایج آزمایش نفوذ مخروط (CPT) در مجاورت آن‌ها مورد استفاده قرار گرفته شده است. این داده‌ها به روش اعتبار سنجی متقابل به دسته‌های آموزش و آزمایش جهت گسترش مدل ماشین بردار پشتیبان به تقسیم شده اند. مقایسه نتایج حاصل از مدل با مقادیر واقعی نشان می‌دهد که مدل ماشین بردار پشتیبان دارای دقت مناسبی در پیش‌بینی ظرفیت باربری شمع‌ها در محدوده داده‌های مورد استفاده می‌باشد، به طوری که در نتایج ارزیابی مدل بهینه بر روی داده‌های آزمایش، مقادیر $R=0.967$ و $RMSE=290.84kN$ برای ظرفیت‌های باربری تا حدود $11000 kN$ به دست آمده‌اند. هم‌چنین نتایج به دست آمده کارایی تکنیک اعتبار سنجی متقابل را برای آماده‌سازی مجموعه داده‌های آموزش و آزمایش تأیید می‌کند. نتایج تحلیل حساسیت بر روی مدل نیز نشان می‌دهد که مشخصات خاک (در قالب نتایج آزمایش CPT) مهم‌ترین متغیر بر میزان ظرفیت باربری می‌باشد.



1. Shahin, M. A. (2010). "Intelligent computing for modeling axial capacity of pile foundations." *Canadian Geotechnical Journal*, 47, 230-243.
2. Abu-Farsakh, M. Y. and Titi, H. H. (2004). "Assessment of direct cone penetration test methods for predicting the ultimate capacity of friction driven piles." *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, 130(9), 935-944.
3. Shahin, M. A., Maier, H. R., Jaksa, M.B. (2004). "Data division for developing neural networks applied to geotechnical engineering." *Journal of Computing in Civil Engineering*, ASCE, 18(2), 105-14.
4. Dibike, Y.B., Velikov, S., Solomatine, D. and Abbot, M.B. (2001). "Model induction with support vector machines-introduction and applications." *Journal of Computing in Civil Engineering*, ASCE, 15(3), 208-216.
5. Goh, A.T.C. and Goh, S.H. (2007). "Support vector machines :Their use in geotechnical engineering as illustrated using seismic liquefaction data." *Computers and Geotechnics*, 34, 410-421.
6. Pal, M. and Deswal, S. (2010). "Modeling pile capacity using gaussian process regression." *Computers and Geotechnics*, 37, 942-947.
7. Oommen, T. and Baise, L. G. (2010). "Model development and validation for intelligent data collection for lateral spread displacements." *Journal of Computing in Civil Engineering*, ASCE, 24(6), 467-477.
8. Samui, P. (2008). "Support vector machine applied to settlement of shallow foundations on cohesionless soils." *Computers and Geotechnics*, 35, 419 - 427.
9. Cristianini, N., Shaw-Taylor, J. (2000). *An introduction to support vector machines and other kernel-based learning methods*. Cambridge: Cambridge University Press.
10. Smola, A. J. and Scolkopf, B. (1998). "Tutorial on support vector regression, NeuroCOLT2 technical report series." *NC2-TR-1998-03*.
11. Pal, M. and Deswal, S. (2008). "Modeling pile capacity using support vector machines and generalized regression neural network." *Journal of Computing in Civil Engineering*, ASCE, 134(7), 1021-1024.
۱۲. پویا نژاد، ف. (۱۳۸۸)، "پیش بینی نشست شمع ها به کمک شبکه های عصبی مصنوعی"، پایان نامه دکتری، دانشگاه فردوسی، مشهد، ایران.
13. Eslami, A. (1996) "bearing capacity of piles from cone penetration test data." Ph.D. thesis, University of Ottawa, Ottawa.
14. Hansen, J.B. (1963). "Discussion on hyperbolic stress-strain response." *Cohesive soils. Journal for Soil Mechanics and Foundation Engineering*, ASCE, 89, SM4, pp. 241 - 242.
15. Pooya Nejad, F., Jaksa, M.B., Kakhi, M. and McCabe, B.A. (2009). "Prediction of pile settlement using artificial neural networks based on standard penetration test data." *Computers and Geotechnics*, 36, 1125-1133.
16. Gunn, R. (2001). <http://www.isis.ecs.soton.ac.uk/isystems/kernel/svm.zip> and Support vector machines for classification and regression, Technical Report, Image Speech and Intelligent Systems Research Group, University of Southampton, 1997, and <http://www.ecs.soton.ac.uk/~srg/publications/pdf/SVM.pdf>.
17. Liong, S. Y., Lim, W. H. and Paudyal, G. N. (2000). "river stage forecasting bangladesh: neural network approach." *Journal of Computing in Civil Engineering*, ASCE, 14(1), 1-8.