

پیش‌بینی ظرفیت باربری نهایی شمع‌های تحت اثر بار محوری به کمک ماشین بردار پشتیبان (SVM) *

علیرضا کردجزی^(۱) فریدون پویانژاد^(۲)

چکیده پیش‌بینی ظرفیت باربری شمع‌های تحت اثر بار محوری یکی از مسائل اساسی در مهندسی ژئوتکنیک می‌باشد. و تاکنون روش‌های متفاوتی برای ارزیابی آن ارائه شده است. کار آبی روش‌های یادگیری ماشین در ارزیابی پدیده‌های ژئوتکنیکی در پژوهش‌های گوناگونی ذکر شده است. از جمله روش‌های یادگیری ماشین می‌توان به روش ماشین بردار پشتیبان (SVM) اشاره کرد. در این مقاله از یک مدل ماشین بردار پشتیبان مبتنی بر داده‌های آزمایش نفوذ مخروط (CPT) برای ارزیابی ظرفیت باربری نهایی شمع‌های تحت اثر بار محوری استفاده شده است. داده‌های مورد استفاده در این پژوهش، از مقالات منتشر شده، استخراج شده است و این داده‌ها شامل نتایج آزمون بارگذاری استاتیکی شمع در مقیاس واقعی، نتایج آزمایش نفوذ مخروط (CPT) در خاک محل و خواص هندسی شمع می‌باشد. با مقایسه ی نتایج به دست آمده از مدل ارائه شده و مقادیر واقعی، کارایی مناسب مدل تأیید می‌شود. در نهایت با تحلیل حساسیت، اثر هر یک از متغیرهای ورودی مدل نیز مورد بررسی قرار می‌گیرد.

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

Prediction of Ultimate Bearing Capacity of Axially Loaded Piles Using a Support Vector Machine

A. Kordjazi

F. Pooya Nejad

Abstract Bearing capacity prediction of axially loaded piles is one of the most important problems in geotechnical engineering practices, with a wide variety range of methods which have been introduced to forecast it accurately. Machine learning methods have been reported by many contemporary researches with some degree of success in modeling geotechnical phenomena. In this study, a fairly new machine learning method known as Support Vector Machine (SVM) has been used to develop a model to approximate the ultimate bearing capacity of axially loaded piles, based on Cone Penetration Test (CPT) data. The utilized dataset obtained from published literature contains full scale static load test and CPT results and pile geometry for each sample. Additionally, sensitivity analysis of the model respect to each input parameter has been investigated. Finally, a comparison between actual values and predicted bearing capacity confirms efficiency of the developed model.

Keywords Static pile load test, Cone penetration test (CPT), Ultimate bearing capacity, Support vector machine.

★ تاریخ تصویب مقاله ۹۱/۰۱/۲۶ و تاریخ دریافت نسخه‌ی نهایی اصلاح شده ۹۱/۰۳/۳

(۱) دانشجوی کارشناسی ارشد مکانیک خاک و پی، دانشکده مهندسی، دانشگاه فردوسی مشهد.

(۲) نویسنده‌ی مسؤول: استادیار گروه عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد.

مقدمه

شمع‌ها شالوده‌هایی برای انتقال بارهای ناشی از سازه به لایه‌های تحتانی خاک هستند و عمل کرد صحیح آن‌ها به طور مستقیم بر عمل کرد سازه ی بنا شده بر این اجزا مؤثر است. از دیدگاه ژئوتکنیکی، ظرفیت باربری شمع‌ها یکی از مهم‌ترین پارامترهای ارزیابی عمل کرد شمع‌ها به شمار می‌آید. اگرچه پیش‌بینی ظرفیت باربری شمع‌ها به علت وجود عوامل گوناگون و متنوعی که در ظرفیت باربری مؤثر هستند و عدم قطعیت‌های آن‌ها، مسأله ی دشواری است [1]، تاکنون پژوهش‌های زیادی منتشر شده است که با به‌کارگیری روش‌های تجربی و یا تئوری راه‌حل‌هایی برای پیش‌بینی این کمیت در انواع شمع‌ها ارائه داده‌اند. بسیاری از روش‌های موجود با در نظر گرفتن فرضیاتی راجع به عوامل مؤثر در ظرفیت باربری شمع، مسأله را ساده کرده‌اند [2]. به دلیل پیچیدگی رفتار شمع در خاک عملاً هیچ‌یک از روش‌های ارائه‌شده، سازگاری قابل توجهی در پیش‌بینی دقیق رفتار شمع‌ها ندارند. در نتیجه، روش‌های دیگری مورد نیاز می‌باشد تا بر محدودیت‌های روش‌های موجود غلبه کند و دقت کافی در پیش‌بینی ظرفیت باربری داشته باشد.

در دهه‌های اخیر پیشرفت سریع سیستم‌های پردازش اطلاعات، پژوهش‌های مهندسی را به سمت استفاده از سیستم‌های هوشمند با کارایی بالا برای مدل‌سازی پدیده‌های تجربی سوق داده است. از این‌رو، گستره ی وسیعی از روش‌های یادگیری ماشین در مدل‌سازی پدیده‌های ژئوتکنیکی با موفقیت مورد استفاده قرار گرفته‌اند. روش شبکه‌های عصبی مصنوعی، نمونه‌ای از این روش‌ها می‌باشد که کارایی آن‌ها در گسترش مدل‌های مسائل مهندسی ژئوتکنیک در مقالات گوناگون تأیید شده است [6-2]. روش ماشین بردار پشتیبان (Support Vector Machine یا SVM) نیز از روش‌های نسبتاً جدید یادگیری ماشین است و با تکیه بر تئوری یادگیری آماری Vapnik نتایج

خوبی در مدل‌سازی پدیده‌های مهندسی ژئوتکنیک داشته است [7-10].

در این مقاله از ماشین بردار پشتیبان به همراه نتایج حاصل از آزمایش نفوذ مخروط (CPT) برای پیش‌بینی ظرفیت باربری نهایی شمع‌های تحت اثر بار محوری استفاده شده است. اهداف این پژوهش عبارتند از:

۱. ارائه و گسترش مدل ماشین بردار پشتیبان برای پیش‌بینی ظرفیت باربری نهایی شمع‌های منفرد تحت اثر بار محوری.

۲. ارزیابی عمل کرد مدل ارائه‌شده ماشین بردار پشتیبان برای پیش‌بینی کمیت مورد نظر.

۳. تحلیل حساسیت ظرفیت باربری نهایی نسبت به پارامترهای مؤثر بر آن.

ماشین بردار پشتیبان

روش ماشین بردار پشتیبان یکی از روش‌های یادگیری ماشینی است. این روش بر مبنای تئوری یادگیری آماری Vapnik در دهه ی ۹۰ میلادی است که توسط Vapnik و همکارانش ارائه گردید. برای کمینه کردن خطای مدل در SVM از اصولی که با عنوان کمینه‌سازی ریسک ساختاری (Structural Risk Minimization) شناخته می‌شوند، استفاده شده است. درحالی‌که سایر روش‌ها (مانند روش شبکه‌های عصبی مصنوعی) از اصول کمینه‌سازی ریسک تجربی (Empirical Risk Minimization) بهره می‌برند. [4,11].

به طور کلی ماشین بردار پشتیبان در مسائل طبقه‌بندی دو یا چند گروه و رگرسیون مورد استفاده قرار می‌گیرد. مانند بسیاری از روش‌های یادگیری ماشینی، در این روش نیز فرآیند ساخت مدل شامل دو مرحله ی آموزش و آزمایش می‌باشد. در انتهای فاز آموزش قابلیت تعمیم یابی مدل آموزش داده شده با استفاده از داده‌های آزمایش مورد ارزیابی قرار می‌گیرد. در واقع ماشین بردار پشتیبان، تابع رگرسیون را با

در این رابطه:

ε = خطای مورد قبول در تابع تلفات (شکل ۱)،

$$\|w\|^2 = \text{نرم بردار وزن (به مقدار } \left(\sum_{i=1}^n w_i^2\right),$$

ζ_i^* = متغیرهای slack که به همراه تابع تلفات در شکل (۱) نشان داده شده‌اند.

بر اساس تئوری لاگرانژ، مسأله ی بهینه‌سازی رابطه ی (۲) قابل تبدیل به تابع لاگرانژ می‌باشد:

$$L(\alpha^*, \alpha) = -\varepsilon \sum_{i=1}^l [\alpha_i^* + \alpha_i] + \sum_{i=1}^l y_i (\alpha_i^* - \alpha_i) - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l [\alpha_i^* - \alpha_i] (\alpha_j^* - \alpha_j) (x_i \cdot x_j) \quad (۳)$$

با بیشینه شدن تابع فوق تحت قیدهای زیر، مقادیر ضرایب α, α^* به دست می‌آیند. این ضرایب، ضرایب لاگرانژ نامیده می‌شوند.

$$\begin{cases} \sum \alpha_i^* = \sum \alpha_i \\ 0 \leq \alpha_i^* \leq C \\ 0 \leq \alpha_i \leq C \end{cases} \quad \text{for } i = 1, 2, \dots, l \quad (۴)$$

در روابط (۳ و ۴):

L = تابع لاگرانژ،

C = پارامتر جریمه یا پارامتر تنظیم.

نکته قابل توجه آن است که مسأله ی بهینه‌سازی فوق قابل حل به کمک روش‌های QP (Quadratic Programming) می‌باشد. در نتیجه رسیدن به اکسترمم کلی نیز قطعی خواهد بود و خطر به دام افتادن در اکسترمم محلی وجود ندارد [11].

به‌کارگیری یک دسته تابع خطی تخمین می‌زند، در این تابع، انحراف مقادیر پیش‌بینی شده از مقدار واقعی به میزان ε مجاز است (تابع تلفات Vapnik). در نهایت بهترین جواب به کمک اصول کمینه‌سازی ریسک ساختاری بر روی ریسک اندازه‌گیری شده توسط تابع تلفات مورد استفاده، ارائه می‌شود [8].

حل مسأله ی رگرسیون در SVM بر روی یک مجموعه از داده‌ها، شامل l نمونه، به صورت $\{(x_1, y_1), \dots, (x_l, y_l) \in R^m, y \in R\}$ یک تابع خطی به شکل رابطه ی (۱) می‌باشد که بتواند مقادیر خروجی را بر مبنای ورودی‌ها تخمین بزند.

$$f(x) = \langle w \cdot x \rangle + b \quad (۱)$$

در این رابطه

x = بردار ورودی ($x \in R^m$),

y = مقدار خروجی ($y \in R$),

w = بردار وزن ($w \in R^m$),

b = بایاس ($b \in R$).

با استفاده از تابع تلفات Vapnik، پارامترهای کنترل‌کننده ی تابع پاسخ بهینه در SVM (یعنی تابع وزن و بایاس) با حل مسأله ی بهینه‌سازی زیر حاصل می‌شوند [11]:

Minimize

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


(۲-الف)

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

Subject to $((w \cdot x_i) + b) - y_i \leq \varepsilon + \zeta_i^*$

$$\zeta_i, \zeta_i^* \geq 0$$

$i = 1, 2, \dots, l$ (۲-ب)



شکل ۱ تابع تلفات Vapnik و متغیرهای slack، [11]

C و ϵ توسط کاربر تعریف می‌شوند. پارامتر C یک پارامتر تنظیمی است و می‌تواند مقادیر صفر تا بی‌نهایت را بپذیرد. نقش این پارامتر ایجاد تعادل میان کمینه کردن ریسک تجربی و بیشینه کردن قابلیت تعمیم‌یابی است. بنابراین، چگونگی اثرگذاری اصل کمینه‌سازی ریسک ساختاری مشاهده می‌شود [4]. به عبارت دیگر می‌توان گفت که مقدار C تعادلی میان عمل‌کرد مدل بر داده‌های آموزش و داده‌های آزمایش ایجاد می‌کند. وقتی به این پارامتر مقادیر بزرگی اختصاص داده شود، SVM اجازه ی وقوع خطا را در داده‌های آموزش نمی‌دهد و نتیجه ی حاصل یک مدل پیچیده خواهد بود (زیرا با افزایش مقدار C، اثر قسمت دوم در سمت راست رابطه (۲-الف) بسیار زیاد می‌شود و مدل از بروز خطاهای کوچک بر داده‌های آموزش جلوگیری می‌کند)، لذا قابلیت تعمیم‌یابی مدل کاهش می‌یابد. از طرف دیگر وقتی که C به سمت صفر میل کند، مدل می‌تواند خطای زیادی را بپذیرد، زیرا با کم شدن مقدار این پارامتر، توجه کم‌تری به میزان متغیرهای slack در رابطه ی (۲-الف) معطوف می‌شود و مدل نسبت به وقوع خطا بر مجموعه ی آموزش حساسیت کم‌تری نشان می‌دهد و در نتیجه، پیچیدگی مدل کم‌تر خواهد بود [8,9].

پارامتر ϵ نیز می‌تواند مقادیر صفر تا بی‌نهایت را بپذیرد. مقدار این پارامتر در وضعیت بردارهای پشتیبان و در نتیجه کارایی مدل بسیار مؤثر است. هر چند که انتخاب مقادیر بسیار بزرگ ϵ سبب کاهش تعداد بردارهای پشتیبان می‌شود و مطلوب نیز چنین است اما

بدین ترتیب پاسخ نهایی به صورت زیر خواهد

بود [4]:

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

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

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

در این روابط:

x_i = بردار ورودی که مدل با آن آموزش داده می‌شود،

x = بردار ورودی،

x_r, x_s = دو بردار پشتیبان،

w_0 = بردار وزن بهینه،

b_0 = مقدار بهینه بایاس.

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 $\pm \epsilon$ هستند. بنابراین، بردارهای پشتیبان درون باند $\pm \epsilon$ قرار نمی‌گیرند و مقدار ϵ تعداد بردارهای پشتیبان را کنترل می‌کند [8]. با توجه به رابطه ی (۵) مشاهده می‌شود که داده‌هایی که ضرایب لاگرانژ آن‌ها صفر است، نقشی در پاسخ نهایی ندارند. به سخن دیگر، بردارهای پشتیبان هستند که تابع رگرسیون نهایی با پاسخ بهینه را تعیین می‌کنند.

برای ساخت مدل ماشین بردار پشتیبان، پارامترهای

ظرفیت باربری نهایی اندازه‌گیری شده از نتایج آزمایش بارگذاری استاتیکی شمع در مقیاس واقعی استخراج شده است و بار گسیختگی به‌عنوان ظرفیت باربری نهایی شمع در نظر گرفته شده است. برای شمع‌هایی که در تفسیر نمودار بار-نشست آن‌ها برای تعیین بار نهایی دشواری‌هایی وجود داشته نیز از معیار ۸۰٪ که توسط Hansen [51] ارائه شده، استفاده شده است. بر اساس این معیار، ظرفیت شمع معادل باری است که تغییر مکان متناظر با آن، چهار برابر تغییر مکان متناظر با ۸۰٪ آن بار باشد [52]. به طور کلی نتایج حاصل از به‌کارگیری این معیار با گسیختگی شمع در حالت گسیختگی کامل (Plunging failure) سازگاری خوبی نشان می‌دهد [52,53].

ورودی‌ها و خروجی‌های مدل. دست‌یابی به یک مدل کارآمد برای پیش‌بینی ظرفیت باربری شمع‌ها نیازمند شناسایی پارامترهای مؤثر در ظرفیت باربری شمع‌ها می‌باشد. در بسیاری از روش‌های موجود، مصالح و هندسه شمع، خصوصیات مکانیکی خاک و بار اعمال‌شده مهم‌ترین فاکتورها در ظرفیت باربری شناخته می‌شوند. با این حال، نحوه‌ی اجرای شمع-ها (کوبیدنی یا غیر کوبیدنی)، انتهای شمع (باز یا بسته) و همچنین نوع آزمون بارگذاری شمع نیز در ظرفیت باربری مؤثر هستند [5].

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) می‌باشد. طول مدفون شمع به سه قسمت مساوی تقسیم و مقادیر متوسط q_c و f_s در هر قسمت محاسبه شده است.

رسیدن به این هدف با عریض کردن باند ϵ نادرست است. از طرف دیگر، مقادیر بسیار کوچک این پارامتر، موجب می‌شود تا تعداد زیادی بردار پشتیبان انتخاب شود و احتمال خطر بیش آموزش شدن افزایش یابد [8].

مسئله‌ی رگرسیون خطی در SVM به آسانی قابل گسترش به رگرسیون غیر خطی است. بدین منظور از توابع کرنل استفاده می‌شود. توابع کرنل، داده‌ها را به یک فضای ویژگی (Feature space) نگاشت می‌کنند که در آن فضا امکان استفاده از رگرسیون خطی وجود داشته باشد. تا کنون کرنل‌های گوناگونی معرفی شده‌اند [11]، اما کرنل‌های چندجمله‌ای (Polynomial) و پایه‌شعاعی (Radial basis function) به‌طور موفقیت‌آمیز در مسائل مهندسی ژئوتکنیک به‌کار گرفته شده‌اند

[7-10, 12].

طراحی مدل

داده‌های مورد استفاده. در این مقاله برای گسترش مدل ماشین بردار پشتیبان برای پیش‌بینی ظرفیت باربری نهایی شمع از یک مجموعه داده شامل ۱۰۸ نمونه استفاده شده است. هر نمونه در برگرفته‌ی مشخصات هندسی شمع، نتایج آزمون بارگذاری استاتیکی شمع در مقیاس واقعی و هم‌چنین نتایج آزمون نفوذ مخروط می‌باشد. داده‌های مورد استفاده از پژوهش‌های منتشر شده استخراج شده‌اند. پیش‌تر تعدادی از این داده‌ها توسط مراجع [13] (۸۷ نمونه) و [14] (۱۸ نمونه) مورد استفاده قرار گرفته شده است. جدول (۱) مراجع داده‌های مورد استفاده را ارائه می‌نماید. هم‌چنین در این جدول مشخص شده است که از هر مرجع چند نمونه برای آموزش مدل و چند نمونه برای ارزیابی کارایی مدل مورد استفاده قرار گرفته است.

جدول ۱ مرجع داده‌های مورد استفاده

ردیف	محل انجام آزمایش	تعداد کل آزمایش‌های بارگذاری استاتیکی	تعداد مورد استفاده در مجموعه آموزش	تعداد مورد استفاده در مجموعه آزمایش	مرجع
۱	Texas A&M Uni.,USA	۲	۲	۰	[15]
۲	George Island Bridge	۱	۱	۰	[16]
۳	ICS2 Site, Portugal	۱	۱	۰	[17]
۴	Louisiana, USA	۱	۱	۰	[18]
۵	Route 351 Bridge,USA	۳	۲	۱	[19]
۶	ITD-Idaho	۱	۱	۰	[20]
۷	Belfast, Ireland	۱	۱	۰	[21]
۸	Indiana, US	۲	۲	۰	[22]
۹	Adelaide, Australia	۱	۱	۰	[23]
۱۰	Brussels, Belgium	۴	۲	۲	[24]
۱۱	Georgia, US	۱	۱	۰	[25]
۱۲	Brazil	۱	۱	۰	[26]
۱۳	Grimsby, UK	۲	۱	۱	[27]
۱۴	Vancouver, Canada	۴	۳	۱	[28]
۱۵	Evanston,IL,USA	۲	۱	۱	[29]
۱۶	SF,California, USA	۱	۱	۰	[30]
۱۷	Baghdad,Iraq	۲	۲	۰	[31]
۱۸	Port of Los Angeles, USA	۱	۱	۰	[32]
۱۹	Noto Island,Japan	۲	۲	۰	[33]
۲۰	Taiwan	۲	۱	۱	[34]
۲۱	Louisiana, USA	۷	۶	۱	[35]
۲۲	Florida, USA	۳	۲	۱	[36]
۲۳	Texas, USA	۲	۱	۱	[37]
۲۴	Almere, Netherland	۱	۱	۰	[38]
۲۵	Milan, Italy	۱	۱	۰	[39]
۲۶	Oklahoma, USA	۲	۲	۰	[40]
۲۷	Alabama, USA	۱	۱	۰	[41]
۲۸	Lock and Dam 26, SL,USA	۳	۲	۱	[42]
۲۹	Seattle, USA	۱	۱	۰	[43]
۳۰	Georgia, 1993	۱	۱	۰	[44]
۳۱	Australia	۲	۲	۰	[45]
۳۲	Sao Paulo, Brazil	۲	۱	۱	[46]
۳۳	West Palm Beach, USA	۱	۱	۰	[47]
۳۴	Jefferson County, USA	۱	۱	۰	[47]
۳۵	Blount Island, USA	۵	۴	۱	[47]
۳۶	Houston, USA	۲	۱	۱	[48]
۳۷	Puerto Rico, USA	۲	۲	۰	[49]
۳۸	USA	۳۶	۳۱	۵	[50]

اجرای شمع در محاسبات ریاضی مدل ماشین بردار پشتیبان، مقادیری به هر یک از پارامترها تخصیص داده شده است. به این ترتیب، در نوع آزمایش بارگذاری شمع به آزمایش‌های از نوع بار ماندگار (ML) مقدار صفر و آزمایش‌های از نوع نفوذ با نرخ ثابت (CRP) مقدار ۱ تخصیص داده شده است. شمع‌های فولادی با مقدار صفر، بتنی با مقدار ۱ و شمع‌های کامپوزیت با مقدار ۰/۵ تعریف شده‌اند. به شمع‌های با انتهای باز مقدار ۱ و به شمع‌های با انتهای بسته مقدار صفر و در نهایت به شمع‌های کوبیده‌شده مقدار صفر و به شمع‌های غیرکوبیدنی مقدار ۱ تخصیص داده شده است.

پیش از شروع آموزش مدل، داده‌ها به بزرگ‌ترین مقدار متناظرشان تقسیم شده‌اند تا به مقدارهای بین صفر و یک مقیاس شوند. به این ترتیب، اثر مقیاس واقعی (Absolute scale) کمینه شده است و همه‌ی ورودی‌ها تقریباً در یک دامنه قرار گرفته‌اند [7].

آموزش مدل و انتخاب معیارهای ارزیابی مدل. به منظور گسترش یک مدل غیرخطی SVM از توابع کرنل پایه شعاعی (RBF) و تابع کرنل چند جمله‌ای استفاده می‌شود. این کرنل‌ها در روابط زیر تعریف شده‌اند [4,8].

$$K(x, x_i) = \exp\left(-|x - x_i|^2 / 2\sigma^2\right) \quad (8)$$

$$K(x, x_i) = (\langle x, x_i \rangle + 1)^d \quad (9)$$

در روابط بالا:

σ = عرض کرنل با پایه شعاعی،

d = توان چند جمله‌ای.

مقادیر عرض کرنل با پایه شعاعی و توان کرنل چند جمله‌ای توسط کاربر تعیین می‌شوند.

لذا پارامترهای ورودی مدل SVM به شکل زیر در نظر گرفته شده‌اند: (۱) نوع آزمایش بارگذاری استاتیکی شمع (از نوع بار ماندگار یا بار با نرخ نفوذ ثابت یا به عبارت دیگر ML یا CRP)، (۲) نوع مصالح شمع (فولادی، بتنی یا کامپوزیت)، (۳) طریقه‌ی اجرای شمع (کوبیده‌شده (Driven) یا غیرکوبیدنی (Bored))، (۴) وضعیت انتهای شمع (باز یا بسته)، (۵) طول مدفون شمع (Lembed)، (۶) پیرامون شمع در تماس با خاک (O)، (۷) مساحت نوک شمع (A_{tip})، (۸) مقادیر متوسط مقاومت نوک مخروط در طول جداره‌ی شمع (q_{c1}, q_{c2}, q_{c3})، (۹) مقادیر متوسط 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.

آماده‌سازی داده‌ها. برای گسترش یک مدل ماشین بردار پشتیبان داده‌ها به دو دسته‌ی آموزش و آزمایش تقسیم‌بندی می‌شوند [4,8]. در این مقاله تعداد ۸۹ داده از کل داده‌ها (حدود ۸۲/۵٪) برای آموزش و بقیه‌ی داده‌ها شامل ۱۹ داده برای آزمایش کارایی مدل مورد استفاده قرار گرفته شده است. سعی شده است تا مشخصات آماری هر یک از پارامترهای ورودی مجموعه‌ی آموزش و مجموعه‌ی آزمایش نظیر میانگین و انحراف معیار به یک دیگر نزدیک باشند. در جدول (۲) مشخصات آماری داده‌ها شامل میانگین، انحراف استاندارد، کمینه و بیشینه و دامنه‌ی داده‌ها ارائه شده است.

به منظور وارد کردن اثرات جنس مصالح شمع، نوع آزمون بارگذاری شمع، وضعیت انتهای شمع و نوع

جدول ۲. مشخصات آماری مجموعه داده‌های ورودی و خروج

متغیرهای مدل و مجموعه داده‌ها	پارامتر آماری				
	دامنه	مینیمم	ماکسیمم	انحراف معیار	میانگین
$A_{tip}(m^2)$					
مجموعه داده‌های آموزش	۰/۷۷۷۴	۰/۰۰۸۰	۰/۷۸۵۴	۰/۱۷۴۹	۰/۱۸۰۰
مجموعه داده‌های آزمایش	۰/۴۹۵۰	۰/۰۰۸۰	۰/۵۰۳۰	۰/۱۱۸۵	۰/۱۵۴۴
$O(mm)$					
مجموعه داده‌های آموزش	۶۷۵۶/۳	۵۸۵/۰	۷۳۴۱/۳	۸۴۲/۸	۱۶۱۴/۴
مجموعه داده‌های آزمایش	۱۶۵۲/۰	۸۵۸/۰	۲۵۱۰/۰	۴۳۶/۰	۱۴۱۲/۹
$L_{embed}(m)$					
مجموعه داده‌های آموزش	۶۱/۵	۵/۵	۶۷/۰	۱۰/۱۲	۱۵/۵۱
مجموعه داده‌های آزمایش	۳۰/۰	۶/۵	۳۶/۵	۹/۰۵	۱۷/۲۰
$q_{c1}(MPa)$					
مجموعه داده‌های آموزش	۱۵/۰۵	۰/۰۲	۱۵۰/۷	۳/۰۹	۴/۰۲
مجموعه داده‌های آزمایش	۱۱/۴۹	۰/۲۴	۱۱/۷۳	۳/۱۸	۴/۱۶
$f_{s1}(kPa)$					
مجموعه داده‌های آموزش	۲۸۳/۲۰	۰/۷۳	۲۸۳/۹۳	۵۷/۴۵	۷۳/۴۶
مجموعه داده‌های آزمایش	۱۶۵/۹۹	۱۰/۷۶	۱۷۶/۷۵	۴۷/۹۸	۷۱/۳۴
$q_{c2}(MPa)$					
مجموعه داده‌های آموزش	۳۰/۳۹	۰/۳۲	۳۰/۷۱	۵/۷۳	۶/۱۴
مجموعه داده‌های آزمایش	۱۷/۴۳	۱/۰۰	۱۸/۴۲	۴/۳۰	۵/۹۵
$f_{s2}(kPa)$					
مجموعه داده‌های آموزش	۶۱۶/۵۴	۲/۱۲	۶۱۸/۶۷	۹۳/۶۹	۱۰۲/۵۸
مجموعه داده‌های آزمایش	۲۸۸/۰۹	۱۵/۰۰	۳۰۳/۰۹	۷۲/۷۲	۱۰۴/۱۴
$q_{c3}(MPa)$					
مجموعه داده‌های آموزش	۳۲/۳۲	۰/۲۷	۳۲/۵۹	۵/۹۲	۷/۱۸
مجموعه داده‌های آزمایش	۲۲/۳۶	۰/۷۰	۲۳/۰۶	۵/۲۰	۷/۲۸
$f_{s3}(kPa)$					
مجموعه داده‌های آموزش	۳۸۸/۵۸	۷/۹۹	۳۹۶/۵۷	۹۳/۶۳	۱۲۵/۸۴
مجموعه داده‌های آزمایش	۳۶۳/۰۰	۲۵/۰۰	۳۸۸/۰۰	۱۱۰/۱۰	۱۴۶/۶۰
$q_{ctip}(MPa)$					
مجموعه داده‌های آموزش	۲۶/۸۶	۰/۲۵	۲۷/۱۱	۶/۰۸	۸/۷۱
مجموعه داده‌های آزمایش	۲۱/۱۵	۱/۱۵	۲۲/۳۰	۶/۸۷	۹/۳۲
$P_u(kN)$					
مجموعه داده‌های آموزش	۱۰۸۴۶/۱۰	۶۳/۹۰	۱۰۹۱۰/۰۰	۱۷۸۴/۱۰	۱۹۷۴/۲۸
مجموعه داده‌های آزمایش	۵۱۲۵/۰۰	۷۲۵/۰۰	۵۸۵۰/۰۰	۱۳۲۳/۳۱	۱۹۷۰/۰۰

در فرآیند آموزش استفاده نشده‌اند (داده‌های آزمایش) ارزیابی می‌شود. نتایج ارزیابی عمل کرد پیش‌بینی مدل SVM به کمک شاخص‌های آماری نظیر ضریب همبستگی و ریشه میانگین مربعات خطاها (RMSE)

در این پژوهش برای آموزش مدل و ارزیابی آن بر داده‌های آزمایش از جعبه ابزار SVM در نرم‌افزار MATLAB [54] استفاده شده است. پس از اتمام فرآیند آموزش مدل، عمل کرد آن توسط داده‌هایی که

محاسبه RMSE، خطاهای بزرگتر اهمیت بیشتری نسبت به خطاهای کوچک می‌یابند، این فاکتور به معیاری متداول برای اندازه‌گیری خطا تبدیل شده است [5,56].

نتایج

در این پژوهش دو مدل ماشین بردار پشتیبان برای پیش‌بینی ظرفیت باربری نهایی شمع‌های تحت اثر بار محوری ارائه شده است. مدل اول با استفاده از یک تابع کرنل پایه شعاعی (RBF) و مدل دوم به کمک تابع کرنل چند جمله‌ای گسترش داده می‌شود. برای رسیدن به مدل بهینه، با ترکیب‌های مختلفی از پارامترهای C ، ε و پارامترهای تابع کرنل (σ) برای کرنل RBF و d در کرنل چندجمله‌ای، مدل ماشین بردار پشتیبان بر داده‌های آموزش گسترش داده می‌شود و به کمک مجموعه داده‌های آزمایش، عمل کرد مدل بررسی می‌شود.

جداول (۳-۵) فرآیند بهینه‌سازی پارامترهای فوق را نشان می‌دهد. هر جدول در برگیرنده ی تعداد بردارهای پشتیبان بر مجموعه آموزش و مقادیر ضریب هم‌بستگی و ریشه دوم میانگین مربعات خطاها بر مجموعه داده‌های آزمایش می‌باشد. در هر یک از این جدول‌ها، نتایج مدل به ازای تغییرات یک پارامتر از پارامترهای سه‌گانه (یعنی C و ε و σ یا d) در حالی که دو پارامتر دیگر ثابت هستند، نشان داده شده است. به‌عنوان مثال در جدول (۳)، نتایج عمل کرد مدل‌ها به ازای تغییرات پارامتر ε در حالی که مقادیر C و پارامتر کرنل ثابت هستند، ارائه شده است. مشاهده می‌شود که با افزایش ε ، تعداد بردار پشتیبان کاهش می‌یابد، اما همان‌طور که گفته شده است، در فرآیند رسیدن به پاسخ بهینه، کاهش تعداد بردار پشتیبان با افزایش مقدار ε تا حد معینی مؤثر است و رسیدن به کم‌ترین خطا در پیش‌بینی و بیش‌ترین هم‌بستگی با مقادیر واقعی الزاماً با افزایش ε برآورده نمی‌گردد. با توجه به جدول (۳)، در

ارائه شده است. ضریب هم‌بستگی معیاری است برای اندازه‌گیری هم‌بستگی نسبی میان مقادیر پیش‌بینی شده و اندازه‌گیری شده و از رابطه ی زیر به دست می‌آید [5].

$$R = \frac{C_{y_j d_j}}{\sigma_{y_j} \sigma_{d_j}} \quad (10)$$

$$C_{y_j d_j} = \frac{1}{n-1} \sum_{j=1}^n (y_j - \bar{y})(d_j - \bar{d}) = \frac{1}{n-1} \left(\sum_{j=1}^n y_j d_j - \frac{\sum_{j=1}^n y_j \sum_{j=1}^n d_j}{n} \right) \quad (11)$$

$$\sigma_{y_j} = \sqrt{\frac{\sum_{j=1}^n (y_j - \bar{y})^2}{n-1}} \quad (12)$$

$$\sigma_{d_j} = \sqrt{\frac{\sum_{j=1}^n (d_j - \bar{d})^2}{n-1}} \quad (13)$$

$$\bar{y} = \frac{\sum_{j=1}^n y_j}{n} \quad (14)$$

$$\bar{d} = \frac{\sum_{j=1}^n d_j}{n} \quad (15)$$

در این رابطه‌ها

y_j = مقدار خروجی اندازه‌گیری شده (مطلوب)،

d_j = مقدار خروجی مدل (پیش‌بینی شده)،

$C_{y_j d_j}$ = کواریانس میان خروجی مدل و خروجی اندازه‌گیری شده،

σ_{y_j} = انحراف استاندارد خروجی اندازه‌گیری شده،

σ_{d_j} = انحراف استاندارد خروجی مدل،

\bar{y} = میانگین خروجی‌های اندازه‌گیری شده،

\bar{d} = میانگین خروجی‌های مدل،

n = تعداد داده‌ها.


در صورتی که مقدار قدر مطلق ضریب هم‌بستگی بزرگتر از ۰/۸ باشد، بنا بر Smith [55]، هم‌بستگی قوی میان دو مجموعه داده وجود دارد. از آن‌جا که در

ازای مقادیر بزرگ‌تر این پارامتر پاسخ‌ها بهینه نیستند.


مدل گسترش‌یافته با تابع کرنل پایه شعاعی به ازای مقادیر $\varepsilon = 0.02$ مدل بهینه حاصل خواهد شد و به

جدول ۳ ارزیابی مدل به ازای مقادیر گوناگون پارامتر ε

Radial Basis Function (rbf) $C=0.1$ & $\sigma=0.1$				Polynomial Function $C=0.2$ & $d=1/9$			
ε	تعداد بردارهای پشتیبان	R	RMSE (kN)	ε	تعداد بردارهای پشتیبان	R	RMSE (kN)
0.001	88	0.963	363/28	0.001	88	0.948	417/12
0.002	87	0.963	371/96	0.002	87	0.948	418/11
0.003	86	0.963	359/85	0.003	86	0.947	418/05
0.004	84	0.963	357/81	0.004	83	0.947	418/54
0.005	83	0.964	355/87	0.005	80	0.947	418/62
0.006	83	0.964	353/78	0.006	79	0.947	417/18
0.007	82	0.965	349/02	0.007	78	0.948	415/63
0.008	81	0.966	343/05	0.008	77	0.948	415/72
0.009	79	0.967	337/22	0.009	75	0.948	417/70
0.01	78	0.968	331/91	0.01	75	0.948	419/29
0.02	64	0.971	308/00	0.02	66	0.939	445/26
0.03	50	0.966	335/55	0.03	58	0.925	498/73
0.04	44	0.959	374/12	0.04	45	0.923	519/06
0.05	38	0.947	424/33	0.05	37	0.921	534/45
0.06	31	0.937	463/14	0.06	32	0.927	509/91
0.07	28	0.921	511/47	0.07	26	0.924	524/53
0.08	23	0.909	557/06	0.08	22	0.926	519/59
0.09	22	0.894	607/60	0.09	21	0.925	528/71
0.1	19	0.878	646/76	0.1	19	0.925	533/66



(ب)



(الف)

شکل ۲ ظرفیت باربری اندازه‌گیری شده در برابر پیش‌بینی شده توسط مدل SVM گسترش داده شده به کمک

تابع کرنل پایه شعاعی (الف) بر روی داده‌های مجموعه آموزش، (ب) بر روی مجموعه داده‌های

آزمایش (ارزیابی)

جدول ۴ ارزیابی مدل به ازای مقادیر گوناگون پارامتر C

Radial Basis Function(rbf) $\varepsilon=0.02$ & $\sigma=0.75$				Polynomial Function $\varepsilon=0.007$ & $d=1/9$			
C	تعداد بردارهای پشتیبان	R	RMSE (kN)	C	تعداد بردارهای پشتیبان	R	RMSE (kN)
0.001	۸۷	-0.170	2128.62	0.001	۸۶	0.763	1376.02
0.01	۶۷	0.044	1630.60	0.01	۷۹	0.907	867.07
0.05	۶۴	0.765	1177.49	0.05	۷۶	0.939	601.33
0.1	۶۱	0.851	964.39	0.1	۷۸	0.945	498.02
0.2	۶۴	0.901	737.60	0.2	۷۸	0.948	410.63
0.3	۶۴	0.927	617.65	0.3	۷۹	0.948	422.25
0.5	۶۰	0.954	427.03	0.5	۸۴	0.945	508.31
0.7	۶۴	0.970	315.14	0.7	۸۰	0.949	507.64
0.8	۶۴	0.971	308.00	0.8	۸۲	0.950	511.12
0.9	۶۴	0.970	330.25	0.9	۸۲	0.952	509.89
۱	۶۴	0.966	378.92	۱	۸۳	0.954	510.11
۲	۶۱	0.954	524.49	۲	۸۱	0.942	654.50
۵	۶۱	0.951	534.71	۵	۸۱	0.931	701.60
۱۰	۶۴	0.952	529.17	۱۰	۸۲	0.913	750.13
۵۰	۶۴	0.952	529.17	۵۰	۸۵	0.850	1034.20
۱۰۰	۶۴	0.952	529.17	۱۰۰	۸۴	0.734	1454.80
۵۰۰	۶۴	0.952	529.17	۵۰۰	۸۷	0.705	4434.06

هر تابع کرنل و تعداد بردارهای پشتیبان متناظر با آن‌ها را نشان می‌دهد. هم‌چنین نتایج عمل کرد مدل بهینه بر مجموعه داده‌های آموزش و آزمایش در جدول (۷) نشان داده شده است. هم‌چنین نمودار مقادیر اندازه‌گیری شده ظرفیت باربری نهایی در برابر مقدار پیش‌بینی شده به وسیله‌ی مدل‌های گسترش یافته به ازای هر یک از توابع کرنل در شکل‌های (۲ و ۳) نشان داده شده است. مقادیر اندازه‌گیری شده ظرفیت باربری نهایی و مقادیر پیش‌بینی شده‌ی آن به همراه مشخصات هندسی شمع و نتایج آزمایش CPT بر داده‌های مجموعه آزمایش در جدول (۸) ارائه شده‌اند. با مقایسه نتایج مشاهده می‌شود که مدل گسترش یافته با تابع کرنل پایه شعاعی عمل کرد بهتری نسبت به کرنل چند جمله‌ای از خود نشان می‌دهد.

با بررسی مدل‌های گسترش یافته با تابع کرنل پایه شعاعی، مشاهده می‌شود مدلی که در آن عرض تابع کرنل (σ) برابر با 0.75 است و سایر پارامترهای مدل (یعنی ε و C) به ترتیب 0.02 و 0.8 انتخاب شده‌اند، با داشتن کم‌ترین مقدار خطا ($RMSE=308$ kN) و بیش‌ترین مقدار ضریب هم‌بستگی ($R=0.971$) بر داده‌های آزمایش، بهترین عمل کرد را نشان می‌دهد. در مدل دیگری که با استفاده از تابع کرنل چندجمله‌ای گسترش داده شده است، مقدار بهینه‌ی درجه تابع کرنل چند جمله‌ای 1/9 تعیین شده است و کاراترین مدل به ازای مقادیر $\varepsilon=0.007$ و $C=0.2$ بر داده‌های آزمایش، ضریب هم‌بستگی $R=0.948$ و $RMSE=410.63$ kN را ارائه می‌دهد. جدول (۶) مقادیر پارامترهای مدل‌های بهینه برای

جدول ۵ ارزیابی مدل به ازای مقادیر گوناگون پارامتر کرنل

Radial Basis Function(rbf) C=۰/۸ & ε=۰/۰۲				Polynomial Function C=۰/۲ & ε=۰/۰۰۷			
σ	تعداد بردارهای پشتیبان	R	RMSE (kN)	d	تعداد بردارهای پشتیبان	R	RMSE (kN)
۰/۰۵	۸۷	۰/۱۲۵	۲۱۰۳/۳۶	۰/۰۵	۸۳	۰/۶۷۷	۱۳۴۵/۲۱
۰/۱	۸۵	۰/۵۳۱	۱۶۸۸/۰۷	۰/۱	۸۰	۰/۷۰۳	۱۲۵۰/۰۹
۰/۲۵	۶۶	۰/۹۵۳	۵۵۲/۵۱	۰/۲۵	۸۰	۰/۷۷۱	۱۰۱۹/۱۷
۰/۵	۶۴	۰/۹۵۷	۴۷۷/۱۱	۰/۵	۸۰	۰/۸۲۱	۸۶۶/۵۶
۰/۶	۶۳	۰/۹۵۷	۴۶۷/۷۹	۰/۶	۸۱	۰/۸۳۷	۸۴۸/۸۳
۰/۷	۶۳	۰/۹۶۸	۳۳۶/۰۱	۰/۷	۸۲	۰/۸۴۸	۸۰۷/۵۲
۰/۷۵	۶۴	۰/۹۷۱	۳۰۸/۰۰	۰/۷۵	۸۱	۰/۸۵۳	۷۹۸/۳۷
۰/۸	۶۴	۰/۹۷۱	۳۱۰/۸۶	۰/۸	۸۲	۰/۸۵۸	۷۸۷/۵۶
۰/۹	۶۱	۰/۹۶۳	۳۶۱/۹۹	۰/۹	۸۱	۰/۸۵۳	۷۷۹/۹۳
۱	۶۰	۰/۹۵۶	۴۱۲/۷۸	۱	۷۹	۰/۸۷۷	۷۴۲/۶۱
۱/۲	۶۱	۰/۹۳۵	۵۲۲/۱۲	۱/۲	۷۷	۰/۹۱۱	۶۷۲/۹۱
۱/۵	۶۰	۰/۹۱۷	۵۸۴/۱۰	۱/۵	۷۷	۰/۹۳۸	۵۶۴/۶۳
۱/۸	۶۵	۰/۹۱۸	۶۳۳/۰۹	۱/۸	۷۸	۰/۹۴۵	۴۴۳/۷۴
۱/۹	۶۵	۰/۹۱۷	۶۴۹/۳۹	۱/۹	۷۸	۰/۹۴۸	۴۱۵/۶۳
۲	۶۴	۰/۹۱۶	۶۴۴/۸۶	۲	۷۷	۰/۹۴۷	۴۲۱/۹۳
۳	۶۱	۰/۸۸۶	۷۶۴/۳۴	۳	۷۶	۰/۹۴۸	۶۰۵/۳۰
۵	۶۳	۰/۸۷۳	۹۱۶/۵۲	۵	۸۳	۰/۹۳۰	۸۳۰/۳۸
۱۰	۷۳	۰/۸۱۸	۱۲۲۴/۱۰	۱۰	۷۹	۰/۸۶۹	۱۵۱۳/۱۲

جدول ۶ مقادیر پارامترهای مدل بهینه و تعداد بردارهای پشتیبان

تعداد بردارهای پشتیبان	ε	C	پارامتر تابع کرنل	مدل بر اساس نوع تابع کرنل
۶۴	۰/۰۲	۰/۸	۰/۷۵	کرنل پایه شعاعی (RBF)
۷۸	۰/۰۰۷	۰/۲	۱/۹	کرنل چند جمله ای


جدول ۷ نتایج عمل کرد مدل بهینه بر مجموعه داده‌های آموزش و آزمایش در قالب ضریب هم‌بستگی و RMSE

مجموعه آموزش			مجموعه آزمایش	
مدل بر اساس نوع تابع کرنل	R	RMSE (kN)	R	RMSE (kN)
(RBF) کرنل پایه شعاعی	۰/۹۸۲	۳۹۳/۴۱	۰/۹۷۱	۳۰۸/۰۰
کرنل چند جمله ای	۰/۹۵۸	۵۱۳/۳۳	۰/۹۴۸	۴۱۵/۶۳


جدول ۸ نتایج مدل بر مجموعه داده‌های آزمایش

ردیف	نوع آزمایش	نوع شمع	نحوه اجرای شمع	وضعیت انتهای شمع	P_{um} (kN)	P_{up} (kN)		
						SVM (R=۰/۹۷۱)	ANN (R=۰/۸۹)	de Ruiter & Beringen (R=۰/۹۴۷)
۱	ML	Steel	Driven	Open	۱۳۷۰/۰۰	۱۱۳۴/۳۳	۱۷۹۵/۴۸	۱۰۷۳/۱۳
۲	ML	Concrete	Driven	Closed	۲۹۴۶/۰۰	۲۸۵۰/۶۰	(۱) --	(۳) --
۳	ML	Concrete	Driven	Closed	۲۴۱۴/۰۰	۲۷۲۷/۸۰	--	--
۴	ML	Steel	Driven	Closed	۱۱۰۰/۰۰	۲۰۲۵/۹۶	۱۳۶۴/۶۷	۱۹۱۲/۷۹
۵	ML	Composite	Driven	Closed	۲۴۱۴/۰۰	۲۱۹۴/۰۴	--	--
۶	ML	Concrete	Bored	Closed	۱۷۰۱/۰۰	۱۸۹۱/۲۱	۳۵۶/۷۲	۲۵۶۴/۰۹
۷	ML	Steel	Driven	Closed	۴۴۶۰/۰۰	۴۱۶۸/۱۹	۴۴۰۰/۹۶	۴۰۵۲/۳۱
۸	ML	Steel	Driven	Closed	۱۰۱۰/۰۰	۸۸۷/۷۱	۱۰۹۰/۱۲	۷۶۶/۴۰
۹	ML	Concrete	Driven	Closed	۲۹۵۰/۰۰	۲۷۱۲/۶۸	۳۱۹۹/۸۵	۳۹۲۴/۸۶
۱۰	ML	Concrete	Bored	Closed	۵۸۵۰/۰۰	۵۹۷۸/۲۲	۳۵۸/۵۴	۶۴۶۵/۹۹
۱۱	ML	Concrete	Driven	Closed	۱۲۶۰/۰۰	۱۳۰۹/۲۰	۱۴۱۹/۸۷	۹۸۴/۲۶
۱۲	ML	Steel	Driven	Closed	۱۸۰۰/۰۰	۱۷۰۳/۰۸	--	۲۱۴۴/۱۵
۱۳	ML	Concrete	Bored	Closed	۷۲۵/۰۰	۱۰۱۷/۷۰	۳۵۶/۹۰	۴۱۲/۸۷
۱۴	ML	Steel	Driven	Closed	۱۶۲۰/۰۰	۱۷۳۷/۲۴	--	۱۳۴۲/۹۹
۱۵	ML	Steel	Driven	Closed	۸۰۰/۰۰	۶۳۳/۰۶	۵۶۸/۲۴	۱۱۱۹/۸۸
۱۶	ML	Concrete	Driven	Closed	۱۴۲۰/۰۰	۱۴۵۹/۷۷	۳۰۰۲/۲۹	۱۵۲۲/۲۸
۱۷	ML	Concrete	Driven	Closed	۱۴۷۰/۰۰	۹۲۵/۲۳	۱۳۱۳/۹۶	۱۴۶۲/۸۳
۱۸	ML	Concrete	Bored	Closed	۸۸۰/۰۰	۱۰۸۳/۶۳	۳۵۷/۰۷	۱۸۳۶/۵۶
۱۹	ML	Steel	Driven	Open	۱۲۴۰/۰۰	۱۰۳۶/۷۰	۷۰۰/۴۴	۱۳۹۷/۲۶

۱. به دلیل محدودیت جنس مصالح یا قرار نگرفتن در محدوده ی مجاز داده‌های سازگار با مدل ANN، پیش‌بینی ظرفیت باربری با مدل شبکه عصبی انجام نشده است.
۲. به دلیل کمبود اطلاعات، در سه نمونه از داده‌های فوق از روش de Ruiter&Beringen برای تعیین ظرفیت باربری استفاده نشده است.



(ب)



(الف)

شکل ۳ ظرفیت باربری اندازه‌گیری شده در برابر پیش‌بینی شده توسط مدل SVM گسترش داده شده به کمک تابع کرنل چند جمله ای (الف) بر روی داده های مجموعه آموزش (ب) بر روی مجموعه داده های آزمایش (ارزیابی)

می‌شود که مدل‌های SVM در برابر این روش سنتی نیز پیش‌بینی بهتری از ظرفیت باربری نهایی شمع‌های منفرد تحت اثر بار محوری ارائه می‌دهند.

برای بررسی حساسیت متغیرهای ورودی بر ظرفیت باربری نهایی از روش معرفی‌شده توسط Liang و همکاران [59] استفاده شده است. در این روش هر بار یکی از متغیرهای ورودی به اندازه‌ی مقداری ثابت تغییر می‌کند و مقدار خروجی به ازای این ورودی‌های جدید محاسبه می‌شود. در این مقاله نرخ تغییر ۲۰٪ برای هر متغیر ورودی به کار گرفته شده است [9]. مقدار حساسیت نیز از رابطه‌ی زیر محاسبه می‌شود:

$$X_i = \frac{1}{r} \sum_{j=1}^r \left(\frac{\text{درصد تغییر خروجی}}{\text{درصد تغییر ورودی}} \right)_j \times 100 \quad (16)$$

در این رابطه r برابر است با تعداد نمونه‌ها. برای تحلیل حساسیت، از پارامترهای مساحت نوک شمع، پیرامون شمع در تماس با خاک و مقاومت مشخصه‌ی خاک در قالب q_c و f_s و q_{tip} استفاده و در نهایت درصد تأثیر هر یک از پارامترهای فوق نسبت به سایر پارامترها در جدول (۹) ارائه شده است. با توجه به این که مدل گسترش‌یافته بر مبنای تابع کرنل پایه شعاعی عمل کرد بهتری از خود نشان داده، آنالیز حساسیت فقط روی این مدل انجام شده است. با توجه به جدول (۹) مشاهده می‌شود که مشخصات خاک در قالب نتایج آزمایش CPT با دارا بودن سهمی معادل با ۳۹/۵۳٪ که حاصل مجموع مقادیر سه ردیف آخر جدول ۹ می‌باشد، بیش‌ترین تأثیر را بر ظرفیت باربری نهایی شمع دارد. پس از این عامل، به ترتیب طول مدفون شمع، مساحت نوک شمع و پیرامون شمع در تماس با خاک موارد اثرگذار در ظرفیت باربری می‌باشند. نتیجه‌ی فوق با فیزیک خاک و شمع مطابقت

برای مقایسه‌ی نتایج حاصل از این پژوهش با سایر مدل‌ها، از مدل شبکه عصبی مصنوعی (ANN) و یک روش سنتی تعیین ظرفیت باربری مبتنی بر نتایج CPT استفاده می‌شود. این روش‌ها بر همان نمونه‌هایی که برای ارزیابی مدل‌های SVM مورد استفاده قرار گرفتند، اعمال شده‌اند و نتایج حاصل با مدل‌های SVM مقایسه شده است. [2] Shahin برای پیش‌بینی ظرفیت باربری شمع‌ها با استفاده از نتایج CPT به صورت مجزا برای شمع‌های کوئیدنی و غیر کوئیدنی مدل‌هایی با استفاده از شبکه‌ی عصبی مصنوعی گسترش داده و به صورت روابطی ارائه کرده است. نتایج حاصل از مدل شبکه‌ی عصبی در جدول (۸) ارائه شده است. نتایج حاصل از مدل ANN گسترش یافته روی شمع‌های کوئیدنی بر داده‌های آزمایش دارای $R=0/89$ و $RMSE=567/6$ kN می‌باشد. با توجه به جدول (۸)، نتایج مدل ارائه‌شده برای شمع‌های غیر کوئیدنی سازگاری مناسبی با مقادیر واقعی ندارد و نتایج بسیار دور از واقعیت هستند. بدین ترتیب، با مقایسه‌ی نتایج مدل‌های ANN و SVM، مشاهده می‌شود که مدل ماشین بردار پشتیبان عمل کرد بهتری نشان می‌دهد.

برای ارزیابی عمل‌کرد مدل‌های SVM، علاوه بر مدل شبکه‌ی عصبی، از یک روش سنتی مبتنی بر CPT نیز استفاده شده است. تا کنون روش‌های گوناگونی برای پیش‌بینی ظرفیت باربری شمع‌ها با استفاده از نتایج CPT پیشنهاد شده است. در این میان روش de Ruyter and Beringen [57] یکی از روش‌های متداول است که کارایی بهتر آن نسبت به روش‌های سنتی دیگر تأیید شده است [58]. مقایسه‌ی نتایج این روش با مقادیر اندازه‌گیری شده‌ی ظرفیت باربری، ضریب هم‌بستگی ۰/۹۴۷ و $RMSE=528/57$ kN را نشان می‌دهد. با مقایسه‌ی نتایج این روش با نتایج مدل‌های SVM مشاهده

(روش de Ruiter and Beringen [57])، برتری مدل‌های ارائه شده در این پژوهش را تأیید می‌کند.

خوبی نشان می‌دهد.

جدول ۹ نتایج آنالیز حساسیت در مدل آموزش داده شده با کرنل پایه شعاعی

متغیر ورودی	حساسیت (%)
A_{tip}	۲۱/۳۵
O	۱۵/۸۱
L_{embed}	۲۳/۳۰
q_c	۱۲/۶۱
f_s	۱۲/۵۰
$q_c(tip)$	۱۴/۴۲

فهرست نشانه‌ها

سطح مقطع نوک شمع	A_{tip}
بایاس	b
مقدار بهینه ی بایاس	b_0
پارامتر جریمه یا پارامتر تنظیمی	C
کواریانس میان خروجی مدل و خروجی اندازه‌گیری شده	$C_{y_j d_j}$
توان کرنل چند جمله ای	d
مقدار خروجی مدل	d_j
میانگین خروجی‌های مدل	\bar{d}
اصطکاک جدار مخروط در CPT	f_s
مقادیر متوسط اصطکاک جدار مخروط در امتداد قسمت‌های اول، دوم و سوم	f_{s1}, f_{s2}, f_{s3}
طول مدفون شمع	\bar{f}_s
مقدار متوسط اصطکاک جدار مخروط در طول مدفون شمع	L_{embed}
طول مدفون شمع	L
تابع لاگرانژ	l
تعداد نمونه‌ها	m
بعد بردار x	n
تعداد نمونه‌ها (در محاسبه ی ضریب هم‌بستگی)	O
پیرامون شمع	q_c
مقاومت نوک مخروط در CPT	q_{c1}, q_{c2}, q_{c3}
مقادیر متوسط مقاومت نوک مخروط در امتداد قسمت‌های اول، دوم و سوم	\bar{q}_c
طول مدفون شمع	q_{ctip}
مقدار متوسط مقاومت نوک مخروط زیر نوک شمع	r
تعداد نمونه‌ها در تحلیل حساسیت	

نتیجه‌گیری

در این مقاله قابلیت روش ماشین بردار پشتیبان برای پیش‌بینی ظرفیت باربری نهایی شمع‌های تحت اثر بار محوری ارزیابی شده است. در این پژوهش از توابع کرنل پایه شعاعی و چند جمله‌ای برای گسترش مدل‌های غیرخطی بر یک مجموعه شامل ۱۰۸ نمونه از اطلاعات اندازه‌گیری‌های میدانی ظرفیت باربری استفاده شده است.

بررسی نتایج نشان می‌دهد که مدل ماشین بردار پشتیبان دقت مناسبی در پیش‌بینی ظرفیت باربری شمع‌ها در محدوده ی داده‌های مورد استفاده دارد، به‌طوری که در نتایج ارزیابی مدل بهینه ی گسترش داده‌شده بر مبنای تابع کرنل پایه شعاعی بر روی داده‌های آزمایش مقادیر $R=0.971$ و kN و $RMSE=3.08$ به دست آمده‌اند. تحلیل حساسیت بر مدل و با استفاده از داده‌های ورودی که دارای مقادیر کمی هستند انجام شده است و بر اساس نتایج به دست آمده، مشخصات خاک (در قالب نتایج آزمایش CPT) با سهمی معادل با 39.53% مهم‌ترین اثر را بر ظرفیت باربری دارا می‌باشد.

علاوه بر هم‌بستگی بسیار خوب نتایج مدل SVM با مقادیر واقعی، مقایسه عمل‌کرد این مدل با نتایج مدل شبکه عصبی (ارائه شده توسط Shahin [2]) و یک مدل سنتی مبتنی بر CPT

عرض کرنل پایه شعاعی	σ	مجموعه اعداد حقیقی	R
انحراف استاندارد خروجی اندازه‌گیری شده	σ_{y_j}	بردار وزن	w
انحراف استاندارد خروجی مدل	σ_{a_j}	بردار وزن بهینه	w_0
عملگر ضرب داخلی	\langle , \rangle	بردار مقادیر ورودی	x
عملگر نرم بردار	$\ \cdot \ ^2$	دو بردار پشتیبان	x_r, x_s
		مقدار خروجی	y
		میانگین خروجی‌های اندازه‌گیری شده	\bar{y}
		ضرایب لاگرانژ	α, α^*

مراجع

1. Lee, I. M., and Lee, J. H., "Prediction of pile bearing capacity using artificial neural networks", *J. Computers and Geotechnics*, Vol. 18, pp. 189-200, (1995).
2. Shahin, M. A., "Intelligent computing for modeling axial capacity of pile foundations", *J. Can. Geotech.*, Vol. 47, pp. 230-243, (2010).
3. Shahin, M. A., Jaksa, M. B., and Maier, H. R., "Predicting the settlement of shallow foundations on cohesionless soils using back-propagation neural networks", *Research Report No. R 167*, Dept. Civil & Env. Eng., Uni. of Adelaide, February, 16 pp., (2000).
4. Dibike, Y.B., Velikov, S., Solomatine, D. and Abbot, M.B., "Model induction with support vector machines-introduction and applications", *J. Comput. Civ. Eng.*, ASCE, Vol. 15, No. 3, pp. 208-216, (2001).
5. Pooya Nejad, F., Jaksa, M. B., Kakhi, M., and McCabe, B. A., "Prediction of pile settlement using artificial neural networks based on standard penetration test data.", *J. Computers and Geotechnics*, Vol. 36, pp. 1125-1133, (2009).
6. Ardalan H., Eslami A. and Nariman-Zadeh N., "Piles shaft capacity from CPT and CPTu data by polynomial neural network and genetic algorithms", *J. Computers and Geotechnics*, Vol. 36, pp. 616-625, (2009).
7. Goh, A. T. C., and Goh, S. H., "Support vector machines: their use in geotechnical engineering as illustrated using seismic liquefaction data.", *J. Computers and Geotechnics*, Vol. 34, pp. 410-421, (2007).
8. Samui, P., "Support vector machine applied to settlement of shallow foundations on cohesionless soils.", *J. Computers and Geotechnics*, Vol. 35, pp. 419 – 427, (2008).
9. Samui, P., Sitharam, T. G., and Kurup, P. U., "OCR prediction using support vector machine based on piezocone data.", *J. Geotech. and Geoenv. Eng.*, ASCE, Vol. 134, No. 6, pp.894-898, (2008).

10. Pal, M., and Deswal, S., "Modeling pile capacity using Gaussian process regression.", *J. Computers and Geotechnics*, Vol. 37, pp. 942-947, (2010).
11. Cristianini, N., and Shaw-Taylor, J., "An introduction to support vector machines and other kernel-based learning methods.", Cambridge, Cambridge University Press, (2000).
12. Pal, M., and Deswal, S., "Modeling pile capacity using support vector machines and generalized regression neural network.", *J. Geotech. and Geoenv. Eng.*, ASCE, Vol. 134, No. 7, pp. 1021-1024, (2008).
13. Eslami, A., "Bearing capacity of piles from cone penetration test data", Ph.D. thesis, *University of Ottawa*, (1996).
14. Pooya Nejad, F. and Jaksa, M. B., "Prediction of Pile Settlement Using Artificial Neural Networks Based on Cone Penetration Test Data." Proceedings of the GeoFlorida Conference, Florida, February 20-24, pp. 1432-1441, (2010).
15. Ballouz, M., Nasar, G., and Briaud, J.L., "Dynamic and static testing of nine drilled shafts at Texas A&M University geotechnical sites.", Research Report, Civil Engineering, Texas A&M University, College Station, Texas, 127, (1991).
16. Florida Department of Transportation (FDOT), "Large diameter cylinder pile database", Research Management Center, (2003).
17. Fellenius, B.H., Santos, J. A., and Fonseca, A. V., "Analysis of piles in residual soil-the ISC'2 prediction.", *J. Can. Geotech.*, Vol. 44, pp. 201-220, (2007).
18. Abu-Farsakh, M. Y., Titi, H. H., and Tumay, M. T., "Prediction of bearing capacity of friction piles in soft Louisiana soils by cone penetration test", *Transportation Research Record: J. Transportation Research Board*, No. 1657, 32-39, (1999).
19. U.S. Department of Transportation, "A laboratory and field study of composite piles for bridge substructures", FHWA-HRT-04-043, (2006).
20. Fellenius, B. H., Harris, D. E., and Anderson, D. G., "Static loading test on a 45m long pile in Sanpoint, Idaho.", *J. Can. Geotech.*, Vol. 41, pp. 613-628, (2004).
21. McCabe, B. A., and Lehane, B. M., "Behavior of axially loaded pile groups driven in clayey silt.", *J. Geotech. and Geoenv. Eng.*, ASCE, Vol. 132, No. 3, pp. 401-410, (2006).
22. Paik, K. H., and Salgado, R., "Determination of bearing capacity of open-ended piles in sands.", *J. Geotech. and Geoenv. Eng.*, ASCE, Vol. 129, No. 1, pp. 46-57, (2003).
23. Adelaide Department of Transportation, Bakewell Bridge, Adelaide, Australia.
24. Omer, J. R., Delpak, R., and Robinson, R. B., "A new computer program for pile capacity prediction using CPT data.", *J. Geotechnical and Geological Engineering*, Vol. 24, pp. 399-426, (2005).

25. Harris, E., and Mayne, P., "Axial compression behavior of two drilled shafts in Piedmont residual soils.", *Proc. Int. Conf. on Design and Construction of Deep Foundation*, FHWA, Washington, D.C., Vol.2, pp. 352-367, (1994).
26. Piexoto, A. S. P., de Albuquerque, P. J. R., and de Carvalho, D., "Utilization of SPT-T, CPT and DMT tests to predict the ultimate bearing capacity of precast pile in Brazilian unsaturated residual soil.", *Proc. Conf. on Advances in Unsaturated Geotechnics, GSP No. 99*, ASCE, Denver, 32-39, (2000).
27. Brown, M. J., Hyde, A. F. L., and Anderson, W. F., "Analysis of a rapid load test on an instrumented bored pile in clay.", *J. Géotechnique*, Vol. 56, No. 9, pp. 627-638, (2006).
28. Campnella, R. G., Robertson, P. K., Davis, M. P., and Sy, A., "Use of in-situ tests in pile design", *Proc. of 12th Int. Conf. on Soil Mechanics and Foundation Engineering, ICSMFE*, Rio de Janeiro, Vol. 1, pp. 199-203, (1989).
29. Finno, R. J., "Subsurface conditions and pile installation data.", *Proc. Symp. on Predicted and Observed Behavior of Piles, GSP No. 23*, ASCE, Evanston, pp.1-74, (1989).
30. O'Neil, M. W., "Pile group prediction symposium - summary of prediction results", FHWA, draft report, (1988)
31. Altaee, A., Fellenius, B. H., and Evgin, E., "Axial Load transfer for piles in sand. 1-Tests on an instrumented precast pile.", *J. Can. Geotech.*, Vol. 29, pp. 11-20, (1992).
32. CH2M Hill, "Geotechnical report on indicator pile testing and static pile testing." Berths 225-229 at Port of Los Angeles, CH2M Hill, Los Angeles, (1987).
33. Matsumoto, T., Michi, Y., and Hirono, T., "Performance of axially loaded steel pipe piles driven in soft rock.", *J. Geotech. and Geoenv. Eng.*, ASCE, Vol. 121, No. 4, pp. 305-315, (1995).
34. Yen, T. L., Lin, H., Chin, C. T., and Wang, R. F., "Interpretation of instrumented driven steel pipe piles.", *Proc. Foundation Eng. Cong.: Current Principle and Practices, GSP No. 22*, ASCE, pp. 1293-1308, (1989).
35. Tumay, M. Y., and Fakhroo, M., "Pile capacity in soft clays using electric QCPT data", *Proc. Conf. on Cone Penetration Testing and Experience*, ASCE, St Louis, pp. 434-455, (1981).
36. Avasarala, S. K. V., Davidson, J. L., and McVay, A. M., "An evaluation of predicted ultimate capacity of single piles from spile and unpile programs" *Proc. Int. Conf. on Design and Construction of Deep Foundations, FHWA*, Orlando, Vol. 2, pp. 712-723, (1994).
37. Reese, J. D., O'Neil, M. W. and Wang, S. T., "Drilled Shaft Tests", Interchange of West Belt Roll Road and US290 Highway, Texas. Final Report. Lymon C. and Associates. Austin, (1988).

38. Viergever, M. A., "Relation between cone penetration and static loading of piles on locally strongly varying sand layers", *Proc. of 2nd European Symp, on Penetration Testing*, Amsterdam, Vol. 2, pp. 927-932, (1982).
39. Gambini, F., "Experience in Italy with centricast concrete piles" *Proc. Int. Symp, on Penetrability and Drivability of Piles*, San Francisco, Vol.1, pp. 97-100, (1985).
40. Neveles, J. B. and Donald, R. S., "Comparison of settlement prediction for single piles in sand based on penetration test results." *Proc. of Settlement-94, Vertical and Horizontal Deformation of Foundations and Embankments, GSP No. 40*, ASCE, College Station, pp. 1028-1039, (1994).
41. Laier, J. E., "Predicting the ultimate compressive capacity of long 12-H-74 steel pile" *Proc. Int. Conf. on Design and Construction of Deep Foundations*, FHWA, Orlando, Vol. 2, pp. 1804-1818, (1994).
42. Tucker, L. M., and Briaud, J. L., "Analysis of pile load test program at Lock and Dam 26 replacement project" Final report, US Army Corps of Engineering, (1988).
43. Horvitz, G. E., Stettler, D. R., and Crowser, J. C., "Comparison of predicted and observed pile capacity" *Proc. Symp, on Cone Penetration Testing*, ASCE, St. Louis, pp. 413-433, (1986).
44. Mayne, P. W., "Axial load-displacement behavior of drilled shaft foundation in Piedmont residuum" Research Report, Rep. No. FHWA-41-30-2175, Federal Highway Administration, Virginia, (1993).
45. Haustoefer, I. J., and Plesiotis, S., "Instrumented dynamic and static pile load testing at two bridges" *Proc. 5th Australia-New Zealand Conf. on Geomechanics, Prediction vs. Performance*, Sydney, pp. 514-520, (1988).
46. Albiero, J. H., Sacilotto, A. C., Mantilla, J. N. Teixeira, J., and Carvalho, D., "Successive load tests on bored piles" *Proc. 10th Pan-American Conf. on Soil Mechanics and Foundation Engineering*, Vol. 2, Mexico City, pp. 992-1002, (1995).
47. Nottingham, L. C., "Use of quasi-static friction cone penetrometer data to predict load capacity of displacement piles" Ph.D. Thesis, Dept. Civil Eng., University of Florida, (1975).
48. O'Neil, M. W., "Reliability of pile capacity assessment by CPT in overconsolidated clay" *Proc. Conf. on In-Situ Tests in Geotechnical Engineering, GSP No. 6*, ASCE, Virginia, pp. 237-256, (1986).
49. URKKADA Technology Ltd., "Dynamic testing of piles and analysis, Puerto Rico", Final Report, Project 9509DH17, (1995).
50. Briaud, J. L., and Tucker, L. M., "Measured and predicted axial capacity of 98 piles" *J. Geotech. Eng.*, ASCE, Vol. 114, No. 9, pp. 984-1001, (1988).

51. Hansen, J. B., "Discussion on hyperbolic stress-strain response: Cohesive soils", *J. Soil Mech. and Found. Eng.*, ASCE, Vol. 89, pp. 241-242, (1963).
52. Fellenius, B.H., "What capacity value to choose from the results a static loading test?", Deep Foundation Institute, Fulcrum, (2001).
53. Prakash, S. and Sharma, H. D. "*Pile Foundations in Engineering Practice*", John Wiley & Sons Inc, (1990).
54. Gunn, S. R., "Support vector machines for classification and regression", Technical Report, *University of Southampton*, (2001).
55. Smith, M., "*Neural network for statistical modeling.*" *Van Nostrand-Reinhold*, New York; (1993).
56. Hecht-Nielson, R. "Neurocomputing", *Addison-Wesley, Publishing Company, Reading, MA*, (1990).
57. De Ruiter, J., and Beringen, F. L., "Pile foundations for large north sea structures", *J. Marine Geotechnology*, Vol. 3, pp. 267-314, (1979).
58. Abu-Farsakh, M. Y., and Titi, H. H., "Assessment of direct cone penetration test methods for predicting the ultimate capacity of friction driven piles," *J. Geotech. and Geoenv. Eng.*, ASCE, Vol. 130, No. 9, pp. 935-944, (2004).
59. Liong, S. Y., Lim, W. H., and Paudyal, G. N., "River stage forecasting Bangladesh: neural network approach", *J. Comp. Civ. Eng.*, ASCE, Vol. 14, No. 1, pp.1-8, (2000).