



پیش بینی نشست شمع‌ها بر اساس مقاومت برشی زهکشی نشده خاک با استفاده از ماشین بردار پشتیبان

مهديه عربی^۱، فریدون پویانزاد^۲

۱- دانشجوی کارشناسی ارشد خاک و پی دانشگاه فردوسی مشهد

۲- استادیار گروه عمران دانشکده مهندسی دانشگاه فردوسی مشهد

ma_ar682@stu-mail.um.ac.ir
pooyaf@um.ac.ir

خلاصه

با پیشرفت روش‌های یادگیری ماشین، علوم مختلف برای مدل‌سازی دقیق‌تر پدیده‌های خود به سمت این روش‌ها گرایش یافتند که مهندسی ژئوتکنیک نیز از آن دسته مستثنی نبوده است. در سال‌های اخیر روش ماشین بردار پشتیبان^۱ یکی از این روش‌هایی است که در علوم مختلف، نتایج خوبی از خود نشان داده است. در رابطه با طراحی شمع‌ها در مهندسی ژئوتکنیک محاسبه دقیق نشست شمع بسیار حائز اهمیت است، زیرا افزایش بیش از حد نشست شمع‌ها سرویس‌دهی سازه‌های متصل به آن‌ها را دچار مخاطره می‌نماید. در این مقاله یک مدل ماشین بردار پشتیبان، برای پیش‌بینی نشست شمع‌ها بر اساس مقاومت برشی زهکشی نشده خاک ارائه شده است. این مدل بر مبنای ۲۵۳ داده در مقیاس واقعی طراحی شده است. نتایج نشان می‌دهند که مقادیر شبیه‌سازی شده با ماشین بردار پشتیبان به نتایج واقعی نزدیک است و مدل کارایی بالایی را از خود نشان می‌دهد.

کلمات کلیدی: ماشین بردار پشتیبان SVM، مقاومت برشی زهکشی نشده، نشست شمع.

۱. مقدمه

نشست شمع‌ها یکی از مهم‌ترین مسائلی است که مهندسان به دنبال رسیدن به یک مدل بهینه برای تخمین آن هستند. نشست فونداسیون‌های عمیق در اثر کاهش حجم ناشی از افزایش تنش لایه‌های زیرین خاک، ایجاد می‌شود. نشست‌ها شامل مجموع نشست آبی یا الاستیک و نشست درازمدت یا تحکیمی می‌باشند. نشست آبی بلافاصله پس از احداث شالوده رخ می‌دهد و حال آن که نشست تحکیمی یک نشست تابع زمان می‌باشد و علت وقوع آن خروج آب از میان حفرات خاک به علت اضافه فشار تحمیل شده بر آن‌ها می‌باشد که این عمل در خاک‌های دانه‌ای سریع اتفاق افتاده و در خاک‌های ریزدانه به کندی صورت می‌گیرد. در مورد خاک‌های چسبنده فشار پیش تحکیمی نیز نقش مهمی در میزان نشست دارد. نشست‌های آبی فونداسیون‌ها که بلافاصله پس از اعمال بار ایجاد می‌شوند باعث ایجاد تغییرشکل‌های سریع در سازه متصل به آن‌ها شده و در نهایت ممکن است باعث انهدام سازه شوند، لذا علاوه بر محاسبه ظرفیت باربری شمع‌ها پیش‌بینی نشست شمع‌ها نیز عامل موثر در طراحی خواهد بود [1].

آزمایش بارگذاری استاتیکی شمع‌ها یک آزمایش پرهزینه و زمان‌بر می‌باشد، این در حالی است که می‌توان با یک آزمایش ساده آزمایشگاهی مانند آزمایش مقاومت فشاری محدود نشده یا آزمایش‌های ساده صحرایی مانند آزمایش برش پره در خاک‌های چسبنده، یک رابطه بین نشست شمع و مقاومت برشی زهکشی نشده بدست آورد. مدل‌سازی با ماشین بردار پشتیبان، علاوه بر این که سبب کاهش حجم آزمایش‌ها و صرفه‌جویی در زمان و هزینه می‌شود، می‌تواند اطلاعات پیوسته‌ای از ساختگاه مورد نظر را فراهم سازد و دانش طراحان را به میزان قابل توجهی بهبود بخشد. نتایج مقالات نشان می‌دهد که این روش جدید کارایی بیشتری نسبت به سایر روش‌های عددی دارد [3,4]. اغلب روش‌های موجود برای محاسبه نشست شمع‌ها با در نظر گرفتن فرضیاتی که در نشست مؤثر می‌باشند مسأله را ساده‌تر کرده‌اند. بنابراین در روش‌های متفاوت پیش‌بینی نشست، سازگاری وجود ندارد و

¹ . Support Vector Machine(SVM)

روش های دیگری مورد نیاز است که بتواند بر محدودیت های روش های موجود غلبه نموده و دقت کافی را در پیش بینی نشست دارا باشد. هدف از این مقاله، پیش بینی نشست شمع ها بر اساس یک مدل ماشین بردار پشتیبان می باشد. این مدل بر اساس ۲۵۳ داده در مقیاس واقعی طراحی خواهد شد.

۲. ماشین بردار پشتیبان (SVM)

سابقه استفاده از روش های یادگیری ماشین به شکل نوین و امروزی به بعد از جنگ جهانی دوم و ابداع رایانه های مدرن (سال های ۱۹۵۰ میلادی) باز می گردد. یکی از روش های نسبتاً جدید در مسائل دسته بندی و رگرسیون روش ماشین بردار پشتیبان (SVM) است که امروزه از آن به عنوان یکی از معتبرترین ابزارهای یادگیری ماشین استفاده می شود. ماشین بردار پشتیبان یک روش از روش های یادگیری با نظارت است که در سال ۱۹۹۲ توسط Vapnik و Chervonenkis بر پایه تئوری یادگیری آماری معرفی شد. تئوری آماری Vapnik سابقه ای نسبتاً طولانی دارد. او و همکاران در سال ۱۹۶۳، تئوری ابرصفحه بهینه را به عنوان طبقه بندی کننده خطی ارائه دادند. آن ها همچنین در سال ۱۹۹۲، طبقه بندی کننده های غیر خطی را با کمک توابع کرنل معرفی کردند. اصول اساسی آن چه که امروز به عنوان ماشین بردار پشتیبان شناخته می شود نتایج کارهای او و همکاران است که در سال ۱۹۹۵ منتشر گردید. و در نهایت گسترش ماشین بردار پشتیبان بر اساس رگرسیون نیز در سال ۱۹۹۶ توسط وی و همکاران او به نتیجه رسید [2].

به طور کلی ماشین بردار پشتیبان در مسائل طبقه بندی دو یا چند کلاسه به صورت خطی یا غیرخطی و رگرسیون مورد استفاده قرار می گیرد. این روش نتایج خوبی در مدل سازی پدیده های مهندسی ژئوتکنیک داشته است [3,4,5,6]. در این روش داده ها به دو دسته آموزش و آزمایش تقسیم می شوند. مدل ساخته شده با داده های آموزش سازگار شده و با استفاده از داده های آزمایش تعمیم یابی مدل ارزیابی می شود.

۳. رگرسیون در ماشین بردار پشتیبان

منظور از رگرسیون، به دست آوردن یک ابرصفحه است که بر داده های مورد نظر برازش داده می شود. فاصله هر نقطه از این ابرصفحه نشان دهنده خطای آن نقطه خاص است. بهترین روشی که تاکنون برای رگرسیون خطی پیشنهاد شده است، روش حداقل مربعات^۲ می باشد [2].

در SVM حل مسأله رگرسیون با معرفی یک تابع تلفات^۳ جدید که در آن حداقل خطایی به میزان ε قابل صرف نظر کردن است، بررسی می گردد. یک مجموعه داده به صورت داده های ورودی و خروجی به صورت $\{(X_1, y_1), \dots, (X_n, y_n)\} \in R^N, y \in R$ که در آن X ورودی و y خروجی است، مفروض می باشد. هدف این است که با یک تابع خطی به شکل $f(X) = (W.X) + b$ خروجی ها بر مبنای ورودی ها تخمین زده شود. در این رابطه W بردار وزن و b بایاس می باشد. تابع تلفات Vanpnik با منطقه غیر حساس به عرض ε (خطای مورد قبول در تابع تلفات) به صورت زیر تعریف می گردد [7]:

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

با توجه به مطالب بالا، بهترین تابعی که عملیات رگرسیون را در روش ماشین بردار پشتیبان انجام می دهد، با کمینه کردن تابع زیر به دست می آید [2]:


$$\begin{cases} \text{Minimize} & \phi(W, \xi^*, \xi) = \frac{1}{2} \|W\|^2 + C(\sum \xi_i^* + \sum \xi_i) \\ & y_i - ((W.X_i) + b) \leq \varepsilon + \xi_i \\ \text{Subject to} & ((W.X_i) + b) - y_i \leq \varepsilon + \xi_i^* \\ & \xi_i^*, \xi_i \geq 0 \quad i = 1, \dots, n \end{cases} \quad (2)$$

در رابطه فوق، $\|W\|^2$ نرم بردار وزن (این مقدار برابر با $\sum W_i^2$ می باشد)، ξ_i^* و ξ_i نیز متغیرهای کمکی می باشند که این پارامترها در شکل (۱) مشخص شده اند. پارامتر C تعادل میان پیچیدگی ماشین و تعداد نقاط تفکیک پذیر را کنترل می کند و می تواند به عنوان یک پارامتر تنظیم کننده شناخته شود. مقدار آن عموماً از طریق سعی و خطا با به کارگیری داده های آموزش و آزمایش تعیین می گردد. اگر به C مقدار بزرگی اختصاص داده شود، در حقیقت به ماشین آموزش داده شده است تا خطا را روی داده های آموزش کم کند، اما قابلیت تعمیم یابی کاهش می یابد. حال اگر به C مقدار کوچکی اختصاص یابد، جریمه کمتری برای خطا وجود دارد (ماشین اجازه دارد بر روی داده های آموزش خطای بیشتری بپذیرد) که موجب کمینه سازی حاشیه با خطاها می شود، پس قابلیت تعمیم یابی بالا می رود. بنابراین اگر C بی نهایت بزرگ باشد، ماشین اجازه وقوع هیچ خطایی را در داده های آموزش ندارد

^۲ . Least Squares

^۳ . Loss Function

و حاصل یک مدل پیچیده خواهد بود. از سوی دیگر، وقتی C به سمت صفر میل می کند، نتایج می تواند مقدار زیادی خطا را تحمل کرده و پیچیدگی مدل کمتر خواهد بود [4].



شکل ۱- چگونگی برازش داده‌ها در فضای ورودی

مقدار پارامتر ϵ نیز در وضعیت بردارهای پشتیبان و در نتیجه کارایی مدل بسیار مؤثر است. با انتخاب مقادیر خیلی بزرگ برای ϵ بردارهای پشتیبان کاهش داده می شود، ولی باند ϵ عریض تر می شود و دامنه خطای مجاز بالا می رود. مقادیر خیلی کوچک ϵ نیز موجب می شود تا بردارهای پشتیبان زیاد شده و احتمال خطر بیش آموزش افزایش می یابد [4].

ماشین بردار پشتیبان یک روش یادگیری ماشین بر مبنای تئوری یادگیری آماری است. در SVM از اصول کمینه سازی ریسک ساختاری^۴ (SRM) استفاده شده است. در حالی که سایر روش‌ها از اصول کمینه سازی ریسک تجربی^۵ (ERM) بهره برده اند. ثابت شده است که اصول SRM از ERM عملکرد بهتری دارد [2]. در صورتی که مجموعه داده‌های آموزش خیلی بزرگ باشد، ریسک تجربی به ریسک واقعی همگرا می شود. در SVM کمینه سازی ریسک با کمینه کردن ریسک ساختاری انجام می شود.

هدف از کمینه کردن ریسک ساختاری یعنی هم زمان با کمینه کردن ریسک تجربی، قابلیت تعمیم یابی، بیشینه گردد. در حالی که در شبکه‌های عصبی مصنوعی از اصول کمینه سازی ریسک تجربی استفاده می شود. در این روش برای غلبه با مشکل تعمیم یابی نامناسب، باید شبکه به طور مناسب طراحی شود. در طول آموزش، شبکه طراحی شده تعداد خطاها را روی داده‌های آموزش کمینه می کند. این در حالی است که شبکه بر روی داده‌های آموزش خیلی خوب عمل کرده و حتی ریسک تجربی را به صفر می رساند اما بر روی داده‌های آزمایش عملکرد مناسبی ندارد. بنابراین، باید ساختار مناسبی انتخاب گردد که علاوه بر کمینه کردن خطاها، قابلیت تعمیم یابی خوبی نیز داشته باشد.

قدرت محاسباتی ماشین‌های یادگیری خطی محدود است. راهکاری که ماشین بردار پشتیبان از آن استفاده می کند، بهره گیری از توابع کرنل^۶ است. به این ترتیب که با تصویر کردن داده‌ها به یک فضای ویژگی^۷ با ابعاد بزرگ تر توسط تابع کرنل قدرت محاسباتی ماشین‌های یادگیری خطی افزایش می یابد [2]. چند نمونه از توابع کرنل مهم که عموماً در کاربردهای مهندسی متداول هستند در ادامه معرفی می شوند:

$$K(x, x_i) = ((x \cdot x_i) + 1)^d$$

تابع کرنل چندجمله‌ای ساده^۸

$$K(x, x_i) = \exp(-\gamma |x - x_i|^2)$$

تابع کرنل پایه شعاعی^۹

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

تابع کرنل گوسی پایه شعاعی^{۱۰}

$$K(x, x_i) = \tanh(b(x \cdot x_i) - c)$$

تابع کرنل تانژانت هیپربولیک

در این روابط، K تابع کرنل، d درجه چندجمله‌ای، پارامتر γ ، σ و مقادیر b و c توسط کاربر و با سعی و خطا تعریف می شوند. مطالعات انجام شده نشان می دهند که تابع کرنل پایه شعاعی و گوسی پایه شعاعی در مسائل مهندسی عمران عملکرد بهتری دارد [3,4,5].

4 . Structural Risk Minimization

5 . Experimental Risk Minimization

6 . Kernel Functions

7 . Feature Space

8 . Polynomial Kernel

9 . Radial Basis Function(RBF)

10 . Gaussian RBF Kernel

۴. طراحی مدل

در این مقاله برای گسترش مدل ماشین بردار پشتیبان از ۲۵۳ مجموعه داده استخراج شده از آزمایش‌های بارگذاری استاتیکی شمع‌ها استفاده شده است. داده‌های استخراج شده از پژوهش‌های مختلف منتشر شده بدست آمده است. این اطلاعات شامل نشست اندازه‌گیری شده شمع و بار وارده نظیر (که از نمودارهای بار-تغییر مکان حاصل از بارگذاری شمع تا مرحله گسیختگی برداشت شده‌اند)، مشخصات هندسی شمع و مشخصات خاک می‌باشد. پارامترهای ورودی مدل شامل: ۱- فشار وارده بر شمع (MPa)، ۲- طول شمع (mm)، ۳- مقاومت برشی زهکشی نشده متوسط در طول شمع (kPa)، ۴- مدول الاستیسیته شمع (GPa)، ۵- محیط شمع (mm) و ۶- شکل شمع (دایره‌ای، مستطیلی و شش ضلعی) می‌باشند. خروجی مدل نیز، نشست اندازه‌گیری شده شمع می‌باشد. قابل ذکر است که دامنه نشست‌های اندازه‌گیری شده از آزمایش بارگذاری شمع بین ۰ تا ۴۸ میلیمتر می‌باشد.

۵. آماده‌سازی مدل

برای گسترش مدل ماشین بردار پشتیبان داده‌ها به دو دسته آموزش و آزمایش تقسیم‌بندی می‌شود [2,7]. در این مقاله تعداد ۲۱۶ داده از کل داده‌ها (۸۵/۴٪) برای آموزش و بقیه داده‌ها شامل ۳۷ داده (۱۴/۶٪) برای آزمایش کارآبی مدل مورد استفاده قرار گرفته شده است. مجموعه‌های آموزشی و آزمایشی به گونه‌ای تقسیم‌بندی شده‌اند که خصوصیات آماری تقریباً یکسانی داشته باشند. از سعی و خطا برای رسیدن به این هدف در یکسان‌سازی خواص آماری مجموعه‌های آموزشی و آزمایشی استفاده شده است. جدول (۱) خصوصیات آماری این دو مجموعه را نشان می‌دهد. پارامترهای آماری شامل میانگین، انحراف از معیار، ماکزیمم، می‌نیم و دامنه است.

پیش از شروع آموزش مدل، داده‌ها نرمالیزه می‌شوند. نرمالیزه کردن داده‌ها برای به حداقل رساندن تاثیر اختلاف مقیاس پارامترهای مختلف و اطمینان از یکسان بودن بازه پارامترهای ورودی می‌باشد. برای این منظور از رابطه زیر استفاده شده است:

$$\frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (۳)$$

جدول ۱- مشخصات آماری متغیرهای ورودی و خروجی

Input and Output parameters	Statistical parameters				
	mean	Std.Dev.	max	min	Range
Pressure, Q(MPa)					
Training set	6.74	6.77	29.33	0	29.33
Testing set	7.55	7.85	28.7	0.24	28.46
Pile length, L(mm)					
Training set	14945.09	6493.39	31400	4420	26980
Testing set	13074.86	6794.66	31400	5490	25910
Undrained shear strength, C _u (kPa)					
Training set	80.56	61.48	200	20	180
Testing set	82.70	60.81	200	20	180
Elastic modulus of the pile, E _p (GPa)					
Training set	32.96	13.62	41	10	31
Testing set	32.62	13.96	41	10	31
Pile perimeter, P(mm)					
Training set	1193.44	496.71	2856	667.6	2188.4
Testing set	1349.52	561.35	2856	667.6	2188.4
Pile settlement, S(mm)					
Training set	6.66	9.31	47.88	0	47.88
Testing set	7.49	9.01	33.44	0.69	32.75

۶. آموزش مدل و ارزیابی آن

برای گسترش مدل از توابع کرنل مختلفی که در قبل ذکر شد، استفاده شده است که تابع کرنل گوسی پایه شعاعی و تابع کرنل پایه شعاعی نتایج قابل قبولی از خود نشان دادند. در این پژوهش برای آموزش مدل و ارزیابی آن بر روی داده‌های آزمایش از نرم‌افزار MATLAB استفاده شده است. روش آموزش داده‌ها Online انتخاب شده است. در این روش آموزش، مدل به صورت مرحله به مرحله توسط قسمتی از داده‌ها (داده‌های آموزش) آموزش داده می‌شود. به عبارت دیگر مدل آموزش داده شده با هر داده جدید به‌هنگام می‌شود. پس از اتمام فرآیند آموزش مدل، عمل کرد آن توسط داده‌هایی که در فرآیند آموزش استفاده نشده‌اند (داده‌های آزمایش) ارزیابی می‌شوند. ارزیابی مدل به منظور اطمینان از توانایی مدل در کلیت بخشی در محدوده داده‌های آموزشی صورت می‌گیرد. چنانچه کارایی کافی باشد مدل قادر به تعمیم بوده و قدرتمند خواهد بود.

نتایج ارزیابی پیش‌بینی مدل به کمک شاخص‌های آماری نظیر ضریب هم‌بستگی^{۱۱} و ریشه میانگین مربعات خطا^{۱۲} ارائه شده است. ضریب هم‌بستگی، معیاری برای سنجش میزان انطباق مقادیر پیش‌بینی شده بر مقادیر اندازه‌گیری شده است و از رابطه زیر بدست می‌آید:

$$R = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (۴)$$

در این رابطه، x_i مقدار واقعی، y_i مقدار پیش‌بینی شده برای x_i ، \bar{x} ، \bar{y} ، میانگین x_i ها و y_i ها می‌باشد. مقادیر بالای R نشان دهنده ارتباط قوی بین مقادیر واقعی و مقادیر پیش‌بینی شده است و در مقابل مقادیر پایین R ارتباط ضعیف و یا عدم ارتباط بین مقادیر را نشان می‌دهد. هم‌چنین مقدار RMSE نیز از رابطه (۵) محاسبه می‌شود که در آن، n تعداد داده‌ها می‌باشد. باید دانست که RMSE برای اندازه‌گیری خطا بیشتر متداول است.

$$RMSE = \left\{ \frac{1}{n} \sum (y_i - x_i)^2 \right\}^{\frac{1}{2}} \quad (۵)$$

۷. بررسی نتایج

در این تحقیق چند مدل ماشین بردار پشتیبان برای پیش‌بینی نشست شمع‌ها بر اساس مقاومت برشی زهکشی نشده خاک انجام شده است که نتایج مدل با تابع کرنل پایه شعاعی (RBF) ارائه شده است. برای رسیدن به مدل بهینه، با ترکیب‌های مختلفی از پارامترهای c ، ε و پارامتر تابع کرنل (γ)، مدل SVM بر روی داده‌های آموزش گسترش داده شده و به کمک مجموعه داده‌های آزمایش، عمل کرد مدل بررسی می‌شود. جداول (۲) تا (۴) فرآیند بهینه‌سازی پارامترهای فوق را نشان می‌دهد. در هر یک از این جداول، نتایج مدل به ازای تغییرات یک پارامتر از پارامترهای سه گانه، در حالی که دو پارامتر دیگر ثابت هستند نشان داده شده است.

جدول ۲- ارزیابی مدل به ازای مقادیر مختلف پارامتر تابع کرنل (γ)

	$\varepsilon = 0.001$	$c = 100$
γ	R	RMSE
0.01	0.7658	0.1889
0.1	0.7650	0.1611
1	0.8926	0.0969
10	0.9526	0.0631
50	0.9470	0.0721
100	0.8880	0.1604
150	0.9785	0.0549
200	0.8546	0.1780
400	0.8595	0.1559

¹¹. Coefficient of Correlation(R)

¹². Root Mean Square Error(RMSE)

جدول ۳- ارزیابی مدل به ازای مقادیر مختلف پارامتر ε

ε	$\gamma = 150$	$c = 100$
	R	RMSE
0.0001	0.9638	0.0635
0.0005	0.9696	0.0588
0.001	0.9785	0.0549
0.005	0.9339	0.0799
0.01	0.8898	0.1150
0.05	0.8891	0.1749
0.1	0.8262	0.1960
0.5	0.8061	0.4237

جدول ۴- ارزیابی مدل به ازای مقادیر مختلف پارامتر c

c	$\varepsilon = 0.001$	$\gamma = 150$
	R	RMSE
0.01	0.7271	0.1926
0.05	0.8296	0.1388
0.10	0.8777	0.1089
0.50	0.9467	0.0647
1	0.9581	0.0602
5	0.9695	0.0711
10	0.9683	0.0571
20	0.9683	0.0564
50	0.9592	0.0645
100	0.9785	0.0549
200	0.9343	0.0817

به عنوان مثال در جدول (۴)، نتایج عمل کرد مدل به ازای تغییرات پارامتر c در حالی که دو پارامتر ε و γ ثابت هستند، ارائه شده است. مشاهده می شود با افزایش مقدار تاحد معینی مقدار ضریب همبستگی بیشینه و ریشه دوم میانگین مربعات خطاها کمینه می گردد. با توجه به جداول بالا، مدل گسترش یافته به ازای مقادیر $\varepsilon = 0.001$ و $\gamma = 150$ و $c = 100$ بهینه شده است. ضریب همبستگی $R = 0.9785$ و خطای $RMSE = 5.49\% \approx 2.6286\text{mm}$ بر روی داده های آزمایش، نشان گر عمل کرد خوب این مدل است. نتایج عمل کرد مدل بهینه بر مجموعه داده های آموزش و آزمایش در جدول (۵) نشان داده شده است.

جدول ۵- نتایج عمل کرد مدل بهینه بر روی داده های آموزش و آزمایش

	Coefficient Of Correlation (R)	Root Mean Square Errors (RMSE)
Train set	0.9850	0.0515
Test set	0.9785	0.0549

۸. نتیجه گیری



در این مقاله قابلیت روش ماشین بردار پشتیبان برای پیش‌بینی نشست شمع‌ها بر اساس مقاومت برشی زهکشی نشده خاک ارزیابی شده است. در مدل معرفی شده در این پژوهش از تابع کرنل پایه شعاعی جهت انجام رگرسیون غیر خطی بر روی یک مجموعه شامل ۲۵۳ داده، استفاده شده است. مقایسه نتایج نشان می‌دهد که مدل ماشین بردار پشتیبان دارای دقت مناسبی در پیش‌بینی نشست شمع‌ها در محدوده داده‌های مورد استفاده می‌باشد. بر اساس نتایج ارزیابی مدل بهینه گسترش داده شده بر مبنای تابع کرنل پایه شعاعی بر روی داده‌های آزمایش، مقادیر ضریب هم‌بستگی ۰/۹۷۸۵ و ریشه دوم میانگین مربعات خطا ۲/۶۲۸۶ میلی‌متر بدست آمده‌اند.

۹. مراجع

1. Sowers, G.F, (1970), "Introductory soil mechanics and foundation: Geotechnical engineering," Macmillan Publishing Company, New York;
2. Cristianini N, Shaw-Taylor J, (2000), "An introduction to support vector machines and other kernel-based learning methods," Cambridge: Cambridge University Press;
3. Goh A.T.C, and Goh S.H, (2007), "support vector machine: Their use in geotechnical engineering as illustrated using seismic liquefaction data," Computers and Geotechnics, **34**, pp.410-421;
4. Samui P, (2008), "Support vector machine applied to settlement of shallow foundations on cohesionless soils," Computers and Geotechnics, **35**, pp.419-427;
5. Pal, M, and Deswal, S, (2008), "Modeling Pile Capacity Using Support Vector Machines and Generalized Regression Neural Network," Journal of Geotechnical and Geoenvironmental Engineering, ASCE, **134**, pp.1021-1024;
6. Samui P, Sitharam, T.G, (2010), "Site characterization model using least-square support vector machine and relevance vector machine based on corrected SPT data (Nc)," International Journal for Numerical and Analytical Methods Geomechanics, **34**, pp.755-770;
7. Dibike, Y.B., Velikov, S., Solomatine, D. and Abbot, M.B. (2001), "Model Induction with Support Vector Machines-Introduction and Applications," Journal computing Civil Engineering, ASCE, (15), pp.208-216;