

تخمین ظرفیت باربری شمع‌ها تحت بار جانبی با استفاده از یک روش ترکیبی هوشمند جدید

هادی فتاحی^{۱*}؛ فاطمه جیریایی^۲

۱. دانشیار؛ دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک

۲. دانشجو؛ دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک

h.fattahi@arakut.ac.ir

تاریخ پذیرش ۱۴۰۰/۱۲/۱۴

تاریخ دریافت ۱۴۰۰/۰۴/۱۰

چکیده

پی‌های شمعی از سازه‌های مهم در حوزه ژئوتکنیک هستند که ممکن است تحت بارهای جانبی بزرگی قرار گیرند. تخمین ظرفیت باربری این گونه شمع‌ها با استفاده از روش‌های تجربی، همواره با خطا همراه بوده و نتیجه مدلسازی را از واقعیت دور می‌سازد. امروزه روش‌های هوشمند، قابلیت بالایی در امر پیش‌بینی و تخمین متغیر مجهول از خود نشان داده‌اند و می‌توانند جایگزین روش‌های تجربی و تحلیلی باشند. در این تحقیق سعی شد با ایجاد یک مدل ترکیبی هوشمند به نام رگرسیون بردار ارتباط بهینه شده با الگوریتم فراابتکاری کلونی زنبور عسل (RVR-ABC) به پیش‌بینی دقیق ظرفیت باربری جانبی شمع‌ها در خاک‌های رسی پرداخته شود. در این روش از رگرسیون بردار ارتباط به عنوان مدل پیش‌بینی‌کننده و از الگوریتم فراابتکاری کلونی زنبور عسل به منظور بهینه‌سازی پارامترهای روش رگرسیون بردار ارتباط استفاده شده است. در این مدلسازی داده‌های به‌کار گرفته شده، مربوط به یک مجموعه داده آزمایشگاهی ظرفیت باربری جانبی شمع در مقیاس کوچک است. برای ارزیابی دقت مدلسازی از شاخص‌های مختلف آماری استفاده شد که سرانجام نتایج نشان داد که مدل ترکیبی RVR-ABC برای داده‌های آزمون با $R^2=0.975$ و $RMSE=0.001$ ، از توانایی بالایی در پیش‌بینی ظرفیت باربری جانبی شمع‌ها برخوردار است. به علاوه آنالیز حساسیت انجام شده در این مطالعه نشان داد که متغیرهای خروج از مرکز بار و طول مدفون شمع، در مقایسه با سایر پارامترها بااهمیت‌تر و تأثیرگذارترند.

واژگان کلیدی: رگرسیون بردار ارتباط (RVR)، کلونی زنبور عسل (ABC)، ظرفیت باربری جانبی شمع، آنالیز حساسیت.

۱. مقدمه

بار محوری قرار نداشته و ممکن است در سازه‌های مختلف همچون پل‌ها، ساختمان‌های بلند و سازه‌های ساحلی، بار جانبی بزرگی را متحمل شوند. شمع‌های سازه‌هایی که تحت بار جانبی قرار دارند به دو گروه بلند و کوتاه تقسیم می‌شوند. تخمین ظرفیت باربری جانبی شمع‌های کوتاه معمولاً براساس تغییر مکان افقی مجاز، محاسبه می‌شود [1]. دقیق‌ترین روش برای به‌دست آوردن ظرفیت باربری جانبی شمع‌ها، تخمین آن

پی‌ها از جمله سازه‌هایی هستند که نقش عمده‌ای در حوزه ژئوتکنیک دارند و به عنوان پایه و اساس بناها، مورد بررسی قرار می‌گیرند. زمانی که به علت پایین بودن ظرفیت باربری خاک نتوان از پی‌های سطحی استفاده کرد، پی‌های عمیق با کاربرد شمع‌ها جایگزین می‌شوند. از این رو تعیین ظرفیت باربری شمع‌ها اهمیت ویژه‌ای دارد. البته شمع‌ها همیشه تحت

به صورت درجا است. از طرفی آزمایشات درجا هزینه بسیاری را در پی خواهد داشت. از این رو بهتر است این آزمایش در مقیاس کوچک انجام شود. محاسبه ظرفیت باربری جانبی شمع تاکنون با روش‌های تجربی بسیاری توسط پژوهشگران انجام شده است. روش‌های برامز^۱ و هانسن^۲ دو مورد از پرکاربردترین آن‌ها است [2, 3]. این روش‌ها، با فرض‌های ساده کننده‌ای که دارند، خروجی تحلیل‌ها را با خطا مواجه می‌کنند، به این دلیل که محیط واقعی که شمع‌ها در آن به کار می‌روند، ناهمگن بوده و خصوصیات مختلف خاک و فاکتورهای مؤثر در ظرفیت باربری، در جای جای آن با هم متفاوت است [4]. امروزه روش‌های مبتنی بر هوش مصنوعی جایگاه خوبی در حوزه پیش‌بینی فاکتورهای مجهول پیدا کرده‌اند. از این رو می‌توان به چند مورد از کاربرد آن‌ها در مورد ظرفیت باربری شمع‌ها اشاره کرد.

پال و دسوال (۲۰۰۸) با به کار بستن ماشین بردار پشتیبان SVM^۳، ظرفیت باربری استاتیکی شمع‌ها را محاسبه کردند و در آن از داده‌های دینامیکی موج-تنش استفاده کردند [5]. شاهین (۲۰۱۰) یک روش هوش هوشمند به نام شبکه عصبی مصنوعی (ANN^۴) را به کار برد تا به کمک آن یک پیش‌بینی دقیق از ظرفیت محوری شمع‌ها داشته باشد. در این تحقیق از نتایج نفوذ مخروط (CPT^۵) استفاده کرد [6]. لیو و همکاران (۲۰۱۱) یک مدل برای پیش‌بینی ظرفیت باربری نهایی شمع ایجاد کردند و در آن از روش ماشین بردار پشتیبان استفاده کردند. در این مطالعه همچنین آنالیز حساسیتی انجام دادند که نشان داد نسبت عمق نفوذ، مؤثرترین فاکتور است [7]. سامویی برای پیش‌بینی ظرفیت باربری شمع از روش ماشین بردار پشتیبان بهره گرفت [8]. ژانگ و همکاران (۲۰۱۲) نیز از روش ماشین بردار پشتیبان برای پیش‌بینی مقاومت اصطکاکی جانبی شمع‌ها با قطر زیاد و طول بسیار بلند، بهره گرفتند [9]. مدولی و همکاران برای پیش‌بینی ظرفیت باربری جانبی شمع‌ها در خاک رسی، به بررسی یک روش هوش

مصنوعی به نام ماشین یادگیری افراطی (ELM^۶) پرداختند و عملکرد آن را با چند روش از جمله شبکه عصبی مصنوعی مقایسه کردند [10]. کردجازی و همکاران (۲۰۱۴) به مقایسه روش‌های تجربی تعیین ظرفیت باربری شمع‌ها تحت اثر بار محوری با روش ماشین بردار پشتیبان پرداختند و در آن از داده‌های مربوط به آزمایش بارگذاری استاتیکی در مقیاس واقعی و همچنین نتایج آزمایش نفوذ مخروط، برای مدل‌سازی استفاده کردند [11]. چن و همکاران (۲۰۲۰) چندین مدل هوشمند از جمله ژنتیک عصبی، امپریالیسم عصبی، برنامه ریزی ژنتیکی (GP^۷) و شبکه عصبی مصنوعی ایجاد کردند تا به وسیله آن‌ها ظرفیت باربری شمع را پیش‌بینی کنند [12].

هدف از این تحقیق بکار بستن یک مدل ترکیبی جدید که متشکل از یک روش هوش مصنوعی به نام روش رگرسیون بردار ارتباط (RVR^۸) و یک الگوریتم فراابتکاری به نام الگوریتم کلونی زنبور عسل مصنوعی (ABC^۹) برای تخمین دقیق ظرفیت باربری جانبی شمع‌های در خاک رسی است. در این مدل‌سازی پارامترهای روش رگرسیون بردار ارتباط توسط الگوریتم کلونی زنبور عسل مصنوعی بهینه و دقت روش را به مراتب بالا می‌برد. در این مدل از داده‌های آزمایشگاهی مربوط به ظرفیت باربری جانبی شمع در مقیاس کوچک استفاده خواهد شد. همچنین آنالیز حساسیتی برای مشخص شدن اهمیت متغیرها انجام خواهد شد.

۲. خلاصه‌ای از روش‌های مورد استفاده در

این تحقیق

۱-۲- مدل رگرسیون بردار ارتباط (RVR)

رگرسیون بردار ارتباط به عنوان یکی از روش‌های هوش مصنوعی، برای مدل‌سازی‌های پیچیده و پیش‌بینی، قابل کاربرد است و در سال ۲۰۰۱ توسط تپینگ ارائه شده است [13]. رگرسیون بردار ارتباط مانند روش رگرسیون بردار

1. Broms
2. Hansen
3. Support Vector Machine
4. Artificial Neural Network
5. Cone Penetration Test

6. Extreme Learning Machine
7. Genetic Programing
8. Relevance Vector Regression
9. Artificial bee colony

که در آن $t = (t_1, t_2, \dots, t_N)$ ، $w = (w_0, w_1, \dots, w_N)$ و ماتریس طراحی با ابعاد $N \times (N+1)$ است. بنابراین روش RVR دیدگاه بیزین را در پیش می‌گیرد و پارامترهای w و σ^2 را محدود می‌کند. به طوری که طبق رابطه ۵ تا ۷ داریم:

$$p(w|\alpha) = \prod_{i=1}^N N(w_i | 0, \alpha_i^{-1}) = \frac{1}{2\pi^{(N+1)/2}} \prod_{i=1}^N \alpha_i^{1/2} \exp\left(-\frac{\alpha_i w_i^2}{2}\right) \quad (5)$$

$$p(\alpha) = \prod_{i=1}^N \text{gamma}(\alpha_i | a, b) \quad (6)$$

$$p(\beta) = \text{gamma}(\beta | a, b) \quad (7)$$

که در آن a یک پارامتر کمکی با $N+1$ بعد، $b = \sigma^2$ و $\text{gamma}(\alpha | a, b)$ به صورت رابطه ۸ تعریف می‌شود.

$$\text{gamma}(\alpha | a, b) = \Gamma(a)^{-1} b^a \alpha^{a-1} e^{-b\alpha} \quad (8)$$

علاوه بر این تابع توزیع پسین روی وزن‌ها به صورت رابطه ۹ تا ۱۱ به دست می‌آید.

$$p(w | t, \alpha, \sigma^2) = \frac{p(t | w, \sigma^2) p(w | \alpha)}{p(t | \alpha, \sigma^2)} = \quad (9)$$

$$\frac{1}{2\pi^{(N+1)/2}} |\Sigma|^{-1/2} \exp\left\{-\frac{1}{2}(w - \mu)^T \Sigma^{-1}(w - \mu)\right\} \quad (10)$$

$$\Sigma = (\sigma^{-2} 2\Phi^T 2\Phi + A)^{-1} \quad (11)$$

که در آن $A = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_N)$ و تابع شباهت سنجی از طریق رابطه ۱۲ به دست می‌آید.

$$p(t | w, \sigma^2) p(w | \alpha) dw = \quad (12)$$

$$p(t | \alpha, \sigma^2) = \int \frac{1}{(2\pi)^{N/2}} |C|^{-1/2} \exp\left\{-\frac{1}{2} t^T C^{-1} t\right\}$$

در اینجا کواریانس به شکل $C = \sigma^2 I + \Phi A^{-1} \Phi^T$ محاسبه می‌شود (۱۶).

۲-۲- الگوریتم کلونی زنبور عسل (ABC)

الگوریتم فراابتکاری کلونی زنبور عسل از جمله الگوریتم‌های بهینه‌سازی مبتنی بر جمعیت است. این الگوریتم توسط کارابوگا برای بهینه‌سازی توابع ریاضی معرفی شد [17]. الگوریتم کلونی زنبور عسل شامل سه مؤلفه اساسی زنبورهای کارگر، زنبورهای غیرکارگر و منابع غذایی است. در این مدل دو نوع بازخورد برای تعیین چگونگی رفتار عامل‌ها وجود

پشتیبان تحت آموزش نظارتی قرار گرفته و با بهره‌مندی از تئوری آموزشی آماری و پینک و با انتقال داده‌ها به فضایی با ابعاد گسترده‌تر و در نهایت برازش یک تابع خطی می‌تواند نگاشتی میان متغیرهای ورودی x و متغیر خروجی مدل y ایجاد کند. روش رگرسیون بردار ارتباط برای متغیرهای ورودی و خروجی، یک تابع توزیع گوسی در نظر می‌گیرد و بر اساس روش بیزین، رویکردی احتمالاتی دارد. این روش نسبت به رگرسیون بردار پشتیبان دارای بردارهای آموزشی کم‌تری است. این باعث می‌شود سرعت مدل‌سازی و پیش‌بینی بالاتری داشته باشد. به همین دلیل رگرسیون بردار ارتباط بیشتر به کار گرفته می‌شود [14, 15]. برخلاف روش ماشین بردار پشتیبان در روش رگرسیون بردار ارتباط، پارامتر توازن میان خطا/حاشیه (C) و پارامتر عدم حساسیت (E) محاسبه نمی‌شود، به همین دلیل زمان محاسبات کمتر شده و به مدل‌سازی سرعت می‌بخشد.

در مدل RVR مجموعه داده‌های ورودی (x) و خروجی (t) به شکل $\{x_n, t_n\}_{n=1}^N$ وارد می‌شوند. خروجی‌ها می‌توانند به جای $t = (t_1, \dots, t_N)^T$ به صورت مجموع بردارهای $y = (y(x_1), \dots, y(x_N))^T$ نمایش داده شوند. ابتدا از ساختار احتمالی شروع می‌شود و فرض بر این است که داده خروجی طبق رابطه ۱، نمونه‌هایی همراه با نویز هستند.

$$t_n = y(x_n, w) + e \quad (1)$$

که در آن e نویز تصادفی و w بردار وزن است. تابع $y(x)$ طبق رابطه ۲ تعریف می‌شود.

$$y(x, w) = \sum_{i=1}^N w_i k(x, x_i) + w_0 = \sum_{i=1}^N w_i \Phi(x) \quad (2)$$

که در آن

$$\Phi(x) = [1, k(x, x_1), k(x, x_2), \dots, k(x, x_N)] \quad \text{است.}$$

پس از آن تابع هدف می‌تواند به شکل رابطه ۳ نوشته شود.

$$p(t_n | x_n) = N(t | y(x_n), \sigma^2) \quad (3)$$

سپس تابع شباهت سنجی از طریق رابطه ۴ به دست می‌آید.

$$p(t | w, \sigma^2) = \frac{1}{2\pi\sigma^2} \exp\left\{-\frac{1}{2\sigma^2} \|t - \Phi(x)w\|^2\right\} \quad (4)$$

دارد. یکی به خدمت گرفتن زنبورهای جدید کاشف برای منابع غذایی غنی، با دریافت بازخورد مثبت و دیگری ترک منابع غذایی ضعیف توسط زنبورها با دریافت بازخورد منفی است. منظور از عامل‌ها زنبورهای عسلی هستند که به سه گروه تقسیم می‌شوند:

- ۱- زنبورهای کارگر مرتبط به منابع غذایی مشخص
- ۲- زنبورهای ناظر که بر انتخاب منابع غذایی نظارت می‌کنند.
- ۳- زنبورهای کاشف که به صورت تصادفی به دنبال منابع غذایی می‌شود.

زنبوران ناظر و کاشف هر دو زنبورهای غیرکارگر نامیده می‌شوند. ابتدا مکان تمام منابع غذایی توسط زنبورهای کاشف مشخص شده، سپس شاهد منابع غذایی توسط زنبوران کارگر و ناظر بهره‌برداری می‌شود. استخراج پیوسته منابع غذایی منجر به تهی شدن آن‌ها می‌شود. پس از آن زنبوران کارگر به زنبوران کاشف تبدیل شده تا به دنبال منابع غذایی جدید شوند. مکان هر منبع غذایی، یک جواب ممکن برای مسئله بهینه‌سازی است و میزان شاهد منبع غذایی، متناظر با برازش جواب مربوطه است. گام‌های اصلی الگوریتم به شرح زیر هستند [18]:

۱- ایجاد جمعیت اولیه

۲- تکرار

۳- استقرار زنبورهای کارگر بر روی منابع غذایی خود

۴- استقرار زنبورهای ناظر روی منابع غذایی برحسب مقدار شاهد آن‌ها

۵- فرستادن زنبورهای کاشف به فضای جستجو برای یافتن منابع غذایی جدید

۶- به یاد سپردن بهترین منبع غذایی تاکنون

۷- ادامه تا برقراری شرط توقف

در گام اول، کلونی زنبور عسل یعنی جمعیت اولیه به صورت تصادفی تولید می‌شود و به تعداد جمعیت اولیه جواب ایجاد می‌شود. این تعداد همان تعداد زنبورهای کارگر یا ناظر است. هر جواب یک بردار n_{var} بعدی است که n_{var} در آن تعداد متغیرهای ورودی است. پس از آن موقعیت جواب‌ها در سیکل تکراری الگوریتم قرار می‌گیرد. یک زنبور ناظر، منبع

غذا را متناسب با احتمال آن از معادله‌ی موجود در رابطه ۱۳ انتخاب می‌کند.

$$p_i = \frac{Fitness(si)}{\sum_{n=1}^{SN} Fitness(sn)} \quad (13)$$

که در آن $Fitness(si)$ مقدار برازندگی جواب si که متناظر با میزان شاهد منبع غذایی در مکان i ام است و sn تعداد منابع غذایی می‌باشد که برابر با تعداد زنبورهای کارگر یا ناظر است. به منظور ایجاد یک موقعیت غذایی جدید از مکان غذای قدیمی، از رابطه ۱۴ استفاده می‌شود.

$$v_{ij} = (X_{ij} - X_{kj})\phi + X_{ij} \quad (14)$$

در این رابطه $k \in \{1, 2, \dots, SN\}$ و $j \in \{1, 2, \dots, D\}$ شاخص‌هایی هستند که به صورت تصادفی انتخاب می‌شوند، اما مقدار آن‌ها با i فرق دارد. ϕ_{ij} یک عدد تصادفی بین -1 و $+1$ است و وظیفه کنترل تولید منابع غذایی همسایه حول X_{ij} را به عهده دارد. بر اساس رابطه ۱۴ هر چه اختلاف بین X_{ij} و X_{kj} کاهش یابد، جستجو به جواب بهینه نزدیک‌تر می‌شود و طول گام کاهش می‌یابد. اگر مقدار پارامتری از حد از پیش تعیین شده تجاوز کند، زنبور کاشف منبع غذایی جدید را از رابطه ۱۵ به عنوان مقدار قابل پذیرش جایگزین می‌کند [19].

$$X_i^j = X_j^{\min} + rand[0,1](X_{\max}^j - X_{\min}^j) \quad (15)$$

۳- مدل‌سازی با روش ترکیبی رگرسیون بردار ارتباط با الگوریتم کلونی زنبور عسل مصنوعی (RVR-ABC)

۳-۱- ساختار داده‌ها (ورودی‌ها و خروجی) برای مدل‌سازی

داده‌های مورد استفاده در این مقاله، مربوط به آزمون‌های آزمایشگاهی ظرفیت باربری جانبی شمع‌ها واقع بر خاک رسی در مقیاس کوچک است که توسط Kumar Rao [20] منتشر شده است. داده‌ها شامل ۳۸ آزمایش بارگذاری شمع تحت بار جانبی واقع بر خاک‌های رسی در مقیاس کوچک است که پارامترهای قطر شمع (D)، طول مدفون شمع (L)، خروجی از مرکز بار (E) و مقاومت برشی زهکشی نشده خاک (S_u) به عنوان ورودی مدل و از مقاومت جانبی شمع (Q_m) به عنوان

باقیمانده به عنوان داده‌های آزمون (ارزیابی مدل ساخته شده) استفاده شده است. جدول (۱) پارامترهای آماری کل داده‌ها را توصیف می‌کند.

خروجی مدل استفاده شده است. در این مدل‌سازی به منظور تخمین دقیق ظرفیت باربری جانبی شمع در خاک‌های رسی، داده‌ها به صورت تصادفی به دو بخش داده‌های آموزش و آزمون تقسیم شدند. به همین منظور ۸۰ درصد داده‌ها (۳۰ داده) به عنوان داده‌های آموزش (ساخت مدل) و ۲۰ درصد

جدول ۱. پارامترهای آماری داده‌ها در متغیرهای مختلف

Variable	Symbol (Unit)	Minimum	Maximum	Mean	Std
diameter of pile	D(mm)	6.35	33.3	17.78	6.04
length of pile	L(mm)	130	300	278.89	52.12
eccentricity of load	E (mm)	0	50	44.17	14.54
undrained shear strength of soil	S _u (KN/m)	3.4	38.8	9.94	9.98
lateral load capacity	Q _m	29.5	225	73.69	37.85

همبستگی نشان دهنده هماهنگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده است که بهترین حالت آن جایی است که مقدار آن یک باشد و اگر صفر باشد بدان معنی است که عملکرد مدل برای پیش‌بینی خیلی ضعیف است. معیار جذر میانگین مربعات خطا نیز بیانگر خطای بین مقادیر اندازه‌گیری شده و پیش‌بینی شده است و هر چه مقدار آن کم‌تر باشد عملکرد مدل از اطمینان بیش‌تری برخوردار است.

۳-۳- نتایج حاصل از مدل‌سازی

در این مدل ابتدا داده‌های ورودی و خروجی در نرم افزار متلب فراخوانی شدند و سپس مراحل اجرای مدل و انجام محاسبات با استفاده از رگرسیون بردار ارتباط با تابع کرنل پایه‌ای شعاعی انجام شده است. از آنجایی که روش رگرسیون بردار ارتباط با تابع کرنل پایه‌ای شعاعی دارای دو پارامتر مجهول و مهم (σ و α) در دقت مدل‌سازی می‌باشند که باید به صورت دستی و با سعی و خطای فراوان تنظیم شوند. بدیهی است که این فرآیند بسیار زمان‌بر و از دقت پایینی برخوردار می‌باشد. از طرفی همان‌طور که ذکر شد مقدار خطای مدل‌سازی به کم یا زیاد شدن این پارامترها بسیار حساس است به شکلی که کوچکترین تغییر باعث بالا و پایین رفتن خطا می‌شود. بنابراین برای بهینه‌سازی پارامترهای مدل بهتر است که از یک الگوریتم بهینه‌ساز کمک گرفته شود که در این مقاله برای بدست آوردن مقادیر σ و α از الگوریتم

۳-۲- پیش پردازش داده‌ها و شاخص‌های آماری

جهت ارزیابی عملکرد مدل

برای مدل‌سازی و ورودی داده‌ها، بیشتر لازم است که دامنه تغییرات داده‌ها مشابه یکدیگر باشند که در اصطلاح این عمل را، نرمال‌سازی داده‌ها می‌نامند. نرمال‌سازی داده‌ها در این مطالعه توسط رابطه زیر انجام گرفته است که این رابطه دامنه داده‌ها را در بازه [۰ ۱] قرار می‌دهد.

$$p_n = \frac{p - p_{\min}}{p_{\max} - p_{\min}} \quad (16)$$

کمینه $p_{\min}$ داده حقیقی، p داده نرمال شده، p_n که در آن: بیشینه داده حقیقی هستند. $p_{\max}$ داده حقیقی و همچنین در این مقاله برای ارزیابی عملکرد مدل، از دو شاخص آماری شامل ضریب همبستگی مربع (R^2) و جذر میانگین خطای مربع (RMSE) استفاده شده است که روابط مربوطه عبارتند از:


$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n y_i^2 - \frac{\sum_{i=1}^n y_i'^2}{n}} \quad (17)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (18)$$

که در این روابط y_i مقدار اندازه‌گیری شده و y'_i مقدار پیش‌بینی شده است. لازم به توضیح است که معیار ضریب

کلونی زنبور عسل بهره گرفته شده است. در شکل (۱) پارامترهای استفاده شده برای الگوریتم بهینه‌سازی مبتنی بر فلوچارت رگرسیون بردار ارتباط بهینه یافته توسط الگوریتم کلونی زنبور عسل در جدول ۲ آورده شده است. همچنین مقادیر

شکل ۱. فلوچارت رگرسیون بردار ارتباط بهینه یافته توسط الگوریتم کلونی زنبور عسل




جدول ۲. مقدار پارامترهای الگوریتم کلونی زنبور عسل

Parameter	Value
Maximum Iteration	500
Population	50
Up Limit Acceleration Coefficient	0.1

مدل رگرسیون بردار ارتباط ایجاد شده که پارامترهای آن توسط الگوریتم کلونی زنبور عسل بهینه شده‌اند، عملکرد خوبی را در پیش‌بینی متغیر خروجی از خود نشان داده است. شکل (۲) نزدیکی نقاط مربوط مقادیر واقعی و پیش‌بینی را به خط برازش شده در داده‌های آموزش و آزمون نشان می‌دهد. هرچه این نقاط به خط نزدیک‌تر باشند، نشان دهنده خطای کمتری است. در این شکل بیشتر نقاط روی خط قرار گرفته‌اند و برازش خوبی صورت گرفته است.

شکل ۲. مقایسه بین مقادیر پیش‌بینی و اندازه‌گیری شده




مراحل آزمون و آموزش در شکل (۳) نشان داده شده است. نتایج حاکی از آن است که این مدل قابلیت بالایی در برآورد ظرفیت باربری شمع‌ها تحت بار جانبی با استفاده از مجموعه پارامترهای ورودی ذکر شده را دارد و می‌تواند برای پروژه‌های دیگر با شرایط مشابه، به طور مطلوبی مورد استفاده قرار گیرد.

در جدول (۳) مقادیر R^2 و RMSE را برای داده‌های آموزش و آزمون را نشان می‌دهد. همانگونه که مشخص است مدل رگرسیون بردار ارتباط بهینه شده توسط الگوریتم کلونی زنبور عسل دارای مقدار R^2 بالا و RMSE بسیار پایین و نزدیک به صفر می‌باشد. همچنین مقایسه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده ظرفیت باربری شمع‌ها تحت بار جانبی توسط مدل ترکیبی روش ترکیبی رگرسیون بردار ارتباط بهینه شده توسط الگوریتم کلونی زنبور عسل در

جدول ۳. شاخص‌های ارزیابی مدل در داده‌های آموزش و آزمون

RVR-ABC Model	Training Data		Testing data	
	R^2	RMSE	R^2	RMSE
	0.981	0.001	0.975	0.001

شکل ۳. نمایش خطای مدل در تخمین ظرفیت باربری شمع‌ها تحت بار جانبی در مراحل آموزش و آزمون




شد که مبنای آن بررسی درصد تغییرات در متغیر خروجی در اثر تغییرات سیستماتیک در متغیر ورودی است. به شکلی که

بعلاوه به منظور مطالعه‌ی تأثیرپذیری متغیر خروجی یعنی مقاومت جانبی شمع، از متغیرهای ورودی، آنالیز حساسیتی انجام

متغیرهای ورودی به جز متغیر مورد مطالعه ثابت در نظر گرفته می‌شود. به این ترتیب برای بررسی اهمیت هر متغیر ابتدا سایر متغیرها را در مقدار ۵۰٪ دامنه‌ی تغییرات آن‌ها ثابت فرض کرده و سپس برای متغیر مورد نظر، تعدادی از مقادیر درصد دامنه

تغییرات آن، به صورت سازمان یافته در نظر گرفته می‌شود و مقدار متغیر خروجی متناظر با این مقادیر، توسط مدل ایجاد شده به دست می‌آید و در نهایت نمودار حاصل می‌شود که در شکل (۴) نشان داده شده است.


شکل ۴. آنالیز حساسیت متغیرهای ورودی بر اساس درصد دامنه تغییرات




مقدار آن باعث کاهش در متغیر خروجی یعنی مقاومت جانبی شمع می‌شود و در شکل نیز این متغیر شیب منفی پیدا کرده است. از طرفی متغیر قطر شمع (D) و مقاومت برشی زهکشی نشده (S_u)، دارای شیب کمتر و تأثیرگذاری پایین‌تری هستند. ارتباط بین دو متغیر را توسط نمودار پراکندگی آن‌ها نیز می‌توان مشاهده کرد. شکل (۵ و ۶) نمودار پراکندگی متغیرهای ورودی D و L نسبت به متغیر خروجی را نشان می‌دهد.

همانطور که در شکل (۴) مشخص است، خطوط مربوط به هر متغیر در نمودار حساسیت، نسبت به یکدیگر متفاوت است. در این نمودار هر چه شیب خط، بیشتر و یا به عبارت دیگر تغییر در درصد دامنه تغییرات متغیر ورودی سبب اختلاف بیشتری در درصد دامنه‌ی تغییرات متغیر خروجی شود، دارای تأثیرگذاری بالاتری است. بر این اساس طول مدفون شمع (L) و خروج از مرکز بار (E)، دارای اهمیت و تأثیرگذاری بالاتری هستند. با این تفاوت که متغیر E ، تأثیرگذاری آن از نوع عکس است، به شکلی که افزایش در

شکل ۵. نمودار پراکندگی متغیر D نسبت به متغیر خروجی Q_m



شکل ۶. نمودار پراکندگی متغیر L نسبت به متغیر خروجی Q_m 

نمودار مربوط به متغیر L دارای یک ارتباط تقریبی به صورت افزایشی است و در یک مقدار خاص از L ، مقدار Q_m نوسان زیادی داشته است. اما در مورد متغیر D ، نمی‌توان نظمی در ارتباط بین آن با Q_m مشاهده کرد. پس با افزایش مقادیر این متغیر Q_m تنها در یک بازه از مقادیر خود کم و زیاد می‌شود و دارای ارتباط پیچیده‌ای هستند.

۷- نتیجه‌گیری

در این مطالعه برای تخمین ظرفیت باربری شمع‌ها تحت بار جانبی از یک روش ترکیبی هوشمند یعنی ترکیب روش رگرسیون بردار ارتباط بهینه شده توسط الگوریتم فراابتکاری کلونی زنبور عسل استفاده شد. بررسی‌ها نشان داد:

- در این مدل‌سازی، الگوریتم فراابتکاری کلونی زنبور عسل توانست مقدار بهینه و دقیق پارامترهای روش رگرسیون بردار ارتباط را برآورد کند. پیدا کردن بهینه‌ترین مقادیر پارامترهای مجهول به صورت دستی فرآیندی بسیار زمان‌بر و دارای خطای فراوان است و همچنین قابلیت روش رگرسیون بردار ارتباط شدیداً به مقدار پارامترهای فوق بستگی دارد. الگوریتم بهینه‌ساز معرفی شده در این مقاله می‌تواند در کمترین زمان ممکن و با بالاترین دقت بهینه‌ترین مقدار را بیابد.

- مدل ترکیبی روش رگرسیون بردار ارتباط بهینه شده توسط الگوریتم فراابتکاری کلونی زنبور عسل توانایی بالایی در تخمین ظرفیت باربری جانبی شمع دارد. چرا که شاخص‌های ارزیابی با مقادیر

- تحلیل حساسیت انجام شده برای بررسی اهمیت متغیرها نشان داد متغیر خروج از مرکز بار و طول مدفون شمع، از تأثیرگذاری بالاتری برخوردار هستند. ارتباط طول مدفون شمع با ظرفیت باربری جانبی شمع از نوع مستقیم بوده است. اما ارتباط خروج از مرکز بار با ظرفیت باربری جانبی شمع از نوع عکس می‌باشد. پس از آن‌ها دو متغیر قطر شمع و مقاومت برشی زهکشی نشده خاک، اهمیت و تأثیرگذاری پایین‌تری دارند.

اعلام تعارض منافع:

نویسندگان اعلام می‌کنند که هیچ تعارض منافی وجود ندارد.

منابع

- [1] Poulos HG, Davis EH. Pile foundation analysis and design 1980.
- [2] Broms BBJotsm, division f. Lateral resistance of piles in cohesive soils. 1964;90(2):27-63.
- [3] Brinch-Hansen JJGI, Bull. The ultimate resistance of rigid piles against transversal forces. ۱۹۶۱.
- [4] Koohestani VR, Bazargan Lari MJJOFCF. Prediction the ultimate bearing capacity of

- reliability-based design: Insights from a tunnel support case. 2020;117:103280.
- [16] Tipping ME, editor The relevance vector machine. Advances in neural information processing systems; 2000.
- [17] Karaboga D, Akay BJAm ,computation. A comparative study of artificial bee colony algorithm. 2009;214(1):108-32.
- [18] Babajani J, Mohammadreza T, Blue G, Abdollahi MJFMS. Forecasting Stock Prices In Tehran Stock Exchange Using Recurrent Neural Network Optimized by Artificial Bee Colony Algorithm. 2019;7(2):195-228.
- [19] Karaboga D, Ozturk CJAsc. A novel clustering approach: Artificial Bee Colony (ABC) algorithm. 2011;11(1):652-7.
- [20] Rao K, Suresh Kumar V, editors. Measured and predicted response of laterally loaded piles. Proceedings of the sixth international conference and exhibition on piling and deep foundations, India; 1996.
- shallow foundations on the cohesionless soils using M5P model tree. 2016;27(2):99-110.
- [5] Pal M, Deswal SJJog, engineering g. Modeling pile capacity using support vector machines and generalized regression neural network. 2008;134(7):1021-4.
- [6] Shahin MAJCGJ. Intelligent computing for modeling axial capacity of pile foundations. 2010;47(2):230-43.
- [7] Liu YJ, Liang SH, Wu JW, Fu N, editors. Prediction method of vertical ultimate bearing capacity of single pile based on support vector machine. Advanced Materials Research; 2011: Trans Tech Publ.
- [8] Samui PJIJoGE. Prediction of pile bearing capacity using support vector machine. 2011;5(1):95-102.
- [9] Zhang MY, Liang L ,Song HZ, Li Y, Peng WT, editors. Intelligent prediction for side friction of large-diameter and super-long steel pipe pile based on support vector machine. Applied Mechanics and Materials; 2012: Trans Tech Publ.
- [10] Muduli PK, Das SK, Das MRJIJoGE. Prediction of lateral load capacity of piles using extreme learning machine. 2013;7(4):388-94.
- [11] Kordjazi A, Nejad FP, Jaksa MJC, Geotechnics. Prediction of ultimate axial load-carrying capacity of piles using a support vector machine based on CPT data. 2014.۱۰۲-۵۵:۹۱;
- [12] Chen W, Sarir P, Bui X-N, Nguyen H, Tahir M, Armaghani DJJewC. Neuro-genetic, neuro-imperialism and genetic programming models in predicting ultimate bearing capacity of pile. 2020;36(3):1101-15.
- [13] Tipping MEJJomlr. Sparse Bayesian learning and the relevance vector machine. 2001;1(Jun):211-44.
- [14] Fang Q, Zhang D, Li Q, Wong LNYJT, Technology US. Effects of twin tunnels construction beneath existing shield-driven twin tunnels. 2015;45:128-37.
- [15] Fang Y, Su YJC, Geotechnics. On the use of the global sensitivity analysis in the

Estimation of Lateral Load Capacity of Piles Using a New Intelligent Combination Method

Hadi Fattahi¹, Fateme Jiryae²

1-Associate Professor, Faculty of Earth Sciences Engineering, Arak University of Technology, Iran

2- MSc Student, Faculty of Earth Sciences Engineering, Arak University of Technology, Iran

Abstract

Estimation of the load carrying capacity of pile foundation is one of the most sought after research areas in geotechnical engineering. Static equilibrium and other dynamic equations are used to predict the axial load capacity of pile. The prediction of lateral load capacity of piles, used in tall and offshore structures is more complex and requires solution of non-linear differential equations. The elastic analysis adopting Winkler soil model is not suitable for the non-linear soil behavior. Estimating the load capacity of such piles using experimental methods is always associated with error and makes the modeling result far from reality. Today, intelligent methods have shown a high capability in predicting and estimating unknown variables and can replace experimental and analytical methods. In this research, we tried to accurately predict the lateral load capacity of piles in clay soils by creating an intelligent hybrid model called optimized relevant vector regression with the artificial bee colony algorithm. The relevant vector regression is a probabilistic method based on Bayesian approach. The relevant vector regression does not need to predict the error/margin tradeoff parameter C , which can decrease the time and the kernel function, does not need to satisfy the Mercer condition. For those relevant vector regression advantages compared with the support vector regression approach, relevant vector regression model is successfully applied in regression prediction problems. In this method, relevant vector regression is used as a predictive model and artificial bee colony algorithm is used to optimize the parameters of relevant vector regression method. The artificial bee colony algorithm is a swarm based meta-heuristic algorithm for optimizing numerical problems. It was inspired by the intelligent foraging behavior of honey bees. The algorithm is specifically based on the model for the foraging behavior of honey bee colonies. The model consists of three essential components: employed and unemployed foraging bees, and food sources. The first two components, employed and unemployed foraging bees, search for rich food sources, which is the third component, close to their hive. The model also defines two leading modes of behavior which are necessary for self-organizing and collective intelligence: recruitment of foragers to rich food sources resulting in positive feedback and abandonment of poor sources by foragers causing negative feedback. In artificial bee colony, a colony of artificial forager bees (agents) search for rich artificial food sources (good solutions for a given problem). To apply artificial bee colony, the considered optimization problem is first converted to the problem of finding the best parameter vector which minimizes an objective function. Then, the artificial bees randomly discover a population of initial solution vectors and then iteratively improve them by employing the strategies: moving towards better solutions by means of a neighbor search mechanism while abandoning poor solutions. In this modeling, the data used are related to a laboratory data set of small-scale pile load capacity. Various statistical indicators were used to evaluate the modeling accuracy. Finally, the results showed that the combined relevant vector regression with the artificial bee colony algorithm for test data with $R^2 = 0.975$ and $RMSE = 0.001$, has a high ability to predict the lateral load capacity of spark plugs. In addition, the sensitivity analysis performed in this study showed that the variables of eccentricity of load and the length of pile are more important and effective compared to other parameters.

Keywords: Relevant vector regression, Artificial bee colony algorithm, Lateral load capacity, Sensitivity analysis.