

## ارائه مدل تخمین CBR و UCS خاک تورم‌پذیر تثبیت‌شده با آهک هیدراته فعال شده با خاکستر پوسته برنج با استفاده از روش ترکیبی MARS-EBS

### مقاله علمی - پژوهشی

علیرضا غنی‌زاده\*، دانشیار، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران  
فرزاد صفی‌جهانشاهی، دانش آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران  
آرش ضیائی، دانش آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران

\*پست الکترونیکی نویسنده مسئول: ghanizadeh@sirjantech.ac.ir

دریافت: ۱۴۰۳/۰۴/۲۰ - پذیرش: ۱۴۰۳/۱۱/۰۱

صفحه ۶۶-۴۵

### چکیده

نسبت باربری کالیفرنیا یکی از مهم‌ترین پارامترهای طراحی روسازی‌های انعطاف‌پذیر و مقاومت فشاری محصورنشده خاک از جمله پارامترهای مهم طراحی و مهندسی است. تعیین مقدار این پارامترها از طریق آزمایش زمان‌بر و پرهزینه است و بنابراین به‌دست آوردن آن‌ها از طریق راه‌حل‌های جایگزین و قابل اعتماد مورد نیاز است. در این مطالعه از روش اسپیلاین رگرسیون تطبیقی چند متغیره برای مدلسازی مقدار CBR و UCS خاک تورم‌پذیر تثبیت‌شده با آهک هیدراته فعال شده با خاکستر پوسته برنج استفاده شده است. پایگاه داده مورد استفاده در این تحقیق شامل ۱۲۱ داده است که ۷۰ درصد آن به‌عنوان داده آموزش و ۳۰ درصد آن به‌عنوان داده آزمون انتخاب شده است. در مدل پیش‌بینی CBR از چهار پارامتر ورودی درصد آهک، حد خمیری، شاخص خمیری و حداکثر وزن مخصوص خشک استفاده شده است. همچنین برای مدل پیش‌بینی UCS از پنج پارامتر درصد، حد خمیری، شاخص خمیری، درصد رطوبت بینه و حداکثر وزن مخصوص خشک به‌عنوان پارامترهای ورودی استفاده شده است. که نشان می‌دهد در این مطالعه از متغیرهای ورودی محدودتری برای مدلسازی این دو پارامتر در مقایسه با مدل‌های توسعه یافته توسط محققان در گذشته استفاده شده است. مقدار ضریب تعیین برای مدل CBR بر اساس داده‌های آموزش و آزمون به‌ترتیب برابر با ۰/۹۹۹۵ و ۰/۹۹۹۴ و برای مدل UCS به‌ترتیب برابر با ۰/۹۹۹۷ و ۰/۹۹۹۹ به‌دست آمده است که نشان‌دهنده دقت مناسب مدل‌های توسعه داده شده است. همچنین نتایج آزمون ANOVA نشان داد که درصد آهک فعال دارای بیشترین درجه اهمیت برای پیش‌بینی CBR و UCS است.

واژه‌های کلیدی: آهک، پوسته برنج، روش اسپیلاین رگرسیونی تطبیقی چند متغیره، ظرفیت باربری کالیفرنیا، مقاومت فشاری محصور نشده

### ۱- مقدمه

خاک‌های رسی تورم‌پذیر، در صورت جذب رطوبت بسیار چسبند و در حالت خشک از لحاظ مقاومت و سختی مانند سنگ می‌باشند که این ویژگی تراکم آن‌ها را دچار مشکل می‌کند (Christopher & Chimobi, 2019; Li et al., 2021). خاک‌های تورم‌پذیر به‌طور گسترده در سراسر جهان در دسترس هستند، به‌طوری‌که ۳۳ درصد از مساحت سودان، ۲۰ درصد از اندونزی و هند، ۱۲ درصد از سوریه و تقریباً ۶ درصد از چین

خاک‌های تورم‌پذیر به دلیل وجود برخی از کانی‌های رسی به تغییرات رطوبت حساس می‌باشند و دچار افزایش حجم می‌شوند. وجود این خاک‌ها در بستر روسازی باعث ایجاد مشکلات متعددی در پروژه‌های راهسازی و ضررهای مالی گسترده‌ای که گاه‌ا از خسارت ایجاد شده توسط برخی از مشکلات زمین‌شناسی بیشتر است، می‌شود (Elbadry, 2017; Ijaz et al., 2020; Liu, Su, et al., 2019; Ma et al., 2020; Onyelowe, Jalal, et al., 2021a).

مخصوص برای تخمین مقدار نسبت باربری کالیفرنیا استفاده کرد (Quan & Do, 2021). علاوه بر این، مقاومت فشاری محصور نشده خاک یک پارامتر ژئوتکنیکی مهم و تأثیرگذار است که برای طراحی و اجرای پروژه‌های مهندسی مورد استفاده قرار می‌گیرد (Sharma & Singh, 2018). به طور کلی این پارامتر رفتار تغییر شکل خاک را با اندازه‌گیری مقاومت و نسبت باربری آن کنترل می‌کند. تعیین مقدار مقاومت فشاری محصور نشده خاک با توجه به عمل‌آوری نمونه‌های ساخته شده، مانند آزمایش نسبت باربری کالیفرنیا، آزمایش زمان‌بر و پرهزینه است (Sharma & Singh, 2018). در سال ۱۹۶۲، بلک در اولین مطالعه به بررسی پیش‌بینی مقدار CBR خاک پرداخت (Black, 1962). همچنین، آگاروال و قانعکار از پارامترهایی مانند شاخص خمیری و دانه‌بندی برای پیش‌بینی مقدار CBR استفاده کردند (Agarwal & Ghanekar, 1970). در ادامه، محققان دیگری مطالعه آن‌ها را با روش‌های دقیق‌تر و با استفاده از پارامترهای بیشتر توسعه دادند (Alawi & Rajab, 2013; Al-Hashemi & Bukhary, 2016; Al-Refaei & Al-Suhaibani, 1997). با توسعه روش‌های محاسبات نرم، توجه محققین بیش از پیش به استفاده از این روش‌ها در پیش‌بینی مشخصات ژئوتکنیکی خاک‌ها از جمله پیش‌بینی نسبت باربری کالیفرنیا و مقاومت فشاری بر اساس خصوصیات پایه خاک معطوف شده است. یلدریم و گونایدین مقدار CBR را با استفاده از روش‌های محاسبات نرم و با استفاده از خصوصیات خاک و خصوصیات تراکمی آن ارزیابی کردند. نتایج این تحقیق نشان‌داد که مقدار CBR پیش‌بینی شده دارای همبستگی و دقت قابل قبول است (Yildirim & Gunaydin, 2011). کومار در تحقیق خود به بررسی یک مدل رگرسیون خطی بر اساس پارامترهای شاخص خمیری، حد روانی، حد خمیری، حداکثر وزن مخصوص خشک و درصد رطوبت به‌نینه برای پیش‌بینی مقدار CBR پرداخت (Talukdar, 2014). پاتل و دسای و پال در تحقیقات خود برای تعیین مقدار CBR از حد روانی، حد خمیری، شاخص خمیری و شاخص‌های تراکم استفاده کردند (Pal & Pal, 2010; Patel & Desai, 2019). تسکیران در تحقیق خود برنامه‌نویسی بیان ژن را برای پیش‌بینی مقدار CBR خاک‌های تورم‌پذیر مورد ارزیابی قرار داد (Taskiran, 2010). راجاکومار به بررسی پیش‌بینی مقدار CBR به‌وسیله شبکه عصبی مصنوعی پرداخت (Rajakumar, 2021). تران و دو

را تشکیل می‌دهند (Jalal et al., 2020). همچنین، در مناطق مختلفی از آسیا، از جمله پاکستان، عربستان سعودی، ایران، مالزی و عمان به وفور یافت می‌شوند که علاوه بر ایجاد مشکل در ساخت و ساز، باعث ایجاد مشکلات پایداری در طولانی مدت نیز می‌شوند (Akbar & Farooq, 2002; Aziz et al., 2015). این خاک‌ها تمایل بیشتری به جذب آب داشته و با جذب آب یا خشک شدن متورم و منقبض می‌شوند (Christopher & Chimobi, 2019; Mahedi et al., 2020). در برخی موارد، حجم این خاک‌ها در حضور آب تا سه برابر بیشتر از حجم اولیه می‌شود که سبب ایجاد یک فشار تورمی بر روی پایه سازه‌ها و ایجاد ترک در شالوده ساختمان‌های مسکونی، بزرگراه‌ها و روسازی فرودگاه‌ها می‌شود (Negawo et al., 2019; Seco et al., 2011; Sridharan & Gurtug, 2004). تثبیت خاک‌های تورم‌پذیر، روش مناسبی برای محدود کردن اثرات منفی تورم یا انقباض خاک‌های تورم‌پذیر است (Quan & Do, 2021). خاک‌های تورم‌پذیر به‌وسیله افزودنی‌های مختلفی تثبیت می‌شوند (Al-Bared et al., 2019). از جمله این تثبیت‌کننده‌ها می‌توان به آهک (Bell, 1996)، سیمان (Sharma et al., 2018)، خاکستر بادی (Puppala et al., 2001) و خاکستر پوسته برنج (Alhassan, 2008; Kumar & Gupta, 2016; Liu, Chang, et al., 2019; Phanikumar & Nagaraju, 2018) اشاره کرد. به‌طور کلی، افزودنی‌ها به سه دسته ۱- افزودنی‌های سنتی (سیمان) ۲- افزودنی‌های محصولات جانبی (غبار مرمر، غبار کوره سیمان و خاکستر بادی) ۳- افزودنی‌های غیر سنتی (ترکیب آمونوم، روغن‌های سولفاته و پلیمرها) تقسیم می‌شوند (Behnood, 2018; Christopher & Chimobi, 2019). فرآیند تثبیت خاک‌ها بر روی برخی از خواص خاک و همچنین مقاومت فشاری محصور نشده آن تأثیر قابل توجهی می‌گذارد. از نسبت باربری کالیفرنیا برای ارزیابی خواص مکانیکی خاک‌های تورم‌پذیر پس از فرآیند تثبیت استفاده می‌شود (Quan & Do, 2021). مقدار این پارامتر پس از متراکم کردن خاک با مقدار رطوبت بهینه و سپس نگهداری به مدت چهار روز در آب توسط آزمایش به‌دست می‌آید که نشان می‌دهد تعیین این پارامتر یک آزمایش زمان‌بر است و برای پروژه‌های بزرگ، قابل توجه نمی‌باشد. در نتیجه، به‌منظور رفع این مشکل می‌توان از سایر پارامترهای خاک که به آسانی قابل اندازه‌گیری هستند، مانند حدود اتربرگ، رطوبت بهینه و حداکثر وزن

دقت بالا برای پیش‌بینی مقدار مقاومت فشاری محصورنشده می‌باشد (Javdanian & Lee, 2019). فام و همکاران از شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری محصورنشده خاک ماسه‌ای تثبیت‌شده با سیمان استفاده کردند و نشان دادند که مدل توسعه داده شده دارای دقت بالا و قابل قبول می‌باشد (Pham et al., 2021b). تران از روش *gradient boosting* برای پیش‌بینی مقدار مقاومت فشاری محصورنشده خاک تثبیت‌شده بر اساس خصوصیات اولیه، درصد افزودنی و مشخصات تراکمی خاک استفاده کردند (Tran, 2022b). افتخار و همکاران در تحقیق خود به پیش‌بینی مقاومت فشاری محصورنشده بلوک‌های ماسه پلاستیکی سنگ‌فرش‌ها با استفاده از برنامه‌نویسی بیان ژن و برنامه‌نویسی چند بیانی پرداختند. نتایج نشان داد که روش برنامه‌نویسی چند بیانی از دقت بالاتری در مقایسه با روش برنامه‌نویسی بیان ژن برخوردار است (Iftikhar et al., 2023). با توجه به مطالعات صورت‌گرفته، پیش‌بینی مقدار نسبت باربری کالیفرنیا و مقاومت فشاری محصورنشده خاک تورم‌پذیر تثبیت‌شده با آهک با استفاده از روش اسپیلاین رگرسیون چند متغیره کمتر مورد توجه قرار گرفته است. هدف از انجام این تحقیق، توسعه مدل اسپیلاین رگرسیون تطبیقی چند متغیره برای پیش‌بینی مقدار CBR و UCS خاک تورم‌پذیر تثبیت‌شده با آهک هیدراته فعال شده با خاکستر پوسته برنج به‌منظور کاهش هزینه و زمان آزمایش است. همچنین در این تحقیق از تعداد متغیر محدودتری در مقایسه با تحقیقات گذشته به‌عنوان ورودی برای مدلسازی استفاده شده است، که نشان دهنده مزیت و نوآوری این روش نسبت به مدل‌های توسعه داده شده است.

## ۲- روش‌شناسی

۲-۱- روش اسپیلاین رگرسیونی تطبیقی چند متغیره  
 MARS یک روش رگرسیونی غیر پارامتریک است که با استفاده از یک سری قطعه معادلات خطی (اسپیلاین) با درجات مختلف بین متغیرهای مستقل (ورودی‌ها) و پارامترهای غیرمستقل (خروجی) ارتباط ایجاد می‌کند. در این روش نیاز به هیچ پیش‌فرضی در خصوص ارتباط بین متغیرهای ورودی و خروجی نیست. نقاط پایانی هر ناحیه گره نامیده می‌شوند. به‌عبارت دیگر، یک گره، نشان دهنده پایان یک ناحیه و شروع ناحیه دیگر است. قطعه منحنی نهایی، که تابع پایه نامیده

نیز از روش *Light Gradient boosting machine* برای پیش‌بینی مقدار CBR خاک تورم‌پذیر تثبیت‌شده استفاده کردند (Quan & Do, 2021). اونیلو و همکاران از برنامه‌نویسی بیان ژن برای پیش‌بینی مقدار CBR خاک تورم‌پذیر تثبیت‌شده استفاده کردند. نتایج نشان داد که مدل توسعه داده‌شده دارای دقت بالا جهت پیش‌بینی مقدار CBR جهت کاربردهای مهندسی می‌باشد (Onyelowe, Jalal, et al., 2021b). احمد و همکاران در تحقیق خود از روش رگرسیون فرآیند گوسی برای پیش‌بینی نسبت باربری کالیفرنیا خاک تورم‌پذیر تثبیت‌شده با آهک هیدراته فعال شده با خاکستر پوسته برنج استفاده کردند. نتایج به‌دست آمده نشان داد که روش استفاده شده دارای دقت قابل قبول برای پیش‌بینی مقدار این پارامتر می‌باشد (Ahmad, Al-Zubi, et al., 2023a).

در سال‌های اخیر محققان مختلفی به بررسی و پیش‌بینی مقاومت فشاری محصورنشده خاک با روش‌های مختلف محاسبات نرم پرداخته‌اند (Al-Bared et al., 2021; Ghanizadeh et al., 2019, 2021, 2022, 2023; Ghanizadeh & Naseralavi, 2023; Ghanizadeh & Rahrovan, 2019; Ghanizadeh & Safi Jahanshahi, 2023; Kumar et al., 2023; Pham et al., 2021a; Salehi et al., 2023; Tabarsa et al., 2021; Tran, 2022a). همکاران از یک مدل رگرسیونی تجربی برای ارتباط بین مقاومت فشاری محصورنشده خاک تثبیت‌شده و خصوصیات خاک و درصد افزودنی استفاده کردند (Teijón-López & Zuazo et al., 2020). همچنین بی و چیان نیز برای ارتباط بین مقدار مقاومت فشاری محصورنشده خاک تثبیت‌شده و خصوصیات خاک، یک مدل تجربی ارائه دادند (Bi & Chian, 2021). داس و همکاران و سومان و همکاران از روش‌های مختلف هوش مصنوعی مانند ماشین بردار پشتیبان، شبکه عملکردی و روش اسپیلاین رگرسیونی چند متغیره برای پیش‌بینی مقاومت فشاری خاک تثبیت‌شده با سیمان با استفاده از خصوصیات خاک استفاده کردند (Das et al., 2011; Suman et al., 2016). سلیمانی و همکاران در تحقیق خود از روش برنامه‌نویسی چند ژنی برای پیش‌بینی مقدار مقاومت فشاری محصورنشده خاک رس تثبیت‌شده با ژئوپلیمر استفاده کردند (Soleimani et al., 2018). جاودانیان و لی از روش گروهی مدلسازی داده برای پیش‌بینی مقاومت فشاری محصورنشده خاک چسبنده تثبیت‌شده با ژئوپلیمر استفاده کردند. نتایج آن‌ها نشان داد که، مدل توسعه داده‌شده دارای

پسرو، مدل توسعه داده شده در مرحله قبل اصلاح و سپس عبارتهایی که تأثیر چندانی بر روی مدل ندارند، از مدل توسعه داده شده حذف می‌شوند. فرض کنید  $y$  یک خروجی پیوسته و  $X$  بردار ورودی است که شامل  $p$  متغیر غیرمستقل است  $X = \{x_1, x_2, \dots, x_p\}$ . رابطه بین متغیرهای ورودی و خروجی به صورت زیر تعریف می‌شود.

$$y = f(x_1, x_2, \dots, x_p) + \varepsilon$$

شده است که گره در مکان  $t$  قرار دارد. تابع  $\max(\cdot)$  نشان می‌دهد که فقط از قسمت مثبت  $x-t$  استفاده شده است، و اگر این مقدار منفی باشد، مقدار تابع برابر با صفر است. به عبارت دیگر:

$$\max(0, x - t) = \begin{cases} x - t & x > t \\ 0 & x < t \end{cases}$$

تابع  $f(x)$  به صورت ترکیبی از توابع پایه به صورت زیر نوشته می‌شود.

$$f(X) = \beta_0 + \sum_{n=1}^N \beta_n \lambda_n(X)$$

به منظور کاهش جمله‌های مدل و توسعه یک مدل بهینه که پارامترهای اضافی آن حذف شده است، استفاده می‌شود. در مرحله پسرو توابع پایه مدل که دارای سهم کمتری می‌باشند حذف می‌شوند تا زمانی که یک مدل ایده‌آل توسعه داده شود. بنابراین در مرحله پسرو، بهترین توابع پایه حفظ می‌شوند. سپس از پارامتر اعتباری سنجی متقاطع تعمیم یافته (GCV) برای مقایسه زیر مدل‌های ساخته شده استفاده می‌شود. این پارامتر تعدادی از توابع پایه را جریمه می‌کند و به عنوان ابزاری موثر برای جلوگیری از بیش برآزش استفاده می‌شود. رابطه  $\varepsilon$ ، برای تعریف پارامتر GCV استفاده می‌شود (Hastie et al., 2001).

$$GCV = \frac{\frac{1}{M} \sum_{i=1}^M (y_i - f(X_i))^2}{\left(1 - \frac{N + d(N+1)/2}{M}\right)^2}$$

معادله میانگین مربعات خطای مدل ارزیابی شده به وسیله داده‌های آموزش در صورت کسر و افزایش واریانس ناشی از پیچیدگی مدل در مخرج قرار دارد. در هر مرحله، یک تابع پایه

می‌شود، دارای انعطاف‌پذیری بالایی است و معمولاً به صورت یک تابع خطی یا درجه دوم تعریف می‌شود. توابع پایه در روش اسپیلاین رگرسیونی تطبیقی چند متغیره به صورت گام به گام تولید می‌شوند و از الگوریتم رگرسیون تطبیقی برای شناسایی محل گره‌ها استفاده می‌شود. مدل MARS شامل دو مرحله پیشرو و پسرو است. اضافه شدن توابع پایه در مرحله پیشرو انجام می‌شود که منجر به بیش برآزش می‌شود. در مرحله

(۱)

که در آن خطای مدل توسط  $\varepsilon$  بیان می‌شود. تابع  $f$  در مدل MARS با استفاده از توابع پایه (BFs) برآورد می‌شود. توابع پایه می‌توانند به صورت توابع خطی یا درجه دوم بیان شوند. در این مطالعه، از روابط خطی به صورت  $\max(0, x-t)$  استفاده

(۲)

در این معادله  $\lambda_n(X)$  تابع پایه است. تابع پایه می‌تواند حاصل ضرب چندین قطعه توابع اسپیلاین یا شامل یک قطعه تابع اسپیلاین باشد (معادله ۲)، ضریب  $\beta$  براساس روش حداقل مربعات تعیین می‌شود. برای توسعه روش اسپیلاین رگرسیونی تطبیقی چند متغیره، در ابتدا یک مدل بر اساس  $\beta_0$  ساخته می‌شود و سپس یک جفت تابع پایه به آن اضافه شده که سبب کاهش چشمگیر خطا در داده‌های آموزش می‌شود. علاوه بر این، حاصل ضرب این توابع نیز به عنوان توابع پایه بررسی می‌شود. توابع پایه تا زمانی که تعداد آن‌ها به تعداد مورد نظر از پیش تعریف شده برسد، به مدل اضافه می‌شوند و سبب بیش برآزش مدل می‌گردند. در این موقعیت، از مرحله پسرو

(۴)

که در این رابطه  $N$  تعداد توابع پایه،  $d$  پارامتر جریمه،  $M$  تعداد مشاهدات و  $f(X_i)$  مقدار پیش‌بینی شده توسط مدل روش اسپیلاین رگرسیونی تطبیقی چند متغیره است. در این

به‌عنوان یک شرط توقف تعریف می‌شود به طوری که اگر ضریب تعیین  $R_2$  مدل بزرگتر یا مساوی  $1-t$  باشد، قبل از به حداکثر رسیدن عبارت‌ها، آموزش مدل متوقف می‌شود.

## ۲-۲- الگوریتم جست‌وجو پرنده فراری

بسیاری از الگوریتم‌های فرا ابتکاری از فرآیند شکار در طبیعت الهام گرفته‌اند. نحوه برخورد طعمه و شکارچی، چگونگی رفتار شکارچی و چگونگی فرار کردن طعمه، یکی از قسمت‌های مهم زندگی حیوانات است. شهروزی و کاوه با الهام گرفتن از سیستم‌های شکارچی موجود در بین پرندگان، الگوریتم جست‌وجوی پرنده فراری را ارائه کرده‌اند (Shahrouzi & Kaveh, 2022). سوئیفت نام پرنده‌ای است که با استفاده از مانورهای سریع مانند بال زدن و چرخیدن سریع توانایی بالایی برای فرار از دست شکارچی دارد. این مانورها شامل مانورهای سطحی (چرخش سریع به‌منظور فرار از حمله‌های افقی) و مانورهای عمودی (برای فرار از حمله‌های افقی و به صورت شیرجه‌ای) می‌باشد. موقعیت پرنده در دامنه جست‌وجو به‌عنوان یک پارامتر طراحی که با توجه به پرواز پرنده متغیر است، در نظر گرفته می‌شود. توانایی پرنده برای مانور دادن به عواملی از قبیل سطح بدن، فرکانس بال زدن و سرعت آن بستگی دارد. مانورپذیری آمین پرنده مصنوعی (MPi) در الگوریتم جست‌وجوی پرنده فراری به صورت زیر تعریف می‌شود.

$$MP_i = b_i \|V_i\|^\beta$$

$V_i$  بردار سرعت است و مقدار آن برابر با اختلاف بین موقعیت فعلی پرنده  $i$ ام و موقعیت قبلی آن است.  $\|V_i\|$  نرم پارامتر  $V_i$  است و به صورت زیر تعریف می‌شود:

$$\|V_i\| = \sqrt{\sum_j V_{i,j}^2} \quad (6)$$

تأثیر تغییرات فرکانس بال زدن هنگام مانور با استفاده از متغیر  $\beta$  شبیه‌سازی می‌شود و مقدار آن بین محدوده ۰ و ۲ متغیر است. همچنین، شبیه‌سازی مساحت سطح بدن (هزینه) با استفاده از پارامتر بدن  $b_i$  و معادله نرمالایزه شده زیر انجام می‌شود.

$$b_i = \frac{C_{max} - C_i}{C_{max} - C_{min} + \varepsilon} \quad (7)$$

$C_i$  بیانگر هزینه پرنده  $i$ ام و  $C_{min}$  و  $C_{max}$  به ترتیب حداکثر و حداقل هزینه جمعیت را نشان می‌دهند. از ثابت  $\varepsilon$  برای جلوگیری از به صفر میل کردن استفاده می‌شود. نرخ فرار (ER) با استفاده از رابطه زیر تعیین می‌شود.

$$ER = \frac{MP_{EB}}{MP_{AB} + MP_{EB}} \quad (8)$$

حذف می‌شود تا معادله به خلاصه‌ترین شکل ممکن کاهش یابد. با تعیین مقدار مناسب برای پارامترهای مدل روش اسپیلاین رگرسیون تطبیقی چند متغیره شامل تعداد بیشینه توابع (MaxF)، پارامتر جریمه (d)، مقدار آستانه (t) و تعداد بیشینه اندرکنش‌ها (MaxI)، می‌توان از بیش برآزش یک کم برآزش شدن مدل جلوگیری کرد. در مرحله پیشرو، از تعداد بیشتری از توابع پایه استفاده می‌شود. مقدار توصیه‌شده برای MaxF، تقریباً دو برابر توابع پایه مورد انتظار در مدل نهایی است (Friedman, 1991). لازم به ذکر است، در صورتی که شرط خاتمه دیگری رخ دهد، این امکان وجود دارد که الگوریتم به این تعداد نرسد. حداکثر تعداد توابع پایه به صورت تقریبی از  $\min(200, \max(20, 2p))$  به دست می‌آید که در آن  $p$  مقدار متغیرهای ورودی است (Milborrow et al., 2017). مقدار زیاد پارامتر جریمه، منجر به کاهش تعداد گره‌ها می‌شود. به عبارت دیگر، مدل نهایی دارای توابع پایه کمتری می‌شود. همچنین، عبارت‌ها در صورتی که مقدار پارامتر جریمه برابر با صفر باشد، جریمه خواهند شد که برای مدل‌سازی‌های با تعداد داده زیاد، کم یا بدون نویز و داده‌هایی که رابطه قوی بین متغیرهای ورودی و خروجی آن وجود دارد، مناسب است. با افزایش پارامتر MaxI، تعداد عبارت‌هایی که حاصل ضرب دو تابع پایه هستند، در مدل نهایی افزایش می‌یابد، در نتیجه می‌تواند باعث بیش برآزش مدل شود. مقدار پارامتر آستانه (t)

(5)

در این معادله  $MP_{EB}$  و  $MP_{AB}$  مانورپذیری پرنده مهاجم (AB) و پرنده فراری (EB) می‌باشند. در طول مانور عمودی، طعمه یک مسیر متفاوت از مسیر شکارچی انتخاب می‌کند که این جابجایی از طریق رابطه زیر تعریف می‌شود.

$$X_{EB} = X_{EB} + r \times ER \times (Opp(X_{AB}) - X_{EB}) \quad (9)$$

موقعیت پرنده مهاجم (AB) و پرنده فراری (EB) به وسیله  $X_{EB}$  و  $X_{AB}$  بیان می‌شود و پارامتر  $r$ ، یک عدد تصادفی بین ۰ و ۱ است. همچنین، تابع  $Opp(\cdot)$  به وسیله رابطه زیر محاسبه می‌شود.

$$Opp(X_{AB}) = X_L + X_U - X_{AB} \quad (10)$$

زمانی که مقدار  $ER$  کوچک باشد، پرنده فراری با انحراف از مسیر فعلی، سطح مانور را انتخاب می‌کند. این اتفاق به وسیله جابجایی یک بردار موقعیت تصادفی مطابق با رابطه ۱۱ مدل سازی می‌شود.

$$X_{EB} = X_L + R \otimes (X_U - X_L) \quad (11)$$

در اینجا  $X_U$  و  $X_L$  کران پایین و بالای بردار متغیرهای طراحی می‌باشند.  $R$  بردار مقادیر تصادفی بین [۰ و ۱] است و  $\otimes$  بیانگر عملیات عنصری می‌باشد. معمولاً مسیر پرواز شکارچی به سمت موقعیت طعمه است. با این وجود، جهت دیگر، مانند پرواز در جهت بهترین مسیری که طعمه تا کنون تجربه کرده است به الگوریتم اضافه خواهد شد که با  $X_{G \text{ best}}$  نشان داده می‌شود. بنابراین، مانور شکارچی به وسیله معادله ۱۲ مدل سازی می‌شود.

$$X_{AB}^{Candidate} = X_{AB} + r_1 \times CR \times (X_{EB} - X_{AB}) + r_2 \times (X_{G \text{ best}} - X_{EB}) \quad (12)$$

$r_1$  و  $r_2$  مقادیر تصادفی هستند و به طور جداگانه تولید می‌شوند. معادله نرخ جذب (CR) به صورت زیر بیان می‌شود.

$$CR = 1 - ER \quad (13)$$

زمانی که مقدار  $ER$  زیاد باشد، نرخ جذب میل به صفر شدن دارد و برعکس. نرخ فرار، تأثیر طعمه و شکارچی را مدل سازی می‌کند. مراحل الگوریتم جست و جوی پرنده فراری با استفاده از مانورهای شبیه سازی شده در بالا، به شرح زیر

$$X_i = X_L + R \otimes (X_U - X_L) \quad (14)$$

پارامترها با استفاده از معادله ۱۱ تعریف می‌شوند. در نتیجه، تابع هزینه برای تمامی پرنده‌ها ارزیابی می‌شود و سرعت آن‌ها صفر در نظر گرفته می‌شود. این جمعیت شامل طعمه و شکارچی است. در مرحله سوم شکارچیان مشخص می‌شوند.

مرحله دوم: مانورپذیری هر پرنده در معادله (۵) به همراه پارامترهای نرمال سازی هزینه در معادله (۷) محاسبه شود.

مرحله سوم: تکرار حلقه اصلی تا برقراری شرط توقف:

انجام مراحل زیر برای  $i$  از ۱ تا  $N$ .

انتخاب پرنده  $\lambda$  و ساخت یک جفت تصادفی با یک پرنده از جمعیت. انتخاب بهترین به عنوان پرنده مهاجم (AB) و بدترین به عنوان پرنده فراری (EB).

محاسبه  $ER$ ،  $CR$  و  $MP$  جفت پرنده با استفاده از معادلات ۵، ۹ و ۱۳.

تعریف یک جواب برای AB با استفاده از معادله ۱۲.

ارزیابی هزینه  $X_{AB}^{Candidate}$

-جایگزین کردن  $X_{AB}$  با  $X_{AB}^{Candidate}$  در صورتی که مقدار هزینه  $X_{AB}^{Candidate}$  کمتر از  $X_{AB}$  باشد (انتخاب حریصانه).  
 -به پایان رسیدن حلقه اصلی به محض رسیدن ارزیاب تابع برازندگی (NFS) یا تعداد هزینه‌ها به مقدار از پیش تعیین شده  $NFE_{max}$ .  
 -ساختن یک راه‌حل برای پرنده فراری (EB) با استفاده از رابطه مانور عمودی (۹) یا رابطه مانور سطحی (۱۱). عوض کردن مانورهای فرار با استفاده از رابطه ۱۵.

$$X_{EB}^{Candidate} = \begin{cases} X_L + R \otimes (X_U - X_L) \\ X_{EB} + r \times ER \times (Opp(X_{AB}) - X_{EB}) \end{cases} \quad \text{if } ER < 1/N \\ \text{otherwise} \quad (15)$$

-ارزیابی هزینه  $X_{AB}^{Candidate}$   
 -جایگزین کردن  $X_{AB}$  با  $X_{AB}^{Candidate}$  در صورتی که مقدار هزینه  $X_{AB}^{Candidate}$  کمتر از  $X_{AB}$  باشد (انتخاب حریصانه).  
 -به پایان رسیدن حلقه اصلی به محض رسیدن ارزیاب تابع برازندگی (NFS) یا تعداد هزینه‌ها به مقدار از پیش تعیین شده  $NFE_{max}$ .  
 -به‌روز رسانی  $X_{G \text{ best}}$   
 رفتن به مرحله سوم اگر  $i$  برابر با  $N$  بود، در غیر این صورت از حلقه اصلی خارج و به مرحله چهارم بروید.  
 مرحله چهارم: گزارش مقدار  $X_{G \text{ best}}$  به‌روز شده به‌عنوان راه‌حل بهینه بعد از خاتمه یافتن حلقه اصلی. الگوریتم جست‌وجو پرنده فراری فقط به دو متغیر  $NFE_{max}$  و  $N$  نیاز دارد.

### ۲-۳- تنظیم پارامترهای MARS با استفاده از الگوریتم جست‌وجوی پرنده فراری

مدل پیش‌بینی کننده تأثیر بگذراند و مانع بیش‌برازش آن شوند، شامل حداکثر تعداد توابع (MaxF)، پارامتر جریمه (d)، مقدار آستانه (t) و حداکثر تعداد اندرکنش‌ها (MaxI) است. روش پیشنهادی دارای چهار مرحله اصلی به‌صورت زیر است.  
 مرحله اول: در نظر گرفتن تابع برازندگی به‌منظور به حداقل رساندن مقدار خطا با استفاده از مقایسه کردن مقدار اندازه گیری شده متغیر خروجی با مقادیر پیش‌بینی شده آن.

در این مقاله، از روش MARS-EBS برای پیش‌بینی نسبت باربری کالیفرنیا و مقاومت فشاری محصورنشده خاک تورم‌پذیر تثبیت‌شده با آهک فعال‌شده استفاده شده است. یکی از انگیزه‌ها اصلی این مطالعه دستیابی به مقادیر بهینه چهار پارامتر مدل MARS برای پیش‌بینی مقدار نسبت باربری کالیفرنیا و مقاومت فشاری محصورنشده با استفاده از راه‌حل‌های مبتنی بر جمعیت است. پارامترهای مدل MARS که می‌توانند بر دقت

$$f = MSE_{Train} + MSE_{Test} \quad (16)$$

مرحله دوم: شروع به تخمین مقدار متغیر خروجی بر اساس توزیع یکنواخت پارامترهای مدل MARS (برای مثال MaxF، d، t و MaxI)، همانطور که در معادله زیر نشان داده شده است.

$$X = (Ub - Lb) \times rand + Lb \quad (17)$$

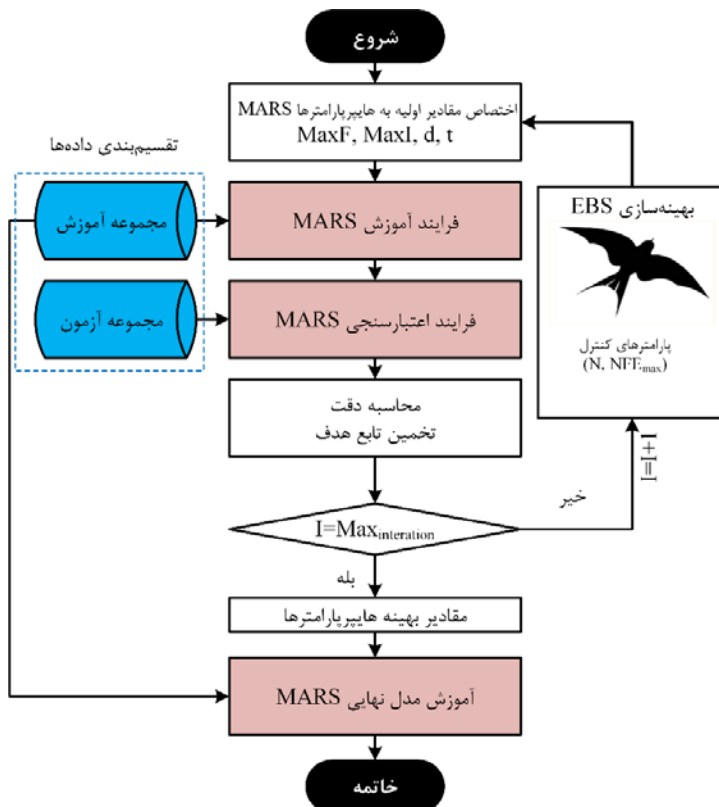
در اینجا  $MSE_{Train}$  و  $MSE_{Test}$  بیانگر میانگین مربعات خطا برای داده‌های آموزش و آزمون است. تعادل به‌دست آمده بین پیچیدگی و قابلیت تعمیم مدل به‌وسیله تابع برازندگی بیان می‌شود.

مرحله سوم: در طول فرآیند بهینه‌سازی جمعیت الگوریتم متاهیرستیک دارای متغیرهای زیادی می‌باشد که شامل پارامترهای مدل MARS است. با هر تکرار، MSE به‌عنوان یک تابع برازندگی هر گروهی از پارامترها محاسبه می‌شود. الگوریتم EBS پارامترهای با برآش کم را حذف می‌کند و به

در اینجا  $Ub$  حداکثر کران بالای پارامتر مورد نظر است و  $Lb$  حداقل کران پایین پارامتر انتخاب شده،  $rand$  بیانگر یک عدد تصادفی بین ۰ و ۱ است و  $X$  یک مقدار تصادفی اولیه برای پارامتر مورد نظر است.

بر اساس مقادیر بهینه پارامترها برای پیش‌بینی نسبت باربری کالیفرنیا و مقاومت فشاری محصورنشده به دست می‌آید. فرآیند ترکیبی MARS-EBS در شکل ۱ نشان داده شده است.

تدرج جمعیت (پارامترهای MARS) را به مقادیر با توابع برازندگی بالا همگرا می‌کند. مرحله چهارم: تا رسیدن به حداکثر تکرار، فرآیند بهینه‌سازی تکرار می‌شود. در نهایت، مدل MARS بهینه



شکل ۱. فرآیند ساخت مدل MARS بر اساس روش MARS-EBS

### ۳- ارزیابی دقت مدل

(RMSE) و میانگین خطای مطلق (MAE) استفاده شد. این شاخص‌ها با استفاده از روابط زیر قابل محاسبه هستند.

در این تحقیق برای سنجش برآزش مدل اسپیلاین رگرسیونی چند متغیره بر اساس داده‌های آموزش و آزمون از شاخص‌های ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا

$$R^2 = \frac{(n \sum t_i o_i - \sum t_i \sum o_i)^2}{(n \sum t_i^2 - (\sum t_i)^2)(n \sum o_i^2 - (\sum o_i)^2)} \quad (18)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - o_i)^2} \quad (19)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |t_i - o_i| \quad (20)$$

در معادلات فوق  $t$  مقدار اندازه‌گیری شده (واقعی)،  $o$  مقدار خروجی مدل و  $n$  تعداد کل نقاط داده می‌باشد.

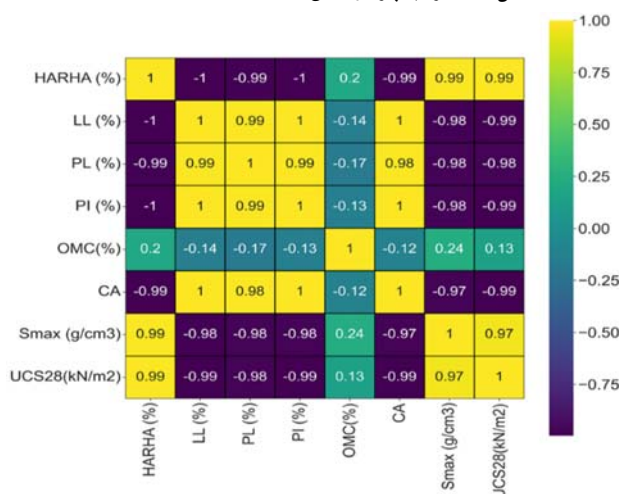
#### ۴- پایگاه داده

کالیفرنیا (CBR) (%) و از پارامترهای آهک هیدراته فعال شده توسط خاکستر پوسته برنج (HAHRA) (%). حد خمیری (PL) (%). شاخص خمیری (PI) (%). رطوبت بهینه (OMC) (g/cm<sup>3</sup>) (γ<sub>dmax</sub>) و حداکثر وزن مخصوص خشک به عنوان ورودی های مدل توسعه داده شده برای پیش بینی مقدار مقاومت فشاری محصور نشده (UCS) (KN/m<sup>2</sup>) استفاده شد. ضریب پیرسون بین پارامترهای مختلف در شکل ۲ و ۳ نشان داده شده است. همانطور که در شکل ۱ و ۲ نشان داده شده است، مقدار CBR و UCS با درصد آهک فعال و حداکثر وزن مخصوص خشک دارای بیشترین همبستگی می باشند. مشخصات آماری داده ها در جدول ۱ ارائه شده است. در اینجا ۸۵ داده (۷۰ درصد) به صورت تصادفی به عنوان مجموعه داده آموزش و ۳۶ داده (۳۰ درصد) به عنوان مجموعه داده آزمون انتخاب شدند.

در تحقیق حاضر از یک مجموعه داده شامل ۱۲۱ نقطه داده حاصل از مطالعات آزمایشگاهی اونیلو و همکاران استفاده شده است (Onyelowe, Jalal, et al., 2021b). متغیرهای ورودی در پایگاه داده شامل آهک هیدراته فعال شده توسط خاکستر پوسته برنج (HAHRA) (%). حد روانی (LL) (%). حد خمیری (PL) (%). شاخص خمیری (PI) (%). رس فعال (CA)، حداکثر وزن مخصوص خشک (γ<sub>dmax</sub>) (g/cm<sup>3</sup>) و رطوبت بهینه (OMC) (%). به عنوان متغیرهای ورودی در نظر گرفته شدند. با توجه به اندرکنش بین پارامترهای ورودی و ضریب همبستگی پیرسون بین آنها از پارامترهای آهک هیدراته فعال شده توسط خاکستر پوسته برنج (HAHRA) (%). حد خمیری (PL) (%). شاخص خمیری (PI) (%). و حداکثر وزن مخصوص خشک (γ<sub>dmax</sub>) (g/cm<sup>3</sup>) به عنوان متغیرهای ورودی مدل توسعه داده شده برای پیش بینی مقدار نسبت باربری



شکل ۲. ضریب پیرسون بین داده های ورودی و CBR



شکل ۳. ضریب پیرسون بین داده های ورودی و UCS

جدول ۱. مشخصات آماری داده‌های آزمایشگاهی خاک رس تثبیت شده با سیمان

متغیر	حداکثر	حداقل	میانگین	انحراف معیار
درصد آهک هیدراته فعال شده توسط پوسته برنج (%)	۱۲	۰	۶	۳/۴۹
حد خمیری (%)	۲۱	۱۲/۸	۱۷/۱۷	۲/۴۰
شاخص خمیری (%)	۴۵	۱۴	۳۰/۸۲	۹/۱۰
درصد رطوبت (%)	۱۹	۱۶	۱۸/۰۲	۰/۷۶
حداکثر وزن خشک مخصوص (g/cm <sup>3</sup> )	۱/۹۹	۱/۲۵	۱/۶۸	۰/۲۴
CBR (%)	۴۴/۶	۸	۲۳/۹۹	۱۱/۶۹
UCS (KN/m <sup>2</sup> )	۲۳۲	۱۲۵	۱۷۲/۸۶	۳۱/۵۲

(MaxF)، پارامتر جریمه (d)، مقدار آستانه (t) و تعداد بیشینه اندرکنش‌ها (MaxI).

با تعیین مقدار مناسب برای پارامترهای مدل روش اسپیلاین رگرسیونی تطبیقی چند متغیره شامل تعداد بیشینه توابع

### توسعه مدل پیش‌بینی نسبت باربری کالیفرنیا و مقاومت فشاری محصورنشده

۲۹/۱۰۳۵، ۱۱/۳۱۵۶، ۰/۰۰۰۰۰۴۲ و ۱۶۹/۸۵۱۴ و مقدار این پارامترها برای مدل توسعه داده شده برای پیش‌بینی مقاومت فشاری محصورنشده به ترتیب برابر با ۲۹/۰۳۷۵، ۳/۳۴۲۲، ۲۹/۳۵۲۰ و ۱۳۶/۵۵۶۰ تعیین شد. معادله توسعه داده شده برای پیش‌بینی مقدار نسبت باربری کالیفرنیا و مقاومت فشاری محصور نشده به صورت زیر می‌باشد.

در این تحقیق از نرم افزار MATLAB و کتابخانه ARESlab به منظور توسعه مدل MARS استفاده شده است (Jekabsons, 2011). مقدار بهینه پارامترهای تنظیمی توسعه داده شده برای پیش‌بینی نسبت باربری کالیفرنیا شامل تعداد بیشینه توابع (MaxF)، پارامتر جریمه (d)، مقدار آستانه (t) و تعداد بیشینه اندرکنش‌ها (MaxI)، به ترتیب برابر با

$$CBR(\%) = 25.188 + 4.4177 \times BF_1 - 3.117 \times BF_2 - 0.1066 \times BF_3 - 5.9652 \times BF_4 + 26.21 \times BF_5 + 4.0074 \times BF_6 \quad (21)$$

که در آن:

$$\begin{aligned} BF_1 &= \text{Max}(0, \text{HAHRA} - 6.8) \\ BF_2 &= \text{Max}(0, 6.8 - \text{HAHRA}) \\ BF_3 &= BF_1 \times \text{Max}(0, \text{PI} - 17.1) \\ BF_4 &= BF_1 \times \text{Max}(0, 14 - \text{PL}) \\ BF_5 &= \text{Max}(0, 14 - \text{PL}) \\ BF_6 &= \text{Max}(0, 1.72 - \gamma_{d\max}) \times \text{Max}(0, 2.2 - \text{HAHRA}) \end{aligned}$$

$$\begin{aligned} UCS(KN/m^2) &= 194.96 - 386.54 \times BF_1 - 7.9969 \times BF_2 + 202.51 \times BF_3 - 0.55294 \\ &\quad \times BF_4 \\ &+ 1.1189 \times BF_5 + 0.57543 \times BF_6 + 0.119 \times BF_7 - 62.123 \times BF_8 - 3.7667 \times BF_9 \\ &- 0.90058 \times BF_{10} + 1.54 \times BF_{11} - 1.1246 \times BF_{12} \end{aligned} \quad (22)$$

که در آن:

$$\begin{aligned} BF_1 &= \text{Max}(0, \text{HAHRA} - 8.6) \\ BF_2 &= \text{Max}(0, 8.6 - \text{HAHRA}) \\ BF_3 &= BF_1 \times \gamma_{d\max} \\ BF_4 &= \text{Max}(0, \text{PI} - 30.4) \\ BF_5 &= \text{Max}(0, 30.4 - \text{PI}) \end{aligned}$$

$$\begin{aligned} BF_6 &= BF_4 \times \text{Max}(0, \text{HAHRA} - 3.6) \\ BF_7 &= BF_4 \times \text{Max}(0, 3.6 - \text{HAHRA}) \\ BF_8 &= BF_2 \times \text{Max}(0, \gamma_{dmax} - 1.83) \\ BF_9 &= \text{Max}(0, 20.8 - \text{PL}) \times \text{Max}(0, \gamma_{dmax} - 1.46) \\ BF_{10} &= BF_9 \times \text{Max}(0, \text{HAHRA} - 9.4) \\ BF_{11} &= BF_9 \times \text{Max}(0, 9.4 - \text{HAHRA}) \\ BF_{12} &= \text{Max}(0, 20.8 - \text{PL}) \times \text{Max}(0, \text{OMC} - 17.53) \end{aligned}$$

۰/۲۵۹ و برای داده‌های آزمون برابر با ۰/۲۳۱ است. مقدار میانگین خطای مطلق (MAE) برای داده‌های آموزش و آزمون به ترتیب برابر با ۰/۲۱۰ و ۰/۲۹۶ می‌باشد. همچنین مقدار ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا (RMSE) و خطای مطلق (MAE) برای تمامی داده‌ها به ترتیب برابر با ۰/۹۹۹۵، ۰/۲۷۱ و ۰/۲۱۶ می‌باشد.


شاخص‌های عملکرد مدل توسعه داده شده برای پیش‌بینی نسبت باربری کالیفرنیا به تفکیک برای داده‌های آموزش و آزمون در جدول ۲ داده شده است. همانگونه که ملاحظه می‌شود مقدار ضریب تعیین ( $R^2$ ) برای داده‌های آموزش و آزمون به ترتیب برابر با ۰/۹۹۹۵ و ۰/۹۹۹۴ است و مقدار جذر میانگین مربعات خطا (RMSE) برای داده‌های آموزش برابر با

جدول ۲. شاخص‌های آماری مربوط به دقت مدل توسعه داده شده برای پیش‌بینی CBR

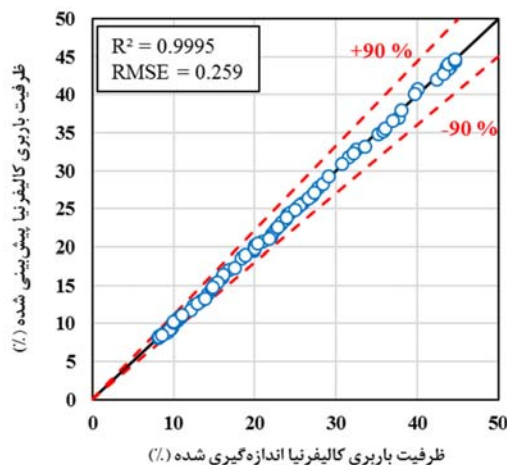
کل داده‌ها	داده‌های آزمون	داده‌های آموزش	
۰/۲۷۱	۰/۲۳۱	۰/۲۵۹	ریشه میانگین خطای مربعات (RMSE)
۰/۲۱۶	۰/۲۹۶	۰/۲۱۰	میانگین خطای مطلق (MAE)
۰/۹۹۹۵	۰/۹۹۹۴	۰/۹۹۹۵	ضریب تعیین ( $R^2$ )

داده‌شده اکثر داده‌ها دارای خطای کمتر از ۱۰ درصد هستند. بنابراین، مدل‌های پیشنهادی دارای دقت بسیار بالایی جهت پیش‌بینی نسبت باربری کالیفرنیا می‌باشد.

عملکرد مدل توسعه داده شده برای پیش‌بینی نسبت باربری کالیفرنیا در شکل ۴ نشان داده شده است. نزدیکی نقاط داده به خط برابری نشان می‌دهد که مدل توسعه داده شده دقت مناسبی در پیش‌بینی نسبت باربری کالیفرنیا دارد. در مدل توسعه



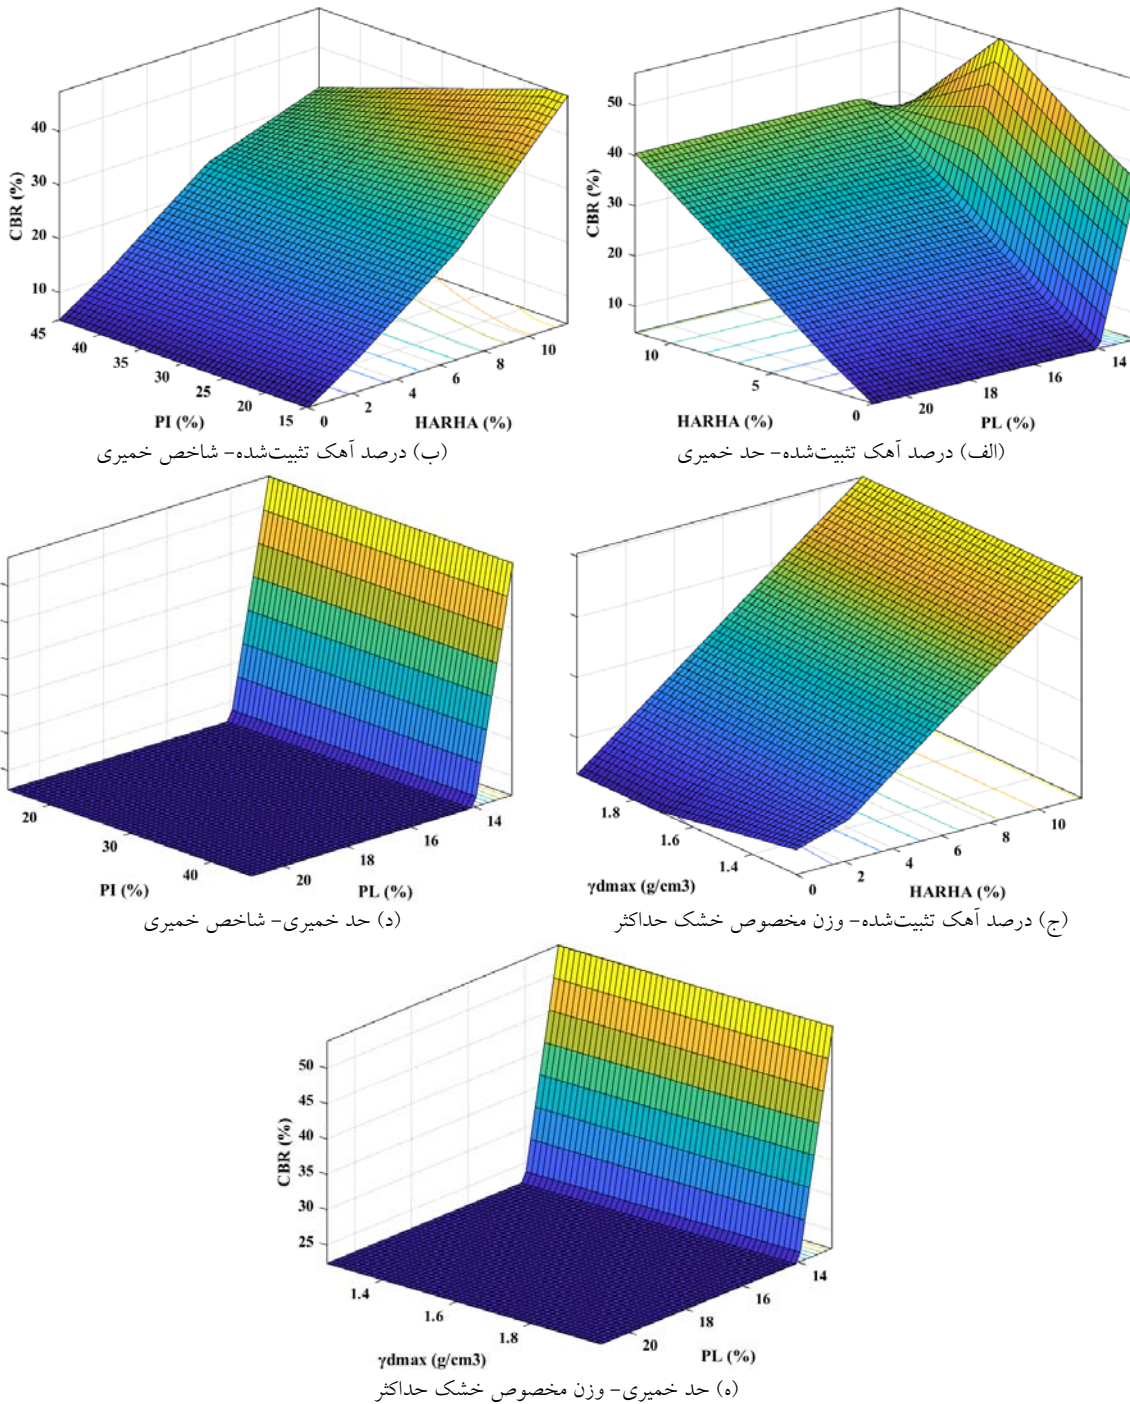
(ب)



(الف)

شکل ۴. عملکرد مدل CBR. الف) داده‌های آموزش و ب) داده‌های آزمون

در شکل ۵ ابرصفحه‌های ساخته شده توسط مدل MARS و تأثیر اندرکنش بین متغیرهای ورودی بر مدل توسعه داده شده برای پیش‌بینی نسبت باربری کالیفرنیا نشان داده شده است.



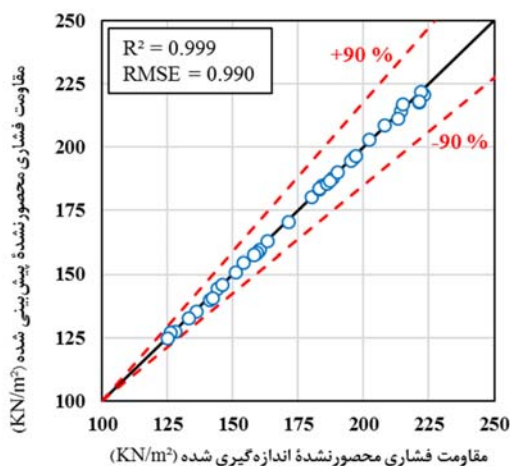
شکل ۵. اندرکنش بین پارامترهای ورودی و تأثیر آن بر روی نسبت باربری کالیفرنیا پیش‌بینی شده

خطای مطلق (MAE) برای تمامی داده‌ها به ترتیب برابر با ۰/۹۹۹۵، ۰/۷۱۶ و ۰/۴۸۸ می‌باشد. عملکرد مدل توسعه‌داده شده برای پیش‌بینی مقاومت فشاری محصورنشده در شکل ۶ نشان داده شده است. نزدیکی نقاط داده به خط برابری نشان می‌دهد که مدل توسعه داده شده دقت مناسبی در پیش‌بینی مقاومت فشاری محصورنشده دارد. در مدل توسعه داده شده اکثر داده‌ها دارای خطای کمتر از ۱۰ درصد هستند. بنابراین، مدل‌های پیشنهادی دارای دقت مورد قبول جهت پیش‌بینی مقاومت فشاری محصورنشده می‌باشد.

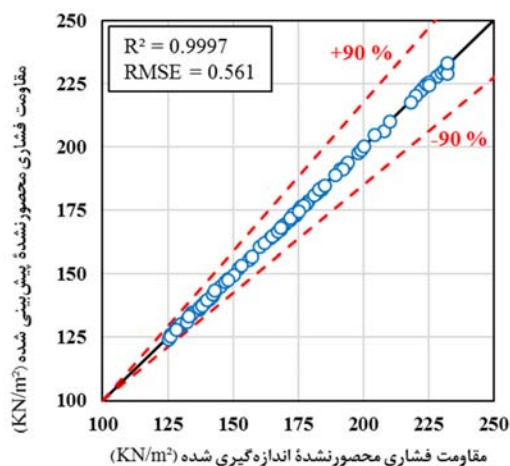
شاخص‌های عملکرد مدل توسعه داده شده برای پیش‌بینی مقاومت فشاری محصورنشده به تفکیک برای داده‌های آموزش و آزمون در جدول ۳ داده شده است. همانگونه که ملاحظه می‌شود مقدار ضریب تعیین ( $R^2$ ) برای داده‌های آموزش و آزمون به ترتیب برابر با ۰/۹۹۹۷ و ۰/۹۹۹ است و مقدار جذر میانگین مربعات خطا (RMSE) برای داده‌های آموزش برابر با ۰/۵۶۱ و برای داده‌های آزمون برابر با ۰/۹۹۰ است. مقدار میانگین خطای مطلق (MAE) برای داده‌های آموزش و آزمون به ترتیب برابر با ۰/۴۰۴ و ۰/۶۸۸ می‌باشد. همچنین مقدار ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا (RMSE) و

جدول ۳. شاخص‌های آماری مربوط به دقت مدل توسعه داده شده برای پیش‌بینی UCS

کل داده‌ها	داده‌های آزمایش	داده‌های آموزش	
۰/۷۱۶	۰/۹۹۰	۰/۵۶۱	ریشه میانگین خطای مربعات (RMSE)
۰/۴۸۸	۰/۶۸۸	۰/۴۰۴	میانگین خطای مطلق (MAE)
۰/۹۹۹۵	۰/۹۹۹	۰/۹۹۹۷	ضریب تعیین ( $R^2$ )



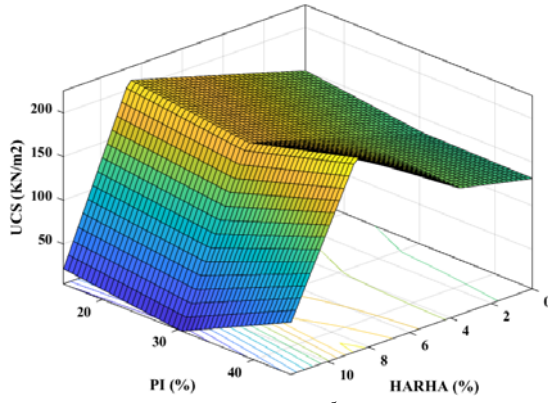
(ب)




(الف)

شکل ۶. عملکرد مدل UCS، الف) داده‌های آموزش و ب) داده‌های آزمون


در شکل ۷ ابرصفحه‌های ساخته شده توسط مدل MARS و تأثیر اندرکنش بین متغیرهای ورودی بر مدل توسعه داده شده برای پیش‌بینی نسبت باربری کالیفرنیا نشان داده شده است.




(ب) درصد آهک تثبیت شده- شاخص خمیری




(الف) درصد آهک تثبیت شده- حد خمیری




(د) درصد آهک تثبیت شده- وزن مخصوص خشک حداکثر




(ج) درصد آهک تثبیت شده- درصد رطوبت بهینه




(و) حد خمیری- درصد رطوبت بهینه





(ه) حد خمیری- شاخص خمیری



(ح) شاخص خمیری- درصد رطوبت بهینه



(ز) حد خمیری- وزن مخصوص خشک حداکثر



شکل ۷. اندرکنش بین پارامترهای ورودی و تأثیر آن بر روی مقاومت فشاری محصورنشده پیش‌بینی شده

مقدار آن بیشتر باشد، حذف متغیر مربوطه یا اندرکنش دو متغیر مربوط به آن باعث ایجاد خطای بالاتری در مدل می‌شود. تعداد توابع پایه که شامل متغیر یا اندرکنش دو متغیر می‌باشد به همراه متغیرهای ورودی مرتبط با توابع پایه در ستون چهارم و پنجم آمده است. لازم به ذکر است که مقدار GCV برای مدل توسعه‌داده شده نهایی CBR که شامل تمام توابع است برابر با ۰/۲۳۹۶ و برای مدل UCS برابر با ۰/۷۷۹۷ است.

نتیجه آزمون ANOVA برای مدل‌های توسعه داده شده برای پیش‌بینی CBR و UCS در جدول ۴ و ۵ نشان داده شده است. در این جدول شماره تابع ANOVA در ستون اول و انحراف معیار این تابع در ستون دوم آورده شده است. در ستون سوم، مقدار GCV برای مدلی که تمام توابع پایه برای آن تابع خاص ANOVA حذف شده‌اند، درج شده است. این ستون بیانگر درجه اهمیت هر یک از متغیرها است به طوری که هرچه

جدول ۴. جزئیات آزمون ANOVA برای مدل توسعه داده شده CBR

متغیرها	#Basis	GCV	انحراف معیار	تابع
HAHRA	۲	۸۲/۱۳۴۳	۱۲/۵۷۴۱	۱
PL	۱	۰/۲۸۹۲	۵/۸۵۵۱	۲
HAHRA, PL	۱	۰/۳۱۱۸	۶/۳۵۰۸	۳
HAHRA, PI	۱	۰/۴۸۴۷	۰/۴۶۹۰	۴
HAHRA, $\gamma_{dmax}$	۱	۱/۱۰۶۳	۰/۸۶۹۵	۵

جدول ۵. جزئیات آزمون ANOVA برای مدل توسعه داده شده UCS

متغیرها	#Basis	GCV	انحراف معیار	تابع
HAHRA	۲	۹/۵۶۲۸	۳۴۲/۲۴۹۸	۱
PI	۲	۰/۸۸۳۴	۷/۶۱۴۶	۲
HAHRA, PI	۲	۱/۲۶۹۴	۱/۵۷۸۶	۳
HAHRA, $\gamma_{dmax}$	۲	۱۰/۰۹۸۲	۳۳۸/۲۶۵۸	۴
PL, OMC	۱	۰/۹۳۸۷	۱/۷۵۲۵	۵
PL, $\gamma_{dmax}$	۱	۰/۹۱۸۵	۵/۳۲۸۸	۶
HAHRA, PL, $\gamma_{dmax}$	۲	۰/۸۸۷۸	۳/۴۶۵۸	۷

### مقایسه مدل‌های توسعه داده شده با مدل‌های موجود

برای به دست آوردن مقدار مقاومت فشاری محصور نشده و نسبت باربری کالیفرنیا نمی‌باشند و به همین دلیل برای سایر کارهای اجرایی و تحقیقاتی قابل استفاده نمی‌باشند که بیانگر ضعف این مدل‌ها در مقایسه با روش توسعه داده شده در این تحقیق می‌باشد. همچنین در این تحقیق مدل‌های توسعه داده شده از بین متغیرهای ورودی، متغیرهای با تأثیر قابل توجه بیشتر را به عنوان ورودی در نظر گرفته و باقی مانده متغیرها را که تأثیر چندانی در مدلسازی نداشته‌اند در نظر نگرفته‌اند. که نشان می‌دهد بر خلاف تحقیقات گذشته که تمامی متغیرهای وارد مدلسازی می‌شوند، در این تحقیق متغیرهای محدودتری وارد مدلسازی شده است.

در این بخش مدل‌های توسعه داده شده توسط محققان پیشین معرفی و نتایج آن‌ها با نتایج مدل‌های پیشنهاد شده در این تحقیق مقایسه شده است. نتایج به دست آمده از پژوهش‌های قبلی در جدول ۶ نشان داده شده است. همانطور که مشخص است در بین مدل‌های توسعه داده شده برای پیش‌بینی مقاومت فشاری محصور نشده، مدل‌های توسعه داده شده بر اساس روش SVM و GPR توسط احمد و همکاران دارای دقت بیشتری در مقایسه با سایر روش‌ها می‌باشند. از بین مدل‌های توسعه داده شده برای پیش‌بینی مقدار نسبت باربری کالیفرنیا نیز مدل‌های توسعه داده شده بر اساس روش ANN و GPR توسط آنیلو و همکاران و احمد و همکاران دارای بیشترین دقت می‌باشند. با این وجود این مدل‌ها دارای رابطه مشخصی

جدول ۶. جزئیات نتایج به دست آمده از سایر محققان

منابع	R <sup>2</sup>		R <sup>2</sup>		مدل
	نسبت باربری کالیفرنیا		مقاومت فشاری محصور نشده		
	آزمون	آموزش	آزمون	آموزش	
مطالعه حاضر	۰/۹۹۹	۰/۹۹۹۷	۰/۹۹۹۴	۰/۹۹۹۵	MARS-EBS
(Onyelowe, Jalal, et al., 2021b)	۰/۹۹۱۶	۰/۹۹۷۲	۰/۹۴۳۴	۰/۸۵۳۹	GEP
(Ahmad, Al-Mansob, et al., 2023)	-	-	۰/۹۹۹۸	۰/۹۹۹۹	SVM
(Ahmad, Al-Mansob, et al., 2023)	-	-	۰/۹۹۹۸	۰/۹۹۹۹	GPR
(Onyelowe, Iqbal, et al., 2021)	۰/۹۹۹۶	۰/۹۹۹۸	۰/۹۸۹	۰/۹۹۹	ANN
(Ahmad, Al-Zubi, et al., 2023b)	۰/۹۹۹۷	۰/۹۹۹۹	-	-	GPR
(Baghbani et al., 2023)	۰/۹۸۱	۰/۹۷۸	۰/۹۹۳	۰/۹۹۰	GP
(Baghbani et al., 2023)	۰/۹۸۲	۰/۹۹۰	۰/۹۸۰	۰/۹۸۵	CART

### ۵- نتیجه گیری

(HAHRA) (%)، حد خمیری (PL) (%)، شاخص خمیری (PI) (%)، رطوبت بهینه (OMC) (%) و حداکثر وزن مخصوص خشک ( $\gamma_{dmax}$ ) ( $g/cm^3$ ) به ترتیب دارای بیشترین تأثیر بر روی نسبت باربری کالیفرنیا و مقاومت فشاری محصور نشده می‌باشند. مقدار  $R^2$ ، RMSE و MAE داده‌های آموزش مدل توسعه داده شده برای پیش‌بینی CBR به ترتیب برابر با ۰/۹۹۹۵، ۰/۲۵۹ و ۰/۲۱۰ و برای داده‌های آزمون آن برابر با ۰/۹۹۹۴، ۰/۲۳۱ و ۰/۲۹۶ می‌باشد. همچنین، مقدار  $R^2$ ، RMSE و MAE داده‌های آموزش مدل توسعه داده شده برای پیش‌بینی UCS به ترتیب برابر با ۰/۹۹۹۷،

در تحقیق حاضر از روش اسپیلاین رگرسیون چند متغیره برای پیش‌بینی نسبت باربری کالیفرنیا و مقاومت فشاری محصور نشده خاک تورم پذیر تثبیت شده با آهک هیدراته فعال شده توسط پوسته برنج استفاده شده است. که برای این منظور از ۱۲۱ داده به دست آمده از نتایج آزمایشگاهی استفاده شده است. نتایج بدست آمده نشان داد که چهار پارامتر آهک هیدراته فعال شده توسط خاکستر پوسته برنج (HAHRA) (%)، حد خمیری (PL) (%)، شاخص خمیری (PI) (%) و حداکثر وزن مخصوص خشک ( $\gamma_{dmax}$ ) ( $g/cm^3$ ) و پنج پارامتر آهک هیدراته فعال شده توسط خاکستر پوسته برنج

شده توسط خاکستر پوسته برنج و وزن مخصوص خشک حداکثر، دارای بیشترین تأثیر در دقت نتایج به دست آمده از مدل توسعه داده شده برای مقاومت فشاری محصورنشده می‌باشند و پارامتر شاخص خمیری دارای کمترین اهمیت می‌باشد. استفاده از مدل توسعه داده شده در این تحقیق می‌تواند سبب کاهش هزینه و همچنین افزایش سرعت پیش‌بینی نسبت باربری کالیفرنیا، پارامتر درصد آهک فعال شده توسط پوسته برنج، دارای بیشتر اهمیت در مقایسه با سایر پارامترها می‌باشد، به‌طوریکه حذف این پارامتر سبب بروز خطای بزرگی در نتایج می‌باشد، همچنین این تحلیل نشان می‌دهد که پارامتر حد خمیری دارای کمترین تأثیر است. نتایج تحلیل ANOVA برای مدل توسعه داده شده برای پیش‌بینی مقاومت فشاری محصورنشده نشان می‌دهد که اندرکنش بین درصد آهک فعال

۰/۵۶۱ و ۰/۴۰۴ است و برای داده‌های آزمون آن برابر با ۰/۹۹۹، ۰/۹۹۰ و ۰/۶۸۸ است. همچنین این مقادیر برای تمامی داده‌های مدل CBR به ترتیب برابر با ۰/۹۹۹۵، ۰/۲۷۱ و ۰/۲۱۶ و برای تمامی داده‌های مدل UCS برابر با ۰/۹۹۹۵، ۰/۷۱۶ و ۰/۴۸۸ می‌باشند. نتایج تحلیل ANOVA نشان می‌دهد که در مدل توسعه داده شده برای پیش‌بینی مقدار نسبت باربری کالیفرنیا، پارامتر درصد آهک فعال شده توسط پوسته برنج، دارای بیشتر اهمیت در مقایسه با سایر پارامترها می‌باشد، به‌طوریکه حذف این پارامتر سبب بروز خطای بزرگی در نتایج می‌باشد، همچنین این تحلیل نشان می‌دهد که پارامتر حد خمیری دارای کمترین تأثیر است. نتایج تحلیل ANOVA برای مدل توسعه داده شده برای پیش‌بینی مقاومت فشاری محصورنشده نشان می‌دهد که اندرکنش بین درصد آهک فعال

## ۶- مراجع

- Al-Bared, M. A. M., Harahap, I. S. H., Marto, A., Abad, S. V. A. N. K., Mustaffa, Z., & Ali, M. O. A. (2019). Mechanical behaviour of waste powdered tiles and Portland cement treated soft clay. *Geomechanics and Engineering*, 19(1), 37.
- Al-Bared, M. A. M., Mustaffa, Z., Armaghani, D. J., Marto, A., Yunus, N. Z. M., & Hasanipahan, M. (2021). Application of hybrid intelligent systems in predicting the unconfined compressive strength of clay material mixed with recycled additive. *Transportation Geotechnics*, 30, 100627.
- Al-Hashemi, H. M., & Bukhary, A. H. (2016). Correlation between California bearing ratio (CBR) and angle of repose of granular soil. *Electron. J. Geotech. Eng*, 21(17), 5655-5660.
- Alhassan, M. (2008). Potentials of rice husk ash for soil stabilization.
- Al-Refeai, T., & Al-Suhaibani, A. (1997). Prediction of CBR using dynamic cone penetrometer. *Journal of King Saud University-Engineering Sciences*, 9(2), 191-203.
- Aziz, M., Saleem, M., & Irfan, M. (2015). Engineering behaviour of expansive soils treated with rice husk ash [J]. *Geomechanics and Engineering*, 8(2), 173-186.
- Baghbani, A., Soltani, A., Kiany, K., & Daghistani, F. (2023). Predicting the Strength Performance of Hydrated-Lime Activated Rice Husk Ash-Treated Soil Using Two Grey-Box Machine Learning Models. *Geotechnics*, 3(3), 894-920. doi.org/10.3390/geotechnics3030048
- Agarwal, K. B., & Ghanekar, K. D. (1970). Prediction of CBR from plasticity characteristics of soil. *Proceeding of 2nd South-East Asian Conference on Soil Engineering, Singapore*, 571-576.
- Ahmad, M., Al-Mansob, R. A., Ramli, A. B. Bin, Ahmad, F., & Khan, B. J. (2023). Unconfined compressive strength prediction of stabilized expansive clay soil using machine learning techniques. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 1-15.
- Ahmad, M., Al-Zubi, M. A., Kubińska-Jabcoń, E., Majdi, A., Al-Mansob, R. A., Sabri, M. M. S., Ali, E., Naji, J. A., Elnaggar, A. Y., & Zamin, B. (2023a). Predicting California bearing ratio of HARHA-treated expansive soils using Gaussian process regression. *Scientific Reports*, 13(1), 13593. https://doi.org/10.1038/s41598-023-40903-1
- Ahmad, M., Al-Zubi, M. A., Kubińska-Jabcoń, E., Majdi, A., Al-Mansob, R. A., Sabri, M. M. S., Ali, E., Naji, J. A., Elnaggar, A. Y., & Zamin, B. (2023b). Predicting California bearing ratio of HARHA-treated expansive soils using Gaussian process regression. *Scientific Reports*, 13(1), 13593.
- Akbar, A., & Farooq, K. (2002). Expansive soils IN Pakistan-case histories. *Journal of Engineering and Applied Sciences*, 21(1), 119-129.
- Alawi, M., & Rajab, M. (2013). Prediction of California bearing ratio of subbase layer using multiple linear regression models. *Road Materials and Pavement Design*, 14(1), 211-219.

- Ghanizadeh, A. R., & Rahrovan, M. (2019). Modeling of unconfined compressive strength of soil-RAP blend stabilized with Portland cement using multivariate adaptive regression spline. *Frontiers of Structural and Civil Engineering*, 13, 787–799.
- Ghanizadeh, A. R., Rahrovan, M., & Heydarabadi, N. (2021). Modeling of Unconfined Compressive Strength (UCS) of Full-Depth Reclaimed Base Materials Stabilized with Portland Cement Using Evolutionary Polynomial Regression. *Journal of Civil and Environmental Engineering*, 51(105), 171–184.
- Ghanizadeh, A. R., & Safi Jahanshahi, F. (2023). A Case Study on Potential Use of Stabilized Mine Overburden Wastes as Pavement Materials. *Transportation Infrastructure Geotechnology*, 1–35.
- Ghanizadeh, A. R., Safi Jahanshahi, F., & Naseralavi, S. S. (2023). Intelligent modelling of unconfined compressive strength of cement stabilised iron ore tailings: a case study of Golgohar mine. *European Journal of Environmental and Civil Engineering*, 1–29.
- Hastie, T., Friedman, J., & Tibshirani, R. (2001). *The Elements of Statistical Learning*. Springer New York. doi.org/10.1007/978-0-387-21606-5
- Iftikhar, B., Alih, S. C., Vafaei, M., Javed, M. F., Rehman, M. F., Abdullaev, S. S., Tamam, N., Khan, M. I., & Hassan, A. M. (2023). Predicting compressive strength of eco-friendly plastic sand paver blocks using gene expression and artificial intelligence programming. *Scientific Reports*, 13(1), 12149. doi.org/10.1038/s41598-023-39349-2
- Ijaz, N., Dai, F., & ur Rehman, Z. (2020). Paper and wood industry waste as a sustainable solution for environmental vulnerabilities of expansive soil: A novel approach. *Journal of Environmental Management*, 262, 110285.
- Jalal, F.-E.-, Xu, Y., Jamhiri, B., & Memon, S. A. (2020). On the recent trends in expansive soil stabilization using calcium-based stabilizer materials (CSMs): a comprehensive review. *Advances in Materials Science and Engineering*, 2020, 1–23.
- Javdanian, H., & Lee, S. (2019). Evaluating unconfined compressive strength of cohesive soils stabilized with geopolymer: a computational intelligence approach. *Engineering with Computers*, 35(1), 191–199. doi.org/10.1007/s00366-018-0592-8
- Jekabsons, G. (2011). ARESLab: Adaptive regression splines toolbox for Matlab/Octave. URL: [Http://www.Cs.Rtu.Lv/Jekabsons](http://www.Cs.Rtu.Lv/Jekabsons).
- Behnood, A. (2018). Soil and clay stabilization with calcium-and non-calcium-based additives: A state-of-the-art review of challenges, approaches and techniques. *Transportation Geotechnics*, 17, 14–32.
- Bell, F. G. (1996). Lime stabilization of clay minerals and soils. *Engineering Geology*, 42(4), 223–237.
- Bi, J., & Chian, S. C. (2021). Estimation of Strength Development of Cement-Stabilized Clayey Soils with Activity Number, Liquid Limit, and Apparent Void Ratio. *International Journal of Geomechanics*, 21(8). doi.org/10.1061/(ASCE)GM.1943-5622.0002080
- Black, W. P. M. (1962). A method of estimating the California bearing ratio of cohesive soils from plasticity data. *Geotechnique*, 12(4), 271–282.
- Christopher, I., & Chimobi, N. D. (2019). Emerging trends in expansive soil stabilisation: a review. *Journal of Rock Mechanics and Geotechnical Engineering*, 11(2), 423–440.
- Das, S. K., Samui, P., & Sabat, A. K. (2011). Application of Artificial Intelligence to Maximum Dry Density and Unconfined Compressive Strength of Cement Stabilized Soil. *Geotechnical and Geological Engineering*, 29(3), 329–342. doi.org/10.1007/s10706-010-9379-4
- Elbadry, H. (2017). Simplified reliable prediction method for determining the volume change of expansive soils based on simply physical tests. *HBRC Journal*, 13(3), 353–360.
- Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *The Annals of Statistics*, 19(1). doi.org/10.1214/aos/1176347963
- Ghanizadeh, A. R., Bayat, M., Tavana Amlashi, A., & Rahrovan, M. (2019). Prediction of unconfined compressive strength of clay subgrade soil stabilized with Portland cement and lime using Group Method of Data Handling (GMDH). *Journal of Transportation Infrastructure Engineering*, 5(1), 77–96.
- Ghanizadeh, A. R., Heidarabadi, N., Bayat, M., & Khalifeh, V. (2022). Modeling of unconfined compressive strength and Young's modulus of lime and cement stabilized clayey subgrade soil using Evolutionary Polynomial Regression (EPR). *International Journal of Mining and Geo-Engineering*, 56(3), 257–269.
- Ghanizadeh, A. R., & Naseralavi, S. S. (2023). Intelligent Prediction of Unconfined Compressive Strength and Young's modulus of Lean Clay Stabilized with Iron Ore Mine Tailings and Hydrated Lime using Gaussian Process Regression. *Journal of Soft Computing in Civil Engineering*, 7(4), 1–25. doi.org/10.22115/scce.2023.370814.1573

- Applied Computational Intelligence and Soft Computing*, 2021, 1–17.
- Onyelowe, K. C., Jalal, F. E., Onyia, M. E., Onuoha, I. C., & Alaneme, G. U. (2021b). Application of Gene Expression Programming to Evaluate Strength Characteristics of Hydrated-Lime-Activated Rice Husk Ash-Treated Expansive Soil. *Applied Computational Intelligence and Soft Computing*, 2021, 1–17.  
**doi.org/10.1155/2021/6686347**
- Pal, K., & Pal, K. (2019). Correlation between cbr values and plasticity index of soil for Kolkata region. *Vol. 6*, 6.
- Patel, R. S., & Desai, M. D. (2010). CBR predicted by index properties for alluvial soils of South Gujarat. *Proceedings of the Indian Geotechnical Conference, Mumbai*, 79–82.
- Pham, V.-N., Do, H.-D., Oh, E., & Ong, D. E. L. (2021a). Prediction of unconfined compressive strength of cement-stabilized sandy soil in Vietnam using artificial neural networks (ANNs) model. *International Journal of Geotechnical Engineering*, 15(9), 1177–1187.
- Pham, V.-N., Do, H.-D., Oh, E., & Ong, D. E. L. (2021b). Prediction of unconfined compressive strength of cement-stabilized sandy soil in Vietnam using artificial neural networks (ANNs) model. *International Journal of Geotechnical Engineering*, 15(9), 1177–1187.  
**doi.org/10.1080/19386362.2020.1862539**
- Phanikumar, B. R., & Nagaraju, T. V. (2018). Effect of fly ash and rice husk ash on index and engineering properties of expansive clays. *Geotechnical and Geological Engineering*, 36(6), 3425–3436.
- Puppala, A., Hoyos, L., Viyanant, C., & Musenda, C. (2001). Fiber and fly ash stabilization methods to treat soft expansive soils. In *Soft ground Technology*, 136–145.
- Quan, V., & Do, H. Q. (2021). Prediction of California bearing ratio (CBR) of stabilized expansive soils with agricultural and industrial waste using light gradient boosting machine. *Journal of Science and Transport Technology*, 1–9.
- Rajakumar, C. (2021). Experimental study and neural network modelling of expansive sub grade stabilized with industrial waste by-products and geogrid. *Materials Today: Proceedings*, 46, 131–137.
- Salehi, M., Bayat, M., Saadat, M., & Nasri, M. (2023). Prediction of unconfined compressive strength and California bearing capacity of cement- or lime-pozzolan-stabilised soil admixed with crushed stone waste. *Geomechanics and Geoengineering*, 18(4), 272–283.
- Kumar, A., & Gupta, D. (2016). Behavior of cement-stabilized fiber-reinforced pond ash, rice husk ash–soil mixtures. *Geotextiles and Geomembranes*, 44(3), 466–474.
- Kumar, A., Sinha, S., Saurav, S., & Chauhan, V. B. (2023). Prediction of unconfined compressive strength of cement–fly ash stabilized soil using support vector machines. *Asian Journal of Civil Engineering*, 1–13.
- Li, M., Wei, Y., Liu, Y., & Jin, J. (2021). A framework for interpreting lateral swelling pressure in unsaturated expansive soils. *Advances in Civil Engineering*, 1–15.
- Liu, Y., Chang, C.-W., Namdar, A., She, Y., Lin, C.-H., Yuan, X., & Yang, Q. (2019). Stabilization of expansive soil using cementing material from rice husk ash and calcium carbide residue. *Construction and Building Materials*, 221, 1–11.
- Liu, Y., Su, Y., Namdar, A., Zhou, G., She, Y., & Yang, Q. (2019). Utilization of cementitious material from residual rice husk ash and lime in stabilization of expansive soil. *Advances in Civil Engineering*.
- Mahedi, M., Cetin, B., & White, D. J. (2020). Cement, lime, and fly ashes in stabilizing expansive soils: Performance evaluation and comparison. *Journal of Materials in Civil Engineering*, 32(7), 04020177.
- Ma, J., Su, Y., Liu, Y., & Tao, X. (2020). Strength and microfabric of expansive soil improved with rice husk ash and lime. *Advances in Civil Engineering*, 1–8.
- Milborrow, S., Hastie, T., Tibshirani, R., Miller, A., & Lumley, T. (2017). earth: Multivariate adaptive regression splines. *R Package Version*, 5(2).
- Negawo, W. J., Di Emidio, G., Bezuijen, A., Verastegui Flores, R. D., & François, B. (2019). Lime-stabilisation of high plasticity swelling clay from Ethiopia. *European Journal of Environmental and Civil Engineering*, 23(4), 504–514.
- Onyelowe, K. C., Iqbal, M., Jalal, F. E., Onyia, M. E., & Onuoha, I. C. (2021). Application of 3-algorithm ANN programming to predict the strength performance of hydrated-lime activated rice husk ash treated soil. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 4(4), 259–274.  
**doi.org/10.1007/s41939-021-00093-7**
- Onyelowe, K. C., Jalal, F. E., Onyia, M. E., Onuoha, I. C., & Alaneme, G. U. (2021a). Application of gene expression programming to evaluate strength characteristics of hydrated-lime-activated rice husk ash-treated expansive soil.

- of soils stabilized using artificial neural networks and support vector machines. *Frontiers of Structural and Civil Engineering*, 15, 520–536.
- Talukdar, D. K. (2014). A study of correlation between California Bearing Ratio (CBR) value with other properties of soil. *International Journal of Emerging Technology and Advanced Engineering*, 4(1), 559–562.
- Taskiran, Tja. (2010). Prediction of California bearing ratio (CBR) of fine grained soils by AI methods. *Advances in Engineering Software*, 41(6), 886–892.
- Teijón-López-Zuazo, E., Vega-Zamanillo, Á., Calzada-Pérez, M. Á., & Juli-Gándara, L. (2020). Estimation of unconfined compressive strength of cement-stabilized jabra as material upgrade on highway construction. *Materiales de Construcción*, 70(338), 218. [doi.org/10.3989/mc.2020.09019](https://doi.org/10.3989/mc.2020.09019)
- Tran, V. Q. (2022a). Hybrid gradient boosting with meta-heuristic algorithms prediction of unconfined compressive strength of stabilized soil based on initial soil properties, mix design and effective compaction. *Journal of Cleaner Production*, 355, 131683.
- Tran, V. Q. (2022b). Hybrid gradient boosting with meta-heuristic algorithms prediction of unconfined compressive strength of stabilized soil based on initial soil properties, mix design and effective compaction. *Journal of Cleaner Production*, 355, 131683. [doi.org/10.1016/j.jclepro.2022.131683](https://doi.org/10.1016/j.jclepro.2022.131683)
- Yildirim, B., & Gunaydin, Ojes. (2011). Estimation of California bearing ratio by using soft computing systems. *Expert Systems with Applications*, 38(5), 6381–6391.
- Seco, A., Ramirez, F., Miqueleiz, L., & García, B. (2011). Stabilization of expansive soils for use in construction. *Applied Clay Science*, 51(3), 348–352.
- Shahrouzi, M., & Kaveh, A. (2022). An efficient derivative-free optimization algorithm inspired by avian life-saving manoeuvres. *Journal of Computational Science*, 57, 101483.
- Sharma, L. K., & Singh, T. N. (2018). Regression-based models for the prediction of unconfined compressive strength of artificially structured soil. *Engineering with Computers*, 34(1), 175–186. [doi.org/10.1007/s00366-017-0528-8](https://doi.org/10.1007/s00366-017-0528-8)
- Sharma, L. K., Sirdesai, N. N., Sharma, K. M., & Singh, T. N. (2018). Experimental study to examine the independent roles of lime and cement on the stabilization of a mountain soil: A comparative study. *Applied Clay Science*, 152, 183–195.
- Soleimani, S., Rajaei, S., Jiao, P., Sabz, A., & Soheilinia, S. (2018). New prediction models for unconfined compressive strength of geopolymer stabilized soil using multi-gen genetic programming. *Measurement*, 113, 99–107. [doi.org/10.1016/j.measurement.2017.08.043](https://doi.org/10.1016/j.measurement.2017.08.043)
- Sridharan, A., & Gurtug, Y. (2004). Swelling behaviour of compacted fine-grained soils. *Engineering Geology*, 72(1–2), 9–18.
- Suman, S., Mahamaya, M., & Das, S. K. (2016). Prediction of Maximum Dry Density and Unconfined Compressive Strength of Cement Stabilised Soil Using Artificial Intelligence Techniques. *International Journal of Geosynthetics and Ground Engineering*, 2(2), 11. <https://doi.org/10.1007/s40891-016-0051-9>
- Tabarsa, A., Latifi, N., Osouli, A., & Bagheri, Y. (2021). Unconfined compressive strength prediction

# Presenting a Model for Predicting CBR and UCS of Expensive Soil Stabilized with Hydrated Lime Activated with Rice Husk Ash Using the Hybrid MARS-EBS Method

*Ali Reza Ghanizadeh, Associate Professor, Department of Civil Engineering,  
Sirjan University of Technology, Sirjan, Iran.*

*Farzad SafiJahanshahi, M.Sc., Grad., Department of Civil Engineering,  
Sirjan University of Technology, Sirjan. Iran.*

*Arash Ziyaie, M.Sc., Grad., Department of Civil Engineering,  
Sirjan University of Technology, Sirjan. Iran.*

*E-mail: ghanizadeh@sirjantech.ac.ir*

Received: November 2024- Accepted: February 2025

## **ABSTRACT**

California bearing ratio (CBR) is one of the most important design parameters of flexible pavements and unconfined compressive strength (UCS) of soil is one of the important design and engineering parameter. Determining the value of these parameters through testing is time-consuming and expensive, and therefore obtaining them through alternative and reliable solutions is required. In this study, the Multivariate adaptive regression splines (MARS) is used to predict the value of CBR and UCS of expensive soil stabilized with hydrated lime activated with rice husk ash. The database used in this research includes 121 data, 70% of which are selected as training data and 30% as test data. Four input parameters of percentage of hydrated lime activated with rice husk ash, plastic limit, plastic index and maximum dry density are used in the prediction model of CBR. Also, for the UCS prediction model, five parameters of HARHA, PL, PI, OMC and MDD have been used as input parameters. In this study, fewer input variables were used to model these two parameters compared to the models developed by researchers in the past. The value of  $R^2$  for CBR model is equal to 0.9995 and 0.9994 and for UCS model is equal to 0.9997 and 0.999, respectively, based on training and testing data, which indicates the appropriate accuracy of the developed models. Also, the results of ANOVA test showed that the percentage of HARHA has the highest degree of importance for predicting CBR and UCS.

**Keywords:** MARS, Unconfined Compressive Strength, CBR, Lime, Husk Ash