

مقایسه الگوریتم‌های مختلف یادگیری ماشین برای تخمین مقاومت فشاری تک‌محوری خاک رس تثبیت‌شده با سیمان و خاکستر آتشفشانی

حدیجه محمودی^{۱*} و هاجر مومنی^۲

^۱ استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه اردکان، اردکان، ایران

^۲ استادیار گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه اردکان، اردکان، ایران

^۳ پژوهشکده آب، انرژی و محیط زیست، دانشگاه اردکان، اردکان، ایران

(دریافت: ۱۴۰۲/۰۴/۳۱، پذیرش: ۱۴۰۲/۰۸/۰۱)

چکیده

یکی از چالش‌های ساخت‌وساز روی خاک‌های رسی ضعیف، مقاومت فشاری کم و نشست‌پذیری زیاد خاک است؛ از این رو مهندسان ژئوتکنیک همواره سعی در بهبود مشخصات این نوع خاک با استفاده از روش‌های مختلف تثبیت خاک دارند. برآورد کارایی روش‌های مختلف تثبیت خاک، مستلزم انجام دادن آزمایش‌های متعدد است که فرایندی زمان‌بر و هزینه‌بر است. در این مقاله به بررسی روش‌های مختلف یادگیری ماشین از جمله رگرسیون خطی، شبکه عصبی پرسپترون چندلایه (MLP)، K نزدیک‌ترین همسایه، تخمین گر ماشین بردار پشتیبان (SVR)، درخت تصمیم، جنگل تصادفی و تقویت گرادیان در تخمین میزان مقاومت فشاری تک‌محوری خاک پرداخته می‌شود. برای این منظور از نتایج آزمایش نمونه‌های خاک رس تثبیت‌شده با استفاده از دو نوع پوزولان در شرایط عمل‌آوری مختلف استفاده شد. متغیرهای مؤثر ورودی الگوریتم‌های یادگیری ماشین شامل زمان و شرایط عمل‌آوری، ملاریته فعال‌ساز قلیایی، نسبت وزنی پوزولان مورد استفاده در خاک رس، نوع پوزولان و نسبت وزنی فعال‌ساز به میزان رطوبت بهینه هستند. جهت بهینه‌سازی و تسریع عملکرد الگوریتم‌ها، تنظیم ابرپارامترها با روش جستجوی مشبک انجام شد. علاوه بر این به منظور کاهش تغییرپذیری نتایج هنگام تقسیم‌بندی داده‌ها به مجموعه آموزشی-آزمایشی از روش اعتبارسنجی متقابل ده‌تایی استفاده و عملکرد الگوریتم‌ها با سه معیار متوسط مربعات خطا، ضریب تبیین و میانگین قدرمطلق خطا بررسی شد. با توجه به نتایج بسیار نزدیک به کارگیری روش‌های SVR و MLP، این دو روش برای برآورد مقاومت تک‌محوری خاک مورد مطالعه پیشنهاد می‌شوند. همچنین تحلیل حساسیت مدل‌ها بیانگر این است که متغیرهای ورودی پوزولان، ملاریته و زمان عمل‌آوری به ترتیب بیشترین درجه اهمیت را در پیش‌بینی مقاومت فشاری دارند.

کلمه‌های کلیدی: خاکستر آتشفشانی، خاک رس، سیمان، مقاومت فشاری تک‌محوری، یادگیری ماشین

۱ مقدمه

یکی از چالش‌های مهندسان ژئوتکنیک از دیرباز، ساخت‌وساز روی خاک‌های رسی مسئله‌دار است. این نوع خاک‌ها معمولاً مستعد نشست زیاد، ظرفیت باربری کم و گاهی مشکلاتی از قبیل واگرایی، رمبندگی (collapsibility)، تورم (swelling) و انقباض زیاد هستند. به‌منظور رفع این مشکلات، از پوزولان‌های مختلف از جمله آهک، سیمان، خاکستر بادی، سرپاره کوره آهن‌گدازی و... برای تثبیت خاک استفاده می‌شود. انتخاب تثبیت‌کننده به عواملی مانند نوع خاک، کیفیت دانه‌بندی و عناصر شیمیایی موجود در خاک بستگی دارد (بهنود، ۲۰۱۸). پژوهش‌های اخیر نشان داده‌اند به‌کارگیری فعال‌سازها نیز باعث تسریع و بهبود فرایند تثبیت خاک می‌شود. یی و همکاران (۲۰۱۵) گزارش کردند کلسیم موجود در خاکستر بادی در ترکیب با سیلیکات و آلومینات خاک رس سبب تشکیل ترکیبات سیمانی و در نتیجه، تثبیت خاک می‌شود. سوکپراسرت و همکاران (۲۰۲۱) به بررسی خصوصیات مکانیکی خاک رس سیلتی تثبیت‌شده با خاکستر آتشفشانی و سرپاره کوره آهن پرداختند. آنها تأثیر جایگزینی خاکستر با سرپاره، غلظت فعال‌ساز قلیایی و زمان عمل‌آوری را مطالعه کردند. نتایج آن پژوهش نشان داد استفاده از فعال‌ساز هیدروکسید سدیم موجب آزاد شدن سیلیکات‌ها و آلومینات‌های خاکستر آتشفشانی و تشکیل ژل سیمانی بیشتر و به‌تبع آن، افزایش بازدهی فرایند تثبیت خاک می‌شود. میاو و همکاران (۲۰۱۷) تثبیت خاک رس با خاکستر آتشفشانی را با استفاده از فعال‌سازهای هیدروکسید پتاسیم و کلسیم بررسی کردند. ایشان گزارش کردند طی فرایند تثبیت، درصد تورم و شاخص پلاستیسیته خاک کاهش و مقاومت فشاری تک‌محوری (UCS) خاک افزایش می‌یابد. گاهی نیز هنگام تثبیت خاک با آهک، از خاکستر آتشفشانی جهت اثربخشی

بیشتر استفاده می‌شود (سکو و همکاران، ۲۰۱۱). از ترکیب سیمان و خاکستر آتشفشانی برای تثبیت خاک نیز استفاده می‌شود. کانیراج و هاواناگی (۱۹۹۹) مقاومت فشاری نمونه‌های خاک رس تثبیت‌شده با سیمان و خاکستر آتشفشانی را در درصد رطوبت بهینه محاسبه و مدلی برای تخمین آن معرفی کردند. میورا و همکاران (۲۰۰۱) دریافتند که نسبت آب به سیمان پارامتری مهم برای خاک رس تثبیت‌شده با سیمان است. ایشان نیز بر اساس درصد آب به سیمان مدلی را برای پیش‌بینی UCS خاک تثبیت‌شده با سیمان پیشنهاد دادند و افزایش ثابت خاک را با یک سری آزمایش بررسی کردند.

برآورد میزان کارایی انواع تثبیت‌کننده‌ها و ارزیابی تأثیر شرایط عمل‌آوری از جمله دما، رطوبت، سن نمونه و افزودن فعال‌سازها، نیازمند آزمایش‌های متعدد، صرف هزینه و زمان زیاد است. با پیشرفت هوش مصنوعی در سال‌های اخیر، به‌منظور تخمین بسیاری از خصوصیات مکانیکی مصالح مختلف مانند خاک و بتن از روش‌های مختلف یادگیری ماشین استفاده می‌شود. داس و همکاران (۲۰۱۱) با در نظر گرفتن پارامترهای درصد شن، ماسه و رس، حد روانی، درصد رطوبت و میزان سیمان مصرفی، UCS و حداکثر وزن مخصوص خشک را با استفاده از الگوریتم‌های شبکه عصبی بازگشتی (BP-ANN) و تخمین‌گر ماشین بردار پشتیبان (SVR) تخمین زدند. مطالعه آنها نشان داد SVR در برآورد پارامتر هدف دقت بیشتری دارد. قربانی و حسن‌زاده (۲۰۱۸) از روش‌های شبکه عصبی مصنوعی (ANN) و رگرسیون چندجمله‌ای برای پیش‌بینی ظرفیت باربری کالیفرنیا (CBR) و UCS خاک ماسه سیلتی سولفاته تثبیت‌شده با آهک و میکروسیلیس استفاده کردند. پارامترهای ورودی برای تخمین CBR خاک در آن مطالعه، شامل شرایط و مدت زمان عمل‌آوری، درصد میکروسیلیس و آهک بود. برای تخمین UCS، علاوه بر پارامترهای ذکر شده، CBR نیز

فازی تطبیقی (ANFIS) تخمین زدند. پارامترهای مستقل در آن مطالعه شامل درصد سیمان، درصد رطوبت، تعداد روزهای عمل‌آوری و درصد ضایعات سنگ آهن بود. طبق نتایج مطالعه ایشان، در بین روش‌های مورد استفاده، ANFIS بهترین عملکرد را در برآورد پارامترهای خروجی مدل دارد. همچنین نتایج تحلیل حساسیت بیانگر این است که درصد سیمان، بیشترین و درصد ضایعات سنگ آهن، کمترین اثر را در تخمین پارامترهای هدف دارد. غنی‌زاده و رهروان (۲۰۱۹)، با روش رگرسیون چندخطی تطبیقی چندمتغیره، UCS مصالح اساس بازیافت‌شده را تخمین زدند. مصالح مورد استفاده، ترکیبی از خاک درشت‌دانه و خرده‌آسفالت بود که با سیمان تثبیت شده بود. در مدل آنها درصد مصالح درشت‌دانه و خرده‌آسفالت، میزان سیمان، درصد رطوبت بهینه، درصد عبوری از الک ۲۰۰ و تعداد روزهای عمل‌آوری، پارامترهای ورودی بودند. نتایج نشان دادند این روش، مقاومت مصالح مورد نظر را با دقت بسیار زیادی برآورد می‌کند. همچنین غنی‌زاده و همکاران (۲۰۲۱) برای مصالح و پارامترهای ورودی ذکرشده در پژوهش غنی‌زاده و رهروان (۲۰۱۹)، یک مدل رگرسیون چندجمله‌ای تکاملی را جهت برآورد UCS مصالح اساس بازیافت‌شده توسعه دادند. نتایج تحلیل حساسیت مدل‌ها نشان داد درصد سیمان تأثیرگذارترین پارامتر بر UCS مصالح آزمایش‌شده است. نتایج مطالعه پارامتری نیز بیانگر این است که درصد بهینه خرده‌آسفالت ۲۰٪ است. همچنین درصد رطوبت و زمان عمل‌آوری به ترتیب رابطه معکوس و مستقیم بر UCS مصالح دارند. غنی‌زاده و همکاران (۲۰۲۲) UCS و مدول کشسانی (E) خاک رس تثبیت‌شده با آهک و سیمان را با استفاده از رگرسیون چندجمله‌ای تکاملی تخمین زدند. آنها برای تخمین UCS از متغیرهای درصد پوزولان (آهک/سیمان)، میزان رطوبت و زمان عمل‌آوری و برای تخمین E، از متغیرهای

به‌عنوان پارامتر ورودی منظور شد. ایشان گزارش کردند BP-ANN عملکرد بهتری نسبت به روش رگرسیون دارد. موزامدر و همکاران (۲۰۱۷) از روش SVR برای برآورد UCS خاک رسی تثبیت‌شده با سرباره دانه‌ای کوره ذوب‌آهن (GGBS) استفاده کردند. پارامترهای ورودی مدل آنها شامل حد روانی، شاخص خمیری، درصد GGBS، مولاریته فعال‌ساز قلیایی، نسبت اتمی (atomic ratio) سدیم به آلومینیوم و نسبت اتمی سیلیس به آلومینیوم بود. ایشان گزارش کردند الگوریتم SVR برای برآورد UCS خاک تثبیت‌شده با GGBS کارآمد است. گولو (۲۰۱۴) با استفاده از الگوریتم ژنتیک و رگرسیون غیرخطی و لحاظ کردن درصد خاکستر آتشفشانی، وزن مخصوص خشک، چگالی نسبی و ظرفیت جذب انرژی به‌عنوان پارامترهای ورودی، مدول یانگ و UCS خاک تثبیت‌شده را تخمین زد. غنی‌زاده و همکاران (۲۰۱۹) با استفاده از روش گروهی بررسی داده‌ها (GMDH)، مدل‌هایی را برای تخمین UCS بستر رسی تثبیت‌شده با سیمان و آهک توسعه دادند. برای این منظور ایشان صد و پنجاه نمونه تثبیت‌شده با درصدهای مختلف آهک، سیمان و رطوبت را در زمان‌های عمل‌آوری مختلف برای توسعه مدل انتخاب کردند. نتایج تحلیل حساسیت مدل‌ها بیانگر این بود که در حالت تثبیت با سیمان، درصد سیمان و در حالت تثبیت با آهک، درصد رطوبت مؤثرترین پارامترها در تخمین UCS خاک مورد مطالعه هستند. سلیمانی و همکاران (۲۰۱۸) گزارش کردند الگوریتم ژنتیک چندژنی در پیش‌بینی UCS خاک رس تثبیت‌شده دقت زیادی دارد. پارامترهای ورودی مدل آنها شامل درصد سرباره، درصد خاکستر، حد روانی، حد خمیری، شاخص پلاستیسیته و غلظت مولار بود. حیدری دزفولی و غنی‌زاده (۲۰۲۰) مقاومت فشاری و کششی خاک رسی تثبیت‌شده با سیمان و ضایعات سنگ آهن را با استفاده از دو روش مختلف ANN و همچنین روش سامانه استنتاج عصبی-

پشتیبان (SVR)، درخت تصمیم (DT)، جنگل تصادفی (RF) و تقویت گرادیان (GBM) در پیش‌بینی UCS خاک تثبیت‌شده استفاده شده است. در ادامه، ابتدا خصوصیات مصالح و داده‌های مورد استفاده تشریح می‌شود. سپس پیشینه‌ای درباره نحوه عملکرد الگوریتم‌ها ارائه و نحوه آماده‌سازی و تقسیم داده‌ها به داده‌های آموزشی و آزمایشی و تنظیم ابرپارامترهای الگوریتم‌ها توضیح داده خواهد شد. کارایی مدل‌ها با استفاده از معیارهای متوسط مربعات خطا (MSE)، ضریب تبیین (R^2) و میانگین قدرمطلق خطا (MAPE) بررسی می‌شود. با تحلیل حساسیت، درجه اهمیت هریک از متغیرهای ورودی در مقاومت فشاری خاک و با تحلیل پارامتریک، تأثیر هریک از پارامترها بررسی خواهد شد.

۲ خصوصیات مصالح و جمع‌آوری داده‌ها

داده‌های استفاده‌شده در این پژوهش، مربوط به یک نوع خاک رس با پلاستیسیته کم (CL) است که ویژگی‌های آن از پژوهش قدیر و رنجبر (۲۰۱۸) استخراج شده است. با توجه به اینکه تثبیت خاک با سیمان، آلودگی زیست‌محیطی و هزینه گزافی دارد، در پژوهش قدیر و رنجبر (۲۰۱۸) سعی شده است ترکیب بهینه‌ای از خاکستر آتشفشانی و فعال‌ساز قلیایی جایگزین سیمان شود. خصوصیات خاک در جدول ۱ بیان شده است.

درصد پوزولان (آهک/سیمان)، میزان رطوبت و UCS استفاده کردند. بر اساس آن پژوهش، برای خاک تثبیت‌شده با سیمان و آهک، درصد سیمان و میزان رطوبت به ترتیب مؤثرترین پارامترها در تخمین UCS معرفی شدند و میزان رطوبت و UCS به ترتیب مؤثرترین پارامترها در خاک تثبیت‌شده با سیمان و آهک برای تخمین E بودند. غنی‌زاده و ناصرعلوی (۲۰۲۳) و UCS و مدول کشسانی خاک رس تثبیت‌شده با ضایعات سنگ آهن و آهک را با استفاده از روش رگرسیون گوسی برآورد کردند. پارامترهای ورودی مدل شامل درصد رطوبت، درصد ضایعات سنگ آهن، درصد آهک هیدراته و زمان عمل‌آوری بود. نتایج آن پژوهش بیانگر این است که در تخمین UCS به ترتیب درصد رطوبت، مدت زمان عمل‌آوری، درصد آهک و درصد ضایعات سنگ آهن مؤثرترین پارامترها هستند. همچنین برای تخمین E، به ترتیب درصد رطوبت، درصد آهک، درصد ضایعات سنگ آهن و زمان عمل‌آوری مؤثرترین پارامترها هستند.

در این مقاله به مقایسه کارایی و امکان‌پذیری استفاده از روش‌های مختلف یادگیری ماشین برای تخمین UCS خاک تثبیت‌شده با سیمان و خاکستر آتشفشانی پرداخته شده است. برای این منظور از الگوریتم‌های رگرسیون خطی (LR)، شبکه عصبی پرسپترون چندلایه (MLP)، K، نزدیک‌ترین همسایه (KNN)، تخمین‌گر ماشین بردار

جدول ۱. مشخصات خاک رس استفاده‌شده (قدیر و رنجبر، ۲۰۱۸).

رس (%)	لای (%)	ماسه (%)	شن (%)	LL (%)	PL (%)	PI (%)	γ_{max} (kN/m ³)	ω_{opt} (%)
۲۳	۳۳	۱۹	۵	۳۱	۲۲	۹	۱۷/۴	۱۴

سیمان پرتلند معمولی و تعدادی دیگر با خاکستر آتشفشانی تثبیت شده‌اند. آزمایش‌ها در سه دسته مختلف به‌گونه‌ای طراحی شدند که تأثیر نوع و درصد

داده‌ها شامل نتایج آزمایش UCS روی نمونه‌های خاک رس تثبیت‌شده هستند. به‌منظور بررسی تأثیر نوع تثبیت‌کننده یا پوزولان، تعدادی از نمونه‌های خاک با

در دسته سوم نیز تأثیر نسبت فعال‌ساز به رطوبت بهینه (نسبت‌های ۱، ۱/۲ و ۱/۴) برای خاک تثبیت‌شده با خاکستر آتشفشانی بررسی شده است. برای دسته‌های دوم و سوم، آزمایش‌ها در زمان‌های عمل‌آوری ۱ و ۲۸ روز در شرایط عمل‌آوری OC و DC انجام شدند که به دوازده آزمایش برای هر دسته منجر شده است. در مجموع برای هر سه دسته هفتاد و دو آزمایش انجام گرفته است (قدیر و رنجبر، ۲۰۱۸).

اطلاعات آماری مجموعه داده‌ها در جدول ۳ و نسبت همبستگی پارامترهای ورودی با یکدیگر و با UCS خاک در جدول ۴ بیان شده است. با توجه به جدول ۴، زمان عمل‌آوری و نسبت فعال‌ساز به رطوبت بهینه، بیشترین مولاریته فعال‌ساز، کمترین همبستگی را با UCS خاک دارند.

تثبیت‌کننده، زمان عمل‌آوری، میزان و مولاریته فعال‌ساز قلیایی و شرایط عمل‌آوری بررسی شود. همان‌گونه که در جدول ۲ مشاهده می‌شود، هدف در دسته اول، بررسی تأثیر نوع تثبیت‌کننده و درصد وزنی آنها (صفر، ۵، ۱۰ و ۱۵ درصد) در زمان‌های عمل‌آوری ۱، ۷ و ۲۸ روز است. برای بررسی شرایط عمل‌آوری، نمونه‌ها در دو محیط مختلف عمل‌آوری شده‌اند. برای عمل‌آوری نمونه‌ها در شرایط درصد رطوبت بهینه (OC)، رطوبت و دما به ترتیب حدود ۸۰٪ و ۲۵٪ و در شرایط خشک (DC)، رطوبت و دما به ترتیب حدود ۱۵٪ و ۴۰٪ است؛ بنابراین با توجه به اینکه از سیمان و خاکستر آتشفشانی به صورت مستقل جهت تثبیت خاک استفاده شده، برای دسته اول چهل و هشت آزمایش انجام شده است. در دسته دوم، تأثیر ملاریته فعال‌ساز قلیایی (مقادیر ۴، ۸ و ۱۲) بر مقاومت خاک تثبیت‌شده با خاکستر آتشفشانی مطالعه شده است.

جدول ۲. خلاصه طراحی آزمایش‌ها برای ارزیابی تأثیر تثبیت خاک با خاکستر آتشفشانی و سیمان پرتلند (برگرفته از قدیر و رنجبر، ۲۰۱۸).

نوع تثبیت‌کننده یا پوزولان	درصد تثبیت‌کننده	نوع فعال‌ساز	ملاریته فعال‌ساز [M]	زمان عمل‌آوری (روز)	شرایط عمل‌آوری	میزان فعال‌ساز	میزان رطوبت بهینه
دسته ۱	صفر، ۵، ۱۰، ۱۵	NaOH	۸	۱، ۷، ۲۸	OC ^۱ ، DC ^۱	۱	۱
سیمان	صفر، ۵، ۱۰، ۱۵	H ₂ O	-	۱، ۷، ۲۸	OC، DC	۱	۱
دسته ۲	۱۰	NaOH	۴، ۸، ۱۲	۱	OC، DC	۱	۱
دسته ۳	۱۵	NaOH	۸	۱	OC، DC	۱/۴، ۱/۲، ۱	۱

^۱ دما ۴۰° و رطوبت نسبی ۱۵٪

^۲ دما ۲۵° و رطوبت نسبی ۸۰٪

جدول ۳. مشخصات آماری مجموعه داده‌ها.

ویژگی	متغیر	میانگین	انحراف معیار	کمینه	بیشینه
درصد پوزولان	ورودی	۹/۲	۵/۴	صفر	۱۵
زمان عمل‌آوری (روز)	ورودی	۱۲/۸	۱۲/۴	۱	۲۸
مولاریته هیدروکسید سدیم	ورودی	۴/۷	۴/۲	صفر	۱۲
فعال‌ساز	ورودی	۱/۰۳	۰/۱	۱	۱/۴
رطوبت بهینه	خروجی	۲۷۶۰	۲۰۹۴	۱۶۶	۱۱۵۷۱
UCS (kPa)					

جدول ۴. مقادیر ضریب همبستگی پارامترهای ورودی با UCS خاک.

ویژگی	درصد پوزولان	زمان عمل‌آوری	مولارپته هیدروکسید سدیم	فعال‌ساز رطوبت بهینه	UCS (kPa)
درصد پوزولان	۱				
زمان عمل‌آوری	۰/۰۴	۱			
مولارپته هیدروکسید سدیم	۰/۴۸	۰/۰۵	۱		
فعال‌ساز رطوبت بهینه	۰/۳۶	۰/۰۵	۰/۲۷	۱	
UCS (kPa)	۰/۳۹	۰/۴۱	۰/۳۶	۰/۴۱	۱

۳ به‌کارگیری الگوریتم‌های مختلف یادگیری ماشین در برآورد UCS خاک تثبیت‌شده

از الگوریتم‌های یادگیری ماشین، به‌منظور استخراج اطلاعات مورد نیاز از داده‌های موجود استفاده می‌شود. یادگیری با این الگوریتم‌ها به سه دسته یادگیری نظارت‌شده، یادگیری غیرنظارتی و یادگیری تقویتی تقسیم می‌شود. یادگیری در روش نظارت‌شده، با داده‌های آموزشی برچسب‌دار انجام می‌شود. در این روش به ازای پارامترهای ورودی موجود در مجموعه داده آموزشی، پارامتر خروجی متناظری وجود دارد. در روش یادگیری غیرنظارتی، داده‌ها بدون هیچ برچسبی به مدل داده می‌شوند و الگوریتم خود به یافتن الگوهای پنهان داده‌ها می‌پردازد. یادگیری در روش تقویتی با آزمون و خطا انجام می‌شود. در روش مذکور، راه‌های مختلف رسیدن به پاسخ امتحان می‌شود. در صورت رسیدن به پاسخ صحیح پاداش داده می‌شود و در غیراین صورت جریمه می‌شود. الگوریتم‌های استفاده‌شده در این پژوهش، در دسته یادگیری نظارت‌شده قرار دارند که در ادامه توضیح داده می‌شود.

۳-۱ الگوریتم رگرسیون خطی (LR)

الگوریتم رگرسیون خطی با به حداقل رساندن مجموع مربعات خطا میان مقدار مشاهده‌شده و مقدار

پیش‌بینی‌شده، برای برازش مدل خطی به کار می‌رود. در رگرسیون خطی به کمک یک معادله خط معرفی‌شده، با استفاده از خط رگرسیون، مقدار متغیر وابسته به ازای مقدارهای مختلف متغیر مستقل برآورد می‌شود. متغیر وابسته همان متغیری است که مقادیر آن پیش‌بینی خواهد شد و متغیرهای مستقل، ورودی‌ها هستند. به‌منظور برآورد پارامترهای مناسب برای مدل بر اساس داده‌های موجود، مدلی انتخاب خواهد شد که کمترین خطا را داشته باشد (رشکا و همکاران، ۲۰۲۲).

۳-۲ الگوریتم شبکه عصبی (MLP)

شبکه عصبی مصنوعی یکی از قدرتمندترین روش‌های نظارت‌شده یادگیری ماشین است که با تقلید از عملکرد مغز انسان کار می‌کند. هر شبکه عصبی از چند لایه مختلف شامل یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان تشکیل می‌شود که هر لایه نیز خود چندین نورون دارد. بردار اطلاعات ورودی (x) با نورون‌های لایه اول دریافت می‌شود. این بردار در پارامتر وزن w ضرب و با میزان اریبی b جمع می‌شود (رابطه ۱). در ادامه، با اعمال تابع فعال‌ساز f خروجی این لایه حاصل می‌شود. این فرایند برای تمام لایه‌ها به‌طور مشابه انجام می‌شود. در نهایت، پاسخ مدل برابر بردار خروجی آخرین

$$f(x) = \sum_{j=1}^n w_j x_j + b \quad w \in \mathbb{R}^n, b \in \mathbb{R} \quad (4)$$

برقرار باشد. در روابط (۲) تا (۴)، n تعداد پارامترهای ورودی، b میزان اربیبی و w پارامتر وزن است. پارامتر C بین میزان پیچیدگی تابع f و مقدار خطای مجاز رابطه برقرار می‌کند. در الگوریتم SVR خطای کمتر از ε پذیرفتنی تلقی می‌شود. برای خطاهای بیش از ε میزان جریمه با متغیرهای مجازی ξ_i و ξ_i^* تعیین می‌شود.

۳-۵ الگوریتم درخت تصمیم (DT)

درخت تصمیم با کمینه کردن تابع هزینه از داده‌های آموزشی برای انتخاب بهترین نقاط جهت تقسیم‌بندی داده‌ها استفاده می‌کند. برای کاهش پیچیدگی و جلوگیری از برازش بیش از حد، معمولاً از هرس استفاده می‌شود؛ یعنی شاخه‌هایی حذف می‌شوند که روی ویژگی‌های با اهمیت کم قرار می‌گیرند (رشکا و همکاران، ۲۰۲۲).

۳-۶ الگوریتم جنگل تصادفی (RF)

این روش که از پرکاربردترین الگوریتم‌های یادگیری نظارت‌شده است، روش یادگیری گروهی را برای رگرسیون به کار می‌گیرد. این الگوریتم در طول زمان آموزش درخت‌های تصمیم‌گیری متعددی می‌سازد و خروجی نهایی را تعیین می‌کند. درختان با در نظر گرفتن معیار کاهش همبستگی میان دسته‌های مجزا ساخته می‌شوند. برای درختان تصمیم که در مجموعه آموزشی دچار بیش‌برازش می‌شوند، روش جنگل تصادفی عملکرد مناسبی دارد. بهبود عملکرد این روش در مقایسه با درخت تصمیم تا حدی به نوع داده بستگی دارد (رشکا و همکاران، ۲۰۲۲).

لایه (y) است (تئوبالد، ۲۰۱۷):

$$y = f(wx + b) \quad (1)$$

۳-۳ الگوریتم K نزدیک‌ترین همسایه (KNN)

این الگوریتم از ویژگی شباهت برای پیش‌بینی مقادیر هر داده جدید استفاده می‌کند؛ به این معنی که نقطه جدید بر اساس شباهت آن به سایر نقاط مجموعه آموزشی مقادیردهی می‌شود. K نزدیک‌ترین نقاط همسایه بر اساس فاصله انتخاب می‌شوند. مقدار متوسط K نزدیک‌ترین همسایه، پیش‌بینی نهایی برای نقطه جدید است. در میان الگوریتم‌های یادگیری ماشین، این روش یکی از ساده‌ترین و قدیمی‌ترین روش‌های غیرخطی با رویکرد نظارت‌شده محسوب می‌شود (رشکا و همکاران، ۲۰۲۲).

۳-۴ الگوریتم ماشین بردار پشتیبان (SVR)

الگوریتم رگرسیون بردار پشتیبان از روش‌های کاربردی در دسته الگوریتم‌های نظارت‌شده یادگیری ماشین است. در این روش زوج داده‌های آموزشی شامل $x_i \in \mathbb{R}^n$ ($i = 1, 2, \dots, l$) است. $(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)$ $y_i \in \mathbb{R}$ ($i = 1, 2, \dots, l$) متغیرهای ورودی الگوریتم و $(1, 2, \dots, l)$ متغیر هدف است. الگوریتم SVR قصد دارد عبارت (۲) را کمینه کند (شو و همکاران، ۲۰۱۴):

$$\frac{1}{4} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (2)$$

درحالی‌که شرایط

$$\begin{cases} y_i - \sum_{j=1}^n \sum_{i=1}^l w_j x_{ji} - b \leq \varepsilon + \xi_i \\ \sum_{j=1}^n \sum_{i=1}^l w_j x_{ji} + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (3)$$

۷-۳ الگوریتم ماشین تقویت گرادیان (GBM)

این الگوریتم به منظور تقویت برازش، دنباله‌ای از مدل‌ها را می‌سازد و قبل از اینکه آنها را در دنباله قرار دهد، سعی در اصلاح اشتباهات مدل‌های قبلی دارد. یادگیری گروهی به شیوه‌ای اجرا می‌شود که هر یادگیرنده ضعیف جدید مستقیماً روی خطاهای فعلی مدل قرار می‌گیرد تا درختان را بر اساس کمینه کردن خطاهای مدل تقویت کند (رشکا و همکاران، ۲۰۲۲).

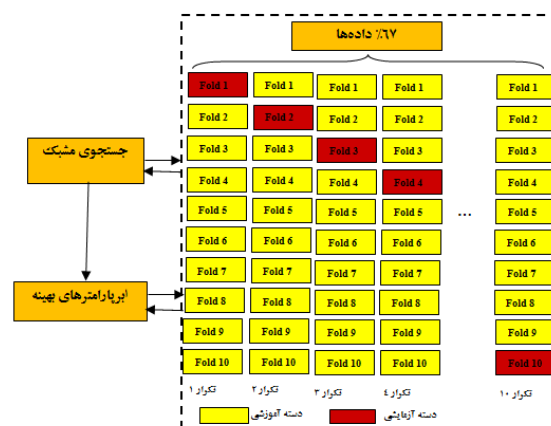
۸-۳ اعتبارسنجی و ارزیابی عملکرد الگوریتم‌های یادگیری ماشین

به منظور افزایش کارایی و دقت الگوریتم‌های یادگیری ماشین، لازم است پارامترهای تأثیرگذار الگوریتم (ابریارامترها) تعیین و سپس این پارامترها برای هر مسئله خاص بهینه شوند. در این مقاله از روش جستجوی مشبک برای تنظیم ابریارامترهای الگوریتم‌ها استفاده شده است. در این روش، عملکرد الگوریتم مورد نظر تحت ترکیب‌های مختلفی از ابریارامترها سنجیده می‌شود. در نهایت، ترکیبی که بهترین عملکرد را طبق معیارهای ارزیابی الگوریتم (مانند ضریب تبیین، متوسط مربعات خطا، متوسط قدرمطلق خطا و...) ارائه دهد، به عنوان پارامترهای تنظیم شده برای حل آن مسئله در نظر گرفته می‌شود (برونلی، ۲۰۱۶).

در فرایند تنظیم ابریارامترها، جهت کاهش تغییرپذیری نتایج در دسته‌بندی مجموعه داده به بخش‌های آموزشی و آزمایشی، روش اعتبارسنجی متقابل ده‌تایی به کار گرفته شد (برونلی، ۲۰۱۶). در این روش، داده‌ها به k بخش (fold) تقسیم می‌شوند. الگوریتم مورد نظر روی $(k-1)$ بخش آموزش می‌بیند و یک بخش به عنوان دسته آزمایشی منظور می‌شود. این فرایند k بار تکرار می‌شود به نحوی که هر بخش الزاماً یک بار در مجموعه آزمایشی قرار گیرد (شکل ۱). طی این فرایند، الگوریتم مورد نظر چندین بار روی داده‌های مختلف آموزش می‌بیند؛ بنابراین نتایج دقیق‌تری حاصل می‌شود.

۹-۳ شیوه اجرای شبیه‌سازی

در این پژوهش روش اعتبارسنجی متقابل ده‌تایی ($k=10$) برای داده‌های بخش آموزشی به کار گرفته شد. این داده‌ها ۶۷٪ از مجموعه داده را تشکیل می‌دهند. به عبارت دیگر، داده‌ها به ده بخش تقسیم شدند و هر بار یک قسمت از ده قسمت به عنوان مجموعه آموزش و مابقی به عنوان مجموعه آموزشی منظور شد به گونه‌ای که هر قسمت فقط یک بار در دسته آزمایشی قرار داشت. به این ترتیب، یک ترکیب بهینه از ابریارامترهای الگوریتم‌های یادگیری ماشین برای تخمین UCS خاک تثبیت شده تعیین شد. مراحل کار در شکل ۱ نشان داده شده است.



شکل ۱. الگوریتم تعیین ابریارامترهای روش‌های یادگیری ماشین.

بزرگ باشد، خطای الگوریتم نزدیک به صفر می‌شود. در این حالت حل بسیاری از مسائل غیرممکن می‌شود. در مقابل، مقادیر کوچک C به معنی کاهش شدت قیدها و بروز خطاهای زیاد است. مقادیر مناسب C به مدل اجازه می‌دهد با یک خطای پذیرفتنی، پاسخ مناسبی برای مسئله پیدا کند. SVR برای حل مسائل غیرخطی، داده‌ها را با کمک کرنل‌های غیرخطی به فضای خطی می‌نگارد. کرنل تابع شعاعی (RBF) یکی از این کرنل‌ها است. نگاشت داده‌ها به فضای خطی در این کرنل با پارامتر گاما انجام می‌شود. برای روش درخت تصمیم، تابع معیار ارزیابی‌کننده خطا تغییر داده شد و قدرمطلق خطا به‌عنوان بهترین معیار انتخاب شد. ابرپارامترها در روش‌های RF و GBM، تعداد تخمین‌گرها و تابع معیار (یا تابع زیان) بودند و با روش جستجوی شبکه تنظیم شدند.

نحوه تنظیم ابرپارامترها برای الگوریتم‌های یادگیری ماشین مورد استفاده در جدول ۵ آورده شده است. برای MLP یک لایه مخفی لحاظ شد. پارامترهای تابع فعال‌ساز (activation function)، تعداد نورون‌های لایه مخفی و حلگر (solver) به‌عنوان ابرپارامترها انتخاب و با الگوریتم جستجوی شبکه تنظیم شدند. محدوده تغییرات تعداد نورون‌های لایه مخفی از ۵ تا ۱۳۰ با گام‌های پنج‌تایی در نظر گرفته شد و بهترین مقدار ۳۵ به‌دست آمد.

برای الگوریتم KNN، ابرپارامتر K نزدیک‌ترین همسایه بود. مقادیر در محدوده ۱ تا ۱۵ با گام‌های دوتایی فرض و بهترین مقدار ۳ انتخاب شد. در الگوریتم SVR، سه ابرپارامتر شامل نوع کرنل، پارامتر حاشیه اطمینان (C) و گاما تنظیم شدند. پارامتر C ارتباط بین شدت قیدهای مسئله و خطای الگوریتم را برقرار می‌کند. با افزایش مقدار C میزان قیدهای مسئله افزایش می‌یابد. اگر مقدار C خیلی

جدول ۵. تنظیم ابرپارامترهای الگوریتم‌های یادگیری ماشین استفاده‌شده.

روش	ابروپارامترهای انتخاب‌شده برای تنظیم کردن	محدوده تغییرات هر ابرپارامتر	بهترین نتیجه با روش جستجوی شبکه
MLP	تعداد نورون‌های یک لایه مخفی تابع فعال‌ساز تابع حلگر	از ۵ تا ۱۳۰ با گام‌های پنج‌تایی logistic, tanh, relu lbfgs, sgd, adam	۳۵ tanh lbfgs
KNN	تعداد K نزدیک‌ترین همسایه	از ۱ تا ۱۵ با گام‌های دوتایی	۳
SVR	مقدار C گاما تابع کرنل	از ۱۰ تا ۱۰۰ با گام‌های ده‌تایی scale, auto linear, poly, rbf, sigmoid	۷۰ auto rbf
DT	تابع معیار ارزیابی خطا	squared_error, friedman_mse, absolute_error, poisson	absolute_error
RF	تابع معیار ارزیابی خطا تعداد تخمین‌گر	squared_error, friedman_mse, absolute_error, poisson از ۵۰ تا ۱۵۰ با گام‌های پنجاه‌تایی	absolute_error ۱۵۰
GBM	تابع زیان تعداد تخمین‌گر	squared_error, absolute_error, huber, quantile از ۵۰ تا ۳۰۰ با گام‌های پنجاه‌تایی	huber ۳۰۰

(MAPE) ارزیابی شد. شکل ۲ مقادیر معیارهای ارزیابی الگوریتم‌های مورد استفاده برای پیش‌بینی UCS خاک را با استفاده از الگوریتم‌های یادگیری ماشین برای داده‌های آموزشی نشان می‌دهد.

مقادیر متوسط مربعات خطا در مرحله آموزش، از ۰/۰۰۰۰۰۲ تا ۰/۳۲ و مقادیر متوسط قدرمطلق خطا در بازه ۰/۰۰۰۰۴ تا ۰/۴۱ متغیر است. مطابق با نتایج، کمترین میانگین MSE و MAPE و بیشترین ضریب تبیین برای الگوریتم MLP حاصل شد که نسبت به سایر روش‌ها به نتایج به‌مراتب بهتری در پیش‌بینی مقاومت خاک منجر شده بود.

نکته‌ای که درباره الگوریتم درخت تصمیم (DT) می‌توان بیان کرد آن است که این روش با وجود کسب نتایج مشابه با الگوریتم MLP در مرحله آموزش، کارایی مناسبی در برآورد مقاومت فشاری خاک تثبیت‌شده ندارد. با توجه به نتایج مندرج در مرحله آزمون (شکل ۳) مشخص است که این روش فقط داده‌های آموزشی را به‌خوبی فرا گرفته است و توانایی مناسبی در یادگیری داده‌های جدید آزمون ندارد؛ بنابراین دچار بیش‌برازش شده است.

یکی از دلایل برتری روش شبکه عصبی در بین الگوریتم‌های استفاده‌شده، وجود رابطه غیرخطی مقاومت فشاری خاک تثبیت‌شده با پارامترهای ورودی مانند زمان و شرایط عمل‌آوری، ملاریته فعال‌ساز قلیایی، نوع پوزولان، نسبت وزنی فعال‌ساز و... است. بعد از الگوریتم شبکه عصبی پرسپترون چندلایه (MLP)، الگوریتم رگرسیون بردار پشتیبان (SVR) با میانگین متوسط قدرمطلق خطای ۰/۰۸، میانگین متوسط مربعات خطای ۰/۰۰۷ و میانگین ضریب تبیین ۰/۹۹۳ در رتبه دوم قرار گرفت. با توجه به نتایج بسیار نزدیک روش‌های MLP و SVR می‌توان هر دو روش را برای تخمین مقاومت فشاری خاک مورد مطالعه، در دسته برترین روش‌ها قرار داد.

در این پژوهش از معیارهای متوسط مربعات خطا (MSE)، ضریب تبیین (R^2) و متوسط قدرمطلق خطا (MAPE) برای ارزیابی عملکرد الگوریتم‌های یادگیری ماشین استفاده شد. MSE برابر با میانگین توان دوم خطا و MAPE میانگین قدرمطلق خطا است. منظور از خطا، اختلاف بین مقدار پیش‌بینی‌شده و مقدار واقعی است. برای MAPE و MSE مقادیر نزدیک به صفر بیانگر عملکرد بهتر مدل هستند. R^2 نیز یک شاخص آماری است که رابطه خطی بین مقادیر برآوردشده و مقادیر واقعی را نشان می‌دهد. R^2 بین صفر و یک تغییر می‌کند. این مقدار هرچه به ۱ نزدیک‌تر باشد، مدل خطای کمتری دارد. این معیارها در روابط (۵) تا (۷) تعریف شده‌اند:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i^* - y_i)^2 \quad (5)$$

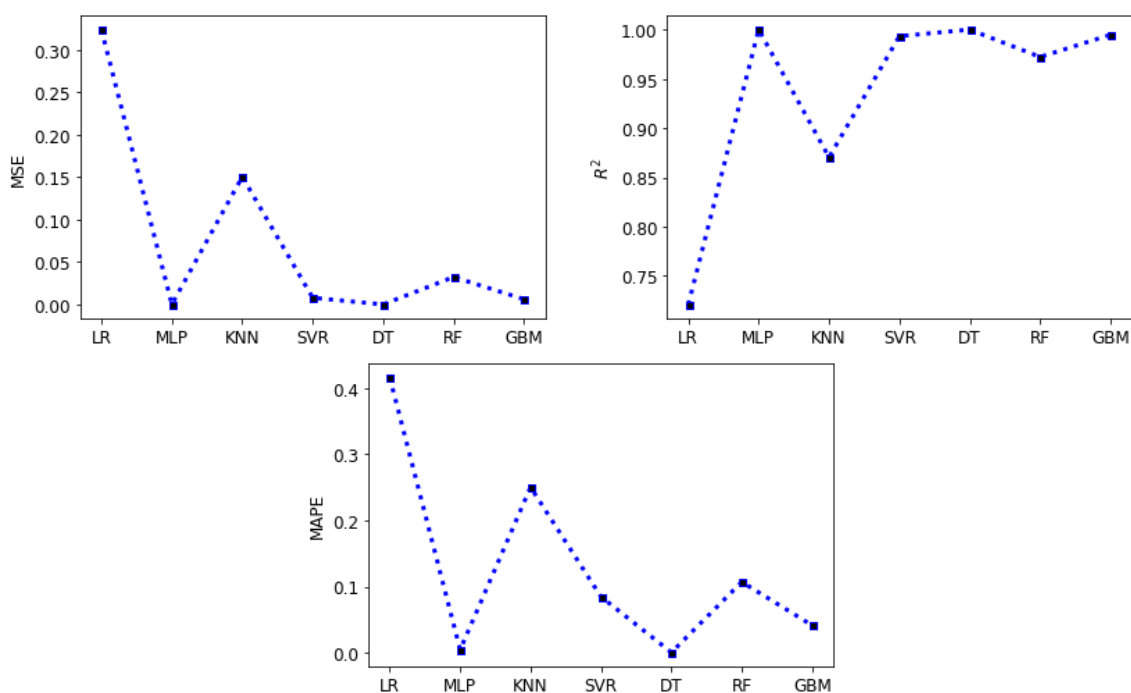
$$R^2 = \left(\frac{\sum_{i=1}^N (y_i^* - \bar{y}^*)(y_i - \bar{y})}{\sqrt{(\sum_{i=1}^N (y_i^* - \bar{y}^*)^2)(\sum_{i=1}^N (y_i - \bar{y})^2)}} \right)^2 \quad (6)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N |y_i^* - y_i| \quad (7)$$

که N تعداد داده‌ها، y_i^* مقادیر UCS پیش‌بینی‌شده با الگوریتم‌های یادگیری ماشین، y_i مقادیر واقعی UCS، \bar{y}^* میانگین مقادیر UCS پیش‌بینی‌شده و \bar{y} میانگین مقادیر واقعی هستند.

۴ تحلیل نتایج

در این بخش، هفت الگوریتم شامل الگوریتم‌های پیش‌بینی‌کننده خطی (LR)، شبکه عصبی (MLP)، K، نزدیک‌ترین همسایه (KNN)، ماشین بردار پشتیبان (SVR)، درخت تصمیم (DT)، جنگل تصادفی (RF) و ماشین تقویت گرادیان (GBM) به کار گرفته شدند. سپس عملکرد این الگوریتم‌ها در برآورد UCS خاک تثبیت‌شده با استفاده از معیارهای میانگین مربعات خطا (MSE)، ضریب تبیین (R^2) و میانگین قدرمطلق خطا



شکل ۲. مقادیر معیارهای ارزیابی الگوریتم‌های استفاده‌شده برای داده‌های آموزش.

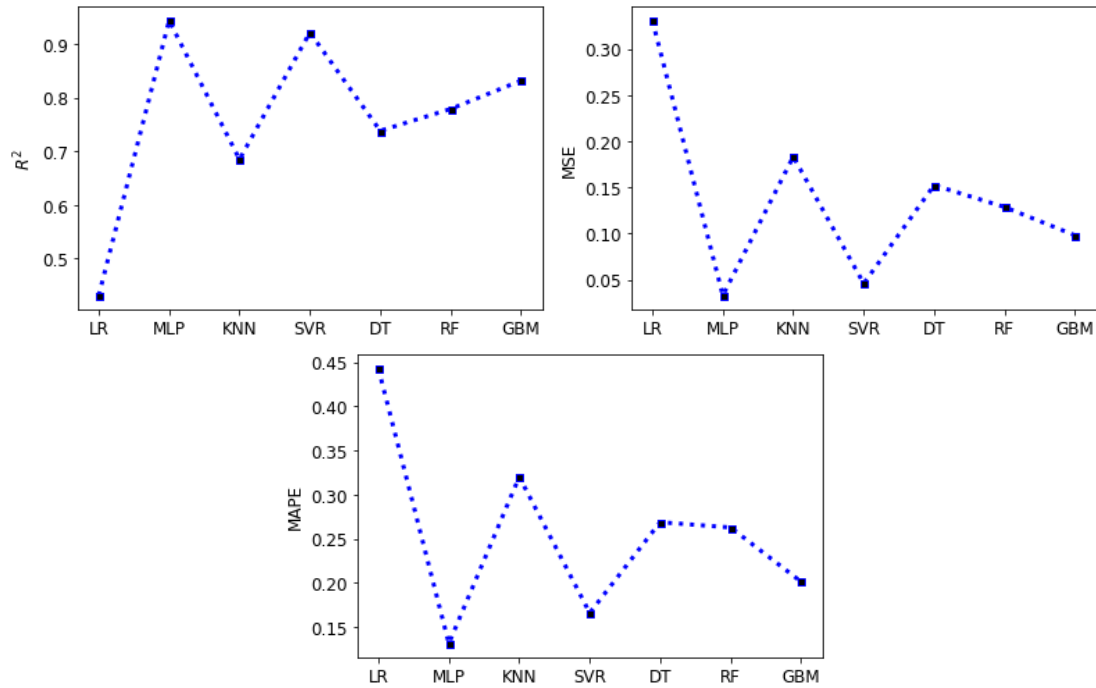
درحالی‌که بیشترین و کمترین مقدار ضریب تبیین به ترتیب در الگوریتم‌های MLP و LR به دست آمد. با توجه به نتایج هر سه معیار ارزیابی، شبکه عصبی پرسپترون چندلایه در مرحله آزمون نیز مشابه مرحله آموزش، بهترین نتیجه را نشان داد. به علاوه طبق معیارهای ارزیابی، روش SVR در مرحله آزمون همانند مرحله آموزش، نتایج بسیار نزدیک به MLP داشت که حاکی از عملکرد خوب آن در پیش‌بینی UCS خاک است.

مقایسه مقادیر اندازه‌گیری شده و برآوردشده مقاومت خاک تثبیت‌شده برای الگوریتم‌های مدنظر در مرحله آزمون، در شکل ۴ نشان داده شده است. با مقایسه شکل‌ها، الگوریتم شبکه عصبی با بیشترین ضریب تبیین (۰/۹۴۳) و کمترین مقدار میانگین قدرمطلق خطا (۰/۱۳۱) و میانگین مربعات خطا (۰/۰۳۳) بهترین نتیجه را نشان داد. الگوریتم‌های ماشین بردار پشتیبان (۰/۹۲۱) و ماشین تقویت گرادیان (۰/۸۳۲) نیز با مقادیر ضریب تبیین بزرگ‌تر از ۰/۸ در رتبه‌های بعدی قرار گرفتند. الگوریتم


همچنین الگوریتم رگرسیون خطی (LR) با بیشترین میانگین قدرمطلق خطا (MAPE)، بیشترین میانگین متوسط مربعات خطا (MSE) و کمترین ضریب تبیین (R²) رتبه آخر را در بین هفت الگوریتم مورد استفاده کسب کرد. پس از آموزش داده‌ها، با به‌کارگیری روش اعتبارسنجی K-fold، از ۳۳ درصد باقیمانده داده‌ها در مرحله آزمون استفاده شد. نتایج مرحله آزمون برای مدل‌سازی الگوریتم‌های مذکور در شکل ۳ نشان داده شده است. همان‌گونه که نتایج نشان می‌دهد، تغییرات متوسط مربعات خطا برای هفت الگوریتم یادگیری ماشین از ۰/۰۳۳ تا ۰/۳۳۱ متفاوت است. بیشترین مقدار MSE در الگوریتم LR (رگرسیون خطی) و کمترین مقدار آن در شبکه عصبی (MLP) مشاهده شد. مقدار میانگین قدرمطلق خطا نیز در بازه ۰/۱۳۱ تا ۰/۴۴۳ و همچنین مقادیر ضریب تبیین در دامنه ۰/۴۳۱ تا ۰/۹۴۳ متفاوت بود. بیشترین و کمترین مقدار MAPE به ترتیب در الگوریتم‌های رگرسیون خطی (LR) و شبکه عصبی (MLP) مشاهده شد،

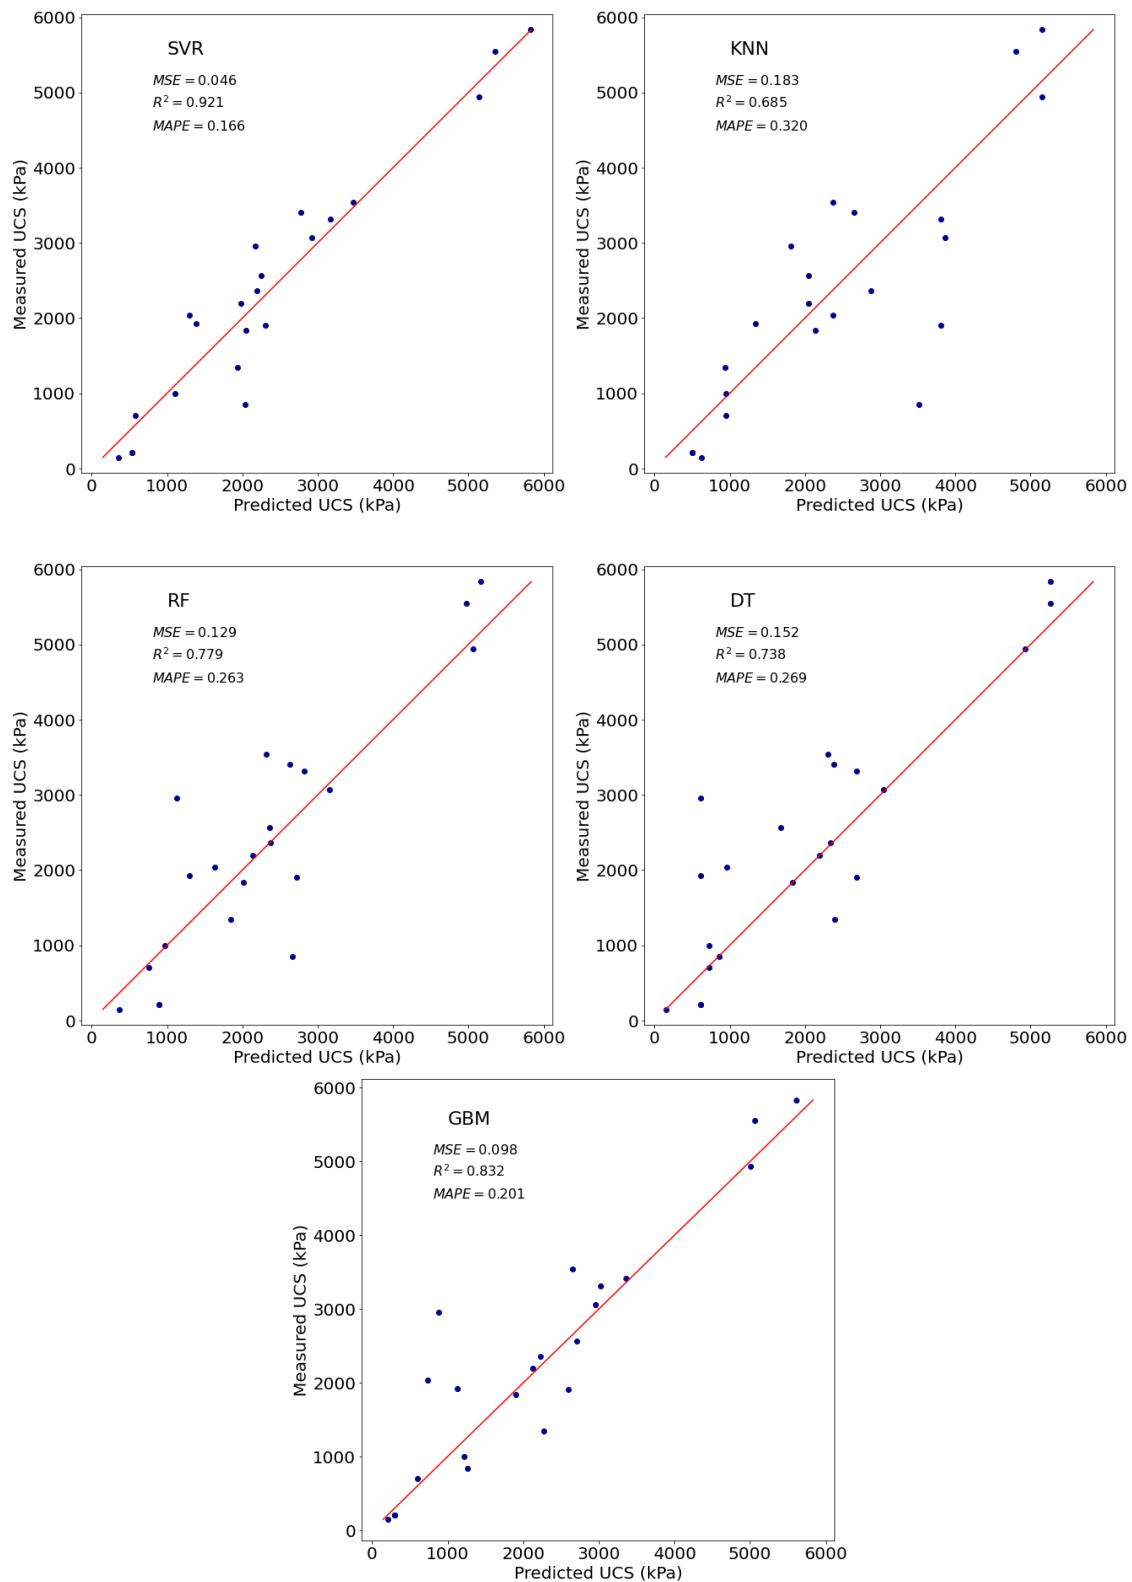
فشاری خاک تثبیت شده با پارامترهای ورودی مانند زمان و شرایط عمل آوری، ملاریته فعال ساز قلیایی، درصد وزنی و نوع پوزولان، نسبت وزنی فعال ساز و... بیان شود.

رگرسیون خطی با کمترین ضریب تبیین (۰/۴۳۱)، در بین همه الگوریتم‌های استفاده شده به عنوان روشی نامناسب برای تخمین مقاومت فشاری خاک مورد مطالعه معرفی شد. علت آن، می‌تواند وجود رابطه غیرخطی مقاومت



شکل ۳. مقادیر معیارهای ارزیابی الگوریتم‌های استفاده شده برای داده‌های آزمایش.





شکل ۴. مقایسه مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده مقاومت خاک برای الگوریتم‌های مدنظر در مرحله آزمون.

۵ تحلیل حساسیت

تحلیل حساسیت، درجه اهمیت هریک از متغیرهای ورودی را در پیش‌بینی مقاومت فشاری خاک نشان می‌دهد. در این تحقیق برای تحلیل حساسیت، از روش دامنه کسینوس (Cosine Amplitude Method, CAM) استفاده شده است که حیدری و غنی‌زاده (۲۰۲۰) به کار گرفته‌اند. در این روش درجه اهمیت متغیر ورودی با توجه به درجه همبستگی میان متغیر ورودی و متغیر خروجی (مقاومت فشاری) از رابطه (۸) محاسبه می‌شود:


$$R_i = \frac{\sum_{k=1}^m x_{ik} y_k}{\sqrt{\sum_{k=1}^m x_{ik}^2 \times \sum_{k=1}^m y_k^2}} \quad (8)$$

که x_{ik} متغیر ورودی (مستقل) داده k -ام، y_k متغیر خروجی (وابسته) متناظر با داده k -ام و m تعداد کل داده‌ها است. طبق رابطه (۸) هرچه مقدار R_i بزرگ‌تر

باشد، ارتباط آن متغیر ورودی با خروجی (مقاومت فشاری خاک) بیشتر است.

برای هریک از متغیرهای ورودی (پوزولان، زمان عمل‌آوری، مقدار مولاریته و نسبت فعال‌ساز به رطوبت) و متغیر خروجی (مقاومت فشاری برآوردشده بر اساس شبکه عصبی)، مقدار R_i محاسبه و برحسب درصد در شکل ۵ نمایش داده شده است. نتایج شکل ۵ نشان می‌دهد درجه اهمیت متغیرهای ورودی مقدار پوزولان، زمان عمل‌آوری، مقدار مولاریته و نسبت فعال‌ساز به رطوبت در پیش‌بینی مقاومت فشاری خاک به ترتیب زیر است:

پوزولان < مولاریته < زمان عمل‌آوری < نسبت فعال‌ساز به رطوبت



شکل ۵. درصد حساسیت متغیرهای ورودی بر مقاومت فشاری.


۶ تحلیل پارامتریک

در تحلیل پارامتریک، تأثیر هریک از متغیرهای ورودی بر مقاومت فشاری خاک بررسی می‌شود. برای این منظور جهت سنجش میزان اثر هر متغیر ورودی، آن متغیر در محدوده مشخصی تغییر می‌کند و با ثابت در نظر گرفتن پارامترهای دیگر، مقاومت فشاری خاک (UCS) با روش شبکه عصبی تعیین می‌شود.


۶-۱ تأثیر زمان عمل‌آوری بر مقاومت فشاری

برای تعیین تأثیر متغیر زمان عمل‌آوری بر مقاومت فشاری خاک، مقدار مولاریته و شرایط محیطی یکسان فرض شد و درصدهای مختلف برای پوزولان لحاظ شد. با تغییر زمان عمل‌آوری به صورت ۱، ۷ و ۲۸ روز، مقاومت فشاری با روش شبکه عصبی به دست آمد. با توجه به داده‌های در دسترس، پوزولان یک‌بار به صورت سیمان و

بیشتری افزایش می‌یابد و با افزایش زمان، شیب کمتر می‌شود. برای درصد‌های مختلف خاکستر در قسمت (ب)، با افزایش زمان عمل‌آوری مقاومت به‌صورت خطی با زمان عمل‌آوری افزایش می‌یابد. این روند برای خاک تثبیت‌شده با ۱۵٪ خاکستر مشهودتر است. این نتایج با یافته‌های سایر پژوهشگران همخوانی دارد (میلر و همکاران، ۲۰۰۶؛ غنی‌زاده و رهروان، ۲۰۱۹؛ حیدری دزفولی و غنی‌زاده، ۲۰۲۰ و آراجو و همکاران، ۲۰۲۳).



(ب)



(الف)

شکل ۶. تأثیر زمان عمل‌آوری بر UCS برای درصد‌های مختلف (الف) سیمان (ب) خاکستر.

دو پوزولان سیمان و خاکستر، با افزایش مقدار پوزولان، مقاومت فشاری افزایش می‌یابد (عبدالله و همکاران، ۲۰۱۷ و یوبانپوت و همکاران، ۲۰۱۷). برای پوزولان سیمان، با افزایش درصد سیمان، نرخ افزایش مقاومت فشاری در شرایط OC بیشتر از پوزولان خاکستر خواهد بود. تغییرات نوسانی مقاومت فشاری در قسمت (الف) یا کاهش مقاومت فشاری در قسمت (ب) برای شرایط محیطی DC نشان می‌دهد در شرایط خشک امکان واکنش‌های پوزولانی و تشکیل ترکیبات سیمانی که موجب کسب مقاومت می‌شوند، چندان فراهم نیست.


بار دیگر به‌صورت خاکستر بررسی شد. در شکل ۶ تأثیر زمان عمل‌آوری بر UCS، برای درصد‌های مختلف سیمان در قسمت (الف) و برای درصد‌های متفاوت خاکستر در قسمت (ب) نشان داده شده است.

مشاهده می‌شود که با افزایش زمان عمل‌آوری برای هر دو پوزولان سیمان و خاکستر، مقاومت فشاری افزایش می‌یابد. در قسمت (الف) برای درصد‌های مختلف سیمان، مقاومت فشاری در بازه ۱ تا ۷ روز عمل‌آوری با شیب


۲-۶ تأثیر درصد پوزولان بر مقاومت فشاری

برای تعیین تأثیر متغیر پوزولان بر مقاومت فشاری، زمان عمل‌آوری برابر ۲۸ روز فرض و شرایط درصد رطوبت بهینه (OC) و خشک (DC) لحاظ شد. با تغییر درصد‌های مختلف پوزولان، مقاومت فشاری با روش شبکه عصبی به‌دست آمد. با توجه به داده‌های در دسترس، پوزولان یک‌بار به‌صورت سیمان و بار دیگر به‌صورت خاکستر بررسی شد. در شکل ۷ تأثیر درصد پوزولان بر UCS نشان داده شده است. در قسمت (الف) تأثیر درصد سیمان و در قسمت (ب) تأثیر درصد خاکستر را می‌توان مشاهده کرد.

ملاحظه می‌شود که با در نظر گرفتن شرایط OC برای هر



شکل ۷. تأثیر درصد پوزولان (الف) سیمان (ب) خاکستر بر UCS.



شکل ۸. (الف) تأثیر مقدار مولاریته بر UCS (ب) تأثیر نسبت فعال ساز به رطوبت بر UCS.

برای بررسی تأثیر متغیر نسبت فعال ساز به رطوبت بر مقاومت فشاری خاک، مقدار خاکستر ۱۵ درصد و شرایط محیطی یکسان فرض شد. روزهای عمل آوری ۱ روز و ۲۸ روز در نظر گرفته شد. با تغییر نسبت فعال ساز به رطوبت به صورت ۱، ۱/۲ و ۱/۴، مقاومت فشاری با روش شبکه عصبی به دست آمد. شکل ۸-ب تأثیر نسبت فعال ساز به رطوبت را بر مقاومت فشاری نشان می دهد. ملاحظه می شود که با افزایش مقدار نسبت فعال ساز به رطوبت تا ۱/۲ برای زمان عمل آوری ۲۸ روز، مقاومت فشاری افزایش می یابد و پس از آن با نرخ ثابتی همراه خواهد بود.

۷ نتیجه گیری

در این پژوهش، مقاومت فشاری تک محوری (UCS)

۳-۶ تأثیر متغیرهای مولاریته و نسبت فعال ساز به رطوبت بر مقاومت فشاری

برای تعیین تأثیر متغیر مولاریته بر مقاومت فشاری خاک، مقدار خاکستر ۱۰ درصد و شرایط محیطی یکسان فرض شد و روزهای عمل آوری ۱ و ۲۸ روز در نظر گرفته شد. با تغییر مقدار مولاریته به صورت ۰.۴، ۰.۸ و ۱.۲، مقاومت فشاری با روش شبکه عصبی به دست آمد. در شکل ۸-الف تأثیر مولاریته بر مقاومت فشاری نشان داده شده است. ملاحظه می شود که با افزایش مقدار مولاریته برای هر دو زمان عمل آوری، مقاومت فشاری افزایش می یابد که با نتایج پژوهش سوکپراسرت و همکاران (۲۰۲۱) منطبق است. مقاومت فشاری با افزایش زمان عمل آوری با شیب بیشتری افزایش یافته است.

مطالعه، متغیرهای پوزولان، مولاریته و زمان عمل‌آوری بیشترین تأثیر را بر مقدار مقاومت فشاری پیش‌بینی‌شده با MLP دارند؛

• با تحلیل پارامتریک نشان داده شد که با افزایش زمان عمل‌آوری برای هر دو پوزولان سیمان و خاکستر، مقاومت فشاری افزایش می‌یابد. همچنین افزایش مقدار مولاریته باعث می‌شود خاک رس تثبیت‌شده با خاکستر آتشفشانی مقاوم‌تر شود؛

• نتایج این پژوهش را می‌توان برای خاک‌هایی با طبقه‌بندی و حدود اتربرگ مشابه تعمیم داد. این نتایج برای خاک‌هایی که دانه‌بندی و خاصیت خمیری آنها با خاک مورد مطالعه در این پژوهش اختلاف زیادی دارند، کاربردی نیست. همچنین تغییر پارامترهای ورودی، ممکن است به نتایج متفاوتی منجر شود؛ بنابراین ممکن است اولویت‌بندی بهینه بودن روش‌های یادگیری ماشین مورد استفاده نیز تغییر کند.

منابع

- Abdullah, H. H., Shahin, M. A., and Sarker, P., 2017, Stabilization of clay with fly-ash geopolymer incorporating GGBFS: Proceedings of the second world congress on civil, structural and environmental engineering (CSEE'17).
- 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, doi:https://doi.org/10.1016/j.trgeo.2018.08.002.
- Brownlee, J., 2016, *Machine Learning Mastery with Python: Understand Your Data, Create Accurate Models, and Work Projects End-to-End: Machine Learning Mastery*, San Francisco.
- Das, S. K., Samui, P., and 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,

خاک رس تثبیت‌شده با استفاده از سیمان و خاکستر آتشفشانی با به‌کارگیری الگوریتم‌های مختلف نظارت‌شده یادگیری ماشین تخمین زده شد. برای این منظور پارامترهای ورودی مدل شامل خصوصیات زمان و شرایط عمل‌آوری، ملاریته فعال‌ساز قلیایی، درصد وزنی پوزولان مورد استفاده، نوع پوزولان و نسبت وزنی فعال‌ساز به رطوبت بهینه بود. علاوه‌براین از معیارهای R^2 ، MSE و MAPE برای ارزیابی کارایی مدل‌ها استفاده شد. نتایج این پژوهش عبارت‌اند از:

- تعداد لایه‌های روش شبکه عصبی (MLP) مورد استفاده در این مطالعه، سه لایه است: یک لایه ورودی؛ یک لایه مخفی با ۳۵ نورون (بر اساس تنظیم ابرپارامترها)؛ یک لایه خروجی. میزان R^2 در روش MLP برای داده‌های آزمایش برابر با ۰/۹۴۳ به‌دست‌آمد که بیشترین مقدار را در بین الگوریتم‌های مختلف استفاده‌شده دارد. مقادیر MSE و MAPE برای این الگوریتم به ترتیب برابر با ۰/۰۳۳ و ۰/۱۳۱ هستند که کمترین مقادیر را در بین مدل‌های مختلف دارند. نتایج بیانگر این است که الگوریتم MLP بیشترین دقت را در بین الگوریتم‌های استفاده‌شده دارد؛
- بعد از الگوریتم شبکه عصبی پرسپترون چندلایه (MLP)، الگوریتم رگرسیون بردار پشتیبان (SVR) با میانگین متوسط مربعات خطای ۰/۰۴۶، میانگین ضریب تبیین ۰/۹۲۱ و میانگین متوسط قدرمطلق خطای ۰/۱۶۶ برای داده‌های آزمایش، در رتبه دوم قرار گرفت. با توجه به نتایج بسیار نزدیک روش‌های MLP و SVR، می‌توان هر دو روش را برای مقاومت خاک مورد مطالعه در دسته برترین روش‌ها قرار داد؛
- روش رگرسیون خطی، کمترین مقدار R^2 و بیشترین مقادیر MAPE و MSE را در بین مدل‌های استفاده‌شده برای داده‌های آزمایش دارد که حاکی از عملکرد ضعیف این روش برای تخمین مقاومت این نوع خاک است؛
- با تحلیل حساسیت مشخص شد که برای خاک مورد

- Güllü, H., 2014, Function finding via genetic expression programming for strength and elastic properties of clay treated with bottom ash: *Engineering Applications of Artificial Intelligence*, **35**, 143-157.
- Heidari Dezfuli, T., and Ghanizadeh, A. R., 2020, Prediction of compressive and tensile strength of clayey subgrade soil stabilized with Portland cement and iron ore mine tailing using computational intelligence methods: *Civil Infrastructure Researches*, **6**(1), 73-88.
- Kaniraj, S. R., and Havanagi, V. G., 1999, Compressive strength of cement stabilized fly ash-soil mixtures: *Cement and Concrete Research*, **29**(5), 673-677.
- Miao, S., Shen, Z., Wang, X., Luo, F., Huang, X., and Wei, C., 2017, Stabilization of highly expansive black cotton soils by means of geopolymerization: *Journal of Materials in Civil Engineering*, **29**(10), 04017170.
- Miller, H. J., Guthrie, W. S., Crane, R. A., and Smith, B., 2006, Evaluation of cement-stabilized full-depth-recycled base materials for frost and early traffic conditions: *Recycled Materials Resource Center, University of New Hampshire*, **27**.
- Miura, N., Horpibulsuk, S., and Nagaraj, T., 2001, Engineering behavior of cement stabilized clay at high water content: *Soils and Foundations*, **41**(5), 33-45.
- Mozumder, R. A., Laskar, A. I., and Hussain, M., 2017, Empirical approach for strength prediction of geopolymer stabilized clayey soil using support vector machines: *Construction and Building Materials*, **132**, 412-424.
- Raschka, S., Liu, Y. H., and Mirjalili, V., 2022, *Machine Learning with PyTorch and Scikit-Learn*: Packt Publishing.
- Seco, A., Ramírez, F., Miqueleiz, L., and García, B., 2011, Stabilization of expansive soils for use in construction: *Applied Clay Science*, **51**(3), 348-352.
- Soleimani, S., Rajaei, S., Jiao, P., Sabz, A., and Soheilinia, S., 2018, New prediction models for unconfined compressive strength of geopolymer stabilized soil using multi-genetic programming: *Measurement*, **113**, 99-107.
- Sukprasert, S., Hoy, M., Horpibulsuk, S., Arulrajah, A., Rashid, A. S. A., and Nazir, R., 2021, Fly ash based geopolymer stabilisation of silty clay/blast furnace slag for subgrade applications: *Road Materials and Pavement Design*, **22**(2), 357-371.
- doi:10.1007/s10706-010-9379-4.
- de Araújo, M. T., Ferrazzo, S. T., Chaves, H. M., da Rocha, C. G., and Consoli, N. C., 2023, Mechanical behavior, mineralogy, and microstructure of alkali-activated wastes-based binder for a clayey soil stabilization: *Construction and Building Materials*, **362**, 129757.
- Ghadir, P., and Ranjbar, N., 2018, Clayey soil stabilization using geopolymer and Portland cement: *Construction and Building Materials*, **188**, 361-371.
- Ghanizadeh, A. R., Bayat, M., Tavana Amlashi, A., and 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., and 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*, doi:https://doi.org/10.22059/IJMGE.2022.306688.594858
- Ghanizadeh, A. R., and 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).
- Ghanizadeh, A. R., and 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., and 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, doi:10.22059/IJMGE.2022.306688.594858.
- Ghorbani, A., and Hasanzadeh Shooiili, H., 2018, Prediction of UCS and CBR of microsilica-lime stabilized sulfate silty sand using ANN and EPR models; application to the deep soil mixing: *Soils and Foundations*, **58**(1), 34-49.

- Theobald, O., 2017, *Machine Learning for Absolute Beginners: A Plain English Introduction*, **157**: Scatterplot Press, London, UK.
- Xue, X., Yang, X., and Chen, X., 2014, Application of a support vector machine for prediction of slope stability: *Science China Technological Sciences*, **57**(12), 2379-2386, doi:<https://doi.org/10.1007/s11431-014-5699-6>.
- Yi, Y., Zheng, X., Liu, S., and Al-Tabbaa, A., 2015, Comparison of reactive magnesia-and carbide slag-activated ground granulated blastfurnace slag and Portland cement for stabilisation of a natural soil: *Applied Clay Science*, **111**, 21-26.
- Yoobanpot, N., Jamsawang, P., and Horpibulsuk, S., 2017, Strength behavior and microstructural characteristics of soft clay stabilized with cement kiln dust and fly ash residue: *Applied Clay Science*, **141**, 146-156, doi:<https://doi.org/10.1016/j.clay.2017.02.028>.

Comparison of various machine learning algorithms for estimation of uniaxial compressive strength of cement and volcanic ash stabilized clay

Khadije Mahmoodi^{1,3*} and Hajar Momeni^{2,3}

¹Assistant Professor, Department of Civil Engineering, Faculty of Engineering, Ardakan University, Ardakan, Iran

²Assistant Professor, Department of Electrical Engineering, Faculty of Engineering, Ardakan University, Ardakan, Iran

³Water, Energy and Environment Research Institute, Ardakan University, Ardakan, Iran

(Received: 22 July 2023, Accepted: 23 October 2023)

Summary

One of the challenges in construction on poor clay soils is their low compressive strength and high settlement. Therefore, geotechnical engineers are always trying to improve the characteristics of this type of soil using different soil stabilization methods. Estimation of the efficiency of different soil stabilization methods requires numerous experimental tests, which can be time-consuming and costly. This article examines the performance of various machine learning methods, including linear regression (LR), multilayer perceptron neural network (MLP), K-nearest neighbor, support vector machine regressor (SVR), decision tree, random forest, and gradient boosting machine in estimating the unconfined compressive strength of stabilized clay soil using two types of pozzolans under different curing conditions. The input variables for the machine learning algorithms include time and curing conditions, the molarity of the alkaline activator, the binder replacement, the type of pozzolan, and ratio of the activator to the optimal moisture content. To optimize and speed up the performance of the algorithms, hyperparameter tuning was performed using a grid search method. In addition, to reduce the variability of the results with respect to data division into training and testing sets, a 10-fold cross-validation method was used. The performance of the algorithms was evaluated using three criteria, namely mean square error, coefficient of determination, and mean absolute percentage error. Given the very close results of the SVR method to the MLP method, these algorithms can be confidently recommended for the estimation of UCS of the studied soil. Moreover, based on the performance evaluation criteria, the linear regression method has the worst results among the models used on the experimental data. Also, the sensitivity analysis of the models shows that, in order of preference, the input variables of binder replacement, molarity and curing time have the highest effect on the predicted compressive strength. The results of parametric analysis represent that by increasing the curing time, for both types of binders, namely cement and volcanic ash, uniaxial compressive strength increases. In addition, by increasing the percentage of binders under the optimum water condition, the uniaxial strength of soil increases, while in dry condition with increasing the binder replacement, for volcanic ash stabilized soil, the UCS decreases and for cement stabilized soil it fluctuates. It is observed that the compressive strength has a direct relationship with the amount of molarity. The results indicate also that by increasing the alkali activator/optimum water content up to 1.2, for the curing time of 28 days, the compressive strength increases and then it will be constant.

Keywords: Volcanic ash, clay, cement, uniaxial compressive strength, machine learning