

پیش بینی مقاومت و مود همرسی ترک نمونه های شبه سنگی دارای درزه های ناممتد تحت تراکم با استفاده از الگوریتم های یادگیری ماشین

وهاب سرفرازی*^۱، فریبرز متن پور، شادمان محمدی بلبان آباد^۳، محمد رضائی^۴

دریافت مقاله: ۱۴۰۳/۰۲/۱۸ پذیرش مقاله: ۱۴۰۴/۰۷/۰۵

چکیده

خصوصیات مقاومتی سنگ درزه دار و فرآیند همرسی ترک در آن، به طور قابل توجهی به خصوصیات مکانیکی آن و پیکربندی درزه های از پیش موجود وابسته هستند. در این پژوهش، مدل های پیش بینی کننده ای مبتنی بر الگوریتم جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و نیز ترکیب آن ها (RF-SVM) با بکارگیری تکنیک جستجوی شبکه ای همراه با فرآیند اعتبارسنجی متقاطع، به منظور پیش بینی مقاومت و مود همرسی ترک در نمونه های شبه سنگی دارای درزه ناممتد تحت آزمایش های تراکم یک محوره و دو محوره، توسعه داده شده اند. خصوصیات مقاومتی نمونه ها $(\sigma_c, \sigma_t, \sigma_n, E, \nu, C, \tan \phi)$ ، فشار محصورکننده (σ_n) ، تعداد درزه ها (N)، زاویه قرارگیری درزه ها نسبت به راستای افق (β) و ضریب درزه داری (JC) به عنوان پارامترهای ورودی و مود همرسی ترک و مقاومت نمونه ها به عنوان پارامترهای خروجی در فرآیند مدل سازی در نظر گرفته شدند. همچنین، با استفاده از رگرسیون خطی چندگانه (MLR) رابطه ای به منظور پیش بینی مقاومت نمونه ها ارائه شد. عملکرد مدل MLR و مدل های بهینه RF، SVM، RF-SVM بر اساس شاخص های آماری R^2 ، RMSE، MAE و صحت کلی (OA) ارزیابی شد. نتایج نشان داد که مدل های RF، SVM و RF-SVM به ترتیب عملکرد به مراتب بهتری نسبت به مدل MLR دارند و قادرند مقاومت و مود همرسی ترک در نمونه ها را با دقت بسیار بالایی پیش بینی نمایند. همچنین، تحلیل عدم قطعیت به منظور ارزیابی اعتمادپذیری مدل ها انجام شد. نتایج تحلیل عدم قطعیت با استفاده از شاخص عرض بازه اطمینان (WCB) در مراحل آموزش و تست نشان داد که مدل ترکیبی RF-SVM و مدل های RF و SVM به ترتیب دارای کمترین مقدار WCB و بالاترین قطعیت در پیش بینی مقاومت نمونه ها هستند. در نهایت، نتایج تحلیل حساسیت نشان داد که مهمترین پارامترهای تأثیرگذار بر مقاومت نمونه ها به ترتیب σ_n ، JC، σ_c هستند، در حالی که پارامتر σ_n و N بیشترین تأثیر را بر مود شکست نمونه ها دارند.

کلید واژه ها: مواد شبه سنگی، درزه ناممتد، مود همرسی ترک، جنگل تصادفی، ماشین بردار پشتیبان.

۱. عضو هیات علمی گروه مهندسی معدن، دانشگاه صنعتی همدان، همدان، vahab.sarfaraizi@gmail.com

۲. دانشجوی دکتری مکانیک سنگ، دانشگاه تهران، تهران

۳. دانشجوی دکتری استخراج، دانشگاه تربیت مدرس، تهران

۴. عضو هیات علمی گروه مهندسی معدن، دانشگاه کردستان، کردستان

* مسئول مکاتبات

۱. مقدمه

توده‌سنگ‌ها شامل تعداد d درزه هستند که در مجموعه‌ها یا گروه‌هایی با جهت‌گیری و خصوصیات یکسان ظاهر می‌شوند. چنین ناپیوستگی‌هایی در هر مقیاسی از مرز دانه‌ها تا درزه‌ها و گسل‌های منطقه‌ای یافت می‌شوند کائو و همکاران (Cao et al., 2015). درزه‌های از پیش موجود در یک توده سنگ تأثیر چشمگیری بر مقاومت و تغییر شکل‌پذیری آن دارند. بعلاوه، گسیختگی در یک توده سنگ می‌تواند غالباً در امتداد درزه‌های از پیش موجود اتفاق بیافتد هوانگ و همکاران (Huang et al., 2016). وجود ناپیوستگی‌ها، درزه‌ها یا ترک‌ها در سنگ ۲ اثر مهم دارد: (۱) مقاومت و سختی توده‌سنگ کاهش داده و (۲) منبعی برای شروع ناپیوستگی‌های جدید هستند که به نوبه خود ممکن است انتشار یافته و با دیگر ترک‌ها پیوند بخورند و باعث کاهش بیشتر مقاومت و سختی سنگ شوند لجتایی و همکاران، بابت و انیشتین (Lajtai et al., 1990; Bobet and Einstein, 1998). درک رفتار شکست یک توده‌سنگ با انواع ترک‌های مختلف در تراکم یک و دو محوره برای طراحی و ساخت تونل‌های عمیق، شیب‌های سنگی، فونداسیون‌ها، راهروهای معادن زغال سنگ و ... ضروری است لیو و همکاران (Liu et al., 2019).

تاکنون تأثیر پیکربندی‌های مختلف درزه‌ها بر روی رفتار مکانیکی نمونه‌های شبه سنگی تحت سیستم بارگذاری تراکم یک محوره و دو محوره به طور گسترده‌ای مورد مطالعه قرار گرفته است. این مطالعات عمدتاً با انجام تست‌های آزمایشگاهی و در برخی موارد با استفاده از شبیه‌سازی‌های عددی انجام شده است. شن و همکاران (Shen et al., 1995) با اجرای یک سری تست‌های تراکم یک محوره بر روی نمونه‌های شبه سنگی از جنس گچ دارای ۲ درزه موازی، فرآیند رشد، انتشار و همرسی ترک در ناحیه پل سنگ را مطالعه نمودند و تأثیر زاویه درزه‌ها و زاویه پل سنگ را بر روی میزان بار بحرانی لازم جهت همرسی ترک‌ها بررسی کردند. بابت و انیشتین (Bobet and Einstein, 1998) با اجرای تست‌های یک و دو محوره بر روی نمونه‌های گچی دارای ۲ درزه از پیش

موجود (درزه‌های باز و بسته) به مطالعه الگوی همرسی ترک در نمونه‌ها و بررسی تأثیر زاویه درزه‌ها و زاویه پل سنگ بر روی میزان تنش لازم برای رشد ترک‌های باله‌ای و ثانویه پرداختند. ونگ و چو (Wong and Chau, 1998) با انجام تست‌های تراکم یک محوره بر روی نمونه‌های شبه سنگی شامل ۲ درزه موازی دارای اصطکاک با مقادیر زاویه درزه، زاویه پل سنگ و ضرایب اصطکاک سطح درزه مختلف به بررسی الگوی همرسی ترک‌ها و مقاومت نمونه‌ها پرداختند. ونگ و همکاران (Wong et al., 2001) با استفاده از تست‌های تراکم تک محوره به مطالعه الگوی همرسی ترک و مقاومت اوج نمونه‌های شبه سنگی شامل ۳ درزه موازی با سطوح دارای اصطکاک پرداختند. یافته‌های آن‌ها نشان داد که مکانیزم همرسی ترک در نمونه‌ها به نحوه قرارگیری درزه‌ها نسبت به هم و ضریب اصطکاک سطح درزه‌ها وابسته است. سگنگ و بابت (Sagong and Bobet, 2002) با اجرای تست‌های تراکم یک محوره بر روی نمونه‌های گچی شامل چند درزه، به مطالعه مکانیزم انتشار ترک و تنش شروع و همرسی ترک پرداختند. نتایج آزمایش‌های آن‌ها نشان داد که با افزایش زاویه درزه‌ها، فاصله ردیف درزه‌ها از هم و تعداد درزه‌ها تنش لازم برای شروع و همرسی ترک‌ها افزایش می‌یابد. موقیدا و کاراسنه (Mughieda and Karasneh, 2006) با انجام تست‌های دو محوره بر روی نمونه‌های شبه سنگی شامل دو درزه موازی با زاویه درزه داری ثابت ۴۵ درجه، مکانیزم رشد و همرسی ترک را با تغییر زاویه پل سنگ بین دو درزه از ۰ تا ۹۰ درجه به ازای ۳ مقدار متفاوت تنش جانبی (۰/۳۵، ۰/۷ و ۱/۵ مگاپاسکال) مطالعه کردند. مشاهدات آنها نشان داد که در سطوح تنش جانبی کم، ترک‌های باله‌ای در نوک درزه‌ها رشد می‌کنند و سپس با افزایش سطح تنش جانبی، ترک‌های باله‌ای در وسط درزه‌ها نیز نمایان می‌شوند. بعلاوه یافته‌های آن‌ها نشان داد که زاویه پل سنگ مهمترین متغیر کنترل‌کننده مود شکست در نمونه‌ها می‌باشد، بگونه‌ای که به ازای زاویای پل سنگ ۰ و ۹۰ درجه مودهای شکست نمونه به ترتیب برشی و کششی بوده و

به ازای زاویه پل سنگ بین ۰ و ۹۰ درجه مود شکست در نمونه‌ها ترکیبی (برشی-کششی) خواهد بود.

ژوو و همکاران (Zhou et al., 2014) مطالعات آزمایشگاهی‌ای را بر روی نمونه‌های شبه سنگی دارای چند درزه (بیش از دو و یا ۳ درزه) تحت تراکم تک محوره به منظور بررسی اثر درزه‌های از پیش موجود بر روی خصوصیات مکانیکی، مودهای رشد ترک و انواع همرسی ترک انجام دادند. بعلاوه، آن‌ها به بررسی تأثیر طول غیر همپوشانی و زاویه درزه‌ها بر روی منحنی‌های تنش-کرنش، تنش شروع ترک، مقاومت اوج، کرنش اوج و مدول الاستیسیته نمونه‌ها نیز پرداختند. حائری و همکاران (Haeri et al., 2014) به مطالعه فرآیند رشد و انتشار ترک در دیسک‌های برزیلی ساخته شده از سیمان پورتلند، ماسه و آب دارای یک و دو درزه واقع در مرکز دیسک تحت تست‌های آزمایشگاهی و شبیه‌سازی عددی پرداختند. آنها همچنین، تأثیر طول ترک و زاویه قرارگیری آن بر روی همرسی ترک و مسیر شکست نمونه‌ها را بررسی کردند. حائری و همکاران (Haeri et al., 2015) مکانیزم انتشار ترک و همرسی ترک‌های مجاور در نمونه‌های استوانه‌ای دارای چند ترک از پیش موجود را به صورت آزمایشگاهی و عددی بررسی کردند. کائو و همکاران (Cao et al., 2015) مکانیزم رشد، انتشار، همرسی و عکس‌العمل ترک‌های موجود در نمونه‌های سنگی شکننده دارای ۲ و ۳ درزه تحت تست تراکم تک محوره را مطالعه و تأثیر درزه سوم از پیش موجود بر روی فرآیند شکست نمونه‌ها را بررسی کردند. ژانگ و همکاران (Zhang et al., 2015) با استفاده از شبیه‌سازی عددی به مطالعه فرآیند ترک خوردن/همرسی ترک بین دو درزه غیر موازی تحت آزمایش تراکم یک محوره پرداختند. یافته‌های آن‌ها نشان داد که هندسه درزه‌های غیر موازی به شدت بر مسیر رشد ترک‌ها و الگوی به هم پیوستن آن‌ها تأثیر می‌گذارد.

ژائو و همکاران (Zhao et al., 2016) با انجام تست‌های آزمایشگاهی به مطالعه فرآیند ترک خوردن و رفتار تنش-کرنش نمونه‌های شبه سنگی شامل ۲ درزه تحت شرایط بارگذاری فشاری تک محوره پرداختند و دریافته‌اند که نوع همرسی ترک

به هندسه ترک‌ها وابسته بوده و با تغییر زاویه پل سنگ (زاویه بین راستای افق و خط واصل بین نوک‌های داخلی دو ترک) مود همرسی ترک‌ها از حالت برشی به برشی-کششی (ترکیبی) و سپس به کششی تبدیل می‌شود. چنگ و همکاران (Cheng et al., 2016) به صورت آزمایشگاهی رفتار انتشار ترک و رفتار همرسی آن‌ها در نمونه‌های شبه‌سنگی شامل ۳ ترک از پیش موجود را تحت آزمایش تراکم یک محوره بررسی کردند و دریافته‌اند که بازشدگی ترک‌ها به طور قابل توجهی بر روی تنش رشد ترک و مودهای شروع ترک تأثیر گذار است. هوانگ و همکاران (Huang et al., 2016) به صورت آزمایشگاهی به بررسی اثرات دو ترک غیر موازی از پیش موجود (یک ترک افقی و یک ترک زاویه‌دار نسبت به راستای افق) در نمونه‌های استوانه‌ای شبه سنگی بر روی خصوصیات مکانیکی (مقاومت اوج و مدول الاستیسیته) و فرآیند همرسی ترک تحت تست تراکم یک محوره پرداختند. نتایج مطالعات آن‌ها نشان داد که مقادیر مقاومت اوج و مدول الاستیسیته نمونه‌ها در ابتدا با افزایش زاویه ترک مورب از ۰ تا ۱۵ درجه به تدریج کاهش یافته و سپس با افزایش زاویه ترک مورب از ۱۵ درجه تا ۷۵ بتدریج افزایش می‌یابند. تیان و یانگ (Tian and Yang, 2017) با انجام تست‌های آزمایشگاهی تراکم تک محوره و نیز مدلسازی عددی به مطالعه تأثیر زاویه پل سنگ بر روی مقاومت فشاری و مود شکست نمونه‌های شبه سنگی استوانه‌ای دارای ۲ درزه غیر همسطح پر شده پرداختند. نتایج مطالعات آن‌ها نشان داد که با افزایش زاویه پل سنگ از ۳۰ تا ۶۰ درجه مقاومت فشاری نمونه اندکی کاهش می‌یابد و سپس با افزایش زاویه پل سنگ مقاومت فشاری نمونه افزایش می‌یابد تا در زاویه ۱۲۰ درجه به حداکثر مقدار خود می‌رسد. بعلاوه یافته آن‌ها نشان داد که تغییر زاویه پل سنگ تأثیر ناچیزی بر مدول الاستیسیته دارد بگونه‌ای که می‌توان از اثرات آن صرف نظر نمود.

لیو و همکاران (Liu et al., 2019) فرآیند انتشار ترک و نیز رفتار گسیختگی نمونه‌های شبه سنگی دارای ترک‌های متقاطع T-شکل و X-شکل را تحت بارگذاری تراکم دو محوره مطالعه

محلی نزدیک نوک ترک را مطالعه نمودند و به تجزیه و تحلیل رفتار تنش- کرنش مرتبط با شروع، انتشار و همرسی ترک در نمونه‌های شبه سنگی دارای دو درزه تحت تست تراکم دو محوره پرداختند. نتایج مطالعات آن‌ها نشان داد که ۷ نوع ترک پایه‌ای و ۱۰ نوع الگوی همرسی ترک تحت آزمایش‌های تراکم دو محوره بر روی نمونه‌های درزه دار وجود دارند.

لین و همکاران (Lin et al., 2021) فرآیند همرسی ترک در نمونه‌های شبه سنگی دارای دو لایه با خصوصیات مکانیکی متفاوت و دو درزه موازی از پیش موجود در این دو لایه را تحت تست تراکم یک محوره مطالعه نمودند و تأثیر زاویه درزه‌ها و زاویه پل سنگ بر روی رفتار مکانیکی و فرآیند شکست را بررسی کردند. یافته‌های آن‌ها نشان داد که مقاومت اوج نمونه‌ها وابسته به زاویه درزه‌ها و زاویه پل سنگ می‌باشد. لی و همکاران (Li et al., 2021) با انجام تست‌های آزمایشگاهی تراکم تک محوره و شبیه سازی عددی به مطالعه توالی رشد، توسعه و اتصال ترک‌ها و نیز مود شکست نمونه‌های ساخته شده از مواد شبه سنگی دارای ۴ نوع مختلف درزه (درزه‌های موازی و متقاطع) پرداختند. چن و همکاران (Chen et al., 2022) فرآیند رشد و انتشار دو ترک با طول‌های مختلف در نمونه‌های شبه سنگی تحت شرایط بارگذاری تراکم یک محوره را مطالعه و تأثیر طول پل سنگ و زاویه ترک نسبت به راستای بارگذاری را بر روی الگوی همرسی ترک بررسی کردند. آن‌ها دریافتند که به ازای زوایای ۳۰ تا ۶۰ درجه ترک نسبت به راستای بارگذاری، ترک‌های کوچکتر با احتمال بیشتری رشد و انتشار می‌یابند، بعلاوه در بیشتر نمونه‌ها فرآیند ترک خوردن از نوک خارجی ترک بزرگتر شروع شده و نقطه کلیدی ناپایداری ترک، نوک خارجی ترک بزرگتر می‌باشد. لین و همکاران (Lin et al., 2024) تست‌های تراکم یک محوره‌ای را بر روی نمونه‌های متشکل از دو لایه سخت-نرم دارای ۳ درزه موازی (۲ درزه هم صفحه و درزه سوم خارج از صفحه ۲ درزه دیگر) انجام دادند و به مطالعه تأثیر زاویه درزه‌ها، زاویه پل سنگ و موقعیت درزه خارج از صفحه بر رفتار انتشار ترک و مود گسیختگی نمونه‌ها پرداختند. یافته‌های آن‌ها نشان داد که

کردند و مکانیزم تأثیر فشار محصور کننده بر روی رفتار ترک خوردن نمونه‌ها را بررسی نمودند. ژائو و همکاران (Zhao et al., 2019) خصوصیات شکست نمونه‌های شبه سنگی ساخته شده از گچ شامل یک درزه با زوایای قرارگیری مختلف را با انجام تست‌های تراکم یک محوره مورد مطالعه و بررسی قرار دادند. نتایج تحقیقات آن‌ها نشان داد که تنش رشد و مقاومت اوج نمونه‌ها متأثر از زاویه قرارگیری درزه هستند بگونه‌ای که در زاویه ۶۰ درجه پارامترهای مذکور به کمترین مقدار خود می‌رسند. بعلاوه یافته‌های آن‌ها نشان داد که با افزایش زاویه قرارگیری درزه، مود شکست در نمونه‌ها عمدتاً از شکست کششی به برشی تغییر می‌یابد. پن و همکاران (Pan et al., 2019) فرآیند انتشار ترک در نمونه‌های شبه سنگی شامل دو ترک غیر موازی با زوایای قرارگیری متفاوت را تحت تست تراکم یک محوره مطالعه کردند و دریافتند که زاویه درزه تأثیر زیادی بر مقاومت نمونه دارد بگونه‌ای که افزایش زاویه درزه علاوه بر کاهش مقاومت نمونه‌ها فرم شکست اصلی در نمونه‌ها را نیز بتدریج از شکست کششی به برشی تغییر می‌دهد. هوانگ و همکاران (Huang et al., 2019) با انجام تست‌های تراکم تک محوره به صورت آزمایشگاهی و عددی به بررسی تأثیر ۴ پارامتر زاویه قرارگیری درزه‌ها نسبت به افق (α)، فاصله بین ردیف‌های درزه (S)، طول درزه‌ها (L) و طول پل سنگ بین دو درزه ناپیوسته هم صفحه (β) بر روی مقاومت فشاری تک محوره، مدول الاستیسته و فرآیند شکست نمونه‌های شبه سنگی شامل چندین ردیف درزه موازی که در هر ردیف درزه‌ها ناپیوسته هستند، پرداختند. یافته‌های آن‌ها نشان داد که از بین پارامترهای مورد بررسی، زاویه درزه‌داری مهمترین پارامتر تأثیرگذار بر مقاومت فشاری تک محوره و مدول الاستیسته نمونه‌ها می‌باشد. وانگ و همکاران (Wang et al., 2020) به مطالعه انتشار و همرسی ترک در نمونه‌های شبه سنگی با دو درزه از پیش موجود تحت تست‌های آزمایشگاهی تراکم دو محوره پرداختند و تأثیر زاویه ترک، زاویه پل سنگ و تنش جانبی بر پروسه رشد ترک را بررسی نمودند. ژائو و همکاران (Zhao et al., 2020) الگوهای همرسی ترک و رفتار کرنش

(O'Donnell, 2020). به علاوه، ویژگی ثبات نتایج در اجرای مکرر، SVM را به گزینه‌ای مناسب‌تر نسبت به روش‌های دیگری مانند شبکه‌های عصبی مصنوعی (ANN) تبدیل می‌کند، که معمولاً به دلیل وابستگی به تعداد زیادی آبر پارامتر و تغییرپذیری بالا در نتایج، چالش‌برانگیز هستند.

در کنار آن، الگوریتم RF به دلیل ساختار خاص خود که شامل ترکیب تعداد زیادی درخت تصمیم است، دقت بالایی در پیش‌بینی داده‌های پیچیده ارائه می‌دهد. این الگوریتم به خوبی می‌تواند داده‌های غیرخطی و تعاملات پیچیده بین پارامترها را مدیریت کند. همچنین، استفاده از روش بوت استرپ باعث می‌شود تخمین‌های داخلی قابل اعتماد و تقریباً بی‌طرفانه‌ای از عملکرد الگوریتم فراهم شود. سترویل و همکاران؛ بوسکرک (Strobl et al., 2007; Buskirk 2018). RF برخلاف روش‌های ساده‌تری مانند درخت تصمیم (DT) که تنها از یک درخت در مدل‌سازی استفاده می‌کند، با بهره‌گیری از تعداد زیادی درخت به دقت بالاتری دست پیدا می‌کند.

به‌طور کلی، انتخاب الگوریتم‌های RF و SVM در مقایسه با روش‌هایی مانند ANN و نزدیکترین همسایه (KNN) بر اساس مزایای قابل توجه آنها صورت گرفته است. ANN به دلیل نیاز به تنظیم تعداد زیادی از پارامترها (مانند تعداد لایه‌ها و نرون‌ها، نوع تابع فعال‌ساز و ...) و عدم اطمینان از تنظیمات بهینه، در این مطالعه مورد استفاده قرار نمی‌گیرد. همچنین، ANN در هر اجرای مجدد ممکن است نتایج متفاوتی تولید کند، در حالی که SVM با تعداد کمتر آبر پارامتر و ثبات بیشتر، این محدودیت‌ها را ندارد. KNN با وجود سادگی، به دلیل حساسیت زیاد به نویز و داده‌های پرت و همچنین کاهش کارایی در داده‌های با ابعاد بالا، کنار گذاشته شد.

در نهایت، علاوه بر الگوریتم‌های RF و SVM ترکیب این دو نیز به دلیل توانایی‌های مکمل آن‌ها در مدیریت داده‌های پیچیده و امکان ارائه پیش‌بینی‌های دقیق‌تر، مورد بررسی و استفاده قرار گرفت. الگوریتم ترکیبی RF-SVM با کاهش محدودیت‌های روش‌های دیگر و بهره‌مندی از قابلیت‌های پیشرفته RF و

همرسی پل سنگ در لایه دارای ۲ درزه، متأثر از زاویه پل سنگ و مقاومت نسبی لایه است.

در بیشتر تحقیقات قبلی تأثیر زاویه درزه، زاویه پل سنگ و طول پل سنگ و در تعداد معدودی از آن‌ها اثر پارمترهای طول درزه و فشار محصور کننده نیز بر فرآیند رشد و همرسی ترک (مودهای همرسی) و میزان بار بحرانی لازم برای این همرسی و در نتیجه شکست نمونه (یعنی مقاومت نمونه‌ها)، تحت آزمایش تراکم مورد بررسی قرار گرفته‌اند. با این وجود، در کلیه تحقیقات قبلی به غیر از لین و همکاران (Lin et al., 2024) به دلیل ثابت بودن خصوصیات مکانیکی نمونه‌های تحت آزمایش، اثر این دسته از پارامترها (مقاومت فشاری و کششی، مدول الاستیسیته، مقاومت چسبندگی، نسبت پواسون و زاویه اصطکاک داخلی) بر روی مود همرسی ترک و مقاومت اوج نمونه، بررسی نشده‌اند. همچنین، از آنجایی که استفاده از نتایج آزمایشگاهی برای بررسی (در نظر گرفتن) اثرات همزمان پارامترهای تأثیر گذار بر مود همرسی ترک و مقاومت اوج نمونه کار دشواری است، بنابراین، در این مقاله ابتدا با توجه به نتایج ۷۵۶ آزمایش تراکم یک و دو محوره انجام شده بر روی نمونه‌هایی با ۳ نوع خصوصیات مکانیکی مختلف که در آن‌ها تعداد درزه، زاویه قرارگیری درزه نسبت به راستای افق، ضریب درزه‌داری و فشار محصور کننده متفاوت هستند، نوع مودهای همرسی ترک، تعیین و مقاومت نمونه‌های تحت آزمایش محاسبه گردید. سپس با بکارگیری دو الگوریتم یادگیری ماشین به پیش‌بینی نوع مود همرسی ترک در نمونه‌های تحت آزمایش و مقاومت آن‌ها پراخته می‌شود. در این مطالعه، الگوریتم‌های SVM و RF به دلیل ویژگی‌های منحصر به فرد و توانایی‌هایشان در پیش‌بینی ویژگی‌های مکانیکی مواد شبه سنگی انتخاب شدند. SVM، با استفاده از توابع کرنل، امکان تبدیل مسائل پیچیده و غیرخطی به فضای خطی را فراهم می‌کند و از دقت بالایی در پیش‌بینی برخوردار است. این الگوریتم نسبت به ابعاد داده‌های ورودی حساس نیست و در مدیریت داده‌های با ابعاد بالا عملکرد خوبی دارد. عواد و همکاران؛ ژانگ و ادانل (Awad et al., 2015; Zhang and

روش‌های درخت، پایه روش‌های آماری ناپارامتری (مدل آزاد) برای اجرای آنالیز طبقه‌بندی و آنالیز رگرسیونی با استفاده از الگوریتم افراهای بازگشتی می‌باشند (Hastie et al., 2017). جنگل‌های تصادفی یک نوع مدرن از درخت پایه هستند که شامل انبوهی از درخت‌های کلاس‌بندی و رگرسیونی می‌باشند (Breiman, 2001). مهمترین ویژگی جنگل‌های تصادفی عملکرد بالای آن‌ها در اندازه‌گیری اهمیت متغیرها برای مشخص کردن نقش هر متغیر در پیش‌بینی پاسخ است. این الگوریتم در واقع یک الحاقی از درخت رگرسیونی و طبقه‌بندی است که اولین بار توسط بریمان (Breiman, 2001) ایجاد و توسعه داده شد. الگوریتم جنگل تصادفی مبتنی بر دسته‌ای از درخت‌های تصمیم است و در حال حاضر یکی از بهترین الگوریتم‌های یادگیری می‌باشد. مدل پیش‌بینی کننده RF براساس میانگین‌گیری از نتایج حاصل از تمامی درخت‌های تصمیم مربوطه استوار است و برای بسیاری از مجموعه داده‌ها، طبقه‌بندی را با صحت بالایی انجام می‌دهد (ابراهیم خانی و همکاران، ۱۳۹۰؛ فرشاد و همکاران، ۱۳۹۲). جنگل تصادفی درخت تصمیم‌های زیادی تولید می‌کند. برای طبقه‌بندی یک شیء جدید بردار ورودی در انتهای هر یک از درختان جنگل تصادفی قرار می‌گیرد و سپس هر درخت به یک طبقه‌بندی منجر می‌شود که اصلاً گفته می‌شود این درخت به آن کلاس رأی می‌دهد. جنگل حاصل از طبقه‌بندی‌ای که بیشترین رأی را داشته باشد انتخاب می‌شود. در الگوریتم جنگل تصادفی نرخ خطا به: الف) همبستگی بین هر دو درخت در جنگل و ب) قدرت هر یک از درختان بستگی دارد. افزایش همبستگی، نرخ خطای جنگل را افزایش می‌دهد، در حالی که افزایش قدرت هر یک از درختان نرخ خطای جنگل را کاهش می‌دهد (Breiman, 2001; Hastie et al., 2017). در الگوریتم جنگل تصادفی دو پارامتر مهم m و n وجود دارند که به ترتیب نشان‌دهنده تعداد متغیرها در زیرمجموعه تصادفی در هر گره و تعداد درختان هستند که باید بهینه شوند (Hastie et al., 2017;)

SVM در یادگیری داده‌ها، گزینه بسیار مناسبی برای پیش‌بینی پارامترهای هدف در مطالعه حاضر بود.

۲. مواد و روش‌ها

در این بخش به معرفی و نحوه عملکرد مدل رگرسیون خطی چندگانه و الگوریتم‌های یادگیری جنگل تصادفی و ماشین بردار پشتیبان به منظور پیش‌بینی مقاومت و مود همرسی ترک مربوط به نمونه‌های شبه سنگی پرداخته می‌شود. همچنین، فرآیند اعتبارسنجی متقاطع و برخی شاخص‌های ارزیابی عملکرد مورد استفاده در این مطالعه معرفی می‌گردند.

۱-۲. رگرسیون خطی چندگانه (MLR)

رگرسیون خطی چندگانه، یک تکنیک قدیمی است که به استفاده پیرسون از آن در سال ۱۹۰۸ برمی‌گردد. این تکنیک برای محاسبه (پیش‌بینی) واریانس در یک بازه وابسته، بر اساس ترکیب‌های خطی متغیرهای مستقل بازه‌ای^۱، دوگانه^۲ و ساختگی^۳ استفاده می‌شود. هدف کلی رگرسیون خطی چندگانه کسب اطلاعات بیشتر در مورد رابطه بین چندین متغیر مستقل یا پیش‌بینی کننده و یک متغیر وابسته یا معیار است. معادله رگرسیون خطی چندگانه به صورت رابطه (۲) می‌باشد (Yilmaz and Kaynar, 2011):

$$y = b_1x_1 + b_2x_2 + \dots + b_nx_n + c \quad (1)$$

b_1, b_2, \dots و b_n ضرایب رگرسیون هستند که مقدار تغییرات متغیر وابسته y زمانیکه متغیر مستقل مربوطه به اندازه ۱ واحد تغییر می‌کند را نشان می‌دهند. ثابت c عرض از مبدأ خط رگرسیونی می‌باشد که در واقع مقدار y را زمانی که متغیرهای مستقل برابر صفر هستند نشان می‌دهد (Yilmaz and Kaynar, 2011).

۲-۲. الگوریتم جنگل تصادفی (RF)

$$R(f) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n L(f(x_i) - y_i) \quad (۳)$$

در رابطه (۳)، $|w|$ تابع نرم و C متغیر منظم ساز می‌باشند. بعلاوه، L تابع هزینه است که توسط وپنیک (Vapnik, 1999) به شرح زیر پیشنهاد شده است:

$$L(f(x_i) - y_i) = \begin{cases} 0 & \text{if } |y - f(x)| \leq \epsilon \\ |f(x) - y| - \epsilon & \text{otherwise} \end{cases} \quad (۴)$$

در رابطه (۴)، پارامتر ϵ شعاع یا حاشیه خطا در اطراف داده‌های آموزشی می‌باشد. توضیحات بیشتر در رابطه با مراحل مدل‌سازی ریاضی ماشین بردار پشتیبان را می‌توان در بسیاری از مقالات بدست آورد (Armaghani et al., 2020; Rad et al., 2018; Shi et al., 2012; Zhou et al., 2012 and 2021).

مهمترین توابع کرنل مورد استفاده در الگوریتم ماشین بردار پشتیبان عبارتند از: خطی، چند جمله‌ای، تابع پایه شعاعی (RBF) و سیگموئیدی. رابطه (۵) معادله تابع کرنل RBF را نشان می‌دهد:

$$K(x_i, x_j) = \exp\left(-|x_i - x_j|^2 / 2\sigma^2\right), \sigma > 0 \quad (۵)$$

x_i و x_j بردارهای ورودی هستند. پارامتر σ شکل مرز تصمیم را کنترل و به علاوه انعطاف‌پذیری مدل و میزان بیش‌برازش یا کم‌برازش داده‌های آموزشی را تعیین می‌نماید. در کرنل چند جمله‌ای، متناظر با پارامتر σ کرنل RBF، از آبر پارامتر d که نشان دهنده توان جمله‌ای است، استفاده می‌شود. بنابراین، C ، ϵ و σ یا d آبر پارامترهای اصلی در الگوریتم ماشین بردار پشتیبان هستند که به منظور دستیابی به جواب مناسب برای الگوریتم، مقادیر بهینه آن‌ها از تکنیک جستجوی شبکه‌ای تعیین خواهد شد.

۲-۴. اعتبارسنجی متقاطع k -fold

به طور کلی، در هر روش یادگیری ماشین کل مجموعه داده‌ها برای ساخت مدل و آزمودن عملکرد آن به دو بخش آموزش و تست تقسیم می‌شود. ساده‌ترین راه برای تقسیم یک مجموعه داده بر اساس نسبت‌هایی مانند 70% - 30% برای آموزش و 30% - 70% برای تست است. با این حال، یک پایگاه داده با اندازه کوچک ممکن است این روش را برای استفاده کامل از نمونه‌های داده محدود کند. بنابراین، نحوه تقسیم مجموعه

(Zhou et al., 2016). پارامتر $mtry$ تابعی از تعداد ورودی‌ها می‌باشد و معمولاً مقدار آن برابر با جذر تعداد ورودی‌ها در نظر گرفته می‌شود (Zhou et al., 2016) همچنین، در حالت کلی هر اندازه تعداد درختان ($ntree$) بزرگتر باشد، پیش‌بینی از دقت بالاتری برخوردار است. با این حال، نمی‌توان مقادیر مشخصی را برای پارامترهای $mtry$ و $ntree$ در نظر گرفت. مقادیر بهینه این پارامترها، منجر به افزایش دقت و کاهش خطای مدل می‌شود. بنابراین، در این مقاله، به منظور دستیابی به مقادیر بهینه $mtry$ و $ntree$ از تکنیک جستجوی شبکه‌ای، استفاده می‌شود.

۲-۳. ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یکی از الگوریتم‌های یادگیری ماشین بنا شده بر تئوری یادگیری آماری و مبتنی بر کرنل است که اولین بار توسط وپنیک (Vapnik, 1995) ارائه شد. این الگوریتم به طور گسترده‌ای برای حل مسائل رگرسیون و طبقه‌بندی در حوزه‌های مختلف مهندسی معدن از جمله انفجار، تونلسازی، پرتاب سنگ و ... مورد استفاده قرار گرفته است (Armaghani et al., 2020; Rad et al., 2018; Shi et al., 2012; Zhou et al., 2012 and 2021). هدف در این الگوریتم جداسازی کلاس‌های مختلف داده در فضا با یک خط یا یک ابر صفحه می‌باشد. با این وجود در بسیاری از مسائل، جداسازی داده‌ها با یک خط (یا صفحه) امکان‌پذیر نمی‌باشد. بنابراین در چنین حالتی، داده‌ها به فضایی با ابعاد بالاتر نگاشت پیدا می‌کنند تا بتوان آن‌ها را در یک فضای جدید بصورت خطی جدا نمود. عمل نگاشت داده‌های ورودی توسط یک تابع خطی که به آن تابع کرنل گفته می‌شود، از فضای اصلی به فضای با ابعاد بالاتر صورت می‌گیرد. تابع پیش‌بینی الگوریتم ماشین بردار پشتیبان، تابع خطی است که در زیر نشان داده شده است (Rad et al., 2018):

$$f(x) = \sum (a_i - a_i^*) K(x_i, x) + b \quad (۲)$$

در رابطه فوق b انحراف پیش‌بینی رگرسیون، a_i ضریب لاگرانژ و K تابع کرنل است. با کمینه کردن یک تابع تنظیم شده، ضرایب لاگرانژ به صورت زیر ایجاد می‌شوند:

۱، صفر و صفر دقت آن افزایش می‌یابد. مقادیر شاخص‌های فوق را می‌توان با استفاده از روابط (۶) تا (۹) بدست آورد (Zhou et al., 2012 and 2016):

$$R^2 = 1 - \frac{\sum_{i=1}^N (M_i - P_i)^2}{\sum_{i=1}^N (M_i - M_{\text{mean}})^2} \quad (6)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (M_i - P_i)^2} \quad (7)$$

$$\text{MAE} = \frac{\sum_{i=1}^N |M_i - P_i|}{N} \quad (8)$$

$$\text{OA} = \frac{N_c}{N} \quad (9)$$

در روابط فوق M_i و P_i به ترتیب مقادیر مقاومت اندازه‌گیری شده و پیش‌بینی شده نمونه‌ها و M_{mean} میانگین مقادیر اندازه‌گیری شده مقاومت آن‌ها می‌باشند. همچنین، N_c و N به ترتیب بیانگر تعداد کل نمونه‌ها (دسته داده‌ها) و تعداد نمونه‌های به درستی طبقه‌بندی شده هستند.

۳. آماده‌سازی نمونه‌ها و اجرای آزمایش‌های تراکم

به منظور پیش‌بینی مود شکست و مقاومت محوری (تنش محوری لازم جهت هم‌رسی ترک و شکست نمونه) نمونه‌های دارای درزه‌های ناممتد تحت شرایط آزمایش تراکم یک محوره (فشار محصور کننده برابر صفر) و دو محوره (فشار محصور کننده غیر صفر)، فاکتورهای تأثیرگذار بر مود شکست باید تعیین شوند. به منظور نیل به این هدف، در این مطالعه ابتدا ۷۵۶ آزمایش تراکم یک و دو محوره بر روی نمونه‌های ساخته شده از ترکیب‌های مختلف آب و گچ، دارای درزه‌های ناممتد انجام شد. شکل ۱ برخی از نمونه‌های مورد استفاده جهت اجرای آزمایش تراکم را نشان می‌دهد. همانطور که مشاهده می‌شود، نمونه‌های ساخته شده دارای ۱، ۲ و ۳ درزه هستند. طول درزه در نمونه دارای ۱ درزه، مجموع طول ۲ درزه در نمونه دارای ۲ درزه و مجموع طول ۳ درزه در نمونه دارای ۳ درزه با هم برابرند. به علاوه در نمونه‌های دارای ۲ و ۳ درزه، درزه‌ها هم صفحه هستند. از طرفی برای هر نمونه با تعداد مشخص درزه و خصوصیات مکانیکی ثابت، درزه‌های ایجاد شده دارای ۴ زاویه قرارگیری مختلف ۰، ۳۰، ۶۰ و ۹۰ درجه نسبت به راستای افقی (راستای اعمال فشار محصور کننده)

داده‌ها به طور قابل توجهی بر ساخت و اعتبار مدل تأثیر می‌گذارد. از سوی دیگر در کلیه روش‌های یادگیری ماشین، الگوریتم یادگیری براساس داده‌های مرحله آموزش به یادگیری روابط بین پارامترهای ورودی و پارامتر خروجی می‌پردازد و از این طریق مدلی ساخته می‌شود که با بکارگیری آن می‌توان برای دسته داده‌های جدید (داده‌های تست) مقادیر خروجی را پیش‌بینی نمود. با این حال مدل ساخته شده براساس داده‌های آموزش همیشه نمی‌تواند قابلیت تعمیم‌پذیری و اعتبار خوبی داشته باشد و عملکرد آن ممکن است برای داده‌های تست، مناسب نباشد. به همین دلیل، برای حل این مشکل از روش‌های اعتبارسنجی متقاطع مانند k-fold به عنوان یک ابزار قدرتمند استفاده می‌شود. در روش اعتبارسنجی متقاطع k-fold، برای ساخت مدل مجموعه داده‌های آموزش ابتدا به طور تصادفی به k زیر مجموعه تقسیم می‌شوند. سپس، k-1 زیر مجموعه از آن برای آموزش و بقیه به عنوان داده اعتبارسنجی استفاده می‌شوند. در طول این روش، فرآیند اعتبارسنجی k بار تکرار می‌شود و در نهایت عملکرد مدل با میانگین خطای پیش‌بینی k زیر مجموعه، ارزیابی می‌گردد. مدل ساخته شده از این طریق دارای قابلیت تعمیم‌پذیری بیشتر بوده و می‌توان آن را با اطمینان بیشتری بکار گرفت.

۲-۵. شاخص‌های آماری ارزیابی عملکرد

شاخص‌های آماری ارزیابی عملکرد معمولاً برای مقایسه دقت و سنجش کارایی مدل‌های مختلف مورد استفاده قرار می‌گیرند. در این مقاله از ۴ شاخص آماری ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE)، خطای مطلق میانگین (MAE) و صحت کلی (OA) استفاده خواهد شد. ۳ شاخص اول برای مسائل رگرسیونی و شاخص آخر برای مسائل طبقه‌بندی بکار گرفته می‌شوند. صحت کلی بیانگر آن است که از تمامی کلاس‌ها چند مورد به درستی طبقه‌بندی شده‌اند. مقادیر R^2 و OA بین صفر و ۱ قرار دارد. مقادیر RMSE و MAE همواره بزرگتر یا مساوی صفر هستند. در یک مدل، با نزدیک شدن مقادیر شاخص‌های R^2 ، OA، RMSE و MAE به ترتیب به ۱،

نمونه‌ای مشابه با تعداد درزه کمتر ولی طول درزه بزرگتر، مقاومت بیشتری دارد.

ب) برای یک نمونه با خصوصیات مکانیکی، فشار محصور کننده (σ_n)، تعداد درزه (N) و زاویه قرارگیری درزه‌ها نسبت به راستای افق (β) ثابت، تغییر ضریب درزه‌داری (J_C) تأثیری بر درصد مودهای کششی (η) و برشی (δ) ندارد. این در حالی است که با افزایش J_C ، و ثابت بودن کلیه پارامترهای دیگر، مقاومت محوری نمونه‌ها کاهش می‌یابد.

ج) برای نمونه‌هایی مورد آزمایش در این مطالعه با تعداد درزه (N) و زاویه درزه‌داری (β) ثابت و خصوصیات مکانیکی و فشار محصور کننده مختلف (σ_n)، روابط ۶ گانه زیر بین درصد مودهای کششی (η) و برشی (δ) در فرآیند شکست نمونه‌ها برقرار است (مشاهده می‌شود):

$$\begin{aligned} \eta(\sigma_c: 8MPa, \sigma_n: 0MPa) &= \\ \eta(\sigma_c: 18MPa, \sigma_n: 0MPa) &= \\ \eta(\sigma_c: 30MPa, \sigma_n: 0MPa) & \end{aligned} \quad (10)$$

$$\begin{aligned} \eta(\sigma_c: 8MPa, \sigma_n: 0.5MPa) &= \\ \eta(\sigma_c: 18MPa, \sigma_n: 3MPa) &= \\ \eta(\sigma_c: 30MPa, \sigma_n: 4MPa) & \end{aligned} \quad (11)$$

$$\begin{aligned} \eta(\sigma_c: 8MPa, \sigma_n: 2MPa) &= \\ \eta(\sigma_c: 18MPa, \sigma_n: 8MPa) &= \\ \eta(\sigma_c: 30MPa, \sigma_n: 13MPa) & \end{aligned} \quad (12)$$

$$\begin{aligned} \delta(\sigma_c: 8MPa, \sigma_n: 0MPa) &= \\ \delta(\sigma_c: 18MPa, \sigma_n: 0MPa) &= \\ \delta(\sigma_c: 30MPa, \sigma_n: 0MPa) & \end{aligned} \quad (13)$$

$$\begin{aligned} \delta(\sigma_c: 8MPa, \sigma_n: 0.5MPa) &= \\ \delta(\sigma_c: 18MPa, \sigma_n: 3MPa) &= \\ \delta(\sigma_c: 30MPa, \sigma_n: 4MPa) & \end{aligned} \quad (14)$$

$$\begin{aligned} \delta(\sigma_c: 8MPa, \sigma_n: 2MPa) &= \\ \delta(\sigma_c: 18MPa, \sigma_n: 8MPa) &= \\ \delta(\sigma_c: 30MPa, \sigma_n: 13MPa) & \end{aligned} \quad (15)$$

جدول ۳ درصد مودهای شکست کششی (η) و برشی (δ) مشاهده شده در فرآیند همرسی ترک مربوط به نمونه‌های آزمایش شده با خصوصیات مکانیکی نوع ۱ را به ازای مقادیر مختلف پارامترهای N ، β و σ_n نشان می‌دهد. با دقت در این جدول می‌توان مود شکست نمونه‌های (مود همرسی ترک در نمونه‌ها) مورد آزمایش را با توجه به درصد مودهای کششی (η) و برشی (δ) به صورت زیر تقسیم‌بندی نمود:

هستند. برای ساخت نمونه‌ها درصدهای مختلف گچ و آب با یکدیگر ترکیب و بر این اساس ۳ نوع نمونه با خصوصیات مکانیکی متفاوت (σ_c ، σ_t ، σ_e ، σ_u ، E ، C و $\tan\phi$) که در جدول ۱ گزارش شده است، تهیه گردید.

قبل از اجرای آزمایش بر روی نمونه‌ها، برای تعیین شرایط فشار بهینه ابتدا آزمایش فشاری تک‌محوره بر روی هر دو نمونه دارای یک شکاف و نمونه دارای سه شکاف انجام شد. سپس، با میانگین‌گیری از نتایج این دو آزمایش، فشار بهینه به دست آمد. نحوه اجرای آزمایش تراکم به این صورت بود که برای هر نوع نمونه با تعداد درزه (N)، زاویه قرارگیری درزه نسبت به راستای افق (β)، و خصوصیات مکانیکی مشخص و نیز به ازای یک فشار محصورکننده معین اعمالی به نمونه (با توجه به مقاومت نمونه)، بتدریج بار محوری به نمونه با سرعت 0.05 mm/min اعمال شد و مقدار آن تا ایجاد ترک‌های کششی و برشی در نمونه و همرسی آن‌ها و درنهایت شکست نمونه افزایش یافت. مقادیر فشارهای محصور کننده اعمالی به هر نوع نمونه با خصوصیات مکانیکی معین، در جدول ۲ آورده شده است. همچنین به ازای یک مقدار فشار محصورکننده ثابت اعمالی به یک نوع نمونه، مقدار ضریب درزه‌داری (J_C) ابتدا 0.1 بوده و سپس با گام 0.1 تا رسیدن به مقدار نهایی 0.7 افزایش یافت. در نهایت نتایج آزمایش‌های انجام شده نشان داد که:

الف) برای یک نمونه با خصوصیات مکانیکی معین (مطابق جدول ۱)، با افزایش هر یک از پارامترهای فشار محصور کننده (σ_n)، تعداد درزه‌ها (N) و زاویه قرارگیری درزه‌ها نسبت به راستای افق (β) و ثابت نگه داشتن دیگر پارامترها، درصد مود کششی (η)، درصد مود برشی (δ) و مقاومت محوری نمونه‌ها به ترتیب کاهش، افزایش و افزایش می‌یابند. با توجه به نتیجه بدست آمده مربوط به اثر تعداد درزه‌ها (N) و با در نظر گرفتن این نکته که در نمونه‌های مورد آزمایش با تغییر تعداد درزه‌ها (N) مجموع طول آن‌ها ثابت است، می‌توان اظهار نمود که یک نمونه با تعداد درزه بیشتر و طول درزه کوچکتر نسبت به

الف) اگر $\eta=100$ و $\delta=0$ باشد آنگاه مود شکست نمونه، مود کششی باله‌ای (I) خواهد بود،
 ب) اگر $\eta=0$ و $\delta=100$ باشد آنگاه مود شکست نمونه، مود برشی (II) خواهد بود،
 ج) اگر η و δ اعدادی بین ۰ و ۱۰۰ باشند (نامساوی ۰ و ۱۰۰) بگونه‌ای که مجموع آنها برابر ۱۰۰ درصد باشد آنگاه مود شکست نمونه، مود ترکیبی (I-II) خواهد بود

زاویه قرارگیری درزه نسبت به راستای افق (درجه)


الف) $\beta = 0$

ب) $\beta = 30$


ج) $\beta = 60$

د) $\beta = 90$


نمونه‌های دارای ۱ درزه



نمونه‌های دارای ۲ درزه هم‌صفحه



نمونه‌های دارای ۳ درزه هم‌صفحه



شکل ۱. الگوی شکست در نمونه‌های دارای ۱، ۲ و ۳ درزه با زوایای قرارگیری درزه‌ها نسبت به راستای افق به ترتیب برابر با الف) ۰، ب) ۳۰، ج) ۶۰ و د) ۹۰ درجه.

جدول ۱. خصوصیات مکانیکی و هندسی ۳ نوع مختلف نمونه شبه سنگی درزه‌دار تحت آزمایش تراکم یک و دو محوره .

Mechanical properties	σ_c (MPa)	σ_t (MPa)	E (GPa)	ν (-)	C (MPa)	$\tan(\phi)$
Specimens						
Type 1	8	0.5	6.3	0.17	2.5	0.45
Type 2	18	1.1	13	0.18	6	0.55
Type 3	30	3.5	19	0.20	11	0.62

جدول ۲. میزان فشار محصورکننده اعمالی به نمونه براساس خصوصیات مکانیکی آن.

Mechanical properties	Type 1	Type 2	Type 3
Confining pressure (MPa)	0, 0.5, 2	0, 3, 8	0, 4, 13

جدول ۳. درصد مودهای شکست کششی (η) و برشی (δ) در مکانیزیم هم‌رسی ترک در نمونه‌های ساخته شده از مواد با خصوصیات مکانیکی نوع ۱ به ازای مقادیر مختلف N ، β ، و σ_n .

dip angle (°)		0			30			60			90		
Confining pressure (MPa)		0	0.5	2	0	0.5	2	0	0.5	2	0	0.5	2
Number of joints = 1	Tensile mode percentage	100	70	0	100	50	0	100	30	0	100	15	0
	Shear mode percentage	0	30	100	0	50	100	0	70	100	0	85	100
Number of joints = 2	Tensile mode percentage	95	60	0	90	40	0	85	20	0	75	5	0
	Shear mode percentage	5	40	100	10	60	100	15	80	100	25	95	100
Number of joints = 3	Tensile mode percentage	85	50	0	75	30	0	65	15	0	60	2.5	0
	Shear mode percentage	15	50	100	25	70	100	35	85	100	40	97.5	100

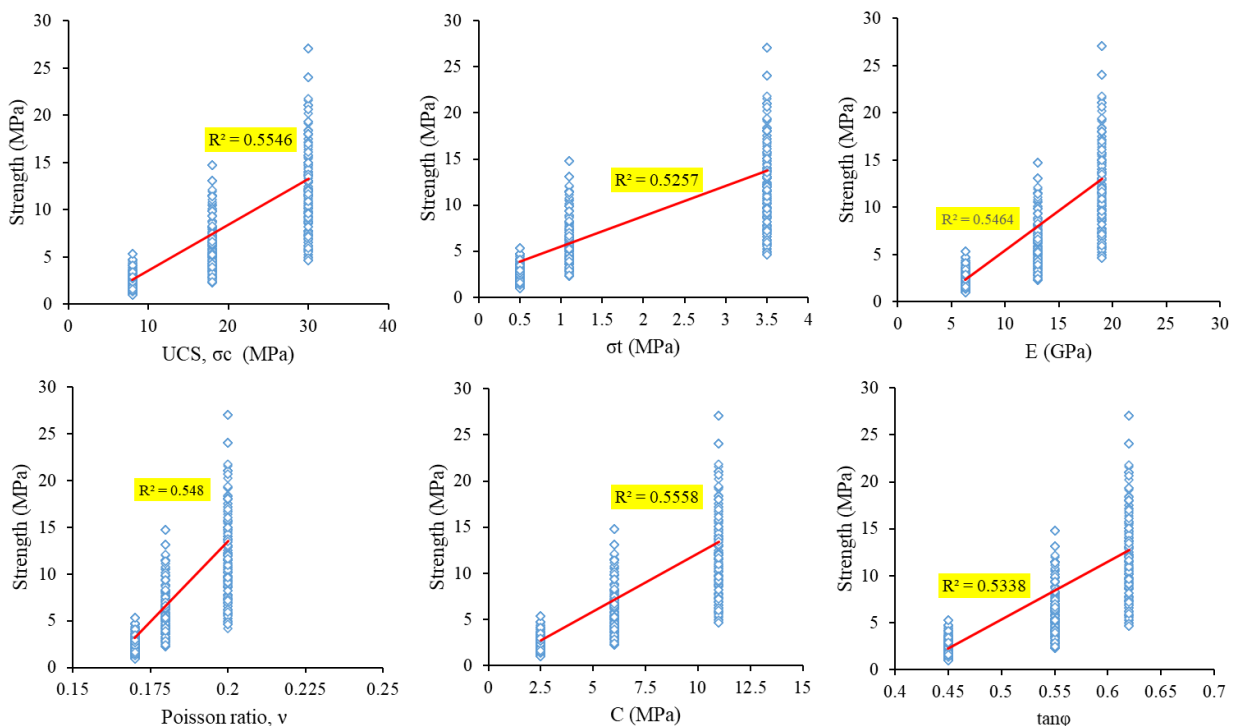
مودهای شکست (δ و η) با توجه به نتایج آزمایش‌ها بدست آمد که در بخش ۳ (روابط ۱ تا ۶ و جدول ۳) به آن پرداخته شد. در نهایت براساس خصوصیات مکانیکی نمونه‌ها، فشار محصورکننده و درصد مودهای شکست، با استفاده از رابطه (۱۶) مقاومت نمونه‌ها در هر آزمایش محاسبه شد.

$$S = 0.9[C + \eta\sigma_t + \delta(C + \sigma_n \tan \varphi)] \quad (16)$$

پارامترهای موجود در رابطه فوق قبلاً بیان شده‌اند. پس از محاسبه مقاومت نمونه‌ها (S)، پایگاه داده مناسب شامل ۷۵۶ دسته داده به منظور پیش‌بینی مقاومت محوری و مود هم‌رسی ترک، تهیه گردید. همچنین، در شکل ۲ رابطه بین خصوصیات مکانیکی نمونه‌ها و مقاومت آن‌ها به تصویر کشیده شده است. با توجه به این شکل می‌توان دریافت که به‌طور کلی با افزایش خصوصیات مکانیکی نمونه‌ها، مقاومت آن‌ها نیز افزایش می‌یابد

۴. استخراج مقاومت نمونه‌ها (تنش لازم برای هم‌رسی ترک)

در بخش ۳ به مراحل انجام آزمایش و نتایج بدست آمده و در نهایت مود هم‌رسی ترک‌های ایجاد شده در نمونه‌های تحت آزمایش پرداخته شد. از آنجاییکه هدف اصلی این تحقیق پیش‌بینی مقاومت نمونه‌های تحت آزمایش تراکم یک و دو محوره (تنش به هم پیوستن ترک) و مود شکست آن‌ها (مود هم‌رسی ترک‌ها)، با استفاده از دو الگوریتم یادگیری جنگل تصادفی (RF) و ماشین بردار پشتیبان (SVM) می‌باشد، لذا در این بخش به نحوه استخراج مقاومت نمونه‌ها پرداخته می‌شود. از طرفی تأثیر خصوصیات مکانیکی نمونه‌ها، فشار محصورکننده (σ_n)، تعداد درزه‌های موجود در نمونه (N)، زاویه قرارگیری درزه‌ها نسبت به راستای افق (β) و ضریب درزه‌داری (JC) بر مقاومت نمونه (S)، به صورت درصدی از مودهای شکست ممکن در نمونه (η): درصد مود شکست کششی و δ : درصد مود شکست برشی، ظاهر می‌شوند. مقادیر درصد



شکل ۲. رابطه بین خصوصیات مکانیکی نمونه‌های شبه سنگی (پارامترهای ورودی) و مقاومت آن‌ها.

۵. پیش‌بینی مقاومت و مود همرسی ترک

در این بخش به پیش‌بینی مقاومت و مود همرسی ترک در نمونه‌های مورد آزمایش با استفاده از الگوریتم‌های RF، SVM، RF-SVM پرداخته می‌شود. الگوریتم‌های RF و SVM مورد استفاده در این مقاله قابلیت حل مسائل رگرسیون و طبقه‌بندی که دو مسئله اصلی پیش‌بینی هستند، را دارا می‌باشند. از آنجاییکه مقاومت نمونه‌ها مقادیری عددی هستند، لذا برای پیش‌بینی آن از ویژگی رگرسیون دو الگوریتم استفاده می‌شود. در نقطه مقابل، مقادیر مودهای همرسی ترک (مود کششی I، مود برشی II و مود ترکیبی I-II) مشاهده شده پس از اجرای آزمایش‌ها، مقادیری غیر عددی می‌باشند و لذا نمی‌توان برای پیش‌بینی این مقادیر غیر عددی از ویژگی رگرسیون دو الگوریتم RF و SVM استفاده کرد و در نتیجه باید از ویژگی طبقه‌بندی آن‌ها استفاده شود. بدین منظور، در این مقاله، از اعداد ۱، ۰ و -۱ به عنوان برچسب‌هایی که به ترتیب نماینده مودهای

همرسی ترک کششی (I)، برشی (II) و ترکیبی (I-II) هستند استفاده شد و سپس الگوریتم‌های مذکور با ویژگی طبقه‌بندی اجرا می‌شوند. در این مطالعه از تکنیک جستجوی شبکه‌ای برای دستیابی به مقادیر بهینه آبر پارامترهای RF و SVM استفاده شد. در جدول ۴ مقادیر آبر پارامترهای مورد استفاده در فرآیند جستجوی شبکه‌ای ارائه شده است. همچنین، از روش اعتبارسنجی مقاطع ۱۰-fold در فرآیند آموزش RF، SVM و RF-SVM استفاده گردید.

به منظور بررسی و مقایسه عملکرد الگوریتم‌های مورد استفاده، از مدل رگرسیون خطی چندگانه (MLR) نیز استفاده و رابطه‌ای جهت برآورد مقاومت نمونه‌ها ارائه می‌گردد. لازم به ذکر است که از MLR نمی‌توان به منظور برآورد مودهای همرسی ترک و ارائه رابطه‌ای برای آن به دلیل غیر عددی بودن این پارامتر استفاده نمود و لذا برای پیش‌بینی آن از الگوریتم RF، SVM و RF-SVM مورد استفاده قرار گرفت.

جدول ۴. مقادیر در نظر گرفته شده برای آبر پارامترهای مربوط به RF و SVM در فرآیند جستجوی شبکه‌ای.

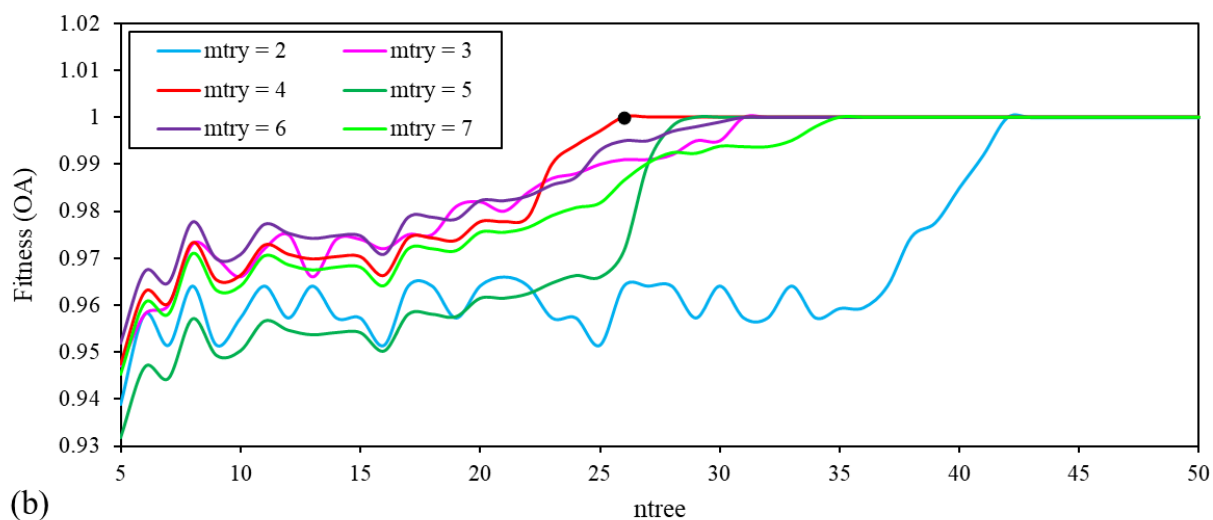

Model	hyperparameter	Parameter value
RF (for Regression)	ntree	10, 20, 30, 40, 50, 60, 70, 80, ..., 470, 490, 500
	mtry	2, 3, 4, 5, 6, 7, 8, 9
RF (for Classification)	ntree	5, 6, 7, 8, 9, 10, 11, ..., 46, 47, 48, 49, 50
	mtry	2, 3, 4, 5, 6, 7
SVM	ϵ	0.01, 0.05, 0.1, 0.15, 0.2, 0.25, 0.3, 0.35, 0.4, 0.45, 0.5, 0.55, 0.6
	C	25, 50, 75, 100, 125, ..., 950, 975, 1000
	σ (parameter of the RBF kernel)	0.2, 0.5, 1, 1.5, 2, 2.5, 3, 3.5, ..., 7, 7.5, 8
	d (degree of the polynomial kernel)	2, 3, 4

در زیر بخش‌های ۱-۵، ۲-۵، ۳-۵ و ۴-۵ به ترتیب مراحل مدل‌سازی مقاومت و مود همرسی ترک، جهت دستیابی به مدل بهینه RF، SVM، RF-SVM و MLR پرداخته می‌شود.

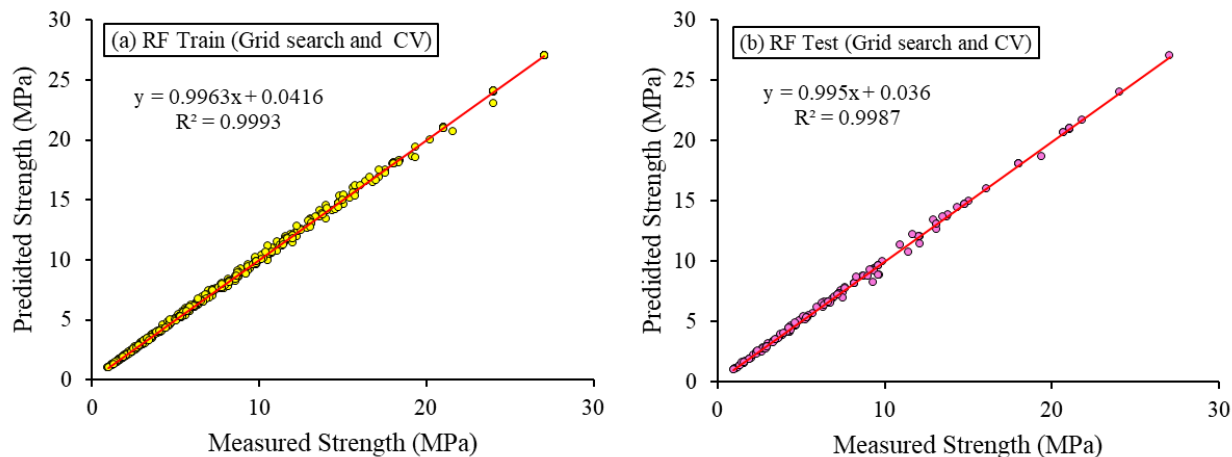
۱-۵. الگوریتم جنگل تصادفی

در مطالعه حاضر، ۷۵۶ دسته داده‌های مورد استفاده پس از درهم ریزی تصادفی (shuffling) به دو قسمت آموزش و تست با نسبت‌های ۸۰٪/۶۰۴ (دسته داده) و ۲۰٪/۱۵۲ (دسته داده) تقسیم بندی شد. shuffling به منظور جابجایی تصادفی دسته داده‌ها و از بین بردن هرگونه ترتیب، الگو و سوگیری در آن‌ها استفاده شد. سپس الگوریتم RF با بکارگیری تکنیک جستجوی شبکه‌ای و استفاده از فرآیند اعتبارسنجی متقاطع اجرا گردید. در شکل ۳ نمودارهای مربوط به تغییرات تابع برازندگی نسبت به تعداد درختان (ntree) به ازای مقادیر مختلف mtry به ترتیب در ۲ حالت پیش‌بینی مقاومت نمونه‌ها و پیش‌بینی مود شکست آن‌ها، رسم شده است. تابع برازندگی زمانی که هدف پیش‌بینی مقاومت نمونه‌ها و مود شکست آن‌ها است، به ترتیب به صورت میانگین خطای مطلق و میانگین صحت کلی زیر مجموعه‌های مربوط به فرآیند اعتبارسنجی متقاطع در نظر گرفته شد. شکل ۳a نشان می‌دهد که به طور کلی به ازای مقادیر مختلف mtry با افزایش تعداد درختان (ntree) خطای الگوریتم کاهش می‌یابد. از سوی دیگر می‌توان دریافت که افزایش تعداد درختان به مرور باعث همگرا شدن خطا به یک مقدار خاصی می‌شود. نکته دیگر آن است که بهترین مدل از بین مدل‌های مختلف RF به ازای مقادیر ntree از ۱۰ تا ۵۰۰، مدلی با پارامترهای ntree و mtry به ترتیب برابر با ۳۱۰ و ۶ می‌باشد.

از سوی دیگر، شکل ۳b نشان می‌دهد که به ازای مقادیر مختلف mtry به طور کلی با افزایش تعداد درختان (ntree) از ۵ تا ۵۰ صحت کلی الگوریتم RF در پیش‌بینی مود شکست نمونه‌ها افزایش می‌یابد. بعلاوه، به ازای مقادیر مختلف mtry زمانی که تعداد درختان از حد مشخصی بیشتر می‌شود، الگوریتم RF قادر است با دقت ۱۰۰٪ مود شکست نمونه‌ها را پیش‌بینی نماید. با توجه به شکل ۳b واضح است که برای هر مدل RF به ازای mtry های مختلف در مقادیر ntree متفاوتی، صحت کلی مدل به ۱ می‌رسد. در نتیجه، از بین مدل‌های مختلف، مدلی با کمترین تعداد درخت به عنوان بهترین مدل انتخاب می‌شود. بنا براین، مدلی با آبر پارامترهای ntree و mtry به ترتیب برابر با ۲۶ و ۴ به عنوان مدل بهینه در نظر گرفته شد. در شکل ۴ رابطه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده مقاومت نمونه‌ها برای مدل بهینه RF در مراحل آموزش و تست نشان داده شده است. همانطور که مشاهده می‌شود مدل بهینه RF توانسته است، مقاومت نمونه‌ها را با دقت بسیار بالایی پیش‌بینی نماید.



شکل ۳. رابطه بین برازندگی و تعداد درختان (ntree) به ازای مقادیر مختلف mtry در پیش‌بینی (a) مقاومت و (b) مود شکست نمونه‌ها طی فرآیند اعتبارسنجی متقاطع و جستجوی شبکه‌ای.



شکل ۴. رابطه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده مقاومت نمونه‌ها با استفاده از مدل بهینه RF.


۲-۵. الگوریتم ماشین بردار پشتیبان

مشابه فرآیند مدلسازی صورت گرفته در زیر بخش ۵-۱، در این مرحله نیز همان دسته داده‌هایی که به صورت تصادفی به ۲ بخش آموزش (۶۰۴ دسته داده) و تست (۱۵۲ دسته داده) تقسیم‌بندی شده بودند، مورد استفاده قرار گرفت و سپس الگوریتم SVM با توابع کرنل خطی، چند جمله‌ای و RBF طی فرآیند جستجوی شبکه‌ای و استفاده از اعتبارسنجی متقاطع اجرا شد. میانگین خطای مطلق و میانگین صحت کلی زیر مجموعه‌های مربوط به فرآیند اعتبارسنجی متقاطع به عنوان دو شاخص به ترتیب در پیش‌بینی مقاومت و مود شکست نمونه‌ها با استفاده از الگوریتم SVM استفاده شدند و بر این اساس مقادیر بهینه آبر پارامترها بدست آمد که در جدول ۵ نشان داده شده است. همچنین، مقادیر شاخص‌های آماری ۶ مدل بهینه SVM (۳ مدل در پیش‌بینی مقاومت و ۳ مدل در پیش‌بینی مود

شکست نمونه‌ها) با در نظر گرفتن توابع کرنل خطی، چند جمله‌ای و RBF بیانگر آن که استفاده از تابع کرنل RBF در SVM منجر به دقت و عملکرد بالاتری می‌شود (با توجه به جدول ۶ بخش ۱-۶). بنابراین، مدل‌های بهینه SVM با تابع کرنل RBF به عنوان مدل‌های بهینه نهایی در پیش‌بینی مقاومت و مود شکست نمونه‌ها در نظر گرفته می‌شوند. در شکل ۵ همبستگی بین مقادیر واقعی و پیش‌بینی شده مقاومت نمونه‌ها در مراحل آموزش و تست برای مدل بهینه نهایی SVR به تصویر کشیده شده است که نشان می‌دهد مدل توانسته است با دقت بالا مقاومت نمونه‌ها را پیش‌بینی نماید.

جدول ۵: مقادیر بهینه آبر پارامترهای الگوریتم SVM طی فرآیند اعتبارسنجی متقاطع و جستجوی شبکه‌ای در پیش‌بینی مقاومت و مود شکست نمونه‌ها.

SVM type	hyperparameter	Strength prediction	Fracture mode prediction
Linear	ϵ	0.05	0.1
	C	125	25
Polynomial	ϵ	0.25	0.15
	C	325	475
	d	3	3
RBF	ϵ	0.15	0.05
	C	625	175
	σ	4.5	1

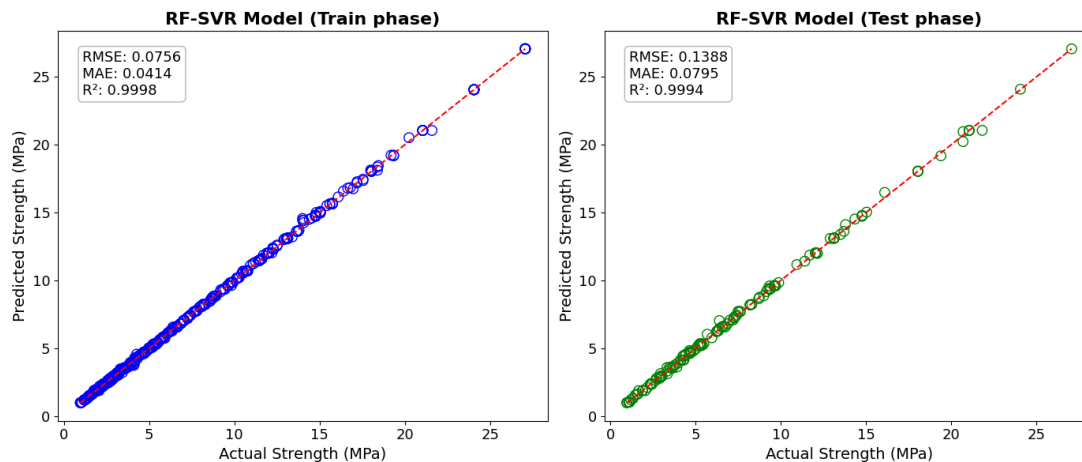


شکل ۵. رابطه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده مقاومت نمونه‌ها با استفاده از مدل بهینه SVR.

استفاده کند. در واقع، مدل نهایی تمام اطلاعات خروجی از مدل‌های پایه را جمع‌آوری کرده و یاد می‌گیرد که چگونه آن‌ها را به یک پیش‌بینی دقیق‌تر تبدیل کند. در این مطالعه، مدل نهایی Random Forest در نظر گرفته شد که به عنوان یک مدل انعطاف‌پذیر، وظیفه ترکیب خروجی‌ها را بر عهده دارد. در این مرحله نیز از تکنیک جستجوی شبکه‌ای و فرآیند اعتبارسنجی مقاطع استفاده شد و مدل بهینه RF-SVM بدست آمد. در شکل ۶ رابطه بین مقادیر واقعی و پیش‌بینی شده مقاومت نمونه‌ها با استفاده از مدل ترکیبی RF-SVR نشان داده شده است بیانگر دقت بالاتر آن نسبت به مدل‌های بهینه RF و SVR است.

۳-۵. مدل ترکیبی RF-SVM

هدف از ترکیب مدل‌های RF و SVM در یک رویکرد گروهی (ensemble) بررسی امکان پیش‌بینی مقاومت و مود شکست نمونه‌ها با دقت و عملکرد بالاتر و نیز مقایسه آن با مدل‌های بهینه RF و SVM به صورت تکی است. به منظور دستیابی به این مهم، از روش Stacking Ensemble برای ترکیب مدل‌ها و بهبود دقت کلی آن‌ها استفاده شد. در این روش ترکیبی، فرآیند یادگیری هر مدل به صورت مستقل انجام می‌شود و سپس خروجی‌های پیش‌بینی شده توسط این مدل‌ها به یک مدل نهایی (final estimator) داده می‌شود. مدل نهایی یاد می‌گیرد که چگونه از این پیش‌بینی‌های ترکیبی برای تصمیم‌گیری نهایی



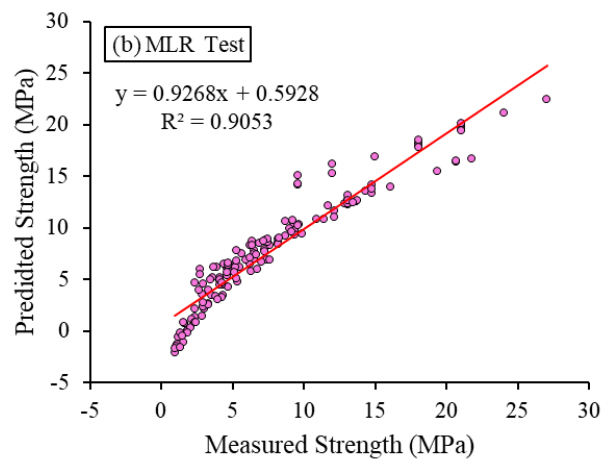
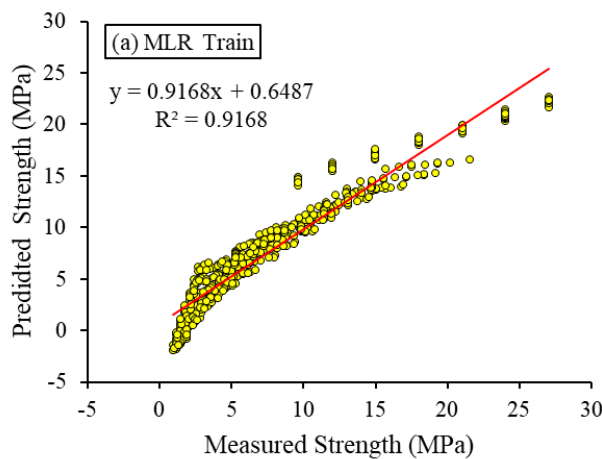
شکل ۶. رابطه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده مقاومت نمونه‌ها با استفاده از مدل ترکیبی RF-SVR.

۵-۴. مدل رگرسیون خطی چندگانه

در این بخش براساس داده‌های مرحله آموزش (۶۰۴ دسته داده) و با استفاده از نرم افزار اکسل مدل رگرسیون خطی چندگانه‌ای مطابق رابطه (۱۷) برای پیش‌بینی مقاومت محوری نمونه‌های شبه سنگی تحت آزمایش یک محوره ($\sigma_n = 0$) و دو محوره ($\sigma_n \neq 0$) به صورت زیر ارائه شد:

$$S_{pre} = 5.3802 - 12.6948(JC) + 0.8729(\sigma_c) + 0.1717(N) + 0.0076(\beta) + 0.6612(\sigma_n) - 0.9185(E) \quad (17)$$

در رابطه (۱۷) ضرایب پارامترهای σ_c ، ν ، C و $\tan\phi$ برابر با صفر بدست آمد، بنابراین ترم مربوط به این پارامترها در رابطه مذکور ظاهر نشده‌اند. به عبارت دیگر، رابطه فوق بیانگر آن است که مقاومت نمونه‌ها علاوه بر N ، JC ، β و σ_n از بین خصوصیات مکانیکی نمونه‌ها تنها به σ_c و E وابسته بوده و دیگر پارامترهای مکانیکی (σ_c ، U ، C و $\tan\phi$) تأثیری بر مقدار آن ندارند. در شکل ۷، رابطه بین مقادیر واقعی مقاومت نمونه‌ها و مقادیر پیش‌بینی شده آن‌ها با استفاده از رابطه (۱۷) نشان داده شده است.



شکل ۷. رابطه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده مقاومت نمونه‌ها با استفاده از مدل MLR.

۶. مقایسه و اعتبارسنجی مدل‌های پیشنهادی

حالت‌های خطی و چند جمله‌ای نیز محاسبه و در جدول نمایش داده شده است. از آنجایی عملکرد مدل SVM با بکارگیری تابع کرنل RBF بهتر از حالت‌های استفاده از تابع کرنل چند جمله‌ای و خطی است، بنابراین مدل SVM با تابع کرنل RBF به عنوان مدل بهینه نهایی در نظر گرفته می‌شود. بعلاوه، شکل ۸ مقایسه‌ای بین مقادیر مقاومت اندازه‌گیری شده و پیش‌بینی شده با استفاده از مدل‌های مختلف را در مرحله تست نشان می‌دهد.

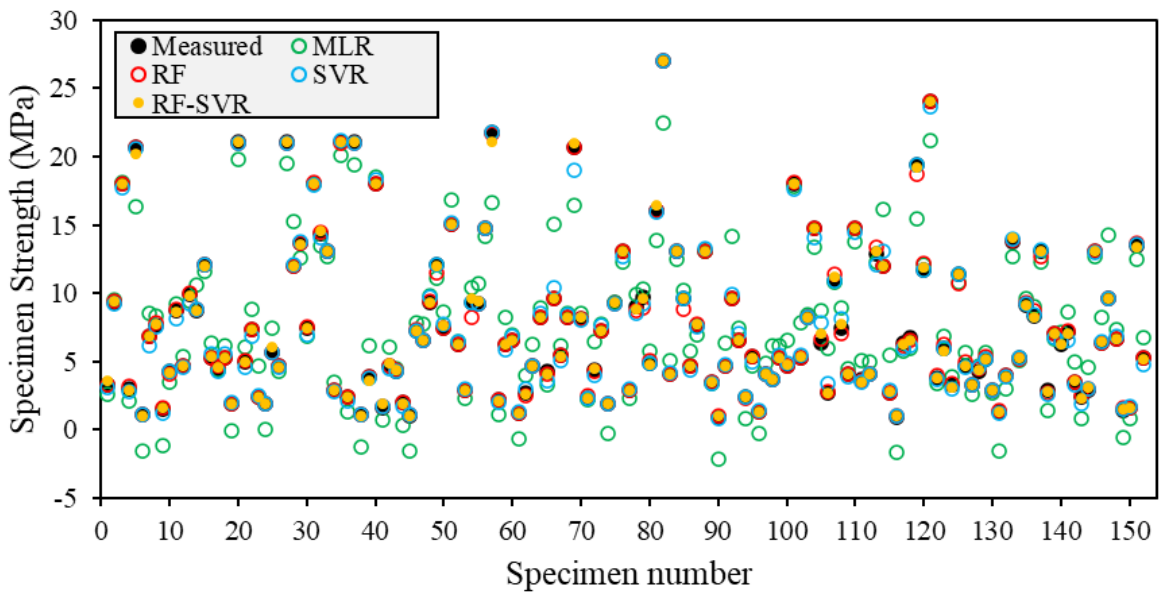
۶-۱- مقایسه و اعتبارسنجی مدل‌ها بدون تفکیک نوع نمونه در این بخش، به منظور مقایسه و اعتبارسنجی کلی مدل‌های بهینه RF، SVM و RF-SVM و مدل MLR در پیش‌بینی مقاومت محوری و مود شکست نمونه‌ها از شاخص‌های آماری معرفی شده در بخش ۲-۵ استفاده شده است. با اعمال روابط (۶) تا (۹) بر داده‌های مرحله آموزش و تست مقادیر این شاخص‌ها برای سایر مدل‌ها بدست آمد که در جدول ۶ ارائه شده است. لازم به ذکر است که برای مدل SVM مقادیر شاخص‌های آماری علاوه بر حالت استفاده از کرنل RBF، برای

جدول ۴. مقادیر شاخص‌های آماری ارزیابی عملکرد مربوط به مدل‌های بهینه RF و SVM در مراحل آموزش و تست برای هر دو روش مدل‌سازی با استفاده از فرآیند سعی و خطا و جستجوی شبکه‌ای.

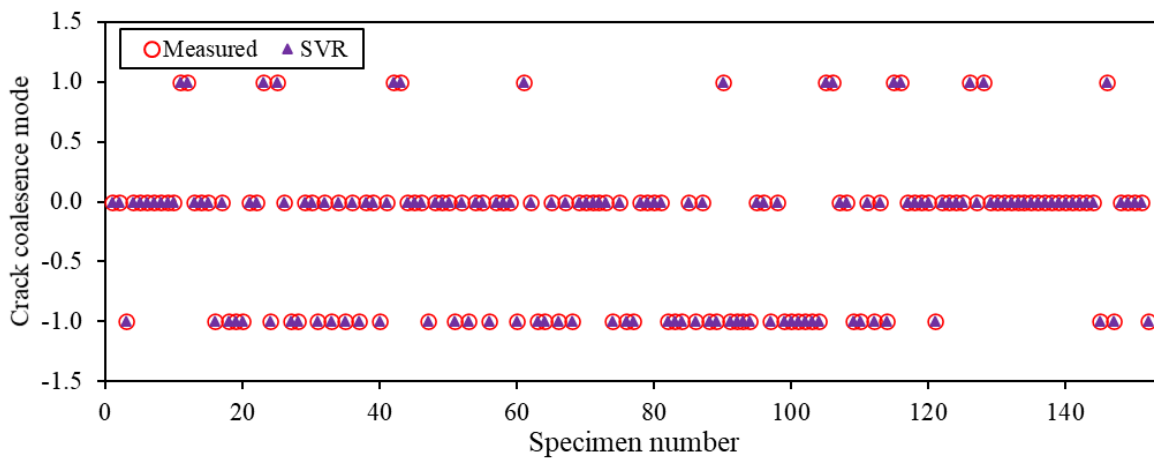

phase	Model	Statistical metrics			
		R ²	MAE	RMSE	OA
Training	MLR	0.9168	1.2919	0.7175	-
	RF	0.9993	0.0904	0.1523	1
	SVM (Linear)	0.9123	-	-	0.972
	SVM (polynomial)	0.9924	-	-	1
	SVM (RBF)	0.9936	0.3392	0.4132	1
	RF-SVM	0.9998	0.0414	0.0756	1
	MLR	0.9053	1.3222	0.7214	-
Testing	RF	0.9987	0.1046	0.1872	1
	SVM (Linear)	0.8782	-	-	0.987
	SVM (polynomial)	0.9915	-	-	0.995
	SVM (RBF)	0.9965	0.2203	0.3108	1
	RF-SVM	0.9994	0.0795	0.1388	1

نتایج مدل‌سازی مود همرسی ترک با توجه به جدول ۶ نشان می‌دهد مدل‌های RF، SVM، RF-SVM می‌توانند با دقت بسیار بالایی مود همرسی ترک را پیش‌بینی نمایند، بگونه‌ای که صحت کلی (OA) مدل بهینه این الگوریتم‌ها با هم برابر بوده و در هر دو مرحله آموزش و تست برابر ۱ می‌باشند. در شکل ۹ مقایسه بین مود همرسی ترک مشاهده شده و پیش‌بینی شده با استفاده از مدل‌های بهینه RF و SVM در مرحله تست نشان می‌دهند.

با توجه به جدول ۶ و با مقایسه شکل‌های ۴ تا ۸ می‌توان دریافت که مدل MLR از دقت پایین‌تر و خطای بالاتری نسبت به مدل‌های بهینه RF، SVR، RF-SVR، در پیش‌بینی مقاومت نمونه‌ها برخوردار است. همچنین، با توجه به شکل ۷ می‌توان دریافت که مدل MLR مقدار مقاومت برخی از نمونه‌ها را منفی برآورد نموده است که این نشان دهنده ضعف مدل MLR در مقایسه با مدل‌های دیگر با وجود سادگی آن می‌باشد. از سوی دیگر، نتایج جدول ۶ و شکل‌های ۴، ۵، ۶ و ۸ حاکی از برتری جزئی مدل ترکیبی RF-SVM در پیش‌بینی مقاومت نمونه‌ها است، در حالی که دقت و عملکرد مدل‌های RF و SVR نیز تفاوت قابل توجهی با آن ندارد.



شکل ۸. مقایسه مقادیر اندازه‌گیری شده و پیش‌بینی شده مقاومت محوری نمونه‌ها با استفاده از مدل‌های MLR، RF، SVR و RF-SVR در مرحله تست.



شکل ۹. مقایسه بین مود همرسی ترک مشاهده شده و پیش‌بینی شده با استفاده از الگوریتم‌های RF و SVM در مرحله تست.

نمونه در جدول ۷ آورده شده است. با توجه به این جدول می‌توان دریافت که مدل بهینه RF نسبت به دو مدل دیگر توانسته است مقاومت هر ۳ نوع نمونه را با دقت بسیار بالایی در مراحل آموزش و تست پیش‌بینی نماید. لازم به ذکر است که دقت مدل‌های MLR و SVR در پیش‌بینی مقاومت نمونه‌های نوع ۱ نسبت به نمونه‌های نوع ۲ و ۳ پایین‌تر می‌باشد. همچنین، نتایج بیانگر آن است که دقت هر ۳ مدل در پیش‌بینی مقاومت نمونه‌ها به تفکیک نوع آن‌ها در مرحله تست بیشتر از مرحله آموزش است.

۶-۲. مقایسه و اعتبارسنجی مدل‌ها به تفکیک نوع نمونه به منظور مقایسه عملکرد مدل‌های بهینه RF، SVM و مدل MLR در پیش‌بینی مقاومت و مود شکست نمونه‌ها به تفکیک نوع آن‌ها، از شاخص‌های R^2 و OA استفاده شد. مقدار صحت کلی (OA) مدل‌های بهینه RF و SVM در پیش‌بینی مود شکست هر ۳ نوع نمونه در مراحل آموزش و تست برابر ۱ می‌باشد که نشان‌دهنده عملکرد مطلوب این مدل‌ها در برآورد مود شکست است. همچنین، مقدار شاخص R^2 مدل‌های RF، SVR و MLR در دو مرحله آموزش و تست برای هر سه نوع

جدول ۷. مقادیر R^2 مدل MLR و مدل‌های بهینه RF و SVR به تفکیک نوع نمونه در پیش‌بینی مقاومت آن‌ها.

phase	Specimens	MLR	RF	SVR
Train	Type 1	0.7787	0.9980	0.9543
	Type 2	0.9380	0.9975	0.9850
	Type 3	0.8765	0.9985	0.9869
Test	Type 1	0.8587	0.9983	0.9752
	Type 2	0.9277	0.9981	0.9887
	Type 3	0.9367	0.9992	0.9977

بدست آمد، بنا براین می‌توان گفت مدل‌های RF و SVC از قطعیت بسیار بالایی در برآورد مود شکست نمونه‌ها برخوردارند.

در این بخش، تنها به ارزیابی کمی مدل‌های توسعه‌یافته برای پیش‌بینی مقاومت نمونه‌ها با تأکید بر اهمیت تحلیل عدم قطعیت پرداخته خواهد شد. به منظور انجام تحلیل عدم قطعیت مدل‌های MLR، RF، SVR و RF-SVR در پیش‌بینی مقاومت نمونه‌ها از معیار عرض بازه اطمینان (Width of Confidence Bound=WCB) حول میانگین قدر مطلق خطاهای هر مدل (MAE= $E_{average}$) در مراحل آموزش و تست استفاده می‌شود. برای اجرای این روش باید انحراف استاندارد (Standard Deviation=SD) حول میانگین قدر مطلق خطاهای مدل و سپس خطای استاندارد (Standard Error=SE) را به ترتیب با استفاده از روابط (۱۸) و (۱۹) بدست آورد:

۷. تحلیل عدم قطعیت

تحلیل عدم قطعیت نقشی اساسی در ارزیابی قابلیت اطمینان مدل‌های توسعه یافته ایفا می‌کند، زیرا شناسایی و کمی‌سازی خطاهای ممکن بین داده‌های اندازه‌گیری شده و پیش‌بینی شده را امکان‌پذیر می‌سازد. استفاده از شاخص‌های مربوط به عدم قطعیت می‌تواند به بهبود دقت و اعتمادپذیری نتایج پیش‌بینی کمک کند. از آنجایی که پیش‌بینی مود شکست نمونه‌ها یک مسئله طبقه‌بندی است بنابراین برای انجام تحلیل عدم قطعیت باید از روش‌های مبتنی بر احتمالات همچون روش آنتروپی، بیزین و بازه اطمینان برای احتمالات کلاس‌ها (Confidence Intervals for Class Probabilities)، استفاده نمود. اجرای این روش‌ها به منظور تحلیل عدم قطعیت زمانبر و پیچیده است. بنابراین، در این مطالعه از اجرای آن صرف‌نظر می‌شود. از سوی دیگر، با توجه به اینکه از اعتبارسنجی متقابل برای افزایش پایداری و تعمیم‌پذیری مدل‌ها در طول مدل‌سازی مود شکست نمونه‌ها استفاده شد و پیش‌بینی‌های با دقت بالا و نا متناقضی

و خطای کمتری پیش‌بینی نماید. بر اساس موارد فوق‌الذکر، تحلیل عدم قطعیت برای مدل MLR و مدل‌های بهینه RF، SVR و RF-SVR در مراحل آموزش و تست انجام شد که نتایج آن در جدول ۸ آورده شده است. مقادیر WCB نشان می‌دهند که ترتیب مدل‌های این مطالعه از نظر قطعیت و اعتمادپذیری به صورت RF، RF-SVR، SVR و MLR است. با این وجود مقادیر WCB بدست آمده برای ۳ مدل RF-SVR، RF و SVR بسیار کوچک و به هم نزدیک هستند که نشان‌دهنده قطعیت بالای ۳ مدل یادگیری ماشین در پیش‌بینی مقاومت نمونه‌ها می‌باشند.

$$SD = \sqrt{\frac{\sum_{i=1}^N (E_i - E_{average})^2}{N - 1}} \quad (18)$$

$$SE = \frac{SD}{\sqrt{N}} \quad (19)$$

در روابط (۱۸) و (۱۹)، E_i نشان‌دهنده خطای مطلق پیش‌بینی مربوط به دسته داده N و N تعداد دسته داده‌ها در مرحله آموزش یا تست می‌باشد. پس از محاسبه SE، حاشیه خطا (Margin of Error=ME) در سطح اطمینان ۹۵٪ بدست می‌آید ($ME=1.96 \times SE$). در نهایت مقدار عرض بازه اطمینان که ۲ برابر مقدار حاشیه خطا است، محاسبه می‌گردد. هر اندازه مقدار WCB برای یک مدل کوچکتر باشد آن مدل از قطعیت بالاتری در برآورد پارامتر هدف برخوردار بوده و می‌تواند پارامتر هدف را با دقت بالاتر

جدول ۸. نتایج تحلیل عدم قطعیت انجام شده برای مدل MLR و مدل‌های بهینه RF، SVR و RF-SVR در مراحل آموزش و تست.

phase	Model	MAE= $E_{average}$	SD	SE	ME	WCB
Training	MLR	1.2919	1.2831	0.0522	0.1023	0.2047
	RF	0.0904	0.0164	0.0007	0.0013	0.0026
	SVR	0.3392	0.1158	0.0047	0.0092	0.0185
	RF-SVR	0.0414	0.0040	0.0002	0.0003	0.0006
Testing	MLR	0.3222	1.2230	0.0992	0.1944	0.3889
	RF	0.1044	0.0304	0.0025	0.0048	0.0097
	SVR	0.2184	0.0657	0.0053	0.0104	0.0209
	RF-SVR	0.0795	0.0130	0.0011	0.0021	0.0041

۸. تحلیل حساسیت

پارامترهای ورودی را بر خروجی مدل محاسبه نماید و در نتیجه نسبت دادن منصفانه و قابل تفسیر اهمیت پارامتر ورودی را تضمین کند. SHAP از یک مدل خطی برای تقریب مدل اولیه پیچیده در تعیین اهمیت متغیرها به صورت زیر استفاده می‌کند (Lundberg and Lee, 2017):

$$g(z') = \phi_0 + \sum_{i=1}^N \phi_i z'_i \quad (20)$$

در رابطه (۲۰)، z'_i بیانگر این است که آیا یک پارامتر در خروجی مدل گنجانده شده است ($z'_i=1$) یا نه ($z'_i=0$)، N نشان‌دهنده تعداد پارامترهای ورودی، ϕ_0 مقدار متوسط پارامتر هدف و ϕ_i مقدار ارزش شپلی مربوط به پارامتر ورودی i است که نشان‌دهنده میزان تأثیر پارامتر مربوطه بر خروجی مدل می‌باشد. برای محاسبه ارزش شپلی یک پارامتر، SHAP تأثیر

آخرین مرحله مدل‌سازی، ارزیابی میزان حساسیت خروجی مدل نسبت به پارامترهای ورودی است. اثر نسبی پارامترهای ورودی مدل بر خروجی مدل (تابع هدف) را می‌توان با استفاده از تحلیل حساسیت ارزیابی کرد. یکی از روش‌های تحلیل حساسیت برای دستیابی به این هدف، روش قدرتمند ارزش شپلی (Shapley Value) است که در این مطالعه، از آن به منظور بررسی اثر نسبی پارامترهای ورودی بر پارامترهای خروجی (مقاومت و مود شکست نمونه‌ها) استفاده می‌شود. SHAP یک رویکرد مبتنی بر نظریه بازی است که با هر پارامتر ورودی به عنوان یک شرکت کننده در "بازی" رفتار می‌کند که در آن "پاداش" پیش‌بینی مدل است. این روش می‌تواند اثر هر پارامتر را به صورت جداگانه و همچنین تعامل آن پارامتر با سایر

درزه‌داری (JC)، فشار محصور کننده (σ_n) و مقاومت فشاری (σ_c) به ترتیب مهمترین پارامترهای تأثیرگذار بر مقاومت نمونه‌ها هستند در حالی که نسبت پواسون (ν) و ضریب اصطکاک داخلی ($\tan\phi$) کم اهمیت‌ترین پارامترهای تأثیرگذار بر مقاومت نمونه‌ها هستند.

به طور کلی بر اساس تحلیل حساسیت انجام شده (شکل ۱۰ و ۱۱) می‌توان گفت فشار محصور کننده (σ_n)، ضریب درزه‌داری (JC)، چسبندگی (C) و مقاومت فشاری (σ_c) مهمترین پارامترها و نسبت پواسون (ν)، ضریب اصطکاک داخلی ($\tan\phi$) و تعداد درزه‌ها (N) کم اهمیت‌ترین پارامترهای موثر بر مقاومت نمونه‌ها هستند.

از سوی دیگر، شکل ۱۲ مقدار اهمیت پارامترهای ورودی تأثیرگذار بر مود شکست نمونه‌ها را برای مدل‌های بهینه RF و SVC نشان می‌دهد. نتایج تحلیل حساسیت برای مدل RF نشان می‌دهد که به ترتیب فشار محصور کننده (σ_n)، تعداد درزه‌ها (N)، ضریب درزه‌داری (JC) و زاویه درزه‌ها نسبت به راستای افق (β) مهمترین پارامترهای تأثیرگذار بر مود شکست خصوصیات مکانیکی نمونه‌ها تأثیر ناچیزی بر مود شکست نمونه‌ها دارند. در نقطه مقابل، نتایج تحلیل حساسیت برای مدل SVC بیانگر آن است که به ترتیب فشار محصور کننده (σ_n)، و خصوصیات مکانیکی نمونه‌ها شامل مقاومت فشاری (σ_c)، مدول الاستیسیته (E) و چسبندگی (C) از اهمیت بالاتری در برآورد مود شکست برخوردارند. در حالی که ضریب اصطکاک نمونه‌ها ($\tan\phi$)، نسبت پواسون (ν) و زاویه درزه‌ها نسبت به راستای افق (β) کمترین تأثیر را بر مود شکست نمونه‌ها دارند. مهمترین پارامتر ورودی تأثیرگذار بر مود شکست در هر دو مدل RF و SVC، فشار محصور کننده (σ_n) است. با این حال اهمیت دیگر پارامترهای تأثیرگذار بر مود شکست در دو مدل با هم متفاوت است. خصوصیات مکانیکی در مدل SVC نقش مهمی دارند در حالی که در مدل RF نقش آن‌ها ناچیز است. دلیل این تفاوت آن است که اهمیت پارامترهای ورودی در مدل RF بیشتر به توانایی آن در کاهش خطای ناخالصی گینی یا خطای طبقه‌بندی در درخت‌ها بستگی دارد، در حالی که اهمیت

هر ترکیب ممکن از پارامترهای ورودی را بررسی نموده و سپس ارزیابی می‌کند که چگونه افزودن یا حذف یک پارامتر ورودی خاص، مقدار پیش‌بینی مدل را تغییر می‌دهد. این فرآیند هم تأثیر تکی یک پارامتر و هم تعامل آن با سایر پارامتر را محاسبه و به تصویر می‌کشد (Liu et al., 2022):

$$\phi_i = \sum_{S \subset Z \setminus \{i\}} \frac{|S|!(|N|-|S|-1)!}{|N|} [f(S \cup \{i\}) - f(S)] \quad (21)$$

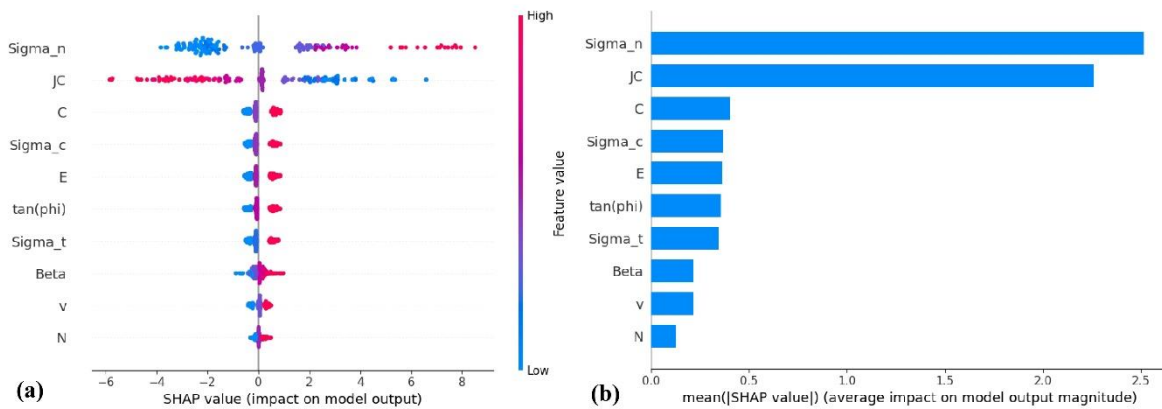
در رابطه (۲۱)، S زیر مجموعه‌ای از پارامترهای ورودی است که شامل پارامتر ورودی i نباشد و $f(S)$ مقدار خروجی مورد انتظار مدل با در نظر گرفتن پارامترهای موجود در زیر مجموعه S است.

در این مطالعه روش شپلی بر روی مدل‌های بهینه RF و SVR که طی فرآیند جستجوی شبکه‌ای و اعتبارسنجی متقاطع مقادیر بهینه آبر پارامترهای آن‌ها بدست آمد، اعمال گردید (برای الگوریتم SVM تابع کرنل RBF بهترین نتیجه را به همراه داشت).

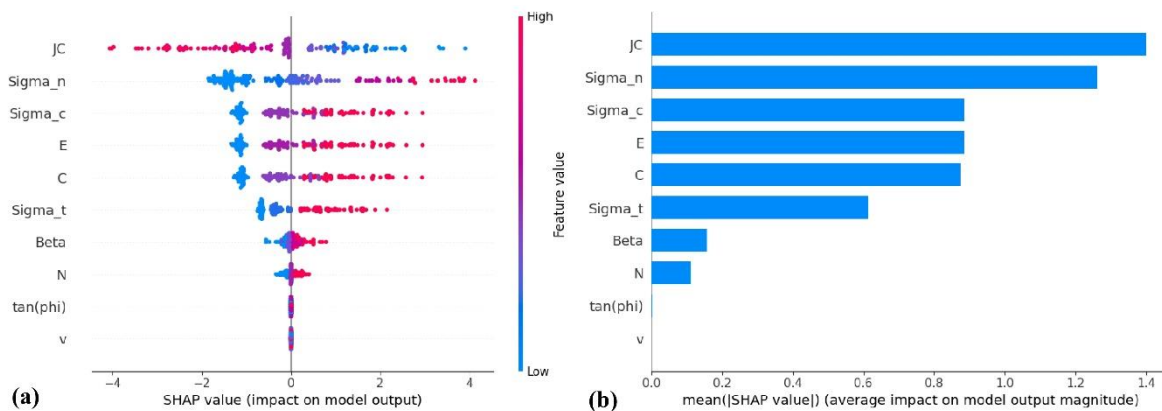
شکل‌های ۱۰a و ۱۱a مقدار ارزش شپلی هر پارامتر برای دسته داده‌های موجود در پایگاه داده را به ترتیب برای مدل‌های بهینه RF و SVR در پیش‌بینی مقاومت نمونه‌ها نشان می‌دهند. هر نقطه بر روی نمودار، مربوط به یک دسته داده مجزا است. در این شکل‌ها، محور x نشان‌دهنده ارزش شپلی است که مقادیر مثبت بیانگر همبستگی مثبت و مقادیر منفی نشان‌دهنده همبستگی منفی بین پارامتر ورودی و خروجی می‌باشد. همچنین، محور y پارامترهای ورودی را به ترتیب اهمیت نزولی نشان می‌دهد. در شکل‌های ۱۰b و ۱۱b میانگین قدرمطلق مقادیر ارزش شپلی برای هر پارامتر ورودی که نشان‌دهنده اهمیت نسبی آن بر مقاومت نمونه می‌باشد به ترتیب برای مدل‌های بهینه RF و SVR به تصویر کشیده شده است. به‌طور کلی شکل ۱۰ نشان می‌دهد که در مدل RF فشار محصور کننده (σ_n)، ضریب درزه‌داری (JC) و چسبندگی (C) به ترتیب مهمترین پارامترهای تأثیرگذار بر مقاومت نمونه‌ها هستند، در حالی که تعداد درزه‌ها (N) و ضریب پواسون (ν) کم اهمیت‌ترین پارامترهای تأثیرگذار بر مقاومت نمونه‌ها می‌باشند. همچنین، شکل ۱۱ بیانگر آن است که در مدل SVR ضریب

نگاه می‌کند.

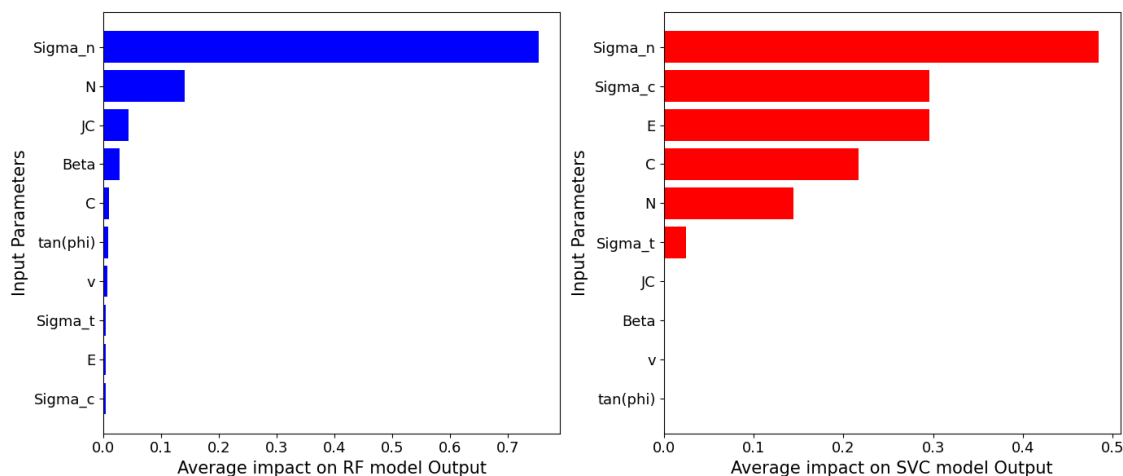
متغیرها در مدل SVC به تأثیر آن‌ها بر روی حاشیه خطا و بردارهای پشتیبان وابسته است. از سوی دیگر، مدل RF بهتر می‌تواند تعاملات پیچیده بین متغیرها را مدل نماید به طوری که اگر برخی متغیرها به تنهایی ضعیف بوده اما در تعامل با دیگر متغیرها قوی باشند، ممکن است اهمیت بیشتری در مدل RF داشته باشند، در حالی که معمولاً تعاملات متغیرها را صریحاً مدل نمی‌کند، بلکه به تأثیر کلی هر متغیر بر مرز تصمیم



شکل ۱۰. تحلیل حساسیت پارامترهای ورودی مدل بهینه RF در پیش‌بینی مقاومت نمونه‌ها: (a) مقدار ارزش شپلی و (b) اهمیت نسبی پارامترهای ورودی.



شکل ۱۱. تحلیل حساسیت پارامترهای ورودی مدل بهینه SVR در پیش‌بینی مقاومت نمونه‌ها: (a) مقدار ارزش شپلی و (b) اهمیت نسبی پارامترهای ورودی.



شکل ۱۲. تحلیل حساسیت پارامترهای ورودی مدل‌های بهینه RF و SVC در پیش‌بینی مود شکست نمونه‌ها.

۹. مزایا، محدودیت‌ها و پیشنهادات برای تحقیقات آینده

با وجود این دستاوردها، مطالعه حاضر از محدودیت‌های خاصی نیز برخوردار است که بایستی مورد توجه قرار گیرند. یکی از محدودیت‌های این مطالعه به دلیل محدودیت‌های دستگاه استاندارد آزمایش UCS از نظر جعبه بارگذاری است. در این تحقیق، با افزایش اندازه نمونه‌ها، مقاومت آن‌ها کاهش می‌یافت زیرا با افزایش ارتفاع نمونه‌ها، میزان کمانش در آن‌ها بیشتر می‌شد. از سوی دیگر، تمرکز تنش در نوک درزه‌ها به دلیل اثر کمانش افزایش می‌یافت که این امر کاهش مقاومت نمونه‌ها را به دنبال داشت. همچنین، این مطالعه عمدتاً بر پارامترهای مکانیکی و هندسی خاصی مانند مقاومت فشاری، مدول الاستیسیته، ضریب درزه‌داری، چیدمان درزه‌ها و ... تمرکز دارد. با این حال، عوامل دیگری مانند طول و زاویه پل سنگ و همچنین شرایط محیطی در نظر گرفته نشده‌اند که می‌توانند بر دقت پیش‌بینی مدل‌ها تأثیر بگذارند. پرداختن به این عوامل در تحقیقات آینده می‌تواند درک جامع‌تری از فرآیند شکست سنگ در شرایط پیچیده زمین‌شناسی فراهم نماید.

علاوه بر این، تمرکز اصلی مطالعه حاضر بر استفاده از مدل‌های RF، SVM و RF-SVM بوده است. اگرچه این الگوریتم‌ها دقت بالایی را نشان می‌دهند، ادغام روش‌های هوش مصنوعی ترکیبی (ترکیب الگوریتم‌های یادگیری و الگوریتم‌های فرا ابتکاری) و استفاده از روش‌های یادگیری عمیق همراه با

در این مطالعه از مدل‌های یادگیری ماشین شامل RF، SVM و RF-SVM برای پیش‌بینی دقیق و هوشمندانه مقاومت محوری و مود همرسی ترک در نمونه‌های شبه‌سنگی استفاده شد. یکی از مزایای برجسته این تحقیق، اتکاء آن به مجموعه داده‌ای متنوع شامل پارامترهای مکانیکی و هندسی نمونه‌های شبه‌سنگی تحت تست آزمایشگاهی می‌باشد که به راحتی قابل اندازه‌گیری و کاربردی در مقیاس وسیع هستند. این رویکرد به‌طور چشمگیری کارایی و دقت مدل‌های توسعه یافته را در پیش‌بینی رفتار مکانیکی نمونه‌های شبه‌سنگی تحت تنش‌های فشاری، به‌ویژه در سناریوهای پیچیده‌ای که شامل چندین ترک از پیش موجود است، را افزایش می‌دهد.

یافته‌ها نشان‌دهنده عملکرد دقیق مدل‌های RF و SVM و نیز عملکرد قوی‌تر مدل ترکیبی RF-SVM است که به‌خوبی نقاط قوت الگوریتم‌های RF و SVM را ترکیب کرده و پیش‌بینی‌های بسیار دقیقی ارائه می‌دهد. این امر نه تنها به پیشرفت حوزه مکانیک شکست کمک می‌کند بلکه چارچوبی مقیاس‌پذیر برای حل چالش‌های مشابه در کاربردهای مهندسی ارائه می‌دهد. علاوه بر این، تحلیل حساسیت انجام‌شده در این مطالعه بینش عمیق‌تری از تأثیر پارامترهای کلیدی ارائه می‌دهد که به طراحی و بهینه‌سازی مدل‌های آزمایشگاهی و محاسباتی در مکانیک سنگ کمک می‌کند.

الگوریتم‌ها با استفاده از تکنیک جستجوی شبکه‌ای و فرآیند اعتبارسنجی متقاطع بدست آمد. به علاوه، رابطه‌ای براساس مدل رگرسیون خطی چندگانه (MLR) به منظور پیش‌بینی مقاومت نمونه‌ها و نیز جهت ارزیابی و مقایسه با مدل‌های بهینه هوش مصنوعی، ارائه گردید. سپس، از ۳ معیار ارزیابی عملکرد شامل ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE) و خطای مطلق میانگین (MAE) در پیش‌بینی مقاومت نمونه‌ها و نیز معیار صحت کلی (OA) در پیش‌بینی مود همرسی ترک به منظور بررسی عملکرد و کارایی الگوریتم‌های مورد استفاده در مراحل آموزش و تست استفاده شد. به علاوه، با انجام تحلیل عدم قطعیت به ارزیابی قابلیت اطمینان و دقت پیش‌بینی مدل‌ها پرداخته شد. در نهایت با انجام تحلیل حساسیت، اهمیت پارامترهای ورودی تأثیرگذار بر مقاومت نمونه‌ها بررسی گردید. نتایج مهم بدست آمده از این مطالعه را می‌توان به صورت زیر بر شمرد:

- ۱) مدل‌های RF، SVM، RF-SVM قابلیت پیش‌بینی بسیار دقیق و کم‌خطای مقاومت و مود شکست نمونه‌های شبه‌سنگی درزه‌دار را دارند.
- ۲) مدل‌های هوشمند توسعه‌یافته با ارائه مقادیر RMSE و MAE پایین‌تر و مقادیر R^2 بالاتر در پیش‌بینی مقاومت نمونه‌ها، برتری خود را نسبت به مدل MLR در مراحل آموزش و تست نشان دادند.
- ۳) تحلیل عدم قطعیت، دقت و قابلیت اطمینان مدل‌های هوشمند توسعه‌یافته را تأیید می‌نمایند.
- ۴) مهم‌ترین پارامترها در پیش‌بینی مقاومت نمونه‌ها عبارتند از σ_n ، JC، C و σ_c ؛ در حالی که N و σ_n بیشترین تأثیر را بر مود شکست آن‌ها دارند.
- ۵) مدل‌های ارائه‌شده پتانسیل قابل توجهی برای تحلیل پایداری در کاربردهای معدنی را دارند، اما انجام تحقیقات بیشتر برای اطمینان از قابلیت تعمیم آن‌ها ضروری می‌باشد.

تکنیک‌های آماری می‌تواند توانایی‌های پیش‌بینی را بهبود بخشد. از سوی دیگر، گسترش مجموعه داده‌ها با در نظر گرفتن مشاهدات میدانی و شرایط زمین‌شناسی مختلف، می‌تواند کاربرد عملی مدل‌ها را افزایش داده و قابلیت اطمینان آن‌ها را در سناریوهای متنوع بهبود بخشیده و تأیید نماید.

تحقیقات آینده همچنین باید به بررسی ادغام داده‌های نظارت لحظه‌ای با مدل‌های پیش‌بینی پردازش تا امکان تحلیل دینامیکی رفتار سنگ تحت تنش فراهم شود. مطالعات مقایسه‌ای با استفاده از رویکردهای مدل‌سازی جایگزین، مانند شبیه‌سازی‌های المان مجزا با استفاده از نرم‌افزار PFC، همراه با تکنیک‌های یادگیری ماشین، می‌تواند اعتبارسنجی متقابل ارزشمندی ارائه داده و به درک جامع‌تری از پدیده شکست در توده‌سنگ‌های درزه‌دار بیانجامد.

در نهایت، با وجود اینکه مطالعه حاضر گامی مؤثر در جهت استفاده از مدل‌های هوشمند برای پیش‌بینی مقاومت و مود شکست سنگ‌های درزه‌دار برداشته است، پیچیدگی‌های ذاتی رفتار سیستم‌های سنگ درزه‌دار همچنان نیازمند تحقیقات بیشتر است. با توجه به محدودیت‌های شناسایی شده و پیگیری و استفاده از رویکردهای تحقیقاتی پیشنهادی، می‌توان چارچوبی جامع‌تر برای تحلیل و پیش‌بینی رفتار مکانیکی و مکانیزم شکست سنگ‌ها توسعه داد.

۱۰. نتیجه‌گیری

در این مقاله، با استفاده از الگوریتم‌های جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و نیز ترکیب آن‌ها (RF-SVM) به پیش‌بینی مود همرسی ترک و مقاومت نمونه‌های شبه سنگی دارای درزه‌های ناممتد هم صفحه، تحت آزمایش تراکم یک و دو محوره پرداخته شد. براساس نتایج ۷۵۶ آزمایش تراکم و با انتخاب ۱۰ متغیر به عنوان پارامترهای ورودی تأثیر گذار بر مود همرسی ترک و مقاومت نمونه‌ها، پس از تقسیم داده‌ها به دو بخش آموزش (۸۰ درصد) و تست (۲۰ درصد)، روش‌های RF، SVM و RF-SVM پیاده‌سازی شدند. مدل‌های بهینه این

منابع

- ابراهیم خانی، سمیه، افضل، مهدی، شکوهی، علی، ۱۳۹۰. پیش‌بینی و بررسی عوامل تصادفات جاده‌ای با استفاده از الگوریتم‌های داده‌کاوی، فصلنامه دانش انتظامی زنجان، شماره ۱، سال اول، ۱۱۱-۱۲۷.
- فرشاد، محمد، و ساد، جواد، ۱۳۹۲. مکان‌یابی خطای اتصال کوتاه در خطوط انتقال جریان مستقیم ولتاژ بالا با استفاده از شبکه عصبی، رگرسیون تعمیم یافته و الگوریتم جنگل تصادفی، سیستم‌های هوشمند در مهندسی برق، شماره ۲، سال چهارم، ۱-۱۴.
- Armaghani, D. J., Koopialipoor, M., Bahri, M., Hasanipanah, M., Tahir, M. M., 2020. A SVR-GWO technique to minimize flyrock distance resulting from blasting, *Bulletin of Engineering Geology and the Environment*, 79(8): 4369-4385.
- Awad, M., Khanna, R., Awad, M., & Khanna, R., 2015. Support vector regression. *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, 67-80.
- Bobet, A., Einstein, H. H., 1998. Fracture coalescence in rock-type materials under uniaxial and biaxial compression, *International Journal of Rock Mechanics and Mining Sciences*, 35(7): 863-888.
- Breiman, L. (2001). Random forest, *Machine Learning*, 45(1): 5-32.
- Buskirk, T. D., 2018. Surveying the forests and sampling the trees: An overview of classification and regression trees and random forests with applications in survey research, *Survey Practice*, 11(1).
- Cao, P., Liu, T., Pu, C., Lin, H., 2015. Crack propagation and coalescence of brittle rock-like specimens with pre-existing cracks in compression, *Engineering geology*, 187: 113-121.
- Chen, Q., Huang, M., Duan, J., 2022. Experimental Study on the Crack Initiation and Propagation of Unequal Cracks in Rock-Like Materials, *Advances in Materials Science and Engineering*, 2022.
- Cheng, H., Zhou, X., Zhu, J., Qian, Q., 2016. The effects of crack openings on crack initiation, propagation and coalescence behavior in rock-like materials under uniaxial compression, *Rock Mechanics and Rock Engineering*, 49: 3481-3494.
- Haeri, H., 2015. Propagation mechanism of neighboring cracks in rock-like cylindrical specimens under uniaxial compression, *Journal of Mining Science*, 51(3): 487-496.
- Haeri, H., Shahriar, K., Marji, M. F., Moarefvand, P., 2014. Experimental and numerical study of crack propagation and coalescence in pre-cracked rock-like disks, *International Journal of Rock Mechanics and Mining Sciences*, 67: 20-28.
- Hastie, T., Friedman, J., Tibshirani, R., 2017. *The elements of Statistical Learning: Data Mining, Inference, and prediction*. Springer.
- Huang, Y. H., Yang, S. Q., Tian, W. L., Zeng, W., Yu, L. Y., 2016. An experimental study on fracture mechanical behavior of rock-like materials containing two unparallel fissures under uniaxial compression, *Acta Mechanica Sinica*, 32: 442-455.
- Huang, C., Yang, W., Duan, K., Fang, L., Wang, L., Bo, C., 2019. Mechanical behaviors of the brittle rock-like specimens with multi-non-persistent joints under uniaxial compression, *Construction and Building Materials*, 220: 426-443.
- Lajtai, E. Z., Carter, B. J., Ayari, M. L., 1990. Criteria for brittle fracture in compression, *Engineering Fracture Mechanics*, 37(1): 59-74.
- Li, X., Bai, Y., Chen, X., Zhao, X., Lv, M., 2021. Experimental and numerical study on crack propagation and coalescence in rock-like materials under compression, *The Journal of Strain Analysis for Engineering Design*, 56(8): 548-562.
- Lin, H., Li, S., & Zhang, X., 2024. Macro-micro failure and crack coalescence behavior of soft-hard composite rock with three parallel joints under uniaxial compression, *Journal of Materials Research and Technology*.
- Lin, Q., Cao, P., Wen, G., Meng, J., Cao, R., Zhao, Z., 2021. Crack coalescence in rock-like specimens with two dissimilar layers and pre-existing double parallel joints under uniaxial compression, *International Journal of Rock Mechanics and Mining Sciences*, 139: 104621.
- Liu, X., Liu, Q., Liu, B., Zhu, Y., Zhang, P., 2019. Failure behavior for rocklike material with cross crack under biaxial compression, *Journal of Materials in Civil Engineering*, 31(2): 06018025.
- Liu, X., Tang, H., Ding, Y., Yan, D., 2022. Investigating the performance of machine learning models combined with different feature selection methods to estimate the energy consumption of buildings, *Energy and Buildings*, 273: 112408.

- Lundberg, S., and Lee, S.I., 2017. A unified approach to interpreting model predictions. arXiv preprint arXiv:1705.07874.
- Mughieda, O., Karasneh, I., 2006. Coalescence of offset rock joints under biaxial loading, *Geotechnical and Geological Engineering*, 24: 985-999.
- Pan, W., Wang, X., Liu, Q., Yuan, Y., Zuo, B., 2019. Non-parallel double-crack propagation in rock-like materials under uniaxial compression, *International Journal of Coal Science and Technology*, 6: 372-387.
- Rad, H. N., Hasanipanah, M., Rezaei, M., Eghlim, A. L., 2018. Developing a least squares support vector machine for estimating the blast-induced flyrock, *Engineering with Computers*, 34: 709-717.
- Sagong, M., Bobet, A., 2002. Coalescence of multiple flaws in a rock-model material in uniaxial compression, *International Journal of Rock Mechanics and Mining Sciences*, 39(2): 229-241.
- Shen, B., Stephansson, O., Einstein, H. H., Ghahreman, B., 1995. Coalescence of fractures under shear stresses in experiments, *Journal of Geophysical Research: Solid Earth*, 100(B4): 5975-5990.
- Shi, X. Z., Jian, Z. H. O. U., Wu, B. B., Huang, D., Wei, W. E. I., 2012. Support vector machines approach to mean particle size of rock fragmentation due to bench blasting prediction, *Transactions of Nonferrous Metals Society of China*, 22(2): 432-441.
- Strobl, C., Boulesteix, A. L., Zeileis, A., Hothorn, T., 2007. Bias in random forest variable importance measures: Illustrations, sources and a solution, *BMC bioinformatics*, 8: 1-21.
- Tian, W. L., Yang, S. Q., 2017. Experimental and numerical study on the fracture coalescence behavior of rock-like materials containing two non-coplanar filled fissures under uniaxial compression, *Geomechanics and engineering*, 12(3): 541-560.
- Vapnik, V. N. (1995). *The nature of statistical learning theory*, New York: Springer.
- Vapnik, V. (1999). *The nature of statistical learning theory*, Springer, Berlin.
- Wang, M., Wan, W., Zhao, Y., 2020. Experimental study on crack propagation and the coalescence of rock-like materials with two preexisting fissures under biaxial compression, *Bulletin of Engineering Geology and the Environment*, 79(6): 3121-3144.
- Wong, R. H., Chau, K. T., 1998. Crack coalescence in a rock-like material containing two cracks, *International Journal of Rock Mechanics and Mining Sciences*, 35(2): 147-164.
- Wong, R. H. C., Chau, K. T., Tang, C. A., Lin, P., 2001. Analysis of crack coalescence in rock-like materials containing three flaws—part I: experimental approach, *International Journal of Rock Mechanics and Mining Sciences*, 38(7): 909-924.
- Yilmaz, I., Kaynar, O., 2011. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils, *Expert System with Application*, 38: 5958-5966.
- Zhang, X. P., Liu, Q., Wu, S., Tang, X., 2015. Crack coalescence between two non-parallel flaws in rock-like material under uniaxial compression, *Engineering Geology*, 199: 74-90.
- Zhang, F., O'Donnell, L. J., 2020. Support vector regression, In *Machine learning* (pp. 123-140). Academic Press.
- Zhao, C., Niu, J., Zhang, Q., Zhao, C., Zhou, Y., 2019. Failure characteristics of rock-like materials with single flaws under uniaxial compression, *Bulletin of Engineering Geology and the Environment*, 78: 593-603.
- Zhao, Y., Liao, J., Wang, Y., Liu, Q., Lin, H., Chang, L., 2020. Crack coalescence patterns and local strain behaviors near flaw tip for rock-like material containing two flaws subjected to biaxial compression, *Arabian Journal of Geosciences*, 13: 1-18.
- Zhao, Y., Zhang, L., Wang, W., Pu, C., Wan, W., Tang, J., 2016. Cracking and stress-strain behavior of rock-like material containing two flaws under uniaxial compression, *Rock Mechanics and Rock Engineering*, 49: 2665-2687.
- Zhou, J., Li, X., Shi, X. 2012. Long-term prediction model of rockburst in underground openings using heuristic algorithms and support vector machines, *Safety science*, 50(4): 629-644.
- Zhou, J., Shi, X., Du, K., Qiu, X., Li, X., Mitri, H.S., 2016. Feasibility of Random-Forest Approach for Prediction of Ground Settlements Induced by the Construction of a Shield-Driven Tunnel, *International Journal of Geomechanics*, 17(6).
- Zhou, J., Qiu, Y., Zhu, S., Armaghani, D. J., Li, C., Nguyen, H., Yagiz, S., 2021. Optimization of support vector machine through the use of metaheuristic algorithms in forecasting TBM advance rate, *Engineering Applications of Artificial Intelligence*, 97: 104015.

Zhou, X. P., Cheng, H., Feng, Y. F., 2014. An experimental study of crack coalescence behaviour in rock-like materials containing multiple flaws under uniaxial compression, *Rock Mechanics and Rock Engineering*, 47:1961-1986.