

پیش‌بینی چندکلاسه شدت مچاله‌شوندگی توده‌سنگ در تونل‌ها با استفاده از مدل‌های یادگیری ماشین

امیرحسین قاندي^۱؛ محمد حسین کدخدایی^۲؛ ابراهیم قاسمی^۳

۱- دانشکده مهندسی معدن، دانشگاه صنعتی اصفهان، اصفهان، ایران.

۲- دانشکده مهندسی معدن، دانشگاه صنعتی همدان، همدان، ایران.

دریافت: ۱۴۰۵/۰۵/۱۵؛ پذیرش: ۱۴۰۵/۰۶/۳۰

(*نویسنده مسئول: e_ghasemi@iut.ac.ir)

چکیده

مچاله‌شوندگی توده‌سنگ یکی از چالش‌های اصلی حفاری تونل در توده‌سنگ‌های ضعیف و شرایط تنش بالا است که می‌تواند موجب تغییر شکل قابل توجه، افزایش فشار بر سیستم نگهداری، کاهش سرعت پیشروی و ناپایداری تونل شود. در این پژوهش، دو مدل یادگیری ماشین شامل درخت تصمیم و درخت مدل لجستیک برای پیش‌بینی شدت مچاله‌شوندگی در پنج کلاس توسعه یافتند. پایگاه داده شامل ۱۳۹ مورد مطالعاتی از پروژه‌های تونل‌سازی در چین، نپال، هند، اتریش، ژاپن و ترکیه بود. پنج پارامتر شامل ارتفاع روباره، قطر تونل، سختی سیستم نگهداری، نسبت تنش به کرنش و شاخص کیفیت پایه توده‌سنگ به عنوان متغیرهای ورودی انتخاب شدند. برای رفع عدم توازن کلاس‌ها، روش نمونه سازی مصنوعی به کار رفت و تعداد نمونه‌ها به ۱۹۰ مورد، با ۳۸ نمونه در هر کلاس، افزایش یافت. عملکرد مدل‌ها با اعتبارسنجی متقابل ۱۰ بخشی و معیارهای دقت، حساسیت، صحت، ضریب همبستگی متو، کاپا و AUC ارزیابی شد. نتایج نشان داد درخت مدل لجستیک با دقت ۸۴.۲۱ درصد و AUC برابر ۰.۹۶ عملکرد بهتری از درخت تصمیم با دقت ۸۲.۱۰ درصد و AUC برابر ۰.۹۴ دارد. با این حال، سادگی ساختار درخت تصمیم، تفسیرپذیری و کاربرد عملی آن را تقویت می‌کند. هر دو مدل توانایی قابل قبولی در پیش‌بینی چندکلاسه شدت مچاله‌شوندگی نشان دادند و می‌توانند به عنوان ابزاری کمکی در ارزیابی اولیه ریسک مچاله‌شوندگی به کار روند.

مچاله‌شوندگی، یادگیری ماشین، طبقه‌بندی چند کلاسه، نمونه سازی مصنوعی، تونل‌سازی

واژگان کلیدی

۱- مقدمه

مچاله‌شوندگی توده سنگ است که عمدتاً ناشی از تغییر شکل‌های بزرگ و وابسته به زمان توده سنگ اطراف تونل است.

مچاله‌شوندگی به پدیده‌ای اطلاق می‌شود که در آن توده سنگ اطراف تونل، تحت تأثیر تنش‌های برجا، تنش‌های القایی ناشی از حفاری و خصوصیات مکانیکی ضعیف سنگ، دچار تغییر شکل پلاستیک و مستمر می‌شود؛ این تغییر شکل‌ها اغلب ماهیتی وابسته به زمان دارند و می‌توانند به افزایش تدریجی فشار وارد بر سیستم نگهداری منجر شوند

یکی از مهم‌ترین مراحل طراحی و اجرای تونل، انتخاب و طراحی سیستم نگهداری مناسب است. وظیفه اصلی سیستم نگهداری، کنترل تغییر شکل‌ها و جابه‌جایی‌های ایجاد شده در توده سنگ اطراف فضای زیرزمینی و تضمین پایداری تونل در مراحل حفاری و بهره‌برداری است. شرایط زمین‌شناسی و ژئوتکنیکی نامطلوب می‌تواند رفتار توده سنگ را به شدت تحت تأثیر قرار داده و چالش‌های متعددی را در فرآیند تونل‌سازی ایجاد کند. یکی از مهم‌ترین این پدیده‌ها،

طولانی در اجرای پروژه و تحمیل هزینه‌های قابل‌توجه می‌شود؛ از این رو، پیش‌بینی صحیح وقوع یا عدم وقوع این پدیده یکی از نخستین و مهم‌ترین گام‌ها در تحلیل و طراحی پروژه‌های تونل‌سازی است و پیش‌بینی نادرست آن می‌تواند خطرات جانی برای پرسنل و کارکنان تونل‌سازی نیز به همراه داشته باشد.

نیاز روزافزون به پیش‌بینی میزان جابه‌جایی‌ها و شدت مچاله‌شوندگی، منجر به توسعه روش‌های متعدد تجربی، تحلیلی و عددی در این زمینه شده است. به‌طور کلی، بررسی رفتار مچاله‌شوندگی توده سنگ در دو رویکرد اصلی، یعنی تسلیم‌شدگی توده سنگ و رفتار وابسته‌به‌زمان آن، صورت می‌گیرد [۱] و روش‌های پیش‌بینی مچاله‌شوندگی را می‌توان به‌طور کلی در سه دسته روش‌های تحلیلی، روش‌های عددی و روش‌های تجربی طبقه‌بندی کرد.

روش‌های تحلیلی بر پایه معادلات مکانیک محیط‌های پیوسته و تئوری‌های مکانیک سنگ بنا شده‌اند و می‌کوشند با استفاده از مدل‌سازی ریاضی، رفتار توده سنگ اطراف تونل را پیش‌بینی کنند [۹، ۱۰]. در مقابل، شبیه‌سازی عددی با استفاده از نرم‌افزارهایی نظیر *FLAC3D*، *PLAXIS* و *UDEC* به‌طور گسترده برای تحلیل مچاله‌شوندگی در پروژه‌های تونل‌سازی به کار می‌رود و امکان بررسی توزیع تنش، کرنش و تغییرشکل در محیط اطراف تونل و ارزیابی اثر پارامترهای ژئوتکنیکی، شرایط تنش اولیه و نوع سیستم نگهداری را فراهم می‌کند. با این حال، هر دو روش تحلیلی و عددی محدودیت‌هایی دارند: روش تحلیلی، هرچند تا حدی پدیده مچاله‌شوندگی را تبیین می‌کند، قادر به توصیف جامع گذار از تعادل استاتیکی توده سنگ به ناپایداری دینامیکی نیست؛ و روش عددی نیز علی‌رغم توانایی بازسازی فرآیند وقوع و گسیختگی در شرایط مختلف، به داده‌های ورودی دقیق، کالیبراسیون صحیح ویژگی‌های فیزیکی-مکانیکی سنگ و تجربه بالای کاربر برای تفسیر نتایج نیاز دارد [۱۱]. در مقابل، روش‌های تجربی بر پایه مقایسه و تجربه حاصل از داده‌های جمع‌آوری‌شده از پروژه‌های واقعی شکل می‌گیرند و به دلیل سادگی و سهولت کاربرد، از محبوب‌ترین رویکردهای ارزیابی پتانسیل مچاله‌شوندگی به شمار می‌روند. در گذشته، توسعه روش‌های تجربی عمدتاً بر پایه تحلیل‌های آماری کلاسیک مانند رگرسیون خطی و لجستیک صورت می‌گرفت؛

[۱]. از دیدگاه مکانیک سنگ، هنگامی که تنش‌های القایی ایجادشده در اثر حفاری زیرزمینی از مقاومت برشی توده سنگ در برگریزنده فراتر رود، ناحیه‌ای پلاستیک و تغییرشکل‌یافته در اطراف تونل شکل می‌گیرد و پدیده مچاله‌شوندگی آغاز می‌شود. این پدیده معمولاً در توده‌سنگ‌های ضعیف، در اعماق زیاد و تحت تنش‌های بالا مشاهده می‌شود؛ با این حال، تونل‌های کم‌عمق واقع در مناطق تکتونیکی فعال با تنش‌های افقی برجای بالا نیز می‌توانند مستعد مچاله‌شوندگی باشند [۲، ۳]. علاوه بر این، مچاله‌شوندگی ممکن است در سنگ‌های نرم و توده‌سنگ‌های ضعیف، حتی در اعماق نسبتاً کم و تحت شرایط زمین‌شناسی پیچیده نیز رخ دهد [۴].

با وجود مطالعات گسترده، به‌دلیل پیچیدگی سازوکارهای حاکم بر مچاله‌شوندگی و تأثیر هم‌زمان عوامل مختلف زمین‌شناسی، ژئوتکنیکی و تنش‌های برجا، هنوز تعریف واحد و جامعی که بتواند همه جنبه‌های این پدیده را پوشش دهد، ارائه نشده است. از این رو، پژوهشگران مختلف بر اساس دیدگاه‌های نظری، مشاهدات صحرایی و مطالعات موردی، تعاریف متفاوتی از مچاله‌شوندگی ارائه کرده‌اند [۵-۷].

در میان این تعاریف، تعریف ارائه‌شده توسط *Barla* جامع‌تر است [۱]؛ زیرا به‌طور هم‌زمان تغییرشکل‌های بزرگ، وابستگی به زمان و رفتار خزش توده‌سنگ را در نظر می‌گیرد. به همین دلیل، این تعریف در مطالعات مرتبط با پدیده مچاله‌شوندگی مورد توجه گسترده قرار گرفته است.

تشخیص به‌موقع زمین‌های مستعد مچاله‌شوندگی و طراحی سیستم نگهداری متناسب با آن، از جمله وظایف حساس، دشوار و در عین حال اجتناب‌ناپذیر مهندسان تونل است. مچاله‌شوندگی علاوه بر مشکلاتی که پس از حفاری، مانند اعمال فشارهای بلندمدت و احتمال شکست سیستم نگهداری ایجاد می‌کند، در حین عملیات حفاری نیز می‌تواند مشکلاتی از قبیل کاهش نرخ پیشروی و گیرکردن ماشین‌های حفاری تمام‌مقطع (*TBM*) به همراه داشته باشد؛ به‌گونه‌ای که در برخی موارد، این پدیده تعیین‌کننده امکان‌پذیری اجرای پروژه است [۸]. برآورد میزان مچاله‌شوندگی، پیش‌بینی پیامدهای آن و انتخاب روش حفاری و نگهداری مناسب، از چالش‌های اصلی مهندسان تونل به شمار می‌رود. تونل‌سازی در توده‌سنگ‌های مستعد مچاله‌شوندگی اغلب موجب تأخیرهای

اما در سال‌های اخیر، با رشد سریع تکنیک‌های یادگیری ماشین، کاربرد این روش‌ها در توسعه مدل‌های تجربی برای پیش‌بینی وقوع و شدت مچاله‌شوندگی به‌طور چشمگیری گسترش یافته است [۱۲]. مروری بر پیشینه پژوهش نشان می‌دهد که تکنیک‌های یادگیری ماشین، در مقایسه با روش‌های آماری سنتی مانند تحلیل رگرسیون، عموماً از دقت و انعطاف‌پذیری بالاتری در پیش‌بینی مچاله‌شوندگی برخوردارند.

طی یک دهه اخیر، پژوهشگران متعددی الگوریتم‌های یادگیری ماشین گوناگونی را برای پیش‌بینی مچاله‌شوندگی توسعه داده‌اند (جدول ۱). بررسی پیشینه پژوهش نشان می‌دهد که اگرچه مطالعات متعددی با استفاده از تکنیک‌های یادگیری ماشین به پیش‌بینی مچاله‌شوندگی پرداخته‌اند، اکثر این مطالعات مسئله را به‌صورت یک طبقه‌بندی دوکلاسه (وقوع یا عدم وقوع مچاله‌شوندگی) یا حداکثر سه کلاسه فرموله کرده‌اند و تعداد محدودی از پژوهش‌ها به پیش‌بینی چندکلاسه شدت مچاله‌شوندگی پرداخته‌اند؛ در حالی که از منظر مهندسی، تفکیک دقیق‌تر سطوح شدت مچاله‌شوندگی اطلاعات کاربردی‌تری برای طراحی سیستم نگهداری و انتخاب روش حفاری در اختیار مهندسان قرار می‌دهد. از سوی دیگر، بیشتر مطالعات پیشین بر الگوریتم‌هایی نظیر *ANN*، *SVM* و روش‌های ترکیبی مبتنی بر بهینه‌سازی فراابتکاری متمرکز بوده‌اند که علی‌رغم دقت بالا، ماهیت جعبه‌سیاه دارند و استخراج قواعد تصمیم‌گیری قابل‌فهم برای مهندسان از آن‌ها دشوار است. در مقابل، مدل‌های درختی نظیر درخت تصمیم (*J48*) و درخت مدل لجستیک (*LMT*)، به دلیل ساختار شفاف و قابلیت استخراج قواعد صریح تصمیم‌گیری، از قابلیت تفسیرپذیری بالاتری برخوردارند؛ ویژگی‌ای که کاربرد عملی آن‌ها را در مهندسی تونل تسهیل می‌کند. با این حال، کاربرد این دو الگوریتم، به‌ویژه در قالب پیش‌بینی چندکلاسه (پنج‌سطحی) شدت مچاله‌شوندگی، کمتر مورد بررسی قرار گرفته است.

با توجه به خلأ پژوهشی یادشده، هدف اصلی پژوهش حاضر، توسعه و مقایسه دو مدل یادگیری ماشین درخت تصمیم (*J48*) و درخت مدل لجستیک (*LMT*) به‌عنوان مدل‌هایی تفسیرپذیر و کاربردمحور، برای پیش‌بینی چندکلاسه (پنج‌سطحی) شدت مچاله‌شوندگی توده سنگ در تونل‌هاست.

اهمیت این پژوهش از آن جهت است که برخلاف بسیاری از مطالعات پیشین که مسئله را به‌صورت دوکلاسه یا سه‌کلاسه فرموله کرده‌اند، رویکرد پنج‌سطحی به‌کاررفته در این مطالعه امکان تفکیک دقیق‌تر شدت مچاله‌شوندگی را فراهم می‌آورد و از این رو، اطلاعات کاربردی‌تر و قابل‌اتکاتری را در اختیار مهندسان برای طراحی سیستم نگهداری و انتخاب روش حفاری قرار می‌دهد. علاوه بر این، برخلاف بسیاری از مدل‌های یادگیری ماشین با ماهیت جعبه‌سیاه که در پژوهش‌های پیشین به کار گرفته شده‌اند، مدل‌های درختی مورد استفاده در این پژوهش، به دلیل ساختار شفاف و قابلیت استخراج قواعد صریح تصمیم‌گیری، تفسیرپذیری بالاتری دارند و امکان درک منطق پیش‌بینی را برای مهندسان طراح فراهم می‌کنند؛ ویژگی‌ای که کاربرست عملی آن‌ها را در پروژه‌های واقعی تونل‌سازی تسهیل می‌کند. نتایج حاصل از این پژوهش، علاوه بر غنی‌سازی ادبیات موجود در زمینه پیش‌بینی هوشمند مچاله‌شوندگی، می‌تواند به‌عنوان ابزاری کمکی برای ارزیابی اولیه ریسک مچاله‌شوندگی در پروژه‌های تونل‌سازی در اختیار مهندسان قرار گیرد.

۲- پایگاه داده

مدل‌های یادگیری ماشین توسعه‌یافته در این پژوهش، بر پایه پایگاه داده‌ای متشکل از ۱۳۹ مورد واقعی مچاله‌شوندگی، جمع‌آوری شده از پروژه‌های تونل‌سازی اجراشده در کشورهای چین (۱۱۰ مورد)، نپال (۲۲ مورد)، هند (۳ مورد)، اتریش (۲ مورد)، ژاپن (۱ مورد) و ترکیه (۱ مورد)، بنا شده است [۱۹،۲۹]. این پایگاه داده به دلیل تنوع جغرافیایی و زمین‌شناسی پروژه‌های مورد بررسی، از قابلیت تعمیم‌پذیری مناسبی برای توسعه مدل‌های پیش‌بینی برخوردار است. پارامترهای ورودی به‌کاررفته در این پایگاه داده شامل پنج پارامتر ارتفاع روباره (H) بر حسب متر، قطر تونل (D) بر حسب متر، سختی سیستم نگهداری (K) بر حسب مگاپاسکال، نسبت مقاومت به تنش (SSR) و شاخص کیفیت پایه توده سنگ (BQ) است. انتخاب این پارامترها صرفاً بر پایه فراوانی کاربرد آن‌ها در پیشینه پژوهش نبوده، بلکه بر مبنای نقش مستقیم و اثبات‌شده هریک در مکانیزم فیزیکی وقوع و توسعه مچاله‌شوندگی صورت گرفته است. ارتفاع روباره (H) به‌عنوان معیاری از تنش برجای قائم عمل می‌کند و افزایش آن، سطح تنش وارد بر توده‌سنگ اطراف تونل و در نتیجه

جدول ۱- برخی از رویکرد های تجربی پیشین با استفاده از تکنیک های یادگیری ماشین

ارائه دهنده یا ارائه دهندگان	سال	پارامتر های ورودی	تکنیک یادگیری ماشین	دقت (%)	تعداد دسته داده	منبع
Jimenez and Recio	۲۰۱۱	H, Q	LR	۸۷.۱۰	۶۲	[۳]
Shafiei et al.	۲۰۱۲	H, Q	SVM	۸۴.۱۰	۱۹۸	[۱۳]
Feng and Jimenez	۲۰۱۵	K, Q, H, D, SSR	NB	۸۶.۶۵	۱۶۶	[۱۴]
Sun et al.	۲۰۱۸	D, H, K, Q	SVM	۸۸.۱۳	۱۱۷	[۱۵]
Ghasemi and Gholizadeh	۲۰۱۸	H, B, Q	KNN, DT	۹۵.۰۰	۱۱۵	[۱۶]
Ghasemi and Gholizadeh	۲۰۱۹	H, Q	BLR, LDA	۸۷.۰۰	۲۲۰	[۱۷]
Zhang et al.	۲۰۲۰	H, Q, D, K, SSR	$BPNN, SVM, DT, NB, KNN, LR, FA$	۹۶.۰۰	۱۶۶	[۱۸]
Chen et al.	۲۰۲۰	SSR, GC, H, D, K	DT	۹۳.۵۰	۱۵۴	[۱۹]
Huang et al.	۲۰۲۲	D, H, Q, K	$SVM, BPNN$	۹۲.۱۱	۱۷۸	[۲۰]
Fathipour-Azar	۲۰۲۲	D, H, Q, K	DT, RBC, BC, LC	۹۰.۰۰	۱۱۷	[۲۱]
Zhou et al.	۲۰۲۲	H, K, Q, D, ε	$SVM, ANN, GP (WOA)$	۹۵.۶۵	۱۱۴	[۲۲]
Bo et al.	۲۰۲۳	H, Q, SSR, K, D	$GBC, ETC, ABC, LR (BOA, SSA)$	۹۸.۰۰	۱۶۶	[۲۳]
Kadkhodaei et al.	۲۰۲۳	H, Q, B	GEP	۹۵.۹۲	۱۱۵	[۲۴]
Geng et al.	۲۰۲۳	SSR, BQ, D, K	$XGBoost (BO, EWM)$	۹۱.۷۰	۱۳۹	[۲۵]
Ghasemi et al.	۲۰۲۴	$D, H, Q, \text{ and } K$	LMT, GEP	۸۸.۲۰	۱۱۷	[۱۲]
Liang et al.	۲۰۲۴	H, GC, SSR, K, D	$SVM, RF, XGBoost, MLP, KNN$	۹۰.۷۷	۱۶۲	[۱۱]
Kadkhodaei et al.	۲۰۲۴	D, H, Q, K	$XGBoost-PSO, RF-EWM$	۹۲.۲۰	۲۶۳	[۲۶]
Hyoung et al.	۲۰۲۴	H, D, Q, RMR, E	$SVM-PSO$	۹۴.۰۰	۱۱۷	[۲۷]
Guan et al.	۲۰۲۵	D, H, SSR, K	$SVM, RF, DT, XGBoost, LGBM, KNN$	۹۶.۸۰	۳۰۵	[۲۸]

LMT = مدل درخت لجستیک، DT = درخت تصمیم، D = قطر تونل، K = سختی سیستم نگهداری، Q = شاخص کیفیت حفاری تونل در سنگ، H = عمق تونل، ε = تغییر شکل، SSR = نسبت مقاومت به تنش، BQ = شاخص اصلاح شده کیفیت توده سنگ، GBC = طبقه‌بندی کننده تقویت گرادایانی، GC = کلاس‌های توده سنگ دربرگیرنده بر اساس سیستم BQ ، GEP = برنامه‌نویسی بیان ژن، SVM = ماشین بردار پشتیبان، NB = ناوی بیز، LR = رگرسیون لجستیک، $BPNN$ = شبکه عصبی پس‌انتشار، KNN = نزدیک‌ترین همسایه، FA = الگوریتم کرم شب‌تاب، LC = طبقه‌بندی کننده تیل، ANN = شبکه عصبی مصنوعی، GP = فرایند گاوسی، $IGWO$ = الگوریتم بهبود یافته بهینه‌سازی گرگ خاکستری، RBC = طبقه‌بندی کننده مبتنی بر قواعد، BC = طبقه‌بندی کننده بیزی، ETC = طبقه‌بندی کننده $Extra-Trees$ ، ABC = طبقه‌بندی کننده $AdaBoost$ ، BOA = الگوریتم بهینه‌سازی بیزی، SSA = الگوریتم جستجوی گنجشک، EGB = تقویت گرادایانی افراطی، WOA = الگوریتم بهینه‌سازی نهنگ، RF = جنگل تصادفی، $LGBM$ = ماشین تقویت گرادایانی سبک، $XGBoost$ = تقویت گرادایان شدید، MLP = پرسپترون چندلایه، E = مدول تغییر شکل، RMR = رده‌بندی توده سنگ، N = عدد توده سنگ، a = شعاع تونل، J_f = ضریب درزه، $\sigma = 1/\sigma$ = تنش برجا قائم.

غیرمستقیم، مقاومت برشی و رفتار تغییرشکلی توده سنگ را کنترل می‌کند. در نهایت، سختی سیستم نگهداری (K) نمایانگر توان سازه نگهداری در مهار تغییرشکل‌های وابسته به زمان توده سنگ است؛ سیستم نگهداری با سختی ناکافی، امکان توسعه آزادانه‌تر تغییرشکل‌ها را فراهم می‌کند، در حالی که سختی بیش از حد نیز می‌تواند به تجمع فشارهای غیرمنتظره بر سازه نگهداری منجر شود. نقش هریک از این پارامترها در بروز و شدت مچاله‌شوندگی، به همراه روش محاسبه یا اندازه‌گیری آن‌ها، در جدول ۲ ارائه شده است. در شکل ۱ هیستوگرام و توضیحات آماری پایه و توزیع تجمعی پارامترهای مورد استفاده در این پژوهش به نمایش درآمده


قطر تونل (D) نیز از طریق تأثیر بر میدان تنش القایی اطراف حفره و مساحت ناحیه تسلیم‌یافته، بر شدت و حجم تغییرشکل‌های مشاهده‌شده اثرگذار است. نسبت مقاومت به تنش (SSR)، به عنوان یک شاخص ترکیبی، مستقیماً نسبت مقاومت فشاری توده سنگ به تنش برجا را بیان می‌کند و از این رو، ارتباط علی روشنی با آغاز و شدت مچاله‌شوندگی دارد؛ به گونه‌ای که کاهش این نسبت به زیر مقادیر بحرانی، با ورود توده سنگ به ناحیه گسیختگی و تشدید تغییرشکل‌های وابسته به زمان همراه است. شاخص کیفیت پایه توده سنگ (BQ) نیز وضعیت کلی درزه‌داری، مقاومت و یکپارچگی توده سنگ را در قالب یک شاخص کمی بازتاب می‌دهد و به طور

جدول ۲- ویژگی پارامترهای ورودی پایگاه داده [۱۹،۲۵].

پارامتر	نقش پارامتر در رفتار مچاله‌شوندگی	روش تعیین پارامتر
ارتفاع روباره (H)	افزایش تنش عمودی روی تونل؛ H بالاتر منجر به پتانسیل مچاله‌شوندگی بیشتر می‌شود.	اندازه‌گیری بر اساس نقشه پروفیل تونل
قطر تونل (D)	قطر بزرگتر، حجم سنگ دست‌خورده را افزایش می‌دهد و منجر به تغییر شکل بیشتر می‌شود.	$D = \sqrt{4A/\pi}$
شاخص کیفیت پایه توده سنگ (BQ)	نشان دهنده وضعیت کلی توده سنگ است؛ BQ کمتر = کیفیت پایین تر = خطر مچاله‌شوندگی بالاتر	$BQ = 63.029 \ln(Q) + 327.5$
نسبت مقاومت به تنش (SSR)	وقتی $SSR < 1$ باشد، توده سنگ وارد مناطق شکست/پلاستیک می‌شود؛ شاخص کلیدی احتمال مچاله‌شوندگی.	$SSR = \frac{\sigma_{cm}}{\gamma \cdot H}$
سختی سیستم نگهداری (K)	سختی بالاتر، تغییر شکل‌ها را محدود می‌کند؛ برای کنترل رفتار مچاله‌شوندگی حیاتی است.	$K_c = \frac{E_c [R^2 - (R - t_c)^2]}{1 + v_c [(1 - 2v_c)R^2 + (R - t_c)^2]}$ $K_{sb} = p \frac{R}{u}$
$\frac{1}{K_b} = \frac{s_c s_l}{R} \left[\frac{4l}{\pi d_b E_b} + Q_{ld} \right]$ R شعاع تونل، l طول آزاد میل مهار ها یا کابل ها، d_b قطر میل مهار ها یا کابل ها، E_b مدول الاستیسیته میل مهار ها و یا کابل و Q_{ld} ثابت نمودار بارگذاری - تغییر شکل، E_c مدول الاستیسیته بتن، t_c ضخامت بتن، v_c ضریب پواسون، s_c فاصله جانبی میل مهار ها و یا کابل، s_l فاصله طولی میل مهارها یا و یا کابل ها در طول تونل، p فشار وارد بر سیستم نگهداری، u تغییر شکل شعاعی تونل، A مساحت سطح مقطع تونل، K_c سختی فعال سیستم نگهداری از نوع شاتکریت، K_{sb} سختی سیستم نگهداری از نوع قاب فولادی با پر کننده، K_b سختی سیستم نگهداری از نوع میل مهار و یا کابل، BQ شاخص کیفیت پایه توده سنگ بر اساس سیستم Q		

است. علاوه بر آن خلاصه آماره‌های توصیفی آن‌ها در جدول ۳ ارائه شده است. پارامتر خروجی (متغیر هدف) در این پایگاه داده، سطح مچاله‌شوندگی توده سنگ است که بر اساس طبقه‌بندی ارائه‌شده توسط هوک و مارینوس [۲] و با استفاده از پارامتر درصد کرنش شعاعی (ε) در پنج سطح کیفی (I) تا (V) تعریف شده است (جدول ۴). بر این اساس، از مجموع ۱۳۹ مورد موجود در پایگاه داده، ۲۸ مورد بدون مچاله‌شوندگی (کلاس I)، ۳۸ مورد مچاله‌شوندگی خفیف

(کلاس II)، ۳۲ مورد مچاله‌شوندگی متوسط (کلاس III)، ۲۶ مورد مچاله‌شوندگی شدید (کلاس IV) و ۱۵ مورد مچاله‌شوندگی بسیار شدید (کلاس V) گزارش شده است [۲۵]. به‌منظور سهولت در فرآیند مدل‌سازی، این پنج سطح کیفی به‌صورت متغیر خروجی عددی در بازه صفر تا چهار کدگذاری شدند؛ به‌طوری‌که مقدار صفر معادل عدم مچاله‌شوندگی و مقدار چهار معادل مچاله‌شوندگی بسیار شدید در نظر گرفته شد.




شکل ۱- هیستوگرام و توضیحات آماری پایه و توزیع تجمعی پارامترهای پایگاه داده

جدول ۳- آماره‌های توصیفی پارامترهای ورودی پایگاه داده.

پارامتر	واحد	کمینه	بیشینه	میانگین	انحراف معیار	ضریب تغییرات
ارتفاع روباره (H)	m	۴.۵۱	۱۱۰۰	۳۵۳.۰۰۸	۲۱۶.۸۲۰	۰.۶۱
قطر تونل (D)	m	۴	۱۴	۹.۳۴۱	۲.۹۶۵	۰.۳۲
شاخص کیفیت پایه توده سنگ (BQ)	-	۷۰	۴۴۱	۲۰۳.۵۳۷	۷۷.۴۹۹	۰.۳۸
نسبت مقاومت به تنش (SSR)	-	۰.۰۰۸	۱.۵۵	۰.۲۹۵	۰.۲۷۶	۰.۹۴
سختی سیستم نگهداری (K)	MPa	۲.۹۸	۱۹۷۹.۵۶	۱۱۴۹.۰۸۶	۴۹۳.۷۳۴	۰.۴۳

نمونه‌های مصنوعی جدیدی تولید می‌کند. این رویکرد بر پایه «فضای ویژگی‌ها» عمل می‌کند و نه «فضای داده‌ها»؛ به این معنا که روابط میان مقادیر ویژگی‌های نمونه‌های موجود را در نظر می‌گیرد و از این طریق، از بروز بیش‌براز ناشی از تکرار صرف داده‌ها جلوگیری می‌کند [۳۱]. روند کلی الگوریتم این تکنیک در شکل ۳ ارائه شده است.

لازم به ذکر است که در این پژوهش، تکنیک *SMOTE* پیش از اجرای اعتبارسنجی متقاطع و بر روی کل پایگاه داده (نه صرفاً درون هر *fold* آموزشی) اعمال شده است. این انتخاب آگاهانه با توجه به حجم محدود پایگاه داده اصلی (۱۳۹ مورد) و توزیع به‌شدت نامتوازن آن میان پنج کلاس، به‌ویژه کلاس پنجم با تنها ۱۵ نمونه واقعی، صورت گرفته است؛ چراکه در صورت اعمال *SMOTE* صرفاً درون فولدهای آموزشی، فولدهای آزمون از توزیع نامتوازن اصلی پیروی می‌کردند و حجم نمونه‌های کلاس‌های اقلیت در هر *fold* آزمون برای محاسبه پایدار شاخص‌های کلاس‌محور ناکافی می‌بود. هدف اصلی از این رویکرد، فراهم کردن پایگاه داده‌ای متوازن برای ارزیابی منصفانه و قابل‌مقایسه عملکرد مدل‌ها در تمامی پنج سطح شدت مچاله‌شوندگی است. از آنجا که این پایپ‌لاین به‌طور یکسان برای هر دو مدل *J48* و *LMT* به‌کار رفته، مقایسه نسبی عملکرد این دو مدل، که هدف اصلی پژوهش حاضر است، از اعتبار کامل برخوردار است.




شکل ۳- روند کلی الگوریتم *SMOTE*

جدول ۴- طبقه‌بندی سطح مچاله‌شوندگی [۲۵]

سطح مچاله‌شوندگی	شدت	درصد کرنش (ε)
I	بدون مچاله‌شوندگی	کمتر از ۱
II	کم	۱ تا ۲.۵
III	متوسط	۲.۵ تا ۵
IV	شدید	۵ تا ۱۰
V	بسیار شدید	بیشتر از ۱۰

بررسی توزیع داده‌ها در کلاس‌های مختلف (شکل ۲) نشان می‌دهد که پایگاه داده مورد استفاده از عدم توازن قابل‌توجهی در میان کلاس‌ها برخوردار است. برای نمونه، در صورتی که مسئله به‌صورت دوکلاسه (مچاله‌شونده در برابر غیرمچاله‌شونده) در نظر گرفته شود، از مجموع ۱۳۹ مورد، تنها ۲۸ مورد (حدود ۲۰ درصد) در کلاس غیرمچاله‌شونده و ۱۱۱ مورد (حدود ۸۰ درصد) در کلاس مچاله‌شونده با شدت‌های مختلف قرار می‌گیرند. این عدم توازن می‌تواند عملکرد مدل‌های یادگیری ماشین را به‌شدت تحت تأثیر قرار دهد و موجب گرایش مدل به سمت کلاس‌های اکثریت و در نتیجه کاهش دقت و توان تعمیم آن در تشخیص کلاس‌های اقلیت شود.



شکل ۲- توزیع داده‌های پایگاه داده در کلاس‌های مختلف به‌منظور رفع این محدودیت و متعادل‌سازی پایگاه داده، از تکنیک نمونه برداری بیش از حد مصنوعی اقلیت (*SMOTE*) استفاده شده است [۳۰]. برخلاف روش‌های سنتی متعادل‌سازی که صرفاً به تکرار نمونه‌های موجود در کلاس‌های اقلیت اکتفا می‌کنند، تکنیک *SMOTE* با درون‌یابی میان نمونه‌های نزدیک به هم در کلاس اقلیت،


هر گره میانی، آزمونی را بر روی یکی از ویژگی‌های ورودی اعمال می‌کند و بر اساس نتیجه آن آزمون، داده‌ها را از طریق شاخه‌ها به زیرگره‌های بعدی هدایت می‌کند؛ این فرآیند تا رسیدن به گره‌های پایانی، موسوم به برگ، که در آن‌ها کلاس نهایی یا توزیع احتمال کلاس‌ها تعیین می‌شود، تکرار می‌گردد [۳۲]. به این ترتیب، هر مسیر از ریشه تا یک برگ، معادل یک قاعده تصمیم‌گیری به شکل زنجیره‌ای از شرط‌های منطقی (if-then) است که به‌سادگی قابل استخراج و تفسیر برای کاربر نهایی است.

۳-۱- درخت تصمیم (J48)

الگوریتم J48 پیاده‌سازی متن‌باز الگوریتم C4.5 در نرم‌افزار WEKA است، الگوریتمی که خود بهبودیافته الگوریتم پیشین ID3 محسوب می‌شود. معیار اصلی این الگوریتم برای انتخاب ویژگی مناسب در هر گره و تقسیم داده‌ها، نسبت بهره اطلاعاتی است که بر پایه مفهوم آنتروپی شانون تعریف می‌شود. برخلاف معیار بهره اطلاعاتی ساده که در الگوریتم ID3 به کار می‌رود و تمایل به انتخاب ویژگی‌های دارای مقادیر متعدد دارد، نسبت بهره اطلاعاتی با نرمال‌سازی بر اساس آنتروپی ذاتی هر ویژگی، از این سوگیری جلوگیری کرده و انتخابی متعادل‌تر از ویژگی‌های ورودی ارائه می‌دهد. برای ویژگی‌های پیوسته نظیر پارامترهای مورد استفاده در این پژوهش (H ، D ، K ، SSR و BQ)، الگوریتم J48 به‌صورت پویا مقدار آستانه بهینه را برای تبدیل ویژگی به یک شرط دودویی (کوچک‌تر یا بزرگ‌تر از آستانه) تعیین می‌کند. پس از ساخت درخت اولیه، به‌منظور جلوگیری از بیش‌برازش و افزایش توان تعمیم‌پذیری مدل بر روی داده‌های جدید، عملیات هرس پس‌رونده مبتنی بر برآورد نرخ خطا بر روی زیردرخت‌ها اعمال می‌شود که طی آن، شاخه‌هایی که سهم چشمگیری در بهبود دقت طبقه‌بندی ندارند، حذف یا با گره برگ جایگزین می‌شوند.

به‌منظور توسعه مدل، پایگاه داده متعادل‌شده حاصل از تکنیک SMOTE شامل ۱۹۰ نمونه و پنج پارامتر ورودی، به همراه متغیر خروجی کدگذاری‌شده در پنج کلاس (صفر تا چهار)، با استفاده از نرم‌افزار WEKA نسخه ۳.۸.۶ مدل‌سازی شد. درخت تصمیم حاصل از این فرآیند در شکل ۵ ارائه شده است. همان‌گونه که مشاهده می‌شود، درخت به‌دست‌آمده از ساختاری نسبتاً فشرده و در عین حال گویا برخوردار است و

در این پژوهش، تکنیک SMOTE با استفاده از یک اسکریپت نوشته‌شده در زبان برنامه‌نویسی پایتون بر روی پایگاه داده اعمال شد؛ به‌گونه‌ای که تعداد نمونه‌های تمامی کلاس‌ها بر اساس پرجمعیت‌ترین کلاس (کلاس دارای ۳۸ نمونه اولیه) متعادل شد. با اجرای این فرآیند، حجم کلی پایگاه داده از ۱۳۹ به ۱۹۰ مورد افزایش یافت و تعداد نمونه‌های هر یک از پنج کلاس به ۳۸ مورد رسید (شکل ۴). پایگاه داده متعادل‌شده حاصل، مبنای آموزش و ارزیابی مدل‌های J48 و LMT در بخش‌های بعدی این پژوهش قرار گرفته است.



شکل ۴- توزیع داده‌ها پس از متعادل‌سازی با SMOTE

۳- توسعه مدل

طبقه‌بندی به‌عنوان یکی از مسائل اصلی یادگیری تحت نظارت، به فرآیند تخصیص یک نمونه جدید به یکی از کلاس‌های از پیش تعریف‌شده، بر اساس ویژگی‌های ورودی آن اطلاق می‌شود. تاکنون ابزارهای متنوعی برای این منظور توسعه یافته‌اند که از آن جمله می‌توان به درخت تصمیم، رگرسیون لجستیک، ماشین بردار پشتیبان، شبکه‌های بیزی و تحلیل تمایز اشاره کرد. در پژوهش حاضر، از میان این رویکردها، مدل‌های مبتنی بر درخت انتخاب شده‌اند؛ چراکه برخلاف بسیاری از الگوریتم‌های یادگیری ماشین با ماهیت جعبه‌سیاه، این مدل‌ها منطق تصمیم‌گیری خود را در قالب مجموعه‌ای از قواعد صریح و قابل‌فهم ارائه می‌دهند و از این رو برای کاربردهای مهندسی که تفسیرپذیری نتایج در آن‌ها اهمیت بالایی دارد، مناسب‌تر تشخیص داده شدند. در این تحقیق دو مدل J48 و LMT توسعه داده و با یکدیگر مقایسه شده‌اند.


در ساختار کلی یک درخت تصمیم، اولین گره که فرآیند تقسیم داده‌ها از آن آغاز می‌شود، گره ریشه نامیده می‌شود.

خود، قادر به مدل سازی روابط غیرخطی و برهم کنش میان ویژگی ها هستند، اما در برگ های خود معمولاً یک مقدار ثابت یا کلاس اکثریت را پیش بینی می کنند که می تواند منجر به از دست رفتن اطلاعات پیوسته موجود در داده شود؛ در مقابل، مدل های رگرسیون لجستیک، روابط احتمالاتی هموار و پیوسته ای میان ویژگی ها و کلاس خروجی ارائه می دهند، اما در تبیین روابط غیرخطی پیچیده با محدودیت مواجه اند. مدل درخت لجستیک (*LMT*) با هدف بهره گیری هم زمان از نقاط قوت هر دو رویکرد توسعه یافته است؛ به این صورت که ساختار درخت، فضای ویژگی ها را به نواحی کوچک تر و همگن تر تقسیم می کند و در هر برگ، به جای یک برچسب ثابت، یک تابع رگرسیون لجستیک چند جمله ای برازش داده می شود که توزیع احتمال تعلق نمونه به هر یک از کلاس های خروجی را برآورد می کند [۳۳، ۳۴].

شامل ۵ گره و ۶ برگ است که پارامتر *SSR*، به عنوان اولین گره، به عنوان تاثیرگذارترین پارامتر بر شدت وقوع مچاله شوندگی انتخاب گردیده است. هر مسیر از ریشه تا یک برگ، یک قاعده تصمیم گیری مشخص را تشکیل می دهد که بر اساس آن می توان کلاس مچاله شوندگی موارد جدید را با در نظر گرفتن مقادیر پارامترهای ورودی، به سرعت و بدون نیاز به محاسبات پیچیده پیش بینی کرد. قواعد تصمیم گیری استخراج شده از این درخت در جدول ۵ ارائه شده اند.

۲-۳- مدل درخت لجستیک (*LMT*)

روش های مبتنی بر درخت تصمیم و مدل های رگرسیونی خطی، از محبوب ترین رویکردهای یادگیری تحت نظارت به شمار می روند و هر کدام از مزایا و محدودیت های خاص خود برخوردارند؛ درخت های تصمیم به دلیل ساختار سلسله مراتبی




شکل ۵- درخت تصمیم حاصل از مدل *J48*

جدول ۵- قوانین استخراج شده از درخت *J48*

شماره	شرط	کلاس
۱	اگر $SSR > 0.205$ و $SSR > 0.435$	۰
۲	اگر $SSR > 0.205$ و $SSR <= 0.435$ و $BQ <= 204$	۲
۳	اگر $SSR > 0.205$ و $SSR <= 0.435$ و $BQ > 204$ و $SSR > 0.2307$	۱
۴	اگر $SSR > 0.205$ و $SSR <= 0.435$ و $BQ > 204$ و $SSR <= 0.2307$	۲
۵	اگر $SSR <= 0.205$ و $BQ <= 138$	۴
۶	اگر $SSR <= 0.205$ و $BQ > 138$	۳

اولین گره (مشابه مدل $J48$)، به عنوان تاثیرگذارترین پارامتر بر شدت وقوع مچاله‌شوندگی انتخاب گردیده است. این درخت شامل ۱۱ گره ریشه و ۱۲ برگ است که هر برگ آن به یکی از مدل‌های رگرسیون لجستیک (LM_1 تا LM_{11}) مرتبط است. قواعد تصمیم‌گیری استخراج‌شده از این درخت در جدول ۶ و معادلات مربوط به هر یک از این مدل‌های لجستیک، که احتمال تعلق هر نمونه به کلاس‌های مختلف را بر اساس مقادیر پارامترهای ورودی برآورد می‌کنند، در جدول ۷ ارائه شده‌اند. برای تعیین کلاس نهایی یک نمونه، ابتدا با استفاده از شرط‌های استخراج‌شده از درخت، مدل لجستیک متناظر با آن نمونه مشخص می‌شود؛ سپس با استفاده از رابطه $P(k) = \frac{\exp(LM_k(x))}{\sum_{i=1}^C \exp(LM_i(x))}$ ، که در واقع تابع بیشینه هموار اعمال‌شده بر خروجی توابع لجستیک است، احتمال تعلق آن نمونه به هر یک از پنج کلاس محاسبه می‌شود و در نهایت، کلاسی که بیشترین احتمال را به خود اختصاص داده باشد، به‌عنوان کلاس پیش‌بینی‌شده نهایی در نظر گرفته می‌شود.

فرآیند آموزش مدل LMT بر پایه الگوریتم $LogitBoost$ صورت می‌گیرد؛ الگوریتمی که به‌صورت افزایشی و گام‌به‌گام، توابع رگرسیون لجستیک ساده را بر روی متغیرهای شاخص کلاس برازش می‌دهد و در هر مرحله، وزن نمونه‌هایی که پیش‌تر به‌درستی طبقه‌بندی نشده‌اند را افزایش می‌دهد. هم‌زمان با این فرآیند، ساختار درخت با استفاده از همان معیار بهره اطلاعاتی به‌کاررفته در الگوریتم $C4.5$ گسترش می‌یابد و برای جلوگیری از بیش‌برازش، از رویه هرس مبتنی بر اعتبارسنجی متقاطع بهره گرفته می‌شود. نتیجه نهایی این فرآیند، درختی است که در آن هر برگ، به‌جای یک پیش‌بینی قطعی، یک مدل رگرسیون لجستیک محلی را در بر می‌گیرد؛ ویژگی‌ای که به‌طور خاص در مسائل طبقه‌بندی چندکلاسه با مرزهای تصمیم‌گیری پیچیده، نظیر پیش‌بینی پنج‌سطحی شدت مچاله‌شوندگی در پژوهش حاضر، برتری قابل‌توجهی نسبت به درخت‌های تصمیم ساده از خود نشان می‌دهد. درخت مدل لجستیک حاصل از مدل‌سازی داده‌های این تحقیق در شکل ۶ ارائه شده است که پارامتر SSR به عنوان



شکل ۶- درخت حاصل از مدل LMT

جدول ۶- قوانین تصمیم‌گیری استخراج‌شده از درخت LMT

شماره مدل	شرط	شماره
LM_{11}	اگر $SSR > 0.205$ و $SSR > 0.441$	۱
LM_7	اگر $SSR > 0.205$ و $SSR <= 0.441$ و $BQ <= 206$	۲

ادامه جدول ۶- قوانین تصمیم‌گیری استخراج شده از درخت LMT

LM10	اگر $SSR > 0.205$ و $SSR \leq 0.441$ و $BQ > 206$ و $SSR > 0.258$ و $D > 8.237977$	۳
LM9	اگر $SSR > 0.205$ و $SSR \leq 0.441$ و $BQ > 206$ و $SSR > 0.258$ و $D \leq 8.237977$	۴
LM8	اگر $SSR > 0.205$ و $SSR \leq 0.441$ و $BQ > 206$ و $SSR \leq 0.258$	۵
LM1	اگر $SSR \leq 0.205$ و $BQ \leq 110$	۶
LM6	اگر $SSR \leq 0.205$ و $BQ > 110$ و $H > 298.6$	۷
LM2	اگر $SSR \leq 0.205$ و $BQ > 110$ و $H \leq 298.6$ و $K \leq 727.682956$	۸
LM5	اگر $SSR \leq 0.205$ و $BQ > 110$ و $H \leq 298.6$ و $K > 727.682956$ و $BQ > 179$	۹
LM3	اگر $SSR \leq 0.205$ و $BQ > 110$ و $H \leq 298.6$ و $K > 727.682956$ و $BQ \leq 179$	۱۰
LM4	اگر $SSR \leq 0.205$ و $BQ > 110$ و $H \leq 298.6$ و $K > 727.682956$ و $BQ \leq 179$ و $K > 1370.125247$	۱۱

جدول ۷- معادلات تخمین احتمال کلاس‌ها در مدل LMT

شماره مدل	وضعیت	معادلات
LM1	0	$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (31.56581)$
	1	$(28.15436 \times SSR) + (0.00133 \times H) + (0.02486 \times BQ) + (0.27636 \times D) - (0.00164 \times K) - (15.87999)$
	2	$(-1.44831 \times SSR) + (0.00123 \times H) - (0.0233 \times BQ) + (0.06782 \times D) - (0.00043 \times K) + (3.77532)$
	3	$(-38.43426 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) + (8.99926)$
	4	$(-22.85622 \times SSR) - (0.0054 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) + (15.55724)$
LM2	0	$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (31.56581)$
	1	$(28.15436 \times SSR) + (0.00133 \times H) + (0.02486 \times BQ) + (0.27636 \times D) - (0.00169 \times K) - (15.87999)$
	2	$(-1.44831 \times SSR) + (0.00123 \times H) - (0.0233 \times BQ) + (0.06782 \times D) - (0.00043 \times K) + (3.77532)$
	3	$(-38.43426 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) + (8.99926)$
	4	$(-22.85622 \times SSR) - (0.0054 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) + (15.55724)$
LM3	0	$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (37.16581)$
	1	$(28.14433 \times SSR) + (0.00133 \times H) + (0.02486 \times BQ) + (0.27635 \times D) - (0.00169 \times K) - (21.4789)$
	2	$(-6.33086 \times SSR) + (0.00123 \times H) - (0.02336 \times BQ) + (0.06782 \times D) - (0.00043 \times K) - (1.40301)$
	3	$(153.00888 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) - (0.21653 \times D) + (0.0296 \times K) - (43.1249)$
	4	$(-216.47037 \times SSR) - (0.02995 \times H) - (0.11299 \times BQ) + (0.59894 \times D) - (0.01647 \times K) + (60.45425)$
LM4	0	$(71.73429 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (32.3658)$
	1	$(28.10726 \times SSR) + (0.00133 \times H) + (0.02486 \times BQ) + (0.27636 \times D) - (0.00169 \times K) - (16.67243)$
	2	$(-1.44831 \times SSR) - (0.03233 \times H) - (0.0233 \times BQ) + (0.06782 \times D) - (0.00043 \times K) + (10.95351)$

ادامه جدول ۷- معادلات تخمین احتمال کلاسه‌ها در مدل *LMT*

$(-35.90926 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) + (7.58004)$	3	
$(-22.85622 \times SSR) + (0.01551 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) + (12.00617)$	4	
$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.0017 \times K) - (37.96564)$	0	
$(28.12039 \times SSR) + (0.00133 \times H) + (0.02477 \times BQ) + (0.27636 \times D) - (0.00169 \times K) - (22.26018)$	1	
$(-1.44831 \times SSR) + (0.00123 \times H) - (0.0233 \times BQ) - (6.81477 \times D) - (0.00401 \times K) + (52.05931)$	2	LM5
$(-38.43426 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (7.00014 \times D) + (0.00285 \times K) - (38.87329)$	3	
$(-22.85622 \times SSR) - (0.00791 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) + (9.66106)$	4	
$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (31.56581)$	0	
$(28.15436 \times SSR) + (0.00133 \times H) + (0.02486 \times BQ) + (0.27636 \times D) - (0.00169 \times K) - (15.87999)$	1	
$(-1.44831 \times SSR) + (0.00123 \times H) - (0.0233 \times BQ) + (0.06782 \times D) - (0.00043 \times K) + (3.77532)$	2	LM6
$(-38.43426 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) + (8.99926)$	3	
$(-22.85622 \times SSR) - (0.0054 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) + (15.55724)$	4	
$(71.63119 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (32.34132)$	0	
$(28.15436 \times SSR) + (0.00133 \times H) - (0.02987 \times BQ) + (0.27636 \times D) - (0.00169 \times K) - (6.20613)$	1	
$(-1.44831 \times SSR) + (0.00123 \times H) + (0.0059 \times BQ) + (0.06782 \times D) - (0.00043 \times K) - (0.77353)$	2	LM7
$(-38.43426 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) + (7.771)$	3	
$(-22.85622 \times SSR) - (0.00237 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) + (13.8786)$	4	
$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (31.56581)$	0	
$(28.15436 \times SSR) + (0.00133 \times H) + (0.02486 \times BQ) + (0.27636 \times D) - (0.00169 \times K) - (15.87999)$	1	
$(-1.44831 \times SSR) + (0.00123 \times H) - (0.0233 \times BQ) + (0.06782 \times D) - (0.00043 \times K) + (3.77532)$	2	LM8
$(-38.43426 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) + (8.99926)$	3	
$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (31.56581)$	4	
$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) - (31.56581)$	0	
$(28.14433 \times SSR) + (0.00133 \times H) + (0.02486 \times BQ) + (0.27635 \times D) - (0.00169 \times K) - (15.87999)$	1	
$(-1.44831 \times SSR) + (0.00123 \times H) - (0.02336 \times BQ) + (0.06782 \times D) - (0.00043 \times K) + (3.77532)$	2	LM9
$(-38.43426 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) + (8.99926)$	3	
$(-22.85622 \times SSR) - (0.0054 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) + (15.55724)$	4	
$(71.73429 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) + (0.06982 \times D) + (0.0097 \times K) - (49.64023)$	0	LM10

ادامه جدول ۷- معادلات تخمین احتمال کلاس‌ها در مدل *LMT*

$(28.15436 \times SSR) - (0.00343 \times H) + (0.02486 \times BQ) - (0.12013 \times D) - (0.00169 \times K) -$ (8.95782)	1	
$(-1.44831 \times SSR) + (0.01449 \times H) - (0.0233 \times BQ) + (0.06782 \times D) - (0.00043 \times K) -$ (2.5164)	2	
$(-38.34113 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) +$ (7.36794)	3	
$(-22.85622 \times SSR) - (0.0054 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) +$ (13.96168)	4	
$(71.73438 \times SSR) - (0.00293 \times H) + (0.04061 \times BQ) - (0.68109 \times D) + (0.00175 \times K) -$ (31.56581)	0	
$(28.12039 \times SSR) + (0.00133 \times H) + (0.02486 \times BQ) + (0.27636 \times D) - (0.00169 \times K) -$ (15.87999)	1	
$(-1.44831 \times SSR) + (0.00123 \times H) - (0.0233 \times BQ) - (0.06782 \times D) - (0.00043 \times K) +$ (3.77532)	2	<i>LM11</i>
$(-38.43426 \times SSR) + (0.00099 \times H) - (0.02196 \times BQ) + (0.13955 \times D) - (0.00072 \times K) +$ (8.99926)	3	
$(-22.85622 \times SSR) - (0.0054 \times H) - (0.11299 \times BQ) + (0.23767 \times D) + (0.00404 \times K) +$ (15.55724)	4	

۳-۳- ارزیابی مدل‌های توسعه یافته

به منظور ارزیابی عملکرد مدل‌های توسعه یافته و کاهش ریسک بیش‌برازش، به‌ویژه با توجه به حجم محدود پایگاه داده مورد استفاده، از روش اعتبارسنجی متقاطع (*K-fold Cross-Validation*) استفاده شد. در این روش، کل پایگاه داده به *K* زیرمجموعه با حجم تقریباً برابر افراز می‌شود؛ در هر تکرار، یکی از این زیرمجموعه‌ها به عنوان داده آزمون و *K-1* زیرمجموعه باقی‌مانده برای آموزش مدل مورد استفاده قرار می‌گیرند. این فرآیند *K* بار تکرار می‌شود، به گونه‌ای که هر زیرمجموعه دقیقاً یک بار نقش داده تست را ایفا می‌کند و در نهایت، میانگین نتایج حاصل از *K* تکرار، به عنوان برآورد نهایی از عملکرد مدل گزارش می‌شود [۳۵، ۳۶]. این رویکرد،

برخلاف روش‌های ساده تقسیم داده به دو مجموعه آموزش و آزمون، امکان استفاده از تمامی نمونه‌های موجود برای هر دو فرآیند آموزش و ارزیابی را فراهم می‌کند و از این رو، برآورد پایدارتر و قابل‌اتکاتری از توان تعمیم‌پذیری مدل به دست می‌دهد. در این پژوهش، مطابق با رویه متداول در پژوهش‌های مشابه، مقدار *K* برابر ۱۰ در نظر گرفته شد. مبنای اصلی محاسبه شاخص‌های ارزیابی عملکرد مدل‌های طبقه‌بندی چندکلاسه، ماتریس آشفتگی (*Confusion Matrix*) است؛ ماتریسی که در آن هر سطر بیانگر کلاس واقعی و هر ستون بیانگر کلاس پیش‌بینی شده توسط مدل است. در شکل ۷ نمای کلی از ماتریس آشفتگی ۵ کلاسه به نمایش درآمده است.

		Predicted class					Row total
		1	2	3	4	5	
Actual class	1	n_{11}	n_{12}	n_{13}	n_{14}	n_{15}	$n_{1+} = \sum_{j=1}^5 n_{1j}$
	2	n_{21}	n_{22}	n_{23}	n_{24}	n_{25}	$n_{2+} = \sum_{j=1}^5 n_{2j}$
	3	n_{31}	n_{32}	n_{33}	n_{34}	n_{35}	$n_{3+} = \sum_{j=1}^5 n_{3j}$
	4	n_{41}	n_{42}	n_{43}	n_{44}	n_{45}	$n_{4+} = \sum_{j=1}^5 n_{4j}$
	5	n_{51}	n_{52}	n_{53}	n_{54}	n_{55}	$n_{5+} = \sum_{j=1}^5 n_{5j}$
Column total		$n_{+1} = \sum_{i=1}^5 n_{i1}$	$n_{+2} = \sum_{i=1}^5 n_{i2}$	$n_{+3} = \sum_{i=1}^5 n_{i3}$	$n_{+4} = \sum_{i=1}^5 n_{i4}$	$n_{+5} = \sum_{i=1}^5 n_{i5}$	$n = \sum_{i=1}^5 \sum_{j=1}^5 n_{ij}$

شکل ۷- نمای کلی از ماتریس آشفتگی ۵ کلاسه

$$MAE = (\sum_i \sum_j n_{ij} \times |i - j|) / n \quad (6)$$

$$QWK = 1 - \frac{\sum_{i,j} W_{i,j} Q_{i,j}}{\sum_{i,j} W_{i,j} E_{i,j}} \quad (7)$$

نتایج حاصل از ارزیابی مدل‌های *J48* و *LMT* با استفاده از روش اعتبارسنجی متقاطع ده‌تایی، در قالب ماتریس‌های آشفتگی (شکل ۸) ارائه شده است. ماتریس آشفتگی مدل *J48* نشان می‌دهد که از مجموع ۳۸ نمونه متعلق به کلاس صفر (عدم مچاله‌شوندگی)، ۳۵ نمونه (معادل ۹۲.۱ درصد) به‌درستی طبقه‌بندی شده و تنها ۳ نمونه به‌اشتباه در کلاس یک قرار گرفته‌اند؛ عملکردی مشابه نیز برای کلاس یک (مچاله‌شوندگی خفیف) با ۳۶ پیش‌بینی صحیح از ۳۸ نمونه مشاهده می‌شود. در مقابل، ضعیف‌ترین عملکرد مدل *J48* مربوط به کلاس دو (مچاله‌شوندگی متوسط) است؛ به‌طوری‌که از ۳۸ نمونه این کلاس، تنها ۲۳ مورد (معادل ۶۰.۵ درصد) به‌درستی شناسایی شده و ۹ مورد به‌اشتباه به کلاس یک و ۶ مورد به کلاس سه نسبت داده شده‌اند. کلاس‌های سه و چهار (مچاله‌شوندگی شدید و بسیار شدید) نیز به‌ترتیب با ۳۳ و ۲۹ پیش‌بینی صحیح از ۳۸ نمونه، عملکردی نسبتاً مطلوب، اما همراه با اندکی هم‌پوشانی با کلاس‌های مجاور خود، نشان دادند.

ماتریس آشفتگی مدل *LMT* الگویی مشابه، اما با بهبود محسوس در برخی کلاس‌ها، را نشان می‌دهد. عملکرد این مدل در کلاس صفر (۳۵ از ۳۸) دقیقاً مشابه مدل *J48* می‌باشد، اما در کلاس چهار (مچاله‌شوندگی بسیار شدید)، مدل *LMT* با شناسایی صحیح ۳۳ نمونه از ۳۸ مورد (در برابر ۲۹ مورد در مدل *J48*)، بهبود قابل‌توجهی از خود نشان داد؛ بهبودی که می‌توان آن را به توانایی مدل رگرسیون لجستیک در برگ‌های درخت، برای برازش دقیق‌تر مرز تصمیم‌گیری میان کلاس‌های انتهایی طیف مچاله‌شوندگی، نسبت داد. با این حال، کلاس دو (مچاله‌شوندگی متوسط) در مدل *LMT* نیز، مشابه مدل *J48* ضعیف‌ترین عملکرد را به خود اختصاص داد؛ به‌طوری‌که تنها ۲۴ نمونه از ۳۸ مورد (۶۳.۲ درصد) به‌درستی طبقه‌بندی شدند و عمده خطاهای طبقه‌بندی، در تفکیک این کلاس از کلاس‌های مجاور (یک و سه) رخ داد.

بررسی الگوی مشترک خطاهای طبقه‌بندی در هر دو مدل نشان می‌دهد که بیشترین چالش، مربوط به تفکیک

از مجموعه‌ای جامع و مکمل از شاخص‌های آماری، مبتنی بر ماتریس آشفتگی، برای ارزیابی و مقایسه عملکرد مدل‌های *J48* و *LMT* استفاده شده است که عبارت‌اند از: معیار دقت کلی (*AC*)، معیار حساسیت میانگین (*SE*) که توان تشخیص صحیح مدل در هر کلاس را می‌سنجد، معیار اختصاصی یا صحت میانگین (*PR*) که نسبت پیش‌بینی‌های صحیح به کل پیش‌بینی‌های هر کلاس را نشان می‌دهد، ضریب همبستگی متیوز (*MCC*) که به دلیل در نظر گرفتن هم‌زمان تمامی عناصر ماتریس آشفتگی، شاخصی متوازن و مقاوم در برابر عدم توازن کلاس‌ها محسوب می‌شود، و ضریب کاپای کوهن (*Kappa*) که میزان توافق مدل با داده‌های واقعی را پس از کسر توافق ناشی از شانس اندازه‌گیری می‌کند. علاوه بر این شاخص‌ها، از منحنی مشخصه عملکرد سیستم (*ROC*) و سطح زیر آن (*AUC*) نیز به‌عنوان معیاری مستقل از آستانه تصمیم‌گیری، برای ارزیابی توان تفکیک‌پذیری مدل‌ها میان کلاس‌های مختلف بهره گرفته شده است. از آنجا که سطوح شدت مچاله‌شوندگی ماهیتی ترتیبی دارند و از منظر مهندسی، اشتباه طبقه‌بندی میان دو کلاس مجاور پیامد به‌مراتب کم‌خطرتری نسبت به اشتباه میان دو کلاس دور از هم دارد، شاخص‌های استاندارد ذکرشده به‌تنهایی این تمایز را لحاظ نمی‌کنند. از این رو، دو شاخص مکمل و حساس به ساختار ترتیبی کلاس‌ها نیز محاسبه شد: (۱) میانگین خطای مطلق کلاس (*MAE*)، که میانگین فاصله عددی میان کلاس پیش‌بینی‌شده و کلاس واقعی را برای تمامی نمونه‌ها اندازه‌گیری می‌کند و ضریب کاپای وزن‌دار درجه‌دوم (*QWK*)، که برخلاف ضریب کاپای استاندارد، به خطاهای دورتر از قطر اصلی ماتریس آشفتگی جریمه بیشتری اختصاص می‌دهد. نحوه محاسبه هر یک از این شاخص‌ها بر پایه عناصر ماتریس آشفتگی، به‌ترتیب در روابط ۱ تا ۵ ارائه شده است.

$$AC = (\sum_{i=1}^5 n_{ii}) / n \quad (1)$$


$$SE = (\sum_{i=1}^5 SE) / 5, SE_i = \sum_{i=1}^5 (n_{ii} / n_{i+}) \quad (2)$$

$$PR = (\sum_{i=1}^5 PR) / 5, PR_i = \sum_{i=1}^5 (n_{ii} / n_{+i}) \quad (3)$$

$$MCC = (n \sum_{i=1}^5 n_{ii} - \sum_{i=1}^5 (n_{i+} \times n_{+i})) / \quad (4)$$


$$Kappa = (n \sum_{i=1}^5 n_{ii} - \sum_{i=1}^5 (n_{i+} \times n_{+i})) / \sqrt{(n^2 - \sum_{i=1}^5 n_{i+}^2)(n^2 - \sum_{i=1}^5 n_{+i}^2)} \quad (5)$$

مدل $J48$ ، معادل ۹۴.۱ درصد (۳۲ از ۳۴ مورد) و از خطاهای مدل LMT ، معادل ۹۰.۰ درصد (۲۷ از ۳۰ مورد) تنها میان دو کلاس مجاور رخ داده‌اند. به همین دلیل، مقدار QWK برای هر دو مدل (۰.۹۴۶۷ برای $J48$ و ۰.۹۴۸۱ برای LMT) به‌طور چشمگیری بالاتر از ضریب کاپای استاندارد گزارش شده در جدول ۸ است. این تفاوت نشان می‌دهد که اگرچه مدل‌ها در برخی موارد کلاس دقیق شدت مچاله‌شوندگی را به‌اشتباه تشخیص می‌دهند، تقریباً هیچ‌گاه خطای مهندسی فاحشی (نظیر خطای کلاس بدون مچاله‌شوندگی با کلاس مچاله‌شوندگی بسیار شدید) رخ نمی‌دهد؛ ویژگی‌ای که اتکاپذیری عملی این مدل‌ها را برای کاربردهای طراحی تونل تقویت می‌کند. مقدار MAE نیز برای مدل LMT (۰.۱۷۳۷) اندکی کمتر از مدل $J48$ (۰.۱۸۹۵) به‌دست آمد که با سایر شاخص‌های عملکرد هم‌راستا بوده و برتری نسبی مدل LMT را از منظر ترتیبی نیز تأیید می‌کند.



کلاس‌های مجاور از یکدیگر، به‌ویژه کلاس دو (متوسط) از کلاس‌های یک (خفیف) و سه (شدید) است؛ در حالی که خطای طبقه‌بندی میان کلاس‌های غیرمجاور (برای نمونه، کلاس صفر و کلاس چهار) عملاً مشاهده نشد. این الگو از نظر مهندسی کاملاً قابل توجیه است؛ چراکه شدت مچاله‌شوندگی به‌طور ذاتی یک طیف پیوسته است و مرز میان سطوح کیفی مجاور آن (بر اساس درصد کرنش شعاعی) اغلب به‌صورت تدریجی و نه ناگهانی تغییر می‌کند. بنابراین، نمونه‌هایی که مقادیر پارامترهای ورودی آن‌ها، به‌ویژه SSR و BQ ، نزدیک به آستانه‌های تفکیک‌کننده دو کلاس مجاور قرار دارد، احتمال بیشتری برای طبقه‌بندی نادرست در کلاس همسایه دارند؛ پدیده‌ای متداول در مسائل طبقه‌بندی ترتیبی که در آن‌ها کلاس‌ها از یک روند پیوسته و درجه‌بندی شده استخراج شده‌اند.



این مشاهده با محاسبه شاخص‌های حساس به ترتیب کلاس‌ها نیز به‌طور کمی تأیید می‌شود. از مجموع خطاهای طبقه‌بندی



شکل ۸- ماتریس آشفستگی مدل‌های توسعه یافته

چهار به‌ترتیب برابر ۰.۹۷، ۰.۹۷، ۰.۹۶ و ۰.۹۹ و AUC کلاس دو، که همچنان ضعیف‌ترین کلاس از نظر تفکیک‌پذیری بود، برابر ۰.۸۹ به دست آمد؛ میانگین AUC برای این مدل نیز به ۰.۹۶ رسید. بهبود مشاهده‌شده در تمامی مقادیر AUC مدل LMT نسبت به مدل $J48$ ، به‌ویژه برای کلاس‌های سه و چهار، نشان‌دهنده توان تفکیک‌پذیری بالاتر این مدل، مستقل از آستانه تصمیم‌گیری انتخابی، است.

منحنی‌های ROC مدل‌های توسعه‌یافته (شکل ۹) نیز این یافته‌ها را تأیید می‌کنند. در مدل $J48$ ، سطح زیر منحنی (AUC) برای کلاس‌های صفر و چهار به بالاترین مقدار (۰.۹۶) و برای کلاس دو به پایین‌ترین مقدار (۰.۸۷) رسید؛ در حالی که کلاس‌های یک و سه به‌ترتیب مقادیر ۰.۹۴ و ۰.۹۱ را به خود اختصاص دادند و میانگین برابر با ۰.۹۴ به دست آمد. در مدل LMT نیز همین روند، اما با مقادیر بهبودیافته، مشاهده شد؛ به‌طوری‌که AUC کلاس‌های صفر، یک، سه و



شکل ۹- منحنی ROC مدل‌های توسعه یافته

۴- بحث

مچاله‌شوندگی توده سنگ یکی از مهم‌ترین و پرهزینه‌ترین مخاطرات ژئوتکنیکی در پروژه‌های تونل‌سازی، به‌ویژه در توده‌سنگ‌های ضعیف و در اعماق زیاد، به شمار می‌رود. این پدیده می‌تواند از طریق تغییرشکل‌های گسترده و وابسته به زمان، به ناپایداری تونل، شکست سیستم نگهداری، کاهش نرخ پیشروی، گیرکردن ماشین‌های حفاری تمام‌مقطع (TBM) و در موارد حاد، خطرات جانی برای پرسنل عملیاتی منجر شود. با وجود اهمیت بالای این پدیده، بررسی پیشینه پژوهش نشان داد که اکثر مطالعات پیشین مبتنی بر یادگیری ماشین، مسئله پیش‌بینی مچاله‌شوندگی را به‌صورت یک طبقه‌بندی دوکلاسه (وقوع یا عدم وقوع) فرموله کرده‌اند و عمدتاً از الگوریتم‌هایی با ماهیت جعبه‌سیاه بهره گرفته‌اند که استخراج قواعد تصمیم‌گیری قابل‌فهم برای مهندسان از آن‌ها دشوار است.

نتایج ارزیابی نشان داد هر دو مدل توسعه‌یافته از دقت طبقه‌بندی قابل‌قبولی برخوردارند. مدل LMT با مقادیر AC برابر ۸۴.۲۱ درصد، SE برابر ۸۴.۲۱ درصد، PR برابر ۸۴.۵۷ درصد، MCC برابر ۸۰.۵۰ درصد، $Kappa$ برابر ۸۰.۲۰ درصد و AUC برابر ۰.۹۶، در تمامی شاخص‌های ارزیابی عملکردی اندکی برتر از مدل J48 (با مقادیر AC برابر ۸۲.۱۰ درصد، SE برابر ۸۲.۱۰ درصد، PR برابر ۸۳.۴۱ درصد، MCC برابر ۷۸.۱۰ درصد، $Kappa$ برابر ۷۷.۶۰ درصد و AUC برابر ۰.۹۴) داشت. این برتری با توجه به بهره‌گیری این مدل از توابع رگرسیون لجستیک در برگ‌های درخت و برازش دقیق‌تر مرزهای تصمیم‌گیری، قابل‌توجیه است. با این حال، اختلاف دو مدل اندک است و هر دو عملکرد نزدیکی دارند. در مقابل، درخت

در جدول ۸ خلاصه‌ای از شاخص‌های آماری کلی هر دو مدل را ارائه می‌دهد. بر اساس این نتایج، مدل LMT در چهار شاخص از پنج شاخص مورد بررسی (AC ، SE ، PR و MCC) عملکردی برتر از مدل J48 داشت؛ با این تفاوت که مقدار ضریب کاپا برای مدل J48 (۸۰/۲ درصد) اندکی بالاتر از مدل LMT (۷۷/۶ درصد) بود. این موضوع نشان می‌دهد که اگرچه مدل LMT به‌طور کلی از دقت طبقه‌بندی بالاتری برخوردار است، توافق آن با داده‌های واقعی پس از کسر اثر شانس، که توسط ضریب کاپا اندازه‌گیری می‌شود، تفاوت معناداری با مدل J48 ندارد؛ نکته‌ای که بار دیگر تأیید می‌کند هر دو مدل از کارایی نسبتاً نزدیک و قابل‌اتکایی برای این مسئله طبقه‌بندی برخوردارند. با در نظر گرفتن مجموع شاخص‌ها می‌توان نتیجه گرفت که مدل LMT، به دلیل بهره‌گیری از رگرسیون لجستیک در برگ‌های درخت، به‌طور نسبی در برازش دقیق‌تر مرزهای تصمیم‌گیری میان کلاس‌های مجاور موفق‌تر عمل کرده است؛ در حالی که مدل J48، با وجود دقت اندکی کمتر، همچنان از سادگی ساختاری و قابلیت تفسیر بالاتری برخوردار است که می‌تواند آن را به گزینه‌ای عملی‌تر برای کاربردهای مهندسی روزمره تبدیل کند.

جدول ۸- شاخص‌های ارزیابی عملکرد مدل‌های توسعه یافته

شاخص‌های عملکرد	J48	LMT
AC	۸۲.۱۰٪	۸۴.۲۱٪
SE	۸۲.۱۰٪	۸۴.۲۱٪
PR	۸۳.۴۱٪	۸۴.۵۷٪
MCC	۷۸.۱۰٪	۸۰.۵۰٪
Kappa	۸۰.۲۰٪	۷۷.۶۰٪
MAE	۰.۱۸۹۵	۰.۱۷۳۷
QWK	۹۴.۶۷٪	۹۴.۸۱٪

می‌تواند در مقایسه با روش‌هایی که *SMOTE* را صرفاً درون هر *fold* آموزشی اعمال می‌کنند، برآورد اندکی خوش‌بینانه‌تر از دقت مطلق مدل‌ها ارائه دهد؛ هرچند مقایسه نسبی دو مدل، که از پایپ‌لاین یکسانی برخوردارند، تحت تأثیر این موضوع قرار نمی‌گیرد. علاوه بر آن، برچسب سطح مچاله‌شوندگی بر اساس یک معیار کمی (کرنش شعاعی) از پایگاه داده منبع گرفته شده است و برای موارد نزدیک به مرز کلاس‌ها می‌تواند با عدم قطعیت همراه باشد.

۵- نتیجه‌گیری

در این پژوهش، دو مدل تفسیرپذیر درخت تصمیم *J48* و درخت مدل لجستیک *LMT* برای پیش‌بینی پنج‌سطحی شدت مچاله‌شوندگی توده سنگ توسعه و مقایسه شدند. نتایج اصلی به شرح زیر است:

۱. بر پایه پایگاه داده‌ای شامل ۱۳۹ مورد واقعی از شش کشور و پنج پارامتر ورودی (*SSR*, *K*, *D*, *H*, *BQ*)، که با *SMOTE* به ۱۹۰ نمونه متوازن تبدیل شد، هر دو مدل پنج کلاس شدت مچاله‌شوندگی را با دقت قابل قبول پیش‌بینی کردند.

۲. مدل *LMT* با دقت ۸۴.۲۱ درصد و *AUC* برابر ۰.۹۶ در تمامی شاخص‌ها اندکی بهتر از مدل *J48* با دقت ۸۲.۱۰ درصد و *AUC* برابر ۰.۹۴ عمل کرد.

۳. درخت *J48* تنها از دو متغیر *SSR* و *BQ* استفاده کرد و ساختاری ساده‌تر و قواعدی صریح‌تر ارائه داد. از این رو انتخاب میان دو مدل به اولویت کاربر میان دقت و سادگی تفسیر بستگی دارد.

۴. بیشتر خطاهای هر دو مدل میان کلاس‌های مجاور رخ داد و کلاس دو (مچاله‌شوندگی متوسط) چالش‌برانگیزترین کلاس بود و خطاهای دور از کلاس واقعی بسیار نادر بودند.

۵. مدل‌ها می‌توانند به صورت بالقوه به عنوان ابزاری کمکی در ارزیابی اولیه ریسک مچاله‌شوندگی به کار روند. کاربرد آن‌ها در طراحی سیستم نگهداری و انتخاب روش حفاری ارزیابی نشده و نیازمند اعتبارسنجی است.

برای پژوهش‌های آتی پیشنهاد می‌شود از پایگاه داده‌ای بزرگ‌تر و متنوع‌تر، رویکرد اعمال *SMOTE* درون *fold*‌های آموزشی و اعتبارسنجی مبتنی بر گروه‌بندی کشور یا پروژه استفاده شود. همچنین ترکیب مدل‌های درختی با الگوریتم‌های بهینه‌سازی فراابتکاری یا افزودن پارامترهای ورودی تکمیلی (مانند دوام‌پذیری و ناهمسانگردی توده سنگ) بررسی گردد.

J48 تنها از دو متغیر *SSR* و *BQ* بهره برده و ساختاری ساده‌تر دارد که استخراج و کاربرد مستقیم قواعد آن را در عمل مهندسی تسهیل می‌کند. به طور کلی، انتخاب میان این دو مدل را می‌توان بر اساس اولویت کاربر میان دقت پیش‌بینی (مدل *LMT*) یا سادگی و سهولت تفسیر (مدل *J48*) صورت داد. بیشتر خطاهای هر دو مدل میان کلاس‌های مجاور رخ داده است (۹۴.۱ درصد خطاهای *J48* و ۹۰.۰ درصد خطاهای *LMT*)، و به همین دلیل ضریب کاپای وزن‌دار درجه دوم برای هر دو مدل (۰.۹۴۶۷ برای *J48* و ۰.۹۴۸۱ برای *LMT*) به طور چشمگیری بالاتر از کاپای استاندارد است. این نشان می‌دهد مدل‌ها به ندرت نمونه‌ای را در کلاسی دور از کلاس واقعی آن طبقه‌بندی می‌کنند.

مقایسه نتایج این پژوهش با پیشینه پژوهش نشان می‌دهد اگرچه دقت مدل‌های توسعه‌یافته از برخی مدل‌های پیشین با دقت‌های گزارش شده بالای ۹۰ درصد پایین‌تر است، این تفاوت عمدتاً ناشی از ماهیت متفاوت و پیچیده‌تر مسئله در پژوهش حاضر است. چراکه اکثر مطالعات پیشین صرفاً به پیش‌بینی وقوع یا عدم وقوع مچاله‌شوندگی (طبقه‌بندی دوکلاسه) پرداخته‌اند، در حالی که مدل‌های این پژوهش، علاوه بر تعیین وقوع پدیده، شدت آن را نیز در پنج سطح کیفی پیش‌بینی می‌کنند. این مسئله به طور ذاتی دشوارتر است و اطلاعات کاربردی بیشتری در اختیار مهندس طراح قرار می‌دهد. از این رو، با در نظر گرفتن این تفاوت بنیادین در فرمول‌بندی مسئله، دقت‌های به دست آمده از هر دو مدل را می‌توان رضایت‌بخش ارزیابی کرد. از منظر کاربردی، مدل‌های توسعه‌یافته به دلیل ساختار شفاف و قابل تفسیر می‌توانند به صورت بالقوه به عنوان ابزاری کمکی در ارزیابی اولیه ریسک مچاله‌شوندگی مورد استفاده قرار گیرند. لازم به ذکر است که کاربرد این مدل‌ها در طراحی یا انتخاب سیستم نگهداری و روش حفاری در این پژوهش ارزیابی نشده و نیازمند اعتبارسنجی در مطالعات آتی است. با این حال، این پژوهش از محدودیت‌هایی برخوردار است. حجم پایگاه داده مورد استفاده، حتی پس از متعادل‌سازی با *SMOTE*، نسبتاً محدود است و افزایش تعداد موارد واقعی، به ویژه از پروژه‌هایی با شرایط زمین‌شناسی متنوع‌تر، می‌تواند توان تعمیم‌پذیری مدل‌ها را بهبود دهد. همچنین *SMOTE* پیش از اعتبارسنجی متقاطع و بر روی کل پایگاه داده اعمال شده است تا توازن کامل میان کلاس‌های خروجی تضمین شود. این رویکرد با توجه به حجم محدود داده اصلی انتخاب شد، اما

۶- منابع

- [1] G. Barla, Squeezing rocks in tunnels, *ISRM News Journal*. 2 (1995) 44–49.
- [2] E. Hoek, P. Marinos, Predicting tunnel squeezing problems in weak heterogeneous rock masses, *Tunnels Tunnelling International*. 32 (2000) 45–51.
- [3] R. Jimenez, D. Recio, A linear classifier for probabilistic prediction of squeezing conditions in Himalayan tunnels, *Engineering Geology*. 121 (2011) 101–109.
- [4] C. Cao, C. Shi, M. Lei, W. Yang, J. Liu, Squeezing failure of tunnels: A case study, *Tunnelling and Underground Space Technology*. 77 (2018) 188–203. <https://doi.org/10.1016/J.TUST.2018.04.007>.
- [5] G. Gioda, A. Cividini, Numerical methods for the analysis of tunnel performance in squeezing rocks, *Rock Mechanics and Rock Engineering*. 29 (1996) 171–193. <https://doi.org/10.1007/BF01042531>.
- [6] T.D. O'Rourke, Guidelines for tunnel lining design, in: ASCE, 1984.
- [7] J.L. Jethwa, B. Singh, B. Singh, Estimation of ultimate rock pressure for tunnel linings under squeezing rock conditions—a new approach, in: *Design and Performance of Underground Excavations: ISRM Symposium—Cambridge, UK, 3–6 September 1984*, Thomas Telford Publishing, 1984: pp. 231–238.
- [8] E. Ghasemi, H. Gholizadeh, Development of Two Empirical Correlations for Tunnel Squeezing Prediction Using Binary Logistic Regression and Linear Discriminant Analysis, *Geotechnical and Geological Engineering*. 37 (2018) 3435–3446. <https://doi.org/10.1007/S10706-018-00758-0>.
- [9] E.T. Brown, E. Hoek, *Underground excavations in rock*, CRC Press, 1980.
- [10] C. Carranza-Torres, Elasto-plastic solution of tunnel problems using the generalized form of the hoek-brown failure criterion, *International Journal of Rock Mechanics and Mining Sciences*. 41 (2004) 629–639. <https://doi.org/10.1016/J.IJRMMS.2004.03.111>.
- [11] M. Liang, H. Peng, W. Xie, B. Yu, Y. Han, M. Zhu, G. Song, N. Huang, Dynamic multiclass prediction of tunnel squeezing intensity with stacking model and Markov process, *Tunnelling and Underground Space Technology*. 146 (2024) 105632. <https://doi.org/10.1016/J.TUST.2024.105632>.
- [12] E. Ghasemi, S. Hassani, M.H. Kadkhodaei, M. Bahri, R. Romero-Hernandez, E.J. Mascort-Albea, An Intelligent Approach to Predict the Squeezing Severity and Tunnel Deformation in Squeezing Grounds, *Transportation Infrastructure Geotechnology* 2024 11:6. 11 (2024) 3992–4016. <https://doi.org/10.1007/S40515-024-00434-2>.
- [13] A. Shafiei, H. Parsaei, M.B. Dusseault, Rock squeezing prediction by a support vector machine classifier, in: *46th US Rock Mechanics/Geomechanics Symposium*, American Rock Mechanics Association, 2012.
- [14] X. Feng, R. Jimenez, Predicting tunnel squeezing with incomplete data using Bayesian networks, *Engineering Geology*. 195 (2015) 214–224.
- [15] Y. Sun, X. Feng, L. Yang, Predicting Tunnel Squeezing Using Multiclass Support Vector Machines, *Advances in Civil Engineering*. 2018 (2018).
- [16] E. Ghasemi, H. Gholizadeh, Prediction of squeezing potential in tunneling projects using data mining-based techniques, *Geotechnical Geological Engineering*. (2018) 1–10. <https://doi.org/10.1007/s10706-018-0705-6>.
- [17] E. Ghasemi, H. Gholizadeh, Development of Two Empirical Correlations for Tunnel Squeezing Prediction Using Binary Logistic Regression and Linear Discriminant Analysis, *Geotechnical and Geological Engineering*. 37 (2019) 3435–3446. <https://doi.org/10.1007/s10706-018-00758-0>.
- [18] J. Zhang, D. Li, Y. Wang, Predicting tunnel squeezing using a hybrid classifier ensemble with incomplete data, *Bulletin of Engineering Geology and The Environment*. (2020) 1–12.
- [19] Y. Chen, T. Li, P. Zeng, J. Ma, E. Patelli, B. Edwards, Dynamic and Probabilistic Multi-class Prediction of Tunnel Squeezing Intensity, *Rock Mechanics and Rock Engineering*. (2020) 1–22.
- [20] Z. Huang, M. Liao, H. Zhang, J. Zhang, S. Ma, Q. Zhu, Predicting Tunnel Squeezing Using the SVM-BP Combination Model, *Geotechnical and Geological Engineering*. 40 (2022) 1387–1405.
- [21] H. Fathipour-Azar, Multi-level Machine Learning-Driven Tunnel Squeezing Prediction: Review

- and New Insights, *Archives of Computational Methods in Engineering*. 29 (2022) 5493–5509.
- [22] J. Zhou, S. Zhu, Y. Qiu, D.J. Armaghani, A. Zhou, W. Yong, Predicting tunnel squeezing using support vector machine optimized by whale optimization algorithm, *Acta Geotechnica*. 17 (2022) 1343–1366.
- [23] Y. Bo, X. Huang, Y. Pan, Y. Feng, P. Deng, F. Gao, P. Liu, Q. Liu, Robust model for tunnel squeezing using Bayesian optimized classifiers with partially missing database, *Underground Space*. 10 (2023) 91–117. <https://doi.org/10.1016/J.UNDSP.2022.11.001>.
- [24] M.H. Kadhodaei, E. Ghasemi, S. Mahdavi, Modelling tunnel squeezing using gene expression programming: a case study, *Proceedings of the Institution of Civil Engineers - Geotechnical Engineering*. (2023) 1–30. <https://doi.org/10.1680/JGEEN.22.00151>.
- [25] X. Geng, S. Wu, Y. Zhang, J. Sun, H. Cheng, Z. Zhang, S. Pu, Developing hybrid XGBoost model integrated with entropy weight and Bayesian optimization for predicting tunnel squeezing intensity, *Natural Hazards*. 119 (2023) 751–771. <https://doi.org/10.1007/S11069-023-06137-0/METRICS>.
- [26] M.H. Kadhodaei, V. Amirkiyaei, E. Ghasemi, Developing two robust hybrid models for predicting tunnel deformation in squeezing prone grounds, *Transportation Geotechnics*. 45 (2024) 101231. <https://doi.org/10.1016/J.TRGEO.2024.101231>.
- [27] D. Liang, Z. Rui, F. Yuguang, A robust evaluating strategy of tunnel deterioration using ensemble machine learning algorithms, *Engineering Applications of Artificial Intelligence*. 133 (2024) 108364. <https://doi.org/10.1016/J.ENGAPPAL.2024.108364>.
- [28] P. Guan, G. Ou, F. Liang, W. Luo, Q. Wang, C. Pei, X. Che, Tunnel squeezing prediction based on partially missing dataset and optimized machine learning models, *Frontiers in Earth Science*. 13 (2025) 1511413. <https://doi.org/10.3389/FEART.2025.1511413/TEXT>.
- [29] J. YY, O. GZ, W. H, Z. GH, Prediction of tunnel squeezing based on evidence theory, *Journal of Basic Science and Engineering*. 29 (2021) 1156–1170. <https://doi.org/10.16058/j.issn.1005-0930.2021.05.007>.
- [30] N. V. Chawla, K.W. Bowyer, L.O. Hall, W.P. Kegelmeyer, SMOTE: Synthetic Minority Over-sampling Technique, *Journal of Artificial Intelligence Research*. 16 (2002) 321–357. <https://doi.org/10.1613/JAIR.953>.
- [31] A. Fernández, S. García, F. Herrera, N. V. Chawla, SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary, *Journal of Artificial Intelligence Research*. 61 (2018) 863–905. <https://doi.org/10.1613/JAIR.1.11192>.
- [32] M.H. Kadhodaei, E. Ghasemi, Development of a Semi-quantitative Framework to Assess Rockburst Risk Using Risk Matrix and Logistic Model Tree, *Geotechnical and Geological Engineering* 2022 40:7. 40 (2022) 3669–3685. <https://doi.org/10.1007/S10706-022-02122-9>.
- [33] N. Landwehr, M. Hall, E. Frank, Logistic model trees, *Machine Learning*. 59 (2005) 161–205. <https://doi.org/10.1007/s10994-005-0466-3>.
- [34] W. Chen, X. Xie, J. Wang, B. Pradhan, H. Hong, D.T. Bui, Z. Duan, J. Ma, A comparative study of logistic model tree, random forest, and classification and regression tree models for spatial prediction of landslide susceptibility, *CATENA*. 151 (2017) 147–160. <https://doi.org/10.1016/J.CATENA.2016.11.032>.
- [35] T.T. Wong, Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation, *Pattern Recognition*. 48 (2015) 2839–2846. <https://doi.org/10.1016/J.PATCOG.2015.03.009>.
- [36] E. Kurniawan, F. Nhita, A. Aditsania, D. Saepudin, C5.0 algorithm and synthetic minority oversampling technique (SMOTE) for rainfall forecasting in bandung regency, 2019 7th International Conference on Information and Communication Technology, ICoICT 2019. (2019). <https://doi.org/10.1109/ICOICT.2019.8835324>.



Multi-Class Prediction of Rock Mass Squeezing Severity in Tunnels Using Machine Learning Models

Amir Hossein Ghaedi¹; Mohammad Hossein Kadkhodaei²; Ebrahim Ghasemi^{1*}

1- Isfahan University of Technology, Department of Mining Engineering, Isfahan, Iran.

2- Hamedan University of Technology, Department of Mining Engineering, Hamedan, Iran.

Received: 06 August 2026 Accepted: 21 September 2026

(*Corresponding author: e_ghasemi@iut.ac.ir)

Keywords

**Squeezing
Machine Learning
Multi-Class Classification
SMOTE
Tunneling**

Abstract

Rock mass squeezing is one of the main challenges in tunnel excavation through weak rock masses under high in-situ stress conditions, and it can cause significant deformation, increased pressure on the support system, reduced advance rate, and tunnel instability. In this study, two machine learning models, namely a decision tree (J48) and a logistic model tree (LMT), were developed to predict squeezing severity across five classes. The database consisted of 139 case histories collected from tunneling projects in China, Nepal, India, Austria, Japan, and Turkey. Five parameters, namely overburden depth, tunnel

diameter, support system stiffness, stress-to-strength ratio, and rock mass basic quality index, were selected as input variables. To address class imbalance, the SMOTE technique was applied, increasing the number of samples to 190, with 38 samples per class. Model performance was evaluated using 10-fold cross-validation and the metrics of accuracy, sensitivity, precision, Matthews correlation coefficient, Kappa, and AUC. The results showed that the logistic model tree, with an accuracy of 84.21% and an AUC of 0.96, outperformed the decision tree, which achieved an accuracy of 82.10% and an AUC of 0.94. Nevertheless, the simpler structure of the decision tree enhances its interpretability and practical applicability. Both models demonstrated acceptable capability for multi-class prediction of squeezing severity and may serve as a supplementary tool for preliminary assessment of squeezing risk.
