

اصلاح سیستم طبقه‌بندی توده‌سنگ RMR به‌منظور تخمین عملکرد TBM در انواع سنگ

آمنه دردشتی^{۱*}؛ جمال رستمی^۲؛ جعفر حسن‌پور^۳؛ رسول اجل‌لوئیان^۴

- ۱- دکتری زمین‌شناسی مهندسی، گروه زمین‌شناسی، دانشگاه اصفهان.
- ۲- استاد مکانیک سنگ، دانشکده معدن Colorado School of Mines
- ۳- دانشیار زمین‌شناسی مهندسی، دانشکده‌گان علوم، دانشگاه تهران.
- ۴- استاد زمین‌شناسی مهندسی، گروه زمین‌شناسی، دانشگاه اصفهان.

دریافت: ۱۴۰۴/۰۵/۲۸ پذیرش: ۱۴۰۴/۰۶/۳۱

(*نویسنده مسئول: am.dardashti@gmail.com)

چکیده

از آن‌جا که سیستم‌های مختلف طبقه‌بندی توده‌سنگ، متداول‌ترین روش‌های مورد استفاده در بسیاری از پروژه‌های مهندسی سنگ هستند، به دلیل پذیرش جهانی و در دسترس بودن پارامترهای مؤثر، روش مناسبی جهت تخمین عملکرد ماشین *TBM* می‌باشند. با مقایسه متداول‌ترین سیستم‌های طبقه‌بندی توده‌سنگ، سیستم طبقه‌بندی *RMR* همبستگی بهتری با نرخ نفوذ *TBM* نشان می‌دهد، که این امر به دلیل استفاده از مقاومت فشاری تک‌محوره سنگ (*UCS*) به عنوان پارامتر ورودی در این سیستم است. از آنجاکه سیستم طبقه‌بندی *RMR* برای تحلیل شرایط پایداری توده‌سنگ در تونل‌ها و طراحی سیستم نگهدارنده توسعه یافته، در نتیجه امتیازدهی پارامترهای ورودی آن نیز بر همین اساس انجام شده و به نظر می‌رسد، می‌توان با تغییر در مقادیر امتیاز پارامترهای ورودی سیستم *RMR* و تغییر در وزن‌دهی داخلی هر پارامتر، به *RMR* بهینه‌ای دست یافت که متناسب با هدف این مطالعه یعنی پیش‌بینی عملکرد ماشین *TBM* در سنگ سخت باشد. هدف از این مطالعه، توسعه روابط جدید برای تخمین عملکرد *TBM* در انواع سنگ بر اساس پارامترهای ورودی سیستم *RMR* و در نهایت اصلاح سیستم *RMR* جهت توسعه مدلی جدید برای پیش‌بینی عملکرد *TBM* در سنگ است. بدین منظور داده‌های مربوط به ۱۰ پروژه تونل‌سازی در شرایط زمین‌شناسی مختلف در یک پایگاه‌داده جمع‌آوری شده است و در نهایت با استفاده از الگوریتم‌های هوش مصنوعی، طبقه‌بندی *RMR_{TBM}* با هدف پیش‌بینی عملکرد *TBM* در سنگ سخت پیشنهاد شده است. در *RMR_{TBM}* به هر یک از پارامترهای ورودی بر اساس جدول و نمودار مربوطه، امتیازی تعلق می‌گیرد و مجموع امتیازات این پارامترها به‌صورت صفر تا صد، مقدار *RMR_{TBM}* را تعیین می‌کند. سپس رده *RMR_{TBM}* تعیین‌شده و با توجه به جدول ارائه شده، محدوده *FPI* توده‌سنگ، رده حفرپذیری، توصیف حفرپذیری و شرایط پایداری توده‌سنگ مسیر تونل پیش‌بینی می‌شود. این مدل در مراحل طراحی و برنامه‌ریزی پروژه‌های تونل‌سازی می‌تواند مفید واقع شود.

عملکرد ماشین *TBM*، سیستم طبقه‌بندی توده‌سنگ *RMR*، طبقه‌بندی *RMR_{TBM}*، یادگیری ماشین

واژگان کلیدی

۱- مقدمه

در صنعت تونل‌سازی، برآورد دقیق عملکرد ماشین‌ها به‌ویژه در شرایط پیچیده زمین‌شناسی هنوز هم می‌تواند

علیرغم استفاده گسترده از ماشین‌های حفر تمام مقطع تونل

تونل‌سازی، پارامترهای ورودی سیستم طبقه‌بندی *RMR* موجود است. البته باید توجه داشت که سیستم *RMR* نیز همانند دیگر سیستم‌های طبقه‌بندی توده‌سنگ، برای طبقه‌بندی شرایط توده‌سنگ از نظر پایداری تونل و طراحی نگهدارنده توسعه یافته و انتخاب پارامترهای مؤثر نیز بر همین اساس صورت گرفته است و چنانچه هدف، استفاده از پارامترهای سیستم *RMR* جهت پیش‌بینی قابلیت حفزپذیری توده‌سنگ و تخمین عملکرد ماشین *TBM* باشد، مسلماً بایستی تغییراتی در پارامترها و وزن‌دهی آن‌ها صورت گیرد [۱]. در این مطالعه امکان استفاده از پارامترهای ورودی *RMR* برای توسعه روابط تخمین عملکرد ماشین با استفاده از آنالیز رگرسیون مبتنی بر الگوریتم‌های یادگیری ماشین بررسی و روابطی ارائه می‌شود. هدف نهایی، اصلاح سیستم طبقه‌بندی توده‌سنگ *RMR* جهت توسعه مدلی جدید برای پیش‌بینی عملکرد ماشین *TBM* در سنگ سخت با استفاده از آنالیزهای آماری و الگوریتم‌های هوش مصنوعی است. به این منظور با تغییر در مقادیر امتیاز پارامترهای ورودی *RMR* و تغییر در وزن‌دهی داخلی هر پارامتر، *RMR* بهینه‌ای تعریف می‌شود که متناسب با هدف این مطالعه یعنی پیش‌بینی عملکرد *TBM* در سنگ باشد. رویکردی که برای توسعه این *RMR* بهینه به کار گرفته شده است، استفاده از الگوریتم‌های رگرسیون غیرخطی درخت تصمیم و *Random Forest* است و در نهایت *RMR_{TBM}* با هدف پیش‌بینی عملکرد *TBM* در سنگ سخت پیشنهاد می‌شود.

۲- عملکرد *TBM* و طبقه بندی توده‌سنگ

تاکنون تلاش‌های زیادی از سوی محققان مختلف برای بررسی ارتباط بین عملکرد ماشین *TBM* با سیستم‌های طبقه‌بندی توده‌سنگ صورت گرفته است. مطالعات نشان می‌دهد که با افزایش کیفیت توده‌سنگ معمولاً مقدار نرخ نفوذ کاهش می‌یابد. البته شرایط بسیار ضعیف توده‌سنگ نیز کمکی به افزایش نرخ نفوذ نمی‌نماید، زیرا باعث ریزش در جبهه کار تونل شده و عملیات حفاری متوقف می‌گردد. بنابراین واضح است که نرخ نفوذ ماشین نسبت به سیستم‌های طبقه‌بندی توده‌سنگ، پراکندگی زیادی نشان می‌دهد. *Sapigni et al.* (2002) با تحلیل داده‌های سه تونل در کوه‌های آلپ در شمال ایتالیا در سنگ‌های دگرگونی متوسط تا سخت، عملکرد ماشین را با سیستم طبقه‌بندی توده‌سنگ *RMR* مرتبط کرد

چالش برانگیز باشد. پیش‌بینی نرخ نفوذ و عملکرد ماشین، یک فاکتور کلیدی در برنامه‌ریزی پروژه‌های تونل‌سازی، تخمین و کنترل هزینه‌ها و انتخاب ماشین مناسب می‌باشد. در طی دهه‌های گذشته، مدل‌های زیادی برای پیش‌بینی عملکرد ماشین *TBM* ارائه شده است، ولی از آن‌جا که عوامل مختلفی از جمله خصوصیات سنگ بکر و توده‌سنگ و همچنین خصوصیات اپراتوری و طراحی ماشین در این فرآیند پیچیده دخالت دارند، تاکنون مدلی ارائه نشده که همه عوامل مؤثر را در نظر گرفته باشد.

از آن‌جا که سیستم‌های مختلف طبقه‌بندی توده‌سنگ، متداول‌ترین روش‌های مورد استفاده در بسیاری از پروژه‌های مهندسی سنگ هستند، به دلیل سادگی، پذیرش جهانی و در دسترس بودن پارامترهای مؤثر، روش مناسبی جهت تخمین عملکرد ماشین می‌باشند. طی سال‌های گذشته تلاش‌های زیادی توسط محققان مختلف برای پیش‌بینی عملکرد ماشین *TBM* بر اساس سیستم‌های طبقه‌بندی توده‌سنگ انجام شده است. از میان سیستم‌های مختلف طبقه‌بندی توده‌سنگ، طبقه‌بندی‌های *RMR*، *Q* و *GSI* متداول‌ترین روش‌های مورد استفاده در بسیاری از پروژه‌های مهندسی سنگ هستند. با مقایسه متداول‌ترین سیستم‌های طبقه‌بندی توده‌سنگ، سیستم طبقه‌بندی توده‌سنگ *RMR* همبستگی بهتری با نرخ نفوذ *TBM* نشان می‌دهد، که این امر به دلیل استفاده از مقاومت فشاری تک‌محوره سنگ (*UCS*) به عنوان پارامتر ورودی در این سیستم طبقه‌بندی است [۱] - [۴]. بر اساس تحقیقات *Rostami (2016)* مهمترین ویژگی‌های زمین‌شناسی که بر عملکرد ماشین تأثیر می‌گذارند عبارتند از مقاومت سنگ (*UCS* یا *BTS*)، فراوانی، جهت و شرایط درزه و همچنین ساینده‌گی سنگ. به استثنای ساینده‌گی سنگ که عمر تیغه‌های برشی و در نتیجه ضریب بهره‌وری ماشین را کنترل می‌کند، سایر پارامترها همانند پارامترهای مورد استفاده در سیستم طبقه‌بندی توده‌سنگ *RMR* است، بنابراین منطقی است که بتوان سیستم طبقه‌بندی *RMR* موجود را با اعمال تغییراتی برای پیش‌بینی عملکرد *TBM* استفاده کرد. تعیین پارامترهای سیستم طبقه‌بندی *RMR* اغلب در مراحل طراحی تونل و نیز در مرحله اکتشاف و حفاری در گزارشات لاگینگ مغزه‌های حفاری و *Back Mapping* تونل صورت می‌گیرد و به همین دلیل در غالب پروژه‌های

$RMR_{D\&B}$ توسط رابطه آلبر (۱۹۹۶) به RMR_{TBM} تبدیل و همین امر باعث بروز عدم قطعیت‌هایی در نتایج مدل می‌شود. *Khademi Hamidi (2010)* نیز مدلی برای پیش‌بینی عملکرد TBM با استفاده از تحلیل رگرسیون خطی چندمتغیره بر روی داده‌های صحرایی تونل زاگرس در ایران انجام داد و یک معادله جهت پیش‌بینی شاخص نفوذ صحرایی (FPI) با استفاده از پارامترهای سیستم RMR ارائه داد. رابطه بین FPI و پنج پارامتر اصلی ورودی RMR به اضافه عمق تونل و زاویه درزه‌ها با محور تونل انجام شد. با توجه به تحلیل رگرسیون، عمق تونل و وضعیت آب زیرزمینی (G_w) همبستگی اندکی با FPI نشان داد و از تحلیل‌ها حذف شدند [۷]. مشکل اصلی این معادلات این است که فقط مربوط به شرایط تونل زاگرس و ماشین با سپر دوگانه است، از این رو نمی‌تواند مدل قابل اعتمادی برای پیش‌بینی عملکرد ماشین در شرایط مختلف زمین‌شناسی باشد. علاوه بر این، حساسیت مدل نسبت به برخی پارامترها از جمله J_c ، J_s و زاویه α کم است تا جایی که حتی ۱۰۰ درصد تغییر در آن، اثرات جزئی بر مقدار FPI دارد.

همانطور که اشاره شد، تاکنون تحقیقات زیادی برای ارزیابی کاربرد سیستم‌های طبقه‌بندی توده‌سنگ در پیش‌بینی عملکرد ماشین انجام شده است و این امر به دلیل سادگی و فراگیری استفاده از سیستم‌های طبقه‌بندی توده‌سنگ در پروژه‌های مهندسی سنگ و تونل‌هاست. با وجود این، مطالعات نشان می‌دهد که میزان موفقیت این مدل‌ها محدود بوده و هیچ فرمول یا مدل پذیرفته‌شده‌ای وجود ندارد که بتوان از سیستم‌های طبقه‌بندی توده‌سنگ و رتبه‌بندی‌های مرتبط در پیش‌بینی عملکرد ماشین استفاده کرد. البته همانطور که ذکر شد، این موضوع را می‌توان به هدف متفاوت توسعه سیستم‌های طبقه‌بندی توده‌سنگ نسبت داد. امروزه با توسعه الگوریتم‌های یادگیری ماشین و روش‌های نوین تحلیل داده، مطالعات جدیدی به کمک این روش‌ها برای استفاده از پارامترهای سیستم‌های طبقه‌بندی توده‌سنگ در پیش‌بینی عملکرد ماشین انجام شده است [۴] و [۸]. مطالعات *Hassanpour et al. (2011)* و *Salimi et al. (2019)* نشان‌دهنده وجود ارتباط خوبی میان عملکرد ماشین و سیستم طبقه‌بندی توده‌سنگ RMR است [۳] و [۴]. بنابراین سیستم RMR و پارامترهای ورودی آن به عنوان

و یک رابطه درجه دوم بین نرخ نفوذ (m/hr) و سیستم RMR به دست آورد که در مطالعات *Hassanpour et al. (2011)* نیز تایید شده است. بر اساس این مطالعات با کاهش کیفیت توده‌سنگ، نرخ نفوذ افزایش می‌یابد و افزایش نرخ نفوذ تا زمانی ادامه می‌یابد که مقدار RMR به حدود ۶۰-۵۰ می‌رسد و با کاهش بیشتر کیفیت توده‌سنگ، نرخ نفوذ نیز کاهش می‌یابد. ساینی بیان کرد که از همبستگی موجود نمی‌توان برای پیش‌بینی عددی نرخ نفوذ استفاده کرد چرا که سیستم RMR پارامترهای تعامل سنگ و ماشین را در نظر نمی‌گیرد. وی به تأثیر نوع سنگ ($Rock Type$) بر عملکرد ماشین اشاره کرد به طوری که با وجود ماشین حفار یکسان و امتیاز RMR یکسان در هنگام حفاری در سنگ‌های مختلف، در سنگ‌های قوی‌تر نرخ نفوذ کمتری بدست می‌آید، که نشان می‌دهد عوامل مرتبط با نوع سنگ از قبیل فابریک سنگ، وجود شیستوزیته، مقاومت کششی و غیره ممکن است بر مکانیسم تشکیل تراشه تأثیر زیادی داشته باشند. بنابراین، این محققین سیستم RMR معمولی را برای پیش‌بینی عملکرد ماشین کافی ندانستند و یک عدد RMR تعدیل شده را با توجه به عوامل مؤثر بر مقاومت سنگ در برابر نفوذ پیشنهاد نمودند [۲].

شاخص RME توسط بنیواسکی و همکاران (۲۰۰۶) بر اساس پنج پارامتر ورودی اصلی به کمک روش "*Linear Discriminant Analysis*" توسعه داده شد. پارامترهای ورودی این شاخص تا حدود زیادی شبیه به RMR است. پنج پارامتر ورودی شامل مقاومت تراکمی تک‌محوره UCS ، شاخص نرخ چالخوری DRI ، فراوانی درزه‌ها در جبهه کار تونل، زمان ایستایی تونل و جریان آب زیرزمینی بوده و از نظر مولفین این پارامترها بیشترین تأثیر را در تعیین نرخ پیشروی ($Advance Rate (AR)$) دارند. در این طبقه‌بندی توزیع وزنی امتیاز مربوط به هر پارامتر نیز پیشنهاد داده شده است [۵]. واقعیت این است که شاخص RME بسیار شبیه به RMR است و بسیار آسان برآورد می‌شود، ولی در آن بار کاتر در نظر گرفته نشده است، در حالی که در بسیاری از تحقیقات ثابت شده است که بار کاتر تأثیر عمده‌ای بر نرخ نفوذ دارد [۶]. علاوه بر این، پارامتر زمان ایستایی تونل باید از یک نمودار RMR که توسط بنیواسکی برای تونل‌سازی به روش سنتی چالزنی و آتشیاری ارائه شده، تخمین زده شود، و ابتدا بایستی

مقطع ثبت شده و با بهره‌گیری از این داده‌ها، پارامترهای عملکرد واقعی ماشین نظیر متوسط نرخ نفوذ، متوسط ضریب بهره‌وری، نرخ پیشروی ماشین، متوسط شاخص نفوذ صحرایی و متوسط انرژی ویژه برای مقاطع انتخابی محاسبه و ثبت شده است. همچنین خصوصیات زمین‌شناسی و زمین‌شناسی مهندسی توده‌سنگ‌های مسیر تونل شامل خصوصیات ماده‌سنگ (آزمون‌های آزمایشگاهی) و خصوصیات درزه‌داری توده‌سنگ‌ها گردآوری شده است که بر اساس آن پارامترهای طبقه‌بندی مهندسی توده‌سنگ محاسبه و مقدار RMR ، Q و GSI هر مقطع تونل محاسبه شده است.

این داده‌ها طی اکتشافات زمین‌شناسی (*Geological Survey*) در فاز پیش از ساخت تونل، نقشه‌برداری زمین‌شناسی صحرایی (*Field Geological Mapping*) توده‌سنگ‌های مسیر تونل و مغزه‌های حفاری، بررسی نقشه‌های حین ساخت (*As-built*) مقاطع تونل، انجام آزمون‌های برجا صحرایی و آزمون‌های آزمایشگاهی، بازدید سینه‌کار و دیواره‌های تونل، بررسی گزارش‌های روزانه حفاری و بررسی داده‌های ثبت‌شده توسط *PLC* ماشین، جمع‌آوری و ثبت شده‌اند. شایان ذکر است که مقاطع انتخابی در تونل‌هایی که با ماشین‌های باز یا کفشک‌دار حفاری شده‌اند، از داخل تونل مطالعه شده‌اند ولی در ماشین‌های سپردار به دلیل نصب قطعات بتنی پیش‌ساخته، بلافاصله پشت سپر امکان مشاهده و بازدید از سنگ میزبان تونل بسیار دشوار است، بنابراین در این تونل‌ها مقاطعی انتخاب شده‌اند که یا در آن، امکان بازدید و بررسی سینه‌کار تونل، همچنین نمونه‌برداری و انجام آزمون‌های آزمایشگاهی در دو انتهای مقطع فراهم باشد و یا مقاطعی که یک گمانه تا عمق تونل حفر شده و با بهره‌گیری از قضاوت مهندسی امکان تعمیم ویژگی‌های سطحی توده‌سنگ به عمق تونل با درجه اطمینان بالا وجود داشته باشد. در هر صورت فقط داده‌های مربوط به مقاطعی از تونل‌ها در تحلیل‌ها استفاده شده، که داده‌های زمین‌شناسی مهندسی و عملکرد ماشین در آن مقاطع از درجه اطمینان بالایی برخوردار بوده‌اند. ویژگی‌های اصلی و خصوصیات زمین‌شناسی و سنگ‌شناسی ۱۰ پروژه تونل‌سازی در سنگ که به روش مکانیزه حفاری و داده‌های آن‌ها در پایگاه‌داده جمع‌آوری شده است، در جدول ۱ خلاصه شده‌اند.

اساس و پایه آنالیزها در مطالعه حاضر خواهد بود. در این راستا داده‌های مربوط به ۱۰ پروژه تونل‌سازی در شرایط زمین‌شناسی مختلف در یک پایگاه‌داده جمع‌آوری شده است. این پایگاه‌داده شامل داده‌های زمین‌شناسی و زمین‌شناسی مهندسی توده‌سنگ‌های مسیر تونل‌ها و همچنین داده‌های راهبری و عملکرد ماشین‌ها می‌باشد.

۳- پروژه‌های مورد مطالعه

به منظور توسعه مدل تجربی تخمین عملکرد *TBM* با استفاده از سیستم طبقه‌بندی توده‌سنگ *RMR*، دسترسی به داده‌های دقیق از شرایط زمین‌شناسی و عملکرد واقعی ماشین، مهم‌ترین عامل موفقیت است. این داده‌ها باید از نظر کمی، کافی و از نظر کیفی، قابل اعتماد و تا حد ممکن عاری از خطا باشند. به این منظور داده‌های حفاری ۱۰ پروژه تونل‌سازی مجموعاً با طول حدود ۸۲ کیلومتر با شرایط زمین‌شناسی متفاوت از گروه‌های تحقیقاتی مرتبط اخذ و در یک پایگاه‌داده گردآوری شده است. پروژه‌های تونل‌سازی مورد مطالعه شامل تونل ذخیره آب *Yinsong* قطعه ۴ و تونل انتقال آب *Yinhan* در چین (*Gong, et al., 2021*)، تونل انتقال آب *MINAS* در اکوادور (*Gong, et al., 2021*)، تونل *Manapouri* در نیوزیلند (*URS Company, 2003; Hassanpour, et al., 2011*)، تونل ذخیره آب *Maroshi-Ruparel* در بمبئی هندوستان (*Jain, et al., 2014*) و تونل انتقال آب زاگرس قطعه ۲ (*Hassanpour, et al., 2009; 2016*)، تونل انتقال آب کرج قطعه ۱ (*Hassanpour, et al., 2010*)، تونل انتقال آب قمرود قطعه ۳ و ۴ (*Hassanpour, et al., 2009; 2011*)، تونل انتقال آب کرمان قطعه جنوبی (*Pourhashemi, et al., 2021*) و تونل انتقال آب گلاب (*Fatemi, 2016; Fatemi, et al., 2016; ICE, 2009*) در ایران می‌باشند [۹] - [۱۷]. این پایگاه‌داده شامل ۵۲۳ مقطع تونل است که این مقاطع به‌طور معمول طولی بین ۵ متر تا بیش از ۱۰۰ متر دارند و به حفاری یک شیفت کاری شامل چندین سیکل حفاری، مربوط بوده‌اند. در این پایگاه‌داده اطلاعات مختلفی از پارامترهای راهبری از جمله متوسط نیروی پیشران، متوسط سرعت چرخش کله‌حفار، گشتاور و توان کله‌حفار در هر مقطع و پارامترهای عملکرد ماشین نظیر طول مقطع حفاری شده و زمان صرف‌شده برای حفاری هر

جدول ۱- ویژگی‌های پروژه‌های تونل‌سازی مورد مطالعه

ردیف	پروژه	پهنه زمین‌شناسی	سنگ‌شناسی	ساختار کلی توده‌سنگ‌ها	طول کل تونل (km)	طول تونل استفاده شده در توسعه مدل‌ها (km)	حداکثر روباره (m)
۱	قطعه ۴ تونل انتقال آب Yinsong (چین)	-	گرانیت (۴۴۲۳ متر)، دیوریت (۱۵۴۷ متر)، سنگ آهک (۳۱۶۱ متر)، توف (۸۹۰ متر)، ماسه‌سنگ (۳۵۶ متر)، شیل (۵۴۶ متر)، توف ماسه‌ای (۸۸۴ متر)	-	۲۰/۲	۱۱/۸	<۳۰۰
۲	تونل انتقال آب Yinhan (چین)	-	فیلیت (۱۲۰۰ متر)، فیلیت کربن دار (۵۰۹ متر)، فیلیت و ماسه‌سنگ دگرگون شده (۳۵۵۴ متر)، شیست آمفیبول-کوارتزار (۱۰۶۷ متر)	-	۱۹/۹۸	۶/۳۳	۱۵۰۰
۳	تونل انتقال آب MINAS (اکوادور)	-	توف (۱۷۳۶ متر)، دیوریت (۳۱۴۸ متر)، توف و آداملیت (۴۰۲ متر)	-	۱۱/۳۹	۵/۲۹	۶۰۰
۴	تونل انتقال آب Manapouri (نیوزیلند)	توده‌های نفوذی و سنگ‌های دگرگونی پالئوزونیک تشکیلات Fiordland	گنیس، کالک سیلیکات و کوارتزیت و سنگ‌های درونگیر گابرو و دیوریت	توده‌ای مستحکم تا بسیار مستحکم	۱۰	۱۰	۱۲۰۰
۵	تونل انتقال آب Maroshi-Ruparel (هند)	Deccan traps (جریان‌های گدازه‌ای سنگ‌های بازالتی) کرتاسه فوقانی تا ائوسن پایینی	بازالت متراکم، بازالت پورفیریک، بازالت آمیگدالونیدی، سنگ‌های آذرآاری (توف، توف برشی) و میان لایه‌های شیلی	-	۱۲/۲۴	۵/۸۳	۸۲
۶	قطعه ۲ تونل انتقال آب زاگرس (ایران)	زاگرس چین‌خورده سنگ‌های کربناته و رسی سازندهای پایده، گوربی و ایلام	سنگ آهک، شیل و شیل آهکی	در رخنمون‌های سطحی: لایه‌لایه، درزه‌دار و متورق در عمق: سنگ‌های حاوی کانی‌های رسی اغلب پیوسته؛ آهک‌ها و ماسه‌سنگ‌ها ناپیوسته	۲۶	۱۵	۶۵۰
۷	قطعه ۱ تونل انتقال آب کرج - تهران (ایران)	البرز مرکزی سنگ‌های آذرآاری سازند کرج	انواع توف، توفیت، آگلومرا همراه با توده‌های نفوذی مستحکم (دیوریت، مونزودیوریت و...)	توده‌ای تا بسیار بلوکی همراه با پهنه‌های خردشده گسلی	۱۵/۷	۸/۷	۶۰۰
۸	قطعات ۳ و ۴ تونل انتقال آب قمرود (ایران)	کمریند دگرگونی سنندج-سیرجان سنگ‌های دگرگونی ژوراسیک (درجه پایین تا متوسط) و سنگ آهک کرتاسه	سنگ آهک، شیل، ماسه سنگ و شیل، فیلیت، شیست با رگه‌های کوارتزیت	سنگ‌های شیستوز و متورق همراه با پهنه‌های گسله	۱۸	۱۸	۷۰۰
۹	قطعه جنوبی تونل انتقال آب کرمان (ایران)	کمریند ماگماتیک سه‌ند-بزمان (زون ارومیه-دختر) سنگ‌های آذرآاری و آتشفشانی ائوسن همراه با توده‌های نفوذی	آندزیت، بازالت آندزیت، توف، ریولیت، گرانیت و گرانودیوریت، آگلومرا	توده‌ای تا بلوکی همراه با پهنه‌های خردشده گسلی	۱۹/۲	۵/۵	۹۴۰
۱۰	تونل انتقال آب گلاب (ایران)	کمریند دگرگونی سنندج-سیرجان سنگ‌های رسوبی و آذرین ائوسن تا ژوراسیک	تناوبی از شیل آریلیتی و ماسه‌سنگ دگرگونی، شیست و آمفیبولیت	-	۱۰	۸	-
کل :					۱۶۶/۲۲	۸۱/۶۶	

در این مقاطع مشکل زمین‌شناسی خاصی مانند ریزش سینه‌کار، توده‌سنگ‌های بلوکی، لهیدگی، جریان آب شدید، گل‌گرفتگی و انسداد ماشین وجود نداشته است. همچنین اطلاعات زمین‌شناسی و داده‌های راهبری ماشین دارای نوسانات زیادی نبوده‌اند و عملکرد ماشین با مشکل خاص و ناشناخته‌ای مواجه نبوده است و دیسک‌کاترها نیز سالم و دارای شرایط مناسبی از نظر میزان سایش بوده‌اند. این تونل‌ها در پهنه‌های مختلف زمین‌شناسی ایران و دیگر نقاط جهان که هریک دارای ویژگی‌های خاصی هستند، قرار دارند. همان‌طور که در این جدول ملاحظه می‌شود، این پروژه‌ها دامنه وسیعی از شرایط زمین‌شناسی را شامل می‌شوند و از نظر سنگ‌شناسی، هر سه نوع سنگ آذرین، رسوبی و دگرگونی، همچنین سنگ‌های آذرآواری را دربرمی‌گیرند. از دیدگاه زمین‌شناسی مهندسی نیز طیف وسیعی از ویژگی‌های زمین‌شناسی مهندسی برای توده‌سنگ‌های مسیر تونل‌ها قابل شناسایی است. از توده‌سنگ‌های ضعیف و خردشده تا سنگ‌های توده‌ای و یکپارچه و از سنگ‌های با ساینده‌اندک تا سنگ‌های بسیار ساینده شناسایی شده است. بدلیل دامنه تغییرات زیاد در ویژگی‌های ژئوتکنیک سنگ‌ها در پایگاه داده گردآوری شده، امکان توسعه مدل جامع برای پیش‌بینی عملکرد ماشین حفر تونل در شرایط مختلف زمین‌شناسی وجود دارد.

جدول ۲- خصوصیات ماشین‌های به کار رفته در پروژه‌های مورد مطالعه را نشان می‌دهد. چنان‌که ملاحظه می‌شود، ماشین‌ها در پروژه‌های داخل ایران شامل کرج (قطعه ۱)، زاگرس (قطعه ۲)، قمرود (قطعات ۳ و ۴)، کرمان (قطعه ۱، جنوبی) و گلاب تا حد زیادی شبیه یکدیگرند و همگی از نوع ماشین‌های سپر دوگانه (تلسکوپ) هستند. ماشین پروژه‌های *Yinhan* و *Yinsong* در چین از نوع ماشین‌های باز و پروژه *MINAS* در اکوادور نیز از نوع سپر دوگانه است. ماشین پروژه ماناپوری، تفاوت زیادی از نظر نوع ماشین و قطر حفاری و سایر پارامترهای مربوط به طراحی، با ماشین سایر پروژه‌ها دارد. ماشین به‌کارگرفته‌شده در این پروژه، از نوع ماشین‌های باز و دارای قطر حدود ۱۰ متر است که بیش از ۲ برابر تونل‌های کرج و قمرود قطر دارد، از این رو این ماشین از نظر توان، حداکثر نیروی پیشران، تعداد تیغه‌های برشی و غیره با سایر ماشین‌ها تفاوت اساسی دارد. در تونل‌های مورد مطالعه، ماشین‌ها دارای کله‌حفار مسطح، قطر ماشین از ۳/۶ تا حدود ۱۰ متر، تیغه‌های برشی اغلب به قطر ۴۳۲ میلی‌متر (۱۷ اینچ) و ۴۸۳ میلی‌متر (۱۹ اینچ) و فاصله متوسط دیسک‌کاترها از ۶۲ تا ۹۰ میلی‌متر متغیر است. پس از جمع‌آوری و دسترسی به داده‌های پروژه‌های تونل‌سازی، اقدام بعدی مرتب کردن داده‌ها در قالب بانک اطلاعاتی مناسب و تشکیل پایگاه‌داده (*Database*) است.

جدول ۲- خصوصیات ماشین‌های TBM به کار رفته در پروژه‌های تونل‌سازی مورد مطالعه

پروژه	قطعه ۴ تونل انتقال آب Yinsong	تونل انتقال آب Yinhan	تونل انتقال آب MINAS	تونل انتقال آب Manapouri	تونل انتقال آب Maroshi-Ruparel		قطعه ۲ تونل انتقال آب زاگرس	قطعه ۱ تونل انتقال آب کرج - تهران	قطعات ۳ و ۴ تونل انتقال آب قمرود	قطعه جنوبی تونل انتقال آب کرمان	تونل انتقال آب گلاب
					Maroshi-Vent hole stretch	Vakola-Vent hole stretch					
TBM type	Open TBM	Open TBM	Double shield	Main beam open TBM	Hard rock Gripper TBM	Hard rock Gripper TBM	Double shield	Double shield	Double shield	Double shield	Double shield
TBM diameter (m)	۷/۹۳	۸/۰۲	۵/۶۷	۱۰/۵	۳/۶	۳/۶	۶/۷۳	۴/۶۶۵	۴/۵۲۵	۵/۲۷۵	۴/۴۹۵
Number of cutters	۵۶	۵۰	۳۷	۶۸	۳۱	۳۱	۴۲	۳۱	۳۵	۳۷	۳۵
Cutter diameter (inch)	۱۷", ۱۹"	۱۹"	۱۹"	۱۷"	۱۷"	۱۷"	۱۷"	۱۷"	۱۷"	۱۷"	۱۷"
Average cutter spacing (mm)	۷۱	۸۲/۲	۷۸	۹۰	۶۲	۶۲	۹۰	۹۰	۷۵	۷۲	۷۵
Maximum thrust force (kN)	۲۳,۲۶۰	۲۷,۴۸۸	۱۱,۰۰۰	۲۷,۱۰۱	۳,۸۲۸	۳,۸۲۸	۲۸,۱۳۴	۱۶,۹۱۳	۱۸,۰۰۰	۲۰,۰۰۰	۲۰,۰۰۰
Rated torque (kN.m)	۸۴۱۰	۷۶۶۱	۲۹۱۶	۹۸۶۰	۲۲۵	۱۸۵	۴۴۵۰	۱۰۲۹	۸۰۲	۱۲۰۰	۸۰۲
Rotational speed (RPM)	۰ ~ ۷/۶	۰ ~ ۷/۳	۰ ~ ۹	۰ ~ ۵/۰۷	۰ ~ ۱۴	۰ ~ ۱۲	۰ ~ ۹	۰ ~ ۱۱	۰ ~ ۱۰	۰ ~ ۱۰/۹	۰ ~ ۱۲

۴- پایگاه‌داده

تاکنون شاخص‌های مختلفی جهت ارزیابی عملکرد ماشین حفر تونل توسط محققین معرفی و مورد استفاده قرار گرفته‌اند. در بین این پارامترها، شاخص نفوذ صحرایی (FPI) که توسط Nelson et al. (1983) ارائه شد، به‌طور موفقیت‌آمیزی جهت ایجاد همبستگی بین خصوصیات توده‌سنگ و عملکرد ماشین به کار رفته است [۱] و [۴]. شاخص FPI از تقسیم بار دیسک‌کاتر ($F_n (kN)$) بر نفوذ کله‌حفار ($P (mm/rev)$) محاسبه می‌شود و با استفاده از این پارامتر اثرات نرخ نفوذ، بار تیغه برشی و دور ماشین یا RPM در یک عامل ترکیب می‌شوند. FPI یک پارامتر مستقل از ماشین است و می‌تواند از داده‌های حفاری با هر قطر ماشین، اندازه، نوع و بار تیغه برشی محاسبه و به‌دلیل استفاده از پارامتر نفوذ در دور، امکان تلفیق داده‌های ماشین‌های با قطر متفاوت را فراهم می‌کند. بنابراین در این تحقیق به منظور ارزیابی عملکرد ماشین در پروژه‌های مورد مطالعه، شاخص FPI به دلیل سادگی، قابل‌اندازه‌گیری بودن و قابلیت هم‌مقیاس شدن ماشین‌های با سایزهای مختلف انتخاب شده است.

مرحله انتخاب پارامترهای ورودی مهم‌ترین و بحرانی‌ترین قسمت در توسعه مدل پیش‌بینی عملکرد ماشین TBM است. این پارامترها به سه دسته خصوصیات توده‌سنگ، خصوصیات راهبری و عملکرد ماشین تقسیم می‌شوند [۱۸]. همان‌طور که اشاره شد، مطالعات (Sapigni et al. (2002)، (Hassanpour et al. (2011)، (Salimi et al. (2019) و (Salimi (2021) نشان‌دهنده وجود ارتباط خوبی میان عملکرد ماشین و سیستم طبقه‌بندی توده‌سنگ RMR است. در کل با مقایسه سیستم‌های طبقه‌بندی توده‌سنگ معمول، RMR همبستگی بهتری با نرخ نفوذ TBM نشان می‌دهد که احتمالاً بواسطه استفاده از مقاومت تراکمی سنگ بکر به‌عنوان یک پارامتر ورودی است، بنابراین سیستم RMR و پارامترهای ورودی آن به عنوان اساس و پایه آنالیزها در مطالعه حاضر خواهد بود. از آنجا که سیستم‌های طبقه‌بندی توده‌سنگ برای تخمین سیستم نگهدارنده در فضاهای زیرزمینی پیشنهاد شده‌اند، شامل برخی پارامترهایی هستند که برای تخمین خواص حفاری توده‌سنگ موثر نیستند مانند جهت‌داری ناپیوستگی، آب زیرزمینی و پارامترهای مربوط به تنش،

بنابراین هوک و براون توصیه کردند که فقط از چهار پارامتر اول سیستم طبقه‌بندی RMR برای تعیین خواص حفاری توده‌سنگ استفاده شود [۱۸]. Hoek et al. (1995) و Hoek and Brown, (1997) نیز جهت توسعه سیستم طبقه‌بندی GSI (Geological Strength Index) به‌منظور تخمین خصوصیات توده‌سنگ از چنین رویکردی استفاده کردند.

بنیادوسی در سال ۱۹۷۳ میلادی اولین نسخه طبقه‌بندی RMR را در آفریقای جنوبی پیشنهاد داد. در این طبقه‌بندی شش پارامتر مقاومت تراکمی تک‌محوره (UCS)، شاخص کیفی سنگ (RQD)، فاصله‌داری ناپیوستگی‌ها (J_s)، شرایط سطح ناپیوستگی‌ها (J_c)، وضعیت آب زیرزمینی (G_w) و جهت‌داری ناپیوستگی‌ها (زاویه α یا زاویه بین دسته ناپیوستگی بحرانی و محور تونل) برای تعیین وضعیت ژئومکانیکی توده‌سنگ استفاده می‌شود. در این طبقه‌بندی به هریک از پارامترها بر اساس جداول مربوطه، امتیاز مشخصی تعلق می‌گیرد و مجموع امتیازات شش پارامتر به‌عنوان $adj-RMR$ (تصحیح شده نسبت به جهت‌داری) شناخته می‌شود. RMR پایه از جمع امتیازات پنج پارامتر اول به‌دست می‌آید و تصحیح جهت‌داری درزه‌ها در آن صورت نمی‌گیرد. همچنین RMR'_{89} همانند RMR پایه محاسبه می‌شود، با این تفاوت که شرایط آب زیرزمینی خشک و امتیاز آن همواره عدد ۱۵ در نظر گرفته می‌شود. بر اساس مطالعات، RMR پایه و RMR'_{89} تطابق بهتری با عملکرد ماشین نسبت به $adj-RMR$ دارند [۱] و [۱۸]. این موضوع نشان می‌دهد، پارامتر جهت‌داری درزه‌ها پارامتر مؤثری برای بهبود ضریب همبستگی RMR با پارامترهای عملکرد ماشین نیست و ضریب تصحیح جهت‌داری درزه‌ها، به شرایط پایداری توده‌سنگ مربوط است و نمی‌تواند به‌عنوان ضریب تصحیح مناسب برای سهولت یا صعوبت حفاری و خردایش سنگ استفاده شود. از نظر تئوری، سطوح ناپیوستگی بسته به جهت‌داری آنها نسبت به محور تونل، نقش مهمی در انتشار ترک در توده‌سنگ و فرایند برش توسط ماشین ایفا می‌کنند. از سوی دیگر، مطالعات قبلی نشان داده است که یافتن رابطه میان جهت‌داری ناپیوستگی‌ها و عملکرد ماشین کار ساده‌ای نیست. در واقع در توده‌سنگ‌های بلوکی و لایه لایه با دو یا سه دسته ناپیوستگی مشابه (توده‌سنگ همسانگرد)، اثر

همچنین با توجه به مطالعات *Hassanpour et al.* (2009)، *Laughton (1998)* و *Nelson (1983)* از نظر تئوری شرایط آب زیرزمینی پارامتر مؤثری در نرخ نفوذ ماشین نیست و به نظر می‌رسد از نظر تأثیر بر نرخ نفوذ دیسک کاتر در توده سنگ، شرایط نمناک، جریان قطره‌ای و جریان زیاد آب زیرزمینی تفاوت چندانی نداشته باشد. در واقع تنها حضور آب (صرف نظر از مقدار آن) برای کاهش پارامترهای مقاومتی ماده سنگ کافی است، اگرچه جریان بسیار زیاد آب نیز می‌تواند در شستن مواد پرکننده درزه‌ها و کاهش مقاومت توده سنگ مؤثر باشد. در حقیقت آب زیرزمینی با افزایش درجه دگرسانی توده سنگ و کاهش مقاومت ماده سنگ و مواد پرکننده درزه‌ها به صورت غیرمستقیم نقش مثبت در افزایش نرخ نفوذ ماشین دارد [۱۸]. تأثیر شرایط آب زیرزمینی روی عملکرد *TBM* توسط *Laughton (1998)* و *Nelson (1983)* نیز مطالعه شد. آنها نشان دادند که آب زیرزمینی اغلب روی نرخ پیشرفت (*AR*) از طریق نرخ بهره‌وری ماشین تأثیر دارد نه روی نرخ نفوذ و اغلب ناپایداری دیواره‌های تونل، با جریان آب زیرزمینی به داخل تونل رخ می‌دهد. بنابراین در این مطالعه از پارامتر وضعیت آب زیرزمینی نیز چشم پوشی می‌شود و نهایتاً در مدل‌سازی جهت توسعه معادلات تجربی، دو پارامتر ورودی سیستم *RMR* یعنی شرایط آب زیرزمینی و تعدیل جهت‌داری ناپیوستگی‌ها حذف می‌شوند. وزن پارامترهای شرایط آب زیرزمینی و *UCS* در سیستم *RMR* یکسان و برابر ۱۵ امتیاز است، در صورتی که تأثیر دو پارامتر روی خردایش سنگ و نرخ نفوذ ماشین کاملاً متفاوت است [۴].

بر اساس *Ribacchi and Lembo-Fazio (2005)* از آنجاکه مقادیر سیستم *RMR* در اکثر پروژه‌های تونل‌سازی برآورد می‌شود، می‌توان این طبقه‌بندی را به صورت *RMR* اندکی تغییر یافته (*RMRP*) برای تخمین عملکرد *TBM* توسعه داد، به طوری که در آن امتیاز ۱۵ (شرایط خشک) به پارامتر G_{11} اختصاص داده شود و پارامتر تعدیل جهت‌داری ناپیوستگی‌ها نیز حذف شود. *Salimi et al. (2019)* نیز با استفاده از روش *PCA* روی پارامترهای ژئوتکنیکی توده سنگ و انجام آنالیزهای متعدد با دو، سه و چهار پارامتر ورودی برای بدست آوردن پارامترهای بحرانی با بیشترین تأثیر روی عملکرد ماشین، نشان داد که چهار پارامتر مقاومت تراکمی

جهت‌داری درزه‌ها را می‌توان بسیار ناچیز فرض کرد. جهت‌داری ناپیوستگی‌ها فقط در مواردی که یک دسته ناپیوستگی اصلی و غالب وجود دارد، نظیر توده‌سنگهای شدیداً متورق و شیستوز (توده‌سنگ ناهمسانگرد) می‌تواند پارامتری مؤثر بر عملکرد ماشین محسوب شود. در این حالت، زمانی که ماشین به موازات سطوح ناپیوستگی غالب در توده‌سنگ پیشروی می‌کند، انتشار ترک در راستای عمود بر سطوح ناپیوستگی انجام می‌شود. این موضوع نرخ نفوذ را کاهش می‌دهد، زیرا شکست سنگ در راستای عمود بر سطوح ناپیوستگی مشکل‌تر است. وقتی سطوح ناپیوستگی غالب توده‌سنگ در جهت عمود بر مسیر پیشروی ماشین قرار دارند، گسیختگی سنگ در راستای این سطوح ناپیوستگی ایجاد می‌شود. این حالت معمولاً مناسب‌ترین شرایط را به لحاظ قابلیت حفاری دارد، چراکه ناپیوستگی‌ها به ایجاد و گسترش ترک بین دو تیغه برشی مجاور کمک می‌کنند [۱۸]. در پایگاه داده گردآوری شده، اغلب مقاطع تونل در توده‌سنگ‌هایی همسانگرد یا با همسانگردی نسبتاً زیاد واقع شده‌اند، بنابراین به نظر می‌رسد تأثیر جهت‌داری ناپیوستگی‌ها روی عملکرد ماشین بسیار اندک باشد. به همین دلیل علیرغم نقش مهم جهت‌داری درزه‌ها در توسعه ترک‌ها حین حفاری، بواسطه چالش‌های یافتن رابطه بین این پارامتر و نرخ نفوذ و با توجه به این که پایگاه داده مورد مطالعه از داده‌های حفاری در توده‌سنگ‌های ایزوتروپ و همسانگرد بدست آمده و جهت ارزیابی این پارامتر مناسب نیست، پارامتر تعدیل جهت‌داری درزه‌ها در این مطالعه حذف شد.

برای تعیین امتیاز دو پارامتر فاصله‌داری (J_2) و شرایط سطح ناپیوستگی‌ها (J_3) در سیستم *RMR*، باید دسته ناپیوستگی بحرانی (با حداکثر فرکانس و حداقل فاصله‌داری) که بیشترین تأثیر را در پایداری تونل دارند، در نظر گرفته شود. در این مطالعه از آنجاکه داده‌های مورد نیاز، از مطالعات توده‌سنگ در پروژه‌های تونل‌سازی مکانیزه جمع‌آوری شده است، منظور از دسته ناپیوستگی بحرانی، دسته ناپیوستگی است که بیشترین تأثیر را در نرخ نفوذ ماشین دارد. در این پروژه‌ها زاویه α بر اساس جهت‌داری سطوح لایه‌بندی و تورق در صورت وجود، یا در مواردی دسته درزه‌ای که بیشترین تأثیر را در حفاری توده‌سنگ داشته (زاویه α بین ۴۵ تا ۷۰ درجه)، محاسبه شده است.

جدول ۳- طبقه‌بندی انواع سنگ (RTC) در پایگاه داده (اقتباس از Hoek and Brown, 1980)

Code	نوع سنگ (Rock Type)
C	رس‌سنگ، گل‌سنگ، مارن، شیل، فیلیت، آرزیلیت
S	ماسه‌سنگ، سیلت‌استون، کنگلومرا، کوارتزیت
L	سنگ‌آهک، گچ، دولومیت، سنگ‌مرمر
K	سنگ آهک کارستی
M	سنگ‌های دگرگونی مانند گنیس و شیست
G	سنگ‌های آذرین درشت‌دانه مانند گرانیت و دیوریت
V	سنگ‌های آتشفشانی ریزدانه مانند بازالت، توف و آندزیت

همان‌طور که ذکر شد، در این مطالعه چهار پارامتر سیستم طبقه‌بندی RMR پایه شامل J_c ، J_s ، RQD ، UCS و پارامتر RTC به‌عنوان پارامترهای ورودی برای توسعه روابط تجربی پیش‌بینی عملکرد ماشین بر اساس داده‌های جمع‌آوری شده در پایگاه‌داده به‌کار رفته است. شکل ۱ توزیع درصد فراوانی و تعداد مقاطع انواع رده سنگ‌شناسی (RTC) در پایگاه‌داده مورد مطالعه را نشان می‌دهد. آنالیز آماری پارامترهای عملکرد ماشین شامل شاخص نفوذ صحرایی (FPI) و نرخ نفوذ (P) به همراه پارامترهای ورودی مدل (UCS ، RQD ، J_s و J_c) در جدول ۴ خلاصه شده است. از آنجا که پارامتر شرایط درزه (J_c) در سیستم طبقه‌بندی RMR کیفی و توصیفی است، در این مطالعه این پارامتر به صورت عدد ۰ تا ۳۰ بر اساس جدول امتیازدهی سیستم RMR تعریف شده است.

از آن‌جا که بافت سنگ چه از نظر دانه‌بندی و چه از نظر ماتریکس به‌طور مستقیم تعیین‌کننده خصوصیات فیزیکی و مکانیکی سنگ است، انتظار می‌رود در سنگ‌هایی که در یک رده سنگ‌شناسی قرار می‌گیرند، پارامترهای عملکرد ماشین مشابه باشند. شکل ۲ نمودار جعبه‌ای پارامتر FPI را در هر رده سنگ‌شناسی (RTC) نشان می‌دهد و نقاط قرمز، متوسط FPI اندازه‌گیری شده در هر رده سنگ‌شناسی است. از این نمودار می‌توان دریافت که وقتی نوع سنگ‌شناسی در مدل مدنظر قرار می‌گیرد، می‌توان رابطه خوبی بین خصوصیات مقاومتی توده‌سنگ و مقدار FPI مشاهده کرد. همان‌طور که انتظار می‌رفت، بیشترین مقادیر FPI در سنگ‌های آذرین (رده G) و کمترین مقادیر FPI در سنگ‌های رسوبی ضعیف

تک‌محوره (UCS)، شاخص کیفی سنگ (RQD)، فاصله‌داری ناپیوستگی‌ها (J_s) و شرایط سطح ناپیوستگی‌ها (J_c) دارای بیشترین تأثیر در عملکرد ماشین هستند.


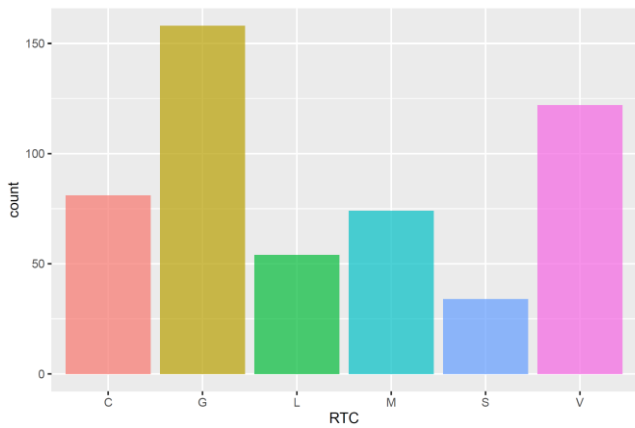
علاوه بر این، *Salimi et al.* (2012) و *Farrokh et al.* (2019) پارامتر نوع سنگ ($Rock Type Code$) را به عنوان یک پارامتر ورودی در مدل، جهت پیش‌بینی نرخ نفوذ ماشین مطرح کردند. به این دلیل که نوع سنگ که معرف بافت سنگ (نوع سیمان و درجه سیمانته شدن)، ترکیب کانی‌شناسی، شکل و سایز دانه‌هاست، روی نرخ نفوذ ماشین تأثیر زیادی دارد [۴] و [۱۹]. طبق نتایج آنالیز حساسیت و مطالعه پارامتریک مدل مطرح شده توسط *Fatemi et al.* (2016) پارامتر RTC نقش مهمی در تخمین قابلیت حفاری توده‌سنگ دارد [۲۰] و بنابراین با توجه به نتایج مطالعات قبلی، این پارامتر نیز در مدل‌سازی مدنظر قرار گرفت. در این مطالعه، هفت گروه انواع سنگ (RTC) که توسط *Hoek and Brown (1980)* و *Stevenson (1999)* تقسیم‌بندی شده، مبنای رده‌بندی گروه‌های سنگی قرار داده شد (جدول). در این رده‌بندی چهار رده اول سنگ‌های رسوبی، رده پنجم دگرگونی، رده ششم آذرین درونی و رده هفتم آتشفشانی و آذرآواری است. شایان ذکر است، گنیس با اینکه سنگ دگرگونی است ولی شبیه به گرانیت رفتار می‌کند، به خصوص وقتی فولیاسیون ضعیفی داشته باشد، به همین دلیل در این مطالعه گنیس جزء سنگ‌های رده G لحاظ شده است. به دلیل عدم وجود لیتولوژی آهک کارستی در پایگاه داده مورد مطالعه، رده K حذف شده است. به این ترتیب برای توسعه روابط و مدل تجربی تخمین عملکرد TBM بر اساس پارامترهای سیستم طبقه‌بندی توده‌سنگ RMR ، از چهار پارامتر RMR پایه شامل UCS ، RQD ، J_s و J_c و پارامتر RTC به عنوان پارامترهای ورودی استفاده شده است.

۵- آنالیز آماری پارامترهای ورودی مدل

در این مرحله بر اساس داده‌های جمع‌آوری شده از پروژه‌های تونل‌سازی، داده‌ها آماده‌سازی می‌شوند. این آماده‌سازی شامل آنالیزهای آماری توصیفی، حذف داده‌های پرت به کمک برخی تکنیک‌های یادگیری ماشین (*Machine Learning*)، شناسایی داده‌های گم‌شده (*Missing Value*) و غیره می‌باشند که به این ترتیب داده‌ها تمیز شده و از تاثیر منفی آن‌ها بر روی مدل جلوگیری می‌گردد.

مثل سنگ‌های آرزلیتی (رده C) اندازه‌گیری شده است. مطالعات Robbins 1992, Laughton 1998, Gong et al. 2006, Hassanpour et al. 2011 نیز این نتایج را برای انواع سنگ تأیید می‌کنند.


مطلعات Robbins 1992, Laughton 1998, Gong et al. 2006, Hassanpour et al. 2011 نیز این نتایج را برای انواع سنگ تأیید می‌کنند.



شکل ۱- (الف) توزیع درصد فراوانی؛ (ب) تعداد مقاطع انواع مختلف سنگ‌شناسی (RTC) در پایگاه داده مورد مطالعه

جدول ۴- آنالیز آماری پارامترهای عملکرد ماشین و چهار پارامتر سیستم RMR پایه

	N	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	Variance	Std. Deviation	Skewness	Kurtosis
FPI (kN/cutter/mm/rev)	۵۲۳	۲/۱۴	۱۰/۴۹	۱۶/۶۸	۲۶/۳۷	۳۱/۵۰	۱۵۰/۰	۶۸۹/۱۱	۲۶/۲۵	۲/۳۱	۵/۸۹
P (mm/rev)	۵۲۳	۱/۵۰	۴/۵۰	۷/۸۰	۸/۷۸	۱۱/۱۰	۴۱/۳۹	۳۶/۸۶	۶/۰۷	۱/۹۶	۵/۳۲
UCS (MPa)	۵۲۳	۴/۲۵	۳۸/۵۰	۶۵/۰	۸۰/۹۳	۱۲۰/۰	۳۰۰/۰	۳۳۵۷/۰۵	۵۷/۹۴	-۰/۸۶	-۰/۲۹
RQD (%)	۵۲۳	۱۰	۴۵	۷۵	۶۷/۱۵	۹۰	۱۰۰	۷۰۸/۰۲	۲۶/۶۰	-۰/۵۳	-۱/۰۳
Js (m)	۵۲۳	-۰/۰۳	-۰/۱۳	-۰/۲۸	-۰/۳۷	-۰/۴۳	۲/۰۰	-۰/۱۱	-۰/۳۳	۱/۹۲	۳/۸۴
Jc (Partial rating in RMR)	۵۲۳	۴	۱۰	۱۶	۱۶/۰۵	۲۰	۳۰	۳۰/۱۷	۵/۴۹	-۰/۲۱	-۰/۶۲



شکل ۲- نمودار مقادیر FPI در هر رده سنگ‌شناسی (RTC)

۶- روابط تجربی پیش‌بینی عملکرد TBM

بخش زیادی از مدل‌های مبتنی بر AI که تاکنون برای پیش‌بینی عملکرد TBM به کار رفته‌اند، براساس تکنیک‌های یادگیری نظارت شده بوده‌اند. در این رویکردها داده‌های ورودی و خروجی به ماشین آموزش داده می‌شوند و سپس ساختار مدل‌های پیش‌بینی کننده، ساخته می‌شوند و سپس بهترین مدل برای آنالیز رابطه بین متغیرهای مستقل و متغیر وابسته انتخاب می‌گردد. در اصول یادگیری ماشین، الگوریتم‌های ریاضی تلاش می‌کنند به کمک ترکیبی از متغیرهای مستقل، تابعی را بهینه کنند تا مقدار پیش‌بینی شده توسط تابع به مقدار واقعی متغیر وابسته نزدیک شود. نوع متغیر وابسته (پیوسته یا گسسته) تعیین کننده نوع الگوریتم‌هایی است که با آن مسائل حل می‌شود و یادگیری الگوریتم از طریق داده‌هایی که مشاهده نموده‌است، رخ می‌دهد. در این تحقیق با استفاده از متغیرهای مستقل شامل چهار پارامتر RMR پایه یعنی UCS ، RQD ، J_s و J_c و رده سنگ‌شناسی RTC ، متغیر وابسته عملکرد ماشین (FPI) پیش‌بینی می‌شود. از آنجا که متغیر وابسته FPI از نوع داده‌های پیوسته است، الگوریتم‌های رگرسیون برای مدل‌سازی روی این داده‌ها مناسب می‌باشند. ابتدا الگوریتم کلاسیک رگرسیون و سپس الگوریتم‌های مدرن‌تر از جمله الگوریتم‌های گام‌به‌گام ($Stepwise Regression$) و الگوریتم‌های قاعده‌سازی ($Regularization$) شامل الگوریتم‌های $Lasso$ و $Ridge Regression$ روی داده‌ها پیاده‌سازی می‌شوند. برای این کار داده‌ها را به دو بخش $Train$ و $Test/Validation$ تقسیم کرده و روی داده‌های $Train$ مدل‌های مختلف الگوریتم‌های ML پیاده‌سازی شده تا به بهترین مدل نزدیک شویم، تا جایی که مسئله تعمیم‌پذیری مدل تأمین گردد و مدل روی داده‌هایی که خارج از بازه داده‌های ورودی مدل است هم خوب عمل کرده و به درستی پیش‌بینی کند.

پس از پیاده‌سازی الگوریتم‌های مختلف، رابطه (۱) براساس چهار پارامتر ورودی سیستم RMR پایه (UCS ، RQD ، J_s و J_c) و پارامتر RTC با R^2 حدود ۰/۸۲ بهترین


رابطه برای تخمین FPI در انواع مختلف سنگ‌شناسی به‌دست آمده و مقادیر پارامتر RTC برای هر رده سنگ‌شناسی تعیین شده است. در این معادله UCS مقاومت تراکمی تک‌محوره بر اساس MPa ، RQD شاخص کیفی توده‌سنگ بر اساس درصد، J_s فاصله‌داری ناپیوستگی‌ها بر اساس متر (m) و J_c امتیاز شرایط سطح ناپیوستگی‌ها در سیستم RMR است. برای تعیین J_s و J_c از دسته ناپیوستگی که بیشترین تأثیر را در نرخ نفوذ ماشین دارد، استفاده شده است. براساس نتایج آزمون t انجام شده روی مدل رابطه (۱)، پارامتر J_c در این رابطه به لحاظ آماری متمایز نشده و بایستی از مدل حذف شود و به این ترتیب رابطه (۲)، مدل بهینه با همان ضریب تعیین R^2 بدست آمد. با استفاده از رابطه (۲) مقدار FPI با استفاده از سه پارامتر ورودی سیستم طبقه‌بندی RMR پایه و ضریب RTC مرتبط با رده سنگ‌شناسی که مقادیر آن در **جدول** مشخص شده‌است، با دقت بالا تخمین زده می‌شود. مقادیر ضریب RTC رابطه (۲) برای هر رده سنگ در **جدول** تعیین شده است. باید توجه داشت که رده سنگ‌شناسی G و V دارای محدوده مقاومتی گسترده‌ای بوده و مقاطع تونل این دو رده سنگ‌شناسی در دو بخش سنگ‌های با مقاومت کم‌تر از ۱۵۰ و بیشتر از ۱۵۰ مگاپاسکال آنالیز شده و ضرایب RTC آن‌ها تعیین شده است. بنابراین هنگام استفاده از رابطه نهایی برای رده سنگ‌شناسی G و V ، بایستی ابتدا به مقدار UCS سنگ توجه کرد و سپس ضریب RTC مرتبط، در رابطه استفاده شده و مقدار FPI برآورد شود. **شکل ۳** مقادیر FPI اندازه‌گیری شده در برابر FPI پیش‌بینی شده توسط رابطه (۲) را به تفکیک داده‌های $Train$ و $Test$ نشان می‌دهد و عملکرد قابل قبول مدل، در این شکل قابل مشاهده است. همان‌طور که در این شکل ملاحظه می‌شود، مقادیر FPI بزرگتر، کمتر از مقدار واقعی پیش‌بینی شده‌اند و همبستگی مدل در مقادیر FPI کمتر از $(kN/cutter/mm/rev)$ ۵۰ خیلی بهتر است. این موضوع تأثیر شرایط خاص و پیچیده ماشین و زمین در FPI بزرگتر را نشان می‌دهد و تمرکز مطالعات آتی جهت توسعه روابط در این شرایط توصیه می‌شود.

$$FPI = 6.066 (UCS)^{0.25} (RQD)^{0.22} (J_s)^{0.4} (J_c)^{-0.15} (RTC) \quad (R^2 = 0.82) \quad (1)$$

$$FPI = 5.173 (UCS)^{0.22} (RQD)^{0.19} (J_s)^{0.41} (RTC) \quad (R^2 = 0.81) \quad (2)$$

جدول ۵- مقادیر ضریب ضربه RTC در رابطه (۲)

RTC	Code	نوع سنگ (Rock Type)
۱	C	رس سنگ، گل سنگ، مارن، شیل، فیلیت، آرژیلیت
۱/۵۹۸	S	ماسه سنگ، سیلت استون، کنگلومرا، کوارتزیت
۱/۳۲۵	L	سنگ آهک، گچ، دولومیت، سنگ مرمر
-	K	سنگ آهک کارستی
۱/۲۰۲	M	سنگ های دگرگونی مانند شیست
۱/۱۷۷	G ₁ (UCS < ۱۵۰ MPa)	سنگ های آذرین درشت دانه مانند گرانیت و دیوریت
۱/۸۴۸	G ₂ (UCS ≥ ۱۵۰ MPa)	
۰/۸	V ₁ (UCS < ۱۵۰ MPa)	سنگ های آتشفشانی ریزدانه مانند بازالت، توف و آندزیت
۱/۸۷۶	V ₂ (UCS ≥ ۱۵۰ MPa)	



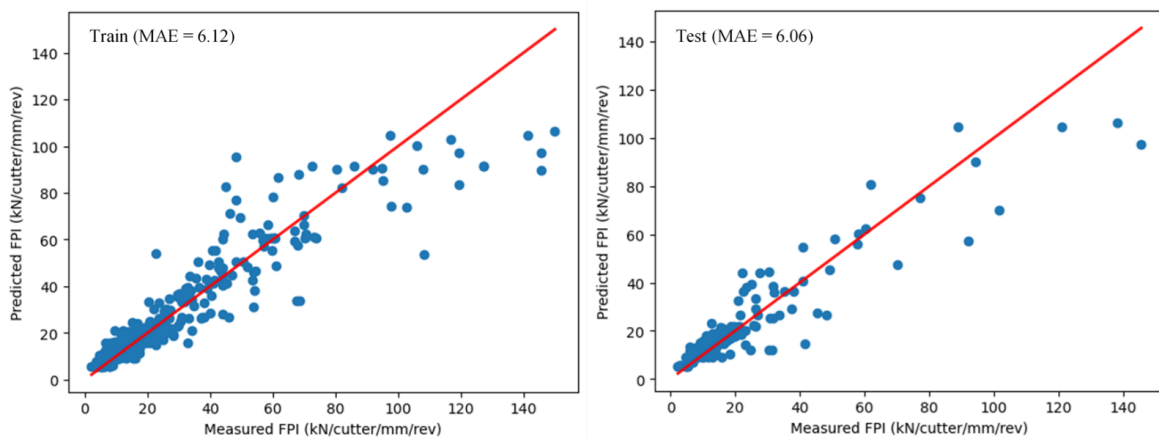
شکل ۳- مقادیر FPI اندازه گیری شده در برابر FPI پیش بینی شده توسط رابطه (۲) به تفکیک داده های Train و Test

مقطع تونل در پایگاه‌داده که حاوی اطلاعات چهار پارامتر ورودی سیستم RMR پایه (J_c و J_s , RQD , UCS) و پارامتر RTC بودند را به دو بخش $Train$ و $Test/Validation$ تقسیم کرده و سپس هایپر پارامترهای الگوریتم $Tuning$ شده است. در هر دو الگوریتم $Bagging$ و $Random Forest$ هایپر پارامترهای مدل شامل $max-feature$: تعداد متغیرهایی که الگوریتم برای ساخت مدل استفاده می‌کند، n - $estimator$: تعداد درخت‌هایی که ساخته می‌شود، $max-depth$: عمق درخت‌ها، $ccp-alpha$: پارامتر پیچیدگی درخت‌ها و $min-samples-leaf$: حداقل تعداد مشاهدات در هر برگ با رویکرد $K-fold Cross Validation$ بهینه شده و بهترین مدل با هایپر پارامترهای بهینه ساخته می‌شود. هر دو الگوریتم $Bagging$ و $Random Forest$ بر اساس هایپر پارامترهای بهینه بر روی داده‌های $Train$ پیاده‌سازی شدند و سپس مدل‌ها در معرض داده‌های $Test$ قرار گرفته تا عملکرد مدل ارزیابی شود. بهترین مدل بدست آمده حاصل آموزش الگوریتم $Random Forest$ بر روی داده‌های $Train$ با میانگین قدرمطلق خطای حدود $6 (kN/cutter/mm/rev)$ است. مقادیر FPI اندازه‌گیری شده در برابر FPI پیش‌بینی شده توسط مدل $Random Forest$ به تفکیک داده‌های $Train$ و $Test$ در شکل ۴ ارائه شده است.

۷- اصلاح سیستم طبقه‌بندی توده‌سنگ

RMR جهت تخمین عملکرد TBM

از آنجاکه سیستم طبقه‌بندی توده‌سنگ RMR یکی از اولین ارزیابی‌هایی است که در پروژه‌های تونل‌سازی انجام می‌شود و پارامترهای آن معمولاً در دسترس است، اصلاح این سیستم با هدف پیش‌بینی عملکرد ماشین می‌تواند در پروژه‌های تونل‌سازی مکانیزه بسیار کمک‌کننده باشد. با توجه به دلایلی که ذکر شد، به‌نظر می‌رسد می‌توان با تغییر در مقادیر امتیاز پارامترهای ورودی سیستم RMR و تغییر در وزن‌دهی داخلی هر پارامتر، به RMR بهینه‌ای دست یافت که بتوان از طریق آن عملکرد ماشین TBM در سنگ را با دقت پیش‌بینی کرد. رویکردی که برای توسعه این سیستم RMR بهینه به کار گرفته شده است، استفاده از شاخص اهمیت متغیر یا $Variable Importance$ در الگوریتم رگرسیون غیرخطی $Random Forest$ است. در ادامه مطالعه برای شناسایی متغیرهای مهم‌تر در مدل و تعیین وزن هر یک از متغیرها، الگوریتم‌های $Bagging$ و $Random Forest$ در $Python$ با استفاده از کتابخانه $Scikit-Learn$ پیاده‌سازی شد. در این کتابخانه الگوریتم $SKlearn$ ، ماژول $ensemble$ و تابع $RandomForestRegressor$ مدل $Random Forest$ و $Bagging$ را اجرا می‌کند. برای مدل‌سازی ابتدا داده‌های ۵۲۳



شکل ۴- مقادیر FPI اندازه‌گیری شده در برابر FPI پیش‌بینی شده توسط مدل $Random Forest$ به تفکیک داده‌های $Train$ و $Test$ پایگاه‌داده مورد مطالعه

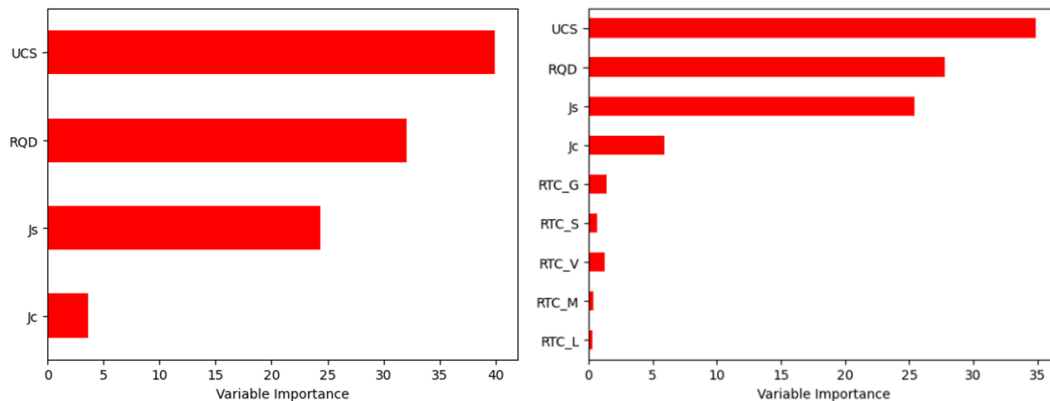
خروجی مدل $Black-Box$ است. برای شفاف شدن نتایج مدل این الگوریتم‌ها، شاخص‌هایی معرفی شده‌اند که از طریق

الگوریتم $Random Forest$ الگوریتم بسیار قدرتمندی است ولی نکته منفی این الگوریتم آن است که به‌علت پیچیدگی،

پایگاه داده در شکل ۵ (راست) نشان داده شده است و همان طور که ملاحظه می شود، به ترتیب UCS ، RQD و J_s بیشترین شاخص VI و بیشترین تأثیر را در مدل دارند. مقدار VI پارامتر RTC صفر یا نزدیک صفر است و این پارامتر بهتر است از مدل حذف شود. تأثیر RTC در مدل سازی عملکرد TBM برای مجموعه داده حاضر ناچیز است، به همین دلیل تصمیم به حذف این پارامتر برای دستیابی به مدلی ساده تر و با قابلیت تعمیم بالاتر گرفته شد. این به معنای نادیده گرفتن نقش نوع سنگ در کلیت مکانیسم خردایش نیست، بلکه نشان دهنده کفایت پارامترهای کمی شده دیگر در بازنمایی رفتار حفاری در چارچوب این مطالعه است.

در مرحله بعدی، پارامتر RTC از مدل حذف شده و مجدداً الگوریتم $Random Forest$ بر روی داده های $Train$ پیاده سازی و شاخص VI مدل محاسبه شد. شاخص VI متغیرهای مدل $Random Forest$ نهایی در شکل ۵ (چپ) نشان داده شده است.

آن می توان دریافت که مدل به کدام متغیرها وزن بیشتری داده تا پیش بینی صورت گیرد. منطق تعیین این شاخص ها به این صورت است که چون در $Random Forest$ برخی متغیرها به صورت تصادفی در مدل نیستند، می توان فهمید که عدم حضور یک متغیر در مدل، چقدر خطای MSE مدل را زیاد می کند. خطای پیش بینی در داده های $Out Of Bag$ (OOB) محاسبه می شوند، چراکه داده های OOB تاکنون در معرض الگوریتم قرار نگرفته و برای محاسبه خطای پیش بینی بسیار مناسب هستند. یکی از این شاخص ها بنام شاخص اهمیت متغیر یا $Variable Importance$ با دو پارامتر افزایش خطا MSE و کاهش ناخالصی گره ($Node Impurity$)، متغیرهای مهم تر در الگوریتم را متمایز می کنند و متغیرهایی که وجود آن ها تأثیر چندانی در کاهش خطای مدل ندارند و مقدار $Variable Importance$ آن صفر یا نزدیک صفر است، می توانند حذف شوند. شاخص VI می تواند بر حسب درصد نیز در مدل محاسبه شود. مقادیر VI حاصل از آموزش الگوریتم $Random Forest$ بر روی داده های



شکل ۵- مقادیر VI متغیرهای مدل $Random Forest$ در تخمین پارامتر FPI (راست) با RTC (چپ) بدون RTC

در سنگ و شهادهای دیگر هم باید این مسئله را تأیید کند. به نظر می رسد، خروجی ماشین با شهادهای حفاری مکانیزه در سنگ هم خوانی دارد. در نهایت با توجه به نتایج الگوریتم های یادگیری ماشین در این مطالعه، امتیاز پارامترهای ورودی سیستم RMR پایه شامل امتیاز UCS برابر ۴۰، امتیاز RQD برابر ۳۰، امتیاز J_s برابر ۲۵ و امتیاز J_c برابر ۵ از ۱۰۰ امتیاز جهت توسعه سیستم RMR بهینه برای پیش بینی عملکرد ماشین TBM در سنگ پیشنهاد می شود. این سیستم RMR توسعه یافته برای تخمین عملکرد ماشین TBM ، RMR_{TBM} نام گذاری شده است. پس از تعیین امتیاز هر یک از پارامترهای

از مقادیر $Variable Importance$ پارامترهای ورودی مدل می توان دریافت که هنگام توسعه درخت های رگرسیون در مدل $Random Forest$ به کدام متغیرها وزن بیشتری داده شده تا بهترین پیش بینی FPI صورت گیرد. در این شکل پارامتر $Variable Importance$ متغیر UCS برابر ۴۰٪ است، به این معنی که اگر UCS را از مدل حذف کنیم و موقع ساخت مدل، درخت های رگرسیون به UCS دسترسی نداشته باشند، نسبت به وقتی که به UCS دسترسی دارند، به طور متوسط خطای MSE حدود ۴۰ درصد افزایش می یابد. باید در نظر داشت که این خروجی ماشین است و تجربیات حفاری

FPI مطابق جدول ۶ پیشنهاد می‌شود. در این طبقه‌بندی به هر یک از پارامترهای RQD ، UCS ، J_s و J_c بر اساس جدول ۶ و نمودارهای شکل ۶ امتیازی تعلق می‌گیرد و مجموع امتیازات این پارامترها به‌صورت صفر تا صد مقدار RMR_{TBM} را تعیین می‌کند. حال باتوجه به مقدار به‌دست‌آمده، رده توده‌سنگ، رده حفریزیری، توصیف حفریزیری و شرایط پایداری توده‌سنگ مسیر تونل پیش‌بینی می‌شود.


ورودی RMR_{TBM} ، باتوجه به محدوده تغییرات هر پارامتر ورودی و FPI پیش‌بینی‌شده مربوط به آن محدوده در درخت‌های رگرسیون توسعه‌یافته، با انجام سعی و خطا باید تصمیم گرفت که وزندهی داخلی هر پارامتر ورودی در چه حالتی بهینه است و درنهایت نمودارهای شکل ۶ برای امتیازدهی به پارامترهای ورودی RMR_{TBM} بدست آمد. به‌این‌ترتیب سیستم طبقه‌بندی RMR_{TBM} با هدف پیش‌بینی عملکرد TBM در سنگ سخت و تخمین شاخص نفوذصحرایی

جدول ۶- سیستم RMR_{TBM} توسعه یافته برای تخمین FPI

Uniaxial Compressive Strength of intact rock (0 – 40)							
Point-load strength index	> ۱۰	۸ – ۱۰	۶ – ۸	۴ – ۶	۲ – ۴	۱ – ۲	–
UCS (MPa)	> ۲۵۰	۲۰۰ – ۲۵۰	۱۵۰ – ۲۰۰	۱۰۰ – ۱۵۰	۵۰ – ۱۰۰	۲۵ – ۵۰	< ۲۵
Ratings	۴۰	۳۷	۳۲	۲۵	۱۷	۹	۳
Drill core Quality RQD (0 – 30)							
RQD (%)	> ۹۹	۹۰ – ۹۹	۷۰ – ۹۰	۵۰ – ۷۰	۳۰ – ۵۰	۱۰ – ۳۰	< ۱۰
Ratings	۳۰	۲۸	۲۴	۱۸	۱۲	۶	۱/۵
Spacing of discontinuities (0 – 25)							
J_s (m)	> ۲	۰/۶ – ۲	۰/۲ – ۰/۶	۰/۰۶ – ۰/۲	۰/۰۶ – ۰/۲	< ۰/۰۶	
Ratings	۲۵	۲۲	۶	۱/۲	۰		
Condition of discontinuities (0 – 5)							
J_c (Partial rating in RMR)	Very rough surfaces Not continuous No separation Unweathered walls	Slightly rough surfaces Separation < 1mm Slightly weathered walls	Slightly rough surfaces Separation < 1mm Highly weathered walls	Slickensided surfaces or Couge < 5 mm or Separation 1-5 mm Continuous	Soft gouge > 5 mm or Separation > 5 mm Continuous		
Partial rating in BRMR	۳۰	۲۵	۲۰	۱۰	۰		
Ratings	۵	۳/۳	۲/۵	۱/۶	۰		

جدول ۷- رده‌بندی سیستم RMR_{TBM} و محدوده مقادیر FPI و شرایط حفاری در هر رده

RMR_{TBM} Class	I	II	III	IV	V
Total Rating of RMR_{TBM}	۸۱ – ۱۰۰	۶۱ – ۸۰	۴۱ – ۶۰	۲۱ – ۴۰	۰ – ۲۰
FPI ranges (kN/cutter/mm/rev)	≥ 70	۴۰ – ۷۰	۲۰ – ۴۰	۱۰ – ۲۰	< ۱۰
Boreability class	B-0	B-I	B-II	B-III	B-IV & B-V
Rock Mass Boreability	Tough	Fair-Tough	Good-Fair	Very Good-Good	Extremely Good shielded tunneling, potential support problems, potential soft rock problems
TBM Excavatability	difficult boring	Fair boring	Good boring	Very good and easy boring, potential support problems	Collapse, squeeze, gripper problems
Stability condition	Completely stable	Stable	Minor instabilities	Local or major instabilities	Highly foliated and schistose rocks, shale, marlstone, thick fault zones
Rock Types	Very strong and massive intrusive and metamorphic rocks	Strong igneous and metamorphic rocks	Blocky and jointed tuffs, limestones	Alternations of sandstones, limestones and shales Flysch type sediments, most low strength rocks and jointed rock masses	



شکل ۶- نمودارهای مورد استفاده در امتیازدهی به پارامترهای ورودی RMR_{TBM}



می‌شود. این درحالی بود که RMR هر دو توده سنگ یکسان و برابر ۶۸ بود و داشتن مقدار RMR کمکی به پیش‌بینی قابلیت حفری توده سنگ نکرده بود. مقدار FPI توده سنگ شماره ۱ بیش از ۷۰ و توده سنگ شماره ۲ در محدوده $(kN/cutter/mm/rev)$ ۲۰-۴۰ پیش‌بینی می‌شود و کاملاً واضح است که حفاری در توده سنگ شماره ۲ آسان‌تر است و قابلیت حفری و نفوذ بیشتری دارد. برای مقایسه کارایی طبقه‌بندی RMR_{TBM} و $Basic\ RMR$ در پیش‌بینی عملکرد ماشین در سنگ، رابطه این دو طبقه‌بندی با FPI به‌عنوان پارامتر ارزیابی عملکرد TBM ، در پایگاه داده مورد مطالعه بررسی شد. همانطور که در شکل ۷ ملاحظه می‌شود، ضریب تعیین R^2 رابطه RMR_{TBM} با FPI نسبت به رابطه $Basic\ RMR$ با FPI بسیار بالاتر است و نشان می‌دهد RMR_{TBM} به‌خوبی می‌تواند برای تخمین عملکرد ماشین در سنگ

برای ارائه مثالی از کاربرد این رده‌بندی، از مثالی که در مطالعات *Salimi (2021)* ذکر شده، استفاده شده است (جدول ۸). در این جدول مثالی از دو توده سنگ مختلف ارائه شده که مقدار RMR پایه یکسان دارند ولی واضح است که حفاری در توده سنگ شماره ۲ بسیار آسان‌تر است. با استفاده از مقدار هر یک از پارامترهای ورودی سیستم RMR در این جدول و به کمک نمودارهای شکل ۶ امتیاز هر پارامتر RMR_{TBM} محاسبه و در جدول ۸ درج شده است. ملاحظه می‌شود که این دو توده سنگ با وجود مقدار RMR یکسان، RMR_{TBM} و در نتیجه شرایط حفری کاملاً متفاوتی دارند. توده سنگ شماره ۱ با $RMR_{TBM} = ۸۳/۲$ در رده حفری (I) و با قابلیت حفری سخت پیش‌بینی می‌شود، درحالی‌که توده سنگ شماره ۲ با $RMR_{TBM} = ۴۷/۲$ در رده حفری (III) و با قابلیت حفری خوب پیش‌بینی

استفاده شود، با این حال محققان به استفاده ترکیبی از مدل‌ها برای اطمینان بیشتر در تخمین نهایی عملکرد ماشین TBM در سنگ تأکید دارند.

جدول ۸- مقایسه دو توده‌سنگ مختلف با مقدار RMR پایه یکسان و RMR_{TBM} متفاوت

RMR input parameters	Rock mass properties		Rating of Basic RMR		Rating of RMR _{TBM}	
	Rock mass 1	Rock mass 2	Rock mass 1	Rock mass 2	Rock mass 1	Rock mass 2
Uniaxial compressive strength (MPa)	۱۸۰	۷۰	۱۲	۸	۳۲/۶	۱۶
RQD (%)	۹۰	۵۰	۱۸	۱۰	۲۷	۱۵
Spacing of discontinuities (m)	۱	۰/۵	۱۴	۱۰	۲۰/۳	۱۲
Condition of discontinuities	Slightly rough and moderately to highly weathered wall rock surface separation <1 mm	Rough and slightly weathered wall rock surface separation <1 mm	۲۰	۲۵	۳/۳	۴/۲
Groundwater condition	Dripping	Completely dry	۴	۱۵	-	-
SUM			۶۸	۶۸	۸۳/۲	۴۷/۲
RMR _{TBM} Class					I	III
FPI ranges (kN/cutter/mm/rev)					> ۷۰	۲۰ - ۴۰
Boreability class					B-0	B-II
Rock Mass Boreability					Tough	Good-Fair



شکل ۷- رابطه RMR_{TBM} و Basic RMR با شاخص FPI در پایگاه داده مورد مطالعه

ورودی آن ارائه نشده است. در الگوریتم *Random Forest* شاخصی معرفی شده است که از طریق آن می‌توان دریافت که مدل به کدام متغیرها وزن بیشتری داده تا پیش‌بینی صورت گیرد. این شاخص به نام شاخص اهمیت متغیر یا *Variable Importance* می‌تواند برحسب درصد در مدل محاسبه شود. از این شاخص برای تعیین امتیاز پارامترهای ورودی RMR بهینه‌ای که برای تخمین عملکرد ماشین TBM در سنگ

۸- نتیجه‌گیری

با وجود این که در بین انواع سیستم‌های طبقه‌بندی توده‌سنگ، سیستم RMR بهترین همبستگی را با عملکرد ماشین نشان می‌دهد ولی از آن‌جا که این طبقه‌بندی برای تعیین شرایط پایداری توده‌سنگ در تونل‌ها و طراحی سیستم نگهدارنده توسعه یافته است، تاکنون رابطه‌ای با دقت بالا برای تخمین عملکرد ماشین با استفاده از این سیستم یا پارامترهای

یک چارچوب جدید برای پیش‌بینی عملکرد TBM در سنگ‌های سخت با قابلیت تعمیم‌پذیری بالاتر ارائه دهد. ولی باید در نظر داشت که مدل ارائه شده در این مطالعه، یک مدل تجربی است و نه یک مدل مکانیکی-تئوریک. بنابراین دقت آن در محدوده داده‌های آموزش دیده بیشتر است و برای شرایط خارج از این محدوده باید با احتیاط به کار رود. در توسعه این مدل به دلیل اطمینان از کیفیت داده‌ها، مقاطعی که با مشکلات اجرایی عمده (توقف طولانی مدت، خرابی ماشین، مداخلات انسانی) یا آبدی قابل توجه مواجه بودند، از تحلیل نهایی حذف شدند. بنابراین مدل حاضر ممکن است برای پیش‌بینی عملکرد در چنین شرایط غیرایده‌آلی کارایی کمتری داشته باشد. توزیع نابرابر داده‌ها در برخی رده‌های سنگی نیز ممکن است دقت پیش‌بینی مدل را برای رده‌های کم‌نمونه مانند سنگ‌های متامورف و ماسه‌سنگ‌ها کاهش دهد. حذف پارامترهایی مانند وضعیت آب زیرزمینی و بخصوص پارامتر تعدیل جهت درزه‌داری، اگرچه برای هدف این مطالعه توجیه شده، اما به‌طور ذاتی باعث می‌شود مدل همه پیچیدگی‌های تعامل سنگ و ماشین را در نظر نگیرد. در نهایت توصیه شود که این مدل به‌عنوان یک ابزار کمکی در کنار روش‌های دیگر و تحلیل‌های مهندسی برای تصمیم‌گیری استفاده شود.

توسعه داده شده است، استفاده شد. در طبقه‌بندی RMR_{TBM} به هر یک از پارامترهای UCS ، RQD ، J_s و J_c بر اساس جدول و نمودارهای مربوطه امتیازی تعلق می‌گیرد و مجموع امتیازات این پارامترها به‌صورت صفر تا صد مقدار RMR_{TBM} را تعیین می‌کند. سپس رده RMR_{TBM} تعیین شده و با توجه به جدول ارائه شده، محدوده FPI توده‌سنگ، رده حفزپذیری سنگ، توصیف حفزپذیری و شرایط پایداری توده‌سنگ مسیر تونل پیش‌بینی می‌شود. همبستگی رابطه RMR_{TBM} باشاخص FPI نسبت به رابطه $Basic RMR$ با FPI بسیار بالاتر است و نشان می‌دهد RMR_{TBM} به‌خوبی می‌تواند برای تخمین عملکرد ماشین در سنگ استفاده شود.

این تحقیق از الگوریتم‌های پیشرفته یادگیری ماشین مانند $Random Forest$ و $Bagging$ برای تعیین اهمیت متغیرها و بهینه‌سازی وزن پارامترها استفاده کرده است. در مطالعات قبلی مانند $Salimi et al. (2019)$ از روش‌های سنتی‌تر مانند تحلیل مؤلفه‌های اصلی (PCA) و رگرسیون خطی چندمتغیره استفاده شده بود، همچنین سیستم RMR بدون تغییر در وزن‌دهی یا ساختار برای تخمین عملکرد TBM به کار رفته بود. اگرچه پارامتر RTC قبلاً توسط $Salimi et al.$ به کار رفته، اما در این تحقیق به‌روزرسانی و یکپارچه‌سازی بهتری با سایر پارامترهای RMR صورت گرفته و تأثیر آن در مدل‌سازی با دقت بیشتری کمی شده است. سیستم RMR_{TBM} می‌تواند

۹- منابع

- [1] Salimi, A. (2021). "Investigation and Evaluation of Rock Mass Characteristics for Development of New TBM Performance Prediction Model in Hard Rock Conditions". Ph.D. Thesis, Stuttgart University, Germany.
- [2] Sapigni, M., Berti, M., Behtaz, E., Busillo, A., Cardone, G. (2002). "TBM performance estimation using rock mass classification". Int. J. Rock Mech. Min. Sci., 39, 771-788.
- [3] Hassanpour, J., Rostami, J., Zhao, J. (2011). "A new hard rock TBM performance prediction model for project planning". J. Tunnel. Under. Space Technol., 26, 595-603.
- [4] Salimi, A., Rostami, J., Moormann, C. (2019). "Application of rock mass classification systems for performance estimation of rock TBMs using regression tree and artificial intelligence algorithms". Tunnel Under. Space Technol., 92, 103046.
- [5] Bieniawski, Z.T., Celada, B., Galera, J.M., Alvarez, M. (2006). Rock Mass Excavability (RME) Indicator: New Way to Selecting the Optimum Tunnel Construction Method. ITA World Tunnelling Congress, Seoul, South Korea .

- [6] Rostami, J. (1997). Development of a force estimation model for rock fragmentation with disc cutters through theoretical modelling and physical measurement of crushed zone pressure. Ph.D. Thesis, Colorado School of Mines, Golden, Colorado, USA .
- [7] Khademi Hamidi, J., Shahriar, K., Rezai, B., & Rostami, J. (2010). Performance prediction of hard rock TBM using Rock Mass Rating (RMR) system. *Tunnel Under. Space Technol.*, 25(4), 333–345.
- [8] Gholami, M., Shahriar, K., Sharifzadeh, M., Hamidi, J.K. (2012). A comparison of artificial neural network and multiple regression analysis in TBM performance prediction. *ISRM Regional Symposium-7th Asian Rock Mechanics Symposium: International Society for Rock Mechanics* .
- [9] Gong, Q., Lu, J., Xu, H., Chen, Z., Zhou, X., Han, B. (2021). A modified rock mass classification system for TBM tunnels and tunneling based on the HC method of China. *Int. J. Rock Mech. Min. Sci.*, 137, 104551.
- [10] Jain, P. (2014). Evaluation of engineering geological and geotechnical properties for the performance of a tunnel boring machine in Deccan traps rocks-a case study From Mumbai, India. Ph.D. thesis, Indian Institute of Technology Bombay, India (Unpublished).
- [11] Hassanpour, J., Ghaedi Vanani, A.A., Rostami, J., Cheshomi, A. (2016). Evaluation of common TBM performance prediction models based on field data from the second lot of Zagros water conveyance tunnel (ZWCT2). *Tunnel Under. Space Technol.*, 52, 147-156.
- [12] Hassanpour, J., Rostami, J., Khamehchiyan, M., Bruland, A. (2009). Developing new equations for TBM performance prediction in carbonate-argillaceous rocks: a case history of Nowsood water conveyance tunnel. *Geomech. Geoeng. Int. J.*, 4, 287-297.
- [13] Hassanpour, J., Rostami, J., Khamehchiyan, M., Bruland, A., Tavakoli, H. (2010). TBM performance analysis in pyroclastic rocks: a case history of Karaj water conveyance tunnel. *Rock Mech. Rock Eng.*, 43(4), 427-445.
- [14] SCE Company. (2004). Geological and Engineering Geological Report for Ghomrood Water Conveyance Tunnel Project (Lots 3 & 4), Unpublished report.
- [15] SCE Company. (2006). Geological and Engineering Geological Report for Karaj Water Conveyance Tunnel Project (Lot1), Unpublished report.
- [16] Pourhashemi, S. M., Ahangari, K., Hassanpour, J., Eftekhari, M. (2021). TBM performance analysis in very strong and massive rocks; case study: Kerman water conveyance tunnel project, Iran. *Geomech. Geoeng. Int. J.*, <https://doi.org/10.1080.17486025.2021.1912410>.
- [17] Fatemi, S.A. (2016). Prediction of TBM penetration rate by rock mass classification system. Ph.D. Thesis, Tarbiat Modares University, Tehran, Iran.
- [۱۸] حسن پور، ج.، رستمی، ج.، خامه‌چیان، م. (۱۴۰۲). زمین‌شناسی مهندسی و تونل‌سازی: ارزیابی عملکرد TBM در تونل‌های سنگی، انتشارات دانشگاه تهران، ۴۷۹ صفحه.
- [19] Farrokh, E., Rostami, J., Laughton, C. (2012). Study of various models for estimation of penetration rate of hard rock TBMs. *Tunnell. Undergr. Space Technol* 30, 110-123.
- [20] Fatemi, S.A. (2016). Prediction of TBM penetration rate by rock mass classification system. Ph.D.

Thesis, Tarbiat Modares University, Tehran, Iran. Unpublished.



Modification of RMR Rock Mass Classification System for TBM Performance Prediction in Various Rock Types

Ameneh Dardashti^{1*}; Jamal Rostami²; Jafar Hassanpour³; Rasoul Ajalloeian⁴

1- Ph.D. in engineering geology, The University of Isfahan, Iran.

2- Professor of rock mechanics, Earth Mechanics Institute, Colorado School of Mines, USA.

3- Associate Professor of engineering geology, School of Geology, The University of Tehran, Iran.

4- Professor of engineering geology, The University of Isfahan, Iran.

Received: 19. August. 2025 Accepted: 22. September. 2025

(*Corresponding author: am.dardashti@gmail.com)

Keywords

TBM Performance
RMR Classification System
RMR_{TBM} System
Machine Learning

Final English Extended Abstract

Since various rock mass classification systems are the most commonly used methods in many rock engineering projects, they serve as a suitable approach for estimating TBM performance due to their global acceptance and the availability of effective parameters. Comparing the most common rock mass classification systems, the RMR classification system demonstrates a better correlation with TBM penetration rate, which is attributed to its incorporation of uniaxial compressive strength (UCS) of rock as an input parameter. As the RMR classification system was developed for analyzing rock mass stability in tunnels and designing support systems, its input parameters ratings have been accordingly structured. It appears that by modifying the rating values of the input parameters and adjusting the internal weighting of each parameter, an optimized RMR can be achieved that aligns with the objective of this study—predicting TBM performance in hard rock. The objective of this study is to develop new relationships for estimating TBM performance in various rock types based on the input parameters of the RMR system and, ultimately, to adjust the RMR system to establish a new model for predicting TBM performance in rock. To this end, data from 10 tunneling projects under different geological conditions were collected in a database. Finally, using artificial intelligence algorithms, the RMR_{TBM} classification is proposed with the aim of predicting TBM performance in hard rock. In RMR_{TBM}, each input parameter is assigned a rating based on the relevant tables and charts, and the sum of these ratings, on a scale of 0 to 100, determines the RMR_{TBM} value. The corresponding RMR_{TBM} category is then identified, and based on the provided table, the rock mass FPI range, excavability class, excavability description, and tunnel stability conditions are predicted. This model can be useful during the design and planning stages of tunneling projects.

Summary

Rock mass classification systems are widely used to estimate TBM performance. Among them, the RMR system shows better correlation with TBM penetration rate, largely due to its inclusion of uniaxial compressive strength (UCS). This study aims to modify the RMR system specifically for TBM performance prediction in hard rock. Data from 10 tunneling projects were compiled, and artificial intelligence algorithms were used to develop a new classification system called RMR_{TBM}. In RMR_{TBM}, input parameters are assigned new ratings and internal weightings. The total score (0-100) determines the RMR_{TBM} class, which then predicts the FPI range, excavability, and tunnel stability conditions. This proposed model is intended to aid in the design and planning stages of tunneling projects.

Introduction



Despite the widespread use of Tunnel Boring Machines (TBMs), accurately predicting their performance, especially in complex geological conditions, remains challenging. Existing prediction models are limited as they fail to comprehensively account for all influential factors, including rock mass properties and machine specifications. Rock mass classification systems, particularly RMR, Q, and GSI, are commonly used for TBM performance estimation due to their simplicity and availability. Among these, the RMR system shows a stronger correlation with TBM penetration rate, largely because it incorporates uniaxial compressive strength (UCS). Key geological parameters affecting TBM performance, such as rock strength and joint conditions, align with those in the RMR system. Since the RMR rock classification system is an early assessment in tunneling projects with readily available parameters, modifying it could significantly aid in predicting TBM performance. However, the RMR system was designed for tunnel stability, not for predicting excavability. This study aims to adapt and optimize the RMR system specifically for predicting TBM performance in hard rock. Using machine learning regression analyses, including decision tree and Random Forest algorithms, the research will modify parameter ratings and weightings. The ultimate goal is to propose a new, optimized classification model, termed RMR_{TBM} , for more accurate TBM performance forecasting.

Methodology and Approaches

Most existing AI models for predicting TBM performance are based on supervised learning, where models are trained on input-output data. This study predicts machine performance (FPI) using RMR input parameters (UCS, RQD, J_s , J_c) and rock type (RTC). Since FPI is continuous, regression algorithms are suitable. Classic regression, along with modern methods like Stepwise, Lasso, and Ridge Regression, are implemented. The data is split into training and test datasets to build and validate the models, aiming for a generalizable model that performs well on new, unseen data. By adjusting the ratings and internal weighting of RMR parameters, an optimized RMR system for accurate TBM performance prediction can be developed. This study employs Random Forest regression's Variable Importance (VI) in Python's Scikit-Learn to identify key parameters and determine their weights.

Results and Conclusions

Although the RMR system exhibits the best correlation with machine performance among various rock mass classification systems, since this classification was developed to determine the stability conditions of rock masses in tunnels and to design support systems, no highly accurate relationship has yet been presented to estimate machine performance using this system or its input parameters.

In the Random Forest algorithm, an index has been introduced that indicates which variables the model weighted more heavily in making predictions. This index, known as the Variable Importance index, can be calculated as a percentage within the model. This index was used to determine the optimal ratings of the input parameters for a developed RMR system designed to estimate TBM performance in rock. Each of the parameters UCS, RQD, J_s , and J_c is assigned a score based on relevant tables and charts, and the sum of these scores, ranging from zero to one hundred, determines the RMR_{TBM} value. Then, the determined RMR_{TBM} class is used, according to the provided table, to predict the range of the FPI, the rock excavability class, excavability description, and the stability conditions of the rock mass along the tunnel. The correlation between the RMR_{TBM} and FPI index is significantly higher than that between the Basic RMR and FPI, indicating that RMR_{TBM} can be effectively used to estimate machine performance in various rock types.
