

پیش‌بینی نرخ نفوذ TBM در انواع سنگ با استفاده از پارامترهای سیستم طبقه‌بندی RMR به روش آنالیز رگرسیون مبتنی بر یادگیری ماشین

مقاله پژوهشی

آمنه دردشتی^۱؛ رسول اجل لوثیان^{۲*}؛ جمال رستمی^۳؛ جعفر حسن پور^۴؛ علیرضا سلیمی^۵

۱- دانشجوی دکتری زمین‌شناسی مهندسی؛ دانشکده علوم، دانشگاه اصفهان، am.dardashti@gmail.com

۲- استاد زمین‌شناسی مهندسی؛ دانشکده علوم، دانشگاه اصفهان، rasajl@sci.ui.ac.ir

۳- استاد مکانیک سنگ؛ دانشکده معدن، Colorado School of Mines، rostami@mines.edu

۴- دانشیار زمین‌شناسی مهندسی؛ دانشکده علوم، دانشگاه تهران، hassanpour@ut.ac.ir

۵- دکترای مهندسی ژئوتکنیک/تونل زنی و مهندسی سنگ؛ ZETCON Ingenieur GmbH، برلین، آلمان، ali.r.salimi83@gmail.com

دریافت دست‌نوشته: ۱۴۰۲/۰۴/۳۰؛ پذیرش دست‌نوشته: ۱۴۰۲/۰۹/۰۳

شماره صفحات: ۲۳۳ تا ۲۵۷

شناسه دیجیتال (DOI): 10.22044/tuse.2023.13396.1480

واژگان کلیدی	چکیده
عملکرد دستگاه TBM سیستم طبقه بندی توده سنگ RMR آنالیز رگرسیون یادگیری ماشین	علیرغم استفاده گسترده از ماشین‌های حفر تمام مقطع تونل در صنعت تونل‌سازی، برآورد دقیق عملکرد آنها به ویژه در شرایط پیچیده زمین‌شناسی هنوز هم می‌تواند چالش‌برانگیز باشد. هدف از این مطالعه، بررسی امکان استفاده از سیستم‌های طبقه‌بندی توده‌سنگ معمول برای تخمین عملکرد ماشین حفر تونل در انواع مختلف سنگ، با استفاده از آنالیز رگرسیون مبتنی بر الگوریتم‌های یادگیری ماشین است. بدین منظور داده‌های واقعی عملکرد ماشین و همچنین داده‌های زمین‌شناسی از ۱۰ پروژه تونل‌سازی در یک پایگاه داده جامع با ۵۲۳ مقطع تونل در انواع مختلف سنگ جمع‌آوری و برای توسعه روابط جدید برای تخمین اندیس نفوذ صحرائی <i>FPI</i> بر اساس پارامترهای ورودی سیستم طبقه‌بندی <i>RMR</i> استفاده شد. از آنجا که انواع مختلف سنگ‌ها، بافت، ساختار و ترکیب کانی‌شناسی متفاوتی دارند و به نیروهای برشی ماشین پاسخ متفاوتی می‌دهند، ترکیب اثرات نوع سنگ در مدل‌های پیش‌بینی عملکرد می‌تواند دقت تخمین‌ها را بهبود بخشد. این روابط به ویژه در مرحله طراحی و برنامه‌ریزی یک پروژه تونل‌سازی، می‌توانند مفید واقع شوند.

۱- مقدمه
و هزینه‌های اجرای پروژه را با دقت مناسبی تخمین زد. بدلیل پیچیدگی اندرکنش میان توده‌سنگ و ماشین، پیش‌بینی عملکرد ماشین به صورت تئوری بسیار سخت است. مدل‌های پیش‌بینی نرخ نفوذ و نرخ پیشروی ماشین شامل دو گروه مدل‌های تئوری و مدل‌های تجربی هستند. مدل‌های تئوری براساس بررسی مراحل خرد شدن سنگ در آزمایشگاه توسعه

از آنجا که استفاده از *TBM* ها مستلزم سرمایه گذاری‌های عمده همراه با قبول سطوح بالای ریسک زمین‌شناسی است، لازم است پس از تعیین مشخصات زمین‌شناسی مسیر تونل و انتخاب ماشین مناسب، پیش‌بینی عملکرد ماشین در شرایط زمین‌شناسی پیش‌بینی شده صورت گیرد، تا بتوان زمان‌بندی

نزدیک‌تر است. بر اساس نتایج مطالعات، همبستگی بالایی بین نرخ‌های پیش‌بینی شده و مقادیر واقعی عملکرد ماشین وجود دارد (He, et al., 2022). طبیعت انعطاف پذیر تکنیک‌های ML آنها را به ابزارهای قدرتمندی در ارزیابی و حل مسائل مهندسی بخصوص مسائل پیچیده و غیرخطی تبدیل کرده است.

از طرفی تلاش‌های زیادی توسط محققان مختلف برای پیش‌بینی عملکرد ماشین 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 که به دلیل سادگی، پذیرش جهانی و در دسترس بودن پارامترهای موثر، روش مناسبی جهت تخمین عملکرد ماشین هستند. 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 طبقه‌بندی است (Salimi, 2021). این موضوع در مطالعات قبلی از جمله حسن‌پور و همکاران (۲۰۰۹، ۲۰۱۱) و سلیمی و همکاران (۲۰۱۶) نیز بیان شده است. بر اساس تحقیقات رستمی (۲۰۱۶) 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 (Rostami, 2016). 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 تونل‌سازی، پارامترهای ورودی سیستم طبقه‌بندی RMR موجود است. البته باید توجه داشت که سیستم RMR نیز

یافته‌اند، ولی از آن جایی که تعمیم مراحل خرد شدن سنگ در آزمایشگاه بدلیل پیچیدگی اندرکنش میان توده‌سنگ و ماشین با محدودیت‌هایی روبروست، مدل‌هایی که تاکنون ارائه شده‌اند، نتوانسته‌اند همه عوامل مؤثر بر عملکرد دستگاه را در نظر بگیرند. مدل‌های تجربی براساس داده‌های واقعی به‌دست‌آمده از عملکرد ماشین در شرایط مختلف زمین‌شناسی به‌دست‌آمده‌اند و مزیت آنها این است که به‌طور طبیعی تمام تأثیرات ناشی از زمین و ماشین را در نظر می‌گیرند، اما با توسعه‌ی ماشین‌های مختلف و با قابلیت‌های متفاوت استفاده از این مدل‌ها با محدودیت‌هایی همراه است. ضمن این‌که چون مدل‌های ارائه‌شده برای شرایط خاص زمین توسعه یافته‌اند، قابل تعمیم به تمام شرایط زمین‌شناسی نیستند (حسن‌پور و همکاران، ۱۴۰۲). در حال حاضر سه مدل (Rostami, CSM (1997;2013)، مدل (Bruland, 1998) NTNU) و مدل‌های شاخص نفوذ صحرائی (FPI) (Nelson, et al., 1983) شناخته‌شده‌ترین مدل‌های پیش‌بینی عملکرد TBM در سراسر جهان هستند. در سال‌های اخیر مدل‌سازی‌های کامپیوتری و تکنیک‌های هوش مصنوعی (*Artificial Intelligence (AI)*) نیز توسط برخی محققان جهت توسعه مدل‌های تجربی پیش‌بینی عملکرد ماشین به‌کارگرفته شده‌اند، از جمله گریم و همکاران (۲۰۰۰)، یایگز و کاراهان (۲۰۱۱)، جاهد آرمغانی و همکاران (۲۰۱۷)، کوپپالیپور و همکاران (۲۰۱۹)، سلیمی و همکاران (۲۰۲۰).

در این سال‌ها استفاده از روش‌های هوش مصنوعی از جمله رویکرد یادگیری ماشین (*Machine Learning (ML)*) در پروژه‌های مهندسی بسیار مورد توجه قرار گرفته است. در مواردی که رابطه‌ی مشخصی میان پارامترهای ورودی و خروجی وجود نداشته و ارتباط میان آنها توسط روش‌های مرسوم قابل شناسایی نیست، استفاده از روش‌های هوش مصنوعی به سبب عدم نیاز به فرمول بندی، پویا بودن و همچنین امکان لحاظ کردن تأثیر پارامترهای مؤثرتر، ایده‌ی خوبی برای تخمین و مدل‌سازی به شمار می‌رود. طی تحقیقات اخیر و با مقایسه مقادیر پیش‌بینی شده با استفاده از یادگیری ماشین و رگرسیون چندمتغیره غیرخطی با مقادیر واقعی نرخ نفوذ، این نتیجه حاصل شده است که نتایج یادگیری ماشین نسبت به رگرسیون غیرخطی به واقعیت

رگرسیون مبتنی بر الگوریتم‌های یادگیری ماشین می‌باشد. روابط جدید می‌تواند به تخمین عملکرد ماشین در شرایط مختلف زمین‌شناسی و با در نظر گرفتن پارامترهای اصلی و موثر منجر شود.

۲- عملکرد TBM و طبقه بندی توده‌سنگ

تاکنون تلاش‌های زیادی از سوی محققان برای بررسی ارتباط بین عملکرد ماشین TBM با سیستم‌های طبقه‌بندی توده‌سنگ صورت گرفته است. جدول ۱، برخی روابط تجربی پیش‌بینی عملکرد TBM براساس سیستم‌های طبقه‌بندی توده‌سنگ را که توسط محققین ارائه شده است، نشان می‌دهد.

جدول ۱- روابط تجربی پیش‌بینی عملکرد TBM بر اساس سیستم‌های طبقه‌بندی توده‌سنگ

روابط	نام محقق
$PR = -0.0059 RSR + 1.59$	Cassinelli, et al., 1982
$PR = UCS^{-0.437} - 0.047 RSR + 3.15$	Innaurato, et al., 1991
$PR = 2.7 - 0.8 \log(Q)$	Mitani, et al., 1987
Rock Mass index (RMI)	Palmström, 1995
IMS classification	Grandori, et al., 1995
$PR = 5 Q_{TBM}^{-0.2}$	Barton, 2000
$Q_{TBM} = \frac{RQD_0}{J_n} \cdot \frac{J_r}{J_a} \cdot \frac{J_w}{SRF} \cdot \frac{SIGMA}{F^{10}/20^9} \cdot \frac{20}{CLI} \cdot \frac{q}{20} \cdot \frac{\sigma_\theta}{5}$	
Quadratic relationship between PR (m/hr) & RMR	Sapigni, et al., 2002
$SP = 250 UCS_{cm}^{-0.66}$ $UCS_{cm} = UCS \cdot \exp(RMR-100/18)$	Ribacchi & Lembo-Fazio, 2005
Rock Mass Excavability (RME) (five basic input parameters) $ARA = 0.422 RME_{07} - 11.61$	Bieniawski, et al., 2007
Rock Mass Rating (RMR) Parameters $FPI = 4.785 + 0.107 UCS + 0.09 RQD - 7.145 J_s + 0.079 J_c + 1.04 \log(\alpha)$ $FPI = 4.161 + 0.091 UCS + 0.077 RQD + 0.117 J_c + 1.077 \log(\alpha)$	Khademi, et al., 2010
$FPI = 0.053 BRMR^2 - 4.205 BRMR + 92.068$	Hassanpour, et al., 2011
$FPI = 4.619 \exp(0.023 GSI)$	Hassanpour, et al., 2011
$FPI = 15.309 Q^{0.304}$	Hassanpour, et al., 2011
$PR = 5/8 [(Fn-14) + (0.0132 - 0.00009 UCS) (100-GSI)^2]$	Benato & Oreste, 2015

RSR: امتیاز ساختار سنگ، UCS: مقاومت فشاری تک محوره سنگ، Q: طبقه‌بندی توده‌سنگ بارتن، RMI: شاخص توده‌سنگ، Q_{TBM} : طبقه‌بندی Q دستگاه حفاری بارتن، RQD_0 : RQD تفسیر شده در جهت تونل، J_n : تعداد دسته درزه، J_r : عدد زبری درزه، J_a : عدد التراسیون درزه، J_w : فاکتور کاهش آب درزه، SRF: فاکتور کاهش تنش، SIGMA: مقاومت توده‌سنگ، F: نیروی دیسک کاتر نرمالیزه شده، CLI: شاخص عمر دیسک کاتر، q: درصد کوآرتز، σ_θ : تنش دو محوری در جبهه تونل، RMR: طبقه‌بندی امتیاز توده‌سنگ، UCS_{cm} : مقاومت فشاری توده‌سنگ، RME: شاخص قابلیت حفاری توده‌سنگ، GSI: شاخص مقاومت زمین‌شناسی، BRMR: RMR پایه بدون در نظر گرفتن امتیاز جهت درزه، ARA: متوسط نرخ پیشروی، FPI: شاخص نفوذ صحرایی، PR: نرخ نفوذ، SP: نفوذ ویژه (معکوس FPI).

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

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 حفاری توده‌سنگ و تخمین عملکرد ماشین TBM باشد، مسلماً بایستی تغییراتی در پارامترها و وزن‌دهی آن‌ها صورت گیرد (Salimi, 2021). هدف از این مطالعه، بررسی امکان استفاده از پارامترهای سیستم طبقه‌بندی توده‌سنگ RMR برای توسعه روابط تخمین عملکرد ماشین با استفاده از آنالیز

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،

نشان می‌دهد. ساپینی و همکاران (۲۰۰۲) 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 و یک رابطه درجه دوم بین نرخ نفوذ (m/hr) و سیستم RMR به دست آورد که در مطالعات حسن‌پور و همکاران (۲۰۱۱) 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 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 (Sapigni, et al., 2002)

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. 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 (Rostami, 1997). علاوه بر این، پارامتر زمان ایستایی تونل باید از یک نمودار RMR که توسط بنیواسکی برای تونل‌سازی به روش سنتی چالزنی و آتشباری ارائه شده، تخمین زده شود، و ابتدا بایستی $RMR_{D\&B}$ توسط رابطه آلبر (۱۹۹۶) به RMR_{TBM} تبدیل و همین امر باعث بروز عدم قطعیت‌هایی در نتایج مدل می‌شود. خادمی و همکاران (۲۰۱۰) 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 (Gw) همبستگی اندکی با FPI نشان داد و از تحلیل‌ها حذف شدند. 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 Jc ، Js 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

Ruparel در بمبئی هندوستان (Jain, et al., 2014) و تونل انتقال آب زاگرس قطعه ۲ (Hassanpour, et al., 2009) 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. جدول ۲، خصوصیات زمین‌شناسی و سنگ‌شناسی تونل‌های مورد مطالعه را نشان می‌دهد. 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 ساینده‌گی اندک 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 ۳، خصوصیات ماشین‌های به‌کار 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 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.

(Salimi, et al., 2019 ; Gholami, et al., 2012) مطالعات حسن‌پور و همکاران (۲۰۱۱) و سلیمی و همکاران (۲۰۱۹) نشان‌دهنده وجود ارتباط خوبی میان عملکرد ماشین و سیستم طبقه‌بندی توده‌سنگ *RMR* است. بنابراین، سیستم *RMR* و پارامترهای ورودی آن به عنوان اساس و پایه آنالیزها در مطالعه حاضر خواهد بود. در این مطالعه سعی بر آن است که با استفاده از پارامترهای سیستم طبقه‌بندی توده‌سنگ *RMR* که در تمامی پروژه‌های تونل‌سازی مورد مطالعه اندازه‌گیری شده است، روابطی به منظور پیش‌بینی عملکرد ماشین در شرایط متفاوت زمین‌شناسی به کمک الگوریتم‌های یادگیری ماشین ارائه گردد.

۳- پروژه‌های مورد مطالعه و جمع‌آوری داده‌ها

به منظور توسعه روابط تجربی برای تخمین عملکرد ماشین حفر تونل در شرایط مختلف زمین‌شناسی با استفاده از پارامترهای سیستم طبقه‌بندی توده‌سنگ *RMR*، داده‌های حفاری از پروژه‌های مختلف تونل‌سازی با شرایط توده‌سنگ متفاوت از گروه‌های تحقیقاتی مرتبط اخذ و در یک پایگاه داده گردآوری شده است. در این پایگاه داده اطلاعات مختلفی در مورد پارامترهای راهبری و عملکرد واقعی ماشین و خصوصیات زمین‌شناسی مهندسی توده‌سنگ گردآوری شده است. ویژگی‌های اصلی ۱۰ پروژه تونل‌سازی در سنگ که به روش مکانیزه حفاری و داده‌های صحرائی آنها در پایگاه داده جمع‌آوری شده است، در **جدول ۲** و **جدول ۳**، خلاصه شده است. اطلاعات این پایگاه داده شامل ۵۲۳ مقطع تونل است که این مقاطع به‌طور معمول طولی بین ۵ تا ۲۰ متر دارند و به حفاری یک شیفت کاری شامل چندین سیکل حفاری، مربوط بوده‌اند و اطلاعات قابل اعتمادی از شرایط زمین و عملکرد ماشین در این مقاطع در دسترس بوده است. در این مقاطع اطلاعات زمین‌شناسی و داده‌های راهبری ماشین دارای نوسانات زیادی نبوده‌اند و عملکرد ماشین با مشکل خاص و ناشناخته‌ای مواجه نبوده 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*

پیش‌بینی نرخ نفوذ TBM در انواع سنگ با استفاده از ...، آمنة دردشتی و ...، ص ۲۳۳-۲۵۷

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.

جدول ۲- ویژگی‌های زمین‌شناسی و سنگ‌شناسی تونل‌های مورد مطالعه

ردیف	پروژه	پهنه زمین‌شناسی	سنگ‌شناسی	ساختار کلی توده‌سنگ‌ها	طول کل تونل (km)	طول تونل استفاده شده در توسعه مدل‌ها (km)	حداکثر روبراه (m)
۱	قطعه ۴ تونل انتقال آب Yinsong (چین)	-	گرانیت (۴۴۳ 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 پالئوزوئیک 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 انوسن پایینی	بازالت متراکم، بازالت پورفیریک، بازالت آمیگدالوئیدی، سنگ‌های آذرآواری (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، گورپی 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 آذرآواری سازند کرج	انواع توف، توفیت، آگلومرا همراه با توده‌های نفوذی مستحکم (دیوریت، مونزودوریت 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)	کمر بند 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 شستوز و متورق همراه با پهنه‌های گسله	۱۸	۱۸	۷۰۰
۹	قطعه جنوبی تونل انتقال آب کرمان (ایران)	کمر بند ماگماتیک سهند - بزمان (زون ارومیه-دختر) سنگ‌های آذرآواری و آتشفشانی انوسن 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)	کمر بند دگرگونی سنندج - سیرجان سنگ‌های رسوبی و آذرین انوسن تا ژوراسیک	تناوبی از شیل آرژیلیتی و ماسه‌سنگ دگرگونی، شیست و آمفیبولیت	-	۱۰	۸	-

جدول ۳- 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		تونل انتقال آب	تونل انتقال آب	تونل انتقال آب	تونل انتقال آب	TBM type	
					Vakola- Vent hole stretch	Maroshi- Vent hole stretch						
	Double shield	Double shield	Double shield	Double shield	Double shield	Double shield	Double shield	Double shield	Double shield	Double shield	Double shield	Double shield
	۴/۴۹۵	۵/۲۷۵	۴/۵۲۵	۴/۶۶۵	۶/۷۲	۳/۶	۳/۶	۱۰/۵	۵/۶۷	۸/۰۲	۷/۹۳	TBM diameter (m)
	۳۵	۳۷	۳۵	۳۱	۴۲	۳۱	۳۱	۶۸	۳۷	۵۰	۵۶	Number of cutters
	۱۷"	۱۷"	۱۷"	۱۷"	۱۷"	۱۷"	۱۷"	۱۷"	۱۹"	۱۹"	۱۷", ۱۹"	Cutter diameter (inch)
	۷۵	۷۲	۷۵	۹۰	۹۰	۶۲	۶۲	۹۰	۷۸	۸۲/۲	۷۱	Average cutter spacing (mm)
	۲۰,۰۰۰	۲۰,۰۰۰	۱۸,۰۰۰	۱۶,۹۱۳	۲۸,۱۳۴	۳,۸۲۸	۳,۸۲۸	۲۷,۱۰۱	۱۱,۰۰۰	۲۷,۴۸۸	۲۳,۲۶۰	Maximum thrust force (kN)
	۸۰۲	۱۲۰۰	۸۰۲	۱۰۲۹	۴۴۵۰	۱۸۵	۲۲۵	۹۸۶۰	۲۹۱۶	۷۶۶۱	۸۴۱۰	Rated torque (kN.m)
	۰ ~ ۱۲	۰ ~ ۱۰/۹	۰ ~ ۱۰	۰ ~ ۱۱	۰ ~ ۹	۰ ~ ۱۲	۰ ~ ۱۴	۰ ~ ۵/۰۷	۰ ~ ۹	۰ ~ ۷/۳	۰ ~ ۷/۶	Rotational speed (RPM)

اندازه، نوع و بار تیغه برشی محاسبه و به دلیل 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، قابل اندازه‌گیری بودن و قابلیت هم‌مقیاس شدن در ماشین‌های با سایزهای مختلف انتخاب شده است.

همانطور که اشاره شد، طبقه‌بندی‌های توده‌سنگ عموماً برای برآورد رفتار توده‌سنگ تدوین شده و کاربرد اصلی آن‌ها برای تعیین نوع نگهدارنده در تونل و برآورد بار وارده به سیستم نگهدارنده است و هیچ‌یک برای کاربرد در حفاری مکانیزه مناسب نیستند. ابداع طبقه‌بندی‌هایی با پارامترهای جدید یا با ضرایب متفاوت، برای کاربرد در حفاری مکانیزه، ایده‌ای نو است و عمده کارهای تحقیقاتی و مطالعات موردی انجام‌شده، در دهه‌های اخیر و با توجه به ناکارآمدی طبقه‌بندی‌های توده‌سنگ در این زمینه بوده است. از آنجا که سیستم‌های طبقه‌بندی توده‌سنگ برای تخمین سیستم نگهدارنده در فضاهای زیرزمینی پیشنهاد شده‌اند، شامل برخی پارامترهایی هستند که برای تخمین خواص حفارپذیری توده‌سنگ نیاز نیست مانند جهت‌داری دسته ناپیوستگی بحرانی، آب زیرزمینی و پارامترهای مربوط به تنش، بنابراین

۴- پایگاه داده

به منظور توسعه مدل‌های تجربی پیش‌بینی عملکرد ماشین، دسترسی به داده‌های دقیق عملکرد واقعی ماشین و خصوصیات زمین‌شناسی و زمین‌شناسی مهندسی توده‌سنگ، مهم‌ترین عامل موفقیت است. این ورودی‌ها به سه دسته خصوصیات توده‌سنگ، خصوصیات راهبری و عملکرد ماشین تقسیم می‌شوند (حسن‌پور و همکاران، ۱۴۰۲). مرحله انتخاب پارامترهای ورودی مهم‌ترین و بحرانی‌ترین قسمت در مدل‌سازی است.

تاکنون شاخص‌های مختلفی جهت ارزیابی عملکرد ماشین حفار تونل توسط محققین معرفی و مورد استفاده قرار گرفته‌اند. در بین این پارامترها، شاخص نفوذ صحرایی (*FPI*) که توسط نلسون و همکاران (۱۹۸۳) ارائه شد، به طور موفقیت‌آمیزی جهت ایجاد همبستگی بین خصوصیات توده‌سنگ و عملکرد ماشین به کار رفته است (Salimi, et al., 2019).

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،

هوک و براون توصیه کردند که فقط از چهار پارامتر اول سیستم طبقه‌بندی *RMR* برای تعیین خواص حفریذیری توده‌سنگ استفاده شود (حسن‌پور و همکاران، ۱۴۰۲). از طرفی با توجه به مطالعات ساپینی و همکاران (۲۰۰۲)، مطالعات حسن‌پور و همکاران (۲۰۱۱) و سلیمی و همکاران (۲۰۱۹) که همبستگی بهتر سیستم طبقه‌بندی *RMR* با عملکرد *TBM* را اثبات می‌کند و با توجه به نتایج تحقیق رستمی (۲۰۱۶) طرح پیش‌بینی عملکرد ماشین در سنگ با استفاده از پارامترهای سیستم طبقه‌بندی *RMR* توسط دکتر رستمی مطرح و مطالعات روی پارامترهای ورودی این سیستم طبقه‌بندی متمرکز شد.

بناوسکی 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 (*Js*)، شرایط سطح ناپیوستگی‌ها (*Jc*)، وضعیت آب زیرزمینی (*Gw*) 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 (*Basic RMR*) 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. 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 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 (حسن‌پور و همکاران، ۱۴۰۲).

شکل ۱، رابطه جهت‌داری ناپیوستگی‌ها (زاویه α یا زاویه بین دسته ناپیوستگی بحرانی و محور تونل) با شاخص *FPI* را نشان می‌دهد، که حاکی از عدم همبستگی جهت‌داری ناپیوستگی‌ها با پارامتر عملکرد ماشین است. همبستگی بسیار کم داده‌ها ($R^2 = ۰/۰۰۲$) در این شکل طبیعی است، زیرا همان‌طور که اشاره شد، در توده‌سنگ‌های همسانگرد با دو یا سه دسته درزه تقریباً مشابه اثر جهت‌داری درزه‌ها بر عملکرد ماشین ناچیز است. در پایگاه داده گردآوری شده، اغلب مقاطع تونل در توده‌سنگ‌هایی همسانگرد یا با همسانگردی نسبتاً زیاد واقع شده‌اند، به همین جهت در مدل‌سازی جهت توسعه معادلات تجربی در این مطالعه، پارامتر ضریب تصحیح جهت‌داری درزه‌ها حذف شد.

برای تعیین امتیاز دو پارامتر فاصله‌داری (*Js*) و شرایط سطح ناپیوستگی‌ها (*Jc*) در سیستم *RMR*، باید دسته ناپیوستگی بحرانی (با حداکثر فرکانس و حداقل فاصله‌داری) که بیشترین تاثیر را در پایداری تونل دارند، در نظر گرفته شود. در این مطالعه از آنجاکه داده‌های مورد نیاز، از مطالعات


ناپیوستگی‌ها حذف می‌شوند. وزن پارامترهای شرایط آب زیرزمینی و UCS در سیستم RMR یکسان است، در صورتیکه تأثیر دو پارامتر روی خردایش سنگ و نرخ نفوذ ماشین کاملاً متفاوت است (Salimi, et al., 2019). سلیمی و همکاران (۲۰۱۹) با استفاده از روش PCA روی پارامترهای ژئوتکنیکی توده‌سنگ 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 UCS ، RQD ، J_s ، J_c دارای بیشترین تأثیر در عملکرد ماشین هستند.

علاوه بر این، فرخ و همکاران (۲۰۱۲) و سلیمی و همکاران (۲۰۱۹) پارامتر نوع سنگ ($Rock Type Code$) را به عنوان یک پارامتر ورودی در مدل، جهت پیش بینی نرخ نفوذ ماشین مطرح کردند، به این دلیل که بافت سنگ شامل نوع سیمان، درجه سیمانته شدن، شکل و سایز دانه‌ها روی نرخ نفوذ ماشین تأثیر زیادی دارند. طبق نتایج آنالیز حساسیت و مطالعه پارامتریک مدل مطرح شده توسط فاطمی و همکاران (۲۰۱۶)، پارامتر RTC نقش مهمی در تخمین قابلیت حفاری توده‌سنگ دارد 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 هوک و براون (۱۹۸۰) و استیونسون (۱۹۹۹) تقسیم‌بندی شده، مینا قرار داده شد (جدول ۴). 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.

جدول ۴- طبقه‌بندی انواع سنگ (RTC) در پایگاه داده (اقتباس از Hoek & Brown, 1980)

Code	نوع سنگ (Rock Type)
C	رس سنگ، گل سنگ، مارن، شیل، فیلیت، آرژیلیت
S	ماسه سنگ، سیلت استون، کنگلومرا، کوارتزیت
L	سنگ آهک، گچ، دولومیت، سنگ مرمر
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

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 حفارپذیری توده‌سنگ داشته (زاویه α بین ۴۵ تا ۷۰ درجه)، محاسبه شده است.




شکل ۱- رابطه بین جهت‌داری ناپیوستگی‌ها و FPI در پایگاه داده مورد مطالعه

همچنین با توجه به مطالعات حسن‌پور و همکاران (۲۰۰۹) از نظر تئوری شرایط آب زیرزمینی پارامتر مؤثری در نرخ نفوذ ماشین نیست و به نظر می‌رسد از نظر تأثیر بر نرخ نفوذ تیغه برشی در توده‌سنگ، شرایط نمناک، جریان قطره‌ای و جریان زیاد آب زیرزمینی تفاوت چندانی نداشته باشد. در واقع تنها حضور آب (صرف‌نظر از مقدار آن) برای کاهش پارامترهای مقاومتی ماده‌سنگ کافی است، اگرچه جریان بسیار زیاد آب نیز می‌تواند در شستن مواد پرکننده درزه‌ها و کاهش مقاومت توده‌سنگ مؤثر باشد. در حقیقت آب زیرزمینی با افزایش درجه دگرسانی توده‌سنگ و کاهش مقاومت ماده‌سنگ و مواد پرکننده درزه‌ها به صورت غیرمستقیم نقش مثبت در افزایش نرخ نفوذ ماشین دارد (حسن‌پور و همکاران، ۱۴۰۲). تأثیر شرایط آب زیرزمینی روی عملکرد TBM توسط لاوتن (۱۹۹۸) و نلسون (۱۹۸۳) 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 چشم‌پوشی می‌شود و از این رو در مدل‌سازی جهت توسعه معادلات تجربی، دو پارامتر سیستم RMR یعنی وضعیت آب زیرزمینی و جهت‌داری

سیستم *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، به همین دلیل در ادامه مطالعه، تمرکز بیشتری روی رده‌های سنگ‌شناسی شده است. آنالیز آماری پارامترهای ورودی مدل به تفکیک رده سنگ‌شناسی در جدول ۶، آمده است.



ب) تعداد مقاطع انواع مختلف سنگ‌شناسی (RTC) در پایگاه داده مورد مطالعه

به این ترتیب چهار پارامتر *RMR* پایه شامل *UCS*، *RQD*، *Js* و *Jc* و پارامتر *RTC* به عنوان پارامترهای ورودی اولیه برای توسعه روابط تجربی بر اساس پارامترهای سیستم طبقه‌بندی توده‌سنگ *RMR* به روش آنالیز رگرسیون مبتنی بر یادگیری ماشین استفاده شدند. شکل ۲، توزیع درصد فراوانی و تعداد مقاطع انواع رده سنگ‌شناسی (*RTC*) در پایگاه داده مورد مطالعه را نشان می‌دهد. به دلیل عدم وجود لیتولوژی آهک کارستی در پایگاه داده مورد مطالعه، رده *K* حذف شده است.

آنالیز آماری پارامترهای عملکرد ماشین (*FPI* و *P*) به همراه پارامترهای ورودی مورد استفاده در مدل در جدول ۵، خلاصه شده است. از آنجا که پارامتر شرایط درزه (*Jc*) در



الف) توزیع درصد فراوانی

شکل ۲- توزیع درصد فراوانی و تعداد مقاطع انواع رده سنگ‌شناسی (RTC)

جدول ۵- 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	-۰/۳	-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

(سنگ‌های آرژیلیتی، رس‌سنگ، گل‌سنگ، شیل، مارن، اسلیت، فیلیت) با حداکثر *FPI* اندازه‌گیری شده $24 (kN/cutter/mm/rev)$ می‌باشد. ۱۵۸ مقطع تونل در رده سنگ‌شناسی *G* (سنگ‌های آذرین درونی مانند گرانیت، دیوریت، پگماتیت و گنیس) با حداکثر *FPI* اندازه‌گیری شده

همان‌طور که ملاحظه می‌شود ۶ رده سنگ‌شناسی براساس داده‌های موجود، تعریف شده و پارامترهای عملکرد ماشین و خصوصیات توده‌سنگ هر رده با واقعیت‌های پروژه‌های تونل‌سازی تطابق دارد. در پروژه‌های تونل‌سازی مورد مطالعه، ۸۱ مقطع تونل در رده سنگ‌شناسی *C*

فصلنامه‌ی علمی مهندسی تونل و فضاهای زیرزمینی؛ دوره‌ی ۱۱؛ شماره‌ی ۳؛ پاییز ۱۴۰۱

ماتامورف مانند شیست و آمفیبولیت و کالک‌سیلیکات) با حداکثر FPI اندازه‌گیری‌شده $77/2 (kN/cutter/mm/rev)$ هستند.

$54 (kN/cutter/mm/rev)$ مقطع تونل در رده سنگ‌شناسی L (سنگ‌آهک، دولومیت، مرمر، گچ) با حداکثر FPI $58/26 (kN/cutter/mm/rev)$ گردآوری شده است. 74 مقطع تونل در رده سنگ‌شناسی M (سنگ‌های


جدول ۶- آنالیز آماری پارامترهای عملکرد ماشین و چهار پارامتر سیستم RMR پایه به تفکیک رده سنگ‌شناسی (RTC)

Std. Deviation	Variance	Max.	3rd Qu.	Mean	Median	1st Qu.	Min.	N	RTC
۵/۳	۲۸/۰۹	۲۴/۰	۱۳/۹۶	۹/۵۲	۸/۸۵	۵/۰۷	۲/۱۴	۸۱	FPI (kN/cutter/mm/rev)
۹/۱	۸۲/۸۸	۴۱/۳۹	۲۳/۶۱	۱۶/۵۴	۱۲/۵۰	۹/۰۴	۶/۰۸	۸۱	P (mm/rev)
۲۵/۵۳	۶۵۲/۱	۱۰۲/۸۲	۴۰/۰۰	۲۹/۶۶	۳۰/۰۰	۶/۰۰	۴/۲۵	۸۱	UCS (MPa)
۲۲/۱	۴۸۸/۲۷	۹۳	۶۵	۴۴/۱	۴۶	۲۲/۵	۲۰	۸۱	RQD (%)
-/۰۷	-/۰۰۵	-/۴۰	-/۱۸	-/۱۳	-/۱۳	-/۰۶	-/۰۵	۸۱	Js (m)
۴/۲۳	۱۷/۸۷	۲۵	۱۵	۱۳/۲۷	۱۰	۱۰	۵	۸۱	Jc (Partial rating in RMR)
۳۱/۶۷	۱۰۰۳/۲۶	۱۵۰/۰	۴۸/۳۸	۴۰/۸۵	۳۲/۶۰	۱۸/۹۰	۵/۸۰	۱۵۸	FPI (kN/cutter/mm/rev)
۳/۰۰۷	۹/۰۴	۱۵/۳۱	۸/۸۴	۶/۶۳	۶/۲۷	۴/۴۸	۱/۵۰	۱۵۸	P (mm/rev)
۵۱/۳۸	۲۶۴۰/۱۳	۳۰۰/۰	۱۵۷/۵	۱۲۰/۰	۱۱۹/۰	۷۱/۵	۴۳/۷	۱۵۸	UCS (MPa)
۱۰/۷۲	۱۱۵/۰۵	۱۰۰	۱۰۰	۸۷/۵۵	۸۸	۸۰	۵۳	۱۵۸	RQD (%)
-/۰۳۷	-/۱۳۶	۲/۰۰	-/۸۰	-/۵۱	-/۴۰	-/۲۵	-/۱۰	۱۵۸	Js (m)
۳/۷۷	۱۴/۲۴	۲۷	۲۰	۱۸/۲۲	۱۹	۱۵	۱۰	۱۵۸	Jc (Partial rating in RMR)
۱۰/۷۵	۱۱۵/۶	۵۸/۲۶	۳۰/۸۵	۲۴/۸۷	۲۲/۹۵	۱۸/۲۲	۷/۰۰	۵۴	FPI (kN/cutter/mm/rev)
۲/۷۹	۷/۷۹	۱۳/۸۸	۹/۹۹	۷/۶۷	۷/۲۸	۵/۵۹	۳/۳۱	۵۴	P (mm/rev)
۳۸/۳۴	۱۴۷۰/۲۲	۱۷۰/۰	۱۰۰/۰	۷۹/۳۱	۶۶/۰	۵۷/۲۵	۱۲/۰	۵۴	UCS (MPa)
۱۴/۰۵	۱۹۷/۶۴	۱۰۰	۹۰	۷۷/۸	۷۷	۶۸/۵	۵۰	۵۴	RQD (%)
-/۰۱۹	-/۰۲۷	-/۸۰	-/۵۰	-/۳۴	-/۲۶	-/۱۸	-/۱۰	۵۴	Js (m)
۴/۷۱	۲۲/۲۳	۲۵	۲۰	۱۷/۲۳	۱۸	۱۵	۸	۵۴	Jc (Partial rating in RMR)
۱۱/۳	۱۲۷/۶۵	۷۷/۲۰	۱۳/۰۲	۱۲/۰۳	۹/۷۶	۷/۸۲	۳/۴۴	۷۴	FPI (kN/cutter/mm/rev)
۳/۶	۱۲/۹۶	۲۲/۳۸	۱۴/۶۰	۱۲/۲۵	۱۲/۵۲	۱۰/۲۶	۲/۸۱	۷۴	P (mm/rev)
۵۰/۴۴	۲۵۴۴/۷۴	۲۱۵/۵۰	۲۷/۵۰	۳۷/۹۷	۱۴/۵۰	۱۴/۵۰	۱۴/۵۰	۷۴	UCS (MPa)
۲۲/۴۹	۵۰۶/۰۸	۱۰۰	۴۲/۵	۳۹/۸	۲۸/۵	۲۸/۵	۱۰	۷۴	RQD (%)
-/۰۱۴	-/۰۱۹	-/۸۰	-/۳۳	-/۱۸	-/۱۱	-/۱۱	-/۰۳	۷۴	Js (m)
۲/۹	۸/۳۹	۲۰	۱۰	۱۱/۴۶	۱۰	۱۰	۱۰	۷۴	Jc (Partial rating in RMR)
۲۳/۴	۵۴۷/۹۴	۷۳/۸۲	۶۰/۱۹	۳۵/۸۰	۲۱/۵۹	۱۵/۵۸	۹/۵۲	۳۴	FPI (kN/cutter/mm/rev)
۳/۲۶	۱۰/۶۶	۱۳/۱۶	۹/۲۴	۶/۸۰	۶/۱۶	۴/۱۳	۱/۹۴	۳۴	P (mm/rev)
۳۱/۴۸	۹۹۱/۵۵	۱۶۵/۰	۷۹/۶۲	۷۴/۰۶	۷۸/۵	۵۲/۵	۳۴/۵	۳۴	UCS (MPa)
۲۳/۷	۵۶۲/۳۱	۱۰۰	۹۵	۷۱/۴۴	۷۶/۵	۵۵	۳۰	۳۴	RQD (%)
-/۰۱۸	-/۰۳۵	-/۶۰	-/۵۶	-/۳۴	-/۳۰	-/۱۵	-/۱۱	۳۴	Js (m)
۵/۶۵	۳۱/۹۷	۲۵	۲۰	۱۶/۰۳	۱۸	۱۰	۵	۳۴	Jc (Partial rating in RMR)
۲۷/۸	۷۷۴/۸۴	۱۴۱/۳۳	۲۰/۳۶	۲۴/۹۵	۱۵/۱۶	۱۱/۳۳	۵/۹۰	۱۲۲	FPI (kN/cutter/mm/rev)
۳/۳۷	۱۱/۳۹	۱۵/۹۸	۷/۴۷	۵/۳۸	۴/۱۶	۲/۹۵	۱/۵۰	۱۲۲	P (mm/rev)
۵۵/۹	۳۱۲۸/۳۲	۲۷۵/۰	۱۱۷/۶۳	۹۳/۰۱	۷۳/۵	۵۵/۰	۱۶/۰	۱۲۲	UCS (MPa)
۲۴/۹۹	۶۲۴/۸۴	۱۰۰	۸۵	۶۶/۷	۷۰	۵۰	۱۰	۱۲۲	RQD (%)
-/۰۳۸	-/۰۱۴۸	۱/۴۰	-/۶۰	-/۴۸	-/۳۹	-/۲۴	-/۰۵	۱۲۲	Js (m)
۷/۰۶	۴۹/۸۲	۳۰	۲۵	۱۷/۳۲	۱۷	۱۲	۴	۱۲۲	Jc (Partial rating in RMR)

سیستم طبقه‌بندی توده‌سنگ RMR، روش‌های یادگیری ماشین شامل الگوریتم‌های رگرسیون به کمک زبان برنامه‌نویسی R و Python پیاده‌سازی شده است. 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) تعیین‌کننده 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 بر اساس 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 گام به گام (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. در صورتی که دو فرض رگرسیون خطی برقرار باشد، تعمیم‌پذیری صورت می‌گیرد. این دو فرض عبارتند از: ۱) برای هر ترکیبی از متغیرهای مستقل، مقدار خطا دارای توزیع نرمال با میانگین صفر و انحراف معیار ثابت باشد. ۲) مقادیر خطا از هم مستقل بوده و یا به عبارت دیگر

۳۴ مقطع تونل در رده سنگ‌شناسی S (ماسه‌سنگ، سیلت‌استون، کنگلومرا، کوارتزیت) با حداکثر FPI اندازه‌گیری شده برابر $73/82 (kN/cutter/mm/rev)$ است و باید در نظر داشت تعداد مقاطع تونل در این رده سنگ‌شناسی کمتر است و ممکن است در این رده سنگ‌شناسی، حین مدل‌سازی ماشین به‌خوبی آموزش نییند. آخرین رده سنگ‌شناسی نیز، ۱۲۲ مقطع تونل در رده سنگ‌شناسی V (سنگ‌های ولکانیکی مانند بازالت، ریولیت، آندزیت، انواع توف و سنگ‌های آذرآواری) با حداکثر FPI اندازه‌گیری شده در مقاطع تونل‌ها برابر $141/33 (kN/cutter/mm/rev)$ است. همانطور که انتظار می‌رفت، بیشترین مقادیر FPI در سنگ‌های آذرین (رده G) و کمترین مقادیر در سنگ‌های رسوبی ضعیف مثل سنگ‌های آرژیلیتی اندازه‌گیری شده است. مطالعات رابینز (۱۹۹۲)، لاوتن (۱۹۹۸)، گانگ و همکاران (۲۰۰۶) و حسن‌پور و همکاران (۲۰۱۱) نیز این نتایج را برای انواع سنگ تأیید می‌کنند. شکل ۳، نمودار جعبه‌ای پارامتر FPI را در هر رده سنگ‌شناسی (RTC) نشان می‌دهد و نقاط قرمز، متوسط FPI اندازه‌گیری شده در هر رده سنگ‌شناسی است.



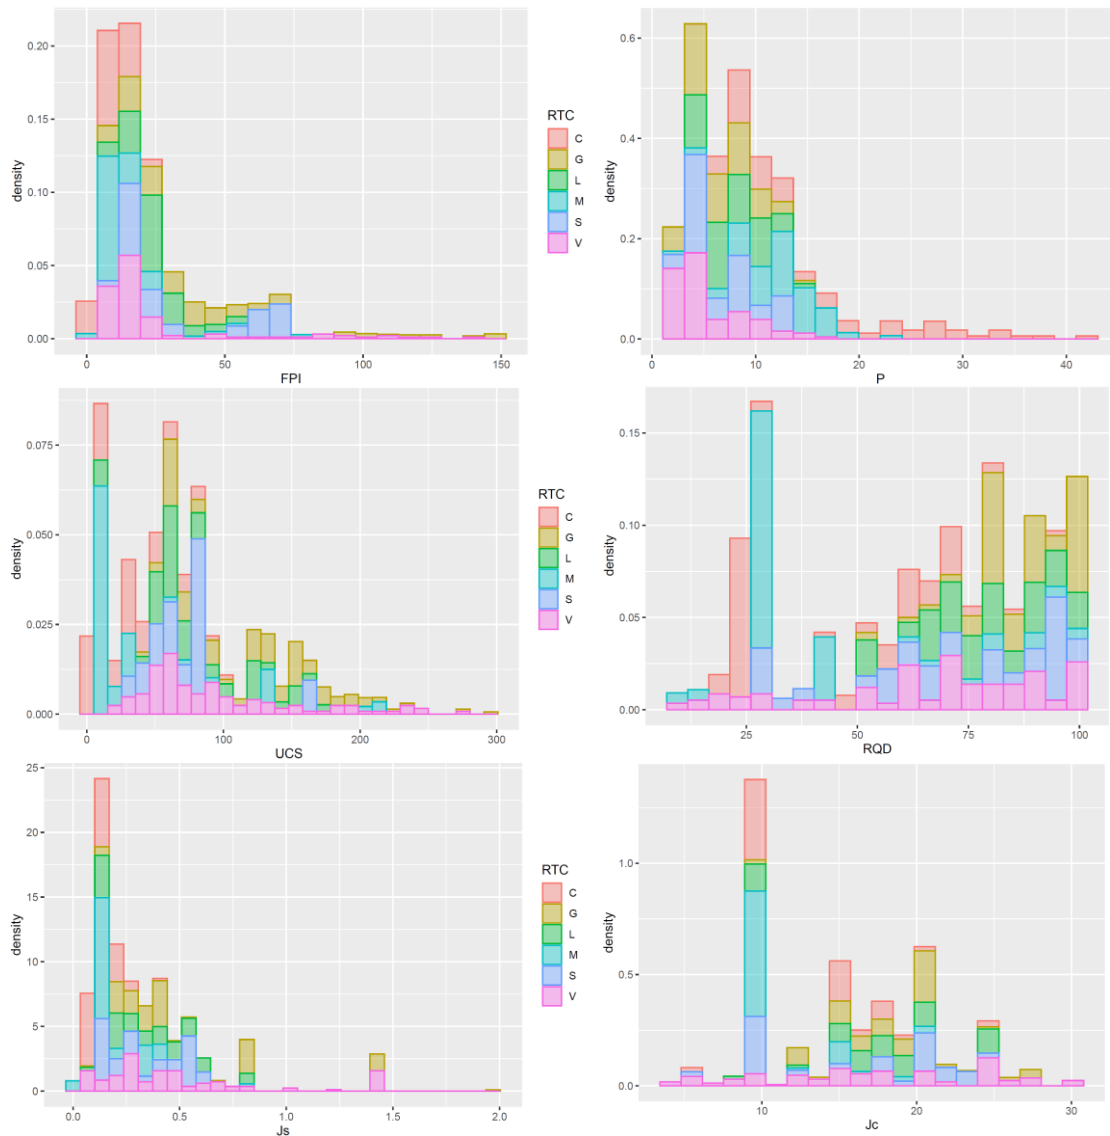
شکل ۳- نمودار مقادیر FPI در هر رده سنگ‌شناسی

به منظور درک بهتر توزیع فراوانی هر یک از پارامترهای عملکرد ماشین (FPI و P) و پارامترهای ورودی مورد استفاده در مدل شامل UCS ، RQD ، J_s و J_c ، نمودار هیستوگرام هر یک از پارامترها بر اساس رده سنگ‌شناسی (RTC) در شکل ۴، رسم شده است. در این شکل محدوده تغییرات هر پارامتر با توجه به نوع سنگ‌شناسی قابل تشخیص است و با واقعیت‌های سنگ‌شناسی تطابق دارد.

۵- مدل‌سازی

در این مطالعه برای توسعه روابط تجربی بر اساس پارامترهای

توزیع واریانس خطاها متقارن باشد (Hastie, et al., 2009).



شکل ۴- نمودار هیستوگرام پارامترهای عملکرد ماشین و پارامترهای ورودی مدل بر اساس رده سنگ‌شناسی (RTC)


۰/۷۸ بوده و بیشترین تأثیر را در عملکرد ماشین داشته‌اند و پس از آن RQD با ۰/۶۲ و سپس Jc با ۰/۳۸ قرار می‌گیرد. مطالعات قبلی صورت گرفته از جمله رابینز (۱۹۹۲)، لاوتن (۱۹۹۸) و حسن‌پور و همکاران (۲۰۰۸، ۲۰۱۱، ۲۰۱۵) نیز نشان می‌دهند، UCS عامل بسیار مهمی در حفاری سنگ به وسیله ماشین TBM است. همچنین بایستی به همبستگی

از آنجا که مسئله رگرسیون مطرح است، با آنالیز همبستگی (*Correlation*) می‌توان به یک دیدگاه کلی پیرامون رابطه بین متغیرهای مستقل و متغیر وابسته FPI دست یافت. شدت همبستگی بین متغیرها در شکل ۵، ارائه شده است. همان‌طور که انتظار می‌رفت بالاترین همبستگی مربوط به UCS برابر ۰/۷۴ و فاصله‌داری درزه‌ها (J_s) برابر

FPI مثبت است و با افزایش هر یک از متغیرهای مستقل، FPI افزایش می‌یابد.

همانطور که در شکل ۶، می‌توان دید، وقتی نوع سنگ در تحلیل و مدل‌سازی مورد توجه قرار می‌گیرد، محدوده تغییرات متغیرهای مستقل UCS ، RQD ، J_s و J_c نسبت به FPI اندازه‌گیری شده، کاملاً با واقعیت‌های سنگ‌شناسی تطابق دارد، چنانچه سنگ‌های آذرین درونی (رده G) دارای خصوصیات مقاومتی (UCS و RQD) بالاتری نسبت به سنگ‌های آتشفشانی، رسوبی و دگرگونی هستند و بالاتری نیز دارند.

بین خود متغیرهای مستقل نیز توجه کرد چرا که در مدل‌سازی ممکن است باعث هم‌خطی (*Multicollinearity*) بین متغیرها شود و ضرایب رگرسیون را تحت تاثیر قرار داده و اثر خالص متغیرهای مستقل را روی متغیر وابسته نتوان تعیین کرد، به‌طور مثال RQD با J_s همبستگی ۰/۶۴ دارد که ناشی از تاثیر فاصله‌داری درزه‌ها در تعیین مقدار RQD است. شکل ۶ رابطه بین FPI اندازه‌گیری شده در پروژه‌های مورد مطالعه را با چهار پارامتر ورودی مدل به تفکیک نوع سنگ‌شناسی در پایگاه‌داده نشان می‌دهد. توجه به این نکته ضروری است که رابطه تمامی متغیرهای مستقل ورودی با



شکل ۵- ماتریس همبستگی بین متغیرهای مستقل و متغیر وابسته FPI

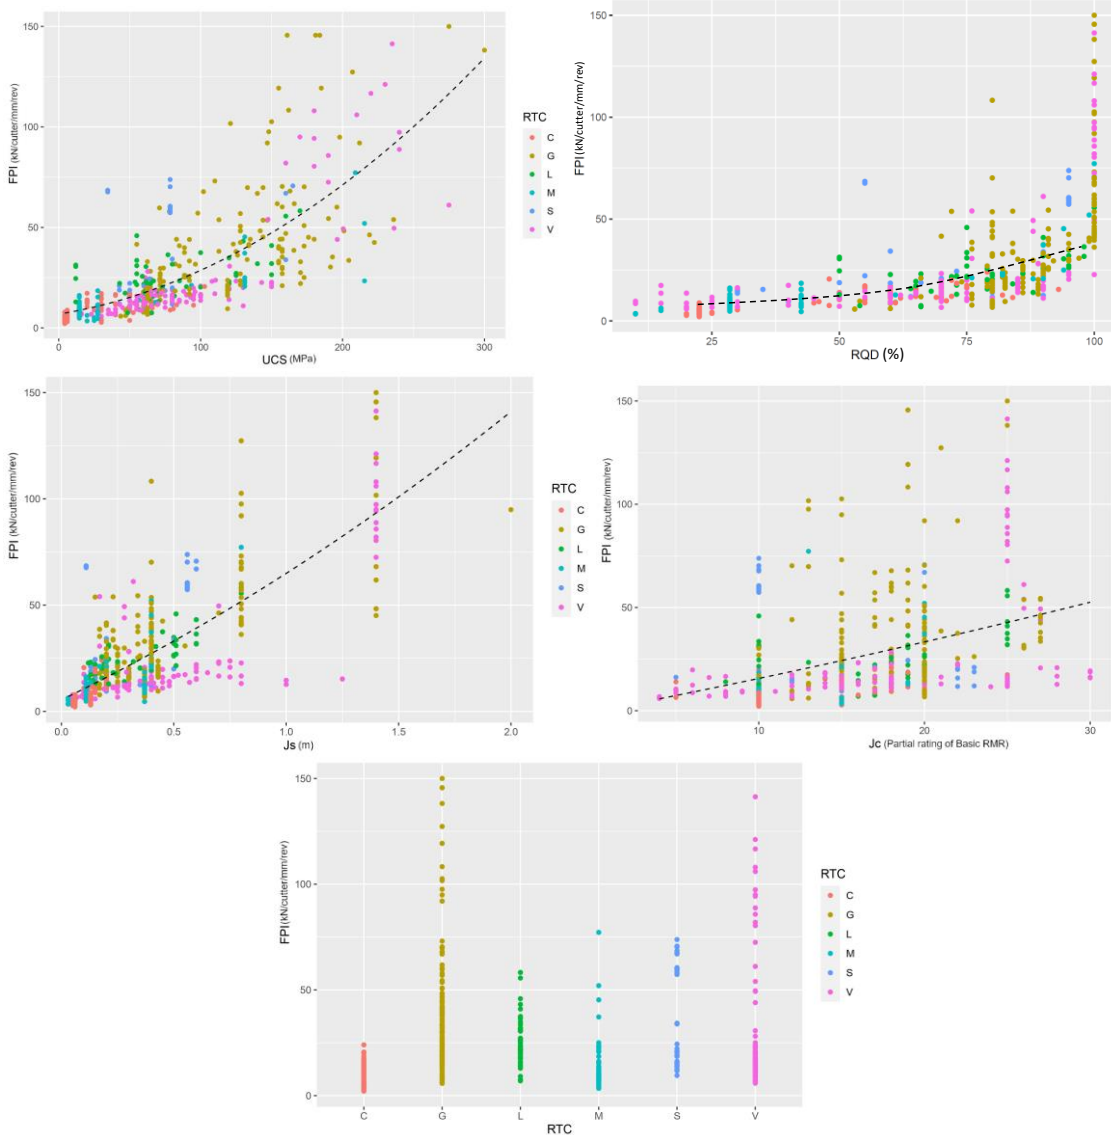
سیستم طبقه‌بندی توده‌سنگ RMR پایه یعنی UCS ، RQD و J_s و J_c بدون در نظر گرفتن رده سنگ‌شناسی RTC پیاده‌سازی شدند. به این ترتیب پارامترهای ورودی سیستم RMR پایه که اغلب در پروژه‌های تونل‌سازی مختلف در دسترس هستند، برای تخمین FPI مورد استفاده قرار خواهند گرفت. بر طبق نتایج رستمی (۱۹۹۷) با محاسبه رگرسیون لگاریتمی، به جای رگرسیون خطی، توابع توان‌دار توسعه داده می‌شوند و این امر باعث می‌شود که روابط در شرایط مرزی با خطای کمتری برآورد شوند. رابطه (۱)

۶- روابط تجربی پیش‌بینی عملکرد TBM

روابط تجربی مبتنی بر داده به طور گسترده برای پیش‌بینی متغیرهای هدف بر اساس سایر متغیرهای مستقل استفاده می‌شوند. در سال‌های اخیر روابط تجربی اهمیت زیادی در کارهای مهندسی سنگ داشته‌اند، چرا که در مقایسه با آنالیزهای تئوری پیچیده، کاربردی‌تر هستند. به‌منظور توسعه روابط تجربی پیش‌بینی عملکرد ماشین در این مطالعه، ابتدا الگوریتم‌های رگرسیون روی داده‌های $Train$ شامل پارامتر FPI به عنوان پارامتر ارزیابی عملکرد TBM و پارامترهای

آزمون *Jarque-Bera* و آزمون *Anscombe-Glynn* انجام و نرمال بودن توزیع خطاها تأیید شد. جهت ارزیابی فرض دوم یعنی همسانی توزیع واریانس خطاها یا عدم *Heteroscedasticity* نمودار واریانس خطاها رسم و متقارن بودن آن تأیید شد.

بهترین مدل بدست آمده از آموزش الگوریتم‌های رگرسیون روی داده‌های *Train* با R^2 حدود ۰/۷ بر اساس چهار پارامتر سیستم طبقه‌بندی توده‌سنگ *RMR* پایه برای همه رده‌های سنگ‌شناسی است. جهت ارزیابی فرض اول رگرسیون یعنی نرمال بودن توزیع خطاها، آزمون‌های آماری *Moment* شامل



شکل ۶- رابطه بین *FPI* اندازه‌گیری شده و چهار پارامتر ورودی سیستم *RMR* پایه به تفکیک نوع سنگ‌شناسی (*RTC*)

امتیاز شرایط سطح ناپیوستگی‌ها در سیستم *RMR* است. همانطور که اشاره شد برای تعیین *Js* و *Jc* از دسته ناپیوستگی که بیشترین تأثیر را در نرخ نفوذ ماشین دارد، استفاده شده

در این معادله *UCS* مقاومت تراکمی تک‌محوره بر اساس *RQD MPa* شاخص کیفی توده‌سنگ بر اساس درصد، *Js* فاصله‌داری ناپیوستگی‌ها بر اساس متر (*m*) و *Jc*

۷، نشان داده شده است. همان‌طور که در شکل ۷، 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 ماشین و زمین در FPI بزرگتر را نشان می‌دهد و تمرکز مطالعات آتی جهت توسعه روابط در این شرایط توصیه می‌شود.

در مرحله بعد داده‌های مربوط به هر رده سنگ‌شناسی به دو دسته $Train$ و $Test/Validation$ تقسیم شده و الگوریتم‌های رگرسیون روی داده‌های $Train$ در هر رده سنگ‌شناسی RTC پیاده‌سازی شدند. به این ترتیب پارامترهای ورودی سیستم طبقه‌بندی RMR پایه برای تخمین FPI در هر رده سنگ‌شناسی به کار می‌رود. جدول ۷، روابط بدست‌آمده برای هر رده سنگ‌شناسی را نشان می‌دهد. روابط (۳) تا (۸) با R^2 حدود ۰/۷۲ تا ۰/۸۱ بر اساس چهار پارامتر سیستم RMR پایه یعنی UCS ، RQD ، J_s و J_c با توجه به رده سنگ‌شناسی RTC توسعه داده شده است. بدیهی است با در نظر گرفتن رده سنگ‌شناسی در مدل‌سازی، مقدار R^2 به میزان قابل توجهی افزایش یافته و این امر اهمیت پارامتر سنگ‌شناسی را در حفاری در سنگ سخت نشان می‌دهد.

است. براساس نتایج آزمون t مدل، مقدار p -value پارامتر J_c بیشتر از ۰/۰۵ بوده و این پارامتر در مدل متمایز ($significant$) نشده، و بهتر است از مدل حذف شود. البته این امر دور از انتظار نیست، چراکه همبستگی J_c با FPI از همه پارامترها کمتر بود. برای بدست آوردن مدل بهینه ($Optimized\ model$) پارامتر J_c حذف و دوباره مدل‌سازی صورت می‌گیرد. رابطه (۲) مدل بهینه با همان R^2 حدود ۰/۷ و بر اساس پارامترهای UCS ، RQD و J_s است.


نکته حائز اهمیت دیگر این‌که زمانی که از الگوریتم‌های رگرسیون برای پیش‌بینی متغیر وابسته بر اساس متغیرهای مستقل استفاده می‌شود، متغیرهای مستقل بایستی مستقل از هم بوده و با یکدیگر همبستگی نداشته باشند، چرا که باعث ایجاد هم‌خطی در رگرسیون می‌گردد. تشخیص هم‌خطی متغیرها به کمک پارامتر $Variation\ Inflation\ Factor$ (VIF) صورت می‌گیرد و $VIF > 10$ نشان‌دهنده هم‌خطی قوی در رگرسیون است. VIF تمامی متغیرهای مستقل در روابط (۱) و (۲) کوچکتر از ۱۰ بودند و مدل از این نظر هم مشکلی نداشت. سپس مدل را در معرض داده‌های $Test$ قرار داده و برای اینکه دید بهتری نسبت به عملکرد مدل پیدا کنیم، ضریب همبستگی (R^2) مدل را روی داده‌های $Test$ بدست می‌آوریم. FPI اندازه‌گیری شده داده‌های $Train$ و $Test$ در برابر FPI پیش‌بینی شده توسط رابطه (۱) در شکل

$$FPI = 3.68 (UCS)^{0.28} (RQD)^{0.33} (J_s)^{0.39} (J_c)^{-0.13} \quad (R^2 = 0.7) \quad (1)$$

$$(R^2 = 0.7) \quad (1)$$

$$FPI = 3.25 (UCS)^{0.26} (RQD)^{0.29} (J_s)^{0.4} \quad (R^2 = 0.7) \quad (2)$$

$$(R^2 = 0.7) \quad (2)$$



شکل ۷- FPI اندازه‌گیری شده در برابر FPI پیش‌بینی شده توسط رابطه (۱) داده‌های $Train$ و $Test$

جدول ۷- روابط بدست‌آمده بر اساس پارامترهای ورودی سیستم RMR پایه برای رده سنگ‌شناسی

RTC	Rock Type	Equation	R ²
Class C	claystone, mudstone, marl, shale, slate, phyllite, argillite	$FPI = 0.856 (UCS)^{0.082} (RQD)^{0.79} (J_S)^{0.16} (J_C)^{-0.21}$	0.75 (۳)
Class G	Coarse igneous such as granite, diorite, pegmatite, gneiss	$FPI = 0.016 (UCS)^{0.7} (RQD)^{1.05} (J_S)^{0.38} (J_C)^{-0.025}$	0.75 (۴)
Class L	limestone, chalk, dolomite, marble	$FPI = 17.06 (UCS)^{-0.49} (RQD)^{0.44} (J_S)^{0.75} (J_C)^{0.5}$	0.8 (۵)
Class M	Metamorphic rocks such as amphibolite, schist, calc-silicate	$FPI = 0.306 (UCS)^{0.06} (RQD)^{0.74} (J_S)^{0.068} (J_C)^{0.36}$	0.72 (۶)
Class S	sandstone, siltstone, conglomerate, quartzite	$FPI = 0.078 (UCS)^{0.7} (RQD)^{1.53} (J_S)^{-0.71} (J_C)^{-1.62}$	0.81 (۷)
Class V	Fine volcanic such as basalt, rhyolite, andesite, tuff, pyroclastic	$FPI = 0.37 (UCS)^{0.93} (RQD)^{0.009} (J_S)^{0.13} (J_C)^{-0.045}$	0.75 (۸)
Class C	claystone, mudstone, marl, shale, slate, phyllite, argillite	$FPI = 0.73 (UCS)^{0.06} (RQD)^{0.72} (J_S)^{0.18}$	0.75 (۹)
Class G	Coarse igneous such as granite, diorite, pegmatite, gneiss	$FPI = 0.0162 (UCS)^{0.7} (RQD)^{1.04} (J_S)^{0.38}$	0.75 (۱۰)
Class M	Metamorphic rocks such as amphibolite, schist, calc-silicate	$FPI = 0.306 (UCS)^{0.06} (RQD)^{0.74} (J_S)^{0.068} (J_C)^{0.36}$	0.72 (۱۱)
Class V	Fine volcanic such as basalt, rhyolite, andesite, tuff, pyroclastic	$FPI = 0.372 (UCS)^{0.91} (J_S)^{0.125}$	0.75 (۱۲)
Class LS	limestone, chalk, dolomite, marble, sandy limestone, limy sandstone, sandstone, siltstone, conglomerate, quartzite	$FPI = 12.71 (RQD)^{0.32} (J_S)^{0.56}$	0.7 (۱۳)

Optimized models

تأثیرگذار نبوده‌اند.

نکته حائز اهمیت دیگر در مورد روابط رده L (سنگ‌آهک، دولومیت، مرمر، گچ) و رده S (ماسه‌سنگ، سیلت‌استون، کنگلومرا، کوارتزیت) آن است که در این دو رده‌سنگ، با توجه به تعداد کمتر مقاطع تونل و روابط بدست‌آمده با R^2 حدود ۰/۸ احتمال برازش بیش‌ازحد (*Overfitting*) در این دو رده‌سنگ وجود دارد. در این صورت این احتمال وجود دارد که الگوریتم‌ها به‌درستی روی داده‌های *train* آموزش ندیده باشند و نهایتاً در آینده نیز روی داده‌هایی که هنوز ندیده است، به‌خوبی پیش‌بینی نکند. در نتیجه با توجه به تعداد کم مقاطع در این دو رده‌سنگ و وجود مقاطع با سنگ‌شناسی حدواسط از جمله کنگلومرا و ماسه‌سنگ آهکی و آهک ماسه‌ای، رده LS (مجموع دو رده L و S) بصورت یک رده سنگ‌شناسی تعریف شده و مدل‌سازی صورت‌گرفته و رابطه (۱۳) با $R^2 = ۰/۷$ بدست آمده است. استفاده از این

همان‌طور که قبلاً نیز ذکر شد، براساس نتایج آزمون t هر مدل، برخی پارامترها در هر رده‌سنگ متمایز (*significant*) نشده و بهتر است از مدل حذف شوند. برای بدست آوردن مدل بهینه هر رده‌سنگ، پارامترهایی که در هر مدل متمایز نشدند، حذف شده و دوباره مدل‌سازی صورت گرفته و به این ترتیب روابط (۹) تا (۱۳) مدل بهینه در هر رده‌سنگ با همان عملکرد، در جدول ۷، نشان داده شده است. نکته قابل توجه در روابط بدست آمده این است که با داشتن تعداد پارامترهای کمتر می‌توان FPI را با توجه به نوع سنگ‌شناسی به‌خوبی پیش‌بینی کرد، مثلاً اگر پیش‌بینی FPI یک سنگ ولکانیک (رده V) مدنظر باشد، فقط با در اختیار داشتن دو پارامتر UCS و J_S می‌توان با $R^2 = ۰/۷۵$ مقدار FPI را پیش‌بینی کرد. این نکته نشان‌دهنده این موضوع نیز هست، که تغییرات دو پارامتر دیگر RQD و J_C در رده‌سنگ V محدود بوده، به‌طوری‌که روی پیش‌بینی متغیر وابسته FPI

Mean Absolute Error (MAE)، *Mean Absolute Error (MAE)*، *Percentage Error (MAPE)* بر حسب درصد، *Root Mean Squared Error (RMSE)* و *Squared Error (MSE)* می‌سنجیم. روابط (۱۴) تا (۱۷) روابط ریاضی این پارامترهاست. در این روابط y_i متغیر وابسته اندازه‌گیری شده، \hat{y}_i متغیر وابسته پیش‌بینی شده از طریق مدل و n تعداد مشاهدات است. مقادیر این پارامترها برای مدل مربوط به کل داده‌ها صرف‌نظر از نوع سنگ‌شناسی و مدل مربوط به هر رده سنگ‌شناسی در جدول ۸، آمده است.

رابطه، تا تکمیل مطالعات و جمع‌آوری داده‌های بیشتر در این دو رده سنگ‌شناسی توصیه می‌شود. در نهایت مدل‌های بدست‌آمده برای هر رده سنگ‌شناسی، در معرض داده‌های *Test* قرار گرفته و *FPI* اندازه‌گیری شده در پروژه‌ها در برابر *FPI* پیش‌بینی شده توسط روابط (۳) تا (۸) برای هر رده سنگ‌شناسی در شکل ۸، رسم شده است. برای اینکه دید بهتری نسبت به عملکرد مدل پیدا کنیم، توزیع خطاها را بر اساس پارامترهای ارزیابی مدل شامل

$$MAE = \frac{\sum |y_i - \hat{y}_i|}{n} \quad (14)$$

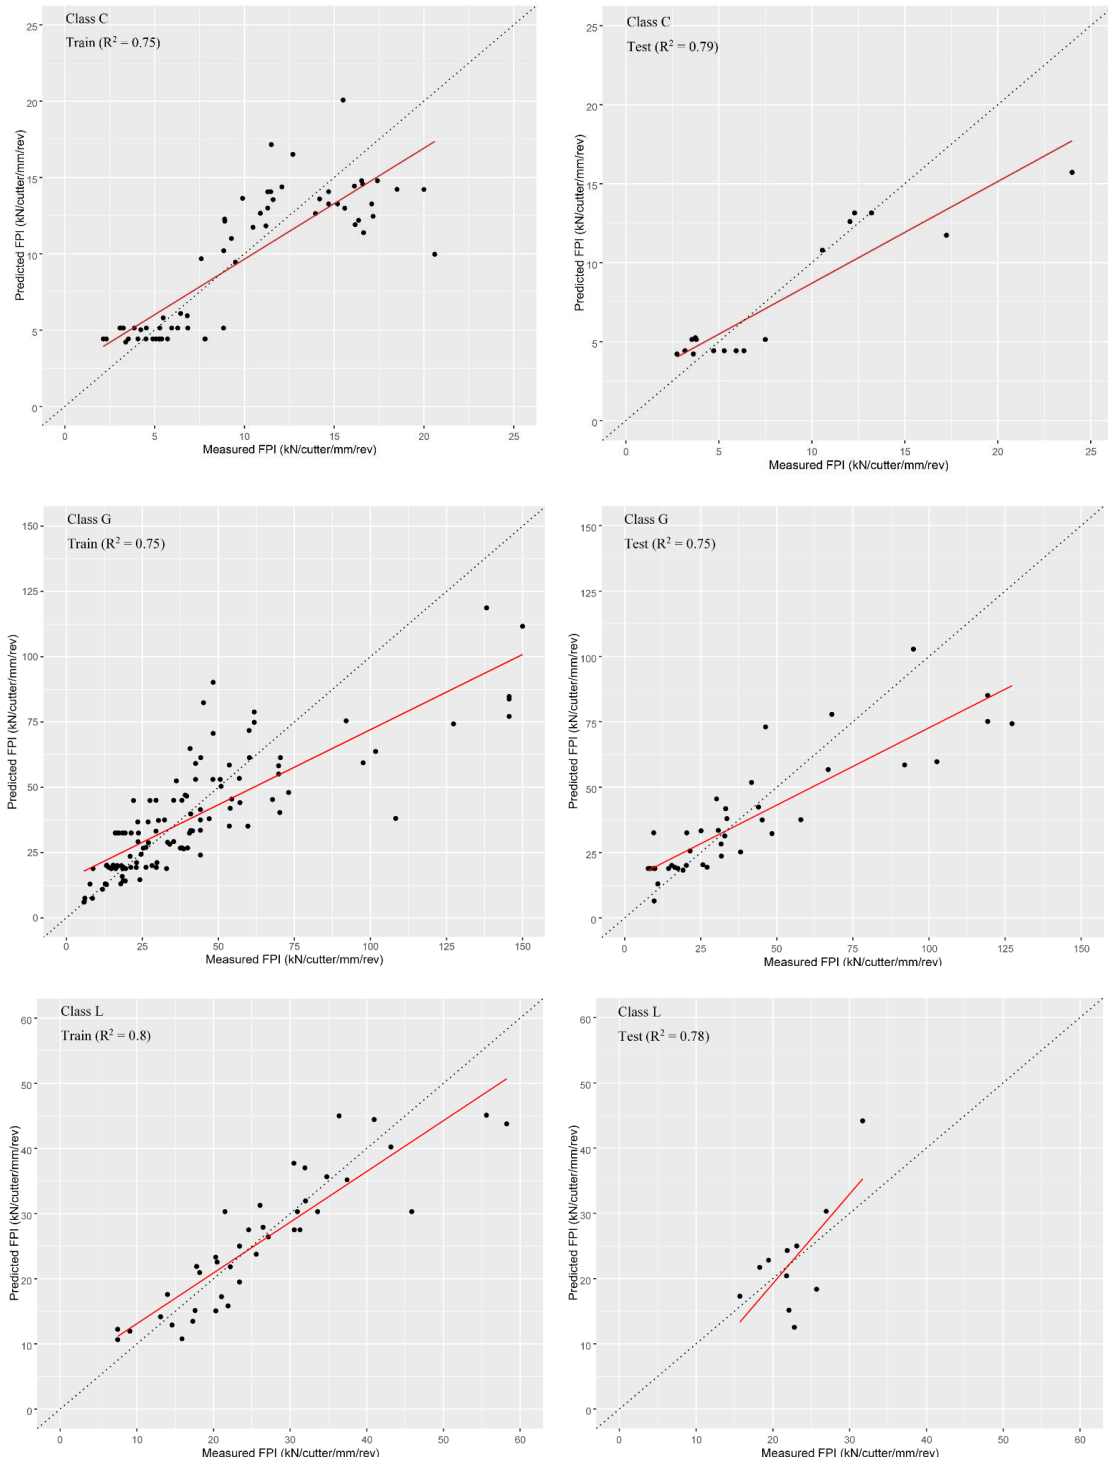
$$MAPE = \frac{1}{n} \sum \frac{|y_i - \hat{y}_i|}{y_i} * 100 \quad (15)$$

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n} \quad (16)$$

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}} \quad (17)$$

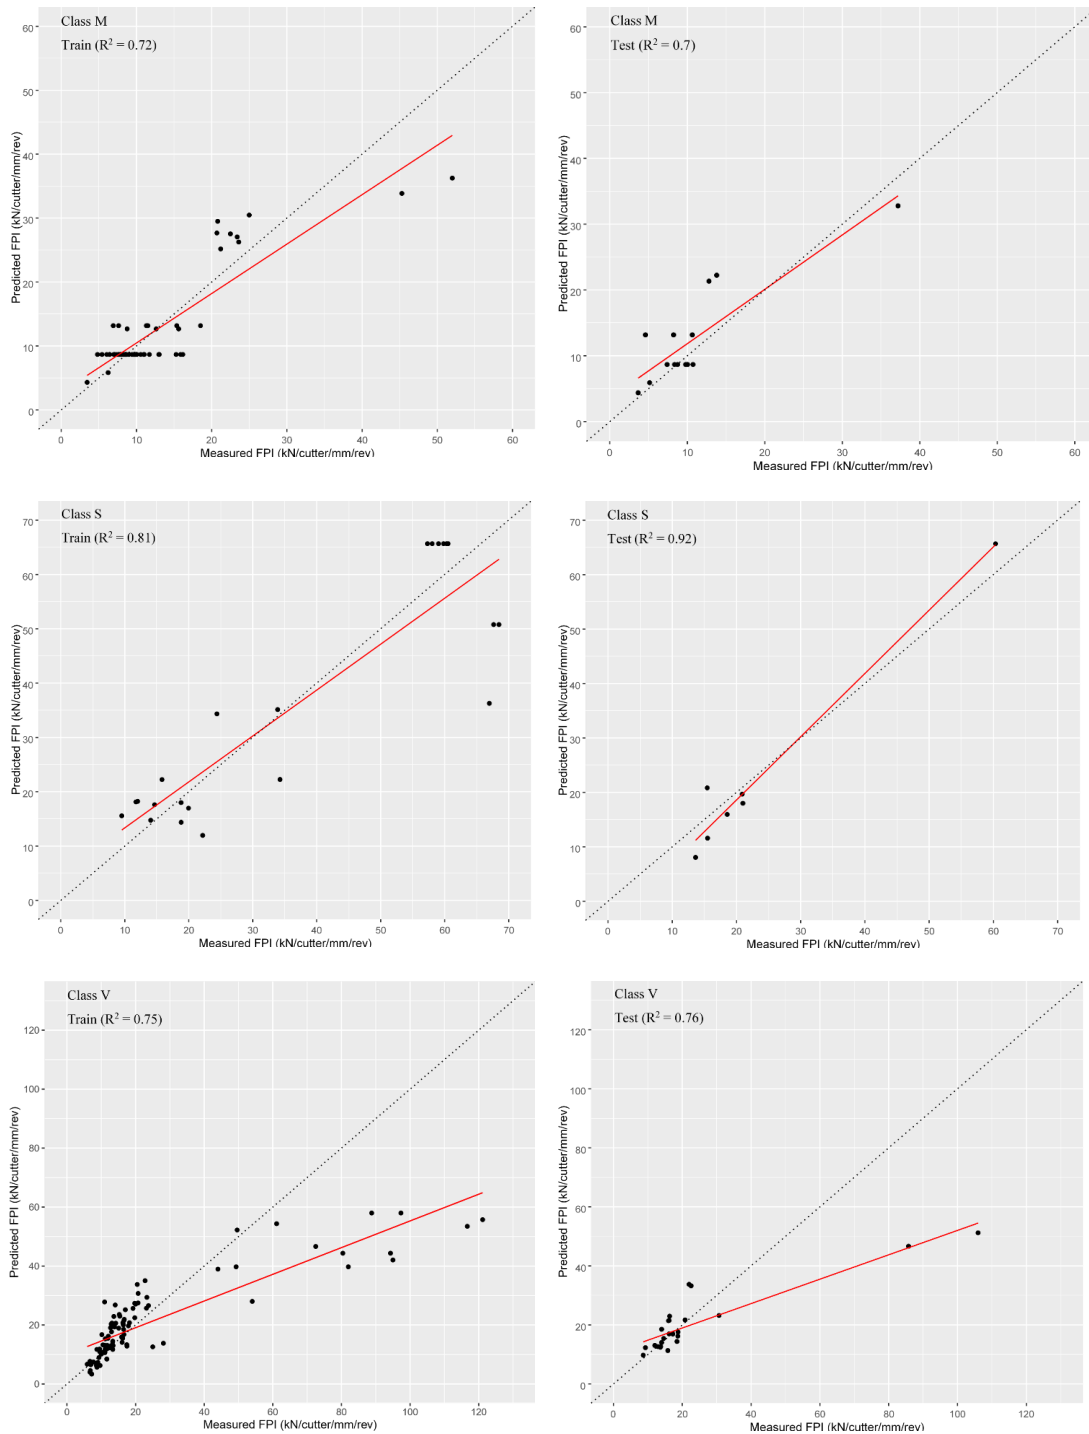
جدول ۸- مقایسه پارامترهای ارزیابی مدل در مدل کل داده‌ها و مدل هر رده سنگ‌شناسی

Model	R ²		MAE	MAPE (%)	MSE	RMSE
	Train	Test				
کل داده‌ها صرف‌نظر از نوع سنگ‌شناسی	۰/۷	۰/۷	۱۱/۱۸	۳۷/۸	۳۶۹/۵	۱۹/۲۲
Class C	۰/۷۵	۰/۷۹	۱/۷۷	۲۴/۶	۷/۲۳	۲/۶۹
Class G	۰/۷۵	۰/۷۵	۱۲/۳۸	۳۹/۲	۳۱۵/۱	۱۷/۷۵
Class L	۰/۸	۰/۷۸	۴/۹۵	۲۰/۷	۳۷/۴	۶/۱۱
Class M	۰/۷۲	۰/۷	۳/۰۹	۳۴/۸	۱۸/۶۴	۴/۳۲
Class S	۰/۸۱	۰/۹۲	۳/۸۶	۲۰/۶	۱۷/۳	۴/۱۶
Class V	۰/۷۵	۰/۷۶	۶/۷۳	۲۰/۸	۲۰۰/۹	۱۴/۱۷



شکل ۸- FPI اندازه‌گیری شده در برابر FPI پیش‌بینی شده داده‌های Train و Test در هر رده سنگ‌شناسی RTC

پیش‌بینی نرخ نفوذ TBM در انواع سنگ با استفاده از ...، آمنة دردستی و ...، ص ۲۳۳-۲۵۷



ادامه شکل ۸- FPI اندازه‌گیری شده در برابر FPI پیش‌بینی شده داده‌های Train و Test در هر رده سنگ‌شناسی RTC

۷- نتیجه‌گیری

انتخاب پارامترهای مؤثر نیز برهمین اساس صورت گرفته است و چنانچه هدف تخمین عملکرد ماشین *TBM* باشد، مسلماً بایستی تغییراتی در پارامترها و وزندهی آنها صورت گیرد. به این منظور پارامترهای ورودی سیستم *RMR* شامل *UCS*، *RQD*، *Jc* و *Js* که اغلب در پروژه‌های مختلف تونل‌سازی در دسترس هستند، برای تخمین *FPI* به‌روش یادگیری ماشین به‌کار رفته و روابط جدیدی توسعه داده شده است. با در نظر گرفتن رده سنگ‌شناسی در مدل‌سازی، مقدار R^2 به میزان قابل توجهی افزایش یافته و این امر اهمیت پارامتر سنگ‌شناسی را در حفاری در سنگ سخت نشان می‌دهد.

تاکنون مدل‌های تجربی مختلفی برای پیش‌بینی عملکرد دستگاه *TBM* معرفی شده‌اند و تلاش‌های زیادی نیز توسط محققان مختلف برای پیش‌بینی عملکرد *TBM* بر اساس سیستم‌های طبقه‌بندی توده‌سنگ انجام شده است. از میان سیستم‌های طبقه‌بندی توده‌سنگ، سیستم *RMR* همبستگی بهتری با نرخ نفوذ *TBM* نشان می‌دهد، که این امر به دلیل استفاده از *UCS* به عنوان پارامتر ورودی این سیستم است. سیستم *RMR* نیز همانند دیگر سیستم‌های طبقه‌بندی، برای تحلیل از نظر پایداری تونل و طراحی ساپورت توسعه یافته و

۸- مراجع

- Armaghani, D. J., Mohamad, E. T., Narayanasamy, M. S., Narita, N., Yagiz, S. (2017). Development of hybrid intelligent models for predicting TBM penetration rate in hard rock condition. *Tunnel Under. Space Technol.*, 63, 29-43.
- 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 Tunneling Congress*, Seoul, South Korea.
- Bruland, A. (1998). Hard rock tunnel boring. Ph.D. Thesis, *Norwegian University of Science & Technology*, Trondheim.
- Fatemi, S.A. (2016). Prediction of TBM penetration rate by rock mass classification system. Ph.D. Thesis, *Tarbiat Modares University*, Tehran, Iran.
- Gholami, M., Shahriar, K., Sharifzadeh, M., Hamidi, J.K. (2012). A comparison of artificial neural network & multiple regression analysis in TBM performance prediction. *ISRM Regional Symposium-7th Asian Rock Mechanics Symposium*: International Society for Rock Mechanics.
- Gong, Q., Lu, J., Xu, H., Chen, Z., Zhou, X., Han, B. (2021). A modified rock mass classification system for TBM tunnels & tunneling based on the HC method of China. *Int. J. Rock Mech. Min. Sci.*, 137, 104551.
- Grima, A., Bruines, M., Verhoef, P. N. W. (2000). Modeling tunnel boring machine performance by neuro-fuzzy methods. *Tunnel Under. Space Technol.*, 15(3), 259-269.
- 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.
- Hassanpour, J., Rostami, J., Khamchian, M. (1402). *Engineering Geology & Tunneling: Evaluation of TBM Performance in Rock Tunnels*, *Tehran University Press*, 479 pages.

- Hassanpour, J., Rostami, J., Khamehchiyan, M., Bruland, A. (2009). Developing new equations for TBM performance prediction in carbonate-argillaceous rocks: a case history of Nowsod water conveyance tunnel. *Geomech. Geoen. Int. J.*, 4, 287-297.
- 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.
- 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.
- Hastie, T., Tibshirani, R., Friedman, J. (2009). The Elements of Statistical Learning, Data Mining, Inference & Prediction. *Springer New York: Springer Series in Statistics*: 2nd Edition, 745p.
- He, B., Armaghani, D. J., & Lai, S. H. (2022). A Short Overview of Soft Computing Techniques in Tunnel Construction. *The Open Construction & Building Technology Journal*, 16(1), 1-6.
- Jain, P. (2014). Evaluation of engineering geological & 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).
- 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.
- Koopialipour, M., Nikouei, S. S., Marto, A., Fahimifar, A., Jahed Armaghani, D., Mohamad, E. T. (2019). Predicting tunnel boring machine performance through a new model based on the group method of data handling. *Bulletin of Engineering Geology & the Environment*, 78(5), 3799-3813.
- Nelson, P. (1983). Tunnel boring machine performance in sedimentary rock. Ph.D. Thesis, *Cornell University*, Ithaca, NY.
- Pourhashemi, S. M., Ahangari, K., Hassanpour, J., Eftekhari, M. (2021). TBM performance analysis in very strong & massive rocks; case study: Kerman water conveyance tunnel project, Iran. *Geomech. Geoen. Int. J.*, <https://doi.org/10.1080/17486025.2021.1912410>.
- Rostami, J. (1997). Development of a force estimation model for rock fragmentation with disc cutters through theoretical modelling & physical measurement of crushed zone pressure. Ph.D. Thesis, *Colorado School of Mines*, Golden, Colorado, USA.
- Rostami, J. (2016). Role of rock mass classification in TBM performance prediction, Where Are We Now, Where Are We Heading. *International Conference on Tunnel Boring Machines in Difficult Grounds (TBM-DIGS)*, Istanbul-Turkey.
- Salimi, A. (2021). Investigation & Evaluation of Rock Mass Characteristics for Development of New TBM Performance Prediction Model in Hard Rock Conditions. Ph.D. Thesis, *Stuttgart University*, Germany.
- Salimi, A., Rostami, J., Moormann, C. (2019). Application of rock mass classification systems for performance estimation of rock TBMs using regression tree & artificial intelligence algorithms. *Tunnel Under. Space Technol.*, 92, 103046. <https://doi.org/10.1016/j.tust.2019.103046>.

- Salimi, A., Rostami, J., Moormann, C., & Delisio, A. (2016). Application of non-linear regression analysis & artificial intelligence algorithms for performance prediction of hard rock TBMs. *Tunnel Under. Space Technol.*, 58, 236–246.
- 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.
- SCE Company. (2004). Geological & Engineering Geological Report for Ghomrood Water Conveyance Tunnel Project (Lots 3 & 4), Unpublished report.
- SCE Company. (2006). Geological & Engineering Geological Report for Karaj Water Conveyance Tunnel Project (Lot1), Unpublished report.
- Yagiz, S., Karahan, H. (2011). Prediction of hard rock TBM penetration rate using particle swarm optimization. *Int. J. Rock Mech. Min. Sci.*, 48(3), 427–433.
- Zhou, J., Bejarbaneh, B. Y. (2019). Forecasting of TBM advance rate in hard rock condition based on artificial neural network & genetic programming techniques. *Bulletin of Engineering Geology & the Environment*. doi.org.10.1007.s10064-019-01626-8.

Prediction of TBM performance in different rock types using input parameters of RMR by applying ML-based regression analysis

A. Dardashti¹; R. Ajalloeian^{2*}; J. Rostami³; J. Hassanpour⁴; A. Salimi⁵

1- PhD Student of Engineering Geology; Faculty of Science, The University of Isfahan, am.dardashti@gmail.com

2- Professor of Engineering Geology; Faculty of Science, The University of Isfahan, rasajl@sci.ui.ac.ir

3- Professor of Rock Mechanics; Earth Mechanics Institute, Colorado School of Mines, rostami@mines.edu

4- Associate Professor of Engineering Geology; School of Geology, College of Science, The University of Tehran, hassanpour@ut.ac.ir

5- Dr.-Ing. Geotechnical Engineering/Tunneling & Rock Engineering; ZETCON Ingenieur GmbH, Berlin Branch, ali.r.salimi83@gmail.com

Received: 21 Jul 2023; Accepted: 24 Nov 2023

DOI: 10.22044/tuse.2023.13396.1480

Keywords

TBM performance
RMR classification system
Regression analysis
Machine learning

Extended Abstract

Summary

Despite the widespread use of tunnel boring machines (TBMs) in tunneling projects, accurate estimates of their performance, especially in complex geological conditions, can still be challenging.

The aim of this study is to investigate the possibility of using RMR rock mass classification system parameters to predict the TBM performance in different rock types, using regression analysis based on machine learning algorithms. Therefore, real machine performance data, as well as geological and geomechanical data, were collected from 10 tunneling projects in a comprehensive database with 523 tunnel sections in different rock types and were used to develop new relationships to predict the field penetration index (FPI) based on input parameters of the RMR classification system. Since different rock types have different textures, structures, and mineralogical compositions and respond differently to machine shear forces, combining the effects of rock type in the models for prediction of TBM performance can improve the accuracy of estimates. These relationships can be especially useful in the design and planning of a tunneling project. This study aims to investigate the possibility of using the input parameters of the RMR rock mass classification system to develop TBM performance prediction relationships using regression analysis based on machine learning (ML) algorithms. New equations can lead to estimating the performance of the TBM under different geological conditions and taking into account the main and effective parameters.

Introduction

Many efforts have been made by researchers to predict the TBM performance based on rock mass classification systems. The RMR classification system shows a better correlation with the TBM penetration rate that is due to the use of uniaxial compressive strength (UCS) as an input parameter in this classification system. In most tunneling projects, input parameters of the RMR classification system are available. It should be noted that the RMR system, like other rock mass classification systems, has been developed to classify the conditions of the rock mass in terms of tunnel stability and support design, and the selection of effective parameters has also been based on this, and if the goal is to use the input parameters of the RMR system to predict the TBM performance, changes should certainly be made to the input parameters and weights.

Methodology and Approaches

To develop empirical equations based on RMR parameters, ML methods, which use supervised learning techniques, have been implemented. In this regard, first, the classic regression algorithm, and then, more modern algorithms, including stepwise regression and regularization algorithms, including Lasso and Ridge regression algorithms have been implemented.

Results and Conclusions

The input parameters of the RMR system, which are often available in tunneling projects, have been used to estimate field penetration index (FPI) as a result of applying ML methods, and new relationships have been developed. Taking into account the rock type in modeling, the TBM performance has increased significantly, indicating the importance of the lithology in boring.
